


*GAZI*  
*JOURNAL OF*  
**ENGINEERING**  
**SCIENCES**



# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### EDİTÖR / EDITOR - IN - CHIEF

**İsmail ŞAHİN**

Gazi University, Ankara, Turkey  
e-mail: [editorgjes@gmail.com](mailto:editorgjes@gmail.com)

### YARDIMCI EDİTÖRLER / ASSOCIATE EDITORS

**Harun GÖKÇE**

Gazi University  
e-mail: [harungokce@gazi.edu.tr](mailto:harungokce@gazi.edu.tr)

**Murat DÖRTERLER**

Gazi University  
e-mail: [dorterler@gazi.edu.tr](mailto:dorterler@gazi.edu.tr)

### ALAN EDİTÖRLERİ / SECTION EDITORS

**Abdullah AKDOĞAN**

Pamukkale University

**Adem TEKEREK**

Gazi University

**Alper BÜYÜKKARAGÖZ**

Gazi University

**Amin MIRZAPOUR**

Zanjan Islami Azad University

**Ayhan AYTAÇ**

National Defense University

**Bülent ÖZKAN**

Gazi University

**Erdem CÜCE**

Recep Tayyip Erdoğan University

**Fecir DURAN**

Gazi University

**Fatih ŞAHİN**

Gazi University

**G. Serdar TOMBUL**

ASELSAN

**Halil KARAKOÇ**

Hacettepe University

**Hüseyin GÖKÇE**

Çankırı Karatekin University

**M. Hanefi CALP**

Ankara Hacı Bayram Veli University

**Mustafa BOZ**

Gazi University

**Mustafa GÜNAY**

Karabük University

**Serhat KARAP**

TUBİTAK-SAGE

**Tayfun MENLİK**

Gazi University

**Umit ATİLA**

Gazi University

### YAYIN DANIŞMA KURULU / ADVISORY BOARD

**Adnan SÖZEN**

Gazi University, Turkey

**Andrew PINKERTON**

Lancaster University, England

**Bekir Sami YILBAŞ**

King Fahd University, Sudia Arabia

**Farzollah MIRZAPOUR****Majid MEGHDADI**

University of Zanjan, Iran

**Mustafa KURT**

Gazi University, Turkey

**Nowruz ALLAHVERDİ**

Karatay University, Turkey

**Reza Negarastani**

# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

University of Zanjan, Iran

**Herbert M. REYNOLDS**  
Michigan State University, USA

**Jamal KHATIB**  
University of Wolverhampton, England

**John KINUTHIA**  
University of South Wales, England

**Jonathan C. BORG**  
University of Malta, Malta

**Hossam KISHAWY**  
University of Ontario Technology, Canada

**Kürşad SEZER**  
Gazi University, Turkey

RIETEX, England

**Salman NISAR**  
National University of Sci. and Tech.,  
Pakistan

**Shahin JALILI**  
Tebriz University, Iran

**Şakir TAŞDEMİR**  
Selçuk University, Turkey

**Tahsin Tecelli ÖPÖZ**  
John Moores University, England

**Yasir JOYA**  
GIK Institute, Pakistan

### **DİL EDİTORLERİ / LANGUAGE EDITORS**

**Türkçe/Turkish:** V. Savaş YELOK (Hacı Bayram Veli  
University)

**İngilizce/English:** H. Kürşad SEZER (Gazi University)

### **TEKNİK EDİTÖR / TECHNICAL EDITOR**

**Neslihan TOP**  
Gazi University

**Nurullah YÜKSEL**  
Gazi University

e-mail: [editorgjes@gmail.com](mailto:editorgjes@gmail.com)

### **BU SAYININ HAKEMLERİ / REVIEWER OF THIS ISSUE**

Abdulkadir KARACI

Adeviye ERDOĞAN

Ayhan ARISOY

Bekir AKSOY

Birkan BÜYÜKARIKAN

Ebru YILMAZ İNCE

Enes AÇIKGÖZOĞLU

Ercüment GÜVENÇ

Erdal AYDEMİR

Ersin ATAY

Fatih YİĞİT

Fatma Gülşah TAN

Ferdi SARAC

Gamze YAKUT

Gül Fatma TÜRKER

Gürcan ÇETİN

Hamit ARMAĞAN

İbrahim Arda CANKAYA

İsmail Serkan ÜNCÜ

Kemal Muhammet ERTEN

Mehmet BİLEN

Mehmet BİLEN

Mehmet KAYAKUŞ

Mevlüt ERSOY

Mevlüt ERSOY

Muhammed Abdulhamid KARABIYIK

Murat İNCE

Nilgün ŞENGÖZ

Okan ORAL

Onur SEVLİ

Osman Özkaraca

Recep ÇOLAK

Remzi GÜRFİDAN

Ulas YAMANCI



# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

**Gazi Journal of Engineering Sciences has been published three issues per year**

**CORRESPONDENCE ADDRESS :**

Gazi Akademik Yayıncılık  
Mustafa Kemal Mah. 2118 Cad. No:4C/140 Çankaya/Ankara  
Tel: +90-312-9113311 Fax: +90-312-9113312  
e-mail: [editorgjes@gmail.com](mailto:editorgjes@gmail.com)

# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### İÇİNDEKİLER / CONTENTS

Derin Öğrenme ve Öğrenme Aktarımı Algoritmalarının Drone Algılama Performansı Üzerine Etkisi <i>The Impact of Deep Learning and Transfer Learning Algorithms on Drone Detection Performance</i>	
<b>Fatma Gülşah Tan</b> .....	1-13
Çıkarımsal Otomatik Metin Özetleme Yöntemlerinin Tıp Makaleleri Kullanılarak Performans Değerlendirmesi <i>Performance Evaluation of the Extractive Methods in Automatic Text Summarization Using Medical Papers</i>	
<b>Anil Kus, Cigdem Inan Aci</b> .....	14-22
Sargılama Tabaka Sayısı ve Uzunluğunun Bazalt-FRP ile Güçlendirilmiş Kestane Kirişlerin Eğilme Özelliklerine Etkisi <i>Dynamic Mode Decomposition with Control: A Case Study of Covid-19 and Vaccination</i>	
<b>Yasemin Şimşek Türker, Şemsettin Kılınçarslan</b> .....	23-20
Hemşire Çizelgeleme Problemi için Genetik Algoritma Tabanlı Optimizasyon <i>Genetic Algorithm-Based Optimization for Nurse Scheduling Problem</i>	
<b>Gürcan Çetin, Osman Özkaraca, Ercüment Güvenç, Murat Sakal</b> .....	31-38
Covid 19 için SIR modelinin Chebyshev Polinom Çözümleri <i>Chebyshev Polynomial Solution for the SIR Model of COVID 19</i>	
<b>Demet Özdek</b> .....	39-47
DMDk ile Kovid-19 ve Aşılamaya İlişkin Bir Örnek Olay İncelemesi <i>Dynamic Mode Decomposition with Control: A Case Study of Covid-19 and Vaccination</i>	
<b>Simge Kacar Eroglu, Gamze Yuksel</b> .....	48-57
Blokzincir ve Kötü Amaçlı Yazılımların Kesişimi: Kapsamlı Bir İnceleme ve Analiz <i>The intersection of Blockchain and Malware: A Comprehensive Review and Analysis</i>	
<b>Egemen Taşkın, İbrahim Alper Doğru</b> .....	58-69
Hurma Meyvesindeki Kalite Kontrol İşlemlerinin Yapay Zeka İle Tahminlenmesi <i>Quality Control Processes In Date Fruit With Artificial Intelligence</i>	
<b>Bekir Aksoy, Mehmet Yücel, Hamdi Sayın, Nergiz Aydın, Özge Ekrem</b> .....	70-81
Zaman Serisi Problemlerinde Parametrik Model Seçimi İçin Bir Çerçeve <i>A Framework for Parametric Model Selection in Time Series Problems</i>	
<b>Muhammed Abdulhamid Karabıyık</b> .....	82-91
Derin Transfer Öğrenmeye Dayalı Pirinç Bitkisi Hastalıklarının Tespiti <i>Detection of Rice Plant Diseases Based on Deep Transfer Learning</i>	
<b>Necaattin Barışçı, Merve Güllü, İbrahim Alper Doğru</b> .....	92-99
Türkiye'deki Hafif Ticari Araç Satışlarının Makine Öğrenmesi Yöntemleriyle Tahmin Edilmesi <i>Forecasting Light Commercial Vehicle Sales in Turkey by Machine Learning Methods</i>	
<b>Mehmet Kayakuş, Mustafa Terzioğlu, Ayten Yağmur, Dilşad Erdoğan</b> .....	100-112

# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

İHA ile Ağaç Çapı ve Yüksekliği Ölçümlerinin Uzaktan Algılama ve Makine Öğrenmesi Yöntemleriyle Bütünleştirilerek Değerlendirilmesi	
<i>Evaluation of Tree Diameter and Height Measurements in UAV Data through the Integration of Remote Sensing and Machine Learning Methods</i>	
<b>Hakan Durgun, Ebru Yılmaz İnce, Murat İnce, H. Oğuz Çoban, Mehmet Eker</b> .....	113-125
Makine Öğrenme Yöntemi Kullanılarak DarkWEB Trafığı Tespiti ve Sınıflandırması	
<i>DarkWEB Traffic Detection and Classification Using Machine Learning Method</i>	
<b>Esen Gül İlgin, Yusuf Sönmez, Murat Dener</b> .....	126-140
Akıllı Kavşaklarda Trafik Hacmi Tahmini İçin Makine Öğrenmesi Modellerinin Karşılaştırılması	
<i>Comparison of Machine Learning Models For Traffic Volume Estimation at Smart Intesections</i>	
<b>Seyitali İlyas, Yalçın Albayrak</b> .....	141-150
Araç Lastiği Yüzey Aşınmalarından Makine Öğrenmesi ile Sağlamlık Sınıflandırması	
<i>Robustness Classification by Machine Learning from Vehicle Tire Surface Abrasions</i>	
<b>Remzi Gürfidan, Oğuzhan Kilim, Tuncay Yiğit, Bekir Aksoy</b> .....	151-157
Eriyik Yığıldırmalı Modelleme (FDM) İmalat Yöntemi Kullanılarak Üretilen Ürünler Üzerinde Polilaktik Asit (PLA) Malzemenin Etkisine Dair Bir İnceleme	
<i>A Review on the Impact of Polylactic Acid (PLA) Material on Products Manufactured Using Fused Deposition Modeling (FDM) Additive Manufacturing Method</i>	
<b>Abdullah Burak Keşkekeçi, Merdan Özkahraman, Hilmi Cenk Bayrakçı</b> .....	158-173
Makine Öğrenimi Teknikleri Kullanılarak Isparta İli İçin Tarımsal Ürün Önerme Sistemi	
<i>Agricultural Product Recommendation System for Isparta Province Using Machine Learning Techniques</i>	
<b>Gamze Yakut, Rabia İlknur Çay, Hasan Hüseyin Öztürk</b> .....	174-185
OECD Ülkelerinin İhraç ve İthal Edilen Ürün Gruplarına Göre Kümelenmesi	
<i>Clustering of OECD Countries by Exported and Imported Product Groups</i>	
<b>Okan Dağ</b> .....	186-200
Matematiksel Modelleme Yöntemleri ile Elmada Verim ve Vejetatif Gelişimin Tahmin Edilmesi	
<i>Predicting Yield and Vegetative Growth in Apples Using Mathematical Modeling Methods</i>	
<b>Hamit Armağan, Ersin Atay</b> .....	201-210
İnsansız Hava Araçları Kullanılarak Deforme Olmuş Karayolu Çizgilerinin Tespitinde Yapay Zekâ Yöntemlerinin Kullanılması	
<i>Using Artificial Intelligence Methods in Detecting Deformed Highway Lines Using Unmanned Aerial Vehicles</i>	
<b>Bekir Aksoy, Muzaffer Eylence, Asım Sinan Yüksel, Seyit Ahmet İnan</b> .....	211-219
Polinom Çekirdekli SVM Algoritmalarında Hiper-Parametre Optimizasyonu ve Uygulaması	
<i>Hyperparameter Optimization in Polynomial Kernel SVM Algorithms and its Application</i>	
<b>Hamit Armağan</b> .....	220-229
Derin Öğrenme Yöntemleri Kullanılarak Gerçek MR Görüntülerinden Sentetik Görüntülerin Üretilmesi	
<i>Generating Synthetic Images from Real MR Images Using Deep Learning Methods</i>	
<b>Ercüment Güvenç, Gürcan Çetin, Mevlüt Ersoy</b> .....	230-239

# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

Kurutulmuş Meyve ve Sebzelerin Gama Radyasyon Düzeylerinin Belirlenmesi ve Karşılaştırılması <i>Determination and Comparison of Gamma Radiation Levels of Dried Fruits and Vegetables</i>	
<b>Ismail Serkan Üncü, Çağatay Bilge Keleş</b> .....	240-256
Binalarda Çatlak Kontrolünde CNN Tabanlı Görüntü İşleme Ölçüm Sisteminin Kullanılması <i>Crack Control in Buildings with a CNN-based Image Processing Measurement System Method</i>	
<b>Ismail Serkan Üncü, Mehmet Kayakuş, Celal Alp Yavru, Nabi İbadov</b> .....	257-267
Evrişimli Sinir Ağı Kullanarak El yazısı Rakamların Tanınmasında Hiper Parametre Analizi <i>Hyper Parameter Analysis in Recognition of Handwritten Digits Using Convolutional Neural Network</i>	
<b>Tuncay Yiğit, Şerafettin Atmaca, Remzi Gürfidan, Recep Çolak</b> .....	268-277
Gpt-3 Sınıflandırma Modeli İle Türkçe Tweetlerin Siber Zorbalık Durumlarının Belirlenmesi <i>Determining Cyberbullying Status of Turkish Tweets with Gpt-3 Classification Model</i>	
<b>Çilem Koçak, Tuncay YİĞİT</b> .....	278-285

---

This is an open access article under the CC-BY license



# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### The Impact of Deep Learning and Transfer Learning Algorithms on Drone Detection Performance

Fatma Gülşah Tan<sup>a\*</sup>

Submitted: 15.11.2023 Revised: 04.12.2023 Accepted: 05.12.2023 doi:10.30855/gmbd.0705S01

#### ABSTRACT

With the rapid advancement of drone technologies, the use of drones has become of significant importance, particularly raising serious concerns in the areas of security and privacy. Deep learning and transfer learning artificial intelligence techniques hold promise for drone detection. However, to successfully apply these techniques, the need to develop new and efficient solutions for accurately detecting complex aerial conditions, variable speeds, and highly maneuverable drones is inevitable. In this study, the performance of training models using the EfficientNet model for drone detection was compared, and the challenges encountered were discussed, offering a perspective on potential future successes. According to the obtained results, when more layers are frozen in the transfer learning method, the required GPU memory for training decreases, leading to reduced GPU usage. This indicates that models trained with larger image sizes can be trained more quickly. Deep learning methods require more data and GPU resources, which extend the training time. In the conducted experiments, the best success rate achieved by a model trained with the deep learning method was 97.3%, while the model trained using the transfer learning method achieved the highest success rate of 99.7%. This demonstrates that transfer learning achieves higher accuracy with less data. However, the success rate obtained through the deep learning method is also considered quite satisfactory.

**Keywords:** EfficientNet, deep learning, transfer learning, object detection, drone detection

<sup>a\*</sup> Suleyman Demirel University  
Department of Information Technology,  
Isparta, Turkey  
Orcid: 0000-0002-2748-0396  
e mail: gulsah@sdnu.edu.tr

\*Corresponding author:  
gulsah@sdnu.edu.tr

### Derin Öğrenme ve Öğrenme Aktarımı Algoritmalarının Drone Algılama Performansı Üzerine Etkisi

#### ÖZ

Drone teknolojilerinin hızla gelişmesiyle birlikte, özellikle güvenlik ve gizlilik alanlarında ciddi endişelere yol açan drone kullanımı, günümüzde büyük bir önem arz etmektedir. Derin öğrenme ve öğrenme aktarımı yapay zekâ teknikleri, drone tespiti konusunda umut vaat etmektedir. Ancak, bu tekniklerin başarıyla uygulanabilmesi için, karmaşık hava koşulları, değişken hızlar ve yüksek manevra kabiliyetine sahip dronelerin doğru şekilde saptanabilmesi için yeni ve verimli çözümler geliştirme ihtiyacı kaçınılmazdır. Bu çalışmada, drone nesnelere tespiti için EfficientNet modeli kullanılarak eğitim modellerinin drone tespiti üzerindeki performansları ve karşılaşılan zorluklar karşılaştırılarak, gelecekteki potansiyel başarıları hakkında bir perspektif sunulmuştur. Elde edilen sonuçlara göre, öğrenme aktarımı yönteminde daha fazla katman dondurulduğunda, eğitim için gereken GPU belleği azalır ve GPU kullanımı düşer. Bu durum, daha büyük görüntü boyutlarıyla eğitilen modellerin daha hızlı eğitilebileceğini göstermiştir. Derin öğrenme yöntemi daha fazla veriye ve GPU kaynağına ihtiyaç duymaktadır, bu da eğitim süresini uzatmaktadır. Yapılan deneylerde derin öğrenme yöntemiyle eğitilen modelin en iyi başarı oranı %97.3, öğrenme aktarımı yöntemiyle eğitilen modelin en iyi başarı oranı ise %99.7 olarak belirlenmiştir. Bu, öğrenme aktarımı yönteminin az veriyle daha yüksek bir doğruluk oranı sağladığını göstermektedir. Ancak, derin öğrenme yöntemiyle elde edilen başarı oranı da oldukça tatmin edici bir sonuç olarak değerlendirilebilir.

**Anahtar Kelimeler:** EfficientNet, derin öğrenme, öğrenme aktarımı, nesne tespiti, drone tespiti



## 1. Giriş (Introduction)

Günümüzde nesne tespiti, otomasyon, güvenlik, sağlık hizmetleri ve daha birçok alan için kritik öneme sahiptir. İnsansız hava araçları ya da popüler adıyla dronelar, birçok farklı sektörde kullanılmakta ve bu alanda hızla yaygınlaşmaktadır. Tarım, lojistik, taşımacılık, haberleşme ve güvenlik gibi çeşitli alanlarda sağladığı avantajlar sayesinde drone teknolojileri, endüstrilerin verimliliğini artırmak ve yeni olanaklar yaratmak adına önemli bir role sahiptir. Ancak, dronelerin geniş kullanımı, güvenlik tehditlerinin ortaya çıkmasına da neden olmaktadır. Özellikle hassas bölgelerin korunması, gizlilik ihlallerinin önlenmesi ve hava sahasının güvenliği gibi önemli konular, drone tespiti ve izlenmesinin ne kadar kritik olduğunu vurgulamaktadır. Geleneksel yöntemlerin yetersiz kaldığı durumlarda, yapay zekâ drone tespitinde büyük bir umut ışığı olarak ortaya çıkmaktadır. Bu çalışma, derin öğrenme ve öğrenme aktarımı tabanlı eğitim modelleri ile drone tespiti konusunda yapılan çalışmaları inceleyerek, bu alanın mevcut durumunu değerlendirmeyi ve gelecekteki potansiyel başarıları öngörmeyi amaçlamaktadır. Ayrıca, drone tespitinin önemini ve bu alandaki zorlukları ele alarak, ilgili araştırmalara yeni bir perspektif kazandırmayı hedeflemektedir.

Son yıllarda, derin öğrenme ve öğrenme aktarımı yöntemleri, nesne tespiti alanında çarpıcı ilerlemelere yol açmıştır [1]. Derin öğrenme, büyük ve karmaşık veri setlerinden otomatik olarak öğrenme yeteneği olan yapay sinir ağları kullanarak karmaşık modeller oluşturma sürecidir. Bu yöntem, geniş veri setlerini kullanarak baştan başlayarak modelin eğitimini içerir. Ancak, bu yaklaşım, büyük miktarda veriye ve yüksek hesaplama kaynaklarına ihtiyaç duyar ve eğitim süreci uzun sürebilir. Öğrenme aktarımı, bir görev için öğrenilen bilgilerin, başka bir görevde kullanılmasıdır. Bu yöntem, önceden eğitilmiş bir modelin, yeni bir görev için hedefe daha hızlı ve daha etkili bir şekilde uygulanması için kullanılmasını içerir. Öğrenme aktarımı, daha az veriyle bile iyi sonuçlar elde etmeyi mümkün kılar ve eğitim süresini kısaltmaktadır.

Bu çalışmada, drone nesnelere tespiti için EfficientNet modeli kullanarak öğrenme aktarımı ve derin öğrenme yöntemlerinin deneysel olarak karşılaştırılması yapılmıştır. EfficientNet son 5 yılda nesne tespiti alanında geniş bir şekilde kullanılmıştır ve çeşitli uygulamalarda etkinliğini göstermiştir. EfficientNetV2 modellerinin, son teknoloji modellere kıyasla çok daha hızlı eğitildiği ve önemli ölçüde daha küçük oldukları gösterilmiştir, bu da onları nesne tespiti görevleri için daha verimli kılmaktadır [2]. Ayrıca, floresan mikroskopi görüntülerinden insan meme kanseri hücrelerinin otomatik sınıflandırılması için kullanılmış, bu da EfficientNet'in tıbbi görüntü analizi alanındaki potansiyelini vurgulamaktadır [3]. Ayrıca, öğrenme aktarımı yönteminde katman dondurma stratejilerinin kullanımının, veri artırma tekniğinin ve ince ayar tekniklerinin, Grafik İşlemci Ünitesi (Graphics Processing Unit, GPU) belleği kullanımı ve eğitim süresi üzerindeki etkisi incelenmiştir. EfficientNet, derin öğrenme tabanlı bir nesne algılama modelidir ve drone nesnelere tespiti için etkili bir çözüm sunmaktadır. Sonuç olarak, bu çalışma, drone nesnelere tespiti alanında derin öğrenme ve öğrenme aktarımı yöntemlerinin kullanılabilirliğini araştıran önemli bir çalışmayı temsil etmektedir. Elde edilecek sonuçların, drone nesnesinin tespiti konusunda daha etkili ve hızlı çözümler sunmak için gelecekteki çalışmalara ışık tutması amaçlanmaktadır.

## 2. İlgili Çalışmalar (Related Works)

Nesne tespiti, makine öğrenmesi ve görüntü işleme alanlarında yoğun bir şekilde araştırılan bir konudur. Son yıllarda, öğrenme aktarımı ve derin öğrenme yöntemlerinin kullanımı, nesne tespiti alanında büyük bir ilerleme sağlamıştır. Öğrenme aktarımı, bir görevde öğrenilen bilgilerin başka bir görevde kullanılmasını içeren bir yaklaşımdır. Derin öğrenme ise büyük ve karmaşık veri setlerinden otomatik olarak öğrenme yeteneği olan yapay sinir ağları kullanarak karmaşık modellerin oluşturulduğu bir yöntemdir. Bu çalışmalarda, farklı veri setleri, model mimarileri ve eğitim stratejileri kullanılarak drone nesnesi tespiti üzerindeki başarı oranları artırılmaya çalışılmaktadır. Bu literatür taraması, mevcut çalışmalardan elde edilen bulguların derinlemesine analizini ve öğrenme aktarımı ile derin öğrenme yöntemlerinin drone nesnesi tespiti alanında nasıl kullanılabileceği konusunda önemli bir bakış açısı sunmaktadır. Çalışmalar, nesne algılama modellerinin performansını ve genelleme yeteneğini geliştirmek için derin öğrenme ve öğrenme aktarımından yararlanmaya yönelik çeşitli teknikleri ve yaklaşımları tartışmaktadır.

Al-Emadi ve Al-Ali [4] çalışmalarında ses tabanlı drone tespiti ve tanımlamasında derin öğrenme tekniklerine odaklanmışlardır. Ses uygulamalarında derin öğrenme algoritmalarının etkinliğini vurgulayarak akustik özelliklere dayalı drone tespiti için derin öğrenmenin kullanımını önermişlerdir. Tan ve arkadaşları [5], derin öğrenme algoritmalarını nesne takip etmek için kullanarak drone takibi üzerine bir çalışma sunmuşlardır.

Lider drone ve takipçi drone olmak üzere iki drone simülasyonu gerçekleştirerek, nesne takibi ve tespiti için derin öğrenme tekniklerini kullanmışlardır. Samadzadegan ve arkadaşları [6], görünür görüntülere dayalı drone tespiti ve tanımlaması için derin evrişimli sinir ağı önermişlerdir. Bu yöntem, sadece dronelerin varlığını veya yokluğunu tespit etmekle kalmaz, aynı zamanda farklı türdeki droneleri ve kuşları birbirinden ayırt etmektedir. Derin öğrenmeyi kullanarak dronelerin tespit ve tanınmasında yüksek doğruluk elde etmişlerdir. Wang ve arkadaşları [7], derin öğrenme tabanlı tespit ve takip modüllerini entegre eden görünür ve termal drone izleme sistemi geliştirmişlerdir. Özellikle termal drone görüntüleri gibi sınırlı eğitim drone görüntüleri zorluğunu, veri artırma teknikleri geliştirerek çözmüşlerdir.

Algoritma karşılaştırması, veri kümesi analizi, ağ yapısı ve performans değerlendirmesi dahil olmak üzere nesne algılamanın farklı yönlerini keşfetmek için çok sayıda çalışma yapılmıştır. Wu ve arkadaşları [8] çalışmalarında derin öğrenme ile görsel nesne algılamadaki son gelişmelere genel bir bakış sunmuşlardır. Yaptıkları anket çalışması, dedektör mimarileri, özellik öğrenme, teklif oluşturma ve örnekleme stratejileri gibi algılama performansını etkileyen çeşitli faktörleri kapsamaktadır. Aziz ve arkadaşları [9] çalışmalarında genel nesne algılamaya odaklanmışlar ve bu alandaki son gelişmelerin kapsamlı bir incelemesini sağlamışlardır. Çalışma yaklaşık 300 yayını kapsamakta ve bölge önerisine dayalı nesne algılama yöntemlerini tartışmaktadır. Genel görüntü analizi alanında nesne algılamanın önemini ve geniş uygulama yelpazesini vurgulamışlardır. Dış hekimliği alanında, Takahashi ve arkadaşları [10] derin öğrenmeyi kullanarak dış implantlarının tanımlanmasına yönelik bir pilot çalışma gerçekleştirmişlerdir. Dış hekimliğinde nesne algılama, sınıflandırma ve tahmin görevleri için derin öğrenme yöntemlerinin kullanımının altını çizmişlerdir. Çalışma özellikle, görüntüler için derin öğrenme tabanlı nesne algılama algoritmaları kullanılarak dış hastalıklarının teşhisine odaklanmaktadır. Ayrıca, bu çalışmada derin öğrenmenin belirli alanlardaki uygulamaları da araştırılmıştır. Fu [11] nesne algılamanın geçmişini gözden geçirmiş ve son yıllarda derin öğrenme nesne algılamanın gelişimine sistematik bir giriş sağlamıştır.

Öğrenme aktarımı alanında yapılan çalışmalar incelendiğinde bu çalışmalar genel olarak önceden eğitilmiş modellerden yararlanarak ve bilgiyi bir alandan diğerine aktararak nesne algılama algoritmalarını iyileştirmeyi amaçlamaktadır. Xia ve arkadaşları [12], hava görüntülerinde nesne algılamaya odaklanmışlar ve doğal sahneler için geliştirilen nesne algılama algoritmalarının hava görüntüsü alanına transferini araştırmışlardır. ImageNet ve Bağlamdaki Microsoft Ortak Nesnelere (Microsoft Common Objects in Context, MSCOCO) gibi büyük ölçekli görüntü veri kümelerinde önceden eğitilmiş ince ayarlı ağları kullanmışlardır. Zhang ve Tao [13] nesne algılama ve semantik bölümlenme dahil olmak üzere çeşitli akış görevleri için ImageNet üzerinde önceden eğitilmiş modellerin ince ayar uygulamalarını tartışmışlardır. Ayrıca öğrenme aktarımında alan uyarlamasının önemini vurgulamışlardır. Zhao ve arkadaşları [14], denetimsiz ön eğitim kullanarak görsel nesne algılama için öğrenme aktarımında dikkate değer bir sonuç bildirmişlerdir. Çalışma sonuçlarında Momentum Kontrastı (Momentum Contrast, MoCo) yöntemi, denetimli ön eğitimden daha iyi performans elde etmiş ve etiketlerin öğrenme aktarımı için her zaman gerekli olmayabileceğini belirtmişlerdir. Shende [15], kayıp nesne tespiti için evrişimli sinir ağlarının kullanımına ilişkin bir literatür araştırması yürütmüştür. Ankette, bağlama duyarlı algılama, üretken çekişmeli ağlar, çok görevli öğrenme ve öğrenme aktarımı dahil olmak üzere farklı yaklaşımlar analiz edilmiştir. Agarwal ve arkadaşları [16], görüntü ve video işleme görevlerinin bir parçası olarak nesne algılamaya genel bir bakış sağlamıştır. Anket, çeşitli teknik yaklaşımları ve nesne algılama yöntemlerinin karşılaştırmalı analizlerini içermektedir. Athanasiadis ve arkadaşları [17], gömülü sistemler için nesne algılamada öğrenme aktarımını araştırmıştır. Yeni bir sınıf grubu için SqueezeDet sinir ağının eğitimini hızlandırmak için öğrenme aktarımı yöntemini kullanmıştır. Wang ve arkadaşları [18] Elektroensefalografi (EEG) tabanlı yorgunluk tespiti için sınıflandırma algoritmalarının gelişimini gözden geçirmişlerdir. Yorgunluk tespitinde geleneksel makine öğrenimi algoritmalarının, derin öğrenme algoritmalarının ve öğrenme aktarımı algoritmalarının kullanımını tartışmışlardır. Shen ve arkadaşları [19], Object365 üzerinde ön eğitim olarak ve öğrenilen görsel temsilleri Büyük Sözcük Örneği Segmentasyonu İçin Veri Seti (A Dataset For Large Vocabulary Instance Segmentation, LVIS) ve diğer küçük nesne algılama veri setlerinde nesne algılama için aktararak sıfır atışlı nesne algılamayı araştırmışlardır. Plata ve arkadaşları [20] manyok fitoplazma hastalığının tanınması için nesne algılamaya konvolüsyonel sinir ağlarının uygulanmasına odaklanmışlardır. Nesne algılamada daha iyi performans elde etmede özellik öğrenme ve öğrenme aktarımı ile konvolüsyonel sinir ağlarının gücünü vurgulamışlardır. Bu çalışmalar, önceden eğitilmiş modellerden yararlanma ve etki alanları arasında bilgi aktarma potansiyelini sergileyerek, öğrenme aktarımı ile nesne algılamadaki geniş uygulama yelpazesini ve ilerlemeleri toplu olarak göstermektedir.

Rahaman ve arkadaşları [21] çalışmalarında dijital göğüs röntgeni görüntülerinden Koronavirüs Hastalığı

(COVID-19) pnömonisinin otomatik olarak saptanması için sağlam bir tekniğin geliştirilmesine odaklanılmışlardır. Çalışmanın temel amacı, öğrenme aktarımı kullanırken COVID-19 pnömonisinin tespit doğruluğunu en üst düzeye çıkaran bir yöntem önermektir. Yazarlar, çeşitli genel veritabanlarını ve yakın zamanda yayınlanan makalelerden görüntüleri birleştiren bir genel veritabanı oluşturmuşlardır. Veritabanı 423 COVID-19, 1485 viral pnömoni ve 1579 normal akciğer röntgeni görüntüsünün karışımından oluşmaktadır. Önceden eğitilmiş birkaç derin konvolüsyonel sinir ağlarını eğitmek ve doğrulamak için görüntü büyütme ile birlikte öğrenme aktarımı teknikleri kullanılmıştır [22]. Bu çalışmada odaklanılan başarı oranı, göğüs röntgeni görüntülerinden COVID-19 pnömonisini tespit etme doğruluğudur. Bu çalışma ile COVID-19 tanısında yardımcı olabilecek teknolojik bir aracın geliştirilmesine katkı sağladıklarını belirtmişlerdir.

Zhu ve arkadaşları [23] çalışmalarında öğrenme aktarımı tekniklerinin Sadece Bir Kere Bak (You Only Look Once, YOLO) nesne tespiti modeline uygulanması yoluyla yoğun nesne tespiti problemlerindeki performansını artırmayı amaçlamışlardır. Çalışmalarında, farklı eğitim veri setleri kullanılarak model eğitimi gerçekleştirilmiştir. Model performansı doğruluk, hassasiyet ve F1 skoru metrikleri kullanılarak değerlendirilmiştir. YOLOv3 modelinin önceden eğitilmiş ağırlıklarının, farklı yoğunluk seviyelerindeki yollar üzerindeki nesnelere tespit etmek için eğitim verileriyle birleştirilerek kullanılabilmesi gösterilmiştir. Bu yaklaşımın, özellikle trafik yoğunluğunun yüksek olduğu yollarda ve araçların birbirine yakın seyahat ettiği yollarda nesne tespiti performansını artırdığını belirtmişlerdir. Çalışma sonuçları, YOLOv3 modeline öğrenme aktarımı uygulandığında, doğruluğun arttığını ve nesne tespiti performansının önemli ölçüde iyileştiğini göstermektedir.


Derin öğrenme ve öğrenme aktarımı, drone nesnelere tespiti alanında akademik çalışmalarda çok sınırlı bir şekilde kullanılmıştır. Yapılan literatür taramasında, bu alanda uygulama eksikliği de gözlemlenmiştir. Bu çalışmada, derin öğrenme ve öğrenme aktarımı tekniklerinin kullanılmasıyla drone nesnesi tespit performansı yapılan deneysel çalışmalarla iyileştirilmiştir. Bozkurt optimizasyon algoritması (GWO), Mirjalili ve diğerleri tarafından vahşi gri kurtların hiyerarşisi ve avlanma yönteminden esinlenilerek geliştirilmiştir [7]. Bozkurtların sürü hiyerarşisinde bireyler alfa, beta, delta ve omega rollerinden birini oynar. Alfa liderdir; grup talimatlarını takip eder. Alpha, grubun en güçlü üyesi değildir, ancak grubu yönetme açısından en iyisi olmalıdır. Beta, sürüdeki en baskın ikinci bireydir. Alfa'yı takip ederken diğerlerine hükmeder.

### 3. Materyal ve Yöntem (Material and Method)

Bu bölümde derin öğrenme ve öğrenme aktarımı yöntemleri hakkında bilgiler verilmiştir ve drone nesnesinin tespiti ile ilgili yapılan deneysel çalışmalar karşılaştırılmıştır.

#### 3.1. Derin öğrenme ile drone tespiti (Drone detection with deep learning)

Derin öğrenme, yapay sinir ağlarından ilham alarak geliştirilen ve büyük veri kümelerini kullanarak karmaşık problemleri çözmek için kullanılan bir makine öğrenme yöntemidir. Derin öğrenme, katmanlı yapılardan oluşan derin sinir ağları aracılığıyla bilgisayarların öğrenme yeteneklerini simüle etmeyi amaçlar. Bir derin öğrenme ağı, genellikle sinir hücrelerinden oluşan bir yapıya sahiptir. Bu sinir hücreleri, veri girdilerini alır, bu girdileri işler ve sonuçları üretir. Derin öğrenme ağları genellikle yarı bağlantılı veya tam bağlantılı katmanlarla birbirine bağlanan düğümlerden oluşur. Bu katmanlar, verileri daha yüksek seviyeli temsillere dönüştürmek için çeşitli matematiksel işlemleri gerçekleştirir. Derin öğrenme ağları, genellikle geriye yayılım adı verilen bir eğitim süreciyle çalışır. Bu süreçte, ağına verilen örnek veriler kullanılarak, ağı optimize eden ve hataları azaltan ağırlıklar ve parametreler ayarlanır. Derin öğrenme ağları, öğrenme süreci boyunca özellik çıkarımı ve otomatik özellik seçimi yaparak veri içindeki karmaşıklıkları algılamada etkili olabilir. Şekil 1'de derin öğrenme ile drone tespit modeli oluşturulmasına ait akış gösterilmiştir.



Şekil 1. Derin öğrenme ile drone tespiti (Drone detection with deep learning)

Derin öğrenme teknikleri kullanılarak geliştirilen drone tespit modeli aşağıda belirtilen adımları içermektedir:

1. Veri setinin hazırlanması
2. Verilerin etiketlenmesi
3. Modelin eğitilmesi
4. Modelin değerlendirilmesi ve iyileştirilmesi

Drone veri seti bilgileri [24] Tablo 1’de gösterilmiştir. Veri seti %80 eğitim, %20 doğrulama verisi olarak ayrılmıştır.

Tablo 1. Drone tespiti eğitim ve test verileri sayısı (Number of training and testing data for drone detection)

Veri Türü	Eğitim Verisi	Doğrulama Verisi
Kuş	112	29
Drone	121	31
Toplam	233	60

Drone nesnesi tespiti için eğitim modelinin oluşturulması aşamasında veri seti hazırlanırken görüntülerde bulunan nesnelere etiketlemek için LabelImg kullanılmıştır. Etiketlenen veriler EfficientNet modeli ile eğitilmiştir. Deneysel çalışmalar 9 model içermektedir.


- model1: Verilerinin %5’inden 5 iterasyonlu derin öğrenme ile öğrenme
- model2: Verilerinin %50’sinden 5 iterasyonlu derin öğrenme ile öğrenme
- model3: Verilerinin %100’ünden 5 iterasyonlu derin öğrenme ile öğrenme
- model4: Verilerinin %5’inden 25 iterasyonlu derin öğrenme ile öğrenme
- model5: Verilerinin %50’sinden 25 iterasyonlu derin öğrenme ile öğrenme
- model6: Verilerinin %100’ünden 25 iterasyonlu derin öğrenme ile öğrenme
- model7: Verilerinin %5’inden 40 iterasyonlu derin öğrenme ile öğrenme
- model8: Verilerinin %50’sinden 40 iterasyonlu derin öğrenme ile öğrenme
- model9: Verilerinin %100’ünden 40 iterasyonlu derin öğrenme ile öğrenme

Tablo 2’de farklı varyasyonlara göre oluşturulan eğitim modellerinin başarı oranları gösterilmiştir. Her model için girdi boyutu 640, aynı anda işlenecek veri sayısı değeri 16 olarak alınmıştır.

Tablo 2. Derin öğrenme modellerinin başarı oranları (Success rates of deep learning models)


Model	Başarı Oranı	Öğrenim Zamanı (Saat)
model1	%0.59	0.003
model2	%12.3	0.008
model3	%74.8	0.013
model4	%2.5	0.008
model5	%96.4	0.023
model6	%97.3	0.045
model7	%15.3	0.013
model8	%92.2	0.035
model9	%97	0.057

Şekil 2, Şekil 3 ve Şekil 4’te alınan veri sayısına göre elde edilen en iyi başarı oranına ait kayıp performans değerleri gösterilmiştir. Şekil 2’de model7 için 40 iterasyon sonucunda drone nesnelere tespitinde alınan kayıp ve performans değerleri gösterilmiştir.



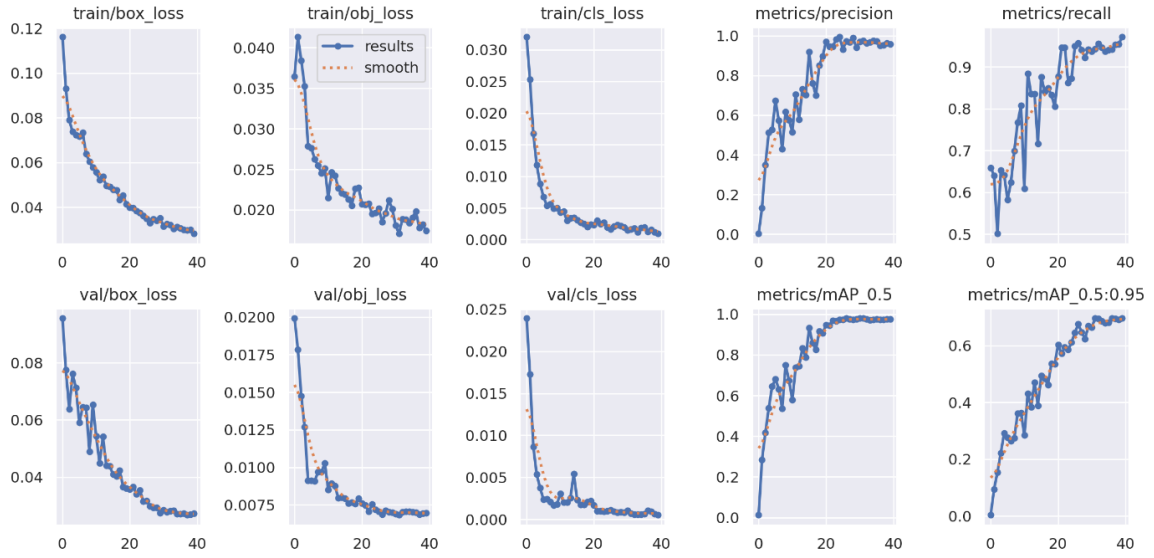
Şekil 2. model7 drone unsurları nesnesine ait kayıp ve performans ölçümleri (Loss and performance measurements for model7 drone object elements)

Şekil 3'te model5 için 25 iterasyon sonucunda drone nesnelere tespitinde alınan kayıp ve performans değerleri gösterilmiştir.



Şekil 3. model5 drone unsurları nesnesine ait kayıp ve performans ölçümleri (Loss and performance measurements for model5 drone object elements)

Şekil 4'te model6 için 25 iterasyon sonucunda drone nesnelere tespitinde alınan kayıp ve performans değerleri gösterilmiştir.



Şekil 4. model6 drone unsurları nesnesine ait kayıp ve performans ölçümleri (Loss and performance measurements for model6 drone object elements)

Şekil 4'e göre oluşturulan eğitim modeli %97.3 tahmin oranına sahiptir. Sınırlayıcı kutu, nesne kaybı ve sınıf kaybı değerleri 0, kesinlik ve geri çağırma değerleri ise 1 değerine yaklaşmaktadır. Eğitim modellerinde aşırı öğrenme olmaması için hiper parametreler deneme-yanılma yoluyla belirlenmiştir. Modellerin tahmin oranları hesaplanırken kullanılan matematiksel formüller formül 1,2,3,4 ve 5'te gösterilmiştir.

$$Kesinlik = \frac{Doğru Pozitif}{(Doğru Pozitif + Yanlış Pozitif)} \quad (1)$$

$$Geri Çağırma = \frac{Doğru Pozitif}{(Doğru Pozitif + Yanlış Negatif)} \quad (2)$$

$$F1 = 2 * \frac{Kesinlik * Geri Çağırma}{(Kesinlik + Geri Çağırma)} \quad (3)$$

$$Ortalama Hassasiyet (AP) = \sum_{k=0}^{k=n-1} [Geri Çağırma(k) - Geri Çağırma(k+1)] * Kesinlik(k) \quad (4)$$

$$Ortalama Hassasiyet Ortalaması (mAP) = \frac{1}{n} \sum_{k=1}^{k=n} AP_k \quad (5)$$


Belirtilen formüllerde kesinlik, modelin pozitif olarak tahmin ettiği örneklerin gerçekten ne kadar doğru olduğunu gösterir. Geri çağırma, gerçek pozitif örneklerin kaçınının model tarafından doğru bir şekilde tespit edildiğini gösterir. F1 skoru, kesinlik ve geri çağırma arasında bir denge kurar. Ortalama hassasiyet, nesne tespiti modellerinin doğruluğunu ölçen bir metriktir ve genellikle sınıf bazında değerlendirilir. Ortalama hassasiyet ortalaması, birden fazla sınıfa sahip bir nesne tespit problemi için kullanılan bir metriktir. Bu, her sınıfın ortalama hassasiyet ortalaması alınarak elde edilir. Şekil 5'te en iyi tahmin oranını alan modelin tespit ettiği nesnelere ait görüntüler verilmiştir.



Şekil 5. Derin öğrenme modeli ile tespit edilen drone görüntüleri (Drone images detected with the deep learning model)

### 3.2. Öğrenme aktarımı ile drone tespiti (Drone detection with learning transfer)

Öğrenme aktarımı, bir görevde öğrenilen bilgilerin, farklı ancak ilgili bir görevde kullanılmasını sağlayan bir makine öğrenme yöntemidir. Öğrenme aktarımı, kaynak görevden hedef göreve bilgi ve beceri aktarımını içerir ve genellikle sınırlı veri veya karmaşık modellerle karşılaşıldığında faydalıdır. Öğrenme aktarımı, genellikle derin öğrenme ağları ile birlikte kullanılır. Derin öğrenme ağları, birçok katmandan oluşan karmaşık bir yapıya sahiptir ve genellikle büyük veri kümeleri üzerinde eğitilir. Öğrenme aktarımı, bu derin öğrenme ağlarının öğrendiği temsilleri ve özellikleri başka bir göreve uyarlamayı amaçlar. Bir öğrenme aktarımı senaryosunda, önceden eğitilmiş bir derin öğrenme ağı genellikle bir önceden eğitilmiş model olarak adlandırılır. Önceden eğitilmiş model, yeni bir görev için kullanılmak üzere özellik çıkarımı ile hedef göreve özgü temsilleri oluşturmak üzere değiştirilir. Önceden eğitilmiş bir modelin temsilleri, hedef görevde daha iyi bir başlangıç noktası sağlayarak, daha hızlı ve daha etkili bir öğrenme süreci sağlayabilir. Şekil 6'da öğrenme aktarımı ile drone tespit modeli oluşturulmasına ait akış gösterilmiştir.



Şekil 6. Öğrenme aktarımı ile drone nesne tespiti (Drone object detection using transfer learning)

Öğrenme aktarımı teknikleri kullanılarak geliştirilen drone tespit modeli aşağıda belirtilen süreçleri içermektedir:

1. Veri setinin hazırlanması
2. Deney parametrelerinin belirlenmesi
3. Modelin eğitilmesi
4. Modelin değerlendirilmesi ve iyileştirilmesi


Öğrenme aktarımı deneyleri aynı eğitim verileri kullanılarak 3 farklı şekilde gerçekleştirilmiştir. Tablo 3'te öğrenme aktarımı ile elde edilen modellerin başarı oranları gösterilmiştir.

- model1: Eğitim verilerinin %5'inden 5 iterasyonlu öğrenme aktarımı ile öğrenme
- model2: Eğitim verilerinin %50'sinden 5 iterasyonlu öğrenme aktarımı ile öğrenme
- model3: Eğitim verilerinin %100'ünden 5 iterasyonlu öğrenme aktarımı ile öğrenme
- model4: Eğitim verilerinin %5'inden 25 iterasyonlu öğrenme aktarımı ile öğrenme
- model5: Eğitim verilerinin %50'sinden 25 iterasyonlu öğrenme aktarımı ile öğrenme
- model6: Eğitim verilerinin %100'ünden 25 iterasyonlu öğrenme aktarımı ile öğrenme
- model7: Eğitim verilerinin %5'inden 40 iterasyonlu öğrenme aktarımı ile öğrenme
- model8: Eğitim verilerinin %50'sinden 40 iterasyonlu öğrenme aktarımı ile öğrenme
- model9: Eğitim verilerinin %100'ünden 40 iterasyonlu öğrenme aktarımı ile öğrenme

Tablo 3. Öğrenme aktarımı modellerinin başarı oranları (Success rates of transfer learning models)

Model	Başarı Oranı	Öğrenim Zamanı (Saat)
model1	%83.3	0.000004
model2	%92	0.0001
model3	%97	0.0003
model4	%100	0.0001
model5	%99.1	0.00036
model6	% 99.5	0.00072
model7	%100	0.0003
model8	%98.7	0.0010
model9	%99.7	0.0016

Tablo 3'te verilen deney sonuçlarında model4 ve model7'de aşırı öğrenme olduğu için başarı grafiklerinde gösterilmemiştir. Şekil 7, Şekil 8 ve Şekil 9'da alınan veri sayısına göre elde edilen en iyi başarı oranına ait kayıp performans değerleri gösterilmiştir.



Şekil 7. model1 öğrenme aktarımı ile en iyi alınan sonuç (Best results obtained with transfer learning using model1)





Şekil 8. model5 öğrenme aktarımı ile en iyi alınan sonuç (Best results obtained with transfer learning using model5)



Şekil 9. model9 öğrenme aktarımı ile en iyi alınan sonuç (Best results obtained with transfer learning using model9)

Şekil 9'a göre model9 doğrulama veri kümesinde %99.7'lik bir doğruluk oranı elde etmiştir. Eğitim ve doğrulama kayıp grafikleri göz önüne alındığında, modelin hızla öğrenmeye başladığı ve zamanla kayıpların düştüğü görülmektedir. Ayrıca, doğruluk değerinin 1'e yaklaştığı gözlemlenmiştir. Bu sonuçlar, modelin aşırı öğrenmeden kaçındığını ve yeni veri kümesinde de başarılı olduğunu göstermektedir. Bu çalışma, öğrenme aktarımı yaklaşımının karmaşık görevleri çözmek için güçlü bir yöntem olduğunu ve drone tespiti problemlerinde yüksek doğruluk elde etmenin mümkün olduğunu vurgulamaktadır.

#### 4. Sonuçlar ve Tartışma (Results and Discussion)

Bu çalışmada, drone nesnelere tespiti için öğrenme aktarımı ve derin öğrenme yöntemlerinin etkinliği değerlendirilmiştir. Nesne tespiti alanında birçok farklı model bulunmaktadır ve kullanılacak en iyi model, belirli bir uygulama bağlamında performans, hız ve ölçeklenebilirlik gibi faktörlere bağlıdır. Hangi modelin

kullanılacağı, belirli bir görevin gereksinimlerine ve sınırlamalarına bağlıdır. Örneğin, büyük bir veri seti varsa ve yüksek doğruluk gerekiyorsa, EfficientNet gibi derin modeller tercih edilebilir. Ancak, gerçek zamanlı uygulamalarda hız ön planda ise, YOLO gibi hızlı modeller tercih edilebilir. EfficientNet, küçük boyutlu ve yüksek performanslı olmasıyla bilinen bir modeldir. Bu çalışmada EfficientNet modeli kullanılarak elde edilen sonuçlar, her iki yöntemin de başarılı sonuçlar sunduğunu göstermektedir. Derin öğrenme yöntemiyle eğitilen model %97.3, öğrenme aktarımı yöntemiyle eğitilen model %99.7 tahmin oranı sunmaktadır.

Derin öğrenme yöntemi, büyük veri setlerine ve yüksek hesaplama kaynaklarına ihtiyaç duyduğundan daha uzun bir eğitim süresi gerektirir. Ancak, yüksek doğruluk oranlarına ulaşmak için etkili bir yöntemdir. Derin öğrenme yöntemi, genellikle büyük veri setleriyle eğitildiğinde en iyi performansı gösterir. Ancak, veri seti yeterince büyük değilse veya veri setindeki sınıflar arasında dengesizlik varsa, genelleme yeteneği zayıflayabilir. Ayrıca, derin öğrenme yönteminin eğitim süreci, daha fazla hesaplama kaynağı gerektirdiği için daha uzun sürebilir. Öte yandan, öğrenme aktarımı yöntemi daha hızlı eğitim süresi ve daha az veriyle bile tatmin edici sonuçlar elde etme avantajına sahiptir. Bu yöntemde, önceden eğitilmiş bir model, hedef görev için daha hızlı bir şekilde uyarlanabilir. Veri seti yetersiz olsa bile, önceden eğitilmiş modelin genel bilgisi, yeni görevde iyi bir performans sağlayabilir. Öğrenme aktarımı yöntemi, özellikle veri seti sınırlı olduğunda veya önceden eğitilmiş modelin kullanıldığı alanlarda başarıyla uygulanmaktadır. Nesne tespitinde veri setine drone nesnesine ek olarak kuş nesnelere de dâhil edilmiştir. Daha fazla sınıf eklemenin avantajları, modelin çeşitli nesnelere daha iyi ayırt etme yeteneğini artırabilir. Bu, özellikle benzer görünümlü nesnelere tespiti konusunda modelin güçlü ve hassas olmasını sağlayabilir. Örneğin, kuşları dronelerden ayırt etmek, bu stratejinin etkisini gösteren önemli bir örnek olabilir. Ancak, yeni sınıflar eklerken dikkate alınması gereken bazı faktörler de vardır. Öncelikle, veri setinizin yeterli ve çeşitli olması önemlidir, çünkü her sınıfın temsil edildiği yeterli örnekler, modelin doğru öğrenmesini sağlar. Ayrıca, modelin daha fazla sınıfı öğrenmesi daha karmaşık hale getirebilir ve eğitim sürecini uzatabilir. Bu bağlamda, yeni sınıflar eklerken dengeli bir yaklaşım benimsemek, özellikle nesnelere arasındaki benzerlikleri ve farklılıkları göz önünde bulundurmak önemlidir. Ayrıca, performansın sürekli olarak izlenmesi ve modelin genelleme yeteneğinin korunması için düzenli değerlendirmeler yapılması da önemlidir. Sonuç olarak, sınıf sayısını artırarak başarıyı artırma stratejisi, iyi bir veri seti ve dengeli bir yaklaşım ile birleştirildiğinde etkili olabilir. Ancak, eklenen her sınıfın getirdiği zorlukları ve potansiyel karmaşıklığı anlamak önemlidir. Bu, daha fazla sınıf eklenip eklenmemesi kararını daha bilinçli bir şekilde yönetmenize yardımcı olacaktır.

Bu çalışmada, öğrenme aktarımı yönteminde katman dondurma stratejilerinin de etkisi incelenmiştir. Katman dondurma, GPU belleği kullanımını azaltmak ve eğitim süresini hızlandırmak için etkili bir yöntemdir. Modelde daha fazla katmanın dondurulması, GPU belleği ihtiyacını azaltır ve eğitim süresini kısaltır. Bu, daha büyük modellerin veya daha yüksek çözünürlüklü görüntülerin kullanıldığı durumlarda avantaj sağlar. Ancak, daha fazla katmanın dondurulması, modelin genel performansı üzerinde de etkili olabilir. Bazı durumlarda, daha fazla katmanın dondurulması, doğruluk oranını azaltabilir veya modelin daha yavaş bir şekilde öğrenmesine neden olabilir. Bu nedenle, öğrenme aktarımı yönteminde katman dondurma stratejilerinin dikkatli bir şekilde seçilmesi ve modelin hedef görevde iyi bir performans sergilemesi için deneme yanılma sürecini gerektirebilir. Her iki yöntemde drone nesnelere tespiti konusunda başarılı sonuçlar sağlamaktadır. Hangi yöntemin tercih edileceği, kullanılabilir veri miktarı, hesaplama kaynakları ve hedeflenen doğruluk oranı gibi faktörlere bağlı olacaktır. Elde edilen sonuçlar, önceki benzer çalışmaların sonuçları ile karşılaştırıldığında önemli bir ilerleme sağladığını göstermektedir. Öğrenme aktarımının, özellikle sınırlı veri durumlarında, modelin başarı oranını önemli ölçüde artırdığı ve nesne algılama alanında geniş bir uygulama potansiyeli olduğu vurgulanmaktadır. Bu çalışma, drone tespiti konusunda derinlemesine bir anlayış sağlamak ve gelecekteki benzer çalışmalara temel oluşturmak amacıyla gerçekleştirilmiştir. Gelecekteki çalışmalarda, daha büyük veri setleri ve farklı model mimarileri kullanarak daha kapsamlı araştırmalar yapılabilir. Ayrıca, farklı katman dondurma stratejilerinin etkileri daha ayrıntılı bir şekilde incelenebilir.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

[1] G. Marques, D. Agarwal, and I. de la Torre Díez, "Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network," *Appl Soft Comput*, vol. 96, p. 106691, Nov. 2020, doi: 10.1016/j.asoc.2020.106691.

- [2] M. Tan and Q. V. Le, "EfficientNetV2: Smaller Models and Faster Training," *ArXiv*, Apr. 2021. [Online]. Available: <https://arxiv.org/abs/2104.00298>. [Accessed: Sep. 25, 2023].
- [3] A. K. Kakumani, "Deep Learning Architecture For Classification Of Breast Cancer Cells in Fluorescence Microscopy Images," *International Journal of Advanced Research in Computer Science*, vol. 13, no. 06, pp. 44–44, Dec. 2022, doi: 10.26483/ijarcs.v13i6.6921.
- [4] S. Al-Emadi, A. Al-Ali, and A. Al-Ali, "Audio-Based Drone Detection and Identification Using Deep Learning Techniques with Dataset Enhancement through Generative Adversarial Networks," *Sensors*, vol. 21, no. 15, p. 4953, Jul. 2021, doi: 10.3390/s21154953.
- [5] Z. TAN, M. KARAKÖSE, and E. ÖZET, "Drone Tracking with Drone using Deep Learning," *International Journal of Computer and Information Technology(2279-0764)*, vol. 11, no. 3, Aug. 2022, doi: 10.24203/ijcit.v11i3.238.
- [6] F. Samadzadegan, F. Dadrass Javan, F. Ashtari Mahini, and M. Gholamshahi, "Detection and Recognition of Drones Based on a Deep Convolutional Neural Network Using Visible Imagery," *Aerospace*, vol. 9, no. 1, p. 31, Jan. 2022, doi: 10.3390/aerospace9010031.
- [7] Y. Wang, Y. Chen, J. Choi, and C.-C. J. Kuo, "Towards Visible and Thermal Drone Monitoring with Convolutional Neural Networks," *APSIPA Trans Signal Inf Process*, vol. 8, no. 1, 2019, doi: 10.1017/ATSIP.2018.30.
- [8] Z. Wu, S. Pan, F. Chen, G. Long, C. Zhang, and P. S. Yu, "A Comprehensive Survey on Graph Neural Networks," *IEEE Trans Neural Netw Learn Syst*, vol. 32, no. 1, pp. 4–24, Jan. 2021, doi: 10.1109/TNNLS.2020.2978386.
- [9] L. Aziz, Md. S. Bin Haji Salam, U. U. Sheikh, and S. Ayub, "Exploring Deep Learning-Based Architecture, Strategies, Applications and Current Trends in Generic Object Detection: A Comprehensive Review," *IEEE Access*, vol. 8, pp. 170461–170495, 2020, doi: 10.1109/ACCESS.2020.3021508.
- [10] T. Takahashi, K. Nozaki, T. Gonda, T. Mameno, M. Wada, and K. Ikebe, "Identification of dental implants using deep learning—pilot study," *Int J Implant Dent*, vol. 6, no. 1, p. 53, Dec. 2020, doi: 10.1186/s40729-020-00250-6.
- [11] Y. Fu, "Recent Deep Learning Approaches for Object Detection," *Highlights in Science, Engineering and Technology*, vol. 31, pp. 64–70, Feb. 2023, doi: 10.54097/hset.v31i.4814.
- [12] G.-S. Xia *et al.*, "DOTA: A Large-Scale Dataset for Object Detection in Aerial Images," in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, IEEE, Jun. 2018, pp. 3974–3983. doi: 10.1109/CVPR.2018.00418.
- [13] J. Zhang and D. Tao, "Empowering Things With Intelligence: A Survey of the Progress, Challenges, and Opportunities in Artificial Intelligence of Things," *IEEE Internet Things J*, vol. 8, no. 10, pp. 7789–7817, May 2021, doi: 10.1109/JIOT.2020.3039359.
- [14] N. Zhao, Z. Wu, R. W. H. Lau, and S. Lin, "What makes instance discrimination good for transfer learning?," Jun. 2020. [Online]. Available: <https://arxiv.org/abs/2006.06606>. [Accessed: Dec. 12, 2023].
- [15] S. Shende, "CNN Based Missing Object Detection," *Int J Res Appl Sci Eng Technol*, vol. 11, no. 4, pp. 956–959, Apr. 2023, doi: 10.22214/ijraset.2023.50138.
- [16] S. Agarwal *et al.*, "Unleashing the power of disruptive and emerging technologies amid COVID-19: A detailed review," May 2020. [Online]. Available: <https://arxiv.org/abs/2005.11507>. [Accessed: Sep. 25, 2023].
- [17] I. Athanasiadis, P. Mousoulotiis, and L. Petrou, "A Framework of Transfer Learning in Object Detection for Embedded Systems," Nov. 2018. [Online]. Available: <https://arxiv.org/abs/1811.04863>. [Accessed: Sep. 13, 2023].
- [18] F. Wang *et al.*, "Recent Advances in Fatigue Detection Algorithm Based on EEG," *Intelligent Automation & Soft Computing*, vol. 35, no. 3, pp. 3573–3586, 2023, doi: 10.32604/iasc.2023.029698.
- [19] S. Shen *et al.*, "K-LITE: Learning Transferable Visual Models with External Knowledge," Apr. 2022. [Online]. Available: <https://arxiv.org/abs/2204.09222>. [Accessed: Sep. 13, 2023].
- [20] I. T. Plata, E. B. Panganiban, D. B. Alado, A. C. Taracatac, B. B. Bartolome, and F. R. E. Labuanan, "A Recognition Method for Cassava Phytoplasma Disease (CPD) Real-Time Detection based on Transfer Learning Neural Networks," *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 12, 2021, doi: 10.14569/IJACSA.2021.0121234.
- [21] M. M. Rahaman *et al.*, "Identification of COVID-19 samples from chest X-Ray images using deep learning: A comparison of transfer learning approaches," *J Xray Sci Technol*, vol. 28, no. 5, pp. 821–839, Sep. 2020, doi: 10.3233/XST-200715.
- [22] M. E. H. Chowdhury *et al.*, "Can AI Help in Screening Viral and COVID-19 Pneumonia?," *IEEE Access*, vol. 8, pp. 132665–132676, 2020, doi: 10.1109/ACCESS.2020.3010287.
- [23] C. Zhu, J. Liang, and F. Zhou, "(Retracted) Transfer learning-based YOLOv3 model for road dense object detection," *J Electron Imaging*, vol. 32, no. 06, Jan. 2023, doi: 10.1117/1.JEI.32.6.062505.
- [24] Saha, I., "drone-bird classification," [Online]. Available: <https://www.kaggle.com/datasets/imbikramsaha/drone-bird-classification> [Accessed: Dec. 25, 2023].

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAEME 2023) and the

*abstract was published as an e-book.*

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## Performance Evaluation of the Extractive Methods in Automatic Text Summarization Using Medical Papers

Anil Kus<sup>a</sup>, Cigdem Inan Aci<sup>b</sup>

Submitted: 16.11.2023 Revised: 19.12.2023 Accepted: 19.12.2023 doi:10.30855/gmbd.0705S02

### ABSTRACT

The rapid development of technology has resulted in a surge in the volume of digital data available. This situation creates a problem for users who need assistance in locating specific information within this massive collection of data, resulting in a time-consuming process. Automatic Text Summarization systems have been developed as a more effective solution than traditional summarization techniques to address this problem and improve user access to relevant information. It is well known that researchers in the health sciences find it difficult to keep up with the latest literature due to their busy schedules. This study aims to produce comprehensive abstracts of Turkish-language scientific papers in the field of health sciences. Although abstracts of scientific papers are already available, more thorough summaries are still needed. To the best of our knowledge, no previous attempt has been made to automatically summarize Turkish language health science papers. For this purpose, a dataset of 105 Turkish papers was collected from DergiPark. Term Frequency, Term Frequency-Inverse Document Frequency, Latent Semantic Analysis, TextRank, and Latent Dirichlet Allocation algorithms were chosen as extractive text summarization methods due to their frequent use in this field. The performance of the text summarization models was evaluated using recall, precision, and F-score metrics, and the algorithms gave satisfactory results for Turkish.

**Keywords:** Automatic text summarization, extractive method, scientific papers, health sciences

<sup>a</sup> Toros University,  
Dept. of Computer Technologies,  
33140 - Mersin, Türkiye  
Orcid: 0000-0002-5964-3727  
e mail: anil.kus@toros.edu.tr

<sup>b</sup> Mersin University,  
Engineering Faculty,  
Dept. of Computer Engineering  
33343 - Mersin, Türkiye  
Orcid: 0000-0002-0028-9890

<sup>\*</sup>Corresponding author:  
anil.kus@toros.edu.tr

## Çıkarımsal Otomatik Metin Özetleme Yöntemlerinin Tıp Makaleleri Kullanılarak Performans Değerlendirmesi

### ÖZ

Teknolojinin hızlı gelişimi, mevcut dijital veri hacminin artmasına neden olmuştur. Bu durum, bu devasa veri koleksiyonu içinde belirli bilgilerin yerini bulma konusunda yardımcı ihtiyaç duyan kullanıcılar için sorun yaratarak zaman alıcı bir süreçle sonuçlanır. Otomatik Metin Özetleme sistemleri, bu sorunu gidermek ve kullanıcının ilgili bilgiye erişimini iyileştirmek için geleneksel özetleme tekniklerinden daha etkili bir çözüm olarak geliştirilmiştir. Sağlık bilimleri alanındaki araştırmacıların yoğun programları nedeniyle güncel literatürü takip etmekte zorlandıkları bilinmektedir. Bu çalışma, sağlık bilimleri alanında Türkçe dilindeki bilimsel makalelerin kapsamlı özetlerini üretmeyi amaçlamaktadır. Bilimsel makalelerin özetleri hâlihazırda mevcut olmasına rağmen, daha kapsamlı özetlere hâlâ ihtiyaç vardır. Bildiğimiz kadarıyla, Türkçe sağlık bilimi makalelerini otomatik olarak özetlemek için daha önce herhangi bir girişimde bulunulmamıştır. Bu amaçla, DergiPark'tan 105 Türkçe makaleden oluşan bir veri kümesi toplanmıştır. Çıkarımsal metin özetleme yöntemleri olarak Terim Frekansı, Terim Frekansı-Tersine Doküman Frekansı, Gizli Anlamsal Analiz, TextRank ve Gizli Dirichlet Ayırımı algoritmaları bu alanda sıklıkla kullanılmaları nedeniyle seçilmiştir. Metin özetleme modellerinin başarımlarını duyarlılık, kesinlik ve F-skor metrikleri kullanılarak değerlendirilmiş ve algoritmalar Türkçe için tatmin edici sonuçlar vermiştir.

**Anahtar Kelimeler:** Otomatik metin özetleme, çıkarımsal metot, bilimsel makaleler, sağlık bilimleri

## 1. Introduction

The health sciences are facing a rapid growth of information, and there is an urgent need for effective methods to extract useful information from massive amounts of textual data. Many important papers have been published in Turkish scientific journals, which have contributed to medical research and healthcare procedures. However, manually reviewing and analyzing these papers takes a lot of time and effort [1]. Therefore, it is essential to develop Automatic Text Summarization (ATS) approaches that are specifically adapted to Turkish medical publications to facilitate the efficient extraction of critical information and accelerate the dissemination of knowledge. In this paper, we present an approach to automatically summarize health science papers to provide researchers, healthcare professionals, and other stakeholders with concise and informative summaries that capture the essential aspects of the original texts. Using Natural Language Processing (NLP) and machine learning techniques, our proposed method aims to improve information retrieval, increase research efficiency, and contribute to advances in the medical field.

There are two main methods used in summarization tasks: extractive and abstractive. Extractive summarization systems produce summaries by directly selecting and combining the most important sentences from the source documents [2]. Abstractive summarization systems, on the other hand, aim to create new words and phrases that are not present in the original documents, using text rewriting operations such as substitution and reordering [3]. The extractive summarization method evaluates the sentences in the text and takes into account the factors that determine the importance of these sentences. For example, factors such as the frequency of a sentence, its inclusion of keywords, its relationship to other sentences, or its relationship to other important elements in the text are evaluated. Using this information, the most important sentences or paragraphs are selected and a summary is created from these selections. The extractive method uses the words in the text you present to summarize. The main difference with abstractive summarizing is that the summary is limited to the words in the original text. When the previous studies were examined, it was found that the success rate of summaries made using extractive methods was more successful than summaries made using abstractive methods [4]. Turkish is an agglutinative language belonging to the Ural-Altaic family. Therefore, some difficulties arise in the field of NLP due to these characteristics. Each suffix added to a word causes the creation of new words with different meanings [5]. Although these limitations have been partially overcome with the increasing number of recent studies, the progress made in English-based research has not been fully replicated. In this regard, the advantages offered by the structural simplicity of the English language and its wide range of applications have played an important role [4].

The motivation of this study is the need to quickly retrieve accurate information in the health field, given the time constraints of academics. While abstracts of scientific papers are currently accessible, there remains a demand for more comprehensive summaries. In addition, there is a lack of research on ATS in the Turkish language. This study aims to develop an ATS system for Turkish scientific publications in the field of health, using algorithms that include extractive summarization methods in Turkish. The proposed system includes a total of five different extractive methods, including four different statistics-based algorithms and one graph-based algorithm. The reason for choosing these methods is to observe the possible effects of summarization algorithms on Turkish, to compare the summarization success of the methods used, and also to determine the success of ATS systems in academic publications written in the field of health.

The contributions of this study can be listed as follows:

- An original dataset of 105 medical papers was collected from well-known Turkish health journals in Dergipark [6].
- Extractive methods such as Term Frequency (TF), Term Frequency-Inverse Document Frequency (TF-IDF), Latent Semantic Analysis (LSA), TextRank, and Latent Dirichlet Allocation (LDA) algorithms were used as ATS methods.
- The expanded summaries showed promising results close to human-generated summaries. It is believed that this study will contribute to Turkish NLP studies in terms of dataset and application.

The rest of the paper is organized as follows: Section 2 presents the previous studies on ATS. Section 3 presents the details of materials and methods. Section 4 presents the experimental results and discussions. The conclusion is given in Section 5.

## 2. Literature Review

The first text summarization studies were carried out in the 1950s, and many of the terms used today were first published in these early studies. The concept of "term frequency (TF)" is still the most important part of today's text summarization studies and is considered the basis of the algorithms used [7].

Turkish ATS studies were conducted after the 2000s. In his dissertation, Güran [8] created 2 new Turkish datasets for this purpose. The first dataset includes 130 news documents, which were collected from different news websites, and 130 summary documents, which were extracted by 3 different people who read these documents. The other dataset contains 20 news documents, which are shorter than the first dataset, and 20 summary documents of these documents produced by 30 different people. In the study by Kaynar et al. [9], text summarization methods based on sentence extraction were discussed and an attempt was made to determine the effectiveness of attributes in producing summaries using a genetic algorithm. The dataset used in the study includes Turkish news texts, consisting of 120 documents, and summaries of these news. In the study of Torun and Inner [10], 12,000 Turkish news items were used for the ATS. Using inference-based methods, the texts were divided into sentences, and abbreviations were not taken into account. The news items in the dataset are summarized in five sentences. Karcioğlu and Yaşa [11] presented a method that uses genetic algorithms to generate ATS models. Sentence selection based on genetic algorithms was used for summarization, after which the summary was created and evaluated using a fitness function.

Table 1 summarizes the Turkish ATS studies developed using extractive methods and their performance results.

Table 1. Previous studies on Turkish ATS using extractive methods

Author	Year	Metrics	The best results
Güran [8]	2013	F-score, ROUGE	0.59 / 0.65
Kaynar et al. [9]	2017	ROUGE	0.72
Torun and Inner [10]	2018	ROUGE	0.68
Karcioğlu and Yaşa [11]	2020	F-score, ROUGE	0.56 / 0.57

## 3. Material and Methods

This section explains the ATS architecture used in the study, the dataset prepared, and the summarization algorithms used.

### 3.1. The extractive ATS model

The extractive method aims to summarize the main points and the main idea by understanding the meaning of a text. When summarizing using the extractive method, information is extracted directly from the text and used to create a shorter summary. The basis of the extractive method is based on analyzing the structure of the text, identifying key words and recognizing important sentences or paragraphs. The algorithm evaluates the sentences in the text and takes into account the factors that determine the importance of these sentences. Figure 1 shows the components of the extractive ATS architecture used in this study.

In our study, we have used five different algorithms that are considered to be among the most widely used extractive methods. All algorithms used the pre-processed version of the texts to be summarized. Since extractive-based methods use the words of the original text, it was observed that the pre-processing stage is very important and has a direct impact on the success of the summary. As can be seen in Figure 1, the created data set goes through normalization and pre-processing stages, respectively. Texts translated into a certain format and suitable for summarization are fed into the appropriate algorithm to obtain word scores and sentence scores based on these scores. Finally, a summary output is generated based on the analysis of these scores, depending on the characteristics of the algorithm.

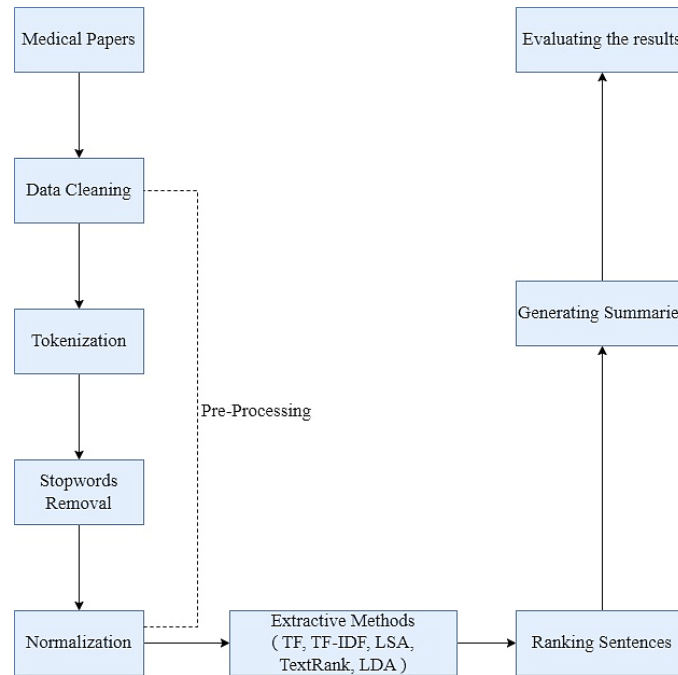


Figure 1. The architecture of the extractive ATS model

### 3.2. The dataset

ATS is a field where both extractive and abstractive methods are used, and it is well known that the dataset is critical to these methods. The dataset plays an important role in training and determining the performance of summarization models. However, it is a fact that Turkish datasets for ATS studies are limited. Qualified Turkish datasets obtained from local sources will contribute to significant progress in the field of ATS by providing a more accurate and effective summary of Turkish texts.

In this study, a dataset consisting of 105 medical research articles, reviews, and case studies was created for automatic summarizing. The dataset was created using the Dergipark [6] website, which is one of Turkey's academic research and publishing platforms and also provides an online publishing infrastructure supported by universities and other academic institutions. The papers used in the dataset were selected from the medical journals of Ankara University [12], Çukurova University [13], Ege University [14], Gazi University [15], Hacettepe University [16], Istanbul University [17], Mersin University [18] and Samsun University [19]. The selected papers were conducted in the last 5 years in the fields of gynecological diseases, brain diseases, eye diseases, heart diseases, and pediatric diseases. The reason these journals were selected for the dataset is that they are published by reputable medical faculties in Turkey.

Among the 105 articles in the dataset, the shortest document contains 6531 characters, the longest document contains 30785 characters, and the average document length is 17465.10 characters. The shortest of the original summaries is 636 characters, the longest is 2321 characters, and the average is 1501.58 characters. The shortest of the summaries produced is 1247 characters, the longest is 8137 characters, and the average is 2862.53 characters.

### 3.2. Pre-processing

Pre-processing steps are used in a variety of text mining applications, including text categorization and ATS; this step is essential for ATS [20]. Unwanted characters and incorrect data ordering are often encountered during the data collection process, which can lead to unwanted problems [21]. During the pre-processing phase of this study, the parts of the dataset were reviewed to determine their relevance to the abstract. As a result, the papers were initially split into two parts. The dataset was stripped of those elements that wouldn't be covered by the abstract, including the bibliography, English language abstract, author, and journal information. The original abstracts in Turkish, which were used to evaluate the results by comparing them with those of the ATS, were included in the second section.



The first step is data cleaning, which removes certain characters, such as numerals and punctuation, which are often considered non-essential. The second step is tokenization. In this step, a text corpus or sentence is broken down into smaller elements, such as words, phrases, or n-grams. Tokenization makes the dataset more manageable, adaptable, and amenable to analysis. It is essential for improving the accuracy of NLP modeling and analysis by making the linguistic and semantic structures of the data more visible. In order to implement ATS algorithms, it is crucial to remove stop words, which are high-frequency functional words, from a text corpus. In Turkish, words such as "ile", "şu", "fakat", "yani", etc. are considered irrelevant for certain NLP tasks. In our study, the Natural Language Toolkit (NLTK) was used to remove all stop words.

The last step is normalization for the pre-processing stage. All texts were converted to lower case, words were converted to their root form and unnecessary characters such as white spaces and short lines were removed.

### 3.3. Term Frequency (TF)

TF is a key concept in the extractive summarization approach. In this approach, the first step is to separate all words based on their root forms and organize them in tables based on their occurrence in the text. The second step is to calculate the frequency of each word, excluding common stop words [22]. These word frequency scores are then divided by the maximum frequency, which represents the overall score of the document. This result indicates the relative importance of the words. Next, sentence scores are calculated based on the length of the sentences. Finally, words with high scores are included in the summarization section by constructing sentences around them.

### 3.4. Term Frequency-Inverse Document Frequency (TF-IDF)

TF-IDF is a technique commonly used in NLP and information retrieval to evaluate the importance of words in a document. Unlike the TF method, which only considers the frequency of a term within a document, TF-IDF considers both the TF and its IDF [7]. In the TF-IDF approach, the TF still represents how often a term occurs within a given document. However, it is further normalized by dividing it by the total number of terms in the document [23]. It is calculated by taking the logarithm of the ratio between the total number of documents in the collection and the number of documents containing the specific term. The IDF value increases for terms that appear in fewer documents, indicating their potential importance.

### 3.5. Latent Semantic Analysis (LSA)

LSA is another common and powerful approach to summarizing text using the extractive method. LSA works by creating a mathematical model that represents the relationships between words and documents in a corpus. It uses a dimensionality reduction technique, such as singular value decomposition, to identify the underlying latent semantic structure. By capturing the co-occurrence patterns of words across multiple documents, LSA can reveal the semantic similarity and relatedness between different terms [24].

### 3.6. TextRank

TextRank is an extractive method used in NLP to identify important words in a text. It represents the text as a graph, with each word or sentence represented as a node and their relationships captured by connections. TextRank calculates importance scores based on these connections and identifies significant keywords within the text [25]. We used some parameters such as iterations and a damping factor to increase the accuracy of the summarizations. A range of 50 to 100 iterations is considered for high performance by determining how many times the algorithm updates the importance scores. A common value, 0.85, is used for the damping factor, which allows us to control the transition probabilities between word or sentence nodes.

### 3.7. Latent Dirichlet Allocation (LDA)

LDA is a generative statistical model used for topic modeling in NLP. It automatically discovers and extracts the underlying thematic structure in a collection of documents, providing insights into large text corpora [26]. The length of the summary is a crucial parameter as it determines the number of most representative words or phrases to be selected from each topic to form the summary. The study determines the optimal number of words based on the desired level of conciseness and information retention.

## 4. Results and Discussion

This section presents the study's performance metrics, development environment, and the performance results of each extractive method.

### 4.1. Performance metrics

Evaluating the effectiveness of ATS systems is crucial, but challenging due to the subjective nature of summarization quality. Analytical evaluation is difficult because of this subjective nature. This study used ROUGE (Recall-Oriented Understudy for Gisting Evaluation) and F-score evaluation metrics, which are commonly used in ATS studies. We chose these metrics to ensure comparability with previous studies, as they are commonly used in the literature [27].

The ROUGE family of metrics is commonly used to evaluate the quality of summarization. ROUGE-N measures similarity based on a given gram size N. For instance, ROUGE-1 assesses single-word summarization, while ROUGE-2 assesses double-word summarization. ROUGE-L is a similarity measure based on the longest common subsequence [28]. The ROUGE metrics evaluate the similarity between the abstract and the reference abstract. The study requires extended summaries, so the maximum value for n was set to 3. The formula for ROUGE-N is given by Eq. (1).

$$ROUGE - N = \frac{\text{Count of matching } n\text{-grams in generated summary}}{\text{Count of } n\text{-grams in reference summary}} \quad (1)$$

The study presented ATS models, and their accuracy was evaluated using recall and precision values. The F-score value was obtained accordingly to evaluate the similarity between system-generated summaries and actual summaries. The precision determines the accuracy level between requested documents and system-generated answers. Precision calculation is done using the formula:

$$Precision = \text{True Positives} / (\text{True Positives} + \text{False Positives}) \quad (2)$$

Recall is used for documents that are relevant to the user's query and are recalled by the system. Recall score is calculated using the formula:

$$Recall = \text{True Positives} / (\text{True Positives} + \text{True Negatives}) \quad (3)$$

F-score is obtained by combining precision and recall. To calculate the F-score, first calculate the average precision and recall using the following formula:

$$F - score = (\text{Recall} * \text{Precision}) / (\text{Precision} + \text{Recall}) \quad (4)$$

All of the Extractive ATS models have been developed in Python/Anaconda using the Zemberek [29] and SpaCy [30] libraries.

### 4.2. Performance results

A total of 105 different papers published in the field of health were used in this study to obtain extended automatic summaries. Table 2 shows the recall and precision values, Figure 2 shows the F-score values and Figure 3 shows the ROUGE-3 results obtained from the TF, TF-IDF, TextRank, LSA, and LDA algorithms used in our study.

Looking at the results, the most successful summary produced by the TF method achieved an F-score of 0.52, indicating an average level of success compared to previous studies. While the results of the TF-IDF method had an F-score of 0.38, the LSA approach produced an F-score of 0.46. It was found that the maximum achievable F-score was 0.51 for summaries generated by the TextRank algorithm. The summaries produced by LDA had an F-score of 0.55, giving them the highest performance score in the study.

Table 2. Precision and Recall values of the ATS algorithms

Algorithm	Precision	Recall
TF	0.55	0.50
TF-IDF	0.52	0.30
LSA	0.53	0.41
TextRank	0.60	0.44
LDA	0.87	0.40

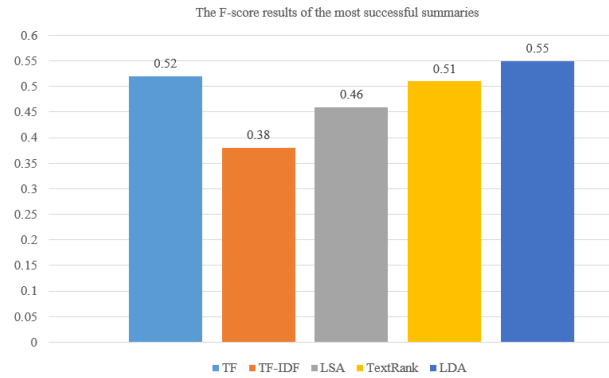


Figure 2. F-score values of the extractive ATS methods

The comparison showed that LDA emerged as the most successful approach. The reason for the superior performance of LDA can be attributed to its ability to capture the underlying topics in a collection of documents. By using the probabilistic topic modelling approach, LDA effectively identifies the main themes and concepts present in the text, allowing for more accurate and coherent summarization [24]. LDA considers the distribution of words across topics, which helps to extract important and representative phrases or sentences for summarization. This ensures that the generated summaries are more informative and concise. Furthermore, LDA is capable of handling large and diverse datasets, making it suitable for different document types and domains [31].




Figure 3. ROUGE-3 values of the extractive ATS methods

#### 4. Conclusions

As part of this research, a system was developed to automatically collect and summarize health-related texts. The system was used to summarize a total of 105 different papers. Performance analysis of the ATS system using five different extraction methods. To the best of our knowledge, there is no study in the literature that systematically collates and summarizes existing work in the field of health. It is widely recognized in the healthcare field that a comprehensive summary of existing studies would be extremely valuable to professionals, providing them with a comprehensive understanding of the subject and aiding their work.

The experiments showed that the most frequent words and keywords did not always accurately reflect the subject matter of the document. It was observed that titles or keywords improved the results and better represented the documents. In addition, due to the limited studies on Turkish ATS, the dataset used in this

research will contribute to researchers studying the Turkish language. The results showed that the summaries generated by the system were similar to the original texts. The LDA method showed an improved performance of the ATS. However, the LSA and TF-IDF methods produced less successful results compared to the LDA method.

When analyzing the results of our summarization, we found that the summaries can be considered successful. However, due to the calculation of success rates based on the original summary, they may appear less successful than they actually are. The subjective nature of summarization is considered to be one of the most challenging aspects of this field. In addition, medical papers are particularly difficult to summarize due to their rich content of technical terms, analysis results, and mathematical and formulaic expressions.

## Conflict of Interest Statement

The authors declare that there is no conflict of interest.

## References

- [1] J. P. Andersen, M. W. Nielsen, N. L. Simone, R. E. Lewiss, and R. Jagsi, "COVID-19 medical papers have fewer women first authors than expected," *eLife*, vol. 9, June 2020. doi:10.7554/elife.58807
- [2] A. See, P. J. Liu, and C. D. Manning, "Get to the point: Summarization with pointer-generator networks," *arxiv.org*, April 2017 [Online]. Available: arXiv, <https://arxiv.org/abs/1704.04368>. [Accessed: 15 Dec. 2023].
- [3] S. Narayan, S. B. Cohen, and M. Lapata, "Ranking sentences for extractive summarization with reinforcement learning," *arxiv.org*, April 2018 [Online]. Available: arXiv, <https://arxiv.org/abs/1802.08636>. [Accessed: 15 Dec. 2023].
- [4] E. Erdağı, "Extractive based automatic text summarization in Turkish texts," Ph.D. dissertation, Maltepe University, İstanbul, Turkey, 2023.
- [5] Ö. E. Gündoğdu and N. Duru, "Turkish text summarization and methods," in *Proc. of 18th Academic Computing Conference -AB 2016, Aydın, Turkey, January 30-February 5, 2016*, pp. 69–76.
- [6] DergiPark, *DergiPark Akademik* [Online]. Available: DergiPark Akademik, <https://dergipark.org.tr/tr/>. [Accessed: 16 Dec. 2023].
- [7] J. Beel, B. Gipp, S. Langer, and C. Breiting, "Research-paper recommender systems: A literature survey," *International Journal on Digital Libraries*, vol. 17, no. 4, pp. 305–338, July 2015. doi:10.1007/s00799-015-0156-0
- [8] A. Güran, "Automatic text summarization system," Ph.D. dissertation, Yıldız Technical University, İstanbul, Turkey, 2013.
- [9] O. Kaynar, Y. Işık, Y. Görmez, and F. Demirkoparan "Genetic algorithm based sentence extraction for automatic text summarization," *Journal of Management Information Systems*, vol. 3, no. 2, pp. 62-75, December 2017.
- [10] H. Torun and A. B. Inner, "Detecting similar news by summarizing Turkish news," in *Proc. of 2018 26th Signal Processing and Communications Applications Conference (SIU), Izmir, Turkey, 2018*, pp. 1-4. doi: 10.1109/SIU.2018.8404826
- [11] A. A. Karcioğlu and A. C. Yaşa, "Automatic summary extraction in texts using genetic algorithms," in *Proc. of 2020 28th Signal Processing and Communications Applications Conference (SIU), Gaziantep, Turkey, 2020*, pp. 1-4. doi: 10.1109/SIU49456.2020.9302205
- [12] Ankara Journal of Health Services Homepage, *DergiPark Akademik* [Online]. Available: DergiPark Akademik, <https://dergipark.org.tr/tr/pub/ashd>. [Accessed: 16 Dec. 2023].
- [13] Çukurova Medical Journal Homepage, *DergiPark Akademik* [Online]. Available: DergiPark Akademik, <https://dergipark.org.tr/tr/pub/cumj>. [Accessed: 16 Dec. 2023].
- [14] Ege Journal of Medicine Homepage, *DergiPark Akademik* [Online]. Available: DergiPark Akademik, <https://dergipark.org.tr/tr/pub/egtd>. [Accessed: 16 Dec. 2023].
- [15] Gazi Journal of Health Sciences Homepage, *DergiPark Akademik* [Online]. Available: DergiPark Akademik, <https://dergipark.org.tr/tr/pub/gsbdergi>. [Accessed: 16 Dec. 2023].
- [16] Journal of Hacettepe University Faculty of Health Sciences Homepage, *DergiPark Akademik* [Online]. Available: DergiPark Akademik, <https://dergipark.org.tr/tr/pub/hsbfd>. [Accessed: 16 Dec. 2023].
- [17] Journal of İstanbul Faculty of Medicine Homepage, *DergiPark Akademik* [Online]. Available: DergiPark Akademik <https://dergipark.org.tr/tr/pub/iuitfd>. [Accessed: 16 Dec. 2023].
- [18] Mersin University Journal of Health Sciences Homepage, *DergiPark Akademik* [Online]. Available: DergiPark Akademik <https://dergipark.org.tr/tr/pub/mersinsbd>. [Accessed: 16 Dec. 2023].

- [19] Journal of Samsun Health Sciences Homepage, *DergiPark Akademik* [Online]. Available: DergiPark Akademik <https://dergipark.org.tr/tr/pub/jshs>. [Accessed: 16 Dec. 2023].
- [20] S. Bal, "New methods for improving the performance of extractive Turkish text summarization," Ph.D. dissertation, Eskisehir Osmangazi University, Eskisehir, Turkey, 2022.
- [21] F. Horasan F and B. Bilen "Extractive text summarization system for news texts," *International Journal of Applied Mathematics Electronics and Computers*, vol. 8, no. 4, pp. 179-184, December 2020. doi:10.18100/ijamec.800905
- [22] N. Abdi Omar, "A user based comparative study of automatic text summarization," M.Sc. Dissertation, Institute of Science and Technology, Kocaeli University, Kocaeli, Turkey, 2018.
- [23] E. Akulker, "Extractive text summarization for Turkish using TF-IDF and pagerank algorithms," Ph.D. dissertation, The Graduate School of Natural and Applied Sciences of Atılım University, İstanbul, Turkey, 2019.
- [24] M. G. Ozsoy, F. N. Alpaslan, and I. Cicekli, "Text summarization using latent semantic analysis," *Journal of Information Science*, vol. 37, no. 4, pp. 405-417, June 2011. doi:10.1177/0165551511408848
- [25] V. Gulati, D. Kumar, D. E. Popescu, and J. D. Hemanth, "Extractive article summarization using integrated TextRank and BM25+ algorithm," *Electronics*, vol. 12, no. 2, p. 372, January 2023. doi:10.3390/electronics12020372
- [26] M. Kar, S. Nunes, and C. Ribeiro, "Summarization of changes in dynamic text collections using Latent Dirichlet Allocation model," *Information Processing & Management*, vol. 51, no. 6, pp. 809-833, November 2015. doi:10.1016/j.ipm.2015.06.002
- [27] S.W. Kim and J.M. Gil, "Research paper classification systems based on TF-IDF and LDA schemes," *Human-Centric Computing and Information Sciences*, vol. 9, no. 1, August 2019. doi:10.1186/s13673-019-0192-7
- [28] M. Zhang, C. Li, M. Wan, X. Zhang, and Q. Zhao, "ROUGE-SEM: Better evaluation of summarization using ROUGE combined with semantics," *Expert Systems with Applications*, vol. 237, p. 121364, March 2024. doi:10.1016/j.eswa.2023.121364
- [29] M. D. Akin and A. A. Akin, "Türk dilleri için açık kaynaklı doğal dil işleme kütüphanesi: ZEMBEREK," *EMO Elektrik Mühendisliği Dergisi*, vol. 431, no. 1, pp. 38-44, August 2007.
- [30] B. Srinivasa-Desikan, *Natural Language Processing and Computational Linguistics: A practical guide to text analysis with Python, Gensim, spaCy, and Keras*. Packt Publishing Ltd, 2018, pp. 250-287.
- [31] R. Rani and D. K. Lobiyal, "An extractive text summarization approach using tagged-LDA based topic modeling," *Multimedia Tools and Applications*, vol. 80, pp. 3275-3305, January 2021. doi:10.1007/s11042-020-09549-3

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### Effect of the Wrapping Layers Number and Length on the Flexural Properties of Chestnut Beams Reinforced with Basalt-FRP

Yasemin Şimşek Türker<sup>a</sup>, Şemsettin Kılınçarslan<sup>b</sup>

Submitted: 19.11.2023 Revised: 18.12.2023 Accepted: 22.12.2023 doi:10.30855/gmbd.0705S03

#### ABSTRACT

**Keywords:** Wrapping layers number, chestnut beams, Basalt-FRP, wrapping length

<sup>a</sup> Suleyman Demirel University,  
Engineering Faculty,  
Dept. of Civil Engineering  
32600 - Isparta, Türkiye  
Orcid: 0000-0002-3080-0215  
e mail: yaseminturker@sdu.edu.tr

<sup>b</sup> Suleyman Demirel University,  
Engineering Faculty,  
Dept. of Civil Engineering  
32600 - Isparta, Türkiye  
Orcid: 0000-0001-8253-9357

<sup>\*</sup>Corresponding author:  
yaseminturker@sdu.edu.tr

Traditional wooden structures often face deterioration due to elevated levels of humidity and temperature. When wood beams suffer dam-age, the typical approach has been either replacement or reinforcement with steel. However, there remains a pressing need to fortify and restore these structures, thus averting the necessity for demolition. The strengthening and rehabilitation of such existing wooden edifices have emerged as a focal point for numerous re-searchers. In recent times, Fiber reinforced polymers (FRP) are used in various areas such as buildings and bridges due to their ease of application, light weight, high strength and resistance to environmental effects. A multitude of researchers have successfully employed FRP composite materials in fortifying wooden members and structures. In this study, 70x70x1200 mm chestnut beams were strengthened 1, 2, 3 layers and 300 mm, 600 mm, 900 mm length with Basalt-FRP fabrics. Beams reinforced with fiber reinforced polymers were subjected to bending tests. As a result of the bending test, it was determined that the bending properties of the beam increased as the number of wraps and length increased.

### Sargılama Tabaka Sayısı ve Uzunluğunun Bazalt-FRP ile Güçlendirilmiş Kestane Kirişlerin Eğilme Özelliklerine Etkisi

#### ÖZ

Geleneksel ahşap yapılar genellikle yüksek nem ve sıcaklık nedeniyle bozulmayla karşı karşıya kalmaktadır. Ahşap kirişler hasar gördüğünde genel olarak çelik eleman ile güçlendirme veya yer değiştirme yapılmaktadır. Yapıların güçlendirilmesi ve restore edilmesi, yıkım zorunluluğunun ortadan kaldırılması yönünde bir ihtiyaç bulunmaktadır. Bu tür mevcut ahşap yapıların güçlendirilmesi ve rehabilitasyonu birçok araştırmacının odak noktası olarak ortaya çıkmıştır. Son zamanlarda, Fiber Takviyeli Polimerler (FRP) uygulama kolaylığı, hafif olması, dayanımının yüksek olması, çevresel etkilere karşı dirençli olması sebebiyle binalar ve köprüler gibi çeşitli alanlarda kullanılmaktadır. Çok sayıda araştırmacı, ahşap elemanların ve yapıların güçlendirilmesinde FRP kompozit malzemeleri başarıyla kullanmıştır. Bu çalışmada 70x70x1300 mm kestane kirişler 1, 2, 3 kat ve 300 mm, 600 mm, 900 mm uzunlukta Bazalt-FRP kumaş ile güçlendirilmiştir. Fiber takviyeli polimerlerle güçlendirilmiş kirişler eğilme testlerine tabi tutulmuştur. Eğilme testi sonucunda sargılama sayısı ve uzunluğu arttıkça kirişin eğilme özelliklerinin arttığı tespit edilmiştir.

**Anahtar Kelimeler:** Sarma katmanları sayısı, kestane kirişler, Bazalt-FRP, sarma uzunluğu

## 1. Introduction

Wood stands out as an exceptionally effective material, showcasing remarkable resilience under both compressive and tension loads, a quality nearly unparalleled in relation to its modest weight density [1-4]. Nevertheless, its historical reputation has not leaned towards durability, owing to its inherent characteristics. Traditionally, wooden components like beams, tasked with bearing bending loads, have often faced either substitution or fortification using conventional methods that incorporate commonplace building materials like concrete or steel [5-9].

In recent decades, various methods have been employed to reinforce wooden elements, although only a few have been successfully put into commercial use [10-12]. Nonetheless, some of these techniques have found application in fortifying existing wooden beams, particularly in cases where a complete replacement of the wooden element was not feasible, often due to a variety of reasons [13-15]. In this context, the utilization of composite materials as reinforcements for wooden elements experiencing bending loads or shear loads has garnered significant attention. This interest is further fueled by the continual advancements in FRP materials, coupled with their broader availability in diverse materials and forms [16-18]. While extensive research and development have been directed towards the utilization of FRP for reinforcing, repairing, and enhancing the performance of reinforced concrete and pre-stressed concrete structures, significantly less attention has been given to wooden and masonry structures [19]. The very nature of the material itself can necessitate reinforcement interventions for wooden elements, stemming from various factors such as an increase in dead loads, a decline in the mechanical properties of the element, or the mitigation of excessive displacements [20].

In recent times, there has been a notable surge in the utilization of FRP composites in highway bridge decks [21-23]. In particular, when employing composite materials to reinforce wood elements subjected to bending loads, it is crucial to give meticulous attention to various facets of the process. Firstly, meticulous planning of the type of intervention to be executed holds paramount importance [24-26]. This is due to the fact that there exists a multitude of techniques for reinforcing a wood element, each employing different arrangements of the FRP elements, and consequently, potentially yielding distinct outcomes [27-29]. Once a method is chosen, the subsequent phase involves the selection of the most fitting FRP elements. Given the extensive array of products and the diverse mechanical properties exhibited by FRP elements in market, designers approaching this reinforcement technique might find it challenging to make an optimal selection. FRP fabric composite materials have been used especially in strengthening wooden materials. Micelli et al. (2005) [30] investigated the possibility of attaching CFRP rods as reinforcement into glulam beams, keeping the latter case in mind. Test findings showed that adding CFRP rods improved glulam beams' ultimate capacity and stiffness by 26–82% and 8–19%, respectively. In order to assess the bond's performance. De et al. (2005) [31] performed pull-out experiments on CFRP rods that had been joined using epoxy resin and glulam components. The length of the bonded joint, the rod's surface pattern, and the direction of the wood fibers with regard to the joint's longitudinal axis were the test variables used. They used the joint test results as the basis for a local bond-slip model. Johnsson et al. (2006) [32] evaluated a total of ten specimens under four-point bending from three different series of glulam beams reinforced with rectangular pultruded CFRP bars. The experimental results were compared with analytical models in several aspects. The authors report an average improvement in the short-term flexural load-carrying capacity of 49–63%. More recently, Gentry (2011) [33] proposed the use of FRP pins positioned transversely across the plies of a glulam to reinforce wood beams in shear. The test findings show that the pinned set of glulams had a much smaller dispersion than the nonpinned specimens. Rehabilitation and repair of steel [34] and reinforced concrete [35, 36] structures. The potential to employ them to reinforce and repair timber structural components was added to these uses. One of the earliest applications for e-glass/epoxy laminates was in the mid-1990s for the restoration of shattered hardwood utility poles. Similar applications of composites have also been used to strengthen timber piles, as shown in Ref. Lopes Anido et al., 2003 [37] Hybrid glued-laminated wood articles were also produced by sandwiching thin laminates of E-glass/epoxy composite materials in between the wood layers [38]. The structural behavior of many Sitka wood beams reinforced with steel and composite materials was investigated by Gilfillan et al., 2003 [39]. Both short- and long-term mechanical stress assessments were performed on these woods. According to experimental results, adding FRP materials to frames significantly boosted their overall strength.

In studies on strengthening wooden beams with FRP, there are no studies on the bending properties of chestnut beams reinforced with basalt fiber reinforced polymers based on the number of FRP layers and FRP length. In this study, the effect of wrapping length and wrapping layer number of basalt-based fiber reinforced

polymer on the bending properties of solid chestnut beams was examined. As a result of examining the bending properties, modulus of rupture and modulus of elasticity properties were determined.

## 2. Material and Method

For this study, chestnut wood was selected, a prevalent choice in our country for producing wood composite materials, particularly for structural applications. Solid beams, crafted from Chestnut wood (*Castenea sativa*), were employed, measuring 70x70x1300 mm in size. The chestnut beams utilized were sourced from Nasreddin Forest Products (Naswood), a company located in the Antalya Organized Industrial Region. Before the solid beams were subjected to the bending test, they were kept in the air conditioning cabin at 65% relative humidity and 25°C until the equilibrium humidity reached 12%. Beams were strengthened 1, 2, 3 layers and 200 mm, 400 mm, 600 mm length with basalt-fiber reinforced polymer fabrics. The process of reinforcing with FRP fabrics involves four main steps. Initially, the material's surface is cleaned, and then a primer is applied. Subsequently, the adhesive is applied to the surface within 1–1.5 hours after the primer application. In the last stage, fiber polymer fabrics are wrapped around the adhesive-treated surface. The basalt-based MasterBrace FIB 600/100 CFS fabrics are sourced from ÜNAL TEKNİK® Practice Construction Industry and Trade. Ltd. Sti. The properties of the tested beams are given in Table 1.

Table 1. Properties of the tested beams (RLA: Reinforcement Laye, RLE: Reinforcement Length, RFT: Reinforcement fabric type, RS:

No	Reinforcement Status)				Code
	RLA	RLE	RFT	RS	
1	-	-	-	-	References
2	1	200	Basalt	+	1-200-R
3	2	200	Basalt	+	2-200-R
4	3	200	Basalt	+	3-200-R
5	1	400	Basalt	+	1-400-R
6	2	400	Basalt	+	2-400-R
7	3	400	Basalt	+	3-400-R
8	1	600	Basalt	+	1-600-R
9	2	600	Basalt	+	2-600-R
10	3	600	Basalt	+	3-600-R

Beams were subjected to four-point bending tests. Figure 1 shows schematic drawing of the 4-point bending test.




Figure 1. Schematic drawing of the 4-point bending test

The beams were subjected to testing using a 1000 kN oleo-dynamic actuator. A steel spreader beam (Figure 2) was employed to facilitate four-point bending. The distance between the two loading points was approximately one-third of the span. The tests were conducted under displacement control, with the crosshead of the electro-mechanic dynamometer or actuator moving at a rate of 5 mm/min. Bending loading persisted until either a sudden increase in loading, signifying failure, was detected by the loading instrument, or substantial damage was visually observed. In order to prevent the timber from crushing, supports and loading points, constructed from steel cylinders with a diameter of 20 mm, were utilized for beam testing. Both unreinforced and reinforced beams underwent testing following the same experimental procedure as the initial tests. This was done to ensure a fair comparison of the beam capacities. Figure 2 shows the real view of the experimental setup.





Figure 2. Bending test experimental setup

To compute the bending modulus of elasticity (MOE) and modulus of rupture (MOR), Gao et al., (2015) [40] utilized the subsequent formula:

$$MOE = \frac{\Delta P (1-s)(2l^2 + 2ls - s^2)}{8\Delta ybh^3} \quad (1)$$

$$MOR = \frac{3P_{\max}(1-s)}{2bh^2} \quad (2)$$

In the formula below, the variables represent the following parameters:

$\Delta y$ : Midspan deflection corresponding to  $\Delta P$

b: Width of the specimen

h: Depth of the specimen

$P_{\max}$ : Maximum load applied

l: Span between supports of the specimen

s: Span between loading sites of the specimen

$\Delta P$ : Difference between the upper and lower loads at the proportional limit.

### 3. Results and Discussion

The flexural strength and modulus of elasticity values of strengthened 1, 2, 3 layers and 200 mm, 400 mm, 600 mm length with basalt-fiber reinforced polymer fabrics chestnut beams are given in Figure 2 and Figure 3.




Figure 2. Experimental results of modulus of rupture

Among the beams strengthened with basalt FRP, the highest modulus of rupture value (80,70 MPa) is in the beam coded 3-600-R. The lowest modulus of rupture value (68,54 MPa) is in the beam coded 1-200-R. The modulus of rupture value of the 3-200-R coded beam is 5.60% higher than the 1-200-R coded beam and 2.52% higher than the 2-200-R coded beam. The modulus of rupture value of the beam coded 3-200-R is 41.50% higher than the reference beam. The 3-400-R coded beam is 8.20% higher than the 1-400-R coded beam and 4.40% higher than the 2-400-R coded beam. The modulus of rupture value of the beam coded 3-400-R is 45.80% higher than the reference beam. The modulus of rupture value of the 3-600-R coded beam is 2.24% higher than the 2-600-R coded beam and 3.94% higher than the 1-600-R coded beam. The beam with code 3-600-R is 100% higher than the reference beam.

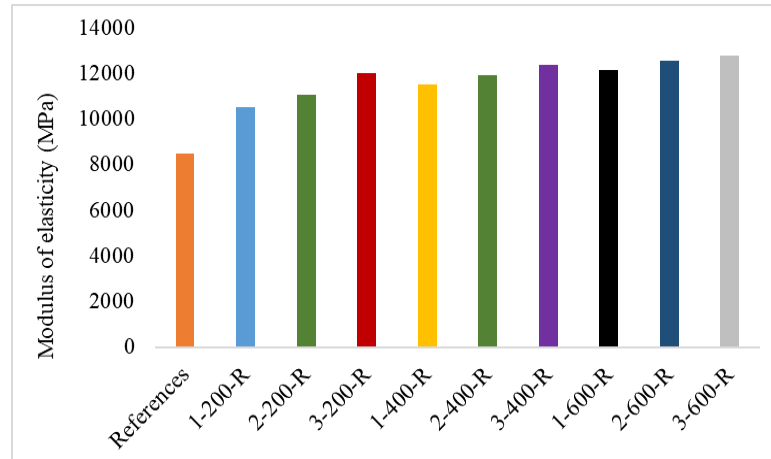


Figure 3. Experimental results of modulus of elasticity

Among the beams strengthened with basalt FRP, the highest modulus of elasticity value (12796 MPa) is in the beam coded 3-600-R. The lowest modulus of elasticity value (10506 MPa) is in the beam coded 1-200-R. The modulus of elasticity value of the 3-200-R coded beam is 7.91% higher than the 2-200-R coded beam and 12.40% higher than the 1-200-R coded beam. The beam coded 3-200-R is 29.23% higher than the reference beam. In the 3-400-R coded beam, it is 3.66% higher than the 2-400-R coded beam, and 6.96% higher than the 1-400-R coded beam. The beam coded 3-400-R is 31.49% higher than the reference beam. Among the longest wrapped beams, the 3-600-R coded beam is 1.95% higher than the 2-600-R coded beam and 5.08% higher than the 1-600-R coded beam. The beam coded 3-600-R is 33.67% higher than the reference beam. It is seen that the bending properties of the strengthened beams are improved compared to the reference beam. Flexural properties increased depending on the number and length of reinforcement layers. Pupsys et al., (2017) [41] studied 145 x 145 x 2450 mm oak wood beams treated with glass fiber reinforced polymer sheets. They found that the reinforcement improved the oak wood beams' bending characteristics. Muratoğlu (2011) [42] examined beams made of Scots pine (*Pinus sylvestris*) and Eastern beech (*Fagusorientalis* L.) wood that had been strengthened using carbon fiber-reinforced polymers. The results showed that the bending strength of the reinforced samples was 108.66 percent more. The bending characteristics of solid Fir (*Pseudotsuga menziesii* Mirb.) beams reinforced with different fiber-reinforced polymer fabric composites (flax, basalt, E-glass FRP, hybrid FRP) were examined by Wang et al., (2019) [43]. It was found that the bending characteristics of wood materials were enhanced by the fiber-reinforced polymers. After conducting an investigation on the impact of carbon-based fiber-reinforced polymer (FRP) fabric on load bearing capacity and modulus of elasticity, Kılincarslan and Simsek Turker (2019) [44] concluded that the use of FRP fabric increases the ductility and bearing capacity of wood beams. Scots pine (*Pinus sylvestris*) beams reinforced with carbon and glass-based polymer fabrics are examined by Ling et al. (2020) [45] who report that the impact of carbon-FRP reinforcement is greater than that of glass-FRP reinforcement. Uzel et al., (2018) [46] examined the bending properties of glue laminated wooden beams produced from *Pinus Pinussylvestris*. The main variables taken into account in the study are the number of laminations, adhesive material types and reinforcement meshes used on the lamination surfaces. Within the scope of the experimental study, glue laminated beams with 90 x 90 mm beam sections and 5 and 3 lamination layers were produced. Epoxy and polyurethane adhesives were used in the lamination process. In addition, aluminum, fiberglass and steel wire meshes were used on the lamination surfaces in order to increase the adhesion strength on the lamination surface. The load-displacement responses, ultimate capacities, ductility ratios, initial stiffness, energy dissipation capacities and damage mechanisms of glue laminated beams were compared with solid beams. They determined that the highest ultimate load capacities were obtained in tests of glue-laminated beams

manufactured using five laminated layers and reinforced with polyurethane glue in the direction perpendicular to the lamination surface using steel wire reinforcement meshes.

#### 4. Conclusions

Four-point bending tests were performed to investigate flexural behavior of beams strengthened by basalt-FRP. Beams were strengthened 1, 2, 3 layers and 200 mm, 400 mm, 600 mm length with basalt-fiber reinforced polymer fabrics. Main findings are as follows:

- The beam coded as 3-200-R exhibits a 5.60% increase in the modulus of rupture compared to the 1-200-R coded beam and a 2.52% increase compared to the 2-200-R coded beam.
- The modulus of rupture for the 3-200-R coded beam surpasses that of the reference beam by 41.50%. Similarly, the 3-400-R coded beam demonstrates an 8.20% and 4.40% increase in modulus of rupture compared to the 1-400-R and 2-400-R coded beams, respectively.
- The modulus of rupture for the 3-400-R coded beam exceeds that of the reference beam by 45.80%.
- The 3-600-R coded beam displays a 2.24% and 3.94% increase in modulus of rupture compared to the 2-600-R and 1-600-R coded beams, respectively.
- The beam with code 3-600-R exhibits a 100% increase compared to the reference beam.
- The beam labeled as 3-200-R demonstrates a 7.91% increase in modulus of elasticity compared to the 2-200-R coded beam and a 12.40% increase compared to the 1-200-R coded beam.
- The 3-200-R coded beam surpasses the reference beam by 29.23%. In the case of the 3-400-R coded beam, it exhibits a 3.66% increase in modulus of elasticity compared to the 2-400-R coded beam and a 6.96% increase compared to the 1-400-R coded beam.
- This results in the 3-400-R coded beam surpassing the reference beam by 31.49%. Among the longest wrapped beams, the 3-600-R coded beam showcases a 1.95% increase in modulus of elasticity compared to the 2-600-R coded beam and a 5.08% increase compared to the 1-600-R coded beam. Consequently, the 3-600-R coded beam surpasses the reference beam by 33.67%.

When wrapped with basalt-based fiber reinforced polymers, the bending properties of solid chestnut beams increased with the increase in the wrapping length and the number of wrapping layers. It is seen that the use of basalt-based FRPs in wooden beams, which deform and lose their load-bearing properties over time, increases the load-carrying capacity of the beams.

#### Conflict of Interest Statement

The authors declare that there is no conflict of interest.

#### References

- [1] H.T. Sahin, M.B. Arslan, S. Korkut and C. Sahin, "Colour changes of heat-treated woods of red-bud maple, european hophornbeam and oak," *Color Research & Application*, vol. 36, no. 6, pp. 462-466, 2011. doi: 10.1002/col.20634
- [2] S. D. Sofuoglu, M. Tosun and A. Atilgan, "Determination of the machining characteristics of Uludağ fir (*Abies nordmanniana* Mattf.) densified by compressing," *Wood Material Science & Engineering*, vol. 18, no.3, pp. 841-851, 2023. doi: 10.1080/17480272.2022.2080586
- [3] C. Sahin, M. Topay and A.A. Var, "A study on some wood species for landscape applications: surface color, hardness and roughness changes at outdoor conditions," *Wood Research*, vol. 65, no. 3, pp. 395-404, 2020. doi: 10.37763/wr.1336-4561/65.3.395404
- [4] S. Kilincarslan and Y. S. Turker, "Experimental investigation of the rotational behaviour of glulam column-beam joints reinforced with fiber reinforced polymer composites," *Composite Structures*, pp. 262, 2021. doi: 10.1016/j.compstruct.2021.113612
- [5] N. Plevris and T. C. Triantafillou, "Creep behavior of FRP-reinforced wood members," *Journal of Structural Engineering*, vol. 121, no. 2, pp. 174-186, 1995. doi: 10.1061/(ASCE)0733-9445(1995)121:2(174)
- [6] T. C. Triantafillou "Shear reinforcement of wood using FRP materials," *Journal of materials in civil engineering*, vol. 9, no. 2, pp. 65-69, 1997.
- [7] A. Wdowiak-Postulak, M. Wieruszewski, F. Bahleda, J. Prokop and J. Brol, "fibre-reinforced polymers and steel for the reinforcement of wooden elements-experimental and numerical analysis," *Polymers*, vol. 15, no. 9, pp. 2062, 2023. doi: 10.3390/polym15092062

- [8] S. Kilincarslan and Y. S. Turker, "Experimental and numerical investigation of flexural properties of solid wood materials reinforced with various FRP," *Sakarya University Journal Of Science*, vol. 27, no.4, pp. 895-901, 2023. doi: 10.16984/saufenbilder.1064612
- [9] I. Smith and M. A. Snow, "Timber: An ancient construction material with a bright future," *The Forestry Chronicle*, vol. 84, no.4, pp. 504-510, 2008. doi: 10.5558/tfc84504-4
- [10] Z. Chen, E. Zhu, J. Pan and G. Wu, "Energy-dissipation performance of typical beam-column joints in Yingxian Wood Pagoda: experimental study," *Journal of Performance of Constructed Facilities*, vol. 30, no.3, 04015028, 2015. doi: 10.1061/(ASCE)CF.1943-5509.0000771
- [11] S. Kilincarslan and Y. Simsek Turker, "Evaluation in terms of sustainability of wood materials reinforced with FRP," *Journal of Technical Sciences*, vol. 10, no.1, pp. 22-30, 2020. doi: 10.35354/tbed.615101
- [12] J. H. Ulaşan, A. Bajraktari, N. Döngel, H. Ö. Imirzi and C. Sögütü, "Modulus of elasticity and flexural behavior of glulam beams reinforced with steel mesh in different mesh openings," *Materials*, vol.16, no.12, pp. 4307, 2023. doi: 10.3390/ma16124307
- [13] G. M. Raftery and P. D. Rodd, "FRP reinforcement of low-grade glulam timber bonded with wood adhesive," *Construction and building materials*, vol. 91, pp. 116-125, 2015. doi: 10.1016/j.conbuildmat.2015.05.026
- [14] M. Bazli, M. Heitzmann and B. V. Hernandez, "Durability of fibre-reinforced polymer-wood composite members: An overview," *Composite Structures*, vol. 295, 115827, 2022. doi: 10.1016/j.compstruct.2022.115827
- [15] H. J. Dagher, T. E. Kimball, S. M. Shaler and B. Abdel-Magid, "Effect of FRP reinforcement on low grade eastern hemlock glulams" *In Proc., National Conf. on Wood Transportation Structures* (pp. 207-215). US Department of Agriculture, Forest Service, Forest Products Laboratory, October, 1996.
- [16] K. U. Schober, A. M. Harte, R. Kliger, R. Jockwer, Q. Xu and J. F. Chen "FRP reinforcement of timber structures," *Construction and building materials*, vol. 97, pp. 106-118, 2015. doi: 10.1016/J.CONBUILDMAT.2015.06.020
- [17] W. G. Davids, H. J. Dagher and J. M. Breton, "Modeling creep deformations of FRP-reinforced glulam beams," *Wood and fiber science*, vol. 32, no.4, pp. 426-441, 2000.
- [18] Y. F. Li, M. J. Tsai, T. F. Wei and W. C. Wang "A study on wood beams strengthened by FRP composite materials," *Construction and Building Materials*, vol. 62, pp. 118-125, 2014. doi: 10.1016/j.conbuildmat.2014.03.036
- [19] S. Kilincarslan, Y. Simsek Turker and M. Ince. "Prediction of Flexural Properties of Wood Material Reinforced with Various FRP Fabrics by Artificial Neural Networks," *Düzce University Journal of Science & Technology*, vol. 9, no.6, pp.188-194, 2021. doi:10.29130/dubited.1015572
- [20] A. Borri, M. Corradi and A. Grazini, "FRP reinforcement of wood elements under bending loads," *In Proceedings of the 10th International Conference on Structural Faults, Repair, (Vol. 13), July, 2003, London, UK*[Online]. Available: <https://dl.acm.org/doi/proceedings/10.1145/3447568>, [Accessed: 10 Sept. 2022]
- [21] M. Bazli, M. Heitzmann and B. V. Hernandez, "Durability of fibre-reinforced polymer-wood composite members: An overview," *Composite Structures*, vol. 295, 115827, 2022. doi: 10.1016/j.compstruct.2022.115827
- [22] H. J. Dagher, T. E. Kimball, S. M. Shaler and B. Abdel-Magid, "Effect of FRP reinforcement on low grade eastern hemlock glulams," *In Proc., National Conf. on Wood Transportation Structures* (pp. 207-215). US Department of Agriculture, Forest Service, Forest Products Laboratory, (October, 1996)
- [23] S. Kilincarslan and Y. Simsek Turker, "Strengthening of solid beam with fiber reinforced polymers," *Turkish Journal of Engineering*, vol. 7, no. 3, pp. 166-171, 2022. doi: 10.31127/tuje.1026075
- [24] Y. F. Li, M. J. Tsai, T. F. Wei and W. C. Wang, "A study on wood beams strengthened by FRP composite materials," *Construction and Building Materials*, vol. 62, 118-125, 2014. doi:10.1016/j.conbuildmat.2014.03.036
- [25] T. Smith, F. C. Ponzo, A. Di Cesare, S. Pampanin, D. Carradine, A. H. Buchanan and D. Nigro, "Post-tensioned glulam beam-column joints with advanced damping systems: testing and numerical analysis," *Journal of Earthquake Engineering*, vol. 18, no.1, pp. 147-167, 2014. doi: 10.1080/13632469.2013.835291
- [26] M. He, J. Luo, D. Tao, Z. Li, Y. Sun and G. He, "Rotational behavior of bolted glulam beam-to-column connections with knee brace," *Engineering Structures*, vol. 207, 110251, 2020. doi: <https://doi.org/10.1016/j.engstruct.2020.110251>
- [27] A. Wdowiak-Postulak, "Strengthening of structural flexural glued laminated beams of ashlar with cords and carbon laminates," *Materials*, vol. 15, no. 23, 8303, 2022. doi: 10.3390/ma15238303
- [28] N. Guo, T. Liu, M. Xu and Y. Zhao, "Influence of steel wires on the seismic performance of prestressed glulam beam-column bolted connections," *Wood Material Science & Engineering*, vol. 18, no. 2, pp. 718-731, 2023. doi:10.1080/17480272.2022.2073470
- [29] S. W. Han and S. H. Lee, "Cyclic behavior of high-performance fiber-reinforced cementitious composite corner joints," *Journal of Building Engineering*, vol. 47, pp. 1-18, 2022. doi: doi.org/10.1016/j.jobee.2021.103892

- [30] F. Micelli, V. Scialpi and A. La Tegola, "Flexural reinforcement of glulam timber beams and joints with carbon fiber-reinforced polymer rods," *Journal of Composites for Construction*, vol.4, no.9, pp.337–347, 2005. doi: 10.1061/(ASCE)1090-0268(2005)9:4(337)
- [31] L. De Lorenzis, V. Scialpi and A. La Tegola, "Analytical and experimental study on bonded-in CFRP bars in glulam wood," *Composite Part B: Engineering*, vol. 36, no.4, pp. 279– 289, 2005. doi: 10.1016/j.compositesb.2004.11.005
- [32] H. Johnsson, T. Blanksvard and A. Carolin, "Glulam members strengthened by carbon fibre reinforcement," *Materials and Structures*, 40, 47–56, 2006. Doi: 10.1617/s11527-006-9119-7
- [33] T.R. Gentry, "Performance of glued-laminated timbers with FRP shear and flexural reinforcement," *Journal of Composites for Construction*, vol. 15, no. 5, pp. 861–870, 2011. doi: 10.1061/(ASCE)CC.1943-5614.00002
- [34] A.S. Mosallam and S. Banerjee, "Enhancement in in-plane shear capacity of unreinforced masonry (URM) walls strengthened with fiber reinforced polymer composites," *Compos Part B Eng*, vol. 42, no.6, pp. 1657-70, 2011. doi: 0.1016/j.compositesb.2011.03.015
- [35] A.S. Mosallam, M.M. Taha, J.J. Kim and A. Nasr, "Strength and ductility of RC slabs strengthened with hybrid high-performance composite retrofit system," *Eng Struct*, vol. 36, pp.70-80 March 2012, 2012. doi: https://doi.org/10.1016/j.engstruct.2011.11.022
- [36] A.S. Mosallam, A. Bayraktar, M. Elmikawi, S. Pul and S. Adanur, "Polymer composites in construction: an overview," *SOJ Mater Sci Eng*, vol. 2, no.1, pp. 125, 2014.
- [37] R. Lopez-Anido, A. Michael and T.C. Sandford, "Experimental characterization of FRP composite wood pile structural response by bending tests," *Mar Struct*, vol. 16, 257, 74, 2003. doi: 10.1016/S0951-8339(03)00021-2
- [38] J. Brody, A. Richard, K. Sebesta, K. Wallace, Y. Hong and R. Anido, "FRP-WoodConcrete composite bridge girders. In: Advanced Technology in structural engineering," *ASCE structures congress 2000, Philadelphia, Pennsylvania, United States*, May 8–10; p. 1-10, 2000.
- [39] J.R. Gilfillan, S.G. Gilbert and G.R.H. Patrick, "The use of FRP composites in enhancing the structural behavior of timber beams," *J Reinf Plastics Compos*, vol. 22, no.15, pp.1373-88, 2003
- [40] Y. Gao, Y. Wu, X. Zhu, L. Zhu, Z. Yu and Y. Wu, "Numerical analysis of the bending properties of cathay poplar glulam," *Materials*, 8(10), 7059-7073, 2015
- [41] T. Pupsys, M. Corradi, A. Borri and L. Amess, "Bending reinforcement of full-scale timber beams with mechanically attached GFRP composite plates," *Dept. of Mechanical & Construction Engineering*, Northumbria University, July 2017. United Kingdom
- [42] A., Muratoğlu, "Reinforcement of Wood Building Components with Carbon Fiber Reinforced Polymers (CFRP) in Restoration," Karabük University, 1219-1240, 2011
- [43] B., Wang, E. V., Bachtiar, L., Yan, B., Kasal and V., Fiore, "Flax, basalt, e-glass FRP and their hybrid FRP strengthened wood beams: an experimental study," *Polymers*, vol. 11, no.8, 1255, 2019. doi: 10.3390/polym11081255
- [44] S. Kilincarslan and Y. Şimşek Turker, "The effect of strengthening with fiber reinforced polymers on strength properties of wood beams," *2<sup>nd</sup> International Turkish World Engineering and Science Congress*, November 7-10, 2019, Turkey
- [45] Z. Ling, W. Liu and J. Shao, "Experimental and theoretical investigation on shear behaviour of small scale timber beams strengthened with Fiber Reinforced Polymer composites," *Composite Structures*, 240, 111989, 2020. doi: 10.1016/j.compstruct.2020.111989
- [46] M. Uzel, A. Togay, Ö. Anil and C. Söğütü, "Experimental investigation of flexural behavior of glulam beams reinforced with different bonding surface materials," *Construction and Building Materials*, 158, pp. 149-163, 2018. doi:10.1016/j.conbuildmat.2017.10.033

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICALAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## Genetic Algorithm-Based Optimization for Nurse Scheduling Problem

Gürcan Çetin<sup>a</sup>, Osman Özkaraca<sup>b</sup>, Ercüment Güvenç<sup>c</sup>, Murat Sakal<sup>d</sup>

Submitted: 19.11.2023 Revised: 07.12.2023 Accepted: 18.12.2023 doi:10.30855/gmbd.0705S04

### ABSTRACT

**Keywords:** Genetic algorithm, nurse scheduling, optimization

<sup>a,\*</sup> Mugla Sıtkı Kocman University,  
Technology Faculty,  
Dept. of Information Systems  
Engineering  
48000 - Mugla, Türkiye  
Orcid: 0000-0003-3186-2781

<sup>b</sup> Mugla Sıtkı Kocman University,  
Technology Faculty,  
Dept. of Information Systems  
Engineering  
48000 - Mugla, Türkiye  
Orcid: 0000-0002-0964-8757

<sup>c</sup> Mugla Sıtkı Kocman University,  
Dept. of Informatics  
48000 - Mugla, Türkiye  
Orcid: 0000-0003-0053-9623

<sup>d</sup> Mugla Sıtkı Kocman University,  
Technology Faculty,  
Dept. of Information Systems  
Engineering  
48000 - Mugla, Türkiye  
Orcid: 0000-0001-6490-4795

\*Corresponding author:  
gctetin@mu.edu.tr

**Anahtar Kelimeler:** Genetik algoritma, hemşire çizelgeleme, optimizasyon

The nursing workforce problem is essentially a scheduling problem. Scheduling problems involve the efficient planning and sequencing of specific resources, aiming to find the best time schedule that meets all constraints. Genetic Algorithm can be utilized to solve scheduling problems effectively. In this study, taking into account the success of the Genetic Algorithm in scheduling problems, a software has been developed in the Python environment to ensure the optimal assignment of nurses in clinics. The Genetic Algorithm-based software operates on a population basis, seeking to find the best schedule that satisfies various tasks and constraints. During the study, the planning of nursing staff considered the possibility of different clinics within the hospital, each dealing with patients requiring different care durations. It was assumed that a nurse works according to legal restrictions. Furthermore, a 4-week period was taken into consideration during the scheduling process, and the program was executed for a total of 28 days (a total working time of 160 hours). As a result, a software solution was presented that can successfully achieve an optimal nurse assignment, enabling the complete fulfillment of patients' care requirements in a given clinic.

## Hemşire Çizelgeleme Problemi için Genetik Algoritma Tabanlı Optimizasyon

### ÖZ

Hemşire iş gücü planlama problemi temelde bir çizelgeleme problemidir. Çizelgeleme problemleri, belirli kaynakların verimli bir şekilde planlanması ve sıralanmasıyla ilgili olup, tüm kısıtlamaları karşılayan en iyi zaman çizelgesini bulmayı amaçlar. Genetik Algoritma, çizelgeleme problemlerini etkili bir şekilde çözmek için kullanılabilir. Bu çalışmada, Genetik Algoritmanın çizelgeleme problemlerindeki başarısı dikkate alınarak, hemşirelerin kliniklerde optimal bir şekilde atanmasını sağlamak amacıyla Python ortamında bir yazılım geliştirilmiştir. Genetik Algoritma tabanlı yazılım, bir nüfus temelinde çalışarak, çeşitli görevleri ve kısıtlamaları karşılayan en iyi çizelgeyi bulmaya çalışmaktadır. Çalışma sırasında, hemşire planlaması yapılırken, hastanede farklı klinikler göz önünde bulundurulmuş ve her bir serviste farklı bakım süresi gerektiren hastaların bulunduğu varsayılmıştır. Bir hemşirenin yasal kısıtlamalara göre çalıştığı varsayılmıştır. Ayrıca, çizelgeleme sürecinde 4 haftalık bir dönem dikkate alınmış ve program toplamda 28 gün (toplam çalışma süresi 160 saat) için çalıştırılmıştır. Sonuç olarak, bir klinikte hizmet alan hastaların bakım gereksinimlerini tamamen karşılayan optimal bir hemşire ataması yapabilen bir yazılım çözümü sunulmuştur.

## 1. Introduction

Hospitals, healthcare institutions, and clinics must have an adequate nursing workforce to provide quality patient care and medical services. Nurses play a fundamental role in the healthcare sector and assume a critical role in the care, treatment, and recovery processes of patients. However, ensuring the correct number and qualified nurses are assigned can be a time-consuming and complex task for administrators. This is a highly challenging problem to calculate due to various factors influencing the nursing workload [1]. These factors include the number of patients, support services provided, patient care requirements, and legal limitations. Additionally, seasonal effects or extraordinary situations like natural disasters or pandemics can significantly impact these factors [2].

The traditional methods used for nurse workforce planning are generally methods performed manually or based on simple calculations. Among these methods, the use of Excel spreadsheets, Paper-based Planning, Experience and Needs-Based Planning, Semi-Automatic Planning Tools, and Shift Management Software can be counted. On the other hand, in recent years, heuristic algorithms have been widely used to address complex scheduling problems where classical and manual methods struggle to find precise and quick solutions [3][4]. One effective optimization technique based on natural evolution processes is the Genetic Algorithm (GA) method. GAs have been widely used in various fields due to their ability to optimize multidimensional nonlinear problems [5]. GAs have been proposed as an effective method for scheduling nurses under different constraints, such as shift and day-off preferences, and have been shown to efficiently reduce infeasible solutions due to practical scheduling constraints [3]. Additionally, GAs have been used to generate high-quality nurse schedules within an acceptable computation time, indicating their applicability to real-world problems with numerous constraints [6].

The literature supports the effectiveness of GAs in addressing the nurse scheduling problem, particularly in handling various constraints, optimizing multi-objective functions, and addressing real-world scheduling instances. Leksakul and Phetsawat [6], utilized a GA with two-point crossover and random mutation to obtain optimal nurse schedules, demonstrating the effectiveness of GAs in addressing staffing and overtime challenges. In another study, Maenhout and Vanhoucke [7] presented a hybrid GA for the nurse scheduling problem, highlighting the potential of GAs in this domain. Moreover, Wibowo and Lianawati [8] introduces a multi-objective GA for optimizing nurse scheduling, emphasizing the significance of GAs in overcoming scheduling challenges in healthcare institutions [3].

In this research, considering the efficacy of Genetic Algorithms in addressing scheduling issues, a Python-based software has been created to optimize nurse assignments in clinics. The software, relying on Genetic Algorithms, operates on a population scale, aiming to discover the most suitable schedule meeting diverse tasks and constraints. The scheduling process spans a 4-week period, executed for a total of 28 days (equivalent to 160 working hours).

The paper is structured as follows: Section 2 introduces the nurse scheduling problem, and Section 3 provides an explanation of the genetic algorithm. Section 4 presents the application and its results. The concluding remarks are presented in Section 5.

## 2. Nurse Scheduling

Nurse workforce planning involves ensuring an adequate number of qualified nurses to provide quality nursing care for both patients and healthy individuals. The decline in the quality of care and service performance in hospitals is often a result of insufficient nursing staff. The planning process aims to address this issue by providing the necessary number of nurses with the required qualifications [9].

When looking at nursing workforce planning approaches in inpatient care institutions, there are factors that affect the nurse workload. These include the number of patients, support services undertaken by nurses, and the care requirements of patients. The patient count is influenced by seasonal changes, natural disasters, or pandemic situations. Additionally, the 24-hour care requirement for each patient admitted to a unit varies. For this purpose, patients are classified based on their care needs. Table 1 provides different patient types and their characteristics according to the Cheltenham patient classification scale [10]. This scale plays a critical role in optimizing nurse staffing, workload management, and patient outcomes in healthcare services.

Table 1. Patient's classification

Type	Patient condition
Patient 1	Capable of self-care and independence
Patient 2	Demands moderate nursing care, semi-independent
Patient 3	Requires comprehensive nursing care, bedridden but not incapacitated
Patient 4	Necessitates intensive nursing care, bedridden and incapacitated

On the other hand, the patient classification system categorizes patients based on care needs, illness severity, and care amount, considering individual characteristics. Its goal is to assign scores to similar-needs groups, defining required nursing care quality. This system classifies patients with diverse care needs and calculates 24-hour care requirements for optimal nurse staffing, ensuring patients' needs are met. In Table 2, sample patient care durations are provided for patients admitted to services in a hospital. According to Table 2, the number of beds in the cardiovascular surgery service is 28. Observation data for three different time intervals are given for this service. These observations represent 8-hour intervals within a 24-hour period. In the first observation, the number of type 1 patients is 15, type 2 patients is 11, and type 3 patients is 2. There are no type 4 patients in this service. The required care need for these patients is calculated as 51.50 for the first and second observations and 39.50 for the third observation. The average care need is 15.02 for the first and second observations and 11.52 for the third observation. In this study, the second and third observations are combined, and a night shift with a working time of 16 hours is planned.

Table 2. Sample patient care durations

Service name	beds	shift	Type1	Type2	Type3	Type4	Care needs	Avg. care needs
Obstetrics	20	1	14	6	0	0	29.00	8.45
Obstetrics	20	2	16	3	1	0	28.00	8.16
Obstetrics	20	3	15	4	0	0	25.00	7.29
cardiovascular surgery	28	1	15	11	2	0	51.50	15.02
cardiovascular surgery	28	2	14	6	5	0	51.50	15.02
cardiovascular surgery	28	3	12	11	0	0	39.50	11.52
Neurology	27	1	20	0	5	2	62.50	18.22
Neurology	27	2	20	2	3	1	48.50	14.14
Neurology	27	3	21	1	3	1	47.00	13.70

### 3. Genetic Algorithm

Genetic algorithms are a computational method based on the principles of biological evolution for solving optimization problems. These algorithms explore the solution space by mimicking evolutionary processes such as natural selection, genetic crossover, and mutation, aiming to find the best solution. The origin of genetic algorithms dates back to the 1970s when John Holland and his colleagues initiated the development of artificial evolutionary systems [11].

The fundamental principle of genetic algorithms is based on how natural selection and genetic processes work in the biological world to increase diversity and adaptability. The operation of the algorithm consists of the following steps.

- **Step 1.** Creating the Initial Population: The first step is to create a population consisting of randomly selected individuals. This population representing potential solutions
- **Step 2.** Fitness Evaluation: Each individual has a fitness value indicating how well it provides a solution for a specific problem or task.
- **Step 3.** Selection: The probability of selecting more fit individuals is determined based on their fitness values. This symbolizes the transmission of better solutions to future generations.
- **Step 4.** Crossover: Genetic material exchange occurs among the selected individuals. This increases diversity and generates new potential solutions.
- **Step 5.** Mutation: With a certain probability, the genetic material of individuals is randomly altered. This allows for the emergence of new features or solution proposals.
- **Step 6.** Creating a New Population: A new population is formed from individuals obtained through selection, crossover, and mutation steps.
- **Step 7.** Stopping Criterion: The algorithm terminates when a specific stopping criterion is met. Otherwise, the steps are repeated.



#### 4. GA-based Nurse Scheduling

In the study, the functionality of the nurse scheduling application developed based on GA was assessed using the data presented in Table 2. As an example, the Obstetrics service chosen has 20 beds, with 14 patients categorized as type 1 and 6 as type 2. There are no type 3 or type 4 patients. Three observation shifts are assigned for these patients throughout the day. The average care hours for patients are 8.45 for the morning shift, 8.16 for the afternoon shift, and 7.29 for the evening shift. A total of 8 nurses are allocated to this service. However, it's crucial to note that an entire 8-hour work shift of a nurse may not be exclusively spent in this service. Nurses are observed to dedicate approximately 18% of their average working hours to service-related tasks and 24% to personal tasks.

In the study, while conducting nurse scheduling, it is assumed that a nurse works according to the legal constraints specified below, taking into account the Obstetrics service:

- The number of nurses in the service is 8.
- Nurses work in two shifts: day and evening. The day shift lasts for 8 hours, and the evening shift lasts for 16 hours. For these periods, the time spent on patient care is 4.64 hours during the day (after subtracting 18% for service-related tasks and 24% for personal tasks) and 9.28 hours during the night.
- A nurse working the 16-hour night shift will be considered on leave the next day.
- A nurse's weekly (7 days) working hours will not exceed 40 hours.
- A nurse's monthly (28 days) working hours will not exceed 160 hours.
- A nurse working the day shift cannot work the night shift simultaneously.
- It is assumed that no nurse has any impediment (illness, having completed 30 years of service, pregnancy, exemption from duty) for the night shift.

In the study, when determining the fitness function, penalty value ( $pv$ ) were calculated for situations where patient care times exceed or fall below the specified durations and for situations where nurses' weekly or monthly working hours exceed or fall below certain limits.

*If nurse care time < patient care time:*

$$pv1 = \text{patient care time} - \text{nurse care time}$$

*If nurse care time > patient care time:*

$$pv2 = \text{nurse care time} - \text{patient care time}$$

*If nurse working time > weekly/monthly working time:*

$$pv3 = \text{nurse working time} - \text{weekly/monthly working time}$$

*If nurse working time < weekly/monthly working time:*

$$pv4 = \text{weekly/monthly working time} - \text{nurse working time}$$

Considering 8 nurses and their weekly/monthly working times, the optimization goal in the optimization process is to minimize the  $pv$  value.

$$\text{Total } pv = pv1 + pv2 + pv3 + pv4$$

To minimize the  $pv$  value in the study, the GA method was chosen. In the Genetic Algorithm, the process begins with creating the initial population. The Initial Population is the set where all individuals come together. The goal here is to obtain higher-quality individuals in each iteration. The fitness value of these individuals is calculated, and then basic operations are iteratively applied. These operations are selection, crossover, and mutation. In selection operations, a random selection method is applied so that the best individuals in the current population will have a higher chance. Randomness is essential in genetic algorithms, but in the selection process, it is a selection where the chances of better individuals are higher. Crossover aims to obtain 2 child individuals from 2 descendent individuals. Random genes are changed within chromosomes. The mutation process is applied rarely but randomly. It can be applied to avoid getting stuck at maximum or minimum points of the optimization problem. The parameters used in the GA are provided in Table 3 below. The parameter values used in genetic algorithms are values obtained manually through trial and error,

ensuring the successful operation of the optimization process. In the study, the application was developed using the Python programming language.

Table 3. Parameters of the genetic algorithm

Parameters	value
Crossover rate	0.95
Mutation rate	0.05 / 0.1
population	30 / 100
Elitism strategy	Roulette wheel
iteration	100.000 / 1.000.000
Crossover strategy	Single point (week scheduling) Two point (month scheduling)

The chromosome structure generated for a 7-day period is provided in Figure 1. A gene has been defined for each nurse (in this example, planning has been made for 8 nurses), representing each day of the week. The possible values for these genes are 0 for non-working days, 8 for day shifts, and 16 for night shifts. Thus, the initial solution randomly generated for solving the problem is determined according to this chromosome structure, taking constraints into account. The size of the chromosome vector varies depending on the number of days and nurses designed for the problem.




Figure 1. Chromosome structure for 7 days

#### 4.1. Results

The program's functionality was tested based on the information from the Obstetrics Service. The three different shift systems in the Obstetrics Service were reduced to two. The 24-hour time frame was expressed as 8 hours of daytime and 16 hours of nighttime work. Accordingly, the program was calculated weekly, with each nurse working 40 hours every weekend. For the daytime shift, a total of 8.45 hours were allocated for patient care, and for the nighttime shift, 15.75 hours were allocated, as indicated in Table 2. Figure 2 depicts the results of the weekly nurse assignment based on a population size of 30, mutation rate of 0.085, iter = 100.000, and single-point crossover values. In the figure, rows represent nurses, columns represent days, and the last column (7) indicates the weekly working hours obtained as a result of the optimization process. Additionally, the cells show 8 hours for morning shifts, 16 hours for night shifts, and 0 for days off.

	Mon	Tue	Wed	Thu	Fri	Sat	Sun	Total Working
N1	8	8	16	0	8	0	0	40
N2	0	8	0	16	0	16	0	40
N3	16	0	16	0	0	8	0	40
N4	0	0	0	8	16	0	16	40
N5	0	0	8	8	16	0	8	40
N6	0	0	8	16	0	16	0	40
N7	8	16	0	0	0	0	16	40
N8	16	0	0	0	8	8	8	40

Figure 2. Nurse scheduling for 7 days

According to Figure 2, Nurse 1 (N1) has been assigned 8 hours of work on Monday, 8 hours on Tuesday, 16 hours on Wednesday, and 8 hours on Friday. This nurse has been designated as being on leave on Thursday, Saturday, and Sunday. Additionally, according to Figure 2, for example, on Monday, only 4 nurses have been assigned. Two of these nurses are assigned to the morning shift, and the other two are assigned to the night shift. Accordingly, the daytime care duration for 2 nurses is  $2 * 4.64 = 9.28$  hours. During this time, the

required patient care duration is met by 8.45 hours. In addition, the total care duration assigned to the two nurses for the night shift is  $2 * 9.28 = 18.56$  hours. During this time, the patient care duration meets the 15.75-hour requirement.




Figure 3. pv value minimization for 7 days

In Figure 3, the pv minimization process, graphically demonstrating the attainment of the best value, is shown. As can be seen from the graph, pv is minimized to at least 42.18 after 58,000 iterations. Here, pv does not reach zero due to the fact that nurse care durations may not be exact multiples of patient care durations, and there may be 1-2 hours of excess time relative to the patient care duration.

In the study, the nurse workforce planning was considered over a 4-week period, and the program was run for 28 days, with a total working time of 160 hours. The results of the study are presented in Figure 4 for 2 weeks (first and last) sections.

	Mon	Tue	Wed	Thu	Fri	Sat	Sun	Mon	Tue
N1	8	0	8	16	0	0	16	0	16
N2	0	8	16	0	16	16	0	0	8
N3	0	16	0	0	0	16	0	0	0
N4	8	16	0	8	8	0	0	8	0
N5	16	0	16	0	16	0	8	16	0
N6	8	8	0	0	8	0	16	0	8
N7	16	0	0	8	0	8	0	16	0
N8	0	8	8	16	0	8	8	8	0

	Sat	Mon	Tue	Wed	Thu	Fri	Sat	Sun	Total Working
N1	0	8	8	0	8	16	0	8	160
N2	0	8	16	0	0	8	16	0	160
N3	0	0	8	8	8	0	0	16	160
N4	0	16	0	0	16	0	8	0	160
N5	8	0	0	16	0	0	0	16	160
N6	16	0	0	8	0	16	0	8	160
N7	0	16	0	16	0	8	8	0	160
N8	16	0	16	0	16	0	16	0	160

Figure 4. Screenshot showing first and last week in 30-day nurse planning

In Figure 4, the results of the monthly nurse assignment are shown based on a population size of 100, mutation rate of 0.1, iter = 1.000.000, and double-point crossover values. As a result of the program, each nurse has been appropriately placed to work 160 hours per month. However, in some cases (e.g., the 8th column), the assignment of the number of nurses required to meet patient needs could not be achieved. In this case, a single nurse assignment for the night shift was made, and the nurse workforce was reduced to 9.28 hours, falling below the required 15.75 hours of patient care. The main factor contributing to this situation is the constraint on the number of nurses and the monthly working hours.

The pv minimization process for the optimization process given in Figure 4 is presented in Figure 5. As can be seen from the graph, pv is minimized to at least 259.11 after 43.451 iterations.




Figure 5. pv value minimization for 28 days

The expected success in the study is to determine the minimum number of nurses that can meet the minimum nurse requirements in a service, including constraints, through the optimization process using genetic algorithms, and to plan them on a schedule. From this perspective, it is observed that the optimization process works successfully.

## 5. Conclusion

The application of Genetic Algorithms (GAs) to nurse scheduling in healthcare settings has proven to be a robust and effective approach. The GA methodology, inspired by biological evolution principles, provides a versatile framework for optimizing nurse schedules while considering various constraints. The study employed a fitness function with penalty values to assess schedule compliance with legal regulations, working hour constraints, and patient care requirements, aiming to minimize penalties for a balanced and efficient nurse schedule. The study's results, depicted in Figures 2, 3, 4, and 5, highlight the successful implementation of the GA-based nurse scheduling application. The algorithm effectively generated schedules that adhered to legal constraints, met patient care demands, and optimized working hours for nursing staff.

In summary, the application of Genetic Algorithms in nurse scheduling demonstrates adaptability and effectiveness in addressing the intricate requirements of healthcare workforce planning. The developed GA-based application serves as a valuable tool for healthcare administrators to optimize nurse schedules, contributing to improved operational efficiency, regulatory compliance, and enhanced patient care. Future research can focus on refining the algorithm, considering additional constraints, and exploring its applicability in diverse healthcare settings.

## Conflict of Interest Statement

The authors declare that there is no conflict of interest.

## References

- [1] M. Gradišar, T. Turk, J. P. Hajdinjak and L. Tomat, "Interactive nurse scheduling," *CIN: Computers, Informatics, Nursing*, vol. 41, no. 3, pp. 172-182, 2023, doi: 10.1097/cin.0000000000000941.
- [2] M.D. Bal, "Yataklı Tedavi Kurumlarında Hemşire İnsan Gücü Planlama Yaklaşımları," *Sağlık ve Hemşirelik Yönetim Dergisi*, vol. 3, no. 1, pp. 148-154, 2015, doi: 10.5222/shyd.2014.148.
- [3] C. Lin, J. Kang, D. Chiang, and C. Chen, "Nurse scheduling with joint normalized shift and day-off preference satisfaction using a genetic algorithm with immigrant scheme," *International Journal of Distributed Sensor Networks*, vol. 11, no. 7, pp. 1-10, 2015.
- [4] M. Mohammadian, M. Babaei, M.A. Jarrahi and E. Anjomrouz, "Scheduling nurse shifts using goal programming based on nurse preferences: a case study in an emergency department," *International Journal of Engineering*, vol. 32, no. 7, pp. 954-963, 2019.

- [5] A. Hofler, B. Terzić, M. Krämer, A. Zvezdin, V. Morozov, Y. Roblin, F. Lin and C. Jarvis, "Innovative applications of genetic algorithms to problems in accelerator physics," *Physical Review Special Topics - Accelerators and Beams*, vol. 16, no. 1, pp. 1-25, 2013.
- [6] K. Leksakul and S. Phetsawat, "Nurse scheduling using genetic algorithm," *Mathematical Problems in Engineering*, pp. 1-16, 2014, doi: 10.1155/2014/246543.
- [7] B. Maenhout and M. Vanhoucke, "Comparison and hybridization of crossover operators for the nurse scheduling problem," *Annals of Operations Research*, vol. 159, no. 1, pp. 333-353, 2007.
- [8] A. Wibowo, and Y. Lianawati, "A multi-objective genetic algorithm for optimizing the nurse scheduling problem," *International Journal of Recent Technology and Engineering (IJRTE)*, vol. 8, no. 3, pp. 5409-5414, 2019.
- [9] D. Yıldırım, "Hemşire İnsan Gücü Planlaması," *Hemşirelik Dergisi*, vol. 12, pp. 57-70, 2002.
- [10] G. Bozkurt, E. Türkmen, N. Zengin, "Work Load Related To Independent Functions of Intensive Care Nurses," *Yoğun Bakım Hemşireliği Dergisi*, vol. 21, no. 2, pp. 36-41, 2017.
- [11] T. Bäck, U. Hammel, and H. Schwefel, "Evolutionary computation: comments on the history and current state," *IEEE Transactions on Evolutionary Computation*, vol. 1, no. 1, pp. 3-17, 1997.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### Chebyshev Polynomial Solution for the SIR Model of COVID 19

Demet Özdek<sup>a</sup>

Submitted: 17.11.2023 Revised: 13.12.2023 Accepted: 13.12.2023 doi:10.30855/gmbd.0705S05

#### ABSTRACT

In this study, we deal with solving numerically initial value problem of a mathematical model of COVID-19 pandemic in Turkey. This model is a SIR model consisting of a nonlinear system of differential equations. In order to solve these equations, a collocation approach based on the Chebyshev polynomials is used. Chebyshev polynomials are orthonormal polynomials and the orthonormality reduces the computation cost of the method as an advantage. Another advantage is that the present method does not require any discretization of the domain. So the method is easy to implement. The main idea of the method is to convert the model to a system of nonlinear algebraic equations. For this we write the approximate solution of the system and its first derivative as the truncated series of Chebyshev polynomials with unknown coefficients in matrix forms and then utilizing the collocation points, the SIR model is converted to a system of the nonlinear equations. The obtained system is solved for the unknown coefficients of the assumed Chebyshev polynomial solution by MATLAB, and so the approximate solution is obtained. In order to check the robustness of the method, residual error of the solution is reviewed. The results show that the method is efficient and accurate.

**Keywords:** SIR model, collocation method, COVID-19 modeling, error analysis, mathematical modeling

<sup>a</sup> Izmir University of Economics,  
Faculty of Arts and Science,  
Department of Mathematics  
35330 - Izmir, Türkiye  
Orcid: 0000-0003-3877-6739  
e mail: [demet.ersoy@ieu.edu.tr](mailto:demet.ersoy@ieu.edu.tr)

<sup>\*</sup>Corresponding author:  
[demet.ersoy@ieu.edu.tr](mailto:demet.ersoy@ieu.edu.tr)

### Covid 19 için SIR modelinin Chebyshev Polinom Çözümleri

#### ÖZ

Bu çalışma, Türkiye'deki COVID-19 salgınına yönelik matematiksel modelin başlangıç değer probleminin sayısal olarak çözümü ile ilgilidir. Bu model, nonlineer denklem sisteminden oluşan SIR modelidir. Bu denklemleri çözmek için Chebyshev polinomlarına dayanan bir kollokasyon yöntemi kullanılmıştır. Chebyshev polinomları ortonormal polinomlardır ve yöntemin bir avantajı olarak, ortonormalite yönteminin hesaplama maliyetini düşürmektedir. Bir diğer avantaj ise mevcut yöntem, alan ayrıştırması gerektirmemektedir. Dolayısıyla yöntemin uygulanması kolaydır. Metodun ana düşüncesi modeli nonlineer cebirsel denklemlere dönüştürmektir. Bunun için sistemin yaklaşık çözümü ve birinci türevi, matris formlarında katsayıları bilinmeyen Chebyshev polinomlarının kesik serisi olarak yazılmaktadır ve sonra kollokasyon noktalarından yararlanarak, SIR modeli nonlineer denklemler sistemine dönüştürülmektedir. Elde edilen sistem Chebyshev polinomlarının bilinmeyen katsayıları için Matlab kullanılarak çözülür ve böylece yaklaşık çözüm elde edilir. Metodun doğruluğunu kontrol etmek için çözümün artık mutlak hatası incelenmiştir. Sonuçlar mevcut metodun etkili ve doğru olduğunu göstermektedir.

**Anahtar Kelimeler:** SIR modeli, kollokasyon metodu, COVID-19 modellenmesi, hata analizi, matematiksel modelleme

## 1. Introduction

Until present, there have been various disease and pandemics that human being has struggled with and millions of people have lost their lives due to these diseases. In the last century, the world experienced major outbreaks such as 1918 H1N1 Influenza, Asian Influenza, Hong Kong flu, HIV/AIDS epidemic etc. which were represented as a threat for the human health [1-4].

By the 21st century, in December 2019, a novel epidemic was appeared in Wuhan, Hubei Province of China. Although the symptoms of this disease such as fever, fatigue, cough, headache and sore throat were similar to influenza, it was understood that the disease was caused by the severe acute respiratory syndrome coronavirus 2 (SARS-COV2) and the disease was named as Corona Virus (Covid-19) by World Health Organization (WHO) and declared as a global pandemic [3,4]. The disease was so rapid that in a couple months, the number of Corona Virus positive patients spreads up to 4 million. Now as of August 2023, there are globally more than 700 million confirmed cases of Covid-19 and more than 6 million deaths reported to WHO while 17 million confirmed cases are from Turkey [3].

Since December 2019, the world has experienced not only health consequences but also devastating impacts on economy, politics and social life. Therefore the additional solutions such as wearing masks, social-distancing, distance education etc. were very essential as well as the medical treatment to control the pandemic and everyone from the younger to the elder tried to contribute to this. In this sense, also mathematical models have made contributions to find out the dynamic pattern of the disease, to investigate forecasting tools, to predict disease transmission, recovery and other paramaters and analyze Covid-19 outcomes of different populations.

One of the basic epidemic model for Covid-19 spread is the Susceptible-Infected-Recovered (SIR) model which is firstly developed by Kermack and McKendrick [5] and is discussed by many researchers [5-14]. This model divides the population into three groups: The susceptible individuals, the infected individuals and the removed individuals. Their descriptions are given in the Table 1.

Table 1. Descriptions of the variables and the parameters

Notation	Description
<b>S</b>	Susceptible population represents individuals which are possible to be exposed to Covid-19
<b>I</b>	Infected population represents individuals which are infected by Covid-19
<b>R</b>	Removed population represents which are recovered or died from Covid-19
<b>α</b>	The transmission rate from the susceptible individuals to the infected individuals
<b>μ</b>	The recovery rate from the infected individuals to the removed individuals

The aim of this study is to use a collocation method based on Chebyshev polynomials in order to examine the flow of the Covid-19 disease according to the data obtained from the Turkish Ministry of Health. For this we consider the SIR epidemic model for Covid-19 and we note that this problem has not been solved by the collocation method based on Chebyshev polynomials so far.

The SIR epidemic model can be given mathematically by the set of nonlinear ordinary differential equations

$$\begin{aligned}
 \frac{dS(t)}{dt} &= -\frac{\alpha}{P}S(t)I(t), \\
 \frac{dI(t)}{dt} &= \frac{\alpha}{P}S(t)I(t) - \mu I(t), \\
 \frac{dR(t)}{dt} &= \mu I(t),
 \end{aligned}
 \quad 0 \leq t \leq L \quad (1)$$

subject to the initial conditions

$$S(0) = S_0, \quad I(0) = I_0, \quad R(0) = R_0 \quad (2)$$

where  $P = S(t) + I(t) + R(t)$  is the population size which is sufficiently large and remains constant as the assumption of the model.

## 2. Chebyshev Polynomials

Chebyshev polynomials of the first kind  $T_n^*(t)$  are nth degree polynomials defined by  $T_n^*(\cos\theta) = \cos(n\theta)$  [15-17] and constructed from the recurrence relation

$$T_{n+1}^*(t) = 2tT_n^*(t) - T_{n-1}^*(t), \quad n \geq 1$$

with initial values  $T_0^*(t) = 1$  and  $T_1^*(t) = t$ .

As one of the basic properties, these polynomials constitute an orthogonal set  $\{T_n^*(t), n = 0, 1, 2, \dots\}$  on the interval  $[-1, 1]$  with respect to the weight function  $w^*(t) = \frac{1}{\sqrt{1-t^2}}$ , that is

$$\int_{-1}^1 w^*(t) T_n^*(t) T_m^*(t) dx = \begin{cases} 0, & n \neq m, \\ \gamma_n, & n = m, \end{cases}$$

where  $\gamma_n = \pi$  if  $n = 0$  and  $\gamma_n = \frac{\pi}{2}$  if  $n \neq 0$ . This implies that Chebyshev polynomials will be orthonormal if each polynomial is normalized by dividing  $\sqrt{\gamma_n}$ ,  $n = 0, 1, 2, \dots$ . When the interval of interest  $[a, b]$  is different than  $[-1, 1]$ , the Chebyshev polynomials are shifted to  $[a, b]$  by a suitable transformation. In this study the shifted Chebyshev polynomials under the transformation  $T_n(t) = T_n^*\left(\frac{2}{L}t - 1\right)$  are orthogonal over the interval  $[0, L]$ . So, all properties of Chebyshev Polynomials will be transformed to their shifted forms. For instance, any square integrable function  $f(t)$  defined on  $[0, L]$  can be expressed as

$$f(t) = \sum_{n=0}^{\infty} a_n T_n(t)$$

where  $a_n = \int_0^L f(t) T_n(t) w_n(t) dt$  and  $w_n(t) = w_n^*\left(\frac{2}{L}t - 1\right)$ . For an approximation, we truncate the series as  $f(t) \approx f_N(t) = \sum_{n=0}^{N-1} a_n T_n(t)$ , where  $N$  is a positive integer.

## 3. Implementation of Chebyshev Polynomials

Assume that the solutions of the model (1) and (2) is written in terms of the Chebyshev polynomials as

$$\begin{aligned} S_N(t) &= \sum_{n=0}^{N-1} a_n T_n(t) = \mathbf{A}^T \boldsymbol{\phi}(t) \\ I_N(t) &= \sum_{n=0}^{N-1} b_n T_n(t) = \mathbf{B}^T \boldsymbol{\phi}(t) \\ R_N(t) &= \sum_{n=0}^{N-1} c_n T_n(t) = \mathbf{C}^T \boldsymbol{\phi}(t) \end{aligned} \tag{3}$$

where  $a_n, b_n, c_n$  are the unknown Chebyshev coefficients;  $T_n$  are the shifted first kind Chebyshev polynomials for  $n = 0, 1, 2, \dots$  and a positive integer  $N$ ;  $\mathbf{A}, \mathbf{B}, \mathbf{C}$  and  $\boldsymbol{\phi}(t)$  are  $N \times 1$  matrices of the form

$$\begin{aligned} \mathbf{A} &= [a_0 \ a_1 \ a_2 \ \dots \ a_{N-1}]^T, & \mathbf{B} &= [b_0 \ b_1 \ b_2 \ \dots \ b_{N-1}]^T \\ \mathbf{C} &= [c_0 \ c_1 \ c_2 \ \dots \ c_{N-1}]^T, & \boldsymbol{\phi}(t) &= [T_0(t) \ T_1(t) \ T_2(t) \ \dots \ T_{N-1}(t)]^T \end{aligned}$$

Our aim is to obtain these unknown coefficients  $a_n, b_n, c_n, n = 0, 1, 2, 3, \dots, N - 1$  to get the Chebyshev polynomial solutions of the model (1) and (2), explicitly. For this, firstly utilizing the  $N \times N$  operational matrix for the derivative  $\mathbf{D}$  of the form [18]

$$\mathbf{D} = [d_{ij}] = \frac{2}{L} \begin{cases} 2(i-1), & \text{if } i-j \text{ is odd and } i > j > 1 \\ \sqrt{2}(i-1), & \text{if } i-j \text{ is odd and } i > j = 1 \\ 0, & \text{otherwise} \end{cases}$$

the derivative of  $\boldsymbol{\phi}(t)$  is represented in matrix form as  $\frac{d}{dt} \boldsymbol{\phi}(t) = \mathbf{D} \boldsymbol{\phi}(t)$ , where  $\boldsymbol{\phi}(t)$  is  $N \times 1$  matrix of the shifted Chebyshev polynomials of the first kind. By means of the operational matrix  $\mathbf{D}$ , the derivatives of



$S_N(t), I_N(t), R_N(t)$  can be expressed as

$$\begin{aligned} S'_N(t) &= \sum_{n=0}^{N-1} a_n T'_n(t) = \mathbf{A}^T \mathbf{D} \phi(t) \\ I'_N(t) &= \sum_{n=0}^{N-1} b_n T'_n(t) = \mathbf{B}^T \mathbf{D} \phi(t) \\ R'_N(t) &= \sum_{n=0}^{N-1} c_n T'_n(t) = \mathbf{C}^T \mathbf{D} \phi(t) \end{aligned} \tag{4}$$

Then  $S_N(t), I_N(t), R_N(t)$  and their derivatives are substituted into (1) and (2). Finally, replacing the first roots  $t_i, i = 1, 2, 3, \dots, N - 1$ , of the  $N$ -th shifted Chebyshev polynomials of the first kind instead of  $t$ , as

$$\begin{aligned} A^T D \phi(t_i) &= -\frac{\alpha}{P} A^T \phi(t_i) [\phi(t_i)]^T B \\ B^T D \phi(t_i) &= \frac{\alpha}{P} A^T \phi(t_i) [\phi(t_i)]^T B - \mu B^T \phi(t_i) \end{aligned} \tag{5}$$

$$\begin{aligned} C^T D \phi(t_i) &= \mu B^T \phi(t_i) \\ A^T \phi(0) &= S_0, \quad B^T \phi(0) = I_0, \quad C^T \phi(0) = R_0 \end{aligned} \tag{6}$$

will provide  $3(N - 1)$  equations to solve. These equations together with the initial conditions in (6) will form a system of  $3N$  equations which can be solved by MATLAB for the unknown coefficients  $a_n, b_n, c_n$  for  $n = 0, 1, 2, 3, \dots, N - 1$ .

### 4. Numerical Experiments

In this section we illustrate the implementation of Chebyshev polynomial solutions method to solve SIR model for the spread of Covid 19. For this firstly the parameters and the initial conditions are determined from the available COVID-19 data in the official source of the Turkey Ministry of Health [19]. Since April 4, 2020 is the first reported date in [19], the number of susceptible people and the number of the people who are infected and removed in Turkey on April 4, 2020 are taken as the initial values of  $S_0, I_0$  and  $R_0$ . If the size of the population is assumed to be 84,000,000, the number of infected people is 3013 and the number of removed people is 378 (daily number of deaths is 76 and the number of recovery is 302), the number of susceptible individuals become 83,996,609. Since the recommended quarantine period is 14 days if the individuals are suspected to be exposed to COVID-19 [20], the transmission rate is estimated as  $\alpha = 1/14$  (1/days)  $\approx 0.0714$  [14,21]. Since the total number of infected people on April 4 is 23934 while the total number of removed people is 1287 (501 total deaths and 786 total recovered patients), the recovery rate is obtained as  $\mu = 1287/23934 \approx 0.0538$ . So these values are as represented in Table 2.

Table 2. The values of the parameters and the initial conditions

Data	Values [19]
$S_0$	83,996,609
$I_0$	3013
$R_0$	378
$\mu$	0.0538
$\alpha$	0.0714

Considering these conditions and the parameters, the model (1) and (2) can be expressed as follows

$$\begin{aligned} \frac{dS(t)}{dt} &= -8.5034 \times 10^{-10} S(t)I(t), \\ \frac{dI(t)}{dt} &= 8.5034 \times 10^{-10} S(t)I(t) - 0.0538I(t), & 0 \leq t \leq 60 \\ \frac{dR(t)}{dt} &= 0.0538I(t), \end{aligned} \tag{7}$$

$$S(0) = 83,996,609, \quad I(0) = 3013, \quad R(0) = 378 \tag{8}$$

Here, the length of the interval is taken as  $L = 60$ . Letting  $N = 6$  corresponds to a fifth order polynomial approximation as

$$\begin{aligned} S_5(t) &= \sum_{n=0}^5 a_n \cdot T_n(t) = \mathbf{A}^T \boldsymbol{\phi}(t), \\ I_5(t) &= \sum_{n=0}^5 b_n \cdot T_n(t) = \mathbf{B}^T \boldsymbol{\phi}(t), \\ R_5(t) &= \sum_{n=0}^5 c_n \cdot T_n(t) = \mathbf{C}^T \boldsymbol{\phi}(t) \end{aligned} \tag{9}$$

where

$$\begin{aligned} \mathbf{A} &= [a_0 \ a_1 \ a_2 \ a_3 \ a_4 \ a_5]^T, & \mathbf{B} &= [b_0 \ b_1 \ b_2 \ b_3 \ b_4 \ b_5]^T, \\ \mathbf{C} &= [c_0 \ c_1 \ c_2 \ c_3 \ c_4 \ c_5]^T, & \boldsymbol{\phi}(t) &= [T_0(t) \ T_1(t) \ T_2(t) \ T_3(t) \ T_4(t) \ T_5(t)]^T. \end{aligned}$$

By means of the  $6 \times 6$  operational matrix of the derivative  $D$  of the form

$$\mathbf{D} = \frac{2}{60} \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ \sqrt{2} & 0 & 0 & 0 & 0 & 0 \\ 0 & 4 & 0 & 0 & 0 & 0 \\ 3\sqrt{2} & 0 & 6 & 0 & 0 & 0 \\ 0 & 8 & 0 & 8 & 0 & 0 \\ 5\sqrt{2} & 0 & 10 & 0 & 10 & 0 \end{bmatrix}$$

the derivative of  $S_5(t), I_5(t), R_5(t)$  can be expressed as

$$\begin{aligned} S'_5(t) &= \mathbf{A}^T \mathbf{D} \boldsymbol{\phi}(t), \\ I'_5(t) &= \mathbf{B}^T \mathbf{D} \boldsymbol{\phi}(t), \\ R'_5(t) &= \mathbf{C}^T \mathbf{D} \boldsymbol{\phi}(t). \end{aligned} \tag{10}$$

Substituting the equations (9) and (10) into the model (7) and replacing the roots

$$t_1 = 4.0192, \quad t_2 = 15, \quad t_3 = 30, \quad t_4 = 45, \quad t_5 = 55.9808.$$

of the sixth order shifted Chebyshev polynomials as collocation points  $t_i, i = 1,2,3,4,5$  instead of  $t$  gives 15 equations of the form

$$\begin{aligned} \mathbf{A}^T \mathbf{D} \boldsymbol{\phi}(t_i) &= -8.5034 \times 10^{-10} \mathbf{A}^T \boldsymbol{\phi}(t_i) [\boldsymbol{\phi}(t_i)]^T \mathbf{B} \\ \mathbf{B}^T \mathbf{D} \boldsymbol{\phi}(t_i) &= 8.5034 \times 10^{-10} \mathbf{A}^T \boldsymbol{\phi}(t_i) [\boldsymbol{\phi}(t_i)]^T \mathbf{B} - 0.0538 \mathbf{B}^T \boldsymbol{\phi}(t_i) \\ \mathbf{C}^T \mathbf{D} \boldsymbol{\phi}(t_i) &= 0.0538 \mathbf{B}^T \boldsymbol{\phi}(t_i), \quad i = 1,2,3,4,5. \end{aligned}$$

Together with the initial conditions

$$\begin{aligned} \mathbf{A}^T \boldsymbol{\phi}(0) &= 83,996,609, \\ \mathbf{B}^T \boldsymbol{\phi}(0) &= 3013, \\ \mathbf{C}^T \boldsymbol{\phi}(0) &= 378, \end{aligned}$$

a system of 18 equations is constructed to solve for the unknown coefficients  $a_n, b_n, c_n$  for  $n = 0,1,2,3,4,5$  by a written algorithm including *fsolve* function in MATLAB. Then we obtain the Chebyshev polynomials solutions as

$$\begin{aligned} S_5(t) &= 83996609 - 215.2289t - 1.8949t^2 - 0.0115t^3 - (4.0096 \times 10^{-5})t^4 - (2.9475 \times 10^{-7})t^5, \\ I_5(t) &= 3013 + 53.1936t + 0.4681t^2 + 0.0028t^3 + (9.9190 \times 10^{-6})t^4 + (7.1973 \times 10^{-8})t^5, \\ R_5(t) &= 378 + 162.0353t + 1.4268t^2 + 0.0086t^3 + (3.0177 \times 10^{-5})t^4 + (2.2278 \times 10^{-7})t^5. \end{aligned}$$

Due to the lack of exact solution, the obtained approximate solutions  $S_5(t), I_5(t), R_5(t)$  are compared with the results of Pell-Lucas Collocation method (PLCM) [13] and the fourth order Runge Kutta method (RK4). The results are presented in the Figure 1. We would like to note that both the present method (CPM) and PLCM in [13] use fifth order polynomial approximations while Runge-Kutta method uses an iteration with step size  $\Delta t = 0.1$  As can be seen that all the numerical results in the Figure 1 coincide.

On the other hand, the Figure 1 shows the change in the susceptible, the infected and the removed population over time interval  $[0,60]$ , respectively.




Figure 1. Comparison of the approximate solutions  $S_5(t), I_5(t), R_5(t)$  obtained by the present method with Pell-Lucas Collocation method and fourth-order Runge Kutta method.

The number of susceptible individuals is decreased from 83,996,609 individuals to 83,973,800 individuals in two-month time period while the number of infected individuals is increased from 3013 individuals to 8685 individuals and the number of removed individuals is increased from 378 individuals to 17,619 individuals. Although, in the Figure 1, the infected population  $I_5(t)$  and removed population  $R_5(t)$  seem to be increasing at a close rate, we observe that the number of removed individuals grows faster than the infected population on the time interval  $[0,60]$ , by the Figure 2.




Figure 2. Growth rate comparison of the Infected  $I_5(t)$  and Removed  $R_5(t)$  populations

### 5. Error Analysis

In this section, in order to check the robustness and efficiency of the current method, we discuss the absolute errors and the absolute residual errors of the model (1) and (2). The maximum absolute errors related to the functions  $S_N, I_N, R_N$  compute how the approximations achieve accurate results through the maximum of the differences between the  $N$ -th and  $(N - 1)$ -st degree polynomial approximations as follows:

$$\begin{aligned}
 \max E_{S_N} &= \max_{t_j \in [0,60]} |S_N(t_j) - S_{N-1}(t_j)|, \\
 \max E_{I_N} &= \max_{t_j \in [0,60]} |I_N(t_j) - I_{N-1}(t_j)|, \\
 \max E_{R_N} &= \max_{t_j \in [0,60]} |R_N(t_j) - R_{N-1}(t_j)|,
 \end{aligned}
 \tag{11}$$

where  $S_N, I_N, R_N$  are approximate solutions of the model (1) and (2) for all  $t_j \in [0,60]$ . Table 3 shows the maximum of the absolute errors  $\max E_{S_N}, \max E_{I_N}$  and  $\max E_{R_N}$  of the current method for all  $t_j \in [0,60]$  when  $N = 8$  and  $N = 10$  which corresponds to seventh and ninth degree polynomial approximations. As seen in the Table 3, the maximum absolute errors for  $S_N, I_N$  and  $R_N$  are decreasing and getting closer to zero when the degree of the Chebyshev polynomials  $N$  is increasing. One can say that the current method is highly accurate.

Table 3. The maximum absolute errors of the current method for N=8 and N=10.

$\max E_{S_8}$	$\max E_{S_{10}}$	$\max E_{I_8}$	$\max E_{I_{10}}$	$\max E_{R_8}$	$\max E_{R_{10}}$
6.0603e-05	1.4901e-08	1.3926e-05	6.0754e-10	4.6951e-05	1.4992e-08

The absolute residual errors  $ReS_N, ReI_N, ReR_N$  of the model (1) and (2) compute how much the approximate solutions  $S_N, I_N, R_N$  satisfy the differential equations by

$$\begin{aligned}
 ReS_N &= \left| \frac{dS_N(t)}{dt} + \frac{\alpha}{P} S_N(t) I_N(t) \right|, \\
 ReI_N &= \left| \frac{dI_N(t)}{dt} - \frac{\alpha}{P} S_N(t) I_N(t) + \mu I_N(t) \right|, \\
 ReR_N &= \left| \frac{dR_N(t)}{dt} - \mu I_N(t) \right|
 \end{aligned}
 \tag{12}$$

where the parameters  $\alpha, \mu, P$  are considered as given in Table 2. It is known that the closer the absolute residual errors are to zero, the better the approximations are. In literature, there is not much study on the polynomial solutions of SIR model for Covid 19 pandemic in Turkey, so far. Yüzbaşı and Yıldırım obtained Pell-Lucas solutions of the model (1) and (2) and presents the residual errors of the Pell-Lucas solutions when  $N = 10$  in [13]. So, setting  $N = 8$  and  $N = 10$ , Table 4a, 4b and 4c present the absolute residual errors for susceptible, infected and removed populations and compare the residual errors of the current method and Pell-Lucas Collocation method (PLCM) in [13], respectively. As observed in the Table 4, the maximum absolute residual errors of  $S_N(t)$ , for  $t \in [0,60]$  are  $O(10^{-6})$  and  $O(10^{-10})$  when  $N = 8$  and  $N = 10$ , respectively, while the maximum absolute residual error obtained by PLCM is  $O(10^{-8})$ .

Table 4. Comparison of absolute residual errors for susceptible individuals

$t$	$ReS_8$ <i>Present Method</i>	$ReS_{10}$ <i>Present Method</i>	$ReS_{10}$ <i>PLCM [13]</i>
0	1.3795e-06	3.8620e-10	1.7821e-08
10	1.9682e-07	8.3868e-12	1.0382e-10
20	1.2282e-08	3.2757e-11	1.0065e-11
30	5.1442e-09	3.8460e-11	1.7963e-14
40	1.4451e-08	3.4894e-11	5.4862e-12
50	1.9413e-07	9.5066e-12	2.3212e-11
60	1.3512e-06	4.6717e-10	6.2135e-14

The Table 5 shows that the maximum absolute residual errors for  $I_N(t)$ , for  $t \in [0,60]$  are  $O(10^{-7})$  and  $O(10^{-10})$  when  $N = 8$  and  $N = 10$ , respectively, while the maximum absolute residual error obtained by PLCM is  $O(10^{-8})$ .

Table 5. Comparison of absolute residual errors for infected individuals

t	ReI <sub>8</sub>	ReI <sub>10</sub>	ReI <sub>10</sub>
	Present Method	Present Method	PLCM [13]
0	2.5844e-07	3.9938e-10	1.5858e-08
10	3.6411e-08	8.6413e-12	9.2552e-11
20	9.2450e-09	3.3787e-11	9.0502e-12
30	9.3203e-10	3.9684e-11	5.9179e-14
40	2.5777e-09	3.5924e-11	4.9293e-12
50	3.3723e-08	9.7608e-12	2.1138e-11
60	2.3012e-07	4.8035e-10	3.2251e-14

As one can see in the Table 6, the maximum absolute residual errors of  $R_N(t)$ , for  $t \in [0,60]$  are  $O(10^{-6})$  and  $O(10^{-11})$  when  $N = 8$  and  $N = 10$ , respectively, while the maximum absolute residual error obtained by PLCM is  $O(10^{-9})$ .

Table 6. Comparison of Absolute Residual Errors for Removed Individuals

t	ReR <sub>8</sub>	ReR <sub>10</sub>	ReR <sub>10</sub>
	Present Method	Present Method	PLCM [13]
0	1.1211e-06	1.3161e-11	1.9418e-09
10	7.1870e-08	2.3383e-13	1.1024e-11
20	1.0024e-08	1.0080e-12	1.0284e-12
30	1.2456e-07	1.2472e-12	5.2996e-14
40	8.6769e-08	1.0040e-12	5.4701e-13
50	1.6041e-07	2.2559e-13	2.2316e-12
60	1.1211e-06	1.3148e-11	4.9546e-14

One can say that the current method is as efficient as PLCM when  $N = 10$  and considering the lower degree polynomial approximation, it is still powerful.

## 6. Conclusion

This study present an efficient method based on the Chebyshev polynomials to solve SIR model of Covid-19 pandemic in Turkey. This method transforms the system of nonlinear ordinary differential equations into a system of algebraic equations which can be solved by Matlab. The solutions of the model and their derivatives are approximated by the truncated series of Chebyshev polynomials. The robustness of the method is indicated by means of the absolute errors and the absolute residual errors. We observe that the Chebyshev polynomials method is highly accurate. As an advantage, the method uses the powerful properties of the Chebyshev polynomials such as the orthonormality property shifted to any interval  $[0, L]$ . This is also a factor which reduces the computational cost. Another advantage of the method is that it does not require any discretization of the interval, and this advantage facilitates the implementation of the method. In this sense, as a future study, the method can be applied to other models of the Covid-19.

## Conflict of Interest

The author declares that there is no conflict of interest.

## References

- [1] "The 1918 Flu Pandemic: Why It Matters 100 Years Later," *Website of Centers for Disease Control and Prevention*, Public Health Matters Blog, 14-05-2018. [Online]. Available: <https://blogs.cdc.gov/publichealthmatters/2018/05/1918-flu> [Accessed: 14-08-2023]
- [2] C.A. Taylor, C. Boulos and M.J. Memoli. "The 1968 Influenza Pandemic and COVID-19 Outcomes," *MedRxiv*. The Preprint Server for Health Sciences, October 25, 2021. [Online]. Available: <https://www.medrxiv.org/content/10.1101/2021.10.23.21265403v1.full-text>. [Accessed: 25-12-2023].
- [3] "Coronavirus (COVID-19) outbreak," *WHO Homepage*, World Health Organization. [Online]. Available:

<https://www.who.int/westernpacific/emergencies/covid-19>. [Accessed: 14-08-2023].

- [4] L. Akin and M.G. Gözel, "Understanding dynamics of pandemics," *Turkish Journal of Medical Sciences*, vol. 50, pp. 515-519, April 2020. Doi: 10.3906/sag2004-133
- [5] W.O. Kermack and A.G. McKendrick, "A contribution to the mathematical theory of epidemics," *Proceedings of the Royal Society of London A*, vol. 115, 1927, pp. 700-721, August 1927. Doi:10.1098/rspa.1927.0118
- [6] F.S. Akinboro, S. Alao and F.O. Akinpelu, "Numerical solution of SIR model using differential transformation method and variational iteration method," *General Mathematics Notes*, vol. 22, no. 2, pp. 82-92, June 2014.
- [7] T. Harko, F.S. Lobo and M. Mak, "Exact analytical solutions of the Susceptible-Infected-Recovered (SIR) epidemic model and of the SIR model with equal death and birth rates," *Applied Mathematics and Computation*, vol. 236, pp. 184-194, June 2014. doi:10.1016/j.amc.2014.03.030
- [8] S. Hasan, A. Al-Zoubi, A. Freihet, M. Al-Smadi and S. Momani. "Solution of fractional SIR epidemic model using residual power series method," *Applied Mathematics and Information Sciences*, vol. 13, pp. 153-161, March 2019. Doi: 10.18576/amis/130202
- [9] S.U. Khan and I. Ali. "Numerical analysis of stochastic SIR model by Legendre spectral collocation method," *Advances in Mechanical Engineering*, vol. 11, pp. 1-10, July 2019. Doi: 10.1177/168781401986
- [10] A. Secer, N. Ozdemir and M.A. Bayram, "Hermite polynomial approach for solving the SIR model of epidemics," *Mathematics*, vol. 6, no. 12, pp. 305, December 2018. doi:10.3390/math6120305
- [11] S. Side, A.M. Utami and M.I. Pratama, "Numerical solution of SIR model for transmission of tuberculosis by Runge-Kutta method," *Journal of Physics: Conference Series*, vol. 1040, pp. 012021, May 2018. doi:10.1088/1742-6596/1040/1/012021
- [12] D. Uçar and E. Çelik, "Analysis of Covid 19 disease with SIR model and Taylor matrix method," *AIMS Mathematics*, vol. 7, pp. 11188-11200, April 2022. doi:10.3934/math.2022626
- [13] Ş. Yüzbaşı and G. Yıldırım, "A Pell-Lucas Collocation Approach for an SIR Model on the Spread of the Novel Coronavirus (SARS CoV-2) Pandemic: The Case of Turkey," *Mathematics*, vol. 11, pp. 697, January 2023. doi: 10.3390/math11030697
- [14] B.M. Ndiaye, L. Tendeng and D. Seck, "Comparative prediction of confirmed cases with COVID-19 pandemic by machine learning, deterministic and stochastic SIR models," *ArXiv:2004*, Quantitative Biology: Populations and Evolution, vol. 2004, pp.13489, April 24, 2020. [Online]. Available: <https://arxiv.org/abs/2004.13489>. [Accessed: 25-12-2023].
- [15] P.L. Chebyshev, *Mémoires présentés à l'Académie impériale des Sciences de St. Petersburg par divers Savans et dans ses assemblées (in French)*. 9th Edition. Saint- Pétersbourg: Imperatorskaja akademija nauk, 1854.
- [16] J.C. Mason and D.C. Handscomb, *Chebyshev Polynomials*. New York: Chapman & Hall/CRC, 2003.
- [17] T.J. Rivlin, *Pure and Applied Mathematics: Chebyshev Polynomials. From Approximation Theory to Algebra and Number Theory*, 2nd Edition. New York: Wiley, 1990, pp. 249.
- [18] M.R. Ahmadi and H. Adibi. "The Chebyshev Tau Technique for the Solution of Laplace's Equation," *Applied Mathematics and Computation*, vol. 184, pp. 895-900, January 2007. doi:10.1016/j.amc.2006.05.212
- [19] "Genel Koronavirus Tablosu", *The Turkey Ministry of Health COVID 19 Information Platform*, [Online]. Available: <https://covid19.saglik.gov.tr/TR-66935/genel-koronavirus-tablosu.html>. [Accessed: 27-05-2023].
- [20] "Coronavirus disease 2019 (COVID-19): Situation report 73," *World Health Organization Homepage*, WHO Coronavirus disease (COVID-19) Situation reports, 2 April 2020. [Online]. Available: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/situation-reports>. [Accessed: 27-05-2023].
- [21] C.N. Ngonghala, E. Iboi, S. Eikenberry, M. Scotch, C.R. MacIntyre, H.M. Bonds and A.B. Gumel. "Mathematical Assessment of the impact of non-pharmaceutical interventions on curtailing the 2019 novel Coronavirus," *Mathematical Biosciences*, vol. 325, pp. 108364, May 2020. Doi:10.1016/j.mbs.2020.108364.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAE 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## Dynamic Mode Decomposition with Control: A Case Study of Covid-19 and Vaccination

Simge Kacar Eroglu<sup>a,b</sup>, Gamze Yuksel<sup>b</sup>

Submitted: 19.11.2023 Revised: 17.12.2023 Accepted: 18.12.2023 doi:10.30855/gmbd.0705S06

### ABSTRACT

**Keywords:** Dynamic mode decomposition, control, data-driven dynamic systems, singular value decomposition, machine learning

<sup>a,\*</sup> Bursa Technical University,  
Mugla Sıtkı Kocman University,  
48000 - Muğla, Türkiye  
Orcid: 0000-0002-4602-2489  
e mail: [simge.eroglu@btu.edu.tr](mailto:simge.eroglu@btu.edu.tr)

<sup>b</sup> Mugla Sıtkı Kocman University,  
Faculty of Science,  
Dept. of Mathematics  
48000 - Muğla, Türkiye  
Orcid: 0000-0003-3578-2762

\*Corresponding the author:  
[simge.eroglu@btu.edu.tr](mailto:simge.eroglu@btu.edu.tr)

Epidemic diseases have posed great threats to human societies throughout history and have seriously affected public health. Epidemic diseases can spread rapidly and cause major deaths and economic losses. Therefore, the control and management of epidemic diseases requires new approaches developed with scientific and technological developments. The method of Dynamic Mode Decomposition with Control (DMDc) is a machine learning technique that predicts the state of systems, that affect the dynamic system from the outside and change the nature of the system. This technique is used to examine how the variables, factors, and effects in the data are related to each other and how they change over time. In this article, the DMDc method used the weekly cumulative number of COVID-19 cases per 100 thousand of Turkey's 81 provinces between February 8 and September 11, 2021, as the situation matrix, and the total number of vaccines per 100 thousand in the same time interval as the control matrix and then calculated error values of the DMD and DMDc are compared with under the different error metrics. In this paper, the number of cases and vaccines in the Turkish Ministry of Health TURCOVID-19 open data set was used.

## DMDk ile Kovid-19 ve Aşlamaya İlişkin Bir Örnek Olay İncelemesi

### ÖZ

Epidemik hastalıklar tarih boyunca insan toplumlarına büyük tehditler oluşturmuş ve kamu sağlığını ciddi şekilde etkilemiştir. Epidemik hastalıklar hızla yayılabilir, büyük ölümlere ve ekonomik kayıplara yol açabilir. Bu nedenle, salgın hastalıkların kontrolü ve yönetimi, bilimsel ve teknolojik gelişmelerle birlikte geliştirilen yeni yaklaşımlar gerektirir. Dinamik Mod Ayırıştırmasında Kontrol (DMAK), dinamik sistemi dışardan etkileyen değişkenin, sistemi kontrol etmek amacıyla dahil edilmesiyle sistemin durumunun incelendiği bir makine öğrenmesi tekniğidir. Bu teknik, verilerdeki değişkenlerin, faktörlerin ve etkilerin birbirleriyle nasıl ilişkilendiklerini ve zamanla nasıl değiştiklerini incelemek için kullanılır. Bu çalışmada DMAK yönteminde, 8 Şubat ile 11 Eylül 2021 tarihleri arasında Türkiye'nin 81 ilinin 100 bin kişideki haftalık kümülatif COVID-19 vaka sayısı durum matrisi, aynı tarih aralığında 100 bin kişideki toplam aşı sayısı kontrol matrisi olarak kullanıldı. Daha sonra Dinamik Mod Ayırıştırması (DMA) algoritması ile DMAK algoritmasının hata değerleri farklı hata metrikleri altında karşılaştırıldı. Bu çalışmada, Türkiye Sağlık Bakanlığı'nın COVID-19 vaka ve aşı sayısını içeren TURCOVID-19 açık veri kullanıldı.

**Anahtar Kelimeler:** Dinamik mod ayırıştırması, kontrol, veriye dayalı dinamik sistemler Acknowledgment ayırıştırması, makine öğrenmesi

## 1. Introduction

The rapid spread and development of epidemic diseases is a major challenge to modern medicine and epidemiology. However, dynamic mode separation with mathematical models and machine learning techniques is emerging as an important strategic tool in combating epidemics. This approach helps us overcome the limitations of traditional epidemiological methods and better understand the control of epidemics while providing the ability to predict future situations.

Basic mathematical models of epidemics are important tools used to analyze the dynamics of disease spread and interactions between individuals. These models help us better understand the control and prediction of epidemics in the fields of epidemiology and public health. SIR Model (Susceptibility-Infected-Resistance Model) [1], SEIR Model (Susceptibility-Infected-Exposure-Resistance Model) [2], SIS Model (Susceptibility-Infected-Susceptibility Model) [3], Stochastic Models, and Agent-Based Models [4] are the most basic mathematical modeling types in the literature for epidemic diseases. However, with the development of technology and the increasing number of data sets, mathematical modeling is being replaced by machine learning techniques that provide maximum efficiency in both time and computational cost. These techniques, combined with big data analytics, data mining, and artificial intelligence applications, help us better analyze the spread patterns of epidemics, develop control strategies, and predict future epidemics.

Time series analysis, artificial neural networks (ANN), classification models, clustering, and dimension reduction techniques are the main machine learning techniques used in epidemiology and epidemic diseases [5], [6].

In this study, dynamic mode decomposition (DMD) and dynamic mode decomposition with control (DMDc) machine learning techniques are used; these methods are based on the singular value decomposition (SVD) dimension reduction technique. Both DMD and DMDc are applied to the real Turkey COVID-19 data set, and then the error values are compared by calculating the state estimation of the number of cases.

## 2. Related Works

The earliest demonstration of the DMD algorithm in analyzing both numerical and experimental data was published by Schmid [7]. In this study, he used the Arnoldi method and various other decomposition techniques to investigate and break down the underlying mechanisms of fluid flow. Unlike previous approaches that relied on models, this work focused on a data-driven DMD procedure that extracts dynamic information. The study successfully applied the DMD algorithm to three different examples.

The foundations and applications of DMD are described in depth in [8] by Tu et.al. This study also covers subjects such as how DMD is handled, how the data set is evaluated, and how the basic modes are derived. Besides that, complex how DMD can be employed in nonlinear systems and the approaches that should be used are covered. The mathematical relationships between DMD and Koopman operator theory are demonstrated. The Koopman operator is a one-dimensional linear operator that describes the development of observables whose modes and eigenvalues describe any (even nonlinear) dynamical system. Also included in this study are system identification approaches such as the Eigensystem realization algorithm (ERA) and linear inverse modeling (LIM). Connections between DMD, ERA, and LIM were also examined.

Brunton et. al., in their work, investigated the governing equations of dynamic systems [9]. Methods from sparse representation and symbolic regression were used in this work. The topic of determining governing equations from data for dynamical systems was covered. A machine learning method that induces sparsity has been devised to extract governing equations from noisy measurement data. This study offered recommendations for the DMD and DMDc methodologies' data arrangement, library construction, and observable selection.

Kutz et. al., take over in their book one of the most fundamental studies covering the theory and applications of dynamic systems, the DMD algorithm [10]. This book is the most comprehensive resource covering the basic theoretical and mathematical foundations of DMD and its types, such as multiresolution DMD and DMDc. The chapters of the book include topics such as Koopman analysis, fluid dynamics, video processing, time delays, and nonlinear observables. These topics include examining numerical examples for DMD and



DMDc, such as theory and Matlab application codes.

Basic examples demonstrating how to use DMDc to solve problems are included in [11]. The dynamic system cannot be correctly modeled by the DMD approach when an external coercive force is applied. Proctor et al. developed the DMDc method, which includes the external force parameter in the system, to fill in the missing information in the DMD method. All of DMD's benefits are taken advantage of by the DMDc approach. It was shown in the study that the DMDc method can be used to make an inconsistent system consistent with its control parameter. Furthermore, a DMDc model for data analysis on infectious diseases is examined, where a control variable is the addition of mass vaccination to the system.

Dekhici et al. generated biogas simulation data using the Anaerobic Model 2 (AM2) in [12]. The DMDc algorithm which uses the dilution rate as the control input—was run using this data. This study also found that adding the control parameter to anaerobic digestion boosted the biogas production's efficiency.

Onstenk, in this study, used the DMDc algorithm to optimize the production process of three-dimensional printers used for the production of large-sized objects [13]. In this study, the data of the dynamic system were obtained by simulating the differential equations of the mass-spring system in Matlab. Then the pressure applied during the inflation of balloons produced from hyperelastic material with a 3D printer was included in the system as a control parameter, and the error values of the DMD and DMDc algorithms were compared.

Mustavee et al. discussed the example of human mobility restriction, which is one of the control types in epidemic diseases [14]. In this study, the COVID-19 epidemic in the US state of Florida was estimated by parameterizing with the control matrix according to the percentage of people using areas such as shopping malls, parks, and public transportation. In addition, the DMDc algorithm was applied to the Hankel matrix based on different  $h$  time delay parameters for the state matrix, and mobility data from the Google Community Movement Report was used as the control matrix.

To summarize the relevant studies from a general perspective, the fundamentals and applications of the DMD method are included in the studies in [7,8,9,10], and the fundamentals and applications of the DMDc method are included in the studies conducted in [11,12,13,14].

In this study, TC Ministry of Health TURCOVID19 Open Data was used as a data set [16], [17].

### 3. Method and Material

The main purpose of using the DMDc method in this study is that DMD cannot predict the system correctly when there is an external force, such as vaccination, acting on the dynamic system. If the external force (in this study it is vaccination) is added to the system as a control parameter then the prediction can be more accurate. One of the important points to consider when applying the DMDc method: In the DMDc algorithm, the singular value decomposition cut-off value  $p$  in equation (7) must be greater than the value decomposition cut-off value  $r$  in equation (8) [10]. In this study,  $p=30$  and  $r=29$  are selected to obtain a minimum error value.

Dynamic Mode Decomposition with Control (DMDc) [7] is a data-driven method that does not require knowledge of the underlying governing equations but only snapshots in time of observables and actuation (external forces) data obtained from experimental, historical, simulations. Controlling high-dimensional systems requires challenging tasks since they do not scale well with the dimensions of the system. In dealing with this challenging task, high-dimensional observational dimensionality reduction techniques are used. DMDc contains the Singular Value Decomposition (SVD) reduction technique.

DMDc aims to analyze the relationship between a future measurement, the current measurement, and the current control measurement given by the following:

$$x_{k+1} = Ax_k + Bu_k$$

where  $x_j \in R^n$ ,  $u_j \in R^l$ ,  $A \in R^{n \times n}$  and  $B \in R^{n \times l}$ . We can store state measurements  $X$ ,  $X'$ , and control measurements  $Y$  as i Fig1.

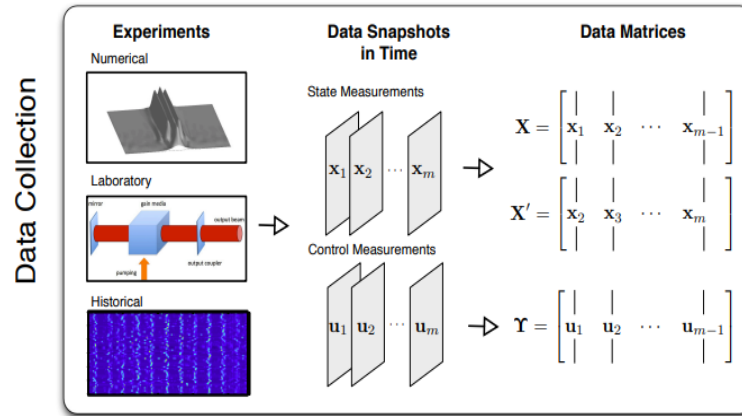


Fig. 1. Data collection from experimental, historical, simulations [11]

### 3.1. Dynamic Mode Decomposition (DMD) algorithm

In general, dynamic systems are represented by equation (1)

$$\frac{dx}{dt} = f(x, t; \mu) \quad (1)$$

Even if the function  $f(x, t; \mu)$  in the system of equations (1) is not known. DMD finds the approximation solution by converting it to a local dynamical system (2).

$$\frac{dx}{dt} = Ax \quad (2)$$

The continuous-time dynamical system (2) turns into a discrete-time step dynamical system  $x_{k+1} = Ax_k$  at time step  $\Delta t$ ,  $x \in R^n$ ,  $A \in R^{n \times n}$ ,  $x_k = x(k\Delta t)$  and  $m$  is the total number of cases,  $X'$  is a one-step shifted in time  $X$  matrices given below

$$X = \begin{bmatrix} \uparrow & \uparrow & & \uparrow \\ x_1 & x_2 & \dots & x_{m-1} \\ \downarrow & \downarrow & & \downarrow \end{bmatrix} \quad X' = \begin{bmatrix} \uparrow & \uparrow & & \uparrow \\ x_2 & x_3 & \dots & x_m \\ \downarrow & \downarrow & & \downarrow \end{bmatrix}$$

Moore-Penrose pseudoinverse [8] is used to find the dynamic modes and eigenvalues of matrix  $A$ .

$$A = X'X^\dagger \quad (3)$$

Singular Value Decomposition (SVD) is used to find the pseudoinverse  $X'$  of the matrix  $X$ .

The Singular Value Decomposition of matrix  $X$  is as follows.

$$X' \approx U\Sigma V^* = [\tilde{U} \quad \tilde{U}_{rem}] \begin{bmatrix} \tilde{\Sigma} & 0 \\ 0 & \tilde{\Sigma}_{rem} \end{bmatrix} \begin{bmatrix} \tilde{V}^* \\ \tilde{V}_{rem}^* \end{bmatrix} \quad (4)$$

$U \in R^{n \times n}$ ,  $\Sigma \in R^{n \times m-1}$ ,  $\tilde{V}^* \in R^{m-1 \times m-1}$ ,  $\tilde{U} \in R^{n \times r}$ ,  $\tilde{\Sigma} \in R^{r \times r}$ ,  $\tilde{V}^* \in R^{r \times m-1}$ , where  $rem$  represents the remainder, and  $*$  indicates the conjugated transpose,  $m-1-r$  represents the singular value.

When Equation (4) is reduced with appropriate  $r$  selection, the approach to the matrix  $A$  is as follows.

$$\tilde{A} = \tilde{U}^* \tilde{V} \tilde{\Sigma}^{-1}$$

Eigen-decomposition of  $\tilde{A}$  is obtained in  $\tilde{A}W = W\Lambda$ .

The columns of  $W$  are eigenvectors of  $A$  and  $\lambda_k$  are eigenvalues of  $A$ , ( $\lambda_k$  are diagonal elements of  $\Lambda$ ).

DMD method computes the following relationship between the eigenvectors of  $\tilde{A}$  and the dynamic modes of  $A$  and the columns of  $\Phi$ ;

$$\Phi = X' \tilde{V} \tilde{\Sigma}^{-1} W.$$

The approximation solution  $x(t)$  is found in all time steps as follows.

$$x(t) \approx \sum_{k=1}^r \Phi_k \exp(\omega_k t) b_k = \Phi \exp(\Omega t) b.$$

$\omega_k = \ln(\lambda_k) / \Delta t$ ,  $\Omega = \text{diag}(\omega)$  is a diagonal matrix with diagonal elements  $\omega_k$ ,  $b_k$  is the initial condition for each dynamic mode.

### 3.2. Dynamic Mode Decomposition with Control (DMDc) algorithm

In the Dynamic Mode Decomposition with Control (DMDc) algorithm, data is stored as a state and control matrix [11]. Here,  $X$ ,  $X'$  are state matrices and  $Y$  is the control matrix given below.

$$X = \begin{bmatrix} \uparrow & \uparrow & & \uparrow \\ x_1 & x_2 & \dots & x_{m-1} \\ \downarrow & \downarrow & & \downarrow \end{bmatrix} \quad X' = \begin{bmatrix} \uparrow & \uparrow & & \uparrow \\ x_2 & x_3 & \dots & x_m \\ \downarrow & \downarrow & & \downarrow \end{bmatrix} \quad Y = \begin{bmatrix} \uparrow & \uparrow & & \uparrow \\ u_1 & u_2 & \dots & u_{m-1} \\ \downarrow & \downarrow & & \downarrow \end{bmatrix}$$

The aim of DMDc is to analyze the relationship between a future system measurement with the current measurement and the current control measurement given by the following:

$$x_{k+1} = Ax_k + Bu_k \quad (5)$$

where  $x_j \in R^n$ ,  $u_j \in R^l$ ,  $A \in R^{n \times n}$  and  $B \in R^{n \times l}$ .

To find best-fit operators  $A$  and  $B$  for the dynamical system in Eq. (5) can be manipulated by giving the following representation.

$$X' = [A \quad B] \begin{bmatrix} X \\ Y \end{bmatrix} = G\Omega \quad (6)$$

And then performed the given below steps to find DMDc modes.

- 1) Compute the singular value decomposition of  $\Omega$  with truncation value  $p$

$$\Omega \approx \tilde{U} \tilde{\Sigma} \tilde{V}^* \quad (7)$$

(\* is a conjugate transpose)

- 2) Compute the singular value decomposition of  $X'$  with truncation value  $r$

$$X' \approx \hat{U} \hat{\Sigma} \hat{V}^* \quad (8)$$

- 3) Compute the approximation of the operators  $G = [A \quad B]$  compute the following:

$$\tilde{A} = \hat{U}^* X' \tilde{V} \tilde{\Sigma}^{-1} \tilde{U}_1^* \hat{U} \quad (9)$$

$$\tilde{B} = \hat{U}^* X' \tilde{V} \tilde{\Sigma}^{-1} \quad (10)$$

- 4) Perform the eigenvalue decomposition given by the following:

$$\tilde{A} W = W \Lambda \quad (11)$$

- 5) Compute the dynamic modes of the operator  $A$  by the same way DMD

$$\Phi = X' \tilde{V} \tilde{\Sigma}^{-1} \tilde{U}^* \hat{U} W \quad (12)$$

### 3.3. Error metrics

In this section, the error values are calculated by taking the differences between the real state matrix  $X$  and each cell of the  $X_{DMD}$  and  $X_{DMDc}$  created by the DMD and DMDc algorithms, respectively. Here,  $X_{DMD}$  and  $X_{DMDc}$  are matrices has  $81 \times 30$  dimensions. Used error metrics in this study; RMSE, MAE and MAPE, which are used for time series applications.

Root Mean Square Error (RMSE)

It is an error metric calculated by taking the square root of the mean of the sum of the squares of the differences between the estimated model and the actual value. Its formula is as follows [15].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2}$$

Mean Absolute Error (MAE)

It is the error metric calculated by taking the average of the sum of the absolute values of the differences between the estimated model and the actual value [15].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i|$$

Mean Absolute Percentage Error (MAPE)

It is the percentage of the sum of the absolute values of the difference between the predicted values and the real values [15].

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right|$$

$y_i$  = real value

$y'_i$  = predicted value

$n$  = number of observations

## 4. Results and Discussion

There are two types of control mechanisms to prevent the spread of epidemic diseases. The first is the restriction of human mobility and the second is the direct control technique vaccine. The first example of control-type human mobility restriction was discussed in the study [14]. The COVID-19 epidemic in the US state of Florida was estimated by parameterizing the control matrix according to the percentage of people using areas such as shopping malls, parks, and public transportation. In this study, the second type, direct vaccination control, was examined. The control diagram of epidemic diseases is given in Fig2.

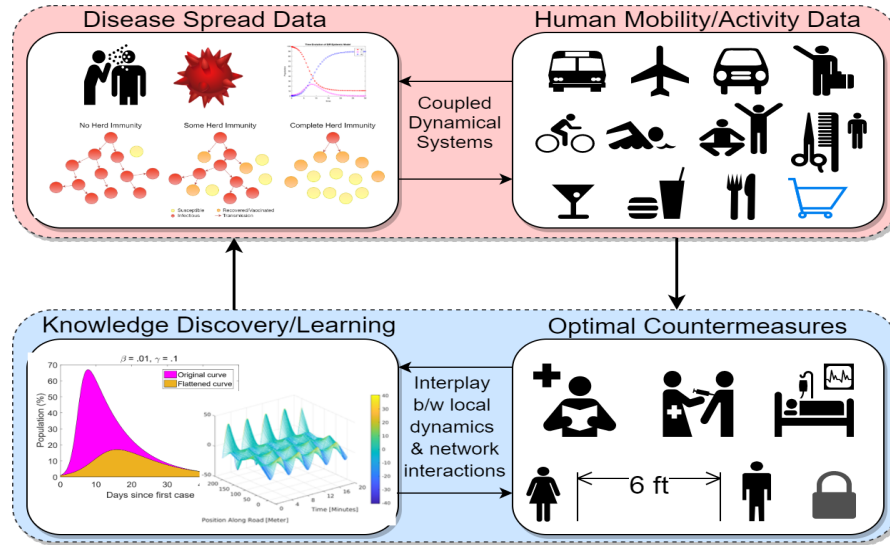


Fig. 2. The control diagram of epidemic diseases [14]

Dynamic Mode Decomposition with Control (DMDc) can be applied to the field of computational epidemiology focusing on the eradication and reduction of diseases [9]. In this study, we applied the DMDc method to the weekly number of COVID-19 cases per 100 thousand people in 81 provinces of Turkey between February 8 and September 11, 2021, as a state matrix and the total number of vaccinations per 100 thousand people in the same time interval was used as control matrix. The data set used is TC Retrieved from the Ministry of Health TURCOVID19 Open Data site [16], [17]. Its website is shown in Fig.3. Dynamic Mode Decomposition (DMD) and DMDc methods were applied to this data set in Matlab; computed singular value decomposition of  $\Omega$  with truncation value  $p$  in (3), computed the singular value decomposition of  $X'$  with truncation value  $r$  in (4), computed the approximation of the operators  $A$  and  $B$  in (5), (6) performed the eigenvalue decomposition in (7), computed the dynamic modes of the operator  $A$  in (8). The results were compared for both methods and error metrics such as Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE) were calculated.

Fig.3. The website of TURCOVID19 [16], [17].

The matrix  $X$  represents the weekly cumulative number of cases per 100 thousand people in 81 provinces between February 8 and September 11, 2021. The control matrix  $Y$  represents the weekly cumulative number of vaccinations per 100 thousand people in the same date range. The DMD and DMDc algorithms were applied to each case, respectively. The state estimate error values calculated by selecting the  $r$  and  $p$  dimension parameters that give the smallest error value in the error metric are given in the table below.

Table 1. Comparison of DMD and DMDc Error

Error Metrics	DMD	DMDc
RMSE	90,0868	0,7907
MAE	63,3380	0,4136
MAPE	52,3908	0,9953

As shown in Table 1, it was seen that the performance of DMDc smaller than DMD errors under the RMSE, MAE, MAPE error metrics. The comparison of the number of COVID-19 cases in Turkey with the outputs of the DMD and DMDc algorithms is illustrated in three-dimensional plots in Matlab, as shown below in Fig. 4, Fig. 5, Fig. 6.




Fig. 4. Original Turkey COVID-19 Data Case Number




Fig. 5. Prediction of DMD Turkey COVID-19 Case Number




Fig. 6. Prediction of DMDc Turkey COVID-19 Case Number

In these figures, the x-axis represents the number of weeks (time), the y-axis represents the 81 provinces of Turkey, and the z-axis represents the total number of COVID-19 cases in Turkey.

## 5. Conclusions and Future Work

As a result, in this study, the situation matrix for the Turkey COVID-19 data set is taken as the weekly cumulative number of cases per 100 thousand people in Turkey's 81 provinces between February 8 and September 11, 2021. The control matrix is taken as the weekly cumulative number of vaccinations per 100 thousand people in the same time interval. Then DMD and DMDc algorithm errors are calculated. The error of the Dynamic Mode Decomposition with Control (DMDc) algorithm, in which the state estimation of the system is made by including the parameter (vaccination) that negatively affects the nature of the dynamic system, is smaller than the Dynamic Mode Decomposition (DMD) algorithm in all error metrics (RMSE, MAE, and MAPE).

The difference between this study and others in the literature is that for Dynamic Mode Decomposition with Control (DMDc) applications, data sets obtained from numerical solutions or simulations are not used, but rather real data is used directly. There are few studies in the literature where the DMDc method has been applied to real data sets [16], [17].

Notably, the DMDc approach demonstrates reduced state prediction errors across various error metrics when compared to the standard DMD method, particularly in the context of limited data a noteworthy outcome of this research.

However, the DMDc method cannot predict the future state due to the small amount of data set. As a future work, we aim to make a future state estimation of Turkey's COVID-19 case number using the DMDc algorithm and data augmentation techniques.

## Acknowledgment

This article was produced from the dissertation of the first (second) author.

## Conflict of Interest Statement

The authors declare that there is no conflict of interest.

## References

- [1] W. O Kermack and A. G. Mckendrick, "A contribution to the mathematical theory of epidemics," *Proceedings of the Royal Society of London*, vol. 115, no. 772, pp. 700–721, Aug. 1927. doi:10.1098/rspa.1927.0118
- [2] R. M. Anderson and R. May, *Infectious diseases of humans : dynamics and control*. Oxford University Press, 1991.
- [3] H. W. Hethcote and P. V. Driessche, "An SIS epidemic model with variable population size and a delay," *J Math Biol*, vol. 34, no. 2, pp. 177–194, 1995. doi:10.1007/BF00178772
- [4] L. J. S. Allen, "A primer on stochastic epidemic models: Formulation, numerical simulation, and analysis," *Infect Dis Model*, vol. 2, no. 2, pp. 128–142, May 2017. doi:10.1016/j.idm.2017.03.001
- [5] S. A. Alanazi, M. M. Kamruzzaman, M. Alruwaili, N. Alshammari, S. A. Alqahtani and A. Karime, "Measuring and preventing COVID-19 using the SIR model and machine learning in smart health care," *J Healthc Eng*, vol. 2020, November 2020. doi:10.1155/2020/8857346
- [6] B. M. Ndiaye, L. Tendeng, and D. Seck, "Analysis of the COVID-19 pandemic by SIR model and machine learning technics for forecasting," *ArXiv*, Apr. 2020. [Online]. Available: <https://arxiv.org/abs/2004.01574v1>. [Accessed: Dec. 09, 2023.]
- [7] P. J. Schmid, "Dynamic mode decomposition of numerical and experimental data," *J Fluid Mech*, vol. 656, pp. 5–28, July 2010, doi:10.1017/S0022112010001217
- [8] J. H. Tu, C. W. Rowley, D. M. Luchtenburg, S. L. Brunton, and J. N. Kutz, "On dynamic mode decomposition: Theory and

applications,” *Journal of Computational Dynamics*, vol. 1, no. 2, pp. 391–421, Nov. 2013, doi:10.3934/jcd.2014.1.391

[9] S. L. Brunton, J. L. Proctor, and J. N. Kutz, “Discovering governing equations from data by sparse identification of nonlinear dynamical systems,” *Proc Natl Acad Sci U S A*, vol. 113, no. 15, pp. 3932–3937, Apr. 2016, doi:10.1073/PNAS.1517384113/SUPPL\_FILE/PNAS.1517384113.SAPP.PDF

[10] J. N. Kutz, S. L. Brunton, B. W. Brunton, and J. L. Proctor, *Dynamic Mode Decomposition: Data-Driven Modeling of Complex Systems*. SIAM, Nov. 2016. doi:10.1137/1.9781611974508

[11] J.L.Proctor, S.L.Brunton, and J. N. Kutz, “Dynamic mode decomposition with control,” *SIAM J. Applied Dynamical Systems*, vol. 15, no. 1, pp. 142–161, Jan. 2016. doi:10.1137/15M1013857

[12] B. Dekhici, B. Benyahia, and B. Cherki, “Dynamic mode decomposition with control for data-driven modeling of anaerobic digestion process,” *CARI*, Oct. 2022. [Online]. Available: <https://hal.science/hal-03696038>. [Accessed: Dec. 09, 2023.]

[13] A. Onstenk, “Simulations in the Loop: Model Based Control for a Plastic Forming Process,” Master, Eindhoven University of Technology, 2021.

[14] S. Mustavee, S. Agarwal, C. Enyioha, and S. Das, “A linear dynamical perspective on epidemiology: interplay between early COVID-19 outbreak and human mobility,” *Nonlinear Dyn*, vol. 109, no. 2, pp. 1233–1252, Jul. 2022. doi:10.1007/s11071-022-07469-5

[15] T. Chai and R. R. Draxler, “Root mean square error (RMSE) or mean absolute error (MAE)? -Arguments against avoiding RMSE in the literature,” *Geosci Model Dev*, vol. 7, no. 3, pp. 1247–1250, Jun. 2014. doi:10.5194/gmd-7-1247-2014

[16] A. Uçar et al., “Türkiye’de Covid-19 Pandemisinin Monitörizasyonu İçin Interaktif Ve Gerçek Zamanlı Bir Web Uygulaması: TURCOVID19,” *Anadolu Kliniği Tıp Bilimleri Dergisi*, vol. 25, no. Special Issue on COVID 19, pp. 154–155, Mar. 2020. doi:10.21673/anadoluklin.726347

[17] “TURCOVID19.” [Online]. Available: <https://turcovid19.com/>. [Accessed: Dec. 09, 2023.]

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license





# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### The intersection of Blockchain and Malware: A Comprehensive Review and Analysis

Egemen Taşkın<sup>a</sup>, İbrahim Alper Doğru<sup>b</sup>

Submitted: 17.11.2023 Revised: 21.12.2023 Accepted: 23.12.2023 doi:10.30855/gmbd.0705S07

#### ABSTRACT

**Keywords:** Blockchain, Malware, Machine Learning

<sup>a</sup> Gazi University,  
Technology Faculty,  
Dept. of Information Security  
Engineering  
06560 - Ankara, Türkiye  
Orcid: 0000-0001-8241-2145  
e mail: [egementaskin@gmail.com](mailto:egementaskin@gmail.com)

<sup>b</sup> Gazi University,  
Technology Faculty,  
Dept. of Computer Engineering  
06560 - Ankara, Türkiye  
Orcid: 0000-0002-5979-4197

\*Corresponding author:  
[egementaskin@gmail.com](mailto:egementaskin@gmail.com)

Blockchain, as a type of distributed ledger technology, emerged as a reliable and transparent mechanism. Its key features are immutability, cryptographic encryption, auditability, and traceability. Blockchain technology, which started with the leadership of the financial sector, has spread to different sectors such as health, supply chain, real estate, law, and information security. Blockchain, integrated with technologies such as Industry 4.0, Internet of Things, Machine Learning and Artificial Intelligence, has caused both progress and challenges in the field of cybersecurity. Malicious actors produce and distribute blockchain-based malware using Industry 4.0 tools. This research contributes to one main issue: Examining current and advanced malware for blockchain systems and detection. In conclusion, this research highlights the critical importance of understanding the interaction between blockchain and malware. Revealing the emerging risks and challenges in this field, this study aims to equip researchers and cybersecurity practitioners with valuable knowledge to strengthen blockchain networks and effectively combat malicious threats.

### Blokszincir ve Kötü Amaçlı Yazılımların Kesişimi: Kapsamlı Bir İnceleme ve Analiz

#### ÖZ

Blokszincir, dağıtık defter teknolojisinin bir türü olarak, güvenilir ve şeffaf bir mekanizma olarak ortaya çıkmıştır. Temel özellikleri değişmezlik, kriptografik şifreleme, denetlenebilirlik ve izlenebilirliktir. Finans sektörünün öncülüğünde başlayan blokszincir teknolojisi, sağlık, tedarik zinciri, emlak, hukuk ve bilgi güvenliği gibi farklı sektörlerle yayılmıştır. Endüstri 4.0, Nesnelerin İnterneti, Makine Öğrenmesi ve Yapay Zekâ gibi teknolojilerle entegre edilen blokszincir, siber güvenlik alanında hem ilerlemeye hem de zorluklara neden olmuştur. Kötü niyetli aktörler, Endüstri 4.0 araçlarını kullanarak blokszincir tabanlı kötücül yazılımlar üretmekte ve dağıtmaktadır. Bu araştırma, blokszincir sistemlerine yönelik güncel ve ileri düzeydeki kötücül yazılımların incelenmesi ve bunların nasıl tespit edildiğini ele almaktadır. Sonuç olarak, bu araştırma blokszincir ve kötücül yazılımlar arasındaki etkileşimi anlamının kritik önemini vurgulamaktadır. Bu alanda ortaya çıkan riskleri ve zorlukları ortaya çıkaran bu çalışma, araştırmacıları ve siber güvenlik uygulayıcılarını blokszincir ağlarını güçlendirmek ve kötü niyetli tehditlerle etkili bir şekilde mücadele etmek için değerli bilgilerle donatmayı amaçlamaktadır.

**Anahtar Kelimeler:** Blokszincir, Kötücül Yazılım, Makine Öğrenmesi

## 1. Giriş (Introduction)

Genel olarak dağıtılmış defter teknolojisi olarak tanımlanan blokzincir, birbirini tanımayan bireyler veya uygulamalar arasında şeffaf bir şekilde güven sağlar [1]. Bu güven değişmezliğe, kriptografik şifrelemeye, denetlenebilirliğe ve çoğunlukla izlenebilirliğe dayanmaktadır [2]. Böylece birbirini tanımayan kimlikler arasında güven tesis etmek makul bir düzeye geldi. Blokzincir kullanımı, özellikle kripto para birimlerinin [3] yaygınlaşmasıyla birlikte kendisine daha geniş bir alan açmıştır. Bu noktada ana itici gücün finans sektörü olduğu söylenebilir. Ancak son zamanlarda finans dışında sağlık, tedarik zinciri, gayrimenkul, hukuk, bilgi güvenliği gibi farklı sektörlerden birçok kurum/kuruluş da blokzincir teknolojisini sunduğu fırsatlardan yararlanmaya başlamıştır. Blokzincir, izin verilen (özel), yetkisiz (kamuya açık) ve hibrit (konsorsiyum) gibi seçeneklerin yanı sıra verilerin zincir üzerinde mi yoksa zincir dışı mı tutulacağına karar veren varlıklar tarafından kullanılabilir [5]. Endüstri 4.0'in hayatımıza girmesiyle birlikte Nesnelerin İnterneti, Makine Öğrenimi ve Yapay Zekâ ile blokzincir teknolojisindeki gelişmeler siber güvenliği bir adım öteye taşımakta ve saldırıların özelliklerinde de ciddi gelişmelere neden olmaktadır [6]. Endüstri 4.0 teknolojik araç ve yöntemlerinin yardımıyla kötü amaçlı yazılım yaratıcıları, farklı türde bir blok zinciri kullanmayı ve savunucular tarafından kaldırılmayan kontrol bilgilerini yaymak için esnek tasarım ilkesini kullanmayı amaçlıyor [7]. Bu sebeplerden dolayı blokzincir teknolojisi ve kötücül yazılımları birlikte düşünmek gerekli hale gelmiştir. Bu çalışmanın temel araştırma katkısı; blokzincirleri hedefleyen son teknoloji kötü amaçlı yazılımların bir incelemesini sunmaktır. Bu makalenin geri kalanı şu şekilde düzenlenmiştir. Bölüm 2, bu çalışmanın oluşturulmasında kullanılan yöntemi açıklar. Bölüm 3'te blokzincirleri hedefleyen ve ona karşı savunma tekniklerini hedefleyen kötü amaçlı yazılımlara ve tespitine yönelik bir inceleme sunar. Bölüm 4, sonuç açıklamalarını ve tartışmayı sunar.

## 2. Yöntem (Method)

Bu araştırma, Sistematik Literatür Taraması metodolojisi ile yapılandırılmıştır. Tarama protokolü; kaynak seçimi, arama yöntemleri, kalite kriterleri ve veri sentezi stratejilerini belirlemeyi amaçlayan herhangi bir Sistematik Literatür İncelemesinin (SLR) kritik bir unsurudur [8]. Araştırma konusunda temel arama terimleri türetilmiştir. Arama sorgusu aşağıdaki gibi oluşturulmuştur: ("blockchain" veya "malware"). Web of Science ve Scopus gibi iki tanınmış dijital kütüphane üzerinden birincil çalışmalar için çevrim içi bir arama gerçekleştirilmiştir. İlk arama sürecinde 216 makale bulunmuştur. Daha sonra birincil çalışmaları seçmek için aşağıdaki dört adım uygulanmıştır:

Adım 1: Araştırma odakları uymayan çalışmaları elemek için başlıkları incelenmiştir.

Adım 2: Geriye kalan çalışmaların özetleri ve anahtar kelimelerini incelenmiştir. Eğer özetler veya anahtar kelimeler gerekli bilgiyi içermiyorsa, çalışmanın ilgili olup olmadığını belirlemek için sonuçlar ve sonuç bölümlerini incelenmiştir.

Adım 3: Farklı kütüphanelerden elde edilen aynı makaleler tespit edilip tekilleştirilmiştir.

Adım 4: Geriye kalan çalışmalar, Tablo 1'de belirtilen dahil etme ve dışlama ölçütleri kapsamında filtrelenmiştir.

Tablo 1. Yayın dahil etme ve dışlama ölçütleri

Dahil Etme Ölçütü	Dışlama Ölçütü
Sadece konferans bildirimlerini ve bilimsel dergi makalelerini potansiyel çalışmalar olarak tut	Akademik olmayan makale ve bildirimleri hariç tut
Sadece blokzincir ve kötücül yazılımları ele alan akademik yayınları tut	Yayınlanmamış çalışmaları, lisans üstü tezleri, teknik raporları, gazete makalelerini, posterleri ve kısa makaleleri hariç tut
Aynı araştırmanın ve aynı yazar(lar)ın en son versiyonunu tut	Aynı yazar(lar) tarafından yayımlanan akademik makalelerinin ön konferans bildirimlerini hariç tut

## 3. Bulgular (Findings)

Günümüzde dijital tehditler, bilgisayar kullanıcılarını ve kurumları giderek daha karmaşık ve çeşitli biçimlerde hedef almaktadır. Taranan makalelerin incelenmesi neticesinde; blokzincir bağlamında bu tehditler arasında öne çıkan bazı önemli kategoriler; kötü amaçlı kripto madenciliği, fidye yazılımları ve ortalama saldırıları olduğu görülmüştür. Kötü Amaçlı Kripto Madenciliği, siber suçuların, kullanıcıların veya kurumların bilgisayar kaynaklarını izinsiz olarak kullanarak kripto para birimleri elde etmeye çalıştığı bir

yöntemdir. Fidyeye Yazılımları, dosyaları şifreleyerek erişimi engelleyen ve genellikle fidye talep eden kötü niyetli yazılımlardır. Ortalama ise sahte iletişim araçları veya web siteleri kullanılarak kişisel bilgilerin çalınmasını amaçlayan bir siber saldırı türüdür. Bu üç tehlikeli tehdidin detaylı bir şekilde incelenmesiyle, bu saldırılar blokzincir bağlamında detaylıca ele alınacak ve bunlara karşı hangi etkili önlemler geliştirildiği hakkında bilgi sağlanacaktır.

### 3.1. Kötü Amaçlı Kripto Madenciliği (Cryptojacking)

Kullanıcının rızası veya izni ile yapılan madencilik işlemine gönüllü madencilik(authedmine) denilirken; kullanıcının izni olmadan yapılan madencilik, kötü amaçlı kripto madenciliği [9] olarak adlandırılır. Kötü amaçlı kripto madenciliği temel olarak tarayıcı ve uygulama tabanlı olmak üzere iki kategoride incelenebilir. Tarayıcı tabanlı olarak, ziyaret edilen web sitesinden madencilik yapan JavaScript kodu veya web derlemesi indirilir ve tarayıcı aracılığıyla korumalı alanda(sandbox) çalıştırılır. Diğerinde ise madencilik gizli olarak arka planda kişisel bilgisayar uygulamaları veya mobil uygulamalar üzerinden yapılır. Blokzincir dünyasında birçok mutabakat protokolü olmasına rağmen en popülerleri Bitcoin'de de kullanılan iş kanıtıdır (Proof of Work). En popüler olan Bitcoin, kimlikleri gizler ancak işlemleri izlenebilir. Ancak Monero tam bir anonimlik sağlar. Ayrıca Bitcoin madenciliği için ciddi kaynaklar (GPU, ASIC vb.) gerekli olsa da Monero isimli kripto para, CryptoNight iş kanıtı [10] mutabakat protokolünü kullanarak düşük CPU kullanımı ile işlemleri gerçekleştirebilmektedir. Bu nedenle kötü amaçlı kripto madenciliği konusunda en çok tercih edilen kripto para birimlerinden biri Monero'dur.

#### 3.1.1. Tarayıcı Temelli (Browser Based)

Günümüzde JavaScript kabiliyetleri açısından çok güçlü ve kullanımı popüler hale gelmiştir. JavaScript kullanılarak web uygulamalarının yanı sıra sunucu ve mobil uygulamalar dahi geliştirilebilmektedir. Bugün web tabanlı ön uç uygulamalarının neredeyse %98'i JavaScript [11] kullanmaktadır. Bu nedenle saldırganların hedefi haline gelmiştir. Kötü amaçlı kripto madenciliği dünyasındaki en bilinen komut dosyası, web sitesi sahiplerinin web sitelerine kripto madencisi koymasına izin veren bir hizmet olan CoinHive aracılığıyla yayınlanmıştır. Bu hizmet artık kullanılmasa da CoinHive betiği günde milyonlarca kez başka yöntemler aracılığıyla istemciler tarafından indirilmekte olup, bu da kötü amaçlı kripto madenciliğinin hala saldırganlar için hedef haline gelmesine neden olmaktadır [12]. Kötü amaçlı kripto madenciliğini tarayıcı aracılığıyla yaymanın başka bir yolu da içerik yönetim sistemleridir. Bu kripto madenciliği etkinleştirmek için hala bazı WordPress eklentileri bulunmaktadır [13]. Ayrıca saldırganlar, kripto madenciliği yapmaya imkân veren komut dosyasını yaymak için Google'ın DoubleClick reklam platformunu kullanmıştır [14]. Bunların yanı sıra, internet servis sağlayıcıları ve büyük kuruluşlar tarafından kullanılan MicroTik yönlendiricilerinin güvenlik açığı nedeniyle, Brezilya'da SSL kullanmayan web sayfalarına bazı kripto madencilik komut dosyaları eklenmiştir [15].

Tarayıcı temelli kötü amaçlı kripto madenciliğinin tespiti NoCoin projesiyle başlamaktadır [16]. Bu proje, tarayıcı eklentisi ile DNS kara listeleri yayınlamak web madenciliğini engellemeye amaçlanmaktadır. Ancak zamanla birçok web sitesine kötü amaçlı kripto madenciliği sağlayan komut dosyalarının enjekte edilmesiyle, böyle bir kara liste tutmak mantıksız bulunmuştur. Kötü amaçlı kripto madenciliği Web Assembly yoluyla da yaygınlaştırılabilmektedir. Web Assembly (WASM); C, C++ gibi yüksek seviyeli programlama dilleri için taşınabilir program olarak hizmet eden bir ikili komut formatıdır. Web Assembly, web tarayıcılarında neredeyse yerel hızda kod çalıştıran düşük seviyeli bir sanal makine olacak şekilde tasarlanmıştır. Bu, geleneksel olarak yalnızca JavaScript gibi teknolojilerle zor olan yüksek performanslı uygulamaların web üzerinde gerçekleştirilmesini amaçlar. WASM programları manuel bir şekilde incelenerek Rüh ve ark. [17] web socketleri dinlenmiş ve WASM komutlarındaki diğer bazı ayırt edici özellikleri (XOR sayısı, kaydırma veya yükleme işlemleri) inceleyerek kötü amaçlı kripto madenciliği tespit edip sınıflandırmıştır. Sonuç olarak, 138 milyon domain üzerinde mevcuttan 5,7 kat daha fazla kötü web sayfası tespit edilebilmiştir. Bunun yanında sözdizimsel özelliklere dayanan algılama yaklaşımları, saldırganlar tarafından kolaylıkla manipüle edilebilmektedir. Ancak, dinamik olarak elde edilen anlamsal kod özelliklerinin karıştırılması(obfuscating) daha zor olmakta ve bu nedenle madenci faaliyetlerinin tespitinde daha kullanışlı olduğu değerlendirilmektedir. SEISMIC [18], WASM komutlarındaki potansiyel kripto hırsızlığı saldırılarını semantik imza eşleştirmesi kullanarak tespit edebilmektedir. Destek Vektör Makineleri (SVM-Support Vector Machine) algoritmasını kullanan çalışma, %98 F1 değeri ile kötü amaçlı kripto madenciliği saldırılarını tespit edebilmekte ve bir tarayıcı eklentisi, vekil sunucu hizmeti veya güvenlik duvarı hizmeti olarak kolayca kullanılabilir. Kripto hırsızlığını tespit etmek için kullanılacak bir diğer yöntem ise işlem kodu

(opcode) analizidir. Carlin ve ark. [19] kripto madenciliğinin dinamik işlem kodu analizini sunan ilk çalışmayı ortaya koymuştur. Bu çalışmada, CPU ile ilgili talimatları izlemek için OllyDbg etkinleştirilmiş ve ardından Intel x86/x64 mimarisindeki izlenen işlem kodları, makine öğrenmesinde kullanmak için CSV dosyasına aktarılmıştır. Çalışma, oluşturulmuş bir veri kümesi içindeki tarayıcı tabanlı kripto madenciliğinin Rastgele Orman (RF-Random Forest) algoritması ile %100'e varan doğrulukla tespit edilebileceğini ispat etmiştir. Outguard [20], büyük bir kripto madenciliği veri seti oluşturarak en iyi yedi özneliği tespit etmiş, kötücül ve iyicil olanları sınıflandırmak için bir Destek Vektör Makinesi modeli kullanarak otomatik bir kripto hırsızlığı tespit sistemi ortaya koymuştur. Outguard; %97,9 doğru pozitif oranı ve %1,1 yanlış pozitif oranı elde etmiştir. Ayrıca Outguard, gereksiz kod blokları ekleme ve yeniden adlandırma gibi yöntemlerle yeniden oluşturulmuş kripto hırsızlığı ikili dosyalarıyla da test edilmiştir. %93 doğru pozitif oranı ve %1,2 yanlış pozitif oranı ulaşarak yanıltma (adversarial evasion) tekniklerine karşı toleranslı olduğu test edilmiştir. MineThrottle[21], tarayıcı içi kripto hırsızlığına karşı savunmanın başka bir yolunu sunmaktadır. Bu çalışma, blok düzeyinde program profili oluşturma adı verilen bir teknik kullanarak madencilikle ilgili kod bloklarını tanımlamakta ve WASM kodunu gerçek zamanlı olarak değiştirerek madencilik davranışını tespit etmektedir. MineThrottle daha sonra kullanıcı tarafından belirlenen politikalara göre madencilik davranışını yavaşlatabilmektedir. MineThrottle en popüler web sitelerinde değerlendirmiş ve tarayıcı içi kripto hırsızlığını tespit etme ve önlemede başarılı olduğunu ortaya koymuştur. Kötü amaçlı kripto madenciliği tespiti, klasik makine öğrenmesi algoritmaları ile yapılabildiği gibi derin öğrenme yöntem ve teknikleriyle de gerçekleştirilebilmektedir. MINOS [22], WASM teknolojisini kullanarak kripto korsanlık yapan kötü amaçlı yazılımları tespit etmek için derin öğrenmeyi kullanan bir tespit sistemidir. Sistem, iyicil web sayfaları ile yetkisiz madencilik için WASM kullananları ayırt etmek için mevcut kötü amaçlı ve iyicil WASM ikili dosyalarının veri kümesiyle eğitilmiş bir evrişimli sinir ağı (CNN-Convolutional Neural Networks) modelini kullanmaktadır. MINOS, WASM ikili dosyaları ve kötü amaçlı kripto madenciliğini içeren web sayfalarından oluşan iki veri kümesi kullanılarak değerlendirilmiştir. Sonuçlar, MINOS'un gerçek örneklerden oluşan derlenmiş bir veri kümesi üzerinde %98,97 doğrulukla WASM tabanlı kripto hırsızlığını tespit etmede son derece etkili olduğunu göstermiştir. Ek olarak MINOS hafif sıklet bir yapıya sahip olup hesaplama açısından ucuz ve platformdan bağımsızdır. Bununla birlikte, kripto korsanlığa yönelik kötü amaçlı yazılımların tespit edilmesi zordur. Çünkü iyi huylu web uygulamaları sıklıkla kripto korsanlığı yapan kötü amaçlı yazılımlarla aynı teknolojileri kullanmaktadır. Mevcut tespit yöntemlerinin, genellikle normal kullanıcılar tarafından erişilemeyen önemli düzeyde bilgisayar yönetimi uzmanlığı veya yürütme izinleri gerektirdiği gözlemlenmektedir. MinerAlert [23], kripto hırsızlığı faaliyetlerini gerçek zamanlı olarak tespit etmek için önerilmiştir. Kullanıcıların kullanımını kolaylaştırmak için bir tarayıcı uzantısı olarak tasarlanmıştır. Ancak MinerAlert'in tarayıcı dışındaki kripto hırsızlığı faaliyetlerini tespit edememesi, yanlış pozitif ve yanlış negatiflere ilişkin kapsamlı bir değerlendirmenin bulunmaması ve MinerAlert'in tarayıcı performansı ve kullanıcı deneyimi üzerindeki olası etkisi gibi bazı sınırlamaları bulunmaktadır. Hernandez-Suarez ve ark. [24] parmak izi tekniği, otomatik kodlama algoritması ve derin, yoğun bir sinir ağı kullanarak web tabanlı kripto hırsızlığını tespit etmek ve karakterize etmek için çok katmanlı bir yaklaşım önermektedir. Önerilen yöntem, normalleştirilmemiş ve normalleştirilmiş veri kümeleri üzerinde gerçekleştirilen deneysel testlerde %99'un üzerinde doğruluk oranıyla, web tabanlı kripto hırsızlığını tespit etme ve karakterize etmede yüksek başarımla elde etmiştir. Ancak çalışmanın; yalnızca belirli bir veri kümesi üzerinde test edilmiş olması ve hesaplama maliyetinin ve diğer son teknoloji yöntemlerle karşılaştırmasının ele alınmadığı değerlendirilmiştir.

Sonuç olarak, web tabanlı ön uç uygulamalarda JavaScript'in popüleritesinin artmasıyla birlikte, kripto hırsızlığı saldırganlar için önemli bir hedef haline gelmiştir. CMS veya Google'ın DoubleClick reklam platformu gibi web sitelerine kripto hırsızlığı eklemenin çeşitli yolları olsa da kripto hırsızlığı faaliyetlerini tespit etmek ve önlemek için çeşitli tespit yöntemleri önerilmiştir. Tespit yöntemleri, sözdizimsel özellik tabanlı algılamadan anlamsal kod özelliği tabanlı algılamaya ve hatta CNN kullanan derin öğrenme tabanlı algılamaya kadar uzanmaktadır. Ancak, kripto hırsızlığı yapan kötü amaçlı yazılımları tespit etmek hala zordur ve mevcut algılama yöntemleri, önemli düzeyde bilgisayar yönetimi uzmanlığı veya yürütme izinleri gerektirir ve bunlara genellikle normal kullanıcılar erişemez. Bu nedenle, son kullanıcıları kripto hırsızlığı saldırılarının kurbanı olmaktan korumak için daha kullanıcı dostu ve erişilebilir tespit yöntemleri geliştirmeye yönelik araştırmaların sürdürülmesi önemlidir.

### 3.1.2. Ana Bilgisayar Temelli (Host Based)

Ana bilgisayar temelli kripto hırsızlığında, kötü amaçlı yazılım genellikle arka planda sessizce çalışır, önemli miktarda işlem gücü tüketir ve ısı üretir, bu da ana sistemi yavaşlatabilir ve potansiyel olarak donanım hasarına neden olabilir. Saldırgan, pahalı madencilik donanımına yatırım yapmak veya onu çalıştıracak

elektriğin bedelini ödemek zorunda kalmadan kripto para birimi kazanarak fayda sağlamaktadır. Ana bilgisayar tabanlı kripto hırsızlığı saldırıları genellikle hassas verilerin çalınmasını veya normal iş operasyonlarının kesintiye uğramasına sebep olmadığı için tespit edilmesi zor olabilmektedir. Ancak mağdur açısından artan enerji maliyetleri, azalan sistem performansı ve lisanssız yazılım çalıştırma nedeniyle potansiyel yasal sorumluluk gibi ciddi sonuçları doğurabilmektedir. Kripto hırsızlığı akıllı telefonları ve Nesnelerin İnterneti (IoT-Internet of Things) cihazlarını da hedef alabilmektedir. Android işletim sisteminde Google Play' e uğramadan uygulama dosyaları doğrudan internet üzerinden indirilip yüklenebilmektedir.

Alanyazında ana bilgisayar temelli kripto hırsızlığını tespit etmek için birçok sistem önerilmiştir. Önerilen sistemlerden ilki olan BitcoinTrap [25], ana bilgisayar tabanlı bir yaklaşım kullanarak Bitcoin madenciliği yapan zombi ağlarını(botnet) tespit etmeyi sağlamıştır. Tespit, uygulamaların en düşük yürütme düzeyinde çalıştırılarak dinamik analizi yoluyla sağlanmaktadır. Bu sistem, dinleyici bileşeninin yeni blokların özetlerini günlüğe kaydettiği ve dedektör bileşeninin kötü niyetli madencilik davranışını tanımlamak için bu günlükleri analiz ettiği asenkron mimariyi kullanmaktadır. BitcoinTrap yaklaşımı, mevcut ticari veya ticari olmayan Bitcoin madenci botnetlerin tespit yöntemleriyle karşılaştırılmamıştır. Ayrıca, değerlendirmesi simüle edilmiş Bitcoin'lere dayanmakta olup gerçek madenci kötü amaçlı yazılımlarına karşı gerçek dünyadaki etkinliği belirsizdir. Ek olarak, BitcoinTrap'i gerçek zamanlı bir tespit sistemine uygulamada ölçeklenebilme ve performans konusunda bilgi verilmemiştir. Ayrıca, önerilen yaklaşımın sınırlamaları ve potansiyel yanlış pozitif/negatif oranları hakkındaki bilgiler yetersiz kalmaktadır. Başka bir çalışma [26], Android kötücül kripto madenciliği amaçlı uygulamaların tespiti ve tanınması için işlevsel ve istatistiksel özelliklerin bir kombinasyonunu kullanan makine öğrenmesi temelli hiyerarşik bir sınıflandırma yöntemi önermektedir. Çalışmada ayrıca, son dönemdeki kötü amaçlı yazılım tehdidi olan fidye yazılımına verilen özel önemden de bahsedilmekte; bu tehdidin yerini blokzincir üzerinde kripto para madenciliği aldığına da değinilmektedir. Her ne kadar makine öğrenmesi ile testlerin gerçekleşeceği ortam belirtilse de deneysel çalışmalar hakkında bilgi sunulmadığı için herhangi bir performans göstergesine rastlanmamıştır.

Berecz ve Czibula[27], kripto hırsızlığını tespit etmek için hem statik hem de dinamik olarak analiz eden bir sistem önermiştir. İyicil uygulamalar ile kripto korsanları arasında ayırım yapmak için seçilen özelliklere göre üç farklı denetimli öğrenme sınıflandırma modeli (SVM, RF, Çok Katmanlı Algılayıcılar (MLP-Multilayer Perceptron)) eğitilmiştir. Sistemin veri kümesi; Malshare, Ninite ve Filehippo dahil olmak üzere çeşitli kaynaklardan oluşturulmuştur. Modeller ortalama %92,46 doğruluk oranı elde etmiştir. Ancak çalışma, kullanılan veri kümesinin boyutu veya belirli özellikleri hakkında belirli ayrıntılar sağlamamakta ve seçilen özelliklerin sınırlamalarını veya eğitim verilerindeki potansiyel önyargıları ve kullanılan denetimli öğrenme sınıflandırma modellerinin veya herhangi birinin potansiyel sınırlamalarını tartışmamaktadır. Ayrıca, iyicil uygulamalar ile kötü amaçlı kripto madenciliği yapan uygulamalar arasında doğru bir şekilde ayırım yapılmasındaki olası zorluklar ve önerilen metodolojinin yeni veya gelişen kripto hırsızlığı türlerine ölçeklenebilirlik veya genelleştirilebilirlik açısından potansiyel sınırlamalar ele alınmamıştır.

Darabian ve ark.[28] kötü amaçlı kripto madenciliği yazılımlarının hem statik hem de dinamik analizi için derin öğrenme tekniklerini, özellikle Uzun Kısa Süreli Bellek(LSTM - Long Short-Term Memory), Dikkat Tabanlı LSTM (ATT(Attention)-LSTM) ve CNN kullanan bir sistem geliştirmiştir. Örnekleri sınıflandırmak ve kötü amaçlı kripto madenciliği yazılımlarını tespit etmek için bu yöntemleri işlem kodu dizilerine ve sistem çağrısı olaylarına uygulamıştır. Statik analiz için sistem, düşük hatalı pozitif oranıyla %95'lik bir doğruluk oranı elde etmiştir. Dinamik analiz için sistem, kötü amaçlı yazılımı çalıştırma ve sistem çağrı olaylarının sıralarını yakalamak için Cuckoo sanal makinesini kullanmıştır. Daha sonra, elde edilen veri setine derin öğrenme yaklaşımları uygulanarak %0,6'lık gibi düşük bir yanlış pozitif oranıyla, %99'luk bir doğruluk oranı elde edilmiştir. Çalışma, derin öğrenme tekniklerini kullanarak kötü amaçlı kripto madenciliği uygulamalarını tespit etmeye odaklanmakta olup karşılaştırma amacıyla diğer geleneksel veya derin öğrenme tabanlı olmayan öğrenme yaklaşımlarını sunmamaktadır. Ayrıca çalışma, pratik uygulamada potansiyel bir sınırlama olabilecek derin öğrenme modellerinin eğitimi ve dağıtımı için gerekli olan hesaplama kaynaklarının ayrıntılı bir analizini sağlamamaktadır. En önemlisi de kötü amaçlı yazılım geliştiricilerinin çalışmada önerilen tespit yöntemlerini atlamak için kullanabileceği kaçınma tekniklerine yönelik bir ifade de bulunmamaktadır.

Vesely ve Zadník[29], kripto para birimi madencilerini tespit etmek için madencilik modellerini belirlemek ve tespit edilen madencileri doğrulamak için ağ trafiğini analiz eden pasif/aktif trafik izleme ve büyük havuzlardan madencilik yazılımı ayrıntılarını toplayan ve bunları kolay erişim için sMaSheD adı verilen bir web uygulamasında saklayan bir madencilik sunucusu katalogu yöntemini geliştirmiştir. Bu aracın

davranışını lisanslı madencilik yazılımlarıyla karşılaştırmış ve biri manuel olarak tasarlanmış, diğeri makine öğrenimine dayalı iki sınıflandırıcı ile değerlendirmiştir. İki aşamalı tespit şemasının tamamının makine öğrenmesi tabanlı sınıflandırıcıyla değerlendirilmesi neticesinde %100 gerçek pozitif ve gerçek negatif sonucu elde edilmiştir. Manuel sınıflandırıcı her sınıfın yaklaşık 10 örneğini doğru bir şekilde tanıyamamış olup; bu da yanlış pozitifler durumunda daha fazla sayıda proba yol açmıştır. Ancak, çalışma kapsamında üç büyük kuruluştan yalnızca üç alt ağa odaklanan deneylerin sınırlı ölçeği, tüm kurumsal ağların çeşitliliğini ve karmaşıklığını tam olarak temsil etmeyebileceği değerlendirilmiştir.

CCEC[30], çeşitli çevrimiçi veri kaynakların(Kaggle, UCI deposu, Buzzfeed, Socrata Açık Veri, Google Veri kümeleri, Wikipedia, Quandl, Quantopian ve Fixshare) kullanılarak kötü amaçlı kripto hırsızlığı yapan yazılımları tespit etmek için harcanan süreyi azaltmaya yönelik bir platform olarak kurgulanmıştır. Bu platform, verileri kümelemek ve küme sayısını tahmin etmek için hafif sıklet bir kümeleme topluluğu yöntemi olan Bayesci Konsensüs Kümelemeyi(Bayesian Consensus Clustering(BCC) kullanmaktadır. Ayrıca RF ve Uyarlanabilir Yükseltme(Adaboosting) dahil olmak üzere birden fazla algoritma, kötü amaçlı yazılımların tespiti için CCEC çerçevesinde temel sınıflandırıcılar olarak test edilmiştir. Yapılan deneysel çalışmalar neticesinde kripto hırsızlığını yapan uygulamaların tespitinde %99,87 doğruluk oranı ile başarımlar elde edilmiştir.

Başka bir çalışma [31], kripto hırsızlığı yapan kötü amaçlı yazılımlara yönelik, ağ kullanımı ve kriptografik kütüphanelere yapılan çağrılar gibi ek ölçümleri içeren, seçilen örneklere göre %93'lük bir doğruluk oranıyla sonuçlanan gelişmiş bir tespit programı önermektedir. Tespit işlemi, bir karar ağacı algoritması için parametreler olarak CPU kullanımı, CPU ve RAM kullanımı ve CPU kullanımının ikinci dereceden sapmasına dayanmaktadır. Çalışma, CPU tabanlı kripto hırsızlarına odaklanmakta ve GPU tabanlı kripto hırsızlarına yönelik bir deney bulunmaması nedeniyle önerilen tespit tekniğinin geliştirilebilirliğini sınırlamaktadır. Ayrıca, deneylerin gerçek dünya senaryolarını doğru şekilde temsil etmeyebilecek bir sanal makine üzerinde gerçekleştirilmesi önemli bir sınırlılık oluşturmaktadır. Sonuçların güvenilirliğini ve genellenirliğini etkileyebilecek, test için kullanılan veri kümesinin boyutu ve çeşitliliği hakkında bilgi bulunmamaktadır. Diğer bir sınırlama ise, tespit programının etkinliği ve doğruluğu hakkında fikir verebilecek yanlış negatiflerin ve yanlış pozitiflerin ayrıntılı bir analizini sağlanmamasıdır.

Sonuç olarak, kötü amaçlı kripto hırsızlığının tespiti için farklı yöntemlerin önerildiği ancak her birinin avantajları ve sınırlamaları olduğu görülmektedir. Bu alandaki araştırmaların daha fazla çalışma ve geliştirilebilirlik açısından daha fazla incelemeyi gerektirmektedir.

### 3.2. Fidyeye Yazılımı (Ransomware)

Fidyeye yazılımı, bir bilgisayar sistemine veya dosyalara erişimi engellemek amacıyla tasarlanan kötü amaçlı bir yazılım türüdür. Bir sistem fidye yazılımına maruz kaldığında, dosyalar şifrelenir ve genellikle kullanıcı veya kuruluşa bir fidye notu sunulurken şifrenin çözülmesi için ödeme talep edilir. Genellikle bir fidye karşılığında, genellikle kripto para ödeme yapılana kadar dosyalar şifrenmiş bir biçimde bekler. Blokzincir teknolojisi doğrudan fidye yazılımı ile bağlantılı olmasa da genellikle kripto paraların kullanıldığı fidye saldırıları için tercih edilen ödeme yöntemleri arasında bir bağlantı bulunmaktadır. Kripto paralar; sınır ötesi işlem kolaylığı, merkezi olmama özelliği, anonimlik sağlaması ve ödemelerin geri alınamaması gibi sebeplerden dolayı tercih edilmektedir. Günümüzde en popüler kripto paralarından biri olan Bitcoin fidye amaçlı da kullanılabilir. Ancak Bitcoin işlemleri, takip edilmesi zor olsa da tamamen anonim değildir ve finansal hareketler IP adresleri ve para akışları aracılığıyla takip edilebilir. Elliptic gibi blokzincir istihbarat şirketleri, Bitcoin ağını analiz etmek ve şüpheli davranış kalıplarını belirlemek için yapay zekayı kullanarak kara para aklamanın tespitini kolaylaştırmaktadır. Blokzincir teknolojisini kötü amaçla kullanan yapılar yeni nesil kripto para birimlerini kullanarak tespit edilme olasılığını daha da azaltabilmektedir [32]. Çoğu kuruluşun fidye yazılımı saldırılarıyla baş etme konusunda siber güvenlik uzmanlığı veya deneyimi bulunmamaktadır. ABD sağlık kurumlarının %85'inin temel siber güvenlik görevleri için nitelikli personelden yoksun olduğu öne sürülmektedir [33]. Dünya Ekonomik Forumu, kripto para daha yaygın olarak benimsendikçe fidye yazılımı saldırılarının artabileceği değerlendirilmekte olup 2027 yılına kadar küresel Gayri Safi Yurt İçi Hasıla (GSYİH)'nın %10'unun blokzincirlerde depolanması da dikkat çekici bir durumdur [34].

Bitcoin'i kötü amaçla kullananların tespiti ve takibi için Bitcoin'in blok yapısı izlenerek bazı çalışmalar yapılmaya başlanmıştır. Huang ve ark.[35] fidye yazılımı ödemelerini, kurbanları ve operatörleri iki yıllık bir süre boyunca izlemek için kullanılan ve fidye yazılımı ikili dosyaları, fidye ödemeleri, kurban telemetrisi ve

Bitcoin adreslerinden oluşan bir veri tabanı gibi çeşitli veri kaynaklarını birleştiren bir ölçüm çerçevesi sunmaktadır. Finansal işlemlerin izlenmesi ve BTC-e'nin para çekmek için bir Bitcoin ve nakit değişim ofisi olarak kullanımının belirlenmesi de dahil olmak üzere, fidye yazılımı ekosistemi ve bununla ilişkili üçüncü taraf altyapısının ana hatlarını çizmektedir. Çalışma, artık kullanılmayan bir Bitcoin borsası olan BTC-e'yi, birçok fidye yazılımı operatörünün kazançlarını nakde çevirmek için kullandığı ortak bir platform olarak tanımlamaktadır. Bu çalışmada, aralarında CoinVault, CryptXXX, CryptoDefense, CryptoLocker, CryptoWall, Dharma, Spora ve WannaCry'nin de bulunduğu sekiz fidye yazılım ailesinden uygulamalar sayesinde gerçek kurbanlardan fidye adresleri toplanmıştır. Ayrıca Cerber ve Locky fidye yazılım ailelerinden de tohum fidye adresleri elde edilmiştir. Sonuç olarak 19.750 kurbandan fidye maksatlı 16 milyon dolardan fazla transfer olduğu tespit edilmiştir. Clouston ve ark.[36] 35 fidye yazılımı ile ilgili işlemleri izlemek ve analiz etmek için halka açık Bitcoin bloklarında bırakılan ayak izlerini analiz etmiştir. Bu yöntemi uygulayarak, her bir fidye yazılımı ailesinin alt sınırdaki doğrudan mali etkisini tahmin etmekte ve fidye yazılımı ödemeleri için yasa dışı pazarın büyüklüğüne ilişkin istatistikler sağlamaktadır. 2013'ten 2017 ortasına kadar 35 fidye yazılımı ailesinin alt sınır doğrudan mali etkisinin en az 12.768.536 dolar olduğu değerlendirilmiştir.

Mohatar ve ark.[37] otomasyon ve adil değişim için akıllı sözleşmeleri ve kriptografik temelleri kullanan blokzincir tabanlı fidye yazılımı şemalarının kullanılmasını önermiştir. Bu öneriler Ethereum Ropsten test ağında uygulanmış ve tam bir fidye yazılımı kampanyası yürütmenin kurban başına sadece 3 cent dolar ek maliyet getireceği tespit edilmiştir. Uygun politikalar ve karşı önlemler geliştirmek için bu programları tanımanın ve incelemenin çok önemli olduğunu vurgulanmıştır. Ancak deneyler ve analizlerin, Ethereum Ropsten test ağında gerçekleştirilmesi; bu, önerilen şemaların gerçek dünya senaryosunda performansını ve ölçeklenebilirliğini doğru şekilde yansıtmayabileceği değerlendirilmiştir.

Özer ve diğerleri [38], veri toplamak ve siber suçlara karşı yeterli yöntemler geliştirmek için küresel bir fidye yazılımı merkezinin kurulmasını önermektedir. Siber suçlara karşı etkili yöntemler geliştirmek ve bu saldırıların arkasındaki kişi veya grupları tespit etmek için hem gelişmiş tespit ve önleme sistemlerine hem de veri toplanmasına ihtiyaç duyulduğu vurgulanmaktadır. Ayrıca ilgili Bitcoin adreslerini ve karanlık web sitelerini birbirine bağlamak için grafik bağlantısı analizinin kullanıldığı ve kara listeye alınan Bitcoin adreslerinin anonimleştirilmesine yardımcı olduklarından da bahsedilmektedir. Ancak Bitcoin işlemlerini ortaya çıkarmak veya Bitcoin işlemlerinin anonimliğini azaltmak için önerilen tekniklerin herhangi bir ampirik değerlendirmesinden veya testinden bahsedilmemiştir. CryptoDrop[39] veya ShieldFS[40] gibi mevcut fidye yazılımı tespit ve önleme sistemlerinin başarı oranlarına veya sınırlamalarına ilişkin kapsamlı bir analiz sunulmamıştır.

Karapapas ve diğerleri [41], gelişmiş gizlilik, otomatik ödemeler, düşük maliyet ve düşük genel gider sunan Ethereum akıllı sözleşmelerini ve Gezegenler Arası Dosya Sistemini(IPFS- InterPlanetary File System) kullanarak Hizmet Olarak Fidyeye Yazılımı (RaaS) kavramını ortaya atmıştır. Daha fazla etkinlik, gizlilik ve güvenlik için sıfır bilgi kanıtları ve anonim ödemelerin dahil edilmesiyle sistemin daha da geliştirilebileceği belirtilmektedir. Ancak bir failin, önerilen fidye yazılımını, saldırgan güvenlik araştırmaları için etik sınırlara uygun olarak, bir hizmet planı olarak serbest bırakmasına izin verebilecek ayrıntılı teknik hususlar sunulmamıştır.

Fidyeye yazılımlarına karşı jenerik çözümler sunulsa da doğrudan ilgili alana dair ihtiyaçlara yönelik çözümler de önem arz etmektedir. Örneğin, sağlık sektöründe klinik verileri yönetme ve koruma alanına giderek endişe yaratan konulardan biri, fidye yazılımı saldırılarının artması ve hastanelere ve ulusal sağlık bilgi hizmetlerine küresel olarak önemli tehditler oluşturan hassas bilgi ihlallerinin endişe verici şekilde ortaya çıkmasıdır. Mendes ve ark.[42] tarafından önerilen blokzincir çözümü, fidye yazılımı saldırılarını önleyerek Akıllı Ortam Destekli SAAL(Smart Ambient Assisted Living) veri güvenliğini artırmaktadır. Akıllı telefon tabanlı SAAL, verilerin bütünlüğünü ve gizliliğini sağlayarak yetkili paydaşlara özel kimlik doğrulama yaparak verilere erişmesine ve bunları değiştirmesine olanak tanımaktadır. Temel olarak blokzincir çözümü, kontrollü veri erişimini kolaylaştırırken SAAL hasta verilerini korumaktadır.

Fidyeye yazılımlarının tespiti istatistiksel yöntemler ve makine öğrenmesi yoluyla da yapılabilmektedir. Akcora ve ark[43] fidye yazılımlarını tespit etmek için topolojik veri analizi yöntemini kullanmış ve mevcut sezgisel tabanlı yaklaşımlarla(RF, Ekstrem Gradyan Arttırma(XGBT-Extreme Gradient Boosting), Yoğunluk Tabanlı Uygulamaların Gürültülü Mekânsal Kümelenmesi(DBSCAN-Density-Based Spatial Clustering of Applications with Noise), K-Means) karşılaştırıldığında daha yüksek oranda doğrulukla tespite ulaşılmıştır. Ancak, topolojik veri analizi yaklaşımının sınırlamalarından açıkça bahsedilmemektedir. Ayrıca önerilen

metodolojinin ölçeklenebilirliği veya daha büyük veri kümeleri üzerindeki performansı hakkında herhangi bir bilgi sağlanmamıştır. Ek olarak, fidye yazılımı tespitinin etkinliğini etkileyebilecek yaklaşımlarının potansiyel yanlış pozitif veya yanlış negatif oranları tartışılmamıştır.

Turner ve diğerleri [44], kripto para işlem ağlarındaki fidye yazılımı saldırılarıyla ilişkili çekirdek düğümleri tanımlamak için ağ analizinin kullanımını önermektedir. Ağlardaki düğümlerin konumunu değerlendirmek ve kripto para birimi işlem ağlarındaki fidye yazılımı saldırılarıyla ilişkili riskli düğümleri belirlemek için denetimsiz makine öğrenmesi grafik algoritması olan DeepWalk kullanılmıştır. Ancak analiz sistemi, halen geliştirilme aşamasında olan ve grafik veri bilimi için Neo4j üretim kütüphanesinde yayınlanmayan DeepWalk algoritması tarafından üretilen grafik yerleştirmelerin kalitesine oldukça bağımlı olduğu değerlendirilmiştir.

Sonuç olarak, Bitcoin işlemleri izlenebilir olmasına rağmen fidye yazılımı saldırıları ve hassas bilgi ihlalleri, küresel olarak ciddi bir tehdit haline gelmiştir. Blokzincir ve diğer teknolojiler, bu tür saldırıları önlemek ve siber suçları tespit etmek için potansiyel çözümler sunmaktadır. Ancak bu çözümlerin gerçek dünya senaryolarında ne kadar etkili olduğu, ölçeklenebilirlikleri ve sınırlamaları hakkında daha fazla araştırma ve test gerekmektedir. Ayrıca, siber güvenlik uzmanlarının eğitimi ve bilinçlenmesi ile bu tür saldırılara karşı daha etkili bir savunma sağlanabileceği değerlendirilmektedir. Fidye yazılımı saldırılarına karşı mücadelede çoklu ve entegre bir yaklaşımın benimsenmesi de önemli ve temel bir yaklaşımdır.

### 3.3. Oltalama (Phishing)

Oltalama, kişisel bilgileri sahte iletişimler veya web siteleri aracılığıyla çalmayı amaçlayan kötü niyetli siber saldırıların bir türüdür. Öte yandan, blokzincir teknolojisi verilerin güvenli ve merkezi olmayan bir şekilde kaydedilmesini sağlayan bir teknoloji olarak bilinmektedir. Oltalama veri güvenliğini tehlikeye atarken, blokzincir teknolojisi ise bu tür tehditlere karşı koruma sağlamaktadır. Bu iki kavram, siber güvenlik alanında önemli bir rol oynamaktadır. Her ne kadar birbirinin zıttı kavramlar gibi görünse de oltalama yoluyla Bitcoin veya diğer kripto varlıkların ele geçirilmesine veya cüzdan kimliklerine yönelik girişimler olmaktadır.

Xia ve ekibi [45], COVID-19 temalı kripto para birimi dolandırıcılıklarını araştırmak için hibrit bir yaklaşım kullanmıştır. Bu yaklaşım iki ana adımı içermektedir: 1) rapor edilen dolandırıcılıkların toplanması ve 2) alanlar ve tweet'ler gibi şüpheli varlıklardan toplanan bilgilere dayanarak açıklanmayan dolandırıcılıkların tespit edilmesi. Çalışmada toplam 195 doğrulanmış COVID-19 kripto para dolandırıcılığı ve bu dolandırıcılıklarla ilişkili 200'den fazla blokzincir adresi belirlenmiştir.

Holub ve Connor[45], kimlik avı kampanyalarını tespit etmek için hafif, ölçeklenebilir ve küresel olarak dağıtılmış bir doğal dil işleme temelli bir sistem kullanmıştır. Potansiyel kimlik avı alanlarını belirlemek için özellikle Cisco Umbrella çözümlenici tarafından yakalanan küresel DNS verilerinin analiz edilmesine odaklanmaktadır. Araştırmacılar ayrıca "Coinhoarder" kampanyası adı verilen bir Bitcoin kimlik avı operasyonunu takip etmek için Ukrayna Siber Polisi ile iş birliği yapmıştır. Bu, kanıt ve öngörü toplamak amacıyla kimlik avı halkasının faaliyetlerinin izlenmesini ve araştırılmasını içermektedir. Genel olarak çalışma, kripto para kimlik avının yükselişi ve bununla mücadele çabaları hakkında değerli bilgiler sunsa da teknik ayrıntılar, etkililik değerlendirmesi ve daha geniş kapsamlı sonuçlar açısından sınırlamalara sahiptir.

Guri[47], saldırganların hava boşluklu cüzdanlara sızma için kullandıkları çeşitli yöntemleri tartışmakta; bunlara, cüzdan kurulumu sırasında kötü amaçlı yazılımın önceden yüklenmesi veya gönderilmesi veya çıkarılabilir medya yoluyla sisteme bulaştırılması da dahil etmektedir. Hava boşluklu cüzdanlardan özel anahtarların nasıl çalınabileceğini göstermek için fiziksel, elektromanyetik, elektrik, manyetik, akustik, optik ve termal yöntemler gibi farklı sızma tekniklerini değerlendirmiştir. Bazı gizli kanalları tespit etmek ve engellemek için davranış analizi, makine öğrenimi ve anormallik tespit teknikleri de önerilmiştir, ancak bunlar yüksek yanlış pozitif oranları durumu tartışmalı hale getirmiştir.

Sonuç olarak araştırmalar, blokzincir ile oltalama arasındaki ilişkiyi inceleyerek, bu alandaki zorlukları ortaya koymuştur. Örneğin, COVID-19 dolandırıcılıklarını araştıran bir çalışma, blokzincir ile ilişkilendirilen dolandırıcılıkları incelemiştir. Başka bir çalışma, kimlik avı kampanyalarını tespit etmek için blokzincir teknolojisini kullanmıştır. Ayrıca, cüzdan güvenliği üzerine yapılan araştırmalar, sızma teknikleri ve koruma yöntemleri hakkında bilgi sunmuştur. Bu çalışmalar, blokzincir ve oltalama arasındaki karmaşıklığı anlamamıza yardımcı olurken, daha fazla araştırma ve geliştirme gerekliliğini de vurgulamaktadır.



### 3. Sonuçlar ve Tartışma (Results and Discussion)

Siber güvenlik, günümüz dijital çağında bilgi teknolojilerinin yaygın kullanımıyla birlikte önemli bir konu haline gelmiştir. Bu bağlamda, kötü niyetli siber saldırılar giderek karmaşıklaşmakta ve çeşitlenmektedir. Kripto madenciliği, fidye yazılımları ve ortalama gibi saldırı türleri, siber güvenlik uzmanlarının karşı karşıya kaldığı ciddi tehditler arasında yer almaktadır. Bu makale, bu siber saldırı türleri ile blokzincir teknolojisi arasındaki ilişkileri derinlemesine inceleyerek, blokzincir teknolojisinin siber güvenlikteki potansiyel rolünü ele almaktadır. Kripto madenciliği, dijital varlıkların üretilmesi sürecini ifade eder ve genellikle siber suçlular tarafından kötü amaçlı bir şekilde kullanılır. Blokzincir, kripto paraların temel altyapısını oluşturan ve dağıtık bir yapıya sahip olan teknoloji olarak öne çıkar. Ancak, kripto madenciliğiyle ilgili sorunlar, blokzincirin güvenliğini zorlayabilir. Blokzincir ağlarındaki madencilik faaliyetlerini kontrol etmek ve istenmeyen madencilik girişimlerini tespit etmek için geliştirilen çeşitli yöntemlerle bu sorunlar ele alınabilir. Özellikle, blokzincir tabanlı güvenlik protokollerinin geliştirilmesi, kripto madenciliği tehditlerine karşı daha etkili bir savunma mekanizması sağlayabilir. Fidye yazılımları, bilgisayar sistemlerine sızarak dosyaları şifreleyen ve genellikle fidye ödenmeden önce dosyaların kilidini açmayı vaat eden kötü niyetli yazılımlardır. Blokzincir, merkezi olmayan ve güvenli veri depolama yetenekleri sağlaması açısından fidye yazılımlarıyla mücadelede önemli bir rol oynayabilir. Blokzincir teknolojisi, dosyaların şeffaf ve güvenli bir şekilde depolanmasını sağlar, bu da fidye yazılımlarının etkilerini azaltabilir. Ancak, blokzincir teknolojisinin ölçeklenebilirlik zorlukları ve fidye yazılımlarının evrimi, sürekli bir mücadeleyi gerektirir. Ortalama, kişisel bilgileri ele geçirmek amacıyla yapılan kötü niyetli siber saldırıların bir türüdür. Blokzincir, bu tür saldırılara karşı ek bir güvenlik katmanı sağlayabilir. Özellikle, merkezi olmayan kimlik doğrulama sistemleri ve şeffaf iletişim protokolleri, ortalama saldırılarına karşı etkili bir savunma mekanizması oluşturabilir. Blokzincir tabanlı kimlik doğrulama çözümleri, kullanıcıların dijital kimliklerini güvenli bir şekilde yönetmelerine olanak tanır. Ancak, blokzincirin siber güvenlikteki rolüne odaklanırken, karşılaşılan zorluklar da göz ardı edilmemelidir. Özellikle enerji tüketimi ve ölçeklenebilirlik konuları, blokzincirin geniş ölçekte benimsenmesini sınırlandıran faktörler arasındadır. Gelecekte, blokzincir teknolojisinin bu zorlukları aşarak siber güvenlik alanında daha etkin bir şekilde kullanılabilmesi için daha fazla araştırma ve geliştirme çalışması gerekmektedir. Kötü amaçlı kripto madenciliği, fidye yazılımları ve ortalama gibi siber saldırı türleri, günümüzdeki dijital tehdit ortamının önemli birer unsuru haline gelmiştir. Blokzincir teknolojisi, bu tehditlere karşı potansiyel bir savunma veya izleme aracı olarak öne çıkmaktadır. Ancak, bu potansiyelin gerçekleştirilebilmesi için daha fazla araştırma ve geliştirme yapılması, blokzincirin siber güvenlikteki rolünü tam anlamıyla ortaya koymak için önemlidir. Blokzincir ve siber güvenlik arasındaki kompleks ilişki, siber güvenlik uzmanlarının sürekli olarak bu alanda çalışmalarını sürdürmelerini gerektirmektedir.

### Teşekkür (Acknowledgment)

Çalışma 7373 hibe numarası ile Gazi Üniversitesi tarafından desteklenmiştir. Destekleri için Gazi Üniversitesine teşekkür ederiz.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

- [1] S. Meunier, Transforming Climate Finance and Green Investment with Blockchains: *Chapter 3 – Blockchain 101: What is Blockchain and How Does This Revolutionary Technology Work?*, A. Marke: Ed. Academic Press, 2018, pp. 23–34.
- [2] S. Li, T. Qin and G. Min, "Blockchain-Based Digital Forensics Investigation Framework in the Internet of Things and Social Systems" *IEEE Transactions on Computational Social Systems*, vol. 6, no. 6, pp. 1433-1441, December 2019. doi:10.1109/TCSS.2019.2927431.
- [3] M. A. Zook and J. Blankenship, "New spaces of disruption? The failures of Bitcoin and the rhetorical power of algorithmic governance", *Geoforum*, vol. 96, pp. 248–255, November 2018. doi:10.1016/j.geoforum.2018.08.023
- [4] S. Fosso Wamba, J. R. Kala Kamdjoug, R. Epie Bawack and J. G. Keogh, "Bitcoin, Blockchain and Fintech: a systematic review and case studies in the supply chain", *Production Planning & Control*, vol. 31, no. 2–3, pp. 115–142, December 2020. doi:10.1080/09537287.2019.1631460
- [5] A. A. Sadawi, B. Madani, S. Saboor, M. Ndiaye, and G. Abu-Lebdeh, "A comprehensive hierarchical blockchain system for carbon

- emission trading utilizing blockchain of things and smart contract", *Technological Forecasting and Social Change*, vol. 173, p. 121124, December 2021. doi:10.1016/j.techfore.2021.121124
- [6] M. Javaid, A. Haleem, R. Pratap Singh, S. Khan, and R. Suman, "Blockchain technology applications for Industry 4.0: A literature-based review", *Blockchain: Research and Applications*, vol. 2, no. 4, pp. 100027, December 2021. doi:10.1016/j.bcra.2021.100027
- [7] S. B. ElMamy, H. Mrabet, H. Gharbi, A. Jemai, and D. Trentesaux, "A Survey on the Usage of Blockchain Technology for Cyber-Threats in the Context of Industry 4.0", *Sustainability*, vol. 12, no. 21, November 2020. doi:10.3390/su12219179
- [8] B. A. Kitchenham, "Procedures for Performing Systematic Reviews" *www.inf.ufsc.br*, 2004. [Online]. Available: <https://www.inf.ufsc.br/~aldo.vw/kitchenham.pdf>. [Accessed: Dec. 25, 2023].
- [9] J. R uth, T. Zimmermann, K. Wolsing, and O. Hohlfeld, "Digging into Browser-Based Crypto Mining", in *Proceedings of the Internet Measurement Conference 2018*, Boston, MA, USA, 2018, pp. 70–76. doi:10.1145/3278532.3278539
- [10] E. Le Jamtel, "Swimming in the Monero pools" 2018 11th International Conference on IT Security Incident Management & IT Forensics (IMF), Hamburg, Germany, 2018, pp. 110-114, doi:10.1109/IMF.2018.00016.
- [11] "Usage statistics of client-side programming languages for websites" *W3Techs*, [Online]. Available: [https://w3techs.com/technologies/overview/client\\_side\\_language](https://w3techs.com/technologies/overview/client_side_language). [Accessed: 25-Dec-2023].
- [12] "I now own the COINHIVE domain. here's how I'm Fighting Cryptojacking and doing good things with content security policies." *Troy Hunt*, 02-Apr-2021. [Online]. Available: <https://www.troyhunt.com/i-now-own-the-coinhive-domain-heres-how-im-fighting-cryptojacking-and-doing-good-things-with-content-security-policies/>. [Accessed: 25-Dec-2023].
- [13] "Plugins categorized as mining" *WordPress*, [Online]. Available: <https://wordpress.org/plugins/tags/mining/> [Accessed: 25-Dec-2023].
- [14] D. Goodin, "Now even YouTube serves ads with CPU-draining cryptocurrency miners" *Ars Technica*, Jan. 26, 2018. [Online]. Available: <https://arstechnica.com/information-technology/2018/01/now-even-youtube-serves-ads-with-cpu-draining-cryptocurrency-miners/> [Accessed: 25-Dec-2023].
- [15] C. Osborne, "MikroTik routers enslaved in massive Coinhive cryptojacking campaign" *ZDNET*, [Online]. Available: <https://www.zdnet.com/article/mikrotik-routers-enslaved-in-massive-coinhive-cryptojacking-campaign/> [Accessed: 25-Dec-2023].
- [16] "No coin is a tiny browser extension aiming to block coin miners such as coinhive" *GitHub*, [Online]. Available: <https://github.com/keraf/NoCoin> [Accessed: 25-Dec-2023].
- [17] J. R uth, T. Zimmermann, K. Wolsing, and O. Hohlfeld, "Digging into Browser-Based Crypto Mining", in *Proceedings of the Internet Measurement Conference 2018*, Boston, MA, USA, 2018, pp. 70–76. doi:10.1145/3278532.3278539.
- [18] W. Wang, B. Ferrell, X. Xu, K. W. Hamlen, and S. Hao, "SEISMIC: SEcure In-Lined Script Monitors for Interrupting Cryptojacks", in *Computer Security: 23rd European Symposium on Research in Computer Security, ESORICS 2018, Barcelona, Spain*, September 3-7, 2018, Proceedings, Part II, Barcelona, Spain, 2018, pp. 122–142. doi:10.1145/3278532.3278539.
- [19] D. Carlin, P. O'Kane, S. Sezer and J. Burgess, "Detecting Cryptomining Using Dynamic Analysis" 2018 16th Annual Conference on Privacy, Security and Trust (PST), Belfast, Ireland, 2018, pp. 1-6. doi:10.1109/PST.2018.8514167.
- [20] A. Kharraz, Z. Ma, P. Murley, C. Lever, J. Mason, A. Miller, N. Borisov, M. Antonakakis, M. Bailey, "Outguard: Detecting in-browser covert cryptocurrency mining in the wild" in: *The World Wide Web Conference, WWW '19, Association for Computing Machinery*, New York, NY, USA, 2019, p. 840–852. doi:10.1145/3308558.3313665. doi:10.1145/3308558.3313665.
- [21] W. Bian, W. Meng, M. Zhang, "MineThrottle: Defending against Wasm In-Browser Cryptojacking", *Association for Computing Machinery*, New York, NY, USA, 2020, p. 3112–3118. doi:10.1145/3366423.3380085
- [22] F. Naseem, A. Aris, L. Babun, E. Tekiner, S. Uluagac, "Minos: A lightweight real-time cryptojacking detection system" in: *28th Annual Network and Distributed System Security Symposium, NDSS, 2021*. doi:10.14722/ndss.2021.24444
- [23] F. Tommasi, C. Catalano, U. Corvaglia, I. Taurino, "Mineralert: an hybrid approach for web mining detection", *Journal of Computer Virology and Hacking Techniques*, March 2021. doi:10.1007/s11416-022-00420-7.
- [24] A. Hernandez-Suarez, G. Sanchez-Perez, L.K. Toscano-Medina, J. Olivares-Mercado, J. Portillo-Portilo, J. Avalos and L.J. Garc a Villalba, "Detecting Cryptojacking Web Threats: An Approach with Autoencoders and Deep Dense Neural Networks", *Applied Sciences*, vol. 12, no. 7, 2022. doi:10.3390/app12073234
- [25] A. Zareh and H. R. Shahriari, "Botcointrap: Detection of bitcoin miner botnet using host based approach", in: *2018 15th International ISC (Iranian Society of Cryptology) Conference on Information Security and Cryptology (ISCISC)*, 2018, pp. 1–6. doi:10.1109/ISCISC.2018.8546867.
- [26] S. Soviany, A. Scheianu, G. Suci, A. Vulpe, O. Fratu and C. Istrate, "Android malware detection and crypto-mining recognition methodology with machine learning", in: *2018 IEEE 16th International Conference on Embedded and Ubiquitous Computing (EUC)*, 2018, pp. 14–21. doi:10.1109/EUC.2018.00010

- [27] G. Berecz. and I. Czibula., "Hunting traits for cryptojackers", in: *Proceedings of the 16th International Joint Conference on e-Business and Telecommunications – SECRYPT*, 2019, pp. 386–393. doi:10.5220/0007837403860393
- [28] H. Darabian, S. Hashemi, S. Homayounoot, A. Dehghantanha, H. Karimipour, R. M. Parizi and K. R. Choo, "Detecting Cryptomining Malware: a Deep Learning Approach for Static and Dynamic Analysis", *Journal of Grid Computing*, vol. 18, no. 2, pp. 293–303, Jun. 2020. doi:10.1007/s10723-020-09510-6
- [29] V. Veselý and M. Žádník, "How to detect cryptocurrency miners? By traffic forensics!", *Digital Investigation*, vol. 31, p. 100884, 2019. doi: 10.1016/j.diin.2019.08.002
- [30] S. Balamurugan and M. Thangaraj, "Cryptojacking Malware Detection using the Bayesian Consensus Clustering with Large Iterative Multi-Tier Ensemble in the Cryptocurrency in the Cloud" *International Journal of Recent Technology and Engineering (IJRTE)*, vol. 8, no. 3. Blue Eyes Intelligence Engineering and Sciences Engineering and Sciences Publication - BEIESP, pp. 4256–4264, Sep. 30, 2019. doi:10.35940/ijrte.c5159.098319.
- [31] D. Tanana and G. Tanana, "Advanced Behavior-Based Technique for Cryptojacking Malware Detection" *2020 14th International Conference on Signal Processing and Communication Systems (ICSPCS)*, Adelaide, SA, Australia, 2020, pp. 1-4, doi:10.1109/ICSPCS50536.2020.9310048.
- [32] "Bitcoin Tracker: Wannacry Doesn't Pay." *Pymnts.Com*, May 19, 2017. [Online]. Available: [www.pymnts.com/news/bitcoin-tracker/2017/bitcoin-tracker-wannacry-doesnt-pay/](http://www.pymnts.com/news/bitcoin-tracker/2017/bitcoin-tracker-wannacry-doesnt-pay/) [Accessed: 25-Dec-2023].
- [33] M.Kan "Old Windows Pcs Can Stop WannaCry Ransomware with New Microsoft Patch." *Computerworld.com*, May 13, 2017. [Online]. Available: [www.computerworld.com/article/3196693/old-windows-pcs-can-stop-wannacry-ransomware-with-new-microsoft-patch.html](http://www.computerworld.com/article/3196693/old-windows-pcs-can-stop-wannacry-ransomware-with-new-microsoft-patch.html). [Accessed: 25-Dec-2023].
- [34] "Deep Shift: Technology Tipping Points and Societal Impact", *weforum.org*, Sept. 9, 2023. [Online]. Available: [https://www3.weforum.org/docs/WEF\\_GAC15\\_Technological\\_Tipping\\_Points\\_report\\_2015.pdf](https://www3.weforum.org/docs/WEF_GAC15_Technological_Tipping_Points_report_2015.pdf). [Accessed: 25-Dec-2023].
- [35] D. Y. Huang, M. M. Aliapoulios, V. G. Li, L. Invernizzi, E. Bursztein, K. McRoberts, J. Levin, K. Levchenko, A. C. Snoeren and D. McCoy, "Tracking ransomware end-to-end" in: *2018 IEEE Symposium on Security and Privacy (SP)*, 2018, pp. 618–631. doi:10.1109/SP.2018.00047.
- [36] M. Paquet-Clouston, B. Haslhofer and B. Dupont, "Ransomware payments in the bitcoin ecosystem", *Journal of Cybersecurity*. vol. 5, no. 1. doi:10.1093/cybsec/tyz003.
- [37] O. Delgado Mohatar, J. Sierra-C' amara and E. Anguiano, "Blockchain-based semi-autonomous ransomware", *Future Generation Computer Systems*, vol. 112, pp. 589-603, 2020. doi:10.1016/j.future.2020.02.037
- [38] M. Ozer, S. Varlioglu, B. Gonen and M. Bastug, "A prevention and a traction system for ransomware attacks", in: *2019 International Conference on Computational Science and Computational Intelligence (CSCI)*, 2019, pp. 150–154. doi:10.1109/CSCI49370.2019.00032.
- [39] N. Scaife, H. Carter, P. Traynor and K. R. B. Butler, "CryptoLock (and Drop It): Stopping Ransomware Attacks on User Data," *2016 IEEE 36th International Conference on Distributed Computing Systems (ICDCS)*, Nara, Japan, 2016, pp. 303-312. doi:10.1109/ICDCS.2016.46.
- [40] A. Continella, A. Guagnelli, G. Zingaro, G. Pasquale, A. Barengi, S. Zanero and F. Maggi, "ShieldFS: A Self-Healing, Ransomware-Aware Filesystem", in *Proceedings of the 32nd Annual Conference on Computer Security Applications*, Los Angeles, California, USA, 2016, pp. 336–347. doi:10.1145/2991079.2991110
- [41] D. Mendes, I. Rodrigues, C. Fonseca, M. Lopes, J. M. Garcia-Alonso and J. Berrocal, "Anonymized Distributed PHR Using Blockchain for Openness and Non-repudiation Guarantee", in *Digital Libraries for Open Knowledge*, 2018, pp. 381–385. doi:10.1007/978-3-030-00066-0\_45
- [42] C. Karapapas, I. Pittaras, N. Fotiou and G. C. Polyzos, "Ransomware as a service using smart contracts and ipfs", in: *2020 IEEE International Conference on Blockchain and Cryptocurrency (ICBC)*, 2020, pp. 1–5. doi:10.1109/ICBC48266.2020.9169451
- [43] C. G. Akcora, Y. Li, Y. R. Gel, and M. Kantarcioglu, 'BitcoinHeist: Topological Data Analysis for Ransomware Prediction on the Bitcoin Blockchain', in *Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence, IJCAI-20*, 7 2020, pp. 4439–4445. doi:10.24963/ijcai.2020/612
- [44] A. Turner, S. McCombie and A. Uhlmann, "Follow the money: Revealing risky nodes in a ransomware-bitcoin network" *Machine Learning and Predictive Analytics in Accounting, Finance, and Management*, January 2021. doi:10.24251/HICSS.2021.189.
- [45] P. Xia, H. Wang, H. Wang, X. Luo, L. Wu, Y. Zhou, G. Bai, G. Xu, G. Huang and X. Liu, "Don't Fish in Troubled Waters! Characterizing Coronavirus-themed Cryptocurrency Scams", *APWG Symposium on Electronic Crime Research (eCrime)*, Boston, MA, USA, 2020, pp. 1-14, doi: 10.1109/eCrime51433.2020.9493255.
- [46] A. Holub and J. O'Connor, "COINHOARDER: Tracking a ukrainian bitcoin phishing ring DNS style," *APWG Symposium on Electronic Crime Research (eCrime)*, San Diego, CA, USA, 2018, pp. 1-5, doi: 10.1109/ECRIME.2018.8376207.
- [47] M. Guri, "BeatCoin: Leaking Private Keys from Air-Gapped Cryptocurrency Wallets," *IEEE International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing*

(CPSCom) and IEEE Smart Data (SmartData), Halifax, NS, Canada, 2018, pp. 1308-1316, doi: 10.1109/Cybermatics\_2018.2018.00227.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAE 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### Quality Control Processes In Date Fruit With Artificial Intelligence

Bekir Aksoy<sup>a\*</sup> Mehmet Yücel<sup>b</sup> Hamdi Sayın<sup>c</sup> Nergiz Aydın<sup>d</sup> Özge Ekrem<sup>e</sup>

Submitted: 20.11.2023 Revised: 23.12.2023 Accepted: 23.12.2023 doi:10.30855/gmbd.0705S08

#### ABSTRACT

The physical properties of fruit and vegetable products play an important role in their quality classification. With the existing manual methods, disease, pesticide and quality status of agricultural products are checked during the control stages. Manual sorting and classification of products requires expertise and the process is time consuming and labor intensive. Today, with the developing technology, the processing and marketing of products can be realized in optimum time and efficiency with the software techniques used in the fields of agriculture and food. In this study, date palm fruit, which has an important share in the fruit and vegetable market, is considered. The use of image processing and artificial intelligence techniques in classifying the quality of date fruits makes the sales process more consistent and efficient. Within the scope of the study, four different artificial intelligence techniques were used with a uniquely prepared dataset. The dataset consists of three different classes: good, bad and medium quality dates. The dataset specially prepared for the study was trained with MobileNetV2, ResNetV2-50, DenseNet-201 and Inception-v3 deep learning models. Among the four models used in the study, MobileNetV2 model was determined as the most successful model with 95% accuracy rate.

**Keywords:** Artificial Intelligence, Deep Learning, Agricultural Applications,

<sup>a\*</sup> Isparta University of Applied Sciences  
Faculty of Technology Mechatronics  
Engineering Department 32100 - Isparta  
Türkiye  
Orcid: 0000-0001-8052-9411  
e mail: [bekiraksoy@isparta.edu.tr](mailto:bekiraksoy@isparta.edu.tr)

<sup>b</sup> Isparta University of Applied Sciences  
Faculty of Technology Mechatronics  
Engineering Department 32100 - Isparta  
Türkiye  
Orcid: 0000-0002-4100-5831

<sup>c</sup> Isparta University of Applied Sciences  
Faculty of Technology Mechatronics  
Engineering Department 32100 - Isparta  
Türkiye  
Orcid: 0000-0002-0826-8517

<sup>d</sup> Isparta University of Applied Sciences  
Faculty of Technology Mechatronics  
Engineering Department 32100 - Isparta  
Türkiye  
Orcid: 0000-0002-3921-3295

<sup>e</sup> Isparta University of Applied Sciences  
Faculty of Technology Mechatronics  
Engineering Department 32100 - Isparta  
Türkiye  
Orcid: 0000-0001-9142-405X

\*Corresponding author:  
[bekiraksoy@isparta.edu.tr](mailto:bekiraksoy@isparta.edu.tr)

**Anahtar Kelimeler:** Yapay Zeka, Derin Öğrenme, Tarım Uygulamaları

### Hurma Meyvesindeki Kalite Kontrol İşlemlerinin Yapay Zeka İle Tahminlenmesi

#### ÖZ

Meyve ve sebze ürünlerinin, kalite sınıflandırmasında sahip oldukları fiziksel özellikler önemli bir rol oynamaktadır. Mevcut manuel yöntemler ile tarım ürünlerinin kontrol aşamalarında; hastalık, pestisit ve kalite durumları kontrol edilmektedir. Manuel olarak ürünlerin ayrıştırılıp sınıflandırılması uzmanlık gerektirmekte olup işleyen süreç zaman alıcı ve büyük emek istemektedir. Günümüzde gelişen teknoloji birlikte, tarım ve gıda alanlarında kullanılan yazılım teknikleri ile ürünlerin işlenmesi ve pazara sürülmesi optimum zamanda ve verimlilikle gerçekleştirilebilmektedir. Gerçekleştirilen çalışmada, meyve ve sebze pazarında önemli bir payı olan hurma meyvesi ele alınmaktadır. Hurma meyvelerinin kalitelerinin sınıflandırılmasında görüntü işleme ve yapay zekâ tekniklerinin kullanılması, satış sürecinin daha tutarlı ve verimli hale gelmesini sağlamaktadır. Çalışma kapsamında özgün olarak hazırlanan veri seti ile dört farklı yapay zekâ tekniği kullanılmıştır. Veri seti, iyi, kötü ve orta kalite hurma olmak üzere üç farklı sınıftan oluşmaktadır. Çalışma için özel olarak hazırlanan veri seti MobileNetV2, ResNetV2-50, DenseNet-201 ve Inception-v3 derin öğrenme modelleri ile eğitilmiştir. Çalışmada kullanılan dört model içerisinde MobileNetV2 modeli %95 doğruluk oranı ile en başarılı model olarak belirlenmiştir.

## 1. Giriş (Introduction)

Hurma meyvesi, latince Phoenix dactylifera L. olarak geçen ve insanoğlu tarafından yetiştiriciliği yapıldığı tahmin edilen en eski tarım ürünlerinden birisidir. Yaklaşık 6000 yıldır gıda olarak tüketilmekte olan hurma, yetiştiği topraklarda yaşayan insanlar için ekonomik ve sosyal açıdan çok büyük bir önem taşımaktadır. Yaşam ağacı olarak da adlandırılan hurmanın tarımı 800.000 hektarlık bir alanda yapılmakta ve dünya üzerinde 2000'den fazla çeşidi bulunmaktadır [1]. Hurma özellikle Orta Doğu ülkelerinde ve Kuzey Afrika'da yetişebilen bir meyvedir [2]. Kurutulmuş ya da taze olarak tüketilmesinin yanı sıra hurma meyvesinden çeşitli gıda ürünleri de üretilmektedir. Hurma şurubu, hurma suyu konsantresi, pekmezi, sirkesi ve marmelatı gibi kullanım alanlarının yanında pasta sektöründe de katkı maddesi olarak kullanılmaktadır. Hurma üretiminde ortaya çıkan atıklardan ise kompost gübre üretimi yapılabilmektedir [3].

Tarımsal ürünlerin fiziksel özelliklerinin hasat aşamasında tespit edilmesi, sınıflandırma, nakliye, depolama, işleme ve paketleme sistemlerinin planlama ve tasarımında oldukça önemlidir [4]. Tarımsal çalışmalarda ele alınan temel konulardan birisi de hasat sonrası işleme, taşıma ve depolama sırasında hem niteliksel hem de niceliksel özelliklerde meydana gelen kayıplar göz önüne alındığında, meyve ve sebzelerin hasat sonrası en yüksek kalitede tüketiciye ulaştırılmasının en iyi şekilde nasıl gerçekleştirileceğidir [5]. Son yıllarda tüketiciler özellikle kendi sağlıkları konusunda son derece hassas olup, her zaman kaliteli ve taze organik ürünlere yönelmektedirler. Bu nedenle meyveleri kategorize etmek ve problemleri olanları satış amacıyla pazara göndermeden önce belirleyip elemek oldukça önemlidir [6]. Yıllardır taze veya işlenmiş meyve ve sebzelerin kalitesi, olgunluk, büyüklük, şekil, renk, kir ve hastalıkların varlığı gibi faktörlerin çoğu kalifiye personel tarafından görsel olarak incelenmiştir. Ancak günümüzde bunun yerini bilgisayarla görme ve görüntü analizine dayanan otomatik inceleme sistemleri almıştır [7]. Meyvelerin özelliklerine göre sınıflandırması sırasında el değmeden sınıflandırılması ihracatta verimi arttırmakta ve meyve kabuğunun daha steril olmasını sağlamaktadır. Bu problemi çözmek için modern tarımda teknolojiyi ve özellikle görüntü işleme tekniklerini kullanmak üreticiler için bir çözüm yöntemidir.

Fotoğraf makinesi ve kamera gibi cihazlardan toplanan sayısallaştırılmış görüntülerin bilgisayar yazılımları vasıtasıyla işlenmesi veya analiz edilmesi görüntü işleme olarak tanımlanmaktadır.[8] Karar destek sistemleri için bilgisayarla görme görevleri; dijital görüntüleri toplama, işleme, değerlendirme ve anlamlı sonuçlar çıkarma yöntemlerini içermektedir [9]. Görüntü işleme tekniklerini kullanarak kalite tespiti; görüntü elde etme, ön işleme, segmentasyon, özellik çıkarma ve sınıflandırma olmak üzere beş adımdan oluşmaktadır. Bu süreç, giriş görüntüsünün sonucunun, ön işlemlerine tabi tutularak, görüntüdeki nesne özelliklerini çıkarılıp ardından da tahminlerde bulunarak analiz edilmesine yardımcı olmaktadır [10]. Görüntülerden anlamlı sonuçlar çıkarmada özellikle derin öğrenme yöntemleri sıklıkla kullanılmaktadır. Derin öğrenme kavramı ile birlikte yapay zekâ tabanlı tarım uygulamalarının elde ettiği başarı oranları da hızlı bir şekilde artmaktadır [11].

Gerçekleştirilen çalışmada çalışmaya özgü olarak oluşturulan yüksek çözünürlükte 288 adet hurma meyvesi görüntülerini içeren veri seti MobileNet-V2, ResNetV2-50, DenseNet-201 ve Inception-v3 derin öğrenme yöntemleri kullanılarak eğitilmiştir. Eğitim sonucunda en başarılı derin öğrenme modeli çalışmada kullanılmıştır.

## 2. Literatür Araştırması (Literature Review)

Zhang vd.(2019) çalışmalarında, tasarladıkları 13 katmanlı bir Evrişimsel Sinir Ağı (ESA) modeli ile meyve kategorilerini belirlemeyi amaçlamışlardır. 3600 görüntü ve 18 sınıftan oluşan veri tabanının kullanıldığı çalışmada, eğitim ve test verilerinin %50 - %50 olarak belirlenmiş ve 30 eğitim döngüsü uygulanmıştır. Önerilen modelin genel doğruluk oranı % 94,94 olarak tespit edilmiştir [12].

Kayaalp vd. (2020) çalışmalarında, CAPA veri tabanından alınan elma görüntülerinden derin öğrenme algoritması kullanılarak elmaların çürük ve sağlam olarak sınıflandırılması amaçlamışlardır. Verilerin %80 eğitim ve %20 test olarak ikiye ayrıldığı modelde kullanılan sistemin eğitim ve test aşamaları için dört farklı dalga boyunda, 16 çeşit görüntü kombinasyonu kullanılmıştır. Test aşamasında yapılan ölçümlere göre çürük ve sağlam elmaların tespitinde modelin %91,25 başarı oranı elde etmişlerdir [13].

Büyükarıkan vd. (2020) çalışmalarında, 12 farklı renk sıcaklığıyla elde edilmiş 1000 görüntüden ve 29 sınıftan

oluşan meyve görüntülerini içeren ALOI-COL veri setindeki görüntüleri, ESA mimarilerinden AlexNet, VGG16 ve VGG19 kullanılarak sınıflandırılmışlardır. Veri setindeki görüntüler, görüntü işleme teknikleriyle zenginleştirilmiş ve her sınıftan 51 adet görüntü elde edilmiştir. 50 eğitim döngüsü sonucunda test verileri, VGG16 mimarisinde %100 doğrulukla sınıflandırılmışlardır [14].

Joseph vd. (2021) çalışmalarında, derin öğrenmede ESA kullanılarak meyve sınıflandırması için TensorFlow tabanlı olarak geliştirilen etkili bir model önermişlerdir. Çalışmada görüntüleri farklı kategorilerde sınıflandırabilen 131 farklı meyve ve sebze sınıfını içeren Fruits 360 veri kümesini kullanılmıştır. 50 eğitim döngüsü ile eğitilen model test aşamasında iken %94,35'lik bir doğruluk oranı elde etmişlerdir [15].

Kumari vd. (2022) çalışmalarında, mango meyvesinin sınıflandırılması için CNN ve bulanık sınıflandırıcının bir arada kullanıldığı hibrit bir model önermişlerdir. Çalışmada ilk olarak, görüntülerde segmentasyon gerçekleştirilerek meyvelerin kalitesine, daha sonra da yüzey kusurlarına ve olgunluk durumuna göre sınıflandırılmıştır. Olgunluk kriteri, hibrit bulanık sınıflandırıcı ve CNN kullanılarak olgun, kısmen olgun ve olgunlaşmamış olarak sınıflandırılmıştır. Farklı performans ölçümlerinin karşılaştırmalı analizi, önerilen modelin diğer geleneksel algoritmalara göre etkinliğini kanıtlamışlardır [16].

Kesler vd. (2023) çalışmalarında, muz meyvesinin yedi farklı olgunlaşma evresinin yapay zekâ ile tespiti sağlamışlardır. Muz meyvesinin yedi farklı olgunlaşma evresinden 700 fotoğraf kullanılarak bir veri seti oluşturmuşlardır. Bu veri seti ve AlexNet derin öğrenme mimarisi ile sınıflandırma işlemleri gerçekleştirilmiştir. Kullanılan yapay zekâ modeli ile %96,63 oranında doğru bir sınıflandırma gerçekleştirilmişlerdir [17].

Kahya ve Özdüven (2023) çalışmalarında, lahanaya ve brokoli sebzelerinin sınıflandırılması için derin öğrenme yöntemlerinden olan Inception-v3 görüntü tanıma ve sınıflandırma modeli kullanılmışlardır. 10 eğitim döngüsü ve 0,001 öğrenme hızı ile uygulanan Inception-v3 modelinin lahanaya ve brokolinin sebzelerinin sınıflandırılmasında %100 oranında başarılı olduğu gözlemlenmiştir [18].

Nasiri vd. (2019) yapmış oldukları çalışmada, sağlıklı hurma meyvelerini diğer kusurlu hurmalardan ayırmak için, VGG-16 mimarisine sahip bir ESA modeli kullanmışlardır. Önerilen model üzerindeki deneysel sonuçlar, ESA modelinin, hurma meyvesi görüntülerinin ayırt edilmesinde %96,98 genel sınıflandırma doğruluğu elde edildiğini göstermişlerdir [19].

Sattar vd. (2021) yapmış oldukları çalışmada, farklı türdeki hurmaları tanıtmak ve sınıflandırmak için kullanmış oldukları CNN modeli ile %82,67 doğruluk elde etmişlerdir. Bunun yanı sıra ele alınan farklı tip modeller için Inception-resnet-V2, Inception-v3 ve Mobilenet V1 modellerini kullanmışlardır. Bu üç model içerisinde Mobilenet-V1 modeli ile %82,67 en yüksek doğruluk oranı elde etmişlerdir [20].

Alaskar vd. (2021) çalışmalarında, e Ekhlâs, Nbut Sultan ve Shayshi olmak üzere üç ana hurma çeşidinin görüntülerini sınıflandırmak için geliştirilmiş bir otomatik sıralama sistemi sunmuşlardır. Bu amaçla farklı hurma çeşitlerini yüksek doğrulukla verimli bir şekilde öğrenmek ve ayırt etmek için ESA modeli kullanılmıştır. Model, her üç çeşitten 1055 adet resim içeren yaklaşık 3165 adet hurma meyvesi görüntüsü ile sıfırdan eğitilmiştir. Yapay Sinir Ağı (YSA) modeli üzerinde farklı gradyan iniş optimizasyon yöntemleri ile karşılaştırmalı bir analiz sunmuşlardır. En yüksek doğruluk oranı %100 ile CNN-Adam modelinden elde etmişlerdir. [21].

Albarrak vd. (2022) yapmış oldukları çalışmada, sekiz farklı hurma sınıfından oluşan bir veri seti oluşturmuşlardır. Çalışmada, MobileNet-V2 mimarisini temel alan bir model önerilmiştir ve önerilen modelin %99 doğruluk oranına ulaştığını ifade etmişlerdir. Önerilen model ayrıca AlexNet, VGG16, InceptionV3, ResNet ve MobileNetV2 gibi diğer mevcut modellerle de karşılaştırılmıştır. Sonuçlar, önerilen modelin doğruluk açısından diğer tüm modellerden daha iyi performans gösterdiğini belirlemişlerdir [22].


### 3. Materyal ve Metot (Material and Method)

#### 3.1. Materyal (Material)

Çalışma kapsamında dört farklı derin öğrenme modeli üzerinden eğitimler gerçekleştirilmiştir. Kullanılan modeller literatür taramasına dayanarak yüksek doğruluk veren modellerden oluşmaktadır.

### 3.1.1 Veri seti (Data Set)

Veri seti 0,035 piksel boyutlarında 288 adet hurma meyvesinin hasara (yırtılma, bozulma, ezilme vb.) göre iyi, orta ve kötü olarak üç sınıfa ait görsellerden oluşmaktadır. Ayrıca veri seti üzerinde derin öğrenme mimarilerindeki doğruluk oranının arttırmak için veri artırımı işlemi ile görüntü sayısı 1152 çıkarılmıştır. Şekil 1'de çalışmada kullanılan veri setine ait örnek bir görsel verilmiştir.



Şekil 1. Veri setinden örnekler. a) kötü b) orta c) iyi (Examples from the data set. a) bad b) average c) good)

### 3.1.2 MobileNet Derin Öğrenme Modeli (MobileNet Deep Learning Model)

Bilgisayarlı görme, mobil ve gömülü sistem alanlarında ESA, nesne algılama ve tanımda önemli rol oynayan, basit ama etkili ve hesaplama açısından çok yoğun olmayan derin öğrenme modelidir. [23]. MobileNet derin öğrenme modelini diğer modellerden ayıran en büyük farklardan birisi transfer öğrenmeyi çalıştırmak veya uygulamak için çok az hesaplama gücüne sahip olmasıdır. MobileNet derin öğrenme modeli, derinlemesine ayrılabilir evrişimler kullanmaktadır. Ağlarda aynı derinliğe sahip düzenli evrişimlere sahip ağ ile karşılaştırıldığında parametre sayısını önemli ölçüde azaltmaktadır [24].

### 3.1.3 ResNetV2-50 Derin Öğrenme Modeli (ResNetV2-50 Deep Learning Model)

ResNet ağı, VGG-19 mimarisinden esas alınarak VGG ağlarından daha az filtreye ve daha düşük karmaşıklığa sahip 34 katmanlı düz bir ağ mimarisi olarak kullanılmaktadır. Daha sonrasında ise düz ağa atlama bağlantıları veya artık bloklar eklenerek mimari artık ağa dönüştürülmektedir. ResNet mimarileri çok daha derin ağlarda daha güçlü geçişler sağlamak için atlama bağlantılarını kullanmaktadır. Çalışmada kullanılan ResNetV2-50 modelinin 50 katmanı vardır [25].

### 3.1.4 DenseNet-201 Derin Öğrenme Modeli (DenseNet-201 Deep Learning Model)

DenseNet derin öğrenme mimarisi Huang vd. tarafından geliştirilen [26] ve özellikle CIFAR-100 ImageNet25 gibi veri kümelerinde nesne tanıma konusunda başarılı sonuçlar elde edilen bir derin öğrenme modelidir [27]. Bu mimari ile DenseNet, kaybolan gradyan problemini azaltmak, özellik yayılımını arttırmak ve yeniden kullanımına olanak sağlamak ve parametre sayısını önemli ölçüde azaltmak gibi birçok özellik DenseNet-201 derin öğrenme modelinin önemli özellikleri arasındadır [26].

### 3.1.5 Inception-v3 Derin Öğrenme Modeli (Inception-v3 Deep Learning Model)

Inception-v3, yaygın olarak kullanılan bir ESA mimarisidir. Google tarafından oluşturulan Inception-v1 mimarisinin geliştirilmiş yeni bir versiyonudur. Inception-v3 mimarisi ilk olarak 2015 yılında kullanılmaya başlanmış olup 42 katmandan oluşmaktadır. Ayrıca önceki modellere göre daha düşük hata oranına sahiptir. Bu mimaride 3x3 evrişim katmanı kullanılmaktadır. Evrişim katmanını azaltmak hesaplama maliyetini de azaltmaktadır [28].

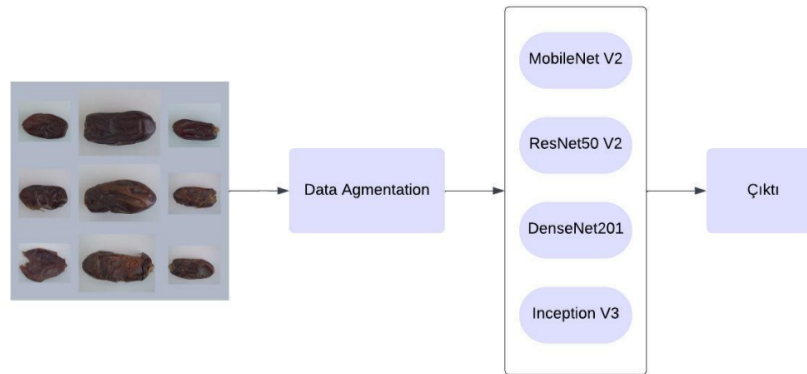
### 3.1.6 Veri artırma (Data augmentation)

Veri artırma, modelin başarımını arttırmak ve aşırı öğrenme problemine engel olmak amacıyla daha önceden var olmayan sentetik verilerin üretilmesi işlemidir. Bu amaçla girdi olarak verilen görüntüler; belirli açılarla döndürülme, yakınlaştırma, uzaklaştırma gibi işlemlere tabi tutularak var olan görüntünün farklı versiyonları üretilerek veri artırımı gerçekleştirilmektedir [29].



### 3.1. Metot (Method)


Çalışmanın iş akış diyagramını Şekil 2’de gösterilmiştir. Çalışmanın ilk aşamasında, 0,035 piksel boyutlarında 288 adet hurma meyvesine ait görsellere veri arttırma işlemi uygulanarak görüntü sayısı 1152 adet görüntüye çıkarılmıştır. Veri arttırımı gerçekleştirildikten sonra veriler sınıflara ayrılarak etiketlenmiştir. Etiketlenen veriler rastgele %80 (921 adet) eğitim ve %20 (231 adet) test görüntüsü olarak ayrılmıştır. Sonraki aşamada ise eğitim verileri MobileNetV2, ResNetV2-50, DenseNet-201, Inception-v3 öğrenme mimarileri ile 15 tekrarlı(epoch) eğitimle eğitilmiştir. Tüm modellerde Relu aktivasyon fonksiyonu kullanılmıştır. Eğitim esnasında her model için öğrenme oranı optimize edilerek en uygun öğrenme oranı belirlenmiştir. Eğitimler sonucunda elde edilen sonuçlar test verileri ile kıyaslanarak sınıflandırma için en doğru sonucu veren derin öğrenme modeli çalışmada kullanılmıştır.



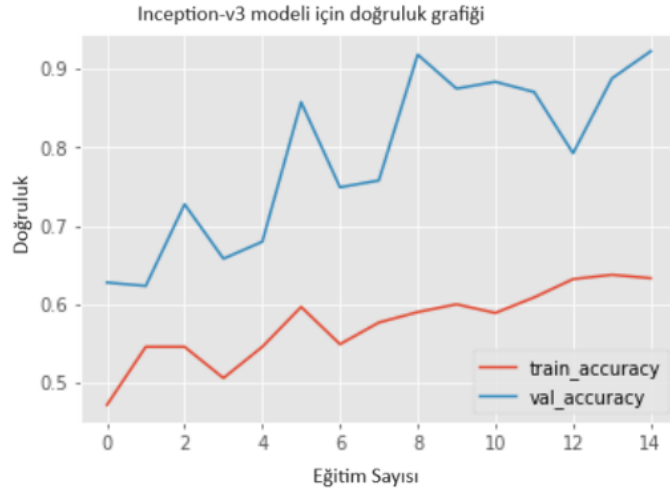
Şekil 2. İş Akış Diyagramı (Workflow Diagram)

### 3. Araştırma Bulguları (Research Findings)

Yapılan çalışmada dört farklı derin öğrenme mimarisi hurma meyvesinin sınıflandırılmasında kullanılarak modeller arasındaki performanslar analiz edilmiştir. İlk olarak Inception-v3 modelinin eğitimindeki eğitim ve test verileri için Şekil 3 kayıp grafiği ve Şekil 4’de ise doğruluk grafikleri elde edilmiştir.




Şekil 3. Inception-v3 modeline ait kayıp grafiği (Loss graph for Inception-v3 model)



Şekil 4. Inception-v3 modeline ait doğruluk grafiği (Accuracy graph for Inception-v3 model)


Şekil 3 ve Şekil 4 incelendiğinde Inception-v3 modelinin eğitimi esnasında hem kayıp hem de doğruluk değerinin 15 eğitim tekrardan sonra değişmediği için eğitim sayısı arttırılmamıştır. 15 eğitim sonucunda elde edilen sonuçlara ait karmaşıklık matrisi Şekil 5'te gösterilmiştir.



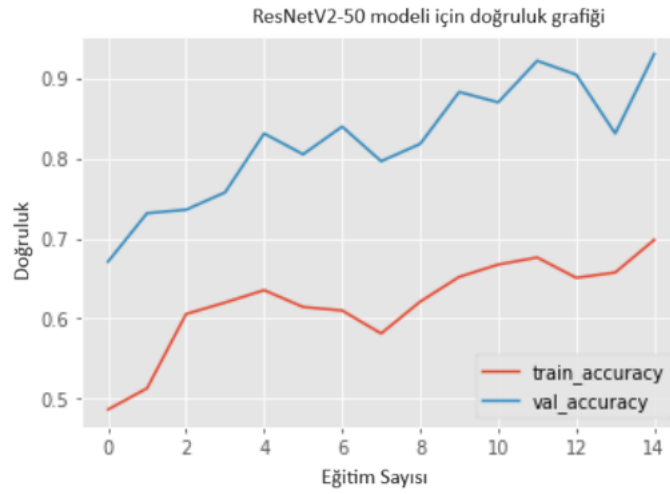
Şekil 5. Inception-v3 modeline ait karmaşıklık matrisi (complexity matrix for Inception-v3 model)

Karmaşıklık matrisi incelendiğinde Inception-v3 derin öğrenme modeli; kötü sınıfına ait 60 adet görüntüyü doğru sınıflandırmış, 7 adet görüntüyü ise orta sınıfı olarak yanlış sınıflandırdığı görülmektedir. İyi sınıfında ise görüntülerden 70 adetini doğru sınıflandırırken 10 adetini ise orta olarak yanlış sınıflandırmıştır. Orta sınıfında ise görüntülerden 83 adetini doğru sınıflandırırken 1 adetini ise iyi sınıfı olarak yanlış sınıflandırmıştır.

Çalışmada ikinci olarak veri seti ResNetV2-50 modeli ile eğitim gerçekleştirilmiştir. Eğitimin esnasındaki eğitim ve test verileri için Şekil 6'da kayıp grafiği ve Şekil 7'de ise doğruluk grafikleri elde edilmiştir.




Şekil 6. ResNetV2-50 modeline ait kayıp grafiği (Loss graph for ResNetV2-50 model)



Şekil 7. ResNetV2-50 modeline ait doğruluk grafiği (Accuracy graph for ResNetV2-50 model)


Şekil 3 ve Şekil 4 incelendiğinde ResNetV2-50 modelinin eğitimi esnasında hem kayıp hem de doğruluk değerinin 15 eğitim tekrarından sonra değişmediği için eğitim sayısı arttırılmamıştır. 15 eğitim sonucunda elde edilen sonuçlara ait karmaşıklık matrisi Şekil 8'te gösterilmiştir.




Şekil 8. ResNetV2-50 modeline ait karmaşıklık matrisi (Complexity matrix of the ResNetV2-50 model)

Karmaşıklık matrisi incelendiğinde ResNetV2-50 derin öğrenme modeli; kötü sınıfına ait 67 adet görüntüyü doğru sınıflandırmış olup hiç yanlış sınıflandırma yapılmadığı tespit edilmiştir. İyi sınıfında ise görüntülerden 71 adetini doğru sınıflandırırken 9 adetini ise orta olarak yanlış sınıflandırmıştır. Orta sınıfında ise görüntülerden 77 adetini doğru sınıflandırırken 7 adetini ise iyi sınıfı olarak yanlış sınıflandırmıştır.

Çalışmada üçüncü olarak veri seti DenseNet-201 modeli ile eğitim gerçekleştirilmiştir. Eğitimin esnasındaki eğitim ve test verileri için Şekil 9’da kayıp grafiği ve Şekil 10’de ise doğruluk grafikleri elde edilmiştir.




Şekil 9. DenseNet-201 modeline ait kayıp grafiği (Loss graph for the DenseNet-201 model)



Şekil 10. DenseNet-201 modeline ait doğruluk grafiği (Accuracy graph for the DenseNet-201 model)


Şekil 9 ve Şekil 10 incelendiğinde DenseNet-201 modelinin eğitimi esnasında hem kayıp hem de doğruluk değerinin 15 eğitim tekrarından sonra değişmediği için eğitim sayısı arttırılmamıştır. 15 eğitim sonucunda elde edilen sonuçlara ait karmaşıklık matrisi Şekil 11’de gösterilmiştir.




Şekil 11. DenseNet-201 modeline ait karmaşıklık matrisi (Complexity matrix of the DenseNet-201 model)

Karmaşıklık matrisi incelendiğinde DenseNet-201 derin öğrenme modeli; kötü sınıfına ait 67 adet görüntüyü doğru sınıflandırmış olup hiç yanlış sınıflandırma yapılmadığı tespit edilmiştir. İyi sınıfında ise görüntülerden 79 adetini doğru sınıflandırırken 1 adetini ise orta olarak yanlış sınıflandırmıştır. Orta sınıfında ise görüntülerden 68 adetini doğru sınıflandırırken 16 adetini ise kötü sınıfı olarak yanlış sınıflandırmıştır.

Çalışmada son olarak veri seti MobileNetV2 modeli ile eğitim gerçekleştirilmiştir. Eğitimin esnasındaki eğitim ve test verileri için Şekil 12’de kayıp grafiği ve Şekil 13’de ise doğruluk grafikleri elde edilmiştir.

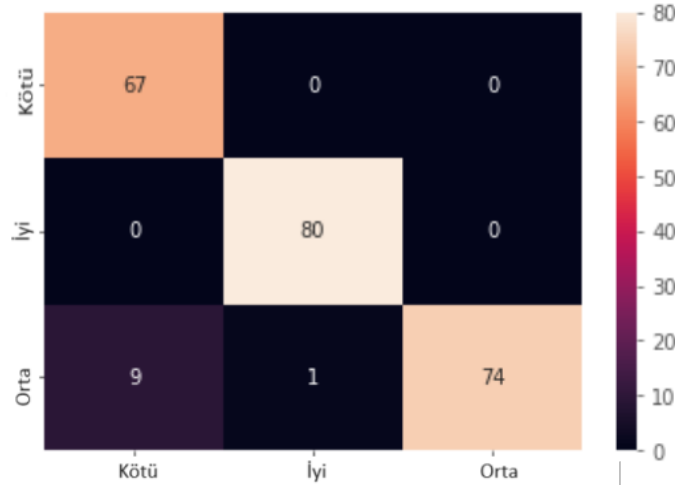


Şekil 12. MobileNetV2 modeline ait kayıp grafiği (Loss graph for MobileNetV2 model)



Şekil 13. MobileNetV2 modeline ait doğruluk grafiği (Accuracy graph of the MobileNetV2 model)

Şekil 12 ve Şekil 13 incelendiğinde MobileNetV2 modelinin eğitimi esnasında hem kayıp hem de doğruluk değerinin 15 eğitim tekrarından sonra değişmediği için eğitim sayısı arttırılmamıştır. 15 eğitim sonucunda elde edilen sonuçlara ait karmaşıklık matrisi Şekil 14’te gösterilmiştir.



Şekil 15. MobileNetV2 modeline ait karmaşıklık matrisi (Complexity matrix of the MobileNetV2 model)

Karmaşıklık matrisi incelendiğinde MobileNetV2 derin öğrenme modeli; kötü sınıfına ait 67 adet görüntüyü doğru sınıflandırmış olup hiç yanlış sınıflandırma yapılmadığı tespit edilmiştir. İyi sınıfında ise görüntülerden 80 adetini doğru sınıflandırmış olup hiç yanlış sınıflandırma yapılmadığı tespit edilmiştir. Orta sınıfında ise görüntülerden 74 adetini doğru sınıflandırırken 9 adedini kötü sınıf ve 1 adet görüntüyü de iyi sınıfı olarak yanlış sınıflandırmıştır.

Çalışmada kullanılan Inception-v3, ResNetV2-50, DenseNet-201 ve MobileNetV2 modelleri ile yapılan eğitimler sonucunda elde edilen Accuracy, Precision, Recall ve F1-Score performans değerlendirme metriklerine ait sonuçlar Tablo 1’de verilmiştir.

Tablo 1. Çalışmada kullanılan derin öğrenme modellerine ait performans değerlendirme sonuçları  
(Performance evaluation results of the deep learning models used in the study)

Model İsmi	Accuracy	Precision	Recall	F1-Score
<i>Inception-v3</i>	0,92	0,93	0,91	0,92
<i>ResNetV2-50</i>	0,93	0,93	0,93	0,93
<i>DenseNet-201</i>	0,92	0,93	0,93	0,92
<i>MobileNetV2</i>	0,95	0,95	0,96	0,95

Tablo 1 incelendiğinde çalışma kullanılan dört farklı derin öğrenme modelinde doğruluk oranlarının %90’nın üzerinde olduğu görülmektedir. Bu durum veri seti ile çalışmada kullanılan derin öğrenme modellerinin uyumlu olduğunu göstermektedir. Çalışmada kullanılan dört farklı derin öğrenme modeli içerisinde Accuracy performans değerlendirme kriterine göre MobileNetV2 modelinin %95 doğruluk değerine göre en başarılı model olduğu tespit edilmiştir.

#### 4. Sonuçlar (Conclusions)

Yapay zekâ uygulamaları günümüzde tarım sektörüne katkılarında dolayı sıklıkla kullanılan bir yöntem olmuştur. Yapay zekâ uygulamaları ile meyvelerde kusurların tespit edilmesi ve bu sayede doğru bir kalite kontrol süreci sürdürmek oldukça önemlidir.

Çalışmada özgün veri setindeki iyi, orta ve kötü sınıf olmak üzere üç sınıftan hurma meyvesine ait görüntüler MobileNetV2, ResNetV2-50, DenseNet-201, Inception-v3 derin öğrenme mimarileri ile eğitilmiştir. Modellerin başarıları, öğrenme oranı-kayıp grafiği ve karmaşıklık matrisi çizdirilerek sonuçlar değerlendirilmiştir. Her bir modelde %90’ın üzerinde doğruluk elde edilmesi veri setinin çalışmada kullanılan derin öğrenme modelleri ile uyumlu ve başarılı sonuçların elde edildiğini göstermektedir. Rastgele alınan test veri setinden model çıktıları incelendiğinde iyi ve kötü sınıfa ait doğruluk oranları çok yüksek çıkmaktadır. Ancak orta kalite sınıfta tüm modeller yanlış sınıflandırmalar gerçekleştirmektedir. Bunun nedeni orta kalite

sınıfa ait verilerde iyi ya da kötü sınıfa ait görüntülere çok yakın benzerlikte görüntülerin bulunmasıdır. Tüm mimarilerin geneline bakıldığında toplamda 61 adet yanlış etiketleme yapılmıştır.

Gerçekleştirilen çalışma ile hurma meyvesinde kalite kontrol sürecinin hızlı ve etkili bir şekilde gerçekleştirilmesine yönelik derin öğrenme tabanlı modeller sunulmuştur. Sunulan modeller ile meyvelerin sınıflandırması için akademik literatüre katkı sağlaması amaçlanmıştır. İlerideki çalışmalarda veri setinin genişletilip farklı yapay zekâ modelleri kullanılarak doğruluk oranlarının artırılması ve gerçek zamanlı bir içimde ayrıtılabilecek bir sisteme entegre edilebileceği düşünülebilmektedir.

### Teşekkür (Acknowledgment)

Çalışma 5. Uluslararası Mühendislikte Yapay Zeka ve Uygulamalı Matematik Konferansı'nda özet metin olarak sunulmuştur.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

- [1] W. M. Amer, "Taxonomic and documentary study of food plants in ancient egypt," Ph.D. Thesis, Cairo University, Giza, 1994.
- [2] M. Al-Farsi, C. Alasvar, A. Morris, M. Baron, and F. Shahidi, "Comparison of antioxidant activity, anthocyanins, carotenoids, and phenolics of three native fresh and sun-dried date (*Phoenix dactylifera* L.) varieties grown in Oman," *Journal of Agricultural and Food Chemistry*, vol. 53, pp. 7586–7599, August 2005. doi: 10.1021/jf050579q
- [3] E. Yıldız and M. Kaplankıran, "Hatay ili Trabzon hurması seleksiyonunda belirlenen tiplerin özellikleri," V. Ulusal Bahçe Bitkileri Kongresi, 4-7 Eylül, 2007, Erzurum, Turkey, pp. 266-270.
- [4] T. Saraçoğlu, "Bazı narenciye türlerinin seçilmiş fiziksel ve hidrodinamik özellikleri," *Anadolu Tarım Bilimleri Dergisi*. vol. 32, pp. 206-215. Haziran 2017. doi: 10.7161/omuanajas.303881
- [5] M.T. Masarirambi, V. Mavuso, V.D. Songwe, T.P. Nkambule and N. Mhazo, "Indigenous postharvest handling and processing of traditional vegetables in Swaziland: A review," *African Journal of Agricultural Research*, vol. 5, no. 24, pp.3333-3341, 2010
- [6] K.G. Liakos, P. Busato, D. Moshou, S. Pearson and D. Bochtis, "Machine learning in agriculture: a review," *Sensors*, vol. 18, no.8 pp. 2674, August 2018. doi: 10.3390/s18082674
- [7] E. Saldana, R. Siche, M. Luján and R. Quevedo, "Computer vision applied to the inspection and quality control of fruits and vegetables," *Brazilian Journal of Food Technology*, vol. 16, no. 4, pp. 254–272, December 2013. doi: 10.1590/S1981-67232013005000031
- [8] H. Armagan, "Color based segmentation with k-means clustering algorithm and numerical analysis of the effect of color spaces on image quantities," *El-Cezeri*, vol. 9, no. 4, pp.1506-1517, December 2022. doi: 10.31202/ecjse.11411 48
- [9] S. Adige, R. Kurban, A. Durmuş and E. Karaköse, "Görüntü işleme tekniklerinden faydalanarak elma çeşitlerinin türlerine göre sınıflandırılması," *Avrupa Bilim ve Teknoloji Dergisi*, no. 37, pp. 131-138, Temmuz 2022. doi: 10.31590/ejosat.1136913
- [10] M. Dhakate, "BIA diagnosis of pomegranate plant diseases using neural networks," In: Proceedings of the 5th National Conference on computer vision, Pattern Recognition, Image Processing and Graphics (NCVPRIPG), 16-19 December, 2015, Patna, India [Online]. Available: IEEE Xplore, <https://ieeexplore.ieee.org/abstract/document/7490056>. [Accessed: 09 July. 2023].
- [11] E. Güneş, "Derin öğrenme yaklaşımı ile fındık meyvesinin sınıflandırılması," Ph.D. Thesis, Marmara Univ., İstanbul, Türkiye, 2022.
- [12] Y. D. Zhang, Z. Dong, X. Chen, W. Jia, S. Du, K. Muhammad and S. H. Wang, "Image based fruit category classification by 13-layer deep convolutional neural network and data augmentation," *Multimedia Tools and Applications*, vol. 78, pp. 3613-3632. September 2019. doi: 10.1007/s11042-017-5243-3
- [13] K. Kayaalp, and S. Metlek, "Classification of robust and rotten apples by deep learning algorithm," *Sakarya University Journal of Computer and Information Sciences*, vol. 3, no. 2, pp.112-120, August 2020. doi: 10.35377/saucis.03.02.717452
- [14] B. Büyükarıkan and E. Ülker, "Aydınlatma özneliği kullanılarak evrişimsel sinir ağı modelleri ile meyve sınıflandırma," *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, vol. 25 no. 1, pp. 81-100. April 2020. doi: 10.17482/uumfd.628166
- [15] J. L. Joseph, V.A. Kumar and S.P. Mathew, "Fruit classification using deep learning," *In Innovations in Electrical and Electronic Engineering: Proceedings of ICEEE 2021*, vol. 756, pp. 807-817, May 2021. doi: 10.1007/978-981-16-0749-3\_62
- [16] N. Kumari, R.K. Dwivedi, A.K. Bhatt, and R. Belwal, "Automated fruit grading using optimal feature selection and hybrid

classification by self-adaptive chicken swarm optimization: grading of mango,” *Neural computing and applications*, vol. 34, pp. 1-22, 2022. doi: 10.1007/s00521-021-06473-x

[17] S. Kesler, A. Karakan, and O. Yüksel, “Alexnet mimarisi ile muz olgunlaşma evrelerinin sınıflandırılması,” *Avrupa Bilim ve Teknoloji Dergisi*, no. 51, pp. 135-141, Ağustos 2023. doi: 10.31590/ejosat.1252946

[18] E. Kahya and F. F. Özdüven, “Robotik hasat sistemlerinde kullanılmak amacıyla lahana ve brokolinin derin öğrenme metodu ile sınıflandırılması,” *Turkish Journal of Agriculture-Food Science and Technology*, vol. 11 no. 9, pp. 1639-1647, 2023. doi: 10.24925/turjaf.v11i9.1639-1647.6177

[19] A. Nasiri, A. Taheri-Garavand, and Y. D. Zhang, “Image-based deep learning automated sorting of date fruit,” *Postharvest biology and technology*, vol. 153, pp. 133-141, July 2019. doi: 10.1016/j.postharvbio.2019.04.003

[20] M. S. Hasan and A. Sattar, “Arabian date classification using CNN algorithm with various pre-trained models” *In 2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV), 04-06 February 2021, Tirunelveli, India* [Online]. Available: IEEE Xplore, <https://ieeexplore.ieee.org/abstract/document/9388413>. [Accessed: 09 July. 2023].

[21] H. Alaskar, S. Alhewaidi, B. Obaid, G. Alzahrani, A. Abdulahi, Z. Sbai, and T. Vaiyapuri, “Dates fruit classification using convolution neural networks,” *In Proceedings of Sixth International Congress on Information and Communication Technology: ICICT 2021, Vol. 3, pp. 757-775, 2022*. doi: 10.1007/978-981-16-1781-2\_66

[22] K. Albarrak, Y. Gulzar, Y. Hamid, A. Mehmood, and A. B. Soomro, “A deep learning-based model for date fruit classification,” *Sustainability*, vol. 14, no. 10, pp. 6339. 2022. doi: 10.3390/su14106339

[23] S. Pa, “An overview on mobilenet: an efficient mobile vision CNN,” *medium.com*, Jun. 10, 2020. [Online] Available: <https://medium.com/@godeep48/an-overview-on-mobilenet-an-efficient-mobile-vision-cnn-f301141db94d>

[24] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto and H. Adam, “Mobilenets: Efficient convolutional neural networks for mobile vision applications,” *arxiv.org*, 17 Apr 2017. [Online]. Available: <https://arxiv.org/abs/1704.04861> [Accessed: Dec. 26, 2023].

[25] S. Akdağ, “Resnet (residual network) nedir?” *medium.com*, Aug. 9, 2021, [Online]. Available: <https://suhedacilek.medium.com/resnet-residual-network-nedir-49105e642566>

[26] G. Huang, Z. Liu, L.V.D. Maaten and K. Q. Weinberger, “Densely connected convolutional networks,” *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 21-26 July 2017, Honolulu, HI, USA* [Online]. Available: IEEE Xplore, <https://ieeexplore.ieee.org/document/8099726>. [Accessed: 09 July. 2023].

[27] X. Yu, N. Zeng, S. Liu, and Y. D. Zhang, “Utilization of denseNet201 for diagnosis of breast abnormality,” *Machine Vision and Applications*, vol. 30, pp. 1135–1144, July 2019. doi: 10.1007/s00138-019-01042-8

[28] A. Sevinç and F. Özyurt, “Beton yüzey çatlaklarının tespitinde derin öğrenme mimarilerinin kullanılması,” *Uluslararası Yenilikçi Mühendislik Uygulamaları Dergisi*, vol. 6 no.2, pp. 318-325, 2022. doi: 10.46460/ijiea.1098046

[29] A.H. Hasan, E. İbra, E. Civil, and M. Cicioğlu, “İnsansız hava araçlarında nesne tespiti ve takibi,” *7. Geleceğin Mühendisleri Uluslararası Öğrenci Sempozyumu, 22-23 June 2023, Zonguldak, Turkey* [Online]. Available: [researchgate.net, https://www.researchgate.net/publication/373549374\\_Object\\_Detection\\_and\\_Tracking\\_in\\_Unmanned\\_Aerial\\_Vehicles](https://www.researchgate.net/publication/373549374_Object_Detection_and_Tracking_in_Unmanned_Aerial_Vehicles). [Accessed: 09 July 2023].

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license





GAZI

JOURNAL OF ENGINEERING SCIENCES

## A Framework for Parametric Model Selection in Time Series Problems

Muhammed Abdulhamid Karabiyik<sup>a</sup>

Submitted: 17.11.2023 Revised: 03.12.2023 Accepted: 04.12.2023 doi:10.30855/10.30855/gmbd.0705S09

### ABSTRACT

**Keywords:** Time series, lstm, cnn, dnn, forecasting.

<sup>a</sup> Niğde Ömer Halisdemir University,  
Bor Vocational School,  
Dept. of Computer Programming  
51700 - Niğde, Türkiye  
Orcid: 0000-0001-7927-8790  
e mail: abdulhamidkarabiyik@ohu.edu.tr

<sup>\*</sup>Corresponding author:  
abdulhamidkarabiyik@ohu.edu.tr

People make future plans with the aim of simplifying their lives, and these plans are essential for preparing for forthcoming challenges. Forecasting methodologies take precedence in order to anticipate and plan for future events. Time series data stands out as a pivotal information type employed for predicting the future. This research introduces a framework for selecting the optimal model among classical artificial neural networks in time series forecasting. The classical artificial neural networks considered encompass the LSTM, CNN, and DNN models. The framework employs various parameters – including the dataset, model depth, loss functions, minimal success rate in model performance, epochs, and optimization algorithms – to determine the best-fitting model. Users have the flexibility to adjust these parameters to address specific issues. By default, the framework incorporates seven distinct loss functions and five optimization algorithms to facilitate model selection. The mean average error loss function is used as the metric for evaluating model performance. To validate the framework, Brent oil prices were utilized as the dataset in a series of tests, encompassing a total of 9000 daily price data points. The dataset was partitioned into 80% for training and 20% for testing purposes. The training iterations within the framework were 50 epochs. In the test scenarios, the price for the eighth day was predicted using price data from the preceding seven days. Consequently, a mean average error score of 1.1239657 was achieved. The results showed that the LSTM model, comprising two layers, the Adadelta optimization algorithm, and the mean square error loss function, emerged as the most successful configuration.

## Zaman Serisi Problemlerinde Parametrik Model Seçimi İçin Bir Çerçeve

### ÖZ

İnsanlar yaşamlarını kolaylaştırmak için geleceğe yönelik planlamalar yapmaktadır. Bu planlamalar gelecekte karşılaşılabilecek problemlere hazırlıklı olmak için önemlidir. Geleceğe yönelik hazırlıklar yapılabilmesi için de tahmin yöntemleri ön plana çıkmaktadır. Geleceğe yönelik tahminler için kullanılan verilerden birisi de zaman serileridir. Bu çalışmada zaman serisi tahminlerinde kullanılacak klasik yapay sinir ağları için en iyi modeli seçen bir çerçeve geliştirilmiştir. Klasik yapay sinir ağları olarak LSTM, CNN ve DNN modelleri kullanılmaktadır. Framework en iyi modeli seçmek için veri seti, model derinliği, kayıp fonksiyonları, model performansında minimum başarı oranı, tekrar sayısı ve optimizasyon algoritmalarını parametre olarak kullanmaktadır. Kullanıcılar bu parametreleri kendi problemlerine uygun güncelleyebilmektedir. Model seçimi içinse varsayılan olarak 7 farklı kayıp fonksiyonu ve 5 farklı optimizasyon algoritması kullanılmaktadır. Model performansları Mean Average Error kayıp fonksiyonuyla belirlenmektedir. Framework deneylerinde, veri seti olarak Brent Ham Petrol fiyatları kullanılmış olup veri seti 9000 günlük fiyat bilgisi içermektedir. Veri seti %80 eğitim ve %20 test olarak iki bölünmüştür. Çerçeve testindeyse eğitimler 50 tekrar ile gerçekleştirilmiştir. Deneyde 7 günlük ardışık fiyat bilgisiyle 8. gündeki fiyat tahmin ettirilmiştir. Sonuç olarak 1.1239657 Mean Average Error skoru elde edilmiştir. En başarılı model, 2 katmanlı Adadelta optimizasyon algoritmasını ve Mean Square Error kayıp fonksiyonu kullanan LSTM modeli olmuştur.

**Anahtar Kelimeler:** Zaman serileri, lstm, cnn, dnn, tahminleme

## 1. Introduction

Deep learning has recently garnered considerable attention as a machine learning technique for addressing various issues. It has been effective in a variety of industries, attributed to its capability to discern complex data structures automatically. This approach is particularly employed due to its ability to handle huge datasets [1]. Nonetheless, an important factor, namely model selection, profoundly influences the application of deep learning. Choosing an appropriate deep learning model requires a careful consideration of both the problem's characteristics and the data [2]. Moreover, the performance of the chosen model is significantly impacted by the proper setup of its parameters. As a result, choosing the right model and the set of parameters for a given problem has become a key research domain for researchers.

There are several techniques available in the literature for the selection of deep learning models. Okewu et al. focused on enhancing a deep learning model by optimizing both loss functions and neural network parameters using a meta-heuristic search algorithm [3]. Meanwhile, Srivastava et al. approached model selection by evaluating the performance of different architectures, such as ResNet and MobileNet, for the task of face recognition [4]. Kotthoff et al. conducted hyperparameter optimization for machine learning models using Bayesian optimization [5]. Taylor et al. introduced an approach for model selection that addresses the complexities of selecting deep learning models in embedded systems [6]. Additionally, Bertrand et al. explored Bayesian model selection through the integration of hyperparameter optimization and model selection [7]. Gharibi et al. developed a system called ModelKB and conducted model experiments in a self-sufficient environment [8]. Murdock et al. proposed a method for simultaneous regularization and model selection that involves teaching model architecture and parameters together [9].

In this study, we present a framework for objectively selecting the most suitable deep learning model. Abbreviations of technical terms are provided upon their first usage. This framework builds upon the foundational deep learning models such as Long Short-Term Memory (LSTM), Convolutional Neural Network (CNN), and Deep Neural Network (DNN) to facilitate well-informed decision-making. These models are chosen for their ability to producing successful results across diverse problem sets. Developed framework empowers users to tailor personalized models by using Tensorflow and Keras libraries [10], [11]. Moreover, it offers the flexibility to expand the model's structure based on user-specified parameters. The effectiveness of each model is evaluated using a variety of metrics.

The study focuses on time series analysis, a technique widely applied across various domains such as meteorology, medicine, and economics. This analytical approach serves the purpose of identifying evolving trends, aiding decision-making, and facilitating future forecasting. The dataset under examination pertains to Brent crude oil pricing, spanning a 9000-day period. This dataset was partitioned into 80% for training and 20% for testing. The experimental results are derived from this dataset, with the objective being the prediction of the 8th-day price based on a 7-day historical price sequence. The framework incorporates multiple parameters, providing users the ability to create personalized models. These parameters comprise of loss functions, optimization algorithms, training epochs, and minimum accuracy. Importantly, these parameters play a vital role in the model selection process within the framework.

As a result, a total of 120 distinct models were generated, with the most optimal model being identified as the 2-layer LSTM model. This particular model was trained by utilizing the Adadelta optimization algorithm, while the mean squared error was adopted as the designated loss function. With a training duration of 50 epochs, the resulting average absolute error score was calculated as 1.1239657. In conclusion, this study demonstrated the effectiveness of a framework for deep learning model selection and its application. The proposed framework allows users to select and customize models suitable for different problem sets, and the experimental results confirm the effectiveness and success of the proposed framework. Our approach holds the potential to enhance the efficiency of deploying deep learning models.

## 2. Methodology

In this study, the method of the developed framework comprises the subsequent steps: Initially, experiments are performed on diverse deep learning models, containing LSTM, CNN, and DNN. Throughout these experiments, the models undergo training for a designated number of training cycles employing distinct loss functions and optimization algorithms. This procedure produces a collection of models. From this collection, the model exhibiting the lowest mean absolute error (MAE) score is identified as the most effective model.

The employed parameters are presented in Table 1.

Table 1. Framework parameters and descriptions.

Parametres	Default Values	Descriptions
Dataset	-	Changeble for every problem so user must define Dataset.
Models	CNN, LSTM,DNN	It can be changed according to the type of problem. The users can use their cutom models.
Epochs	50	Users can adjust it according to their preferences.
Loss	MAE,MSE, MASE	Users can adjust it according to their preferences.
Functions		
Optimizers	Adam, Adadelata,Adamax	All optimizers supported by the Keras library can be used.
Success Rate	Avarage of Training Set Values	Users can use this parameter if they prefer models below a certain success rate.

## 2.1. Dataset

Brent crude oil prices serve as the dataset, containing a comprehensive collection of 9000 daily price data points. Upon analyzing the distribution of these prices, it becomes evident that the lowest price is 9.1 USD, while the highest price is 143.95 USD. The mean price is 48.421 USD. This considerable price range significantly influenced the choice of this dataset, ensuring the inclusion of diverse price trajectories over time. To facilitate effective modeling, the dataset was partitioned, allocating 80% for the training set and the remaining 20% for the test set. The graphical representation of price fluctuations within the training and test sets is illustrated in Figure 1.




Figure 1. Training set and test set graph.

## 2.2. Deep learning models

Convolutional Neural Networks (CNN), a fundamental method in deep learning, is notably efficient for analyzing visual data. CNNs generate feature maps by employing filters in layers and achieve results by integrating these features in alignment with the desired output [12]. Long Short Term Memory (LSTM) is utilized for analyzing sequential data. The model operates through input, output, and forget gates, enabling it to scrutinize long-term connections and comprehend extended sequences of sequential data [13]. Deep Neural Networks (DNN) form the basis for general deep learning models. These models consist of layers of artificial neural network cells with connections established by weight values. The weight values are learned to address problems [14].

### 2.3. Loss functions

This study assesses the impact of loss functions on the training of models employed for regression problems. The selection of loss functions was aligned with the respective model and evaluated during the training of the models. They represent a crucial component in the training of deep learning models. Following loss functions were employed:

- Mean Squared Error
- Root Mean Squared Error
- Mean Absolute Error
- Mean Absolute Percentage Error
- Mean Squared Logarithmic Error
- Cosine Similarity
- Log Cosh Error

The MAE is a measure of success calculated by averaging the absolute differences between the actual values and model results [15]. Equation 1 demonstrates the formula for MAE.

$$\sum_{i=1}^D |X_i - Y_i| \quad (1)$$

The MSE is a measure of success calculated as the mean of the squares of the differences between the model results and the actual values [16]. Equation 2 demonstrates the formula for MSE.

$$\sum_{i=1}^D (X_i - Y_i)^2 \quad (2)$$

The RMSE is calculated by taking the square root of the MSE value and shows the average of the errors between the predicted values and the actual values [17]. Equation 3 demonstrates the formula for RMSE.

$$\sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{d_i - f_i}{\partial_i} \right)^2} \quad (3)$$

MAPE calculates the error between model predictions and actual values as a percentage [18]. Equation 4 demonstrates the formula for MAPE.

$$\frac{100\%}{N} \sum_{i=0}^{N-1} \frac{y_i - \hat{y}_i}{y_i} \quad (4)$$

MASE assesses model effectiveness using MAE values that have been normalized to the dataset's characteristics. MASE enables the assessment of errors in the training history [19]. Equation 5 demonstrates the formula for MASE.

$$\frac{\frac{1}{N} \sum_{i=0}^{N-1} |y_i - \hat{y}_i|}{\frac{1}{N-1} \sum_{i=1}^{N-1} |y_i - y_{i-1}|} \quad (5)$$

### 2.4. Optimization algorithms

Choice of the optimization algorithm is a crucial step for effective training of models. Following optimization algorithms were considered:

- Adam
- Stochastic Gradient Descent
- Adadelata
- Nadam
- Adamax

These optimization algorithms were applied to mitigate the error rates derived from the loss functions. The selection of the appropriate optimization algorithm was determined with consideration of the problem nature and the underlying data structure. This selection aimed to enhance the optimization of deep learning models, thereby facilitating improved understanding and prediction of price fluctuations within the dataset.

Adam is a gradient-based optimisation algorithm commonly utilised in deep learning models. It was initially proposed by Kingma and Ba in 2014. Adam adjusts the learning rate through the use of moving averages of the gradient momentum and the square of the gradient, facilitating accelerated learning and decreasing the necessity for hyperparameter tuning [20].

Stochastic Gradient Descent (SGD) is a fundamental optimisation algorithm widely used in machine learning and deep learning models. SGD learns by updating the weights for each data sample. However, this can cause fluctuations and may require some modifications to ensure faster convergence [21].

Adadelata is an optimisation algorithm that attempts to overcome the disadvantages of SGD without the need to specifically set the learning rate hyperparameter. Adadelata automatically adjusts the learning rate using moving averages of the gradients. This can provide better convergence to the model [22].

Nadam is an optimisation approach that combines the Nesterov Momentum and Adam algorithms. Nesterov Momentum employs a technique that encourages swift convergence in momentum-based optimisation algorithms, while also maintaining the adaptive properties of Adam. Consequently, Nadam frequently attains rapid and steady convergence [23].

Adamax is a variant of the Adam optimization algorithm. It works similarly to Adam but employs the unbounded norm of the gradient values instead of moving averages. This approach can result in superior performance, particularly when the L2 norm is significant [24].

## 2.5. The Framework

The primary objective of the framework is to generate diverse models by replicating the layers of the input model. These generated models undergo training phase using a variety of loss functions and optimization algorithms. Finally, the framework assesses the performance of these models resulting from different parameter combinations.

The framework systematically gathers and compares the performance scores of the models generated through varied training processes. These scores effectively gauge the predictive capability of each model, aiding in the identification of the most suitable one. Thus, the framework identifies and presents the model that aligns best with the user-specified criteria.

The fundamental workflow of the framework is illustrated in Figure 2. It depicts the creation of diverse models by replicating input model layers and employing diverse loss functions and optimization algorithms. Subsequently, these models are evaluated during the training processes to determine the optimal choice. The framework's objective is to attain optimal results by promoting model diversity through systematic experimentation with distinct parameters.

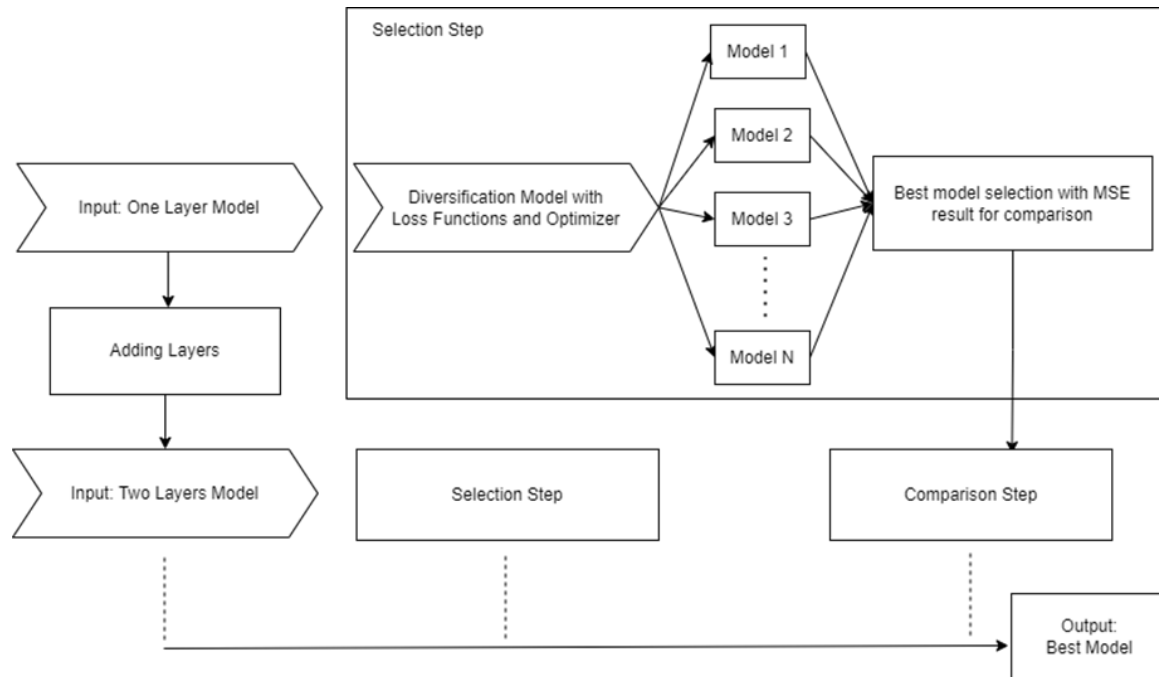


Figure 2. Workflow of the framework.

The framework presents a structured approach for the selection and development of models. Users have the flexibility to input models of their preference into the framework, thereby optimizing training costs for models tailored to specific problems. Developed by utilizing the Tensorflow and Keras libraries, the framework accepts models that are created using Keras' layer class as its input. By default, it employs CNN, DNN, and LSTM models, chosen based on their proven efficacy across diverse problem domains.

Multiple versions of the model can be provided to the framework via its parameters. These variations are created by implementing different loss functions and optimization algorithms. To determine the total number of models, the product of NL (number of layers), NLF (number of loss functions), and NOA (number of optimization algorithms) must be calculated. The number of divergent models generated can be determined using the formula outlined in Equation 6.

$$\text{Number of Models} = NL * NOA * NLF \quad (6)$$

A distinctive diversification process is executed for each model and layer provided as a parameter, considered a measure towards achieving diversity. The results of diversification are evaluated based on the Mean Absolute Error (MAE) results for the respective model. The framework utilizes the early stopping function from the Keras library to address overfitting and underfitting situations that may arise during model training. Therefore, the outcomes acquired from the models are prepared for comparison. The most suitable model is retained in memory and compared with subsequent diversification processes. The inclusion of layers is halted if the success rate falls below that of the previous step. The framework promotes variation based on the input models, achieved through various combinations of loss functions and optimization algorithms. MAE results are utilized within the framework to assess the effectiveness of diversified versions of the models. As a result, the most optimal model is selected.

The framework selects the optimal outcome among various models and presents it to the user. Simultaneously, upon the user's request, a compilation can display optimal outcomes alongside additional successful examples. This level of flexibility empowers users to showcase and select the most suitable models.

### 3. Results and Discussion

The framework was tested using Brent Crude Oil prices. To introduce model diversity in the tests, a range of loss functions including MSE, MAE, and MAPE, along with optimization algorithms such as Adam, Adadelta, Nadam, and Adamax, were employed. The process of adding layers was implemented on the default LSTM, CNN, and DNN models, resulting in a foundational model comprising ten distinct layers. This foundational

model was assessed in 120 variations, encompassing different loss functions and optimization algorithms. The training process of the models involved 50 epochs. The results of the most successful model, employing 50 epochs for the ten base models, are presented in Table 2.

Table 2. The most successful model with 50 epochs for the base 10 models.

Model	Loss Function	Optimizer	MAE	MSE	RMSE	MAPE	MASE
CNN-1L	MAE	ADAMAX	1.1951666	3.2317772	1.7977145	2.0679417	1.0574669
CNN-2L	MSE	ADAMAX	1.1716549	3.0966759	1.7597374	2.020125	2.020125
CNN-3L	MSE	ADADELTA	1.2711904	3.4629989	1.8609134	2.1794298	1.1247317
DNN-1L	MSE	ADAMAX	1.2403895	3.4186473	1.8489584	2.151392	1.0974795
DNN-2L	MSE	ADADELTA	1.2403287	3.2778876	1.8104937	2.138884	1.0974256
DNN-3L	MSE	ADAMAX	1.1692218	3.074043	1.753295	2.0136263	1.0345112
DNN-4L	MSE	ADADELTA	1.1800587	3.036366	1.7425171	2.03344	1.0440996
LSTM-1L	MSE	ADADELTA	1.1503365	2.9347835	1.7131209	1.9893798	1.0178018
<b>LSTM-2L</b>	<b>MSE</b>	<b>ADADELTA</b>	<b>1.1239657</b>	<b>2.840379</b>	<b>1.6853424</b>	<b>1.9417524</b>	<b>0.99446934</b>
LSTM-3L	MSE	ADADELTA	1.1298846	2.903611	1.7039986	1.9573519	0.99970627

From the 120 models created, the optimal performance was exhibited by the LSTM model with two layers. The most successful model employed MSE as its loss function and Adadelata as its optimization algorithm. The results are shown in Figure 3.




Figure 3. Best model results for Windows size 7.

The experiment entailed a window size of 7 for the series in the data set. To view the outcomes from an alternative viewpoint, the experiment was re-executed with a window size of 15. Table 3 exhibits the effects of the experiment carried out with a window size of 15.

Table 3. The most successful model with 50 epochs for the base 7 models.

Model	Loss Function	Optimizer	MAE	MSE	RMSE	MAPE	MASE
CNN-1L	MSE	ADAMAX	1.2158406	3.2258146	1.7960552	2.0856576	1.07523
CNN-2L	MSE	ADAMAX	1.470338	4.511765	2.1240916	2.5233996	1.300295
DNN-1L	MSE	ADAMAX	1.3783844	3.6747472	1.916963	2.3201127	1.2189758
DNN-2L	MSE	ADADELTA	1.2984885	3.767063	1.9408923	2.236332	1.1483197
DNN-3L	MAE	ADADELTA	1.4727191	4.197971	2.048895	2.4877105	1.3024007
<b>LSTM-1L</b>	<b>MSE</b>	<b>ADAMAX</b>	<b>1.2086239</b>	<b>3.277059</b>	<b>1.810265</b>	<b>2.0864668</b>	<b>1.0688479</b>
LSTM-2L	MSE	ADAMAX	1.2292047	3.4163816	1.8483456	2.1175768	1.0870485

In the second experiment, from the 96 models created, the optimal performance was exhibited by the LSTM

model with one layer. The most successful model employed MSE as its loss function and Adamax as its optimization algorithm. The results are shown in Figure 4.




Figure 4. Best model results for Windows size 15.

## 4. Conclusions

In this study, we have designed a framework for the development and selection of models in the context of time series analysis. User-specified models are input into the framework, which subsequently evaluates their performance by constructing a diverse collection of models. These models, generated through a variety of loss functions and optimization algorithms, are then assessed based on their Mean Absolute Error (MAE) results. These findings offer valuable insights to users facilitating the process of model selection and refinement.

The framework has been implemented using the Tensorflow and Keras libraries, supporting tailored to diverse problem domains. By default, a comprehensive collection of models, including Convolutional Neural Networks (CNN), Deep Neural Networks (DNN), and Long Short-Term Memory (LSTM) networks, is available. The determination of diverse models depends on the combination of distinct loss functions and optimization algorithms, with the most proficient model selected the optimal choice.

This study affords users substantial ease in both model selection and performance assessment. The framework empowers users to identify appropriate models for specific problems and attain optimal results by iteratively experimenting with various loss functions and optimization algorithms. Furthermore, it offers support for different models. In particular, the default CNN, DNN, and LSTM models can be applied to wide range of problem domains.

The future perspective of the study is to extend the framework by incorporating additional models and diversification methods. Furthermore, extending the framework's domain to ensemble learning will pave the way for exploration of different research studies. In deep learning problem-solving, an array of techniques is implemented to enhance result success. However, the success strategies presented within the framework only encompass methods that cover all problems. In forthcoming research, problem-specific approaches could be integrated into the framework. To reduce the runtime cost of the framework, search algorithms that are effectively used in parameter selection can be integrated into the model in future studies. In this way, some steps that can be defined as unnecessary during model diversification can be removed from the process.



## Conflict of Interest Statement

The authors declare that there is no conflict of interest.

## References

- [1] P. Wang, E. Fan, and P. Wang, "Comparative analysis of image classification algorithms based on traditional machine learning and deep learning," *Pattern Recognit Lett*, vol. 141, pp. 61–67, Jan. 2021, doi: 10.1016/j.patrec.2020.07.042.
- [2] U. Michelucci, "A Case-Based Approach to Understanding Deep Neural Networks," in *Applied Deep Learning*, Berkeley, CA: Apress, 2018. doi: 10.1007/978-1-4842-3790-8.
- [3] E. Okewu, P. Adewole, and O. Sennaike, "Experimental Comparison of Stochastic Optimizers in Deep Learning," in *Computational Science and Its Applications – ICCSA 2019*, 2019, pp. 704–715. doi: 10.1007/978-3-030-24308-1\_55.
- [4] Y. Srivastava, V. Murali, and S. R. Dubey, "A Performance Comparison of Loss Functions for Deep Face Recognition," *ArXiv*, Dec. 2018, doi: 10.48550/arXiv.1901.05903.
- [5] L. Kotthoff, C. Thornton, H. H. Hoos, F. Hutter, and K. Leyton-Brown, "Auto-WEKA: Automatic Model Selection and Hyperparameter Optimization in WEKA," in *Automated Machine Learning*, 2019, pp. 81–95. doi: 10.1007/978-3-030-05318-5\_4.
- [6] B. Taylor, V. S. Marco, W. Wolff, Y. Elkhatib, and Z. Wang, "Adaptive deep learning model selection on embedded systems," *ACM SIGPLAN Notices*, vol. 53, no. 6, pp. 31–43, Dec. 2018, doi: 10.1145/3299710.3211336.
- [7] H. Bertrand, R. Ardon, M. Perrot, and I. Bloch, "Hyperparameter optimization of deep neural networks: combining Hperband with Bayesian model selection," in *Conférence sur l'Apprentissage Automatique*, 2017. [Online]. Available: <https://api.semanticscholar.org/CorpusID:10497518>.
- [8] G. Gharibi, V. Walunj, R. Alanazi, S. Rella, and Y. Lee, "Automated Management of Deep Learning Experiments," in *Proceedings of the 3rd International Workshop on Data Management for End-to-End Machine Learning*, New York, NY, USA: ACM, Jun. 2019, pp. 1–4. doi: 10.1145/3329486.3329495.
- [9] C. Murdock, Z. Li, H. Zhou, and T. Duerig, "Blockout: Dynamic Model Selection for Hierarchical Deep Networks," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jun. 2016, pp. 2583–2591. doi: 10.1109/CVPR.2016.283.
- [10] T. Developers, "TensorFlow," *Zenodo*, May 2021, doi: 10.5281/zenodo.4758419.
- [11] N. Ketkar, "Introduction to Keras," in *Deep Learning with Python*, Berkeley, CA: Apress, 2017, pp. 97–111. doi: 10.1007/978-1-4842-2766-4\_7.
- [12] L. O. Chua and T. Roska, "The CNN paradigm," *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, vol. 40, no. 3, pp. 147–156, Mar. 1993, doi: 10.1109/81.222795.
- [13] A. Sherstinsky, "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network," *Physica D*, vol. 404, p. 132306, Mar. 2020, doi: 10.1016/j.physd.2019.132306.
- [14] G. Li *et al.*, "Understanding error propagation in deep learning neural network (DNN) accelerators and applications," in *Proceedings of the International Conference for High Performance Computing, Networking, Storage and Analysis*, New York, NY, USA: ACM, Nov. 2017, pp. 1–12. doi: 10.1145/3126908.3126964.
- [15] J.-H. Lin, T. M. Sellke, and E. J. Coyle, "Adaptive stack filtering under the mean absolute error criterion," *IEEE Trans Acoust*, vol. 38, no. 6, pp. 938–954, Jun. 1990, doi: 10.1109/29.56055.
- [16] A. A. Poli and M. C. Cirillo, "On the use of the normalized mean square error in evaluating dispersion model performance," *Atmospheric Environment. Part A. General Topics*, vol. 27, no. 15, pp. 2427–2434, Oct. 1993, doi: 10.1016/0960-1686(93)90410-Z.
- [17] W. Wang and Y. Lu, "Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model," *IOP Conf Ser Mater Sci Eng*, vol. 324, p. 012049, Mar. 2018, doi: 10.1088/1757-899X/324/1/012049.
- [18] J. McKenzie, "Mean absolute percentage error and bias in economic forecasting," *Econ Lett*, vol. 113, no. 3, pp. 259–262, Dec. 2011, doi: 10.1016/j.econlet.2011.08.010.
- [19] P. H. Franses, "A note on the Mean Absolute Scaled Error," *Int J Forecast*, vol. 32, no. 1, pp. 20–22, Jan. 2016, doi: 10.1016/j.ijforecast.2015.03.008.
- [20] Z. Zhang, "Improved Adam Optimizer for Deep Neural Networks," in *2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS)*, IEEE, Jun. 2018, pp. 1–2. doi: 10.1109/IWQoS.2018.8624183.
- [21] S. Ruder, "An overview of gradient descent optimization algorithms," *ArXiv*, Sep. 2016, doi: 10.48550/arXiv.1609.04747.
- [22] E. M. Dogo, O. J. Afolabi, N. I. Nwulu, B. Twala, and C. O. Aigbavboa, "A Comparative Analysis of Gradient Descent-Based

Optimization Algorithms on Convolutional Neural Networks,” in *2018 International Conference on Computational Techniques, Electronics and Mechanical Systems (CTEMS)*, IEEE, Dec. 2018, pp. 92–99. doi: 10.1109/CTEMS.2018.8769211.

[23] Q. Zhang *et al.*, “Boosting Adversarial Attacks with Nadam Optimizer,” *Electronics (Basel)*, vol. 12, no. 6, p. 1464, Mar. 2023, doi: 10.3390/electronics12061464.

[24] R. Llugsí, S. El Yacoubi, A. Fontaine, and P. Lupera, “Comparison between Adam, AdaMax and Adam W optimizers to implement a Weather Forecast based on Neural Networks for the Andean city of Quito,” in *2021 IEEE Fifth Ecuador Technical Chapters Meeting (ETCM)*, IEEE, Oct. 2021, pp. 1–6. doi: 10.1109/ETCM53643.2021.9590681.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



**GAZİ**
**JOURNAL OF ENGINEERING SCIENCES**

## Detection of Rice Plant Diseases Based on Deep Transfer Learning

Necaattin Barışçı<sup>a\*</sup>, Merve Güllü<sup>b</sup>, İbrahim Alper Doğru<sup>c</sup>

Submitted: 16.11.2023 Revised: 05.12.2023 Accepted: 08.12.2023 doi:10.30855/gmbd.0705S10

### ABSTRACT

**Keywords:** rice plant diseases, deep learning, transfer learning

<sup>a\*</sup> Gazi University,  
 Technology Faculty,  
 Dept. of Computer Engineering  
 06560 - Ankara, Türkiye  
 Orcid: 0000-0002-8762-5091  
 e mail: nbarisci@gazi.edu.tr

<sup>b</sup> Gazi University,  
 Technology Faculty,  
 Dept. of Computer Engineering  
 06560 - Ankara, Türkiye  
 Orcid: 0000-0001-7442-1332

<sup>c</sup> Gazi University,  
 Technology Faculty,  
 Dept. of Computer Engineering  
 06560 - Ankara, Türkiye  
 Orcid: 0000-0001-9324-7157

\*Corresponding author:  
 nbarisci@gazi.edu.tr

Rice, obtained through the processing of paddy, is one of the most widely consumed food products globally. However, diseases affecting rice plants, particularly those occurring on the rice leaves, pose significant challenges for farmers. The identification of rice plant diseases demands specialized knowledge, making it a complex issue to tackle. Often, due to insufficient understanding, farmers misdiagnose diseases and apply incorrect treatments. Rapid and accurate disease diagnosis plays a pivotal role in enhancing healthy and productive crop cultivation. To address this problem, a deep learning-based model was developed to detect rice plant diseases. The model was trained on a dataset containing four different rice plant diseases and achieved a successful outcome with a loss value of 0.0014. Additionally, four different deep learning algorithms were used to create models through transfer learning with pre-trained ImageNet models, and a comparison of their performance was presented. The most successful model was obtained using the VGG16 transfer learning architecture. Experimental results in this study demonstrate that the proposed transfer learning method can effectively recognize rice leaf diseases, providing a reliable approach for identifying leaf diseases in various plants.

## Derin Transfer Öğrenmeye Dayalı Pirinç Bitkisi Hastalıklarının Tespiti

### ÖZ

Çeltiğin işlenmesi sonucu elde edilen pirinç, dünyada en çok tüketilen gıda ürünlerinden bir tanesidir. Bitki yapraklarında özellikle, çeltik yapraklarında oluşan hastalıklar çiftçilerin karşılaştığı önemli sorunlardan biridir. Çeltik bitkisi hastalıkları uzman bilgisi gerektirdiğinden dolayı zor bir problemdir. Çiftçiler mahsul hastalıkları hakkında yeterince bilgi sahibi olmadıklarından dolayı hastalık için yanlış tespit yapılmakta ve yanlış tedavi uygulanmaktadır. Hastalıkların hızlı ve doğru olarak tanınması, sağlıklı ve verimli üretimin artmasındaki en önemli süreçtir. Bu tür problemlere çözüm sunmak amacıyla çeltik bitkisi hastalıklarını tespit eden derin öğrenme tabanlı bir model geliştirilmiştir. Dört farklı çeltik bitkisi hastalığı içeren veri kümesi üzerinde model eğitilmiş ve 0,0014 kayıp değeri ile başarılı bir model oluşturulmuştur. Eğitilmiş ImageNet modelleri üzerinde transfer öğrenme metodu ile modeller oluşturmak için dört farklı derin öğrenme algoritması kullanılmış ve bu modellerin performansları karşılaştırılmıştır. En başarılı model VGG16 transfer öğrenme mimarisini ile elde edilmiştir. Deneysel sonuçlar, bu çalışmada önerilen transfer öğrenme yönteminin pirinç yaprağı hastalıklarını tanıyabildiğini ve bunun da birçok bitkinin yaprak hastalıklarını tanımak için güvenilir bir yöntem sağladığını göstermektedir.

**Anahtar Kelimeler:** çeltik bitkisi hastalıkları, derin öğrenme, transfer öğrenme

## 1. Giriş (Introduction)

2021-2022 yılı arasında pirinç, tahıl üretiminde 509,87 milyon ton ile üçüncü sırada yer almaktadır [1]. Enerji kaynağında temel gıda olarak pirinç, dünya nüfusunun yarısından fazlası tarafından tüketilmektedir [2]. Özellikle Asya, Latin Amerika ve Afrika bölgelerinde pirinç beslenmenin hayati bir parçası olarak kabul edilmektedir. Dünya çapında insanlar tarafından tüketilen kalorinin beşte birinden fazlasının pirinçten sağlandığı tahmin edilmektedir [3].


Çeltik bitkisinin üretimini ve kalitesini etkileyen hastalıkların teşhisi sayesinde hastalıkların tedavisini gerçekleştirmek ve yayılmasının önüne geçmek hedeflenmektedir. Bitki hastalıklarının teşhisi, alanında uzman kişilerin tanısını gerektirir [1-24]. Ayrıca hastalıkların çeşitli belirtileri arasında benzerlikler olması ve hastalıkların ilk zamanlarda ayırt edilememesi büyük problemlerdir. Bu nedenlerden dolayı hastalık tanısı maliyetli ve uzun bir süreç almaktadır. Literatürde bu problemi çözmek için yapay zekâ ve görüntü işleme tabanlı çalışmalar gerçekleştirilmiştir. Bu sayede uzman görüşüne gerek kalmadan zeki uygulamalar ile hastalık teşhisi gerçekleştirilebilmesi hedeflenmiştir. Son yıllarda bu alanda gerçekleştirilen yapay zekâ ile tespit işlemlerinde derin öğrenme teknikleri kullanılmaktadır. Özellikle transfer öğrenme teknikleri ile model üretimi gerçekleştirilmektedir.

Chen ve arkadaşları yaptıkları çalışmada, çeltik bitkisi hastalıklarını tanımlarken kullanılan görüntülerdeki gürültü kısmının etkisini azaltmaya yönelik dikkat odaklı dinamik mod ayrıştırma tekniğini ve dört farklı çeltik bitkisi hastalık türü tespiti için XceptionNet modeli transfer öğrenme ile son katmanda makine öğrenimi algoritmaları kullanmışlardır. Çalışma sonucunda, gürültü etkisini azaltmak için geliştirdikleri algoritma ile %94,33 test başarısına ulaşmışlardır [21]. Yapılan farklı bir çalışmada ise en sık karşılaşılan Brown Spot hastalığının teşhisinde CNN-VGG19 modeli ile %93 doğruluğa küçük bir veri kümesi (40 görüntü) ile ulaşılmıştır [5]. Chowdhury ve ekibi, çalışmalarında model yorumlama ve tanımlama doğruluğunu artırmaya yönelik artık damıtılmış transformatör mimarisi kullanmışlardır. Multi-Layer Perceptron ile desteklenen mimaride dört farklı hastalık verisi için %92 oranında doğruluk değerine ulaşılmıştır. Önerilen mimari ile tahmin sonuçlarında önemli olan temel özellikleri kavramada modelin yorumlanabilmesini sağladıklarını belirtmişlerdir [22]. Bir diğer çalışmada, çeltik bitkisi hastalıklarını tespit etmek için GoogLeNet mimarisi temel alınmıştır. Mimari üzerinde evrişim çekirdek yapısı değişikliği yapılması ve mimariye dikkat mekanizması eklenmesi ile rE-GoogLeNet adı verilen mimari oluşturulmuştur. Oluşturulan bu modelin %99,58 doğruluk oranı ile GoogLeNet ile oluşturulan modelden daha başarılı sonuç verdiği gösterilmiştir [7].

Bu alanda yapılan çalışmalar temel olarak; çeltik bitkisi hastalıklarının teşhisi için kullanılan yöntem veya çalışmalarda yer verilen hastalık çeşitlerine göre gruplandırılabilir. Bu çalışmada, literatürdeki klasik makine öğrenmesi, derin öğrenme ve hibrit yöntemleri kullanan çalışmalar gruplandırma yapılarak incelenmiştir. Şekil 1'de, incelenen çalışmalardaki veri kümesi büyüklükleri ve çalışmaların başarı performans oranları grafik üzerinde verilmiştir. Şekil incelendiğinde genel olarak veri kümesi büyüklüğü arttıkça başarı değerinin arttığı gözlemlenmiştir. Genel olarak, hibrit yöntemler derin öğrenme modellerini içermektedir. Derin öğrenme metodlarının kullanıldığı çalışmalarda yüksek performans elde edildiği görülmektedir. Her hastalık için veri kümesinde yer alan örnek sayısının artmasının genel olarak başarıyı artırdığı gözlemlenmiştir. İncelenen çalışmalar arasında en çok hastalık çeşidi ile (dokuz farklı sınıf) [22] ve en az çeşit ile (bir hastalık ve sağlıklı bitki sınıf bilgisi) [2] numaralı çalışmalar öne çıkmıştır. Dört hastalık verisinin sınıflandırıldığı ve her sınıf bilgisi için en çok örnek sayısı bulduran çalışma [16] ise %99.7 oranı ile en yüksek başarıya sahip çalışmadır. Bu çalışmayı %99,58 başarı oranı ile [7] numaralı çalışma takip etmektedir. Bu çalışmada sekiz farklı hastalık verisi sınıflandırılmış ve her sınıfa ait örnek sayısı tüm incelenen çalışmaların ortalama örnek sayısından daha azdır.

Bu çalışma pirinç bitkisi hastalıklarından en sık karşılaşılan dört hastalık türü (Bacterial Blight, Blast, Brown Spot ve Tungro) üzerine yoğunlaşmıştır. Bu hastalıklardan toplamda 5932 adet örnek resim verisi bulunmaktadır. Hastalık tespiti için en uygun yöntemi bulmak amacıyla dört mimari (DenseNet, InceptionV3, VGG16 ve MobileNet) ile transfer öğrenme yaklaşımı üzerinde incelemeler gerçekleştirilmiştir.

Bu çalışma toplam dört bölümden oluşur. Birinci bölüm problem tanımı ve literatürdeki benzer problemler için üretilmiş çalışmaların özetleri ve karşılaştırmalarını sunan giriş bölümüdür. İkinci bölüm, çalışmada kullanılan veri seti ve modeller ile ilgili bilgileri içeren materyal ve metod bölümüdür. Çalışmamızda izlediğimiz süreçler bu bölümde detaylandırılmıştır. Üçüncü bölümde deneysel sonuçlarımızın tartışıldığı ve önerilen modelin sunumunu içermektedir. Son bölümde ise çalışmanın sonuç ve değerlendirmesini içerir.




Şekil 1. İncelenen çalışmalar hakkında elde edilen bilgilerin özeti  
(Summary of information obtained about the studies reviewed)

## 2. Materyal ve Metotlar (Material and Methods)

Bu bölümde çalışmada kullanılan veri kümesi ve değerlendirme metrikleri anlatılmaktadır. Değerlendirilen metot ve elde edilen deneysel sonuçlar hakkında bilgiler de bu bölümde yer almaktadır. Çalışmada gerçekleştirilen tüm deneyler Intel(R) Core(TM) i7-8750H CPU @ 2.20GHz Windows 10 x64 işletim sistemine, Nvidia GeForce RTX 1080 Ti grafik kartına ve 16 GB RAM'e sahip bir bilgisayarda Python ile gerçekleştirildi.

Çalışmada izlenen adımlar Şekil 2'de gösterime sunulmuştur. Çalışmada kullanılan dört pirinç hastalığına ait görüntüler eğitim ve test olarak ayrılmıştır. Eğitimde kullanılacak veriler üzerinde veri çoğaltma işlemi uygulanmıştır. Artırılan eğitim verisi transfer learning metodunu kullandığımız dört farklı mimari ile modellere girdi olarak sunulmuştur. Tüm mimariler için ortak parametreler belirlenmiştir. Modellerin başarı ve kayıp değerleri ile birlikte parametre sayıları üzerinde model değerlendirme işlemleri gerçekleştirilmiştir.



Şekil 2. Çalışmada izlenen metodolojinin gösterimi  
(Demonstration of the methodology followed in the study)

### 2.1. Veri kümesi (Dataset)

Çalışmada kullanılan veri kümesi, Mendeley'de genel kullanıma açılmış bir pirinç yaprak hastalık veri kümesidir. Toplamda "Bacterial Blight, Blast, Brown Spot ve Tungro" olarak 4 adet sınıf ve toplamda 5932 adet resim içermektedir. Veri kümesinde Bacterial Blight sınıfına ait 1584 adet, Blast sınıfına ait 1440 adet, Brown Spot için 1600 ve Tungro için toplamda 1308 adet veri bulunmaktadır. Hastalıklar yani sınıflar ile ilgili örnek görseller Şekil 3'de sunulmuştur.


Blast, patlamaya neden olur ve bir pirinç bitkisinin tüm toprak üstü kısımlarında patlama gözlemlenebilir [20]. En sık görüneni yaprak patlamasıdır. Brown Spot, yani Kahverengi Leke, en yaygın ve en zararlı pirinç hastalıklarından biridir. Bu hastalık yaprak, yaprak kılıfı ve salkım dallar üzerine bulaşabilen bir mantar

hastalığıdır [23]. Bacterial Blight hastalığında ise bakterilerden dolayı yapraklar grimsi yeşile döner ve kıvrılır. Hastalık ilerledikçe yapraklar sarararak saman rengine döner ve solgunlaşır. Bu da bütün fidelerin kurumasına ve ölmesine neden olur [30]. Tungro, viral bir hastalıktır ve yaygın olarak görünmektedir [31]. Bu çalışmada, veri kümesinde eğitim ve doğrulama için kullanılan her bir veri için veri çoğaltma işlemi gerçekleştirilmiştir. Veri çoğaltma işleminde 0.2 rotasyon uygulanmıştır. Veri çoğaltma işlemine ait görsel Şekil 4 üzerinde gösterilmektedir.

Veri kümesinde yer alan sınıflara ait sayısal bilgiler Tablo 1 üzerinde gösterilmektedir. Buna göre veri çoğaltma işlemleri ile ilgili değerler; eğitim, doğrulama ve test işlemleri için veri kümesindeki veri sayıları da tabloda görülmektedir. Toplam resim sayısı ve veri çoğaltmada kullanılan resim sayısı dört sınıf için dengeli durumdadır. Test veri sayısı olarak en fazla Brown Spot ve en az olarak Tungro sınıfları için değerlendirilmiştir.



Şekil 3. Veri kümesinde yer alan sınıflara ait örnek görüntüler  
(Sample images of the classes in the dataset)



Şekil 4. Veri çoğaltma işlemi için örnek  
(An example for data augmentation)

Tablo 1. Veri boyutu değişimi (Data size change)

Sınıf	Toplam resim sayısı	Veri çoğaltmada kullanılan resim sayısı	Eğitim ve doğrulamada kullanılan toplam veri sayısı	Test veri sayısı
Bacterial Blight	1584	1425	12825	159
Blast	1440	1296	11664	144
Brown Spot	1600	1440	12960	160
Tungro	1308	1177	10593	131
Toplam	5932	5338	48042	594

## 2.2. Değerlendirme metrikleri (Evaluation metrics)

Literatürde makine öğrenmesi algoritmalarında model performansının değerlendirmesinde doğruluk (accuracy), duyarlılık (recall), kesinlik (precision) ve F-ölçütü (F1-score) sık kullanılan metriklerdir. Bu metrikler sınıflandırma sonucunda elde edilen hata matrisi kullanılarak çözümlenmektedir. Hata matrisinde, gerçek ve tahmin sınıfları için pozitif ve negatif etiketler bulunmaktadır. Gerçek sınıfta pozitif etikete sahip verilerin; tahmin sınıfında pozitif etikete sahip olması Doğru Pozitif (DP), tahmin sınıfında negatif etikete sahip olması ise Yanlış Negatif (YN) ile ifade edilir. Gerçek sınıfta negatif etikete sahip verilerin; tahmin sınıfında pozitif etikete sahip olması Yanlış Pozitif (YP), tahmin sınıfında negatif etikete sahip olması ise Doğru Negatif (DN) ile ifade edilir. Eşitlik 1 üzerinde doğruluk değerinin matematiksel gösterimi ve kullanılan değerler yer almaktadır.

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+DN+YN} \quad (1)$$

## 2.3. Metotlar (Methods)

Çalışmada problemin çözülmesine yönelik dört adet derin öğrenme mimarisi ile modeller geliştirilmiştir. Buradaki amaç problem çözümü için en uygun modelin belirlenmesidir. Bu mimariler DenseNet, InceptionV3, VGG16 ve MobileNet'tir. DenseNet, özellik haritalarını ağ boyunca bir katmandan diğerine yinelemeli olarak birleştiren bir mimari sunmaktadır [27]. InceptionV3 ise Google tarafından geliştirilmiştir ve serisinin üçüncü sürümüdür. Model ağı en iyi hale getirmek üzere bir dizi yaklaşım kullandığı için eğitilmesi zaman bakımından maliyetli olan bir mimaridir [28]. VGG16, Görsel Geometri Grubu (Visual Geometry Group, VGG) tarafından geliştirilen evrişimli bir sinir ağı modelidir. Model

performansını yüksek boyutlu evrişim çekirdekleri ( $11 \times 11$ ,  $7 \times 7$ ) yerine birden fazla  $3 \times 3$  boyutunda evrişim çekirdeğinin kullanılması ile artacağı düşüncesi ile geliştirilmiş bir mimaridir [25]. MobileNet ise model boyutu daha küçük, eğitilebilir parametreleri ve hesaplama miktarı daha az olan ve kısıtlı olarak mobil cihazlarda dağıtım için uygun hale getirilen bir mimaridir [26].

Tablo 2. Modellerdeki parametre değerleri (Parameter values in models)

Parametre	Değer
Tek seferde alınan örnek sayısı boyutu	32
Öğrenme oranı	$1e-4$
Optimizasyon algoritması	optimizers.SGD
Başlangıç ağırlık değerleri	Imagenet
Momentum	0.9
Kayıp fonksiyonu	categorical_crossentropy
Son katman	Softmax
Epok	50
Tek seferde alınan örnek sayısı boyutu	32
Öğrenme oranı	$1e-4$
Optimizasyon algoritması	optimizers.SGD

Bu çalışmada dört mimari içinde transfer öğrenme yaklaşımı kullanılmıştır. Transfer öğrenimi; farklı bir modelin daha büyük veya farklı bir veri kümesi üzerinde eğitilmesiyle elde edilen ağırlıkları kullanarak bir modeli önceden başlatma işlemidir [29, 32]. Derin öğrenme modelini küçük bir veri kümesiyle eğitmek genellikle modelin performansı açısından yetersizdir. Bu sorunun önüne geçmek için transfer öğrenimi yöntemi kullanılır. Bu yöntem ile derin öğrenme sürecindeki ilk birkaç katman, görevin özelliklerini tanımlamak için eğitilir. Eğitilen ağırlık son birkaç katmanı kaldırılabilir ve hedef görev için yeni katmanlarla yeniden eğitilebilir. Çalışmada son katman, problem sınıfı sayısına göre şekillendirilmiştir.

Tüm model geliştirmelerinde kullanılan parametreler sabit tutulmuştur. Bu parametreler ve ilgili değerler Tablo 2’de verilmiştir.

### 3. Deneysel Sonuçlar (Experimental Results)

Çalışmada dört pirinç bitkisi hastalığı için geliştirilen modellerde elde edilen eğitim ve test başarı değerleri Tablo 3 üzerine yerleştirilmiştir.

Tablo 3. Modellerin başarı değerleri (Success values of the models)

Model	Eğitim Başarısı	Eğitim Kayıp	Test Başarısı	Test Kayıp	Parametre Sayısı
DenseNet	0.9989	0.0075	1.0	0.0019	18,329,668
InceptionV3	0.9985	0.0079	1.0	0.0014	21,810,980
VGG16	1.0	0.0005	1.0	0.0001	14,716,740
MobileNet	0.8933	0.2809	0.9356	0.1410	2,263,108

Başarı değerleri incelendiğinde eğitim ve test verisi üzerindeki en yüksek başarı değeri VGG16 ile elde edilmiştir. Eğitilen modeller arasında en düşük başarı değeri ise MobileNet ile oluşturulan modelde gözlemlenmiştir. VGG16 modelinin yüksek doğruluk, düşük kayıp değerleri üretmesi ve aynı zamanda dört modelden düşük parametre sayısında ikinci sırada olması modelin tercih edilebilirliğini artırmıştır.

MobileNet ile oluşturulan model hariç diğer tüm modellerde, literatürde incelenen çalışmalardan daha başarılı sonuç üretilmiştir. Özellikler aynı veri seti veya aynı sınıf sayısına sahip çalışmalar karşılaştırıldığında [2,9,12,13,15,16,17,19] en başarılı model VGG16 ile çalışmada üretilen modeldir. Upadhyay ve Kumar 2021’de gerçekleştirdikleri çalışmada %99,7 ile çalışmamıza en yakın sonuçları elde etmişlerdir.

### 4. Sonuç ve Değerlendirme (Conclusion and Evaluation)

Hastalık belirtileri bitkilerin çeşitli kısımlarında görülebilir. Özellikle yapraklar bitki hastalığını teşhis etmek için yaygın olarak kullanılmaktadır. Derin öğrenme uygulamalarının gelişmesi, araştırmacıları yaprak görüntüsü analiz tekniklerini kullanarak bitki hastalıklarını tanıma konusunda araştırma yapmaya teşvik etmektedir. Son yıllarda bu alanda yapılan çalışma sayısı artış göstermektedir. Bu çalışmada, çeltik bitkisi hastalığı transfer öğrenme tekniği ile üretilen model sayesinde tahmin edilmektedir. Çalışmada kullanılan erişime açık veri kümesinde, toplamda dört hastalık görüntüsü bulunmaktadır. Yüksek doğruluk sağlanması, düşük kayıp değerler üretmesi ve aynı zamanda düşük parametre sayısına sahip olması ile VGG16 modeli çalışmada seçilmiştir. Önerilen çalışmadan elde edilen sonuçlar, çeltik bitkisi hastalıklarının teşhis edilmesi



konusunda oldukça umut vericidir. Ama çalışmada en yaygın görülen dört hastalık verisi kullanılsa da farklı hastalıklar da mevcuttur. İleriki çalışmalar için hastalık çeşidini artırmak ve gerçek zamanlı tanıma sistemi oluşturarak çiftçiye katkılar sağlamak amaçlanmaktadır.

### Teşekkür (Acknowledgment)

Çalışma FGA-2022-7973 nolu Gazi Üniversitesi BAP Projesi tarafından desteklenmiştir. Destekleri için Gazi Üniversitesine teşekkür ederiz.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

- [1] M. Shahbandeh, "Grain production worldwide 2022/23, by type," Sept. 20, 2023. [Online]. Available: <https://www.statista.com/statistics/263977/world-grain-production-by-type/>. [Accessed: Nov. 10, 2023]
- [2] N. Krishnamoorthy, L.V.N. Prasad, C.S.P. Kumar, B. Subedi, H.B. Abraha and V.E. Sathishkumar, "Rice leaf diseases prediction using deep neural networks with transfer learning," *Environmental Research*, Vol. 198, pp. 1-8, 2021. doi: 10.1016/j.envres.2021.111275.
- [3] O. Wallach, "Visualizing the World's Biggest Rice Producers," Feb. 23, 2022. [Online]. Available: <https://www.visualcapitalist.com/worlds-biggest-rice-producers/>. [Accessed: Nov. 10, 2023]
- [4] K. M. Sudhesh, , V. Sowmya, , S. Kurian and O. K. Sikha, "AI based rice leaf disease identification enhanced by Dynamic Mode Decomposition," *Engineering Applications of Artificial Intelligence*, Vol. 120, pp. 1-22, 2023. doi: 10.1016/j.engappai.2023.105836.
- [5] R. Dogra, S. Rani, A. Singh, M. A. Albahar, A. E. Barrera and A. Alkhayat, "Deep learning model for detection of brown spot rice leaf disease with smart agriculture," *Computers and Electrical Engineering*, Vol. 109, pp. 1-11, 2023. doi: 10.1016/j.compeleceng.2023.108659.
- [6] C. Zhou, Y. Zhong, S. Zhou, J. Song and W. Xiang, "Rice leaf disease identification by residual-distilled transformer," *Engineering Applications of Artificial Intelligence*. Vol. 121, pp. 1-9, 2023. doi: 10.1016/j.engappai.2023.106020.
- [7] L. Yang, X. Yu, S. Zhang, H. Long, H. Zhang, S. Xu and Y. Liao, "GoogLeNet based on residual network and attention mechanism identification of rice leaf diseases," *Computers and Electronics in Agriculture*, Vol. 204, pp. 1-11, 2023. doi: 10.1016/j.compag.2022.107543.
- [8] T. G. Devi and P. Neelamegam, "Image processing based rice plant leaves diseases in Thanjavur, Tamilnadu," *Cluster Computing*, Vol. 22, pp. 13415–13428, 2019. doi: 10.1007/s10586-018-1949-x.
- [9] M. Al-Amin, D. Z. Karim and T. A. Bushra, "Prediction of Rice Disease from Leaves using Deep Convolution Neural Network towards a Digital Agricultural System," in *2019 22nd International Conference on Computer and Information Technology, ICCIT 2019, Dhaka, Bangladesh, 18-20 December 2019*, pp. 1–5,
- [10] M. E. Pothan and M. L. Pai, "Detection of Rice Leaf Diseases Using Image Processing," in *2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC)*, pp. 424-430, 2020. doi: 10.1109/ICCMC48092.2020.ICCMC-00080.
- [11] S. Ramesh and D. Vydeki, "Recognition and classification of paddy leaf diseases using Optimized Deep Neural network with Jaya algorithm," *Information Processing in Agriculture*, Vol. 7, 2020, pp. 249-260, doi: 10.1016/j.inpa.2019.09.002.
- [12] S. Ghosal and K. Sarkar, "Rice Leaf Diseases Classification Using CNN With Transfer Learning," in *2020 IEEE Calcutta Conference, CALCON 2020, Kolkata, India, 28-29 February 2020*, pp. 230-236.
- [13] B.S. Bari, M.N. Islam, M.M. Rashid, M.J. Hasan, M.A. Razman, R.M. Musa, A.F. Nasir and A.P. Majeed, "A real-time approach of diagnosing rice leaf disease using deep learning-based faster R-CNN framework," *PeerJ Computer Science*, Vol. 7, pp. 1-27, 2021. doi: 10.7717/peerj-cs.432.
- [14] P. Mekha and N. Teeyasuksaet, "Image Classification of Rice Leaf Diseases Using Random Forest Algorithm," in *2021 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunication Engineering, Cha-am, Thailand, 03-06 March 2021*, pp. 165-169,
- [15] S. M. Shahidur Harun Romy, M. I. Arefin Hossain, F. Jahan and T. Tanvin, "An IoT based System with Edge Intelligence for Rice Leaf Disease Detection using Machine Learning," in *2021 IEEE International IOT, Electronics and Mechatronics Conference IEMTRONICS 2021, Toronto, ON, Canada, 21-24 April 2021*, pp. 1-6,
- [16] S.K. Upadhyay and A. Kumar, "A novel approach for rice plant diseases classification with deep convolutional neural network" *International Journal of Information Technology*, Vol. 14, pp. 185–199, 2022. doi: 10.1007/s41870-021-00817-5.

- [17] P. K. Sethy, N. K. Barpanda, A. K. Rath and S. K. Behera, "Deep feature based rice leaf disease identification using support vector machine", *Computers and Electronics in Agriculture*, Vol. 175, pp. 1-9, 2020. doi: 10.1016/j.compag.2020.105527.
- [18] Z. Jiang, Z. Dong, W. Jiang and Y. Yang, "Recognition of rice leaf diseases and wheat leaf diseases based on multi-task deep transfer learning", *Computers and Electronics in Agriculture*, Vol. 186, pp. 1-9, 2021. doi: 10.1016/j.compag.2021.106184.
- [19] F. Jiang, Y. Lu, Y. Chen, D. Cai and G. Li, "Image recognition of four rice leaf diseases based on deep learning and support vector machine", *Computers and Electronics in Agriculture*, Vol. 179, pp. 1-9, 2020, doi: 10.1016/j.compag.2020.105824.
- [20] A. Sparks, "blast leaf collar" Sept. 10, 2021. [Online]. Available: <http://www.knowledgebank.irri.org/training/fact-sheets/pest-management/diseases/item/blast-leaf-collar>. [Accessed: Nov. 10, 2023]
- [21] J. Chen, D. Zhang, Y. A. Nanekharan and D. Li, "Detection of rice plant diseases based on deep transfer learning," *Journal of the Science of Food and Agriculture*, Vol. 100, pp. 3246-3256, 2020. doi: 10.1002/jsfa.10365.
- [22] C.R. Rahman, P.S. Arko, M. E. Ali, M. A. I. Khan, S. H. Apon, F. Nowrin and A. Wasif, "Identification and recognition of rice diseases and pests using convolutional neural networks," *Biosystems Engineering*, Vol. 194, pp. 112-120, 2020. doi: 10.1016/j.biosystemseng.2020.03.020.
- [23] A. Sparks, "Brown Spot" Sept. 15, 2021. [Online]. Available: <http://www.knowledgebank.irri.org/training/fact-sheets/pest-management/diseases/item/brown-spot>. [Accessed: Nov. 10, 2023]
- [24] M. T. Ahad, Y. Li, B. Song and T. Bhuiyan, "Comparison of CNN-based deep learning architectures for rice diseases classification," *Artificial Intelligence in Agriculture*, Vol. 9, pp. 22-35, 2023. doi: 10.1016/j.aiaa.2023.07.001.
- [25] H. Yang, J. Ni, J. Gao, Z. Han and T. Luan, "A novel method for peanut variety identification and classification by Improved VGG16," *Scientific Reports*, Vol. 11, pp. 1-17, 2021. doi: 10.1038/s41598-021-95240-y.
- [26] Y. Nan, J. Ju, Q. Hua, H. Zhang and B. Wang, "A-MobileNet: An approach of facial expression recognition," *Alexandria Engineering Journal*, Vol. 61, pp. 4435-4444, 2022. doi: 10.1016/j.aej.2021.09.066.
- [27] X. Xu, J. Lin, Y. Tao and X. Wang, "An improved DenseNet method based on transfer learning for fundus medical images," in *7th international conference on digital home 2018 (ICDH)*, pp. 137-140. Nov. 30 - Dec 01, 2018, Guilin, China [Online]. Available: IEEE Xplore, <http://www.ieee.org>. [Accessed: 10 Nov. 2023].
- [28] M. Mujahid, F. Rustam, R. Álvarez, J. L.V. Mazón, I. T. Díez and I. Ashraf, "Pneumonia classification from X-ray images with inception-V3 and convolutional neural network," *Diagnostics*, Vol. 12, pp. 1-16, 2022. doi: 10.3390/diagnostics12051280.
- [29] K. Weiss, T. M. Khoshgoftaar and D. Wang, "A survey of transfer learning," *Journal of Big data*, Vol. 3, pp. 1-40, 2016. doi: 10.1186/s40537-016-0043-6.
- [30] A. Sparks, "Bacterial Blight" Sept. 25, 2021. [Online]. Available: [http://www.knowledgebank.irri.org/training/fact-sheets/pest-management/diseases/item/bacterial-blight?category\\_id=326](http://www.knowledgebank.irri.org/training/fact-sheets/pest-management/diseases/item/bacterial-blight?category_id=326). [Accessed: Nov. 10, 2023]
- [31] N. A. Mohamed, N. M. F. Ngah, A. Abas, N. Talip, M. N. Sarian, H. S. Hamezah, S. Harun and H. Gunawan, "Candidate miRNAs from *Oryza sativa* for Silencing the Rice Tungro Viruses," *Agriculture*, Vol. 13, pp. 1-14, 2023. doi: 10.3390/agriculture13030651.
- [32] N. Barışçı, M. Güllü and İ.A. Doğru, "Derin Transfer Öğrenmeye Dayalı Pirinç Bitkisi Hastalıklarının Tespiti," in *Accepted Abstracts e-Book: Proc. of the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering, ICAIAME 2023, Antalya, Türkiye, 03-05 November 2023*, pp. 40.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### Forecasting Light Commercial Vehicle Sales in Turkey by Machine Learning Methods

Mehmet Kayakuş<sup>a</sup>, Mustafa Terzioğlu<sup>b</sup>, Ayten Yağmur<sup>c</sup>, Dilşad Erdoğan<sup>d</sup>

Submitted: 19.11.2023 Revised: 07.12.2023 Accepted: 08.12.2023 doi:10.30855/gmbd.0705S11

#### ABSTRACT

Light commercial vehicles such as vans, pick-up trucks, panel vans, and minibuses are a class of vehicles used in large quantities, especially in the trade and service sectors. Changes in demand for this class of vehicles are also perceived as an indicator of the economic vitality of countries. In this study, it is thought that forecasting the sales and imports of light commercial vehicles, which is accepted as a macroeconomic indicator, will contribute to the evaluation of general economic indicators and will be useful for automotive companies operating in this market in terms of effective corporate resource planning and efficient use of resources from a micro perspective. The sales forecasting model designed in this study was created by analysing previous studies in the literature and including macroeconomic variables that are thought to affect light commercial vehicle sales in the model. The sales forecasting model designed in this study is constructed by analysing previous studies in the literature and including macroeconomic variables that are thought to affect light commercial vehicle sales in the model. Three machine learning methods, namely artificial neural network (ANN), multiple linear regression (MLR) and decision tree (DT) regression, were used to measure the forecasting success of the model. As a result of the study, the R2 value was found to be 94.6% for ANN, 64.1% for MLR, and 82.2% for DT. According to the results obtained, it is concluded that the model designed for the prediction of light commercial vehicle sales in Turkey performs very successful predictions with ANN method.

**Keywords:** Light commercial vehicle, vehicle demand forecast, Turkey economy, machine learning

<sup>a,\*</sup> Akdeniz Üniversitesi,  
Manavgat Sosyal ve Beşerî Bilimler  
Fakültesi,  
Yönetim Bilişim Sistemleri Bölümü  
07600 - Antalya, Türkiye  
Orcid: 0000-0003-0394-5862  
e mail: [mehmetkayakus@akdeniz.edu.tr](mailto:mehmetkayakus@akdeniz.edu.tr)

<sup>b</sup> Akdeniz Üniversitesi,  
Korkuteli Meslek Yüksekokulu,  
Muhasebe ve Vergi Bölümü  
07800 - Antalya, Türkiye  
Orcid: 0000-0002-4614-7185

<sup>c</sup> Akdeniz Üniversitesi,  
İktisadi ve İdari Bilimler Fakültesi,  
Çalışma Ekonomisi ve Endüstri İlişkileri  
Bölümü  
07070 - Antalya, Türkiye  
Orcid: 0000-0003-2138-240X

<sup>d</sup> Akdeniz Üniversitesi,  
Korkuteli Meslek Yüksekokulu,  
Finans, Bankacılık ve Sigortacılık Bölümü  
07800 - Antalya, Türkiye  
Orcid: 0000-0002-9117-5994

\*Corresponding author:  
[mehmetkayakus@akdeniz.edu.tr](mailto:mehmetkayakus@akdeniz.edu.tr)

**Anahtar Kelimeler:** Hafif ticari araç, taşıt talep tahmini, Türkiye ekonomisi, makine öğrenmesi

### Türkiye'deki Hafif Ticari Araç Satışlarının Makine Öğrenmesi Yöntemleriyle Tahmin Edilmesi

#### ÖZ

Kamyonet, pikap, panelvan, minibüs gibi hafif ticari araçlar, özellikle ticaret ve hizmet sektörlerinde büyük miktarlarda kullanılan bir araç sınıfıdır. Bu sınıftaki araçlara yönelik talepteki değişimler, ülkelerin ekonomik canlılığının da bir göstergesi olarak algılanmaktadır. Bu çalışmada, makroekonomik bir gösterge olarak kabul edilen hafif ticari araç satış ve ithalatının tahmin edilmesinin, genel ekonomik göstergelerin değerlendirilmesine katkı sağlayacağı ve bu pazarda faaliyet gösteren otomotiv firmaları için mikro bakış açısıyla etkin kurumsal kaynak planlaması ve kaynakların verimli kullanılması açısından faydalı olacağı düşünülmektedir. Bu çalışmada tasarlanan satış tahmin modeli, literatürdeki önceki çalışmaların analiz edilmesi ve hafif ticari araç satışlarını etkileyebileceği düşünülen makroekonomik değişkenlerin modele dahil edilmesi ile oluşturulmuştur. Bu çalışmada tasarlanan satış tahmin modeli, literatürdeki önceki çalışmalar analiz edilerek ve hafif ticari araç satışlarını etkileyebileceği düşünülen makroekonomik değişkenler modele dahil edilerek oluşturulmuştur. Modelin tahmin başarısını ölçmek için yapay sinir ağı (YSA), çoklu doğrusal regresyon (MLR) ve karar ağacı regresyonu (DTR) olmak üzere üç makine öğrenmesi yöntemi kullanıldı. Çalışma sonucunda R2 değeri YSA için %94,6, ÇDR için %64,1 ve DTR için %82,2 olarak bulunmuştur. Elde edilen sonuçlara göre, Türkiye'deki hafif ticari araç satışlarının tahmini için tasarlanan modelin YSA yöntemi ile oldukça başarılı tahminler gerçekleştirdiği sonucuna varılmıştır.

## 1. Giriş (Introduction)

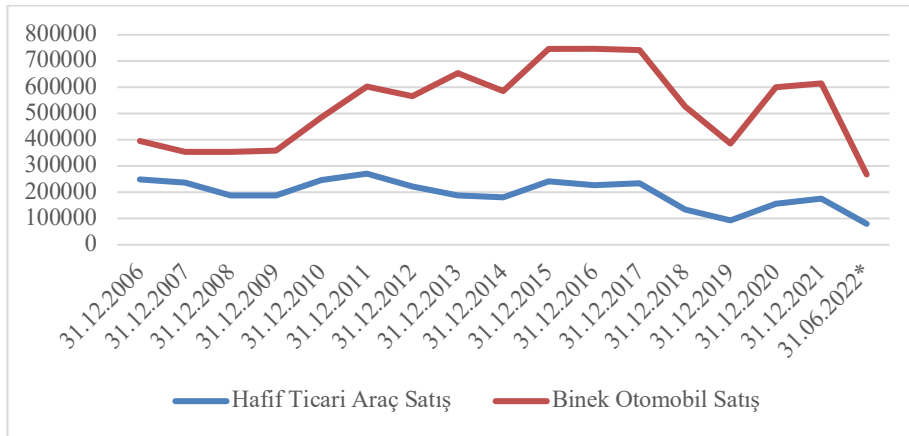
Otomotiv sektörü; teknolojik gelişmelerle birlikte ülke ekonomisi için yarattığı katma değer, istihdam alanı yaratması ve diğer sektörlerle olan yakın ilişkisi sebebiyle önem taşımaktadır [1]. Diğer sektörlerle bağlantılı olan otomotiv sektörü teknolojiye gerçekleşen hızlı gelişmeler ve küreselleşmenin de etkisiyle yaşanan uluslararası rekabet ortamında ülkelerin ekonomik görünümü açısından önemi daha da artmıştır [2, 3]. Otomotiv sektörü aynı zamanda sahip olduğu ürün çeşitliliği ile teknolojik gelişmelerin en hızlı uygulandığı, üretim tekniklerinin hızla geliştiği ve rekabetin en fazla yaşandığı sektörlerdendir. Bu açıdan hem gelişmiş hem de gelişmekte olan ülkeler için önem taşımaktadır. Aynı zamanda otomotiv sektörünün hizmet sektörüyle olan bağlantısı sebebiyle satış, bakım-onarım sigortacılık, kiralama hizmetlerine de katkı sağlamaktadır [2].

Otomotiv sektöründe uluslararası piyasada fiyat rekabeti söz konusuysen günümüzde kalite, ürün çeşitliliği ve geleceğe yatırım rekabet için belirleyici unsurlar olmuştur. Satışlar tüketici tercihlerine göre belirlendiği için ürün geliştirme, marka ve model geliştirme gibi faktörler daha önemli hale gelmiştir [4].

Otomotiv sektöründe üretim planlarının yapılabilmesi için uzun dönemli talep tahminlerinin yapılması önemlidir. Talep ise belli bir dönemde piyasadaki tüketicilerin bir ürüne yönelik olarak ortaya çıkan satın alma isteğidir. Tüketicilerin seçimleri birçok faktöre bağlı olmakla birlikte en önemli faktör malın kendi fiyatıdır. Bu bağlamda rekabetin fazla olduğu otomobil sektöründe, otomobil talebi sadece kendi fiyatı değil beraberinde diğer otomobil fiyat ve kalitesinden de etkilenmektedir. Ayrıca ülkenin genel ekonomik görünümü, taşıt finansmanı olanakları, hane halklarının tasarruf kabiliyeti gibi faktörler de otomotiv satışlarını etkileyen diğer değişkenlerdir [5, 6].

Tahmin, geçmiş yıllar verilerinden hareketle çeşitli yöntemler kullanarak gelecek hakkında farklı yöntemler uygulayarak geleceği tahmin etmektir. Talep tahmini yapmak ise; sektördeki firmaların satış gelirlerini, verimliliği artırma, gibi amaçları için önem taşımaktadır [7]. Farklı yöntemlerle yapılan tahminler firmaların piyasa performansına katkı sağlayarak, kar elde etmelerine etmelerini sağlar [8]. Aynı zamanda satış tahmini firma yöneticilerin belirsiz bir ortamda uygun kararlar almasına yardımcı olmaktadır.

Türkiye’de hafif ticari araçların yıllara göre satışı bakıldığında yıllar içinde hafif dalgalanmalar seyretse de yatay bir seyir izlediği görülmektedir. Özellikle binek otomobil satışlarındaki daha büyük dalgalanmaların hafif ticari araçlardaki satışlarda aynı büyüklükte oluşmadığı Şekil 1’de gösterilmektedir.



Şekil 1. Yıllara Göre Türkiye’de Hafif Ticari Araç ve Binek Otomobil Satışı  
(Light commercial vehicle and passenger car sales in turkey by years)

Not: Zaman aralığı araştırmanın yapıldığı dönemi içermektedir. \* İlk altı aylık satışlar dikkate alınmıştır.

Şekil 1’de görüldüğü gibi hafif ticari araç satışları araştırmanın yapıldığı 2006- 2022 döneminde 100.000 adet ile 300.000 adet aralığında değişmektedir. Özellikle taşıt piyasasının temel pazarı binek otomobil piyasasına göre 2011-2015 arasında satışların seyri ayrılmaktadır. Bunun nedeni 2008 yılında başlayarak 2012 yılının sonlarına kadar devam eden küresel ekonomik krizin Türkiye’deki özellikle ticaret ve üretim alanındaki etkileri olarak düşünülebilir. Bu nedenle hafif ticari araçların satışını ileri tahmin metodlarından olan makine

öğrenmesi yöntemleri ile tahmin etmek bu alanda Türkiye gibi bu alanda dışa bağımlı olan ülkelerin kaynak kullanımını için büyük önem taşımaktadır.

Bu çalışmada makine öğrenmesi yöntemleri kullanılarak Türkiye’de satılan hafif ticari araç satış miktarı tahmini gerçekleştirilmiştir. Otomotiv sektörü ve buna bağlı hizmet sektörleri olan satış, sigortacılık, bakım ve kiralama hizmetleri bu çalışma sonuçlarına gelecek bütçe ve planlarını şekillendirebileceklerdir. Otomotiv sektörünün faaliyet alanlarını büyütme ve yeni yatırımlar yapma kararlarına katkı sağlayacaktır.

Türkiye’de otomobil satış tahmini [9-11] yapılmış olmakla birlikte; bu çalışmanın hem kapsam olarak Türkiye üzerinde daha önce çalışılmamış hafif ticari araçlarının satışlarını ele alması hem de kullanılan veri setindeki bağımsız değişken seçimi ve kullanılan yöntemler çalışmayı özgünlük kazandırmakta ve benzer çalışmalardan ayırmaktadır.

## 2. Literatür (Literature)

Alper ve Serdar çalışmalarında Türkiye’de 1996-1999 yılları arasında otomobil piyasasının bir görünümünü ortaya koyarak otomobil fiyat fonksiyonu tahmin etmişler. 2005 yılı için talep tahmini yapmışlardır. 120 ayrı marka ve modele ait aylık fiyat, satış, kalite ve teknik özellik verileriyle birlikte talep eğrisinin tahmininde, bahsi geçen verilerin yansıma, reel faiz, reel tüketici kredileri, enflasyon ve enflasyonun değişkenliği verileri de kullanılmıştır. Çalışmalarında panel veri analizini kullanmışlardır. Çalışmanın sonucunda yapılan tahminler sonucunda, yerli, Avrupa Birliği’nden (AB) ve diğer ülkelerden ithal edilen otomobil taleplerinin yapısal değişiklikler gösterdiği belirlenmiştir [11].

Wang ve arkadaşları çalışmalarında otomobil satış miktarı, tesadüfi gösterge, öncü gösterge, toptan eşya fiyat endeksi ve gelir olmak üzere yedi değişkenden oluşan bir satış tahmin yöntemi önermiştir. Tayvan’da otomobil satışı üzerine tahminleme yapmışlardır. Veri seti aylık tahminlerden oluşmaktadır. Yapay sinir ağları (ANN), ANFIS (Adaptive-Network Based Fuzzy Inference Systems), ARIMA (autoregressive integrated moving average) yöntemleri kullanılmıştır. Çalışmanın ampirik sonuçlarına göre ANFIS yönteminin diğer iki yönteme göre daha başarılı sonuç verdiğini paylaşmışlardır [12].

Karaatlı ve arkadaşları çalışmalarında Türkiye’deki Ocak 2007 ve Haziran 2011 yılları arasındaki aylık otomobil satışları verileriyle yapay sinir ağları kullanılarak satış tahmini yapılmıştır. Çalışmalarında Türkiye’de 2007- 2011 yıllarındaki verilerle yeni otomobil satışı tahmin edilmiştir. Çalışmada otomobil satışını etkileyen değişkenler gayri safi yurtiçi hasıla, reel kesim güven endeksi, tüketici güven endeksi, yatırım harcamaları, tüketim harcamaları, tüketici fiyat endeksi, araç alım satımı, dolar ve zaman olarak belirlenmiştir. Çalışmada MAPE (Mean Absolute Percentage Error) değeri %16,82 çıkarak modelin doğru tahminler sınıfında gerçekleştiği araştırmacılar tarafından paylaşılmıştır. Gerçek değerlerle tahminler karşılaştırıldığında tahmin edilen ve gerçekleşen değerlerin birbirlerine yakın olduğu görülmektedir [9].

Akyurt çalışmasında Ocak 2011 – Eylül 2015 dönemi için Türkiye’deki yerli otomobil satışına ilişkin aylık verilerle yerli otomobil satış büyüklükleri tahmin edilmiştir. Geri yayılım algoritmasıyla eğitilmiş ileri beslemeli yapay sinir ağları modelini kullanılmıştır. Çalışma sonucunda, bulgular mevsimsel etkilerden arındırılmış yerli otomobil satış serinin kullandığı, iki gizli katmanın olduğu ve her gizli katmanda yedi nöronun olduğu modelin en iyi tahmin sonucunu verdiği saptanmıştır [10].

Kuvvetli ve arkadaşları çalışmalarında farklı segment ve markaları kullanarak, ekonomik ve çevresel parametrelerle aylık otomobil satışlarını tahmini yapmışlardır. Girdi olarak taşıt kredilerinde faizler, geçmiş zamanda gerçekleşmiş satış adetleri, gayrisafi milli hasıla, yakıt tüketimi, CO2 emisyonları gibi farklı parametreler seçilmiştir. 2008 – 2012 yılları arasındaki satış miktarlarını tahmin edebilecek bir ANN modeli önerilmiştir. İleri beslemeli yapay sinir ağları kullanılmış ve modelin eğitimi için ise Levenberg-Marquadt algoritması seçilmiştir. Yapay sinir ağı sonuçları lineer regresyon modeli ile kıyaslanmıştır. Yapay sinir ağı modeli ile lineer regresyon modeline göre daha doğru tahminler elde edilmiştir [13].

Pai ve Liu çalışmalarında ABD’de Şubat 2008’den Ağustos 2017’ye kadar aylık araç satış talebini tahmin etmek için çok değişkenli bir regresyon modeli ve zaman serisi analizi önermiştir. Twitter’den “araba satın al”, “yol satın al” ve “araç satın al” olmak üzere üç anahtar kelime ile veri toplayarak bu verileri otomatik duygu çözümlü ile analiz etmişlerdir. Çalışmaları, her iki tweetin duygu puanlarını içererek geliştirilen hibrit modelin araç satış talebinde daha üstün olduğunu ortaya çıkarmışlardır [14].

Aslankaya ve Öz çalışmalarında talep tahmin yöntemlerini kullanarak otomobil satışlarını tahmin etmeyi amaçlamışlardır. Zaman serisi analizi ve yapay sinir ağları kullanılmıştır. Kayıtlı araç, GSYİH (Gayri safi yurt içi hasıla), tüketici fiyat endeksi, dolar kuru, reel sektör güven endeksi, tüketici güven endeksi, aylık çalışma saatleri, üretilen model sayısı bağımsız değişken olarak kullanılmıştır. Satılan toplam araç sayısı da bağımlı değişken olarak alınmıştır. Karşılaştırma yapıldığında yapay sinir ağlarını yöntemindeki değerlerin birbirine daha yakın olduğu görülmüştür. Yapay sinir ağlarıyla elde edilen MAPE değeri %7,44 dür. Bu sonuç çoklu regresyon, hareketli ortalama ve basit üstel düzeltme yöntemlerine göre daha iyi bir tahmin gücünü işaret etmektedir [15].

### 3. Materyal ve Yöntem (Material and Method)

Bu çalışmada makine öğrenmesi yöntemleri kullanılarak Türkiye’de satılan hafif ticari araç satış miktarı tahmini gerçekleştirilmiştir. Çalışmada sekiz bağımsız değişken ve bir bağımlı değişkenden oluşan 1782 verinin yer aldığı özgün bir veri seti kullanılmıştır. Çalışmada tahmin için makine öğrenmesi yöntemlerinden yapay sinir ağları, çoklu doğrusal regresyon ve karar ağaçları regresyon yöntemleri kullanılmıştır. Bu bölümde çalışmanın materyal ve yöntemi hakkında bilgi verilmiştir.

#### 3.1. Veri seti (Data set)

Çalışmada Ocak 2006- Haziran 2022 dönemini kapsayan aylık veriler kullanılmıştır. Veriler, Türkiye İstatistik Kurumu (TÜİK), Otomotiv Distribütörleri Derneği (ODD) ve Türkiye Cumhuriyet Merkez Bankası Elektronik Veri dağıtım Sistemi (TCMB EVDS) üzerinden elde edilen açık kaynak verilerden düzenlenmiştir. Çalışmada talep tahmini modeli oluştururken bağımlı değişken olarak ODD’nin aylık raporlarından derlenen aylık hafif ticari satış adedi kullanılmıştır. Modelin tüm değişkenleri Tablo 1’de gösterilmektedir.

Tablo 1. Bağımlı ve bağımsız değişkenler (Dependent and independent variables)

Bağımlı Değişken	Bağımsız Değişkenler
Hafif Ticari Satış Adedi	Tüketici Fiyat Endeksi (TÜFE) (2003=100)
	Sanayi Güven Endeksi
	İmalat Sanayi Kapasite Kullanım Oranı
	Taşıt Kredi Faiz Oranı
	ABD dolar TL Kuru
	Euro TL Kuru
	Sanayi Üretim Endeksi (2015=100)
Trafikten Silinen Hafif Ticari Araç Sayısı	

Çalışmada hafif ticari araç satış adedi tahminini gerçekleştirmek için modele Türkiye’nin genel ekonomik durumunu yansıtabilmek için tüketici fiyat endeksi (TÜFE), imalat sanayi kapasite kullanım oranı, sanayi üretim endeksi, ABD doları kuru, Euro kuru ve bunun yanında sanayi sektöründeki ekonomik beklenti ve eğilimleri ortaya koyan sanayi güven endeksi de bağımsız değişkenler olarak seçilmiştir. Ayrıca modele taşıt satışı ile ilgili taşıt kredi faiz oranı ve trafikten silinen hafif ticari araç sayısı bağımsız değişken olarak dahil edilmiştir. Taşıt kredi faiz oranındaki değişikliklerin satın almada belirleyici bir finansman kaynağı olması düşünüldükçe modele dahil edilmiştir. Trafikten silinen hafif ticari araç sayısı bağımsız değişkeni ise yeni araç talebi oluşturabileceği için modele ilave edilmiştir.

#### 3.2. Yöntem (Method)

##### 3.2.1. Yapay Sinir Ağları (Artificial Neural Networks)

Yapay sinir ağları, insanların gerçek bir biyolojik sinir sisteminin çalışma yapısını bilgisayar ve makine sistemlerine uyarlamak ve insanlar gibi öğrenme, tahmin ve sınıflandırma işlevlerini gerçekleştirmek için kullanılan yapay zekâ disiplini [16]. Özellikle doğrusal olmayan problemlerin çözümünde sağladıkları başarılı sonuçlar nedeniyle yapay sinir ağlarının kullanım alanı ve yaygınlığı artmıştır. ANN belirli bir konuda, mevcut verileri kullanarak sonucu bilinmeyen örneklerle ilgili tahmin yapabilme yeteneğine sahiptir [15, 17].

Yapay sinir ağları, mimari yapısına göre ileri ve geri beslemeli olarak ikiye ayrılmaktadır. İleri beslemeli ağlar, bir giriş, bir gizli ve bir çıkış katmanından oluşmaktadır. Gizli ve çıkış katmanlarında bulunan işlem

birimlerine nöron adı verilir ve her nöron kendi aktivasyon fonksiyonu ve toplama fonksiyonundan oluşmaktadır [18]. Aktivasyon fonksiyonu, ağın verilerdeki karmaşık kalıpları öğrenmesine yardımcı olmak için bir yapay sinir ağına eklenen bir fonksiyondur ve bir nöronun ağda aktive edilip edilmeyeceğine karar vermektedir. Nöronun ağa girişinde matematiksel işlemler kullanarak tahmin sürecinde önemli olup olmadığına karar vermesini sağlamaktadır [19]. Gizli katmandaki aktivasyon fonksiyonu seçimi, ağ modelinin eğitim veri kümesini ne kadar iyi öğrendiğini kontrol etmesini sağlamaktadır [20]. Çıktı katmanındaki aktivasyon fonksiyonu seçimi, modelin yapabileceği tahminlerin türünü tanımlamaktadır. Aktivasyon fonksiyonu olarak adimsal, doğrusal ve sigmoid gibi fonksiyonlarından biri seçilebilir. Nöronlar daha sonra diğer katmanlardan nöronlara kısmen veya tamamen bağlanmaktadır. Her bağlantının bir ağırlığı bulunmaktadır. Ağırlıklar, sinir ağının istenen hedefe ulaşması için ayarlanan birer parametredir. Her katman girdilere karşılık gelen ağırlıklarıyla çarpılmaktadır. Daha sonra nöronlardaki aktivasyon fonksiyonuna aktarılır [21]. Geri beslemeli sinir ağının temel amacı, sinir ağının çıktısının istenen hedefe ulaşması için ağ ağırlıklarının her birini güncellemesidir. Geri beslemeli sinir ağı en çok kullanılan yapay sinir ağı türüdür [22]. Sinir ağı çıktısı ile istenen hedef arasındaki hata, bir maliyet fonksiyonu olarak ifade edilmektedir. Amaç, ağırlıkları güncelleyerek bu maliyet fonksiyonunu en aza indirmektir [23].

Yapay sinir ağı ile beyin arasındaki bir diğer benzerlik ise öğrenme yaklaşımıdır. İnsan beyni gibi yapay sinir ağının da eğitilmesi gerekir. Yapay sinir ağının eğitimi, nöronların girdileri üzerinde en iyi ağırlıkları ayarlama işlemidir. Yapay sinir ağlarının en önemli özelliklerinden biri, daha önce hiç görmedikleri soruların (girdileri) cevaplarını önceki bilgilerinden çıkarabilmeleridir. Bu, yapay sinir ağlarının genelleme yeteneği olarak adlandırılmaktadır [24].

### 3.2.2. Çoklu Doğrusal Regresyon (Multiple Linear Regression)

Regresyon modeli, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkinin gücünü ve karakterini belirlemeye çalışan finans, yatırım ve diğer disiplinlerde kullanılan istatistiksel bir yöntemdir [25, 26]. Değişkenler arasındaki bu ilişki doğrusal veya doğrusal olmayan düzlemler ile ifade edilebilmektedir. [27]

Doğrusal regresyon, regresyon analizinde kullanılan bir modelleme tekniğidir. Doğrusal regresyon, iki değişken arasındaki ilişkiyi düz bir çizgi boyunca kurmaya çalışmaktadır. Doğrusal regresyon bağımsız ve bağımlı değişken olmak üzere iki sürekli değişkene sahip olduğunda kullanılabilir. Bağımsız değişken, bağımlı değişkeni veya sonucu hesaplamak için kullanılan değişkendir [28].

Doğrusal regresyon, değişken sayısına göre basit ve çoklu doğrusal regresyon olmak üzere ikiye ayrılmaktadır. Basit doğrusal regresyon, bağımlı değişkenin değerini bir bağımsız değişken kullanarak tahmin etmeyi sağlamaktadır [27, 29].

Tek bir bağımsız değişkenle açıklanamayan bağımlı değişkenler için çoklu regresyon kullanılmaktadır. Çoklu doğrusal regresyon, bağımlı bir değişkenin sonucunu tahmin etmek için iki veya daha fazla bağımsız değişken kullanan istatistiksel bir tekniktir [30].

m adet bağımsız değişken olan ve değişkenler arasında doğrusal bir ilişki olan bir modelde:

$$y = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \beta_3 X_{i3} + \dots + \beta_k X_{ik} + \varepsilon_{ij} \quad (1)$$

Burada X bağımsız değişkenin değerini,  $\beta$  regresyon katsayısını, e hata terimini, k bağımsız değişken sayısını göstermektedir.  $\beta$  katsayısı, bağımsız değişkenin bir birim değişmesine karşılık bağımlı değişkende meydana gelecek değişme miktarını göstermektedir.

### 3.2.3. Karar Ağaçları Regresyonu (Decision Trees Regression)

Makine öğrenmesi teorisine dayanan karar ağacı, sınıflandırma ve regresyon problemlerinin çözümü için kullanılan bir yöntemdir. Karar ağacı, her düğümde rasgele sayıda düğüm ve daldan oluşan bir ağaç veri yapısıdır [31, 32]. Tekrarlayan bölme işlemi yoluyla tahmin için kullanılacak kurallar kümesi oluşturmaktadır. Karar ağacının diğer modelleme tekniklerine göre en büyük avantajı, yorumlanabilir kuralları veya mantık ifadelerini temsil edebilecek bir model üretmesidir [33, 34]. Sınıflandırma karmaşık hesaplamalar yapılmadan gerçekleştirilebilmektedir. Ayrıca hem sürekli hem de kategorik değişkenler için

kullanılabilmektedir [35].

Sınıflandırmayı tek bir karar adımında gerçekleştirmek için bir dizi özellik kullanan diğer sınıflandırma yaklaşımlarından farklı olarak, karar ağacı çok aşamalı ve hiyerarşik bir karar şemasına dayanan ağaca benzeyen bir yapı oluşturmaktadır. Ağaç, bir kök düğümden (tüm verileri içeren), bir dizi iç düğümden (bölünmeler) bir dizi terminal düğümden (yapraklar) oluşmaktadır. Karar ağacı yapısının her düğümü, bir sınıfı diğer sınıflardan ayıran ikili bir karar vermektedir. Ağaç yapısı yaprak düğüme ulaşılan kadar aşağı doğru hareket ettirilerek gerçekleştirilmektedir [36].

Bir karar ağacının temel amacı, karmaşık bir kararı, yorumlanması daha kolay bir çözüme götürecek birkaç basit karara bölmektir. Bir karar ağacı yaklaşımında, verilerin özellikleri tahmin değişkenleri iken, eşleştirilecek sınıf hedef değişken olarak adlandırılmaktadır [37].

Hedef değişken ayrık olduğunda karar ağacı sınıflandırması, hedef değişkenler sürekli olduğunda karar ağacı regresyonu olarak adlandırılmaktadır. Karar ağacı regresyon yaklaşımı, özellikler ve hedef nesnel arasındaki ilişkilerin doğrusal ya da doğrusal olmadığı varsayım üzerine kurulmaktadır. Bir karar ağacında, sınıflandırma için maksimum bilgi taşıyan öznitelikler otomatik olarak seçilmekte ve kalan öznitelikler reddedilerek hesaplama verimliliği artmaktadır [38].

Karar ağacı, verilen örneklerden bir karar ağacı oluşturan bir algoritma oluşturmaktadır. Gerçekleştirilen algoritma, uygunluk fonksiyonunu minimize ederek optimal karar ağacını bulmayı amaçlamaktadır. Başlangıçta, ağacın yapısını belirlemek için tüm eğitim örnek için kullanılmaktadır [39]. Veri kümesi, her bağımsız değişken için birkaç bölme noktasına bölünmektedir. Her bölme noktasında, gerçekleştirilen algoritma, önceden tanımlanmış uygunluk fonksiyonuyla ilgili olarak tahmin edilen değer ile gerçek değerler arasındaki hatayı hesaplamaktadır. Değişkenler arasındaki bölünme noktası hataları karşılaştırılmakta ve en düşük uygunluk fonksiyonu değerini veren değişken bölme noktası olarak seçilmektedir [40, 41]. Bu süreç yinelemeli olarak her bir düğüm, kullanıcı tarafından belirlenen minimum düğüm boyutuna (düğümdeki eğitim örneklerinin sayısı) ulaşılan ve bir uç düğüm haline gelene kadar devam etmektedir [42, 43].

En yaygın ağaç yöntemleri arasında CHAID, CART, C4.5 ve C5 bulunur [44].

### 3.3. Model performans değerlendirilmesi

Çalışma sonuçlarını analiz etmek ve yorumlamak için  $R^2$ , MSE (Mean Squared Error) ve MAPE (Mean Absolute Percentage Error) teknikleri kullanılmıştır.

$R^2$ , belirli bir olayın sonucunu tahmin ederken, bağımlı değişkendeki değişikliklerin bağımsız bir değişkendeki farkla nasıl açıklanabileceğini inceleyen istatistiksel bir ölçümdür [45]. Başka bir deyişle, daha yaygın olarak  $R^2$  olarak bilinen bu katsayı, doğrusal ilişkinin iki değişken arasında ne kadar güçlü olduğunu değerlendirir.  $R^2$  değeri 0 ile 1 arasında bir sayıdır [46]. 0 ile 1 arasında olması modelin sonucu kısmen tahmin ettiğini gösterir. 1 olması mükemmel bir uyumu gösterdiğini; 0 ise modelin verileri doğru bir şekilde modelleyemediğini gösterir [47, 48].  $R^2$  formülü Denklem 2'de gösterilmiştir:

$$R^2 = 1 - \frac{\text{Açıklanamayan Varyasyon}}{\text{Toplam Varyasyon}} \quad (2)$$

MSE (Mean Squared Error), regresyon modelinin verilere ne kadar iyi veya ne kadar kötü uyduğunu ölçmek için kullanılan istatistiksel bir yöntemdir [49]. Bir regresyon çizgisinin bir dizi noktaya ne kadar yakın olduğunu söyler. Bunu, noktalardan regresyon çizgisine olan mesafelerin (bu mesafeler hata olarak adlandırılır) karesini alarak yapar [50]. Makine öğrenmesinde gözlenen ve tahmin edilen değerler arasındaki ortalama kare farkını değerlendirir. Bir modelde hata olmadığında, MSE sıfıra eşittir. Bir modelin MSE değeri düşüğe, yani 0'a yakınsa, veri seti için iyi bir uyumdur. Tersine, 0'dan uzak yüksek MSE değerine sahip bir model, veri seti için uygun değildir. Model hatası arttıkça değeri de artar [51, 52]. MSE formülü Denklem 3'te gösterilmiştir:

$$MSE = \frac{1}{n} \sum_{j=1}^n e_j^2 \quad (3)$$



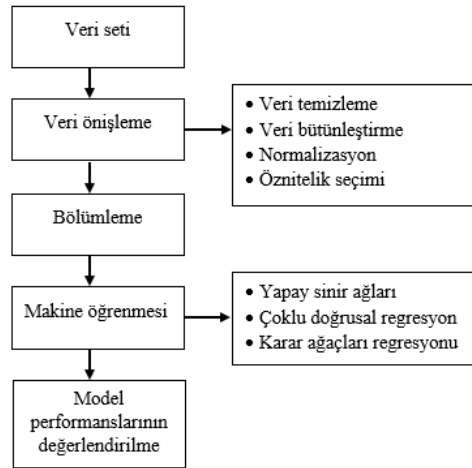
Burada  $n$  veri sayısını,  $e$  hata değerini göstermektedir.

MAPE (Mean Absolute Percentage Error) bir tahmin sisteminin doğruluğunu yüzdesel olarak ölçen istatistiksel bir yöntemdir. MAPE, bir makine öğrenmesi yönteminin iyi performans gösterip göstermediğini belirlemek için yaygın olarak kullanılan bir yöntemdir [53]. Bir veri kümesindeki her girişin mutlak yüzde hatalarının ortalamasını temsil eder ve ortalama olarak, tahmin edilen miktarların gerçek miktarlarla karşılaştırıldığında ne kadar doğru olduğunu gösterir. MAPE genellikle daha büyük veri kümelerini analiz etmek için etkilidir [54]. Veri kümelerinin MAPE'sini sıfır değerlerle hesaplamak mümkün değildir. Bunun nedeni, hesaplamanın sıfıra bölmeyi gerektirmesidir. MAPE ne kadar küçük olursa, tahmin o kadar iyi olur. MAPE, yorumlanması ve açıklanması kolay önemli bir ölçümdür [55]. MAPE formülü Denklem 4'te gösterilmiştir:

$$MAPE = \frac{100}{n} \sum_j^n \frac{|e_j|}{|A_j|} \quad (4)$$

#### 4. Sonuçlar ve Tartışma (Results and Discussion)

Çalışmada Türkiye'deki ticari araç satış adetini tahmin etmek için 198 veri kullanılmıştır. Çalışmada oluşturulan modelde bağımlı değişken olarak Türkiye'deki hafif ticari araç satış adeti; bu bağımlı değişkeni tahmin etmek için de sekiz bağımsız değişken kullanılmıştır. Çalışmada çoklu doğrusal regresyon, karar ağacı regresyonu ve yapay sinir ağları olmak üzere 3 farklı makine öğrenmesi tekniği kullanılmıştır. Modellerin başarı ve hata analizlerini yapmak için ise R2, MSE ve MAPE istatistiksel yöntemleri kullanılmıştır. Çalışmada açık kaynak program olan Knime programı kullanılmıştır. Knime programı veri analizi, raporlama, entegrasyon işlemlerinde kullanılan grafiksel bir arayüze sahip olan bir platformdur. Çalışmanın temel çalışma yapısı Şekil 2'de görülmektedir.



Şekil 2. Çalışmanın yapısı (Structure of the study)

Şekil 2'de görüldüğü gibi veri seti oluşturulduktan sonra yapılacak ilk işlem veri seti üzerinde ön işleme aşamasıdır. Bu aşamanın da ilk adımı veri temizlemedir.

Veri toplama aşamasında hatalı veri elde edilebilir veya veri toplama araçlarından hatalı bilgiler gelebilmektedir. Bu yüzden veri kümeleri makine öğrenmesi yöntemlerinin doğru olarak anlayamadığı ve yorumlayamadığı veriler içerebilir [56]. Veri kümesindeki bu hatalara gürültü veri adı verilmektedir. Gürültülü veriler, depolama alanı miktarını gereksiz yere artırır ve herhangi bir veri madenciliği analiz sonucunu olumsuz etkileyebilir [57, 58]. Gürültülü verileri veri kümesinden tespit etmek ve ortadan kaldırmak için yapılabilecekler:

Normalleştirme, genellikle makine öğrenmesi için veri hazırlamanın bir parçası olarak uygulanan bir tekniktir [59]. Normalleştirme amacını, değer aralıklarındaki farklılıkları bozmadan veya bilgi kaybetmeden veri

kümesindeki sayısal sütunların değerlerini ortak bir ölçek kullanacak şekilde değiştirmektedir [60, 61]. Bazı algoritmaların verileri doğru modellemesi için normalleştirme de gereklidir. Normalleştirme, kaynak verilerdeki genel dağılımı ve oranları koruyan yeni değerler oluştururken, değerleri modelde kullanılan tüm sayısal sütunlara uygulanan bir ölçek içinde tutarak bu sorunları önler [62]. Bu çalışmada veriler Min-Max yöntemi kullanılarak orijinal veriler üzerinde doğrusal bir dönüşüm gerçekleştirilmiştir. Her özellik için o özelliğin minimum değeri 0'a, maksimum değeri 1'e ve diğer tüm değerler 0 ile 1 arasında ondalık sayıya dönüştürülür. Normalleştirme de orijinal veri değerleri arasındaki ilişkileri korunur [63, 64]. Min-Max normalizasyon formülü:


$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (5)$$

Burada  $x'$  normalize edilmiş veriyi,  $x_i$  girdi değerini,  $x_{min}$  veri kümesindeki en küçük veriyi,  $x_{max}$  veri kümesindeki en büyük veriyi göstermektedir.

Çalışmanın bir diğer aşaması verilerin eğitim ve test olmak üzere ikiye bölünmesidir [65]. Eğitim aşamasında seçilen makine öğrenmesi için ideal parametrelerin belirlendiği ve hatanın minimum düzeye indirildiği aşamadır. Test aşamasında ise eğitim aşamasında belirlenen parametrelerin veri setinde daha önce kullanılmamış veriler üzerinde test edildiği ve istatistiksel olarak değerlendirildiği aşamadır [66]. Eğitim ve test verilerinin ayrılması için kesin bir kural olmamakla birlikte çalışmanın niteliğine ve veri sayısına göre veri kümesinin %60'ı ile %80'i arasında bir oran eğitim verisi olarak ayrılmaktadır. Bu çalışmada veri kümesinin %70 eğitim ve %30 test verisi olarak yani 139 veri eğitim, 59 veri test için ayrılmıştır. Verilerin eğitim ve test olmak üzere ikiye ayrılmasında farklı yöntemler kullanılmaktadır. Veri kümesinin en üstten alma, doğrusal örnekleme ve rastgele veri alma kullanılabilir veri seçim yöntemlerinden bazılarıdır. Çalışmada iki modelin sonuçlarını karşılaştırabilmek için veri seçiminde doğrusal örnekleme yöntemi tercih edilmiştir.

Çalışmada üç farklı makine öğrenmesi tekniği kullanılmıştır. Bunlar yapay sinir ağları, çoklu doğrusal regresyon ve karar ağaçları regresyonudur.

Yapay sinir ağları yöntemi için sekiz giriş, bir çıkış nöronundan oluşan geri beslemeli bir model geliştirilmiştir. İdeal gizli katman ve her gizli katmandaki nöron sayısına modelde yapılan çok sayıda test sonucu karar verilmiştir. Çalışmada en başarılı sonucu verdiği için üç gizli katman ve her gizli katmanda üç nöron olan yapının daha başarılı sonuçlar ürettiği görülmüştür. Geliştirilen modelin yapısı Şekil 3'te görülmektedir.



Şekil 3. Tasarlanan ANN modeli (ANN model)

Aktivasyon fonksiyonu için çeşitli fonksiyonların denenmesinin ardından sigmoid fonksiyonun geliştirilen model ve veri kümesi için en iyi sonucu verdiği görülmüştür. Çalışmada hata değerlerini minimize edilmesi için geri yayılım sinir ağı tercih edilmiştir. Modelde en iyi sonucu almak için 1000 iterasyon gerçekleştirilmiştir.

Çoklu doğrusal regresyonda değişkenlerin sisteme olan etkilerini ölçebilmek için öncelikle bir önem değeri (significance value) belirlendi. En yüksek p-value değerine (probability value) sahip değişken belirlenip ve şayet  $P > SL$  ise değişken sistemden kaldırıldı. Model yeniden oluşturulup ardından bu adım tekrarlandı. Tüm değişkenler için  $P < SL$  olduğunda ise eleme sonlandırıldı. Tasarlanan modelde p değerleri için 0,05'in altında kalan bağımsız değerler olmadığı için modelin anlamlı olduğu görülmüştür.

Çalışmada kullanılan bir diğer makine öğrenmesi yöntemi olan karar ağacı regresyonu yönteminde bölmenin hesaplandığı kalite ölçüsü olarak "Gini Index" kullanılmıştır. Her düğümde en az üç minimum kayıt sayısını bulunmaktadır. Kayıt sayısı bu sayıdan küçük veya ona eşitse, ağaç daha fazla yetiştirilmez. Ağaçta görünüm için 10.000 kayıt saklanmaktadır. Çalışmada 8 tane iş parçacığından ve dolayısıyla işlemciden veya çekirdekten yararlanılmıştır. Bu da çalışmanın performansının artmasını sağlamıştır.

ANN, MLR ve DT yöntemlerinin karşılaştırılması Tablo 2'de gösterilmiştir.

Tablo 2. Modellerin başarı ve hata karşılaştırılması (Success and error comparison of the models)

	Yapay sinir ağları	Çoklu doğrusal regresyon	Karar ağaçları regresyonu
R <sup>2</sup>	0,946	0,641	0,822
MSE	0,001	0,055	0,041
MAPE	0,130	0,654	0,295

Verilerin doğrusal bir eğriye ne kadar iyi uyduğunu gösteren R<sup>2</sup> değerinin 1 olması, test verilerinin doğrusal bir eğri sağlandığını göstermektedir. Çalışmanın sonucunda R<sup>2</sup> değeri ANN için %94,6, MLR için %64,1, DT için %82,2 olmuştur ve ideal değere çok yakın olduğu görülmüştür. Makine öğrenmesi modellerinin performansını hata değerine göre ölçen MSE değerinin sıfıra yakın olması modellerin daha iyi ve daha az hata gösterdiğini ifade etmektedir. Bu yüzden çalışmada kullanılan modeller için MSE değerinin sıfır değerine yakın olması istenmektedir. Çalışmada MSE değerinin ANN için 0.001, MLR için 0.055 ve DT için 0.041 olduğu ve ideal değere yakın olduğu görülmüştür. MAPE değerinin yüzde 10 değerinin altında olan modeller çok iyi kabul edilmektedir [67]. Çalışmada ANN için 1,30, MLR için 6.54 ve DT için 2.95 olduğu görülmüştür. Her üç model içinde MAPE değerinin çok iyi olduğu kabul edilmektedir. Hata ve başarı değerlerine bakıldığında en başarılı ve en az hataya sahip modellerin sırasıyla ANN, DT ve MLR olduğu görülmüştür.

## 5. Sonuçlar (Conclusion)

Bu çalışmada Ocak 2006 Haziran 2022 tarihleri arasında veriler ile oluşturulan modelde makine öğrenmesi yöntemleri kullanılarak Türkiye'de satılan hafif ticari araç satış miktarı tahmini gerçekleştirilmiştir. Çalışma, otomotiv sektörünün bir alt kolu olan hafif ticari araçların satış adedi tahmini üzerine yapılması literatürdeki özellikle Türkiye'deki çalışmalardan farklılaşmaktadır. Hafif ticari araçların odaklanmasındaki temel motivasyon bu grup araçların özellikle binek otomobillerden farklı olarak sadece bireysel kullanım değil ülkenin ticari, üretim ve hizmet olmak üzere üç temel sektörde ticari bir taşıt vasfı ile kullanılmasıdır. Bu üç temel sektördeki dinamizm ülkelerin özellikle ekonomi üzerinde olumlu yönde bir devinim sağlarken daralmada ekonomilerdeki yavaşlama hakkında önemli göstergeler vermektedir. Bu nedenle çalışmada özellikle Türkiye gibi gelişmekte olan ülkelerde yapılacak araştırmalar açısından bir katkı sağlayacağı düşünülmektedir. Bunun yanında hafif ticari araç sektörü başta bu araçların satışı başta olmak üzere bankacılık, sigortacılık, bakım-onarım ve kiralama hizmetleri gibi birçok sektör ile etkileşim içindedir. Bu nedenle hafif ticari araçların satışını tahmin etmek ilgili sektörlerdeki hedef, kaynak planlaması ve bütçeleme faaliyetleri için önem arz etmektedir. Çalışmada en büyük sınırlama veri aralığı ile ilgilidir. Her ne kadar Türkiye'deki benzer otomotiv sektörü satış tahmini çalışmalara göre daha uzun bir veri aralığı kullanılsa da özellikle 1990'lardan başlayarak o yıllarda Türkiye'de yaşanan ekonomik krizlerinde etkilerini makine öğrenmesi tekniklerinde kullanmak modelin başarısının ölçülmesi noktasında daha yararlı olacağı muhakkaktır. Ancak sunulan verilerin çoğu ortak başlangıç noktası Ocak 2006 olduğu için zaman serisi buradan başlatılmıştır.

Bu araçlarının satışını gerçekleştiren otomotiv satış bayileri bu modeli kullanılarak otomotiv fabrikalarından yıllık alım stoklarını belirleyebileceklerdir. Böylelikle bu taşıtları alırken oluşacak sermaye maliyetinden kaçınarak aynı zamanda stok maliyetlerini düşürebilirler. İkinci olarak bankacılık, sigortacılık, bakım onarım, filo hizmetleri veren işletmeler de oluşacak hafif satış miktarı tahminlerine göre satış bütçelerini hazırlayabileceklerdir. Ayrıca özellikle bu tip araçlara bakım onarım hizmetleri veren şirketler yedek parça ihtiyaçlarını bu tahminlere göre şekil verebileceklerdir. Son olarak çalışmada değinildiği gibi hafif ticari araçların satışı ekonominin genel görünümü hakkında bilgiler de verebilir. Ekonominin konjonktürel olarak yükselme ve zirve dönemlerinde ekonominin büyümesi ile bu araçların satışı artacaktır. Bu yüzden bu satışların tahmini uzun dönemli ekonomik kararların alınmasında kullanılabileceği düşünülmektedir.

Çalışmanın modeli tasarlanırken hem ekonominin genel görünümü hem de hafif ticari araç satışlarını

etkileyeceği düşünülen tüketici fiyat endeksi (TÜFE), sanayi güven endeksi, imalat sanayi kapasite kullanım oranı, sanayi güven endeksi, taşıt kredi faiz oranı, trafikten silinen hafif ticari araç sayısı, ABD dolar TL ve Euro TL kuru bağımsız değişken olarak seçilmiştir. Çalışmada makine öğrenmesi tekniklerinden ANN, MLR ve DT yöntemleri kullanılmıştır. Elde edilen sonuçlar  $R^2$  değeri ANN için %94,6, MLR için %64,1, DT için %82,2 olmuştur ve ideal değere çok yakın olduğu görülmüştür. Bu sonuçlar ANN'nin diğer iki makine öğrenmesi yöntemine göre daha başarılı tahmin gücüne sahip olacağını göstermektedir. Çalışmanın sonuçları Karatlı vd. (2012), Akyurt (2015), Kuvvetli vd. (2015)'nin Türkiye'de otomobil satış tahmini üzerine yaptıkları benzer çalışmalar ile örtüşmektedir. Bu çalışmalarda da ANN başarılı bir makine öğrenmesi tekniği olarak tespit edilmiştir. Ayrıca Vahabi vd. (2016)'da İran'da bir otomobil markası üzerine yapmış olduğu çalışma da benzer şekilde ANN'yı başarılı bir makine öğrenmesi olarak göstermiştir.

Çalışmadaki tasarlanan modelin değişkenlerine ait verilerin ulaşılabilirliği ve uygulanan makine öğrenmesi teknikleri bundan sonraki akademik araştırmalar için karşılaştırılabilir bir önerinin yanında hafif ticari araç satışı yapan bayiler ve sektörün paydaş işletmeleri için de geleceğin planlaması noktasında örnek teşkil etmektedir. Problem Sandgren tarafından araştırıldı. Deb ve Goyal, problemi genetik algoritmaya dayalı akıllı bir yöntem olan genetik uyarlamalı aramaya (GeneAS) uyguladı. Lampinen ve Zelinka, problemi diferansiyel evrim (DE) yöntemiyle çözmeye çalışmışlardır. Lampinen ve arkadaşları, problemi parçacık sürüsü algoritmasıyla araştırdı.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

- [1] A. G. Ö. Görener, "Türk otomotiv sektörünün ülke ekonomisine katkıları ve geleceğe yönelik sektörel beklentiler," *Yaşar Üniversitesi E-Dergisi*, vol. 3, no. 10, pp. 1213-1232, 2008.
- [2] S. Yılmaz, K. Taştan, N. Ecek, ve E. Çınar, "Otomotiv sektörünün dünyadaki ve Türkiye'deki değişimi," *Ordu Üniversitesi Sosyal Bilimler Enstitüsü Sosyal Bilimler Araştırmaları Dergisi*, vol. 7, no. 3, pp. 685-695, 2017.
- [3] O. Başkol, "Türk otomotiv sektörünün uluslararası rekabet gücü (1996-2010)," *Paradoks Ekonomi Sosyoloji ve Politika Dergisi*, vol. 7, no. 2, pp. 63-78, 2011.
- [4] T.C. Sanayi ve Teknoloji Bakanlığı, "Otomotiv sektör raporu," [Online]. Available: <https://www.sanayi.gov.tr/assets/pdf/plan-program/OtomotivSektorRaporu2020.pdf> [Accessed: December. 12, 2023].
- [5] M. H. Eken ve M. Çiçek, "Türkiye'de otomotiv sektöründeki ürünlerin kredilerle finansmanının satışlara etkisi," *Maliye ve Finans Yazıları*, vol. 1, no. 84, pp. 61-77, 2009.
- [6] S. Kaynak ve Y. O. Ari, "Türk otomotiv sektöründe yoğunlaşma: binek ve hafif ticari araçlar üzerine bir uygulama," *Ekonomik Yaklaşım*, vol. 22, no. 80, pp. 39-58, 2011.
- [7] T. Efendigil ve Ö. E. Eminler, "Havacılık sektöründe talep tahminin önemi: Yolcu talebi üzerine bir tahmin modeli," *Yaşar Üniversitesi E-Dergisi*, vol. 12, pp. 14-30, 2017.
- [8] M. Soysal ve M. Ömürganülşen, "Türk turizm sektöründe talep tahmini üzerine bir uygulama," *Anatolia: Turizm Araştırmaları Dergisi*, vol. 21, no. 1, pp. 128-136, 2010.
- [9] M. Karaatlı, Ö. C. Helvacıoğlu, N. Ömürbek ve G. Tokgöz, "Yapay sinir ağları yöntemi ile otomobil satış tahmini," *Uluslararası Yönetim İktisat ve İşletme Dergisi*, vol. 8, no. 17, pp. 87-100, 2012. Doi: 10.11122/ijmeb.2012.8.17.290
- [10] İ. Z. Akyurt, "Talep tahmininin yapay sinir ağlarıyla modellenmesi: Yerli otomobil örneği," *Ekonometri ve İstatistik Dergisi*, no. 23, pp. 147-157, 2015.
- [11] C. E. Alper ve A. Mumcu-Serdar, "Türkiye'de otomobil talebinin tahmini," *Ekonomi ve Ekonometri Merkezi, Boğaziçi Üniversitesi*, 2000.
- [12] F. K. Wang, K. K. Chang, and C. W. Tzeng, "Using adaptive network-based fuzzy inference system to forecast automobile sales," *Expert Systems with Applications*, vol. 38, no. 8, pp. 10587-10593, 2011. Doi: 10.1016/j.eswa.2011.02.100
- [13] Y. Kuvvetli, C. Dağsuyu, ve M. Oturakci, "Türkiye'deki araç satışları için ekonomik ve çevresel faktörleri göz önüne alan yapay sinir ağı tabanlı bir tahmin yaklaşımı," *Endüstri Mühendisliği*, vol. 26, no. 3, pp. 23-31, 2015.
- [14] P. F. Pai and C. H. Liu, "Predicting vehicle sales by sentiment analysis of Twitter data and stock market values," *IEEE Access*, vol. 6, pp. 57655-57662, 2018. Doi: 10.1109/ACCESS.2018.2873730

- [15] S. Arslankaya and V. Öz, "Time series analysis of sales quantity in an automotive company and estimation by artificial neural networks," *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, vol. 22, no. 5, pp. 1482-1492, 2018. Doi: 10.16984/saufenbilder.456518
- [16] S. Haykin, "Neural networks and learning machines", 3/E. Pearson Education India, 2009.
- [17] M. Kayakuş and K. K. Çevik, "Estimation the number of visitors of e-commerce website by artificial neural networks during covid19 in turkey," *Electronic Turkish Studies*, vol. 15, no. 4, pp. 615-631, 2020.
- [18] F. Recknagel, M. French, P. Harkonen, and K.-I. Yabunaka, "Artificial neural network approach for modelling and prediction of algal blooms," *Ecological Modelling*, vol. 96, no. 1-3, pp. 11-28, 1997. Doi: 10.1016/S0304-3800(96)00049-X
- [19] B. Karlik and A. V. Olgac, "Performance analysis of various activation functions in generalized MLP architectures of neural networks," *International Journal of Artificial Intelligence and Expert Systems*, vol. 1, no. 4, pp. 111-122, 2011.
- [20] G. Bandyopadhyay and S. Chattopadhyay, "Single hidden layer artificial neural network models versus multiple linear regression model in forecasting the time series of total ozone," *International Journal of Environmental Science & Technology*, vol. 4, pp. 141-149, 2007. Doi: 10.1007/BF03325972
- [21] S. B. Maind and P. Wankar, "Research paper on basic of artificial neural network," *International Journal on Recent and Innovation Trends in Computing and Communication*, vol. 2, no. 1, pp. 96-100, 2014.
- [22] S. Herzog, C. Tetzlaff, and F. Wörgötter, "Evolving artificial neural networks with feedback," *Neural Networks*, vol. 123, pp. 153-162, 2020. Doi: 10.1016/j.neunet.2019.12.004
- [23] C. Vidal et al., "Hybrid energy storage system state-of-charge estimation using artificial neural network for micro-hybrid applications," *IEEE Transportation Electrification Conference and Expo (ITEC)*, 2018: IEEE, pp. 1075-1081. Doi: 10.1109/ITEC.2018.8450251
- [24] S. Cavaliere, P. Maccarrone, and R. Pinto, "Parametric vs. neural network models for the estimation of production costs: A case study in the automotive industry," *International Journal of Production Economics*, vol. 91, no. 2, pp. 165-177, 2004. Doi: 10.1016/j.ijpe.2003.08.005
- [25] L. E. Eberly, "Multiple linear regression," *Topics in Biostatistics*, pp. 165-187, 2007. Doi: 10.1007/978-1-59745-530-5\_9
- [26] M. Kayakuş, D. Erdoğan, and M. Terzioğlu, "Predicting the share of tourism revenues in total exports," *Alphanumeric Journal*, vol. 11, no. 1, pp. 17-30, 2023. Doi: 10.17093/alphanumeric.1212189
- [27] M. Tranmer and M. Elliot, "Multiple linear regression," *The Cathie Marsh Centre for Census and Survey Research (CCSR)*, vol. 5, no. 5, pp. 1-5, 2008.
- [28] S. Kılıç, "Doğrusal regresyon analizi," *Journal of Mood Disorders*, vol. 3, no. 2, pp. 90-92, 2013.
- [29] M. Kayakuş, B. Tutcu, M. Terzioğlu, H. Talaş, and G. F. Ünal Uyar, "ROA and ROE forecasting in iron and steel industry using machine learning techniques for sustainable profitability," *Sustainability*, vol. 15, no. 9, p. 7389, 2023. Doi: 10.3390/su15097389
- [30] X. Yan and X. Su, "Linear regression analysis: theory and computing". *World scientific*, 2009. Doi: 10.1142/6986
- [31] W. Y. Loh, "Classification and regression trees," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 1, no. 1, pp. 14-23, 2011. Doi: 10.1002/widm.8
- [32] M. Kayakuş and F. Y. Açıkgöz, "Classification of News Texts by Categories Using Machine Learning Methods," *Alphanumeric Journal*, vol. 10, no. 2, pp. 155-166, 2022. Doi: 10.17093/alphanumeric.1149753
- [33] P. Perner, U. Zscherpel, and C. Jacobsen, "A comparison between neural networks and decision trees based on data from industrial radiographic testing," *Pattern Recognition Letters*, vol. 22, no. 1, pp. 47-54, 2001. Doi: 10.1016/S0167-8655(00)00098-2
- [34] M. Kayakuş and F. Yiğit Açıkgöz, "Twitter'da makine öğrenmesi yöntemleriyle sahte haber tespiti," *Abant Sosyal Bilimler Dergisi*, vol. 23, no. 2, pp. 1017-1027, 2023. Doi: 10.11616/asbi.1266179
- [35] G. K. Tso and K. K. Yau, "Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks," *Energy*, vol. 32, no. 9, pp. 1761-1768, 2007. Doi: 10.1016/j.energy.2006.11.010
- [36] M. Xu, P. Watanachaturaporn, P. K. Varshney, and M. K. Arora, "Decision tree regression for soft classification of remote sensing data," *Remote Sensing of Environment*, vol. 97, no. 3, pp. 322-336, 2005. Doi: 10.1016/j.rse.2005.05.008
- [37] L. Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone, "Classification and regression trees", Routledge, 2017. Doi: 10.1201/9781315139470
- [38] G. Hughes, "On the mean accuracy of statistical pattern recognizers," *IEEE Transactions on Information Theory*, vol. 14, no. 1, pp. 55-63, 1968. Doi: 10.1109/TIT.1968.1054102
- [39] C. Kingsford and S. L. Salzberg, "What are decision trees?," *Nature Biotechnology*, vol. 26, no. 9, pp. 1011-1013, 2008. Doi: 10.1038/nbt0908-1011

- [40] J. Elith, J. R. Leathwick, and T. Hastie, "A working guide to boosted regression trees," *Journal of Animal Ecology*, vol. 77, no. 4, pp. 802-813, 2008. Doi: 10.1111/j.1365-2656.2008.01390.x
- [41] W.-Y. Loh and Y.-S. Shih, "Split selection methods for classification trees," *Statistica Sinica*, pp. 815-840, 1997.
- [42] E. Pekel, "Estimation of soil moisture using decision tree regression," *Theoretical and Applied Climatology*, vol. 139, no. 3, pp. 1111-1119, 2020. Doi: 10.1007/s00704-019-03048-8
- [43] B. M. Moret, "Decision trees and diagrams," *ACM Computing Surveys (CSUR)*, vol. 14, no. 4, pp. 593-623, 1982. Doi: 10.1145/356893.356898
- [44] J. R. Quinlan, *C4.5: Programs for machine learning*. Elsevier, 2014.
- [45] A. Günel, "Regresyon denkleminin başarısını ölçmede kullanılan belirleme katsayısı ve kritiği," *Doğuş Üniversitesi Dergisi*, vol. 4, no. 2, pp. 133-140, 2003. Doi: 10.31671/dogus.2019.313
- [46] D. J. Ozer, "Correlation and the coefficient of determination," *Psychological Nulletin*, vol. 97, no. 2, p. 307, 1985. Doi: 10.1037/0033-2909.97.2.307
- [47] N. J. Nagelkerke, "A note on a general definition of the coefficient of determination," *Biometrika*, vol. 78, no. 3, pp. 691-692, 1991. Doi: 10.1093/biomet/78.3.691
- [48] O. Renaud and M.-P. Victoria-Feser, "A robust coefficient of determination for regression," *Journal of Statistical Planning and Inference*, vol. 140, no. 7, pp. 1852-1862, 2010. Doi: 10.1016/j.jspi.2010.01.008
- [49] C. J. Willmott and K. Matsuura, "Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance," *Climate Research*, vol. 30, no. 1, pp. 79-82, 2005. Doi: 10.3354/cr030079
- [50] T. Chai and R. R. Draxler, "Root mean square error (RMSE) or mean absolute error (MAE)," *Geoscientific Model Development Discussions*, vol. 7, no. 1, pp. 1525-1534, 2014. Doi: 10.5194/gmdd-7-1525-2014
- [51] M. Şahan, "Yapay sinir ağları ve Angström-Prescott denklemleri kullanılarak Gaziantep, Antakya ve Kahramanmaraş için global güneş radyasyonu tahmini," *Süleyman Demirel Üniversitesi Fen Edebiyat Fakültesi Fen Dergisi*, vol. 16, no. 2, pp. 368-384, 2021. Doi: 10.29233/sdufeffd.953182
- [52] M. Kayakuş, "Yazılım çaba tahmininde yapay sinir ağları için optimum yapının belirlenmesi," *Avrupa Bilim ve Teknoloji Dergisi*, no. 22, pp. 43-48, 2021. Doi: 10.31590/ejosat.847712
- [53] A. De Myttenaere, B. Golden, B. Le Grand, and F. Rossi, "Mean absolute percentage error for regression models," *Neurocomputing*, vol. 192, pp. 38-48, 2016. Doi: 10.1016/j.neucom.2015.12.114
- [54] F. Liantoni and A. Agusti, "Forecasting bitcoin using double exponential smoothing method based on mean absolute percentage error," *JOIV: International Journal on Informatics Visualization*, vol. 4, no. 2, pp. 91-95, 2020. Doi: 10.30630/joiv.4.2.335
- [55] J. McKenzie, "Mean absolute percentage error and bias in economic forecasting," *Economics Letters*, vol. 113, no. 3, pp. 259-262, 2011. Doi: 10.1016/j.econlet.2011.08.010
- [56] E. Karadağ, "Eğitim bilimleri doktora tezlerinde kullanılan araştırma modelleri: Nitelik düzeyleri ve analitik hata tipleri," *Kuram ve Uygulamada Eğitim Yönetimi*, vol. 1, no. 1, pp. 49-71, 2010.
- [57] A. Oğuzlar, "Veri ön işleme," *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, no. 21, pp. 67-76, 2003.
- [58] F. Arslan ve H. T. Kahraman, "Yapay zekâ tabanlı büyük veri yönetim aracı," *Journal of Investigations on Engineering and Technology*, vol. 2, no. 1, pp. 8-21, 2019.
- [59] P. J. M. Ali, R. H. Faraj, E. Koya, P. J. M. Ali, and R. H. Faraj, "Data normalization and standardization: a technical report," *Mach Learn Tech Rep*, vol. 1, no. 1, pp. 1-6, 2014.
- [60] Y. Gültepe, "Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme," *Avrupa Bilim ve Teknoloji Dergisi*, no. 16, pp. 8-15, 2019. Doi: 10.31590/ejosat.530347
- [61] S. Yavuz ve M. Deveci, "İstatistiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi," *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, no. 40, pp. 167-187, 2012.
- [62] D. Singh and B. Singh, "Investigating the impact of data normalization on classification performance," *Applied Soft Computing*, vol. 97, p. 105524, 2020. Doi: 10.1016/j.asoc.2019.105524
- [63] L. Munkhdalai, T. Munkhdalai, K. H. Park, H. G. Lee, M. Li, and K. H. Ryu, "Mixture of activation functions with extended min-max normalization for forex market prediction," *IEEE Access*, vol. 7, pp. 183680-183691, 2019. Doi: 10.1109/ACCESS.2019.2959789
- [64] D. Borkin, A. Némethová, G. Michalčonok, and K. Maiorov, "Impact of data normalization on classification model accuracy," *Research Papers Faculty of Materials Science and Technology Slovak University of Technology*, vol. 27, no. 45, pp. 79-84, 2019. Doi:

10.2478/rput-2019-0029

[65] M. F. Keskenler, D. Deniz, ve T. Aydın, "Yapay zekâ destekli ÇOKS yöntemi ile kredi kartı sahtekarlığının tespiti," *El-Cezeri*, vol. 8, no. 2, pp. 1007-1023, 2021. Doi: 10.31202/ecjse.908260

[66] M. K. Uçar, M. Nour, H. Sindi, ve K. Polat, "The effect of training and testing process on machine learning in biomedical datasets," *Mathematical Problems in Engineering*, vol. 2020, 2020. Doi: 10.1155/2020/2836236

[67] F. Aslay ve Ö. Üstün, "Meteorolojik parametreler kullanılarak yapay sinir ağları ile toprak sıcaklığının tahmini," *Politeknik Dergisi*, vol. 16, no. 4, pp. 139-145, 2013.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAE 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## Evaluation of Tree Diameter and Height Measurements in UAV Data through the Integration of Remote Sensing and Machine Learning Methods

Hakan Durgun<sup>a</sup>, Ebru Yılmaz İnce<sup>b</sup>, Murat İnce, H. Oğuz Çoban<sup>d</sup>, Mehmet Eker<sup>e</sup>

Submitted: 18.11.2023 Revised: 15.12.2023 Accepted: 18.12.2023 doi:10.30855/gmbd.0705S12

### ABSTRACT

**Keywords:** Machine learning, unmanned aerial vehicle, remote sensing, point cloud

This study evaluates the effects of various ground sampling distances on the diameter and height measurements of brutian pine trees in point cloud data from unmanned aerial vehicle photographs. The study is conducted within the Çandır Forest Management Directorate of the Isparta Regional Directorate of Forestry. The results serve as independent variables in machine learning methods to predict field-measured diameter and height values. Nine distinct machine learning techniques were employed, including AdaBoost Regression, Artificial Neural Networks, Deep Neural Networks, Decision Tree Regression, Gradient Boosting Regression, Linear Regression, Random Forest Regression, Support Vector Regression, and eXtreme Gradient Boosting Regression. The results reveal that predictions based on data with a low ground sampling distance exhibit the lowest correlation values for both diameter and height, while predictions made using data with a high ground sampling distance had the lowest correlation values. Deep Neural Network achieved the highest success rate for diameter estimation, while Decision Tree Regression exhibited the lowest success.

<sup>a,\*</sup> Isparta University of Applied Sciences, Faculty of Forestry, Dept. of Forest Engineering, Forest Construction Geodesy and Photogrammetry Isparta/Türkiye, Orcid: 0000-0002-2220-4472 [hakandurgun@isparta.edu.tr](mailto:hakandurgun@isparta.edu.tr)

<sup>b</sup> Isparta University of Applied Sciences, Vocational School of Technical Sciences Department of Computer Technologies, Computer Programming Isparta/Türkiye, Orcid: 0000-0001-9462-0363,

<sup>c</sup> Isparta University of Applied Sciences, Vocational School of Technical Sciences, Department of Computer Technologies, Computer Programming Isparta/Türkiye, Orcid: 0000-0001-5566-5008

<sup>d</sup> Isparta University of Applied Sciences, Faculty of Forestry, Department of Forest Engineering, Forest Construction, Geodesy and Photogrammetry, Isparta/Türkiye, Orcid: 0000-0002-4037-4811,

<sup>e</sup> Isparta University of Applied Sciences, Faculty of Forestry, Department of Forest Engineering, Forest Construction, Geodesy and Photogrammetry, Isparta/Türkiye, Orcid: 0000-0002-1817-3706

\*Corresponding author: [hakandurgun@isparta.edu.tr](mailto:hakandurgun@isparta.edu.tr)

**Anahtar Kelimeler:** Makine öğrenmesi, insansız hava aracı, uzaktan algılama, nokta bulutu

## İHA ile Ağaç Çapı ve Yüksekliği Ölçümlerinin Uzaktan Algılama ve Makine Öğrenmesi Yöntemleriyle Bütünleştirilerek Değerlendirilmesi

### ÖZ

Bu çalışmada insansız hava aracı fotoğraflarından elde edilen nokta bulutu verilerinde farklı yerden örnekleme mesafelerinin kızılçam ağaçlarının çap ve yükseklik ölçümlerine etkisi değerlendirilmektedir. Çalışma Isparta Orman Bölge Müdürlüğü'ne bağlı Çandır Orman İşletme Müdürlüğü bünyesinde yer almaktadır. Sonuçlar, sahada ölçülen çap ve yükseklik değerlerini tahmin etmek için makine öğrenimi yöntemlerinde bağımsız değişkenler olarak hizmet etmektedir. Araştırmada, AdaBoost Regresyon, Yapay Sinir Ağları, Derin Sinir Ağları, Karar Ağacı Regresyonu, Gradient Boosting Regresyon, Doğrusal Regresyon, Rastgele Orman Regresyon, Destek Vektör Regresyonu ve eXtreme Gradient Boosting Regresyon dahil olmak üzere dokuz farklı makine öğrenme tekniği kullanıldı. Sonuçlar, düşük yerden örnekleme mesafesine sahip veriler kullanılarak yapılan tahminlerin çap ve yükseklik için en düşük korelasyon değerlerine sahip olduğunu, yüksek yerden örnekleme mesafesine sahip veriler kullanılarak yapılan tahminlerin ise en düşük korelasyon değerlerine sahip olduğunu göstermektedir. Çap tahmininde en yüksek başarı oranını Derin Sinir Ağı elde ederken, Karar Ağacı Regresyonu en düşük başarıyı elde etmiştir.



## 1. Introduction

Numerous scientific disciplines are actively engaged in extensive research on the vastbroad topic of remote sensing investigations. Data from various airborne sources, including satellite imagery and aerial photography, can be used in a variety of forestry applications after photogrammetric processing [1, 2]. Since remote sensing data can be used with Geographic Information Systems (GIS) [3], this integration has enabled remote sensing data to become a highly effective source of information [4]. Unmanned aerial vehicles (UAVs) are increasingly popular for remote sensing. They are cheaper and easier to operate than other aerial vehicles, allowing for fast and convenient solutions to emerging problems. Data collected by UAVs is frequently used for various purposes and inferences, particularly in forestry research [5]. This data can serve as a scientific basis for forest management and planning and may be useful in solving the forestry issues [6].

The amount of data has grown more than ever in recent years due to the widespread use of technology, and this growth is still going strong [7]. Furthermore, the development of computer technology has led to a significant increase in computational capacity, with data science and machine learning (ML: Machine Learning) emerging as two of the most researched topics. In order to get results quickly, machine learning—which is used to extract information from data—is frequently employed, particularly when working with large amounts of data [8]. UAV data is made into a more potent and valuable source of information when it is evaluated using ML [9]. ML techniques have been used successfully in a variety of forestry applications [10, 11, 12,13] and are recognized as a method that offers solutions to many engineering problems [14, 15]. In these studies, ML methods build prediction models using an UAV dataset to calculate the values of objects or situations investigated in forestry studies. The input for machine learning involves data acquired from the UAV, while the output comprises a predictive model that characterizes the forest ecosystem [16]. In an investigation on the application of ML in forestry, 274 studies were carried out in total between 2004 and 2023. 135 (58%) of the 274 research fell under the categories of modeling, remote sensing, and forest inventory [17]. This indicates that most researchers favor the combination of machine learning and remote sensing.

For research on forest inventory and planning, precise measurement of tree stem volumes is essential in forest ecosystems. It is important to take careful and accurate measurements, as data on tree trunk diameter and height are crucial for determining trunk volumes [18]. The diameter ( $d_{1.3}$ ) and height of cut brutian pine (*Pinus brutia* Ten.) trees were measured in this study using point clouds (colored points with x, y, and z coordinate information) from data collected using different ground sampling distance (GSD) values. The ML utilized the results of diameter and height measurements from photographs and environmental variables as inputs, resulting in estimated diameter and height results for each tree based on ground measurements. Therefore, the study evaluated the effect of different GSDs on measurements of tree diameter and height using point cloud data acquired by a field-based UAV at different flight altitudes using ML. Additionally, the study also compared the performance of different ML methods employed. The study aimed to test the performance of different machine learning techniques. Various machine learning techniques, including Ada Boost Regression (ABR), Artificial Neural Network (ANN), Deep Neural Network (DNN), Decision Tree Regression (DTR), Gradient Boosting Regression (GBR), Linear Regression (LR), Random Forest Regression (RFR), Support Vector Regression (SVR), and eXtreme Gradient Boosting Regression (XGBR) were used, and the same test trees were used in all calculations to ensure an unbiased comparison.

## 2. Material and Method

### 2.1. Material

The research is conducted in the Çandır Forest Management Directorate of the Isparta Regional Directorate of Forestry (Fig. 1). With a surface size of 10348.4 ha, the Çandır Forest Management Directorate has an elevation range of 248 to 1877 m [19]. Brutian pine is the most prevalent tree species with 91.8% of the forest area under the management of the Çandır Forest Management Directorate [20].

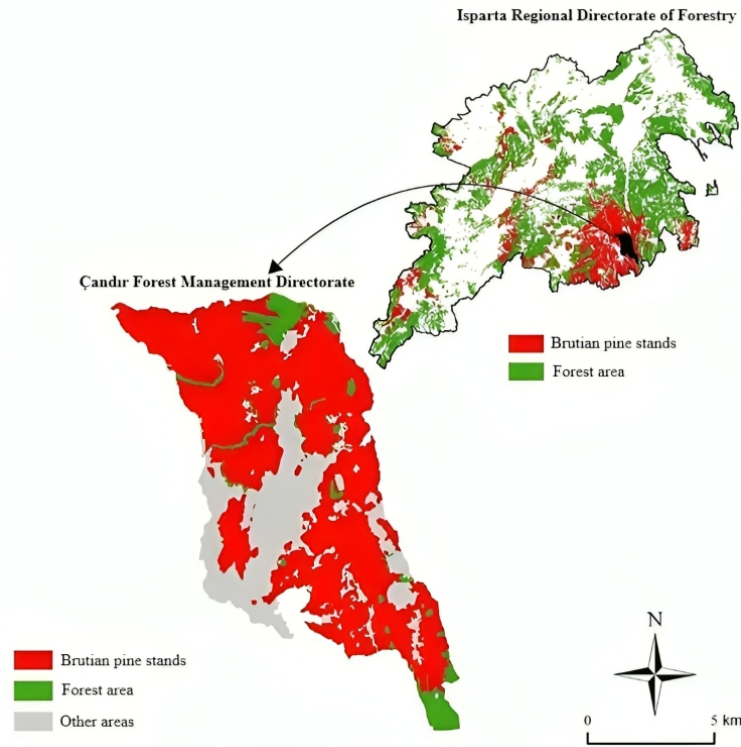


Figure 1. Workspace location

Two distinct research areas in the Çandır Forest Management Directorate were found to include brutian pine trees with various trunk diameters and heights (Fig. 2). Brutian pine trees with trunk diameters between 8 and 36 cm can be found in the first study area (Stand-C), while brutian pine trees with chest diameters between 36 and 52 cm can be found in the second study area (Stand-D). More than 70% of the soil is shaded by trees in both sites. The Stand-C region is 3.2 ha in size and has an elevation range of 355–420 m, whereas the Stand-D area is 0.76 ha in size and has an elevation range of 322–371 m.




Figure 2. Stand-C and Stand-D areas

The study made use of DJI's Mavic Air model UAV, which was released in 2018. In addition to its 430 gram weight, 21 minute flight time and link to GPS, the UAV offers a CMOS 1/2.3-inch sensor, 12 MP resolution, 2.8 aperture and 85° field of view [21]. Ground control points (GCP) of 50x50 cm were set up in the field and measurements were taken using Global Positioning System (GPS) compatible with TUSAGA-Active (Turkey National Fixed GPS Network-Active), as it is well known that the use of GCPs is crucial for increasing positional accuracy in photogrammetric studies [22, 23, 24]. These measurements were conducted using a South/Galaxy G6 precision GPS [25]. In the study, ArcGIS software [26] was favored for spatial analysis and

map creation, whereas Microsoft Office software [27] was preferred for the creation of the data collection. Pix4d "Mapper" photogrammetry software was used to process the aerial photographs taken by the UAV, increase the spatial accuracy by marking the GCPs on the UAV photographs and diameter-height measurements of the cut trees [28]. Pix4d "Capture" software was used to fly the UAV in accordance with the photogrammetric acquisition conditions.

## 2.2. Method

### 2.2.1. Field research

The chopped brutian pine trees diameter and height measurements were catalogued for the field research. Except for trees that had fallen on top of one another in the study regions or where measurements could not be made, trees of various diameters were chosen at random. The bottom of the tree trunks ( $d_0$ ) were secured with A4 papers that had numbers inscribed on them in a size that could be seen in the UAV photos when the trees were numbered. In order to make it easier to measure the diameter and height of these trees in UAV data, 5x5 cm marker sheets were also fixed at the breast height ( $d_{1.3}$ ) and the end of the trunk ( $d_{end}$ ) of these trees. A tape measure was used to measure the height of the designated trees, and a diameter gauge was used to measure their diameter. The diameter and height of 175 trees were measured in the field, 150 of which were in Stand-C and 25 in Stand-D. Following the measurements of the trees, the GCPs coordinates were measured and uniformly distributed along the perimeter of the study areas. Following the installation and measurements GCPs in the field, UAV flights were done (Fig. 3). The flying speed was 4.75 m/sec, the overlap rate was 80%, and the camera angle was 90° for all flights.




Figure 3. UAV photos show a ground control point and marker sheets

### 2.2.2. UAV images processing and measurements

In this work, point clouds were created from UAV images using the Structure from Motion (SfM) technique. The SfM approach arranges the positions and matches the objects in the UAV photographs using the metadata [29]. Point clouds with 1.5 cm (42 m altitude) and 1.7 cm (38 m altitude) GSD in the Stand-C and Stand-D areas respectively, were used as Low GSD data ( $L_{GSD}$ ). Point clouds with GSDs of 1.95 cm (55 m altitude) in Stand-C and 2.15 cm (52 m altitude) in Stand-D were used as High GSD data ( $H_{GSD}$ ). RMSE (Root Mean Square Error) average positional error values of 2.6 cm in Stand-C and 1.5 cm in Stand-D were found after processing the UAV photos.

The study used the Pix4dmapper application to measure the diameter and height of trees in point cloud data. The Pix4dmapper software generates 3-dimensional measurements in the point cloud that are all analyzed

along with height data to obtain findings. The measurements made use of the multi-correct feature, and the measurement data were saved in the "Objects" layer. To increase accuracy, each marking made during the measurements was then marked on the UAV photos using the "Properties" window. During field surveys, markers ( $d_0$ ,  $d_{1.3}$ , and  $d_{end}$ ) were affixed to the trunks of the trees to measure their diameter and height. Tree trunks were measured for diameter and height while being as closely as possible to ensure accurate measurements. The diameter and height of the trees were measured twice and averaged (Fig. 4) to minimize measurement errors.




Figure 4. Tree height measurements from point cloud data in Pix4dmapper

### 2.2.3. ML techniques and employed datasets

Four separate data sets were utilized for ML in the study. The data sets employed comprised measurements of the trunk diameter and height as well as slope and aspect values arising from the stance of the trunks in the field. The data set additionally includes the altitude values of the tree trunks' starting ( $d_0$ ) and finishing ( $d_{end}$ ) positions. The elevation values at the beginning and end of each log were calculated, and their disparities were used to calculate the trunk slope. To calculate the slope in percent, these discrepancies were multiplied by 100 and then divided by the log length. The coordinates of the tree's start and end points were used to calculate the trunk angle, which was then used to calculate the stand angles of the individual tree trunks. It was deemed permissible to employ slope, aspect, and altitude information for ML because these spatial properties are useful for measurements [30]. Spatial characteristics were included as independent variables in all 4 data sets. Furthermore, the diameter values recorded in the first data set  $L_{GSD}$  were used as independent variables in the first data set, and the diameter values recorded in the  $H_{GSD}$  data were used as independent variables in the second data set, the height values recorded in the  $L_{GSD}$  data in the third data set, and the height values recorded in the  $H_{GSD}$  data in the fourth data set. The reference diameter-height values derived from field measurements served as the dependent variable (target) in each of the four datasets. The purpose of this study was to compare the variations among these four datasets as well as the impact of ML,  $L_{GSD}$  and  $H_{GSD}$  values on the outcomes of measurements of tree diameter and height made using point cloud data.

These 4 data sets were examined by using nine different ML techniques such as boosting, regression, and neural networks. One of the popular ML technique is Ada Boost Regression (ABR), which combines weak regression models and modifies training weights according on misclassification errors [31]. A powerful ensemble model that can handle complex relationships and is noise-resistant is created by iteratively training weak models and integrating their predictions through weighted voting. Another machine learning approach called Decision Tree Regression (DTR) predicts continuous numerical values using a structure resembling a tree [32]. The input space is divided according to features, and training samples are assigned the average goal value. To ascertain the relationship between a dependent variable and independent variables, a statistical modeling technique known as linear regression (LR) fits a linear equation to observed data points [33]. Using decision trees and ensemble learning, Random Forest Regression (RFR) is a machine learning technique that produces accurate predictions and it is helpful in predictive modeling [34]. SVM and regression analysis are used in Support Vector Regression (SVR), a machine learning technique, to provide accurate predictions. It

recognizes complex patterns and generates accurate predictions by transferring input data into a higher-dimensional feature space using a kernel function [35].

A machine learning technique called gradient boosting regression (GBR) starts with weak regression models and builds a robust prediction model from them. It provides excellent accuracy, robustness against anomalies, and adaptability in data administration [36]. Another boosting method is XGBoost Regression (XGBR) for predictive performance. It combines gradient boosting with tree-based models. It builds a collection of imperfect decision trees, trains new trees to correct errors, and use regularization to prevent overfitting [37].

Computer models that can learn from data and generalize are called artificial neural networks (ANNs), and they are based on biological neural networks. They can do tasks like pattern recognition, regression, and classification because they are built on networked nodes. Neural Networks (ANNs) are widely used in many fields, including finance, natural language processing, computer vision, and sentiment analysis [38]. Artificial neural networks called Deep Neural Networks (DNNs) are used to recognize and interpret complicated patterns in data. They are employed in computer vision, natural language processing, and speech recognition and perform particularly well on large-scale, high-dimensional datasets. DNNs have improved performance and opened up new applications for machine learning across a range of domains, revolutionizing the industry [38].

Of the 175 brutian pine measurement data, 80% (140 trees) were used for training and 20% (35 trees) were used for testing in each of these methods. To create a more unbiased comparison, all ML calculations used the same testing trees. Additionally, GridSearchCV [39] was used to improve all ML algorithm parameters in order to obtain the best outcomes. All ML algorithms used in this study's implementation were done in Python.

### 3. Results

Table 1 lists the descriptive statistics, correlation coefficients, and  $L_{GSD}$ ,  $H_{GSD}$ , and reference diameter-height values for the diameter-height measurements obtained on point cloud data. When the diameter measurements' means are taken into account in the table, it becomes clear that both data sets ( $L_{GSD}$  and  $H_{GSD}$ ) have mean values that are higher than the values for the reference diameters. The fact that the lowest values are 3-4.5 cm larger than the reference data, despite the fact that the greatest values are relatively near to the reference value, demonstrates that point cloud diameter measurements provide better findings than the reference, particularly for small diameter values. When the diameter measures' correlation coefficients are examined, it can be noted that, despite the  $L_{GSD}$  data showing a larger correlation than the  $H_{GSD}$  data, both data sets attain very significant correlations for the diameter measurements. The correlation coefficients and the statistics of the height measurements in the table show that the height measurements in both data sets in the point clouds produce results that are extremely near to the reference values. According to this graph, it can be concluded that UAV height measurements are more accurate than diameter measurements. It is further observed that the GSD values perform better on diameter measurements compared to length measurements.

Table 1. Statistics for diameter-height calculated from reference and UAV images (n = 175)

	Measurements of diameter statistics (cm)				Measurements of height statistics (m)		
	Reference	$L_{GSD}$	$H_{GSD}$		Reference	$L_{GSD}$	$H_{GSD}$
Mean	25.31	28.67	28.98		16.44	16.4	16.43
Standard deviation	9.29	8.34	8.66		4.1	4.07	4.07
Maximum	61.5	61.36	61.35		30.75	30.7	30.67
Minimum	12	16.29	15.12		8.23	8.21	8.28
Correlation	-	0.950	0.949		-	0.996	0.996

Table 2 in the study provides the error values of the predictions generated using the diameter measurements taken in the point cloud data with  $L_{GSD}$  and  $H_{GSD}$  values and their correlations to the reference measurements. When the predictions of the  $L_{GSD}$  data are assessed, the DNN and ANN methods show the highest correlation with the reference data ( $r=0.946$ ), whilst the DTR approach shows the lowest correlation ( $r=0.902$ ). In the predictions made using the  $H_{GSD}$  data, the DNN approach showed the highest correlation ( $r=0.966$ ), whereas the DTR method showed the lowest correlation ( $r=0.883$ ). The lowest correlation values received from the

$L_{GSD}$  data are higher than the value obtained from the  $H_{GSD}$  data, and it is understood that the values of the GSD are effective in these circumstances rather than the highest correlation values. Additionally, it can be observed that DNN and DTR are the most and least successful ML methods for diameter predictions, respectively.

Table 2. Diameter estimations using ML techniques with correlation and error values

		DNN	RFR	ABR	XGBR	DTR	ANN	GBR	LR	SVR
$L_{GSD}$	Correlation	0.946	0.937	0.916	0.928	0.902	0.946	0.939	0.933	0.938
	RMSE*	0.064	0.069	0.079	0.073	0.084	0.063	0.067	0.070	0.068
	MAE**	0.052	0.054	0.061	0.060	0.068	0.050	0.054	0.052	0.057
$H_{GSD}$	Correlation	0.966	0.953	0.960	0.959	0.883	0.961	0.957	0.961	0.949
	RMSE	0.051	0.059	0.055	0.056	0.092	0.055	0.057	0.054	0.062
	MAE	0.044	0.050	0.047	0.047	0.074	0.044	0.050	0.045	0.050

\* Root mean square error (cm), \*\* Mean absolute error (cm)

Based on the data in Table 2, the DNN method produced the best results and the DTR method produced the worst results for the diameter estimations made in the  $L_{GSD}$  and  $H_{GSD}$  data. Graphs showing the distribution of the prediction and reference data for 35 brutian pine trees whose diameter was estimated using these methods were created (Fig. 5). When the graphs are examined, it can be shown that for both data sets, the DNN method's distribution is more linear than the DTR approach.

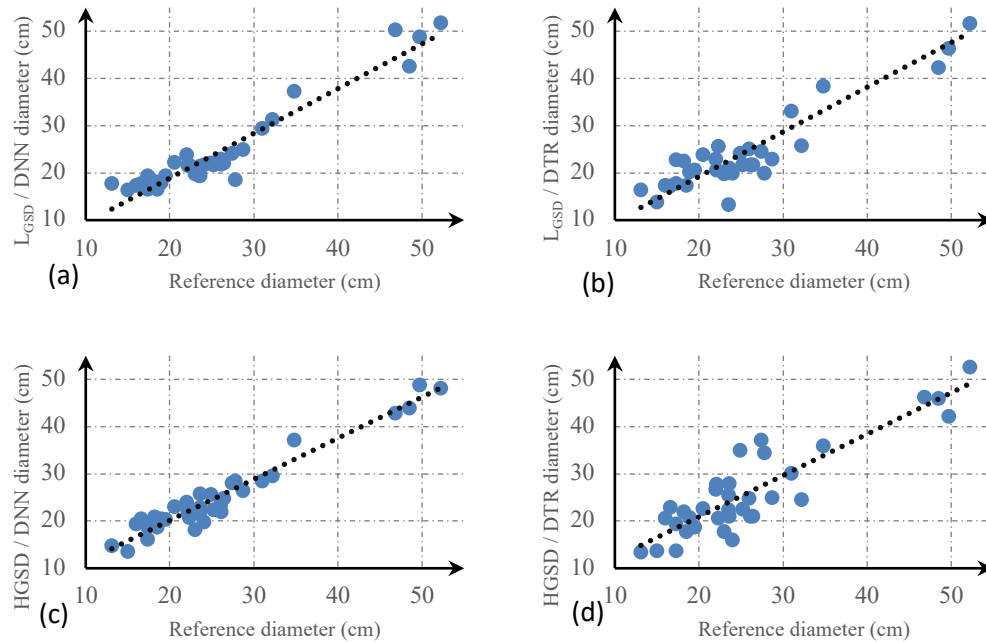


Figure 5. Scatter plots of the diameter values for the reference and expected; a) DNN method ( $L_{GSD}$ ); b) DTR method ( $L_{GSD}$ ); c) DNN method ( $H_{GSD}$ ); d) DTR method ( $H_{GSD}$ )

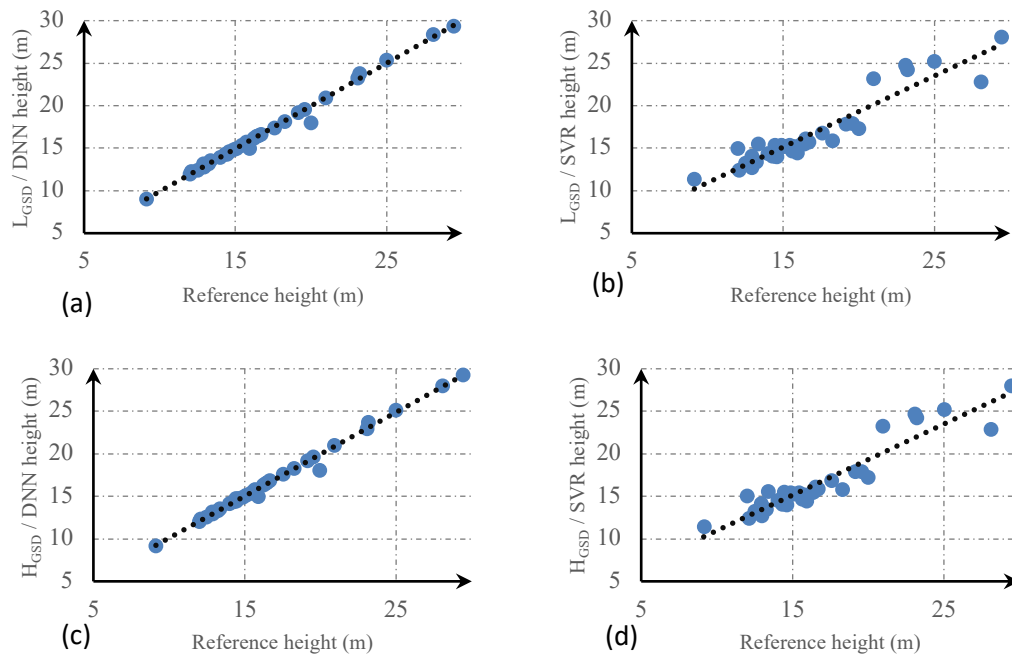
In the study, Table 3 provides the error values of the height estimations derived using the ML algorithms on point cloud data with  $L_{GSD}$  and  $H_{GSD}$  values, as well as their correlations with the reference measurements. In the table, the DNN, ANN, and LR methods produced the highest correlation ( $r=0.996$ ), whereas the SVR approach produced the lowest correlation ( $r=0.939$ ) in  $L_{GSD}$ . In the ML predictions using the  $H_{GSD}$  data, the DNN approach produced the highest correlation ( $r=0.996$ ), whereas the SVR method produced the lowest correlation ( $r=0.938$ ). The smallest correlation values obtained from the  $L_{GSD}$  data are higher than the value obtained from the  $H_{GSD}$  data, and it is understood that, similarly to diameter predictions, in height predictions the ML values are effective at lower correlation values rather than higher correlation values. Additionally, it can be shown that DNN and SVR are the most and least successful ML methods for height predictions, respectively.

Table 3. Height estimates by ML techniques with correlation and error values

		DNN	RFR	ABR	XGBR	DTR	ANN	GBR	LR	SVR
$L_{GSD}$	Correlation	0.996	0.995	0.995	0.990	0.991	0.996	0.995	0.996	0.939
	RMSE*	0.018	0.020	0.021	0.028	0.026	0.018	0.019	0.019	0.070
	MAE**	0.009	0.009	0.015	0.013	0.015	0.011	0.010	0.010	0.070
$H_{GSD}$	Correlation	0.996	0.995	0.994	0.989	0.993	0.994	0.994	0.995	0.938
	RMSE	0.017	0.020	0.021	0.029	0.024	0.023	0.021	0.019	0.070
	MAE	0.008	0.010	0.015	0.014	0.013	0.018	0.011	0.010	0.051

\* Root mean square error (cm), \*\* Mean absolute error (cm)

Based on the information in Table 3, graphs showing the distribution of the prediction and reference data for 35 brutian pine trees whose diameter was predicted by these methods were created (Fig. 6). The DNN method produced the most successful result, and the SVR method produced the least successful result, in both datasets for the height predictions. When the graphs are examined, it can be shown that for both data sets, the DNN approach's distribution is more linear than the SVR method.

Figure 6. Scatter plots showing the expected and reference height values; a) DNN method ( $L_{GSD}$ ); b) SVR method ( $L_{GSD}$ ); c) DNN method ( $H_{GSD}$ ); d) SVR method ( $H_{GSD}$ )

As a consequence of measurements taken using point clouds with  $L_{GSD}$  and  $H_{GSD}$  values, the correlation values and their averages of the prediction values of the nine distinct ML approaches employed in the study are provided in Table 4. When the table is analyzed, the top 3 methods for estimating diameter in the  $L_{GSD}$  data are DNN ( $r=0.946$ ), ANN ( $r=0.946$ ), and GBR ( $r=0.939$ ), while the methods with the lowest correlation values for estimating diameter are DTR ( $r=0.902$ ), ABR ( $r=0.916$ ), and XGBR ( $r=0.928$ ). DNN, ANN, and LR were the top 3 most successful algorithms for estimating diameter in the  $H_{GSD}$  data, whereas DTR, SVR, and RFR produced the least successful results ( $r=0.883$ ,  $0.949$ , and  $0.953$ ). When the average correlations of ML approaches used to forecast diameter are examined, the top 3 most effective methods are DNN ( $r=0.956$ ), ANN ( $r=0.953$ ), and GBR ( $0.948$ ), whereas DTR ( $r=0.893$ ) and ABR ( $r=0.938$ ) produce the least successful predictions.

Table 4. Diameter and height correlation scores for ML algorithms

Data \ ML Algo.	DNN	RFR	ABR	XGBR	DTR	ANN	GBR	LR	SVR
L <sub>GSD</sub> diameter	0.946	0.937	0.916	0.928	0.902	0.946	0.939	0.933	0.938
H <sub>GSD</sub> diameter	0.966	0.953	0.960	0.959	0.883	0.961	0.957	0.961	0.949
Mean correlation for diameters	0.956	0.945	0.938	0.943	0.893	0.953	0.948	0.947	0.943
L <sub>GSD</sub> height	0.996	0.995	0.995	0.990	0.991	0.996	0.995	0.996	0.939
H <sub>GSD</sub> height	0.996	0.995	0.994	0.989	0.993	0.994	0.994	0.995	0.938
Mean correlation for heights	0.996	0.995	0.995	0.990	0.992	0.995	0.995	0.996	0.938

DNN ( $r=0.996$ ), ANN ( $r=0.996$ ), and LR ( $r=0.996$ ) were the top 3 methods for height estimations in the L<sub>GSD</sub> data, whereas SVR ( $r=0.939$ ) and XGBR ( $r=0.990$ ) were the least successful (Table 4). DNN ( $r=0.996$ ), RFR ( $r=0.995$ ), and LR ( $r=0.995$ ) were the top 3 methods for height predictions in the H<sub>GSD</sub> data, whereas SVR ( $r=0.938$ ) and XGBR ( $r=0.989$ ) produced the least accurate results. When the average correlations of ML approaches for height predictions are examined, DNN ( $r=0.996$ ) and LR ( $r=0.996$ ) produce the best results, while SVR ( $r=0.938$ ) and XGBR ( $r=0.990$ ) produce the worst results. According to this data, it can be seen that the DNN and ANN approaches produced the best predictions, while the SVR and DTR methods produced the worst predictions.

#### 4. Discussion and Conclusion

To better comprehend the many linkages influencing the development of forest ecosystems, diameter-height models are required [40, 41]. The diameter-height relationship is influenced by various topographic characteristics, including slope, aspect, elevation, etc. Therefore, topographic factors should be added to the model in addition to the breast diameter variable to improve the accuracy of diameter-height models [41, 42, 43, 44]. Along with tree diameter-height variables, topographic factors were included in this study's ML approaches as input variables with the goal of evaluating the impact of GSD values on manual measurements taken from UAV data [45].

Effective forest planning and design is necessary to sustain forest resources efficiently. To ensure optimal design, stand volume parameters such as breast height, diameter, height, and number of trees should be calculated as closely as possible to the actual data [46]. It is well known that stand volume parameters are often measured by researchers using UAV technology. Researchers found that UAV data produced highly successful results, like as this work, when they used the data to estimate tree height and crown breadth [47, 48]. Biomass estimation [49,50], tree volume estimation [51], and post-felling tree trunk volume estimation [52] studies have all effectively used UAV data. Researchers have had success using UAVs and ML to map woody biomass that remains in the field after production [53], identify species automatically [54], and locate tree roots [55]. The benefits of UAVs in terms of labor, money, and time are cited in nearly all the related studies in the literature. Specifically, it is well known that UAV data can be a very useful and powerful tool when combined with artificial intelligence methods like ML. Compared to other remote sensing instruments, UAVs are typically thought to be more precise, effective, and economical.

Similar to the research conducted by Akay et al. [56] and Akgül et al. [57], this study examined the impact of ground sampling interval on the assessment of tree height and diameter in UAV-generated photogrammetric data. In contrast to these research, the outcomes were assessed using machine learning techniques, and the impact of ground sample intervals on the effectiveness of ML methods was examined. Instead of using digital elevation models, this study used point cloud data, as opposed to Akgül et al. [57] and Zhou et al. [52]. Point cloud data is preferred in this study because it is more reliable than orthomosaic data for measuring tree height [45]. This is despite the fact that it is well known that using orthomosaic data in the measurement of short lengths, such as tree diameter measurement, can provide more accurate results and save labor/time [58, 59]. Furthermore, since ground control points are known to enhance UAV image quality and yield more dependable results [60, 61, 62, 63], they were also employed in this study, resulting in an increase in the positional accuracy of the photogrammetric data generated.

According to the study's findings, the manual diameter measurements performed on the L<sub>GSD</sub> data yielded a correlation value of 0.950, but the DNN method (the most successful ML method) obtained a correlation



value of 0.946. The diameter measurements based on the  $H_{GSD}$  data had a correlation value of 0.949, and the most effective ML approach, the DNN method, had a correlation value of 0.966. Manual height measurements on the  $L_{GSD}$  and  $H_{GSD}$  data yielded correlation values of 0.996, respectively, while 0.996 correlation values were obtained using the DNN approach in ML estimations for both data sets. It can be seen in this context that ML approaches enhance diameter measurements, particularly in data with  $H_{GSD}$  values. Since the production of data with  $L_{GSD}$  values is more expensive (in terms of flight time, UAV energy consumption, energy and time consumption during the processing of UAV images in the computer environment) than the production of data without  $H_{GSD}$  values, it is believed that ML methods will be helpful for achieving precise results, especially in point cloud data with  $H_{GSD}$  values. Given that the greatest GSD difference between the  $L_{GSD}$  and  $H_{GSD}$  data in this investigation is 6.5 mm, it is projected that if this difference widens, so might the success difference between the two sets of data. These findings also demonstrate that, albeit marginally, the diameter measurement and ML estimation results obtained from the  $L_{GSD}$  data outperform those obtained from the  $H_{GSD}$  data and demonstrate the significance of the GSD values in measurements and estimations [64, 65, 66].

From the most successful approach to the least successful method, DNN ( $r=0.976$ ), ANN ( $r=0.974$ ), GBR ( $r=0.972$ ), LR ( $r=0.971$ ), RFR ( $r=0.970$ ), XGBR ( $r=0.967$ ), ABR ( $r=0.966$ ), DTR ( $r=0.942$ ) and SVR ( $r=0.941$ ) had the average correlation values for the diameter and height estimates. It is believed that DNN and ANN approaches can be applied in research of a similar nature to reduce costs and time. It is anticipated that field work can be reduced, sufficient trees can be measured in the field to learn ML methods, and the diameters and heights of unmeasured trees can be estimated with a very high degree of accuracy using the integration of ML and UAV photogrammetry [67, 68, 69]. Overall, these findings emphasize the utility of GSD values in UAV photogrammetry-generated data for measurements, especially in precision investigations recording tiny distances. To optimize cost and time, combining remote sensing with ML techniques is recommended.

## Acknowledgment

The data used in this study (tree diameter and height values) were taken from the master's thesis titled "Measuring the diameter and length of brutian pine tree from aerial photographs obtained by unmanned aerial vehicle" supported by Isparta University of Applied Sciences Scientific Research Projects Coordination Unit with the project number 2021-YL1-0137. We would like to thank forest engineers A. Cankut GÖZ, Erhan ERTAN and Aytekin SARIŞAHİN for their help during field work.

## Conflict of Interest Statement

The authors declare that there is no conflict of interest.

## References

- [1] H. O. Çoban, "Uydu verileri ile orman alanlarındaki zamansal değişimlerin belirlenmesi," Ph.D. dissertation, İstanbul Univ., İstanbul, Türkiye, 2006.
- [2] H. Durgun and H. O. Çoban, *Tarım, orman ve su bilimlerinde öncü ve çağdaş çalışmalar: Isparta ve Burdur bölgesindeki orman ekosistemleri ve topoğrafik değişkenler arasındaki ilişkilerin değerlendirilmesi*. Duvar Yayınları, 2023, 113-137.
- [3] A. Koç, "Coğrafi bilgi sistemlerinde veriler ve elde edilmiş yöntemleri," *Journal of the Faculty of Forestry Istanbul University*, vol. 43, pp. 117-134, 1993.
- [4] İ. Balcı, H. O. Çoban and M. Eker, "Coğrafi bilgi sistemi," *Turkish Journal of Forestry*, vol. 1, pp. 115-132, 2009. doi:10.18182/tjf.56117
- [5] E. Buğday, "Orman yönetiminde insansız hava aracı uygulamaları," in *Abstract Book: 2nd International Eurasian Conference on Biological and Chemical Sciences, EurasianBioChem2019, Ankara, Turkey, June 28-29, 2019*, pp. 29.
- [6] B. Menteşoğlu and M. İnan, "İnsansız hava araçlarının (İHA) ormancılık uygulamalarında kullanımı," in *VI. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu: UZAL-CBS 2016, Adana, Turkey, October 5-7, 2016*, pp. 5-7.
- [7] W. Gao, Q. Qiu, C. Yuan, X. Shen, F. Cao, G. Wang and G. Wang, "Forestry big data: A review and bibliometric analysis," *Forests*, vol. 13(10), pp. 1549, 2022. doi:10.3390/f13101549
- [8] G. Selvi, "Automated Machine Learning Platform," in *6th International Conference on Computer Science and Engineering: UBMK2021, Ankara, Turkey, September 15-17, 2021*, pp.769-774.

- [9] T. Liu, Y. Sun, C. Wang, Y. Zhang, Z. Qiu, W. Gong and X. Duan, "Unmanned aerial vehicle and artificial intelligence revolutionizing efficient and precision sustainable forest management," *Journal of Cleaner Production*, vol. 311, pp. 127546, 2021. doi:10.1016/j.jclepro.2021.127546
- [10] M. A. Lefsky, W. B. Cohen, A. Hudak, S. A. Acker and J. L. Ohmann, "Integration of lidar, Landsat ETM+ and forest inventory data for regional forest mapping," in *International Archives of Photogrammetry and Remote Sensing*, vol. 32, no. 3/W14, pp. 119–126, 1999.
- [11] M. Moghaddam, J. Dungan, S. Acker, "Forest variable estimation from fusion of SAR and multispectral optical data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 40, no. 10, pp. 2176–2187, 2002. doi:10.1109/TGRS.2002.804725
- [12] K. Tsuya, N. Fujii, D. Kokuryo, T. Kaihara, Y. Sunami, R. Izuno and M. Mano, "A Study on tree species discrimination using machine learning in forestry," *Procedia CIRP*, vol. 99, pp. 703–706, 2021. doi:10.1016/j.procir.2021.03.094
- [13] A. Şahin, G. Aylak Özdemir, O. Oral, B. L. Aylak, M. İnce and E. Özdemir, "Estimation of tree height with machine learning techniques in coppice-originated pure sessile oak (*Quercus petraea* (Matt.) Liebl.) stands," *Scandinavian Journal of Forest Research*, vol. 38, no. 1-2, pp. 87–96, 2023. doi:10.1080/02827581.2023.2168044
- [14] B. L. Aylak, M. İnce, O. Oral, G. Süer, N. Almasarwah, M. Singh and B. Salah, "Application of machine learning methods for pallet loading problem," *Applied Sciences*, vol. 11, no. 18, pp. 8304, 2021. doi:10.3390/app11188304
- [15] H. Varol Özkavak, M. İnce and E. Bıçaklı, "Prediction of mechanical properties of the 2024 aluminum alloy by using machine learning methods," *Arabian Journal for Science and Engineering*, vol. 48, no. 3, pp. 2841–2850, 2023. doi:10.1007/s13369-022-07009-8
- [16] D. Stojanova, P. Panov, V. Gjorgjioski, A. Kobler and S. Džeroski, "Estimating vegetation height and canopy cover from remotely sensed data with machine learning," *Ecological Informatics*, vol. 5, no. 4, pp. 256–266, 2010. doi:10.1016/j.ecoinf.2010.03.004
- [17] R. Eker, K. C. Alkiş, Z. Uçar and A. Aydın, "Ormanlıkta makine öğrenmesi kullanımı," *Turkish Journal of Forestry*, vol. 24, no.2, pp. 150-177, 2023. doi:10.18182/tjf.1282768
- [18] O. Alkan and R. Özçelik, "Toros göknarı için uyumlu hacim ve gövde çapı modelleri," *Turkish Journal of Forestry*, vol. 22, no. 4, pp.408–416, 2021. doi:10.18182/tjf.989732
- [19] USGS, "Shuttle Radar Topography Mission (SRTM) Data Download," *United States Geological Survey*, [Online]. Available: <https://earthexplorer.usgs.gov>. [Accessed: July. 26, 2023]
- [20] IOBM, "Çandır Orman İşletme Şefliği 2021 yılı Orman Amenajman Planı," *Isparta Orman Bölge Müdürlüğü*, Isparta, Türkiye, 2021.
- [21] DJI, "Mavic Air User Manual," [Online] Available: <https://dl.djicdn.com/downloads>. [Accessed: July. 15, 2023]
- [22] B. Ruzgienė, T. Berteška, S. Gečyte, E. Jakubauskienė and V. C. Aksamitauskas, "The surface modelling based on UAV Photogrammetry and qualitative estimation," *Measurement*, vol. 73, pp. 619–627, 2015. doi:10.1016/j.measurement.2015.04.018
- [23] C. Stöcker, F. Nex, M. Koeva and M. Gerke, "Quality assessment of combined IMU/GNSS data for direct georeferencing in the context of UAV-based mapping," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 42, pp. 355–361, 2017. doi:10.5194/isprs-archives-XLII-2-W6-355-2017
- [24] H. Durgun, H. O. Çoban and M. Eker, "İHA görüntülerinin geometrik düzeltmesinin ağaç çap ve boy ölçümlerine etkileri," in *5<sup>th</sup> International Conferences on Science and Technology, ICONST22, Budva, Montenegro, September 7-8, 2022*.
- [25] South, "Galaxy G6 measuring system user manual," [Online] Available: <https://globalgpsystems.com/wp-content/uploads/2020/03/Galaxy-G6-Measuring-System-User-Manual.pdf>. [Accessed: July. 18, 2023]
- [26] ArcGIS, "ArcGIS," [Online] Available: <https://www.arcgis.com/index.html>. [Accessed: July. 18, 2023].
- [27] Microsoft "Microsoft," [Online] Available: <https://www.microsoft.com/tr-tr/microsoft-365>. [Accessed: July. 18, 2023]
- [28] Pix4d, "Pix4d," [Online] Available: <https://www.pix4d.com>. [Accessed: July. 18, 2023]
- [29] N. Snavely, S. Seitz and R. Szeliski, "Modeling the world from internet photo collections," *International journal of computer vision*, vol. 80, pp. 189–210, 2008. doi:10.1007/s11263-007-0107-3
- [30] H. Durgun, "İnsansız hava aracıyla elde edilen hava fotoğraflarından kızılçam ağaçlarının çap ve boylarının ölçülmesi," MSc. dissertation, Isparta Uygulamalı Bilimler Univ., Isparta, Türkiye, 2023.
- [31] Y. Freund and R. E. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," *Journal of computer and system sciences*, vol. 55 no. 1, pp. 119-139, 1997.
- [32] L. Breiman, J. H. Friedman, R. A. Olshen and C. J. Stone, "Classification and regression trees," *CRC press*, 1984.
- [33] Y. Jiang, Y. Zhang, J. Tian and C. Zhou, "A comparative study of machine learning methods for predicting house prices," *Sustainability*, vol. 13, no. 15, pp. 8233, 2021.

- [34] R. M. Costa, M. F. Ribeiro, M. C. Fialho and J. M. C. Sousa, "A random forest classifier for medical diagnosis based on particle swarm optimization," *Computational and mathematical methods in medicine*, 2020.
- [35] J. Wu, W. Xu, C. Zeng, Y. Wang and J. Huang, "Support vector regression for predicting disease progression in breast cancer," *BMC Bioinformatics*, vol. 18, no. 1, pp. 365, 2017.
- [36] J. Sequeira, M. Barandas, J. Neves and F. Silva, "Hybrid gradient boosting machine learning approach to predict photovoltaic energy production," *Energies*, vol. 14, no. 3, pp. 630, 2021.
- [37] K. Zhao, Y. Ma and J. Zhang, "XGBoost-based stock price forecasting in financial market," *Mathematical Problems in Engineering*, 2019.
- [38] Y. LeCun, Y. Bengio and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, 2015.
- [39] GridSearchCV, "Scikit-learn machine learning in python," [Online] Available: [https://scikitlearn.org/stable/modules/generated/sklearn.model\\_selection.GridSearchCV.html](https://scikitlearn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html). [Accessed: Aug. 10, 2023]
- [40] C. Peng, "Developing ecoregion-based height-diameter models for jack pine and black spruce in Ontario. Sault Ste. Marie: Ontario," Forest Research Institute, 2001.
- [41] R. Özçelik, M. J. Diamantopoulou, F. Crecente-Campo and Ü. Eler, "Estimating Crimean juniper tree height using nonlinear regression and artificial neural network models," *Forest ecology and management*, vol. 306, pp. 52-60, 2013. doi:10.1016/j.foreco.2013.06.009
- [42] J. Castaño-Santamaría, F. Crecente-Campo, J. L. Fernández-Martínez, M. Barrio-Anta and J. R. Obeso, "Tree height prediction approaches for uneven-aged beech forests in northwestern Spain," *Forest Ecology and Management*, vol. 307, pp. 63-73, 2013. doi:10.1016/j.foreco.2013.07.014
- [43] İ. Ercanlı, "Artificial intelligence with deep learning algorithms to model relationships between total tree height and diameter at breast height," *Forest Systems*, vol. 29, no. 2, pp. 13, 2020. doi:10.5424/fs/2020292-16393
- [44] S. Long, S. Zeng, F. Liu and C. Wang, "Influence of slope, aspect and competition index on the height-diameter relationship of *Cyclobalanopsis glauca* trees for improving prediction of height in mixed forests," *Silva Fennica*, vol. 54, no. 1, 2020. doi:10.14214/sf.10242
- [45] H. Durgun, H. O. Çoban and M. Eker, "İnsansız hava aracıyla elde edilen hava fotoğraflarından kızılçam ağaçlarının çap ve boylarının ölçümü ve gövde hacminin tahmini," *Turkish Journal of Forestry*, vol. 23, no. 4, pp. 255-267, 2022. doi:10.18182/tjf.1199567
- [46] S. Carus and Y. Çatal, "Kızılçam (*pinus brutia* ten.) meşcerelerinde 7-ağaç örnek nokta yöntemiyle meşcere ağaç sayısının çap basamaklarına dağılımının belirlenmesi," *Turkish Journal of Forestry*, vol. 9, no. 2, pp. 158-169, 2009. doi:10.18182-tjf.94714-195711
- [47] Y. S. Lim, J. S. Park, M. W. Pyeon and J. Kim, "Calculation of tree height and canopy crown from drone images using segmentation," *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, vol. 33, no. 6, pp. 605- 613, 2015. doi:10.7848/ksgpc.2015.33.6.605
- [48] A. C. Birdal, "Ağaç Yüksekliklerinin Belirlenmesinde İnsansız Hava Araçlarının Kullanımı: Eskişehir Kent Ormanı Örneği," MSc. dissertation, Anadolu Univ., Eskişehir, Türkiye, 2016.
- [49] D. J. Kachamba, H. O. Orka, T. Gobakken, T. Eid and W. Mwase, "Biomass estimation using 3d data from unmanned aerial vehicle imagery in a tropical woodland," *Remote Sensing*, vol. 8, no. 11, pp. 968, 2016. doi:10.3390/rs8110968
- [50] M. Messinger, G. P. Asner and M. Silman, "Rapid assessments of amazon forest structure and biomass using small unmanned aerial systems," *Remote Sensing*, vol. 8, no. 8, pp. 615, 2016. doi:10.3390/rs8080615
- [51] B. Brede, K. Calders, A. Lau, P. Raunonen, H. M. Bartholomeus, M. Herold and L. Kooistra, "Non-destructive tree volume estimation through quantitative structure modelling: comparing UAV laser scanning with terrestrial lidar," *Remote Sensing of Environment*, vol. 111355, pp. 233, 2019. doi:10.1016/j.rse.2019.111355
- [52] X. Zhou, Y. He, H. Huang and X. Xu, "Estimation of forest stand volume on coniferous forest cutting area based on two periods unmanned aerial vehicle images," *Scientia Silvae Sinicae*, vol. 55, no. 11, pp. 117-125, 2019. doi:10.11707/j.1001-7488.20191113
- [53] L. Windrim, M. Bryson, M. McLean, J. Randle and C. Stone, "Automated mapping of woody debris over harvested forest plantations using uavs, highresolution imagery, and machine learning," *Remote Sensing*, vol. 11, pp. 733, 2019. doi:10.3390/rs11060733
- [54] G. Morales, G. Kemper, G. Sevillano, D. Arteaga, I. Ortega and J. Telles, "Automatic segmentation of *Mauritia flexuosa* in unmanned aerial vehicle (UAV) imagery using deep learning," *Forests*, vol. 9, no. 12, pp. 736, 2018. doi:10.3390/f9120736
- [55] S. Puliti, B. Talbot and R. Astrup, "Tree-stump detection, segmentation, classification, and measurement using unmanned aerial vehicle imagery," *Forests*, vol. 9, pp. 102, 2018. doi:10.3390/f9030102
- [56] S. S. Akay, Ö. Özcan, F. B. Şanlı, B. Bayram and T. Görüm, "İHA Görüntülerinden Üretilen Verilerin Doğruluk Değerlendirmesi," *X. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği Teknik Sempozyumu*, Nisan 25-27, Aksaray, Türkiye, 106-110, 2019.

- [57] M. Akgül, H. Yurtseven, M. Demir, A. E. Akay, S. Gülci and T. Öztürk, "İnsansız hava araçları ile yüksek hassasiyette sayısal yükseklik modeli üretimi ve ormancılıkta kullanım olanakları," *Journal of the Faculty of Forestry Istanbul University*, vol. 66, no. 1, pp. 104-118, 2016. doi:10.17099/jffiu.23976
- [58] A. Navarro, M. Young, B. Allan, P. Carnell, P. Macreadie and D. Ierodiaconou, "The application of unmanned aerial vehicles (UAVs) to estimate above-ground biomass of mangrove ecosystems," *Remote Sensing of Environment*, pp. 242, 2020. doi:10.1016/j.rse.2020.111747
- [59] T. Liu, Y. Sun, C. Wang, Y. Zhang, Z. Qiu, W. Gong and X. Duan, "Unmanned aerial vehicle and artificial intelligence revolutionizing efficient and precision sustainable forest management," *Journal of Cleaner Production*, pp. 311, 2021. doi:10.1016/j.jclepro.2021.127546
- [60] B. Ruzgiene, T. Berteska, S. Gecyte, E. Jakubauskiene and V. C. Aksamitauskas, "The surface modelling based on UAV photogrammetry and qualitative estimation," *Measurement*, vol. 73, pp. 619-627, 2015.
- [61] C. Stöcker, F. Nex, M. Koeva and M. Gerke, "Quality assessment of combined IMU/GNSS data for direct georeferencing in the context of UAV-based mapping," *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 42, pp. 355, 2017.
- [62] H. S. Kapıcıoğlu, K. O. Hastaoğlu, F. Poyraz and Y. Gül, "Investigation of topographic effect in ground control point selection in uav photogrammetry: Gaziantep/Nizip," *International Conference on Innovative Engineering Applications, September 20-22, Sivas, Türkiye*, 1174-1178, 2018.
- [63] M. Rabah, M. Basiouny, E. Ghanem and A. Elhadary, "Using RTK and VRS in direct geo-referencing of the UAV imagery," *NRIAG Journal of Astronomy and Geophysics*, vol. 7, no. 2, pp. 220-226, 2018. doi:10.1016/j.nrjag.2018.05.003
- [64] S. S. Akay, O. Özcan, F. B. Şanlı, B. Bayram and T. Görüm, "İHA görüntülerinden üretilen verilerin doğruluk değerlendirmesi," in *X. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği Teknik Sempozyumu*, pp. 25-27, 2019.
- [65] S. Krause, T. G. Sanders, J. P. Mund and K. Greve, "UAV-based photogrammetric tree height measurement for intensive forest monitoring," *Remote sensing*, vol. 11, no. 7, pp. 758, 2019. doi:10.3390/rs11070758
- [66] A. P. Dalla Corte, F. E. Rex, D. Almeida, C. R. Sanquetta, C. A. Silva, M. M. Moura and E. N. Broadbent, "Measuring individual tree diameter and height using GatorEye High-Density UAV-Lidar in an integrated crop-livestock-forest system," *Remote Sensing*, vol. 12, no. 5, pp. 863, 2020. doi:10.3390/rs12050863
- [67] M. J. Allen, S. W. Grieve, H. J. Owen and E. R. Lines, "Tree species classification from complex laser scanning data in Mediterranean forests using deep learning," *Methods in Ecology and Evolution*, vol. 14, no. 7, pp. 1657-1667, 2022. doi:10.1111/2041210X.13981
- [68] S. Arjasakusuma, S. Swahyu Kusuma and S. Phinn, "Evaluating variable selection and machine learning algorithms for estimating forest heights by combining lidar and hyperspectral data," *ISPRS International Journal of Geo-Information*, vol. 9, no. 9, pp. 507, 2020.
- [69] M. Ataş and A. Talay, "Development of automatic tree counting software from UAV based aerial images with machine learning," *arxiv.org*, Jan. 7, 2022. [Online]. Available: <https://arxiv.org/abs/2201.02698>. [Accessed: Sept. 16, 2023].

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## DarkWEB Traffic Detection and Classification Using Machine Learning Method

Esen Gül İlğün<sup>a</sup>, Yusuf Sönmez<sup>b</sup>, Murat Dener<sup>c</sup>

Submitted: 19.11.2023 Revised: 20.12.2023 Accepted: 20.12.2023 doi:10.30855/gmbd.0705S13

### ABSTRACT

**Keywords:** DeepWEB, DarkWEB, encrypted network traffic, machine learning, classification

<sup>a\*</sup> Gazi University,  
Graduate School of Natural And  
Applied Sciences,  
Dept. of Information Security Engineering

06560 - Ankara, Türkiye  
Orcid: 0000-0002-1719-5727  
e mail: egul.ilgun@gazi.edu.tr

<sup>b</sup> Gazi University,  
Technology Faculty,  
Dept. of Computer Engineering  
06560 - Ankara, Türkiye  
Orcid: 0000-0002-9775-9835

<sup>c</sup> Gazi University,  
Graduate School of Natural And  
Applied Sciences,  
Dept. of Information Security Engineering  
06261 - ANKARA, Türkiye  
Orcid: 0000-0001-5746-6141

\*Corresponding author:  
egul.ilgun@gazi.edu.tr

DarkWEB makes up 6% of DeepWEB, which contains data that search engines cannot index and is approximately 96% of all websites. DarkWEB is encrypted network traffic tunneled through special software such as TOR (The Onion Router) and provides a high level of anonymity with a series of anonymized connections that make the IP address untraceable. This makes it easier to carry out criminal activities such as media piracy, drug dealing, terrorism and child pornography. In this study, the statistical information of the packets was analyzed without decrypting this encrypted network traffic. Different data sets were obtained by applying categorical data coding, scaling, feature selection and data balancing pre-processes separately and together to the CIC-Darknet2020 data set used within the scope of the proposed methodology for high-accuracy detection and classification of DarkWEB traffic. Obtained data sets and Logistic Regression (LR), Gaussian Naive Bayes (GNB), Decision Tree (DT), K-Nearest Neighbor (KNN), Multi Layer Perceptron (MLP), Random Forest (RF), eXtreme Gradient Boosting (XGBoost), many DarkWEB traffic detection and classification models have been created using Light Gradient Boosting Machine (LightGBM), Category Boosting (CatBoost) machine learning algorithms. With the models created, Encryption (Encrypted, Standard), Category (Tor, Non-Tor, Non-VPN, VPN), Subcategory (Audio-Stream, Browsing, Chat, E-mail, P2P, Transfer, Video-Stream, VOIP) classes 2, 4 and 8 classifications were made. Accuracy rates of 99.9% were achieved in 2-fold and 4-fold classification, and 94% accuracy rate were achieved in 8-fold classification.

## Makine Öğrenme Yöntemi Kullanılarak DarkWEB Trafığı Tespiti ve Sınıflandırması

### ÖZ

DarkWEB, arama motorlarının indeksleyemediği verileri içeren ve tüm web sitelerinin yaklaşık %96'sı olan DeepWEB'in %6'sını oluşturur. DarkWEB, TOR (The Onion Router) gibi özel yazılımlar ile tünellenen şifreli ağ trafiğidir ve IP adresini izlenemez hale getiren anonimleştirilmiş bir dizi bağlantı ile yüksek düzeyde anonimlik sağlar. Bu durum medya korsanlığı, uyuşturucu satıcılığı, terörizm, çocuk pornografisi gibi suç faaliyetlerinin gerçekleştirilmesini kolaylaştırır. Bu çalışmada, bu şifreli ağ trafiğinde deşifreleme işlemi yapılmadan, paketlerin istatistik bilgileri analiz edilmiştir. DarkWEB trafiğinin yüksek doğrulukta tespiti ve sınıflandırılması için önerilen metodoloji kapsamında kullanılan CIC-Darknet2020 veri setine kategorik veri kodlama, ölçeklendirme, öznitelik seçimi ve veri dengeleme ön işlemleri ayrı ayrı ve de birlikte uygulanarak farklı veri setleri elde edilmiştir. Elde edilen veri setleri ve Logistic Regression (LR), Gaussian Naive Bayes (GNB), Decision Tree (DT), K-Nearest Neighbor (KNN), Multi Layer Perceptron (MLP), Random Forest (RF), eXtreme Gradient Boosting (XGBoost), Light Gradient Boosting Machine (LightGBM), Category Boosting (CatBoost) makine öğrenme algoritmaları kullanılarak çok sayıda DarkWEB trafiği tespit ve sınıflandırma modeli oluşturulmuştur. Oluşturulan modeller ile Encryption (Şifreli, Standart), Category (Tor, Non-Tor, Non-VPN, VPN), Subcategory ( Audio-Stream, Browsing, Chat, E-mail, P2P, Transfer, Video-Stream, VOIP) sınıfları olmak üzere 2'li, 4'lü, 8'li sınıflandırmalar yapılmıştır. 2'li ve 4'lü sınıflandırmada %99.9, 8'li sınıflandırmada ise %94 doğruluk oranına ulaşılmıştır.

**Anahtar Kelimeler:** DeepWEB, DarkWEB, şifreli ağ trafiği, makine öğrenme, sınıflandırma

## 1. Giriş (Introduction)

Herkesin erişebileceği ve dizine eklenmiş adres alanı, clearnet olarak bilinen ağın dışında olan, standart arama motorları tarafından indekslenmeyen, internetin yer altı olarak tabir edilen Deep WEB'in, clearnet'in 500 katından fazlası olduğu tahmin edilmektedir [1]. DeepWEB'in asıl amacı kullanıcı anonimliğidir ve kullanımı yasadır. DeepWEB içindeki ayrılmamış adres alanından oluşan ağlar ise DarkWEB olarak bilinir. DarkWEB [2], internet içinde şifrelenmiş, yalnızca belirli bir yapılandırma ve yetkilendirme ile erişilebilen bir yer paylaşımını ifade eder yani DeepWEB'in gizli kısmıdır. Kullanım amacına göre DarkWEB yasal ya da yasadışı olabilir fakat yaklaşık %95 oranında yasadışı faaliyetler için kullanılmaktadır.

DarkWEB'e özel bir yazılım ile kullanıcı yetkilendirmesi veya standart dışı iletişim protokolleri gerektiren bir yer paylaşımlı ağ ile ulaşılır [3]. Bu özel yazılımlardan en bilinenleri Tor ve FreeNet'tir. Tor 2002 yılında ABD Donanma Araştırma Laboratuvarı ile Free Haven Projesi arasında ortak bir proje olarak ortaya çıkmıştır. Projenin amacı anonim, şifrelenmiş bir ağ oluşturmaktır. FreeNet ise "Dağıtılmış, Merkezi Olmayan Bilgi Depolama ve Alma Sistemi" adında bir tezden üretilmiş yazılımdır. Bu yazılımlar ile giriş yapılan web adresleri, anlamsız numaralar ile harflerden oluşmaktadır ve bu adresler düzenli olarak değiştirilmektedir. Bu ağlar, bir IP adresini izlenemez hale getiren anonimleştirilmiş bir dizi bağlantı, proxy ağları aracılığıyla yüksek düzeyde anonimlik sağlar. Bu durum bilgisayar korsanlığı, medya korsanlığı, uyuşturucu satıcılığı, terörizm, insan kaçakçılığı ve çocuk pornografisi gibi suç faaliyetlerinin gerçekleştirilmesini kolaylaştırır. Birçok yasa dışı ürün ve hizmetin satışa sunulduğu DarkWEB pazarlarında, 2020 yılı itibarıyla [4] 500.000'den fazla kullanıcı işlem gerçekleştirdi, 2400'den fazla aktif satıcı olduğu tespit edildi, 320.000'den fazla alım-satım işlemi yapıldı, 4.650'den fazla bitcoin ve 12.800'den fazla monero kripto para el değiştirdi. Bu rakamların günümüze dek katlanarak arttığı tahmin edilmektedir. DarkWEB ortamında gerçekleştirilen suç faaliyetlerini engellemek için DarkWEB trafiğinin makine öğrenme ve derin öğrenme teknikleri kullanılarak tespiti ile sınıflandırılması, önemli bir çalışma alanıdır.

Bu çalışmanın amacı, Lashkari vd. [5] tarafından üretilen ve açık kaynak olan CICDarknet2020 veri setine çeşitli ön işlemler uygulayarak, kurulan makine öğrenme modellerinin yüksek doğrulukta DarkWEB trafiği tespiti ile sınıflandırması yapmasını sağlamaktır.

Bu makalenin ana katkı noktaları aşağıdaki gibi olmuştur:

- XGBoost gömülü öznitelik seçimi yöntemi kullanılarak modellerin tespit ve sınıflandırma başarısını olumsuz etkileyecek öznitelikler veri setinden çıkarılmıştır.
- Rastgele Yeniden Örnekleme (Random Over Sampling, ROS) yöntemi kullanılarak modelin objektif tespit ve sınıflandırma yapmasını engelleyebilecek, veri seti içerisindeki sınıf dengesizliği sorunu giderilmiştir.
- Oluşturulan modeller ile CICDarknet2020 veri setindeki katmanlı yaklaşım baz alınarak Encryption (Şifreli, Standart), Category (Tor, Non-Tor, Non-VPN, VPN), Subcategory (Audio-Stream, Browsing, Chat, E-mail, P2P, Transfer, Video-Stream, VOIP), sınıfları olmak üzere 2'li, 4'lü, 8'li sınıflandırmalar yapılmıştır.
- CICDarknet2020 veri setine, kategorik veri kodlama, ölçeklendirme, öznitelik seçimi, veri dengeleme ön işlemlerinin ayrı ayrı ve birlikte uygulandığı dört farklı senaryo denenmiş ve senaryoların uygulanması ile elde edilen sonuçlar karşılaştırılmıştır.
- Yapılan çalışmada, CICDarknet2020 veri setinin kullanıldığı literatür ile karşılaştırıldığında daha yüksek sınıflandırma doğruluğuna ulaşılmıştır.

Çalışmanın 2. bölümünde, ilgili çalışmalar özetlenmiştir. 3. bölümde, önerilen metodoloji detaylı olarak anlatılmıştır. 4. bölümde, önerilen metodolojinin uygulanması ve alınan sonuçlar verilmiştir. 5. bölümde ise sonuçların analizi ve değerlendirilmesi yapılmıştır.

## 2. İlgili Çalışmalar (Related Works)

Literatürde DarkWEB trafiğinin tespiti ve sınıflandırılması konusunda birçok yöntem önerilmiş, bu yöntemlerin uygulanması ile başarılı sonuçlar alınmış ve bu konuda gelecekte yapılması planlanan çalışmalara değinilmiştir. Bu bölümde yapılan bu çalışmalardan bahsedilmektedir:

Muhammad Bilal Sarwar vd. [6] DarkWEB ağ trafiği tespiti ve sınıflandırması için veri setinden en uygun özellikleri seçerken, Principal component analysis (PCA), Decision Tree Classifier, XGBClassifier kullanmış, geleneksel makine öğrenme algoritmaları ve ön işlenmiş veri seti ile modeller oluşturmuştur. Ardından, ağ trafiğini daha doğru bir şekilde tanımak için değiştirilmiş CNN-LSTM ve CNN-GRU derin öğrenme tekniklerini uygulamıştır. Önerilen yaklaşım, XGB özellik seçme yöntemi ve CNN-LSTM kullanılarak DarkWEB trafiği tespitinde %96, sınıflandırmasında ise %89 doğruluk elde etmiştir. L. A. Iliadis ve T. Kaifas [7] CICDarknet2020 veri seti üzerinde, ikili ve çok sınıflı sınıflandırma görevinde Random Forest algoritması ile ortalama %98'in üzerinde bir tahmin doğruluğu elde etmiş ve özellik önem analizi ile birlikte bir ROC analizi yapmıştır. S. Sridhar and S. Sanagavarapu [8] CICDarknet2020 veri seti üzerinde, öznelik seçimi için Ki-Kare yöntemi, sınıf dengesizliğini gidermek için Conditional Generative Adversarial aşırı örnekleme yöntemi uygulayarak çok sınıflı sınıflandırmada Random Forest ile 97,87 F1 Puanı elde etmiştir. Y. Li, Y. Lu ve S. Li [9] CIC-Darknet2020 veri setini kullanarak sıfır gün saldırılarını sınıflandırmak için CNN ve K-Means'ı birleştiren bir Şifreli Sıfır Gün Uygulamaları Sınıflandırması (EZAC) yöntemini önermiştir. İlk önce akışları sınıflandırmak için CNN, sıfır gün uygulamaları olabilecek akışları kategorize etmek için ise K-Means'ı kullanmıştır. Daha sonra bu akışlar manuel olarak etiketlenmiştir. EZAC yöntemi ile %97,4 doğru tespit oranı elde edilmiştir. M. Uğurlu vd. [10], CICDarknet2020 veri setindeki 82 adet öznelik içerisinden ağırlıklandırma işlemi yaparak 30 adet öznelik seçmiş, ROSE tekniği ile veri dengeleme yapmış, 10 farklı makine öğrenme algoritması ile model oluşturmuş ve hiper-parametre ayarı yapmıştır. Çalışmada önerilen yöntem ile Karar Ağacı algoritması ile kurulan model de %93,32 doğru tespit oranına ulaşılmıştır. Nhien Rust-Nguyen vd. [11] CIC-Darknet2020 veri setini kullanarak, modellerde hiper-parametre ayarı yapmış, kayıtları dört trafik sınıfına ve sekiz uygulama sınıfına göre sınıflandırmıştır. Sınıf dengesizliği için ise SMOTE seviyelerini denemiş, CNN ve AC-GAN için trafik özelliklerinin iki boyutlu temsillerini araştırmıştır. Ayrıca en iyi performans gösteren sınıflandırıcının kafasını karıştırmak için bir saldırganın bakış açısıyla yaklaşarak, uygulama sınıfı trafik özelliklerini etkili bir şekilde gizlemiştir. Random Forest ile trafik sınıflandırması için %99,8 F1 puanı ve uygulama sınıflandırması için %92,2 F1 puanı elde etmiştir. Ammar Almomani [12], DarkWEB trafiğini tespit etmek için iki aşamalı bir yöntem önermiştir. İlk aşamada ANN, RF ve SVM algoritmaları ile yapılan tahmin performanslarını, 2. Aşamada lojistik regresyon meta sınıflandırıcısına dayanan bir teknik ile son tahminleri oluşturmak için birleştirmiştir. Kümeleme topluluk öğrenimi denilen bu yöntem ile eğitim veri setinde %99'dan ve test veri setinde %97'den fazla hassasiyet ve doğruluk değerlerine ulaşılmıştır. Hardhik Mohanty vd. [13], RF, KNN, DT olmak üzere üç temel öğrenicinin tahminlerini en verimli şekilde birleştirmek için bir İstifleme Topluluğu (SE) modeli önermiştir. Önerilen model, Hızlı Gradyan İşaret Yöntemi (FGSM), Temel Yinelemeli Yöntem (BIM), DeepFool ve sınır saldırısı olmak üzere 4 saldırı çeşidi ile test edilmiş ve %98,89 doğru tespit oranı, %0,43 FPR elde edilmiştir. Qasem Abu Al-Haija vd. [14], Torbalama Karar Ağacı Toplulukları (BAG-DT), AdaBoost Karar Ağacı Toplulukları (ADA-DT), RUSBoosted Karar Ağacı Toplulukları (RUS-DT), Optimize Edilebilir Karar Ağacı (O-DT), Optimize Edilebilir k en yakın komşu (O-KNN) ve Optimize Edilebilir Discriminant (O-DSC) olmak üzere altı denetimli makine öğrenme tekniği ile DarkWEB trafik algılama modeli oluşturmuştur. Modelin CICDarknet2020 veri seti üzerindeki test performansı, torbalama topluluğu tekniği (BAG-DT) ile kurulan modelde 9,09 saniyede %99,50 sınıflandırma doğruluğu olmuştur. Yan Li ve Yifei Lu [15], şifreli uygulamaları sınıflandırmak için hem protokolleri hem de uygulamaları tanımlayabilen CNN (ETCC) yöntemini kullanan iki aşamalı, iki etiketli sınıflandırma önermiştir. İlk aşama, şifreli trafiği kullanılan protokolü sınıflandırır. İkinci aşama, uygulamaları trafik tarafından kullanılan protokole göre sınıflandırır. Önerilen ETCC yöntemi ile %97 sınıflandırma doğruluğuna ulaşılmıştır. Mahmoud Alimoradi vd. [16], DarkWEB trafiğini Tor, Tor olmayan, VPN ve VPN olmayan olmak üzere dört sınıfa ayırmış, 79 giriş nöronlu ve 6 gizli katmanlı derin sinir ağı mimarisi ile ham DarkWEB trafiğinden karmaşık, doğrusal olmayan ilişkileri keşfederek DIDarknet veri seti üzerinde %96 doğruluk oranına ulaşmıştır. Gerard Draper-Gil vd. [17], VPN trafiğini algılamak ve şifreli trafiği tarama, akış vb. trafik türüne göre farklı kategorilerde karakterize etmek için akışa dayalı zamanla ilgili özneliklerin etkinliğini incelemiş, özneliklerin doğruluğunu test etmek için makine öğrenme teknikleri (C4.5 ve KNN) kullanmıştır.

Literatür incelendiğinde DarkWEB trafiği tespiti ve sınıflandırması konusunda yeterince çalışma ve de veri seti olmadığı görülmüştür. Tablo 1'de ilgili çalışmaların bir özeti yer almaktadır.

Tablo 1. İlgili çalışmalar (Related works)

Yıl	Yazarlar	Model	Veri Seti	En iyi sonuçlar
2016	G. Draper-Gil vd.	C4.5, KNN	Real time dataset	Doğruluk:%80
2021	Y. Li, Y. Lu	CNN	CICDarknet2020	Doğruluk:%97
2021	M. B. Sarwar vd.	DT, GB, RFR, XGB, CNN-LSTM, CNN-GRU	CICDarknet2020	Doğruluk: %96, %89
2021	L. A. Iliadis, T. Kaifas	KNN, MLP, RF, DT, GB	CICDarknet2020	Doğruluk: 98.71 Hassasiyet: 0.9871 Kesinlik: 0.9870 F1- Ölçütü: 0.9870 F1- Ölçütü: 97,87
2021	S. Sridhar, S. Sanagavarapu	RF	CICDarknet2020	F1- Ölçütü: 97,87
2022	H. Mohanty vd.	Stacking Ensemble (SE) model (RF-KNN-DT)	CICDarknet2020	Doğruluk:%98,89
2022	Q. A. Al-Haija vd.	BAG-DT, ADA-DT, RUS-DT, O-DT, O-KNN, O-DSC	CICDarknet2020	Doğruluk:%99,50
2022	M. Alimoradi vd.	DNN	CICDarknet2020	Doğruluk:%96
2023	M. Uğurlu vd.	KNN, LR, RF SVM, DT, GNB, LDA, GB, ET, XGBoost	CICDarknet2020	Doğruluk : %93,32
2023	N. Rust-Nguyen vd.	GBDT, XGBoost, KNN, MLP, SVM, RF, CNN, AC-GAN	CICDarknet2020	F1- Ölçütü: %99,8, %92,2
2023	A. Almomani	NN LG KNN SVM stacking ensemble learning (RF SVM ANN)	CICDarknet2020	Doğruluk:%99.4, %96.74
2023	E. G. İlgün vd.	LR, GNB, DT, KNN, MLP, RF, XGBoost, LightGBM, CatBoost	CICDarknet2020	Doğruluk: %99.9, %94

Tablo 1’de yer alan çalışmalar incelendiğinde, CICDarknet2020 veri seti ile yapılan DarkWEB trafiği tespit ve sınıflandırılması çalışmalarında, çoğunlukla geleneksel makine öğrenme yöntemlerinin kullanıldığı, %89-%99.8 doğruluk oranında sınıflandırma başarısına ulaşıldığı görülmektedir.

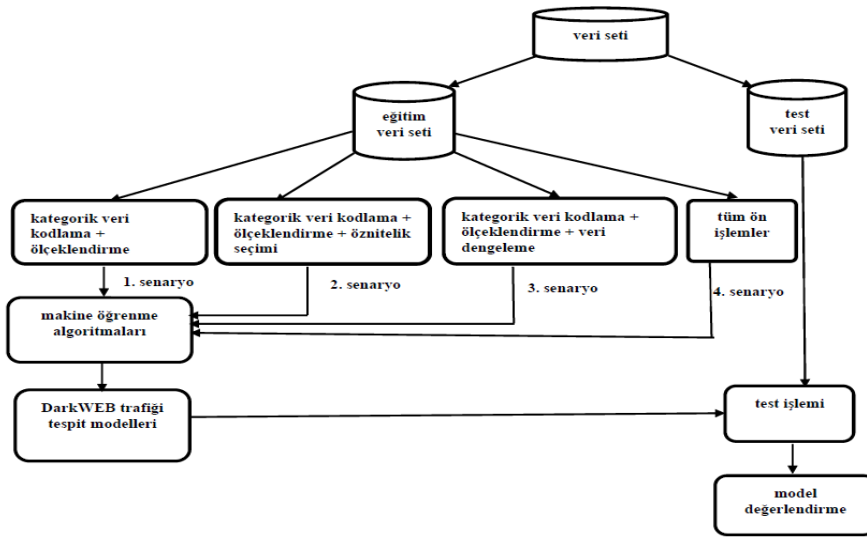
## 2. Önerilen Metodoloji (Recommended Methodology)

Bu çalışmada, DarkWEB trafiğinin yüksek doğrulukta tespiti ve sınıflandırması için üç aşamalı bir metodoloji önerilmiştir:

- 1) Veri setinin ön işlenmesi;
- 2) Ön işlenmiş veri setleri ve makine öğrenme algoritmaları ile saldırı tespit ve sınıflandırma modelleri oluşturulması;
- 3) Modellerin değerlendirilmesi;

Çalışmada önerilen metodoloji, Şekil 1’de gösterildiği gibi dört farklı senaryo ile uygulanmıştır.






Şekil 1. Önerilen metodolojinin akış diyagramı  
(Flowchart of the proposed methodology)


İlk senaryoda CIC-Darknet2020 veri setindeki kategorik veriler, label encoder ile kodlanmış ve veri setine min-max ölçeklendirme ön işlemi uygulanmıştır. 2. senaryoda 1. senaryonun uygulanması ile elde edilen veri setine, XGBoost gömülü öznitelik seçim yöntemi ile öznitelik seçimi ön işlemi uygulanmıştır. 3. senaryoda 1. senaryonun uygulanması ile elde edilen veri setine, ROS yöntemi ile veri dengeleme işlemi uygulanmıştır. 4. senaryoda 1. senaryonun uygulanması ile elde edilen veri setine, veri dengeleme işleminin ardından öznitelik seçimi ön işlemi uygulanmıştır. 4 farklı senaryonun uygulanması ile elde edilen veri setleri kullanılarak LR, GNB, KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost makine öğrenme algoritmaları eğitilmiş ve çok sayıda saldırı tespit ve sınıflandırma modeli oluşturulmuştur, son olarak modellerin performansları test veri seti kullanılarak karşılaştırılmıştır.

### 3.1. CIC-Darknet2020 veri seti (CIC-Darknet2020 dataset)

Bu çalışmada kullanılan veri seti, ISCXTor2016 ve ISCXVPN2016 veri setlerinin bir karışımı olan CIC-Darknet2020 veri setidir [18]. Veri seti toplam 141530 örnek, 83 öznitelik ve 2 sınıf içermektedir. Üst sınıfta Tor, Non-Tor, Non-VPN, VPN olmak üzere 4 farklı trafik türü vardır. Alt sınıf ise üst sınıftaki trafik türlerinin elde edildiği uygulama türlerini içermektedir. Bunlar: Audio-Stream, Browsing, Chat, E-mail, P2P, Transfer, Video-Stream, VOIP'tir. Şekil 2, trafik türlerinin; Şekil 3 ise uygulama türlerinin veri setindeki dağılımını göstermektedir.



Şekil 2. Trafik türlerinin veri setindeki dağılımı  
(Distribution of traffic types in the dataset)



Şekil 3. Uygulama türlerinin veri setindeki dağılımı  
(Distribution of application types in the dataset)

Şekiller incelendiğinde trafik ve uygulama türlerinin dengesiz dağıldığı, özellikle trafik türlerinden Non-Tor sınıfının baskın, Tor sınıfının ise çok az sayıda olduğu görülmektedir.

### 3.2. Ön işlemler (pre-treatments)

Veri setlerindeki eksik değerli veriler, sınıfların dengesiz dağılması, kategorik değerli veriler, farklı aralıklardaki veri değerleri, veri setini temsil etmede yetersiz öznitelikler, makine öğrenme algoritmalarının sınıflandırma performansını düşürebilir [19]. Bu çalışmada, kullanılan makine öğrenme algoritmalarından en üst düzeyde performans elde edebilmek için CIC-Darknet2020 veri setine veri temizleme ve düzenleme, kategorik veri kodlama, ölçeklendirme, öznitelik seçimi ve veri dengeleme ön işlemleri uygulanmıştır.

**Veri temizleme ve düzenleme:** CIC-Darknet2020 veri seti, üst sınıfta 4 trafik türünü (Tor, Non-Tor, Non-VPN, VPN), alt sınıfta bu trafik türlerinin elde edildiği 8 uygulama türünü (Audio-Stream, Browsing, Chat, E-mail, P2P, Transfer, Video-Stream, VOIP), 83 özniteliği ve 141530 örneği içermektedir. Eksik değer içeren veriler, tüm verilerin yaklaşık %0.0004 olduğu ve bu verilerin kaldırılmasının eğitim süreci üzerinde kayda değer bir etkisi olmayacağı düşünüldüğü için veri setinden kaldırılmıştır. Yine her örnek için farklı değerlere sahip ve sınıflandırma performansına herhangi bir etkisi olmadığı düşünülen Flow ID özniteliği; her örnekte aynı formatta olmadığı için ön işlenemeyen Timestamp özniteliği veri setinden kaldırılmıştır. Veri setinden mümkün olduğunca fazla bilgi elde etmek için Source IP, Destination IP öznitelikleri ise octet'lerine ayrılmıştır. Ayrıca ikili sınıflandırma için veri setine Non-Tor ve Non-VPN trafik türlerinin 0 (standart), Tor ve VPN trafik türlerinin ise 1 (şifreli) olarak kodlandığı Encryption sınıfı eklenmiştir. Şekil 4 ve Şekil 5, şifreli ve standart trafiğe ait uygulamaların veri setindeki dağılımını göstermektedir. CIC-Darknet2020 veri setine uygulanan bu düzenlemeler sonunda 2, 4 ve 8 değişkene sahip üç sınıftan (Category, Subcategory, Encryption), 87 öznitelik ve 141481 örnekten oluşan bir veri seti elde edilmiştir.

**Kategorik veri kodlama:** Çoğu makine öğrenme algoritması kategorik değere sahip verileri, aralarında matematiksel ya da mantıksal bir ilişki bulunmadığı için işleyemez. Bu nedenle kategorik değerler sayısal değerlere dönüştürülmelidir. Bu çalışmada CIC-Darknet2020 veri setindeki kategorik değerli veriler, az sayıda değişkene sahip oldukları için en klasik yöntem olan label encoding ile sayısal formata dönüştürülmüştür.

**Ölçeklendirme:** Çalışmada, CIC-Darknet2020 veri setindeki farklı aralıklardaki veri değerlerinin ortak bir ölçekte eşleştirilerek söz konusu verilerin daha objektif karşılaştırılabilmesi için en küçük değere sahip veri 0, en büyük değere sahip veri 1 olacak şekilde, diğer bütün veri değerlerinin bu 0-1 aralığına yayıldığı min-max ölçeklendirme yöntemi kullanılmıştır.

**Öznitelik seçimi:** Ağ trafiğinde kullanılan protokolü ve uygulamaları ayırt etmek, trafik türlerini tanımlamak ya da sınıflandırmak için paket boyutu ve paket varış aralığı gibi öznitelikler belirleyicidir. Sınıflandırmaya en fazla katkısı olan özniteliklerin seçimi ile daha hızlı, daha doğru trafik türü tespiti ve sınıflandırması yapılabilir. Çalışmada, veri setini temsil etmede yetersiz, algoritmanın sınıflandırma performansını düşürecek öznitelikleri veri setinden çıkarmak için gömülü öznitelik seçimi yöntemi olan XGBoost kullanılmıştır. Yöntemin seçilmesinin nedeni, gömülü yöntemlerin aşırı öğrenmeye, sarmal ve filtreleme yöntemlerine kıyasla daha az eğilimli olması ve XGBoost ile hesaplama maliyetinin düşük olması, topluluk öğrenme algoritmaları içerisinde ve çevrim içi veri bilimcileri ile makine öğrenme uygulayıcıları topluluğu olan kaggle'in düzenlediği yarışmalarda açık ara başarılı olmasıdır [20]. XGBoost gömülü öznitelik seçim yöntemi, öznitelikleri önemlerine göre sıralamakta ve önem değerleri için bir eşik değeri belirlenerek bu eşik değerinin üzerinde önem derecesine sahip öz nitelikler seçilebilmektedir. Fakat eşik değerinin ne olacağı bilgisi açık olmadığı için çalışmada, en iyi başarı oranlarını veren eşik değerleri, deneme yanılma yoluyla belirlenmiştir [21].

**Veri dengeleme:** Dengesiz sınıflandırma, veri setindeki örneklerin sınıflar arasındaki dağılımının eşit olmadığı bir sınıflandırma problemidir. Sınıf dağılımı dengesiz bir veri seti ile sınıflandırma modeli oluşturmak, modelde yanlılığa neden olarak modelin azınlık sınıfının aleyhine tahmin performansı ile sonuçlanır ki çoğu sınıflandırma probleminde ana amaç azınlık sınıfın doğru sınıflandırılmasıdır. Bu çalışmada da kullanılan veri setinde sınıflar arasında net bir dengesizlik söz konusudur ve bu sorunun çözümü için %70-%30 eğitim ve test veri seti olarak ayrılan CIC-Darknet2020 veri setinin eğitim verilerine, ROS veri dengeleme yöntemi uygulanmıştır. ROS yöntemi ile azınlık sınıftan örnekler rastgele kopyalanır ve eğitim veri setine eklenir, bu şekilde azınlık sınıftan örnekler eğitim veri setine birden çok kez eklenebilir. Bu yöntem ile bir sınıflandırıcı, görünüşte doğru olan ancak aslında çoğaltılmış örnekleri kapsayan kurallar oluşturabilir [22]. Tüm bunlar kurulan modelin aşırı öğrenme olasılığını artırabilir. Bu nedenle, yöntemin etkisi hakkında bilgi edinmek için, yüksek hızda örneklemeden sonra hem eğitim hem de test veri setlerindeki performansı izlemek ve sonuçları orijinal veri setindeki aynı algoritmayla karşılaştırmak önerilmiştir [23].

Çalışmada ROS yöntemi kullanılırken bu öneriler dikkate alınmıştır. Ayrıca ROS yönteminde “sampling strategy” parametresi ile ikili sınıflandırma problemleri için azınlık sınıfın, çoğunluk sınıfının ne kadar fazlasının örneklenmesinin yapılacağını belirlemek mümkündür. Fakat bu çalışmada 2'li sınıflandırma ile birlikte 4'lü ve 8'li sınıflandırmalar yapıldığı için bu öneri uygulanamamıştır. Eğitim veri setinde veri dengeleme ön işleminden önce ve sonra Encryption, Category, Subcategory sınıflarına ait değişkenlerin örnek sayısı Tablo 2 'de gösterilmiştir.

Tablo 2. ROS öncesi ve sonrası Encryption, Category, Subcategory sınıflarına ait değişkenlerin örnek sayısı  
(Number of examples of variables belonging to Encryption, Category, Subcategory classes before and after ROS)

Encryption sınıfı	ROS öncesi örnek sayısı	ROS sonrası örnek sayısı
Şifreli (0)	82018	82018
Standart (1)	17018	82018


  

Category sınıfı	ROS öncesi örnek sayısı	ROS sonrası örnek sayısı
Non-Tor (0)	93309	65180
NonVPN (1)	23861	65180
Tor (2)	1392	65180
VPN (3)	22919	65180


  

Subcategory sınıfı	ROS öncesi örnek sayısı	ROS sonrası örnek sayısı
Audio-Streaming (0)	18050	33903
Browsing (1)	32808	33903
Chat (2)	11473	33903
Email (3)	6143	33903
File-Transfer (4)	11173	33903
P2P (5)	48520	33903
VOIP (6)	3566	33903
Video-Streaming (7)	9748	33903

Şekil 4 ve Şekil 5'de CIC-Darknet2020 veri setindeki trafik türlerinin üretildiği uygulama türlerinin şifreli ve standart trafiğe ait dağılımları gösterilmektedir.



Şekil 4. Şifreli trafiğe ait uygulama türlerinin dağılımı  
(Distribution of application types for standard traffic)



Şekil 5. Standart trafiğe ait uygulama türlerinin dağılımı  
(Distribution of application types for encrypted traffic)

Şekil 4 ve 5'e göre veri setinde şifreli ağ trafiğini en çok içeren uygulama türü Audio-Streaming, en az içeren uygulama türü Browsing ve P2P'tir. Standart trafikte ise durum neredeyse tam tersidir. Bu durum uygulama türlerinin şifreli ya da standart trafiğe göre değişiklik gösterdiğini ve uygulama türüne göre sınıflandırma yapılmasının anlamlı olabileceğini göstermektedir.

### 3.3. DarkWEB trafiği tespit ve sınıflandırma modellerinin oluşturulması (creation of DarkWEB traffic detection and classification models)

Önerilen metodolojinin 2. aşamasında LR, GNB, KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost makine öğrenme algoritmaları, metodolojinin 1. aşamasında uygulanan ön işlemler sonucu elde edilen veri setleri ile eğitilerek çok sayıda DarkWEB trafiği tespit ve sınıflandırma modeli oluşturulmuştur. Oluşturulan modeller ile **Encryption** (Şifreli, Standart), **Category** (Tor, Non-Tor, Non-VPN, VPN), **Subcategory** (Audio-Stream, Browsing, Chat, E-mail, P2P, Transfer, Video-Stream, VOIP) sınıfları olmak üzere 2'li, 4'lü, 8'li sınıflandırmalar yapılmıştır.

### 3.4. Modellerin değerlendirilmesi (evaluation of models)

Önerilen metodolojinin 3. aşamasında, ön işlenmiş veri setleri ile makine öğrenme algoritmaları kullanılarak oluşturulan modellerin performansları, test veri seti ile Tablo 3'te gösterilen karışıklık matrisinden elde edilen değerlendirme metrikleri ölçüt alınarak değerlendirilmiştir.

Tablo 3. Karışıklık matrisi (Confusion matrix)

Karışıklık matrisi	Tahmin edilen pozitif (saldırı)	Tahmin edilen negatif (normal)
Gerçek Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
Gerçek Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

$$\text{Doğruluk} = (DP + DN) \setminus (DP + DN + YP + YN)$$

$$\text{Kesinlik} = DP \setminus (DP + YP)$$

$$\text{Duyarlılık} = DP \setminus (DP + YN)$$

$$\text{F1-Ölçütü} = 2 * ((kesinlik * duyarlılık) \setminus (kesinlik + duyarlılık))$$

## 4. Uygulama Sonuçları ve Tartışmalar (Implementation Results and Discussions)

Yapılan çalışmada önerilen metodoloji dört farklı senaryo ile uygulanmış, her senaryonun uygulanması sonucunda DarkWEB trafiği tespit ve sınıflandırma modelleri oluşturulmuş, test veri seti kullanılarak modellerin başarı durumları, doğruluk, kesinlik, duyarlılık ve F1-Ölçütü metrikleriyle analiz edilmiştir.

### 4.1. 1.Senaryo: Makine öğrenme algoritmalarının label encoding ve min-max ölçeklendirme ön işlemleri yapılan veri setleri üzerinde çalıştırılması (scenario 1: running machine learning algorithms on datasets with label encoding and min-max scaling pre-processing)

CIC-Darknet2020 veri setine label encoding ve min-max ölçeklendirme ön işlemleri uygulanarak LR, GNB, KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost algoritmaları ile modeller oluşturulmuş ve test veri seti ile test edilmiştir. Birinci senaryonun uygulanması ile alınan sonuçlar (bkz. Tablo 4) değerlendirildiğinde; 2'li (şifreli-standart) ve 4'lü (trafik türü) sınıflandırmada KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost ile oluşturulan modellerde dört metriğin değerinin de birbirine yakın ve oldukça yüksek olduğu, LR ve GNB ile kurulan modellerde ise performansın diğer yedi algoritma ile kurulan modellere göre daha düşük olduğu görülmektedir.


8'li (uygulama türü) sınıflandırmada ise beklenildiği gibi 2'li ve 4'lü sınıflandırmaya kıyasla performansın düştüğü, %94 ile en yüksek doğruluk değerinin XGBoost ile kurulan modelde, %32.6 ile en düşük doğruluk değerinin ise GNB ile kurulan modelde olduğu görülmüştür.

Algoritmalar	Doğruluk			Kesinlik			Duyarlılık			F1 -Ölçütü		
	Sınıf sayısı			Sınıf sayısı			Sınıf sayısı			Sınıf sayısı		
	2'li	4'lü	8'li	2'li	4'lü	8'li	2'li	4'lü	8'li	2'li	4'lü	8'li
XGBoost	0.999	0.999	0.940	0.999	0.999	0.940	0.999	0.999	0.940	0.999	0.999	0.940
LGBM	0.999	0.999	0.939	0.999	0.999	0.939	0.999	0.999	0.939	0.999	0.999	0.938
RF	0.999	0.999	0.931	0.999	0.999	0.931	0.999	0.999	0.931	0.999	0.999	0.931
CatBoost	0.999	0.999	0.930	0.999	0.999	0.930	0.999	0.999	0.930	0.999	0.999	0.929
DT	0.999	0.998	0.928	0.999	0.998	0.928	0.999	0.998	0.928	0.999	0.998	0.928
MLP	0.998	0.998	0.871	0.998	0.998	0.872	0.998	0.998	0.871	0.998	0.998	0.868
KNN	0.997	0.996	0.878	0.997	0.995	0.876	0.997	0.996	0.878	0.997	0.995	0.876
GNB	0.859	0.729	0.326	0.903	0.766	0.452	0.859	0.729	0.326	0.871	0.699	0.269
LR	0.986	0.973	0.725	0.986	0.973	0.709	0.986	0.973	0.725	0.986	0.973	0.709

Tablo 4. Senaryo 1: Label encoding+min-max ölçeklendirme ön işlemleri uygulanarak alınan sonuçlar  
(Scenario 1: Results by applying label encoding+min-max scaling preprocesses)

#### 4.2.2. Senaryo: Makine öğrenme algoritmalarının label encoding, min-max ölçeklendirme ve öznelik seçimi ön işlemleri yapılan veri setleri üzerinde çalıştırılması (scenario 2: running machine learning algorithms on datasets with label encoding, min-max scaling and feature selection pre-processing)

2. senaryoda 1. senaryonun uygulanması ile elde edilen veri setinden, XGBoost gömülü öznelik seçim yöntemi ile öznelikler seçilmiştir. Seçilen özneliklerin, önem sıralaması Şekil 6'daki gibidir.



Şekil 6. XGBoost gömülü öznelik seçim yönteminin öznelik önem sıralaması  
(Attribute importance ranking of XGBoost embedded feature selection method)

Önem katsayısı en yüksek öznelikleri seçmek için deneme yanılma yoluna gidilerek, eşik değer 0.001 olarak belirlenmiş ve 87 öznelik içerisinde 34'ü seçilmiştir. Seçilen öznelikler Tablo 5'te yer almaktadır.

Tablo 5. XGBoost gömülü öznelik seçim yöntemi ile seçilen öznelikler  
(Attributes selected with the XGBoost embedded feature selection method)

Seçilen öznelikler
'Src Port', 'Dst Port', 'Total Fwd Packet', 'Total Length of Fwd Packet', 'Total Length of Bwd Packet', 'Fwd Packet Length Mean', 'Bwd Packet Length Min', 'Flow IAT Mean', 'Flow IAT Min', 'Fwd IAT Std', 'Bwd IAT Total', 'Fwd Header Length', 'Packet Length Min', 'Packet Length Mean', 'Packet Length Std', 'FIN Flag Count', 'RST Flag Count', 'Average Packet Size', 'Subflow Bwd Bytes', 'FWD Init Win Bytes', 'Bwd Init Win Bytes', 'Fwd Act Data Pkts', 'Fwd Seg Size Min', 'Idle Mean', 'Idle Std', 'Idle Max', 'Idle Min', 'oct1', 'oct2', 'oct3', 'oct4', 'oct5', 'oct6', 'oct7'

Label encoding, min-max ölçeklendirme ve öznelik seçimi ön işlemleri uygulanan veri seti ve LR, GNB, KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost algoritmaları ile oluşturulan modellerin test veri seti üzerindeki performansları Tablo 6'da yer almaktadır.

Tablo 6. Senaryo 2: Label encoding+min-max ölçeklendirme+öznitelik seçimi ön işlemleri uygulanarak alınan sonuçlar  
(Scenario 2: Results obtained by applying label encoding + min-max scaling + feature selection pre-processes)

Algoritmalar	Doğruluk			Kesinlik			Duyarlılık			F1-Ölçütü		
	Sınıf sayısı			Sınıf sayısı			Sınıf sayısı			Sınıf sayısı		
	2'li	4'lü	8'li	2'li	4'lü	8'li	2'li	4'lü	8'li	2'li	4'lü	8'li
XGBoost	0.999	0.999	0.940	0.999	0.999	0.939	0.999	0.999	0.940	0.999	0.999	0.939
LGBM	0.999	0.999	0.937	0.999	0.999	0.937	0.999	0.999	0.937	0.999	0.999	0.936
RF	0.999	0.999	0.940	0.999	0.999	0.939	0.999	0.999	0.940	0.999	0.999	0.939
CatBoost	0.999	0.999	0.929	0.999	0.999	0.929	0.999	0.999	0.929	0.999	0.999	0.928
DT	0.999	0.999	0.930	0.999	0.999	0.930	0.999	0.999	0.930	0.999	0.999	0.930
MLP	0.997	0.998	0.860	0.997	0.998	0.861	0.997	0.998	0.860	0.997	0.998	0.857
KNN	0.997	0.996	0.878	0.997	0.996	0.876	0.997	0.996	0.878	0.997	0.996	0.876
GNB	0.968	0.907	0.389	0.968	0.927	0.520	0.968	0.907	0.389	0.968	0.914	0.310
LR	0.980	0.964	0.698	0.980	0.964	0.683	0.980	0.964	0.698	0.980	0.964	0.679

Tablo 6'daki sonuçlar değerlendirildiğinde 2'li sınıflandırmada KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost ile oluşturulan modellerde dört metriğin değerinde 1.senaryoya göre pek bir değişiklik olmamıştır. GNB ile kurulan modelde ise doğruluk değeri %85.9'dan %96.8'e yükselmiştir. 4'lü sınıflandırmada KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost ile oluşturulan modellerde dört metriğin değerinde 1.senaryoya göre pek bir değişiklik olmamıştır. GNB ile kurulan modelde ise doğruluk değeri %72.9'dan %90.7'ye yükselmiş, LR ile kurulan modelde ise %97.3'ten %96.4'e küçük bir düşüş yaşanmıştır. 8'li sınıflandırmada KNN, DT, XGBoost, LightGBM ve CatBoost ile oluşturulan modellerde dört metriğin değerinin de 1.senaryoya göre pek bir değişiklik olmamıştır. RF ile kurulan modelde doğruluk değerinde %93.1'den %94'e bir yükseliş olmuştur. MLP ile kurulan modelde doğruluk değerinde %87.1'den %86'ya bir düşüş olmuştur. GNB ile kurulan modelde ise doğruluk değeri %32.6'dan %38.9'a yükselmiş, LR ile kurulan modelde ise %72.5'ten %69.8'e düşmüştür. Öznitelik seçimi ön işlemi, modellerin sınıflandırma performanslarında küçük çaplı yükseliş ve azalışlara neden olmakla beraber beklenen performans artışı sağlamamıştır. Bu artışı gözlemleyene dek farklı öznitelik seçim yöntemleri ve farklı eşik değerleri denenebilir.

#### 4.3. 3.Senaryo: Makine öğrenme algoritmalarının label encoding, min-max ölçeklendirme ve veri dengeleme ön işlemleri yapılan veri setleri üzerinde çalıştırılması (scenario 3: running machine learning algorithms on datasets with label encoding, min-max scaling and data balancing pre-processing)

3. senaryoda CIC-Darknet2020 veri setine label encoding, min-max ölçeklendirme ve veri dengeleme ön işlemleri uygulanarak LR, GNB, KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost algoritmaları ile modeller oluşturulmuş ve test veri seti ile test edilmiştir. 3.senaryonun uygulanması ile alınan sonuçlar (bkz. Tablo 7) değerlendirildiğinde; 2'li sınıflandırmada KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost ile oluşturulan modellerde dört metriğin değerinde 1.senaryoya göre pek bir değişiklik olmamıştır. GNB ile kurulan modelde ise doğruluk değerinde %1.8'lik, LR ile kurulan modelde ise %0.4'lük bir düşüş görülmüştür. 4'lü sınıflandırmada KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost ile oluşturulan modellerde dört metriğin değerinde 1.senaryoya göre pek bir değişiklik olmamıştır. GNB ile kurulan modelde ise doğruluk değerinde %1.8'lik bir yükseliş, LR ile kurulan modelde ise %1.7'lik bir düşüş görülmüştür.

Tablo 7. Senaryo3: Label encoding+min-max ölçeklendirme+veri dengeleme ön işlemleri uygulanarak alınan sonuçlar


Algoritmalar	Doğruluk			Kesinlik			Duyarlılık			F1 -Ölçütü		
	Sınıf sayısı			Sınıf sayısı			Sınıf sayısı			Sınıf sayısı		
	2'li	4'lü	8'li	2'li	4'lü	8'li	2'li	4'lü	8'li	2'li	4'lü	8'li
XGBoost	0.999	0.999	0.936	0.999	0.999	0.942	0.999	0.999	0.936	0.999	0.999	0.937
LGBM	0.999	0.999	0.933	0.999	0.999	0.940	0.999	0.999	0.933	0.999	0.999	0.934
RF	0.999	0.998	0.934	0.999	0.998	0.936	0.999	0.998	0.934	0.999	0.998	0.934
CatBoost	0.999	0.999	0.928	0.999	0.999	0.935	0.999	0.999	0.928	0.999	0.999	0.929
DT	0.999	0.998	0.928	0.999	0.998	0.928	0.999	0.998	0.928	0.999	0.998	0.928
MLP	0.996	0.995	0.862	0.995	0.996	0.877	0.995	0.995	0.862	0.995	0.995	0.865
KNN	0.995	0.996	0.889	0.997	0.996	0.894	0.997	0.996	0.889	0.997	0.996	0.891
GNB	0.841	0.747	0.325	0.895	0.796	0.463	0.841	0.747	0.325	0.855	0.736	0.269
LR	0.982	0.956	0.687	0.983	0.961	0.730	0.982	0.956	0.687	0.982	0.958	0.697

(Scenario 3: Results obtained by applying label encoding + min-max scaling + data balancing pre-processes)

8'li sınıflandırmada XGBoost ile kurulan modelin doğruluğunda %0.4'lük bir düşüş, LGBM'de %0.6'lık bir düşüş, CatBoost'ta %0.2'lik bir düşüş, MLP'de %0.9'luk bir düşüş, RF'de %0.3'lük bir yükseliş, LR'de %3.8'lik bir düşüş, KNN'de %1.1'lik bir yükseliş görülmüştür. DT ve GNB'de pek bir değişiklik gözlemlenmemiştir. Özetle 3. senaryonun uygulanması, özellikle veri dengeleme işlemi, modellerin 8'li sınıflandırma performanslarında önemli bir değişikliğe neden olmamıştır. 3.senaryonun uygulanması ile modellerin performanslarında genel anlamda küçük çaplı düşüşler olduğu görülmüştür.

4.4. 4.Senaryo: Makine öğrenme algoritmalarının label encoding, min-max ölçeklendirme, veri dengeleme ve öznitelik seçimi ön işlemleri yapılan veri setleri üzerinde çalıştırılması (scenario 4: running machine learning algorithms on data sets with label encoding, min-max scaling, data balancing and feature selection pre-processing.)

4. senaryoda label encoding, min-max ölçeklendirme, veri dengeleme ön işlemleri uygulanan veri setinden XGBoost gömülü öznitelik seçim yöntemi ile öznitelik seçimi yapılmıştır. Seçilen öznitelikler Şekil 7'de görülmektedir.



Şekil 7. Veri dengeleme ön işlemi yapılan veri setinde XGBoost yönteminin öznitelik önem sıralaması (Attribute importance ranking of the XGBoost method in the data set with data balancing pre-processing)

Önem katsayısı en yüksek öznitelikleri seçmek için deneme yanılma yoluna gidilerek eşik değer 0.001 olarak belirlenmiş ve 87 öznitelik içerisinde 38'i seçilmiştir. Seçilen öznitelikler Tablo 8'de yer almaktadır.

Tablo 8. Label encoding min-max ölçeklendirme veri dengeleme ön işlemleri uygulanan veri setinden XGBoost gömülü öznitelik seçim yöntemi ile seçilen öznitelikler (Attributes selected with the XGBoost embedded feature selection method from the dataset with label encoding min-max scaling data balancing pre-processing applied.)

Seçilen öznitelikler
'Src Port', 'Dst Port', 'Total Fwd Packet', 'Total Length of Fwd Packet', 'Total Length of Bwd Packet', 'Fwd Packet Length Min', 'Fwd Packet Length Mean', 'Fwd Packet Length Std', 'Bwd Packet Length Max', 'Bwd Packet Length Min', 'Bwd Packet Length Mean', 'Flow Bytes/s', 'Flow IAT Mean', 'Flow IAT Std', 'Flow IAT Min', 'Packet Length Min', 'Packet Length Mean', 'Packet Length Std', 'FIN Flag Count', 'RST Flag Count', 'Down/Up Ratio', 'Average Packet Size', 'Subflow Bwd Bytes', 'FWD Init Win Bytes', 'Fwd Act Data Pkts', 'Fwd Seg Size Min', 'Idle Mean', 'Idle Std', 'Idle Max', 'Idle Min', 'oct1', 'oct2', 'oct3', 'oct4', 'oct5', 'oct6', 'oct7', 'oct8'

4.senaryonun uygulanması ile elde edilen modellerin test veri seti üzerindeki performansları Tablo 9'da yer almaktadır.

Tablo 9. Senaryo 4: Tüm ön işlemlerin uygulanması ile alınan sonuçlar  
(Scenario 4: Results obtained by applying all pre-treatments)

Algoritmalar	Doğruluk			Kesinlik			Duyarlılık			F1 -Ölçütü		
	Sınıf sayısı			Sınıf sayısı			Sınıf sayısı			Sınıf sayısı		
	2'li	4'lü	8'li	2'li	4'lü	8'li	2'li	4'lü	8'li	2'li	4'lü	8'li
XGBoost	0.999	0.999	0.934	0.999	0.999	0.939	0.999	0.999	0.934	0.999	0.999	0.935
LGBM	0.999	0.999	0.931	0.999	0.999	0.939	0.999	0.999	0.931	0.999	0.999	0.932
RF	0.999	0.999	0.940	0.999	0.999	0.942	0.999	0.999	0.940	0.999	0.999	0.941
CatBoost	0.999	0.999	0.925	0.999	0.999	0.933	0.999	0.999	0.925	0.999	0.999	0.926
DT	0.999	0.998	0.930	0.999	0.998	0.930	0.999	0.998	0.930	0.999	0.998	0.930
MLP	0.997	0.993	0.861	0.997	0.995	0.879	0.997	0.993	0.861	0.997	0.993	0.861
KNN	0.996	0.997	0.887	0.996	0.997	0.892	0.996	0.997	0.887	0.996	0.997	0.888
GNB	0.954	0.879	0.467	0.957	0.913	0.553	0.954	0.879	0.467	0.955	0.892	0.420
LR	0.975	0.940	0.654	0.977	0.950	0.703	0.975	0.940	0.654	0.976	0.944	0.667

4.senaryonun uygulanması ile alınan sonuçlar (bkz. Tablo 9) değerlendirildiğinde; 2'li sınıflandırmada KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost ile oluşturulan modellerde dört metriğin değerinde 1.senaryoya göre pek bir değişiklik olmamıştır. GNB ile kurulan modelde ise doğruluk değerinde %9.5'lik bir yükseliş, LR ile kurulan modelde ise %1.1'lik bir düşüş görülmüştür. 4'lü sınıflandırmada KNN, DT, RF, XGBoost, LightGBM ve CatBoost ile oluşturulan modellerde dört metriğin değerinde 1.senaryoya göre pek bir değişiklik olmamıştır. MLP'de %0.5'lik, LR ile kurulan modelde ise %3.3'lük bir düşüş görülmüştür. GNB ile kurulan modelde ise doğruluk değerinde %15'lik bir yükseliş, görülmüştür. 8'li sınıflandırmada XGBoost ile kurulan modelin doğruluk değerinde %0.6'lık, LGBM'de %0.8'lik, CatBoost'ta %0.5'lik, MLP'de %1'lük, LR'de %7.1'lik düşüşler gözlemlenirken; RF'de %0.9'lük, DT'de %0.2'lik, KNN'de %0.9'lük bir yükseliş, GNB'de % 14.1'lik yükseliş gözlemlenmiştir.

Dört senaryonun uygulanması sonucunda, modellerin 2'li ve 4'lü sınıflandırmada doğruluk oranlarında pek bir değişiklik olmamıştır ve senaryolar boyunca doğruluk oranı KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost ile oluşturulan modellerde %99.9-%99.3 arasında bir değer almıştır. Fakat 8'li sınıflandırmada senaryolar boyunca modellerin doğruluk oranlarında değişkenlik gözlemlenmiştir. Senaryolar boyunca 8'li sınıflandırmada modellerin doğruluk metriklerindeki değişimin görüldüğü Tablo 10'daki sonuçlar değerlendirildiğinde: XGBoost'un %94 doğruluk oranı ile en başarılı olduğu senaryolar 1. ve 2. senaryolardır. LGBM'in %93.9 doğruluk oranı ile en başarılı olduğu senaryo 1.senaryodur. RF'in %94 doğruluk oranı ile en başarılı olduğu senaryolar 2. ve 4. senaryolardır. CatBoost'un %93 doğruluk oranı ile en başarılı olduğu senaryo 1. senaryodur. DT'nin %93 doğruluk oranı ile en başarılı olduğu senaryo 2. ve 4. senaryolardır. MLP'nin %87.1 doğruluk oranı ile en başarılı olduğu senaryo 1.senaryodur. KNN'nin %88.9 doğruluk oranı ile en başarılı olduğu senaryo 3.senaryodur. GNB'nin %46.7 doğruluk oranı ile en başarılı olduğu senaryo 4.senaryodur. LR'nin %72.5 doğruluk oranı ile en başarılı olduğu senaryo 1.senaryodur.

Tablo 10. 8'li sınıflandırmada senaryolar boyunca modellerin sınıflandırma doğruluğu değişimleri  
(Classification accuracy changes of models across scenarios in 8-class classification)

Algoritmalar	1.senaryo	2.senaryo	3.senaryo	4.senaryo
XGBoost	<b>%94</b>	<b>%94</b>	%93.6	%93.4
LGBM	<b>%93.9</b>	%93.7	%93.3	%93.1
RF	%93.1	<b>%94</b>	%93.4	<b>%94</b>
CatBoost	<b>%93</b>	%92.9	%92.8	%92.5
DT	%92.8	<b>%93</b>	%92.8	<b>%93</b>
MLP	<b>%87.1</b>	%86	%86.2	%86.1
KNN	%87.8	%87.8	<b>%88.9</b>	%88.7
GNB	%32.6	%38.9	%32.5	<b>%46.7</b>
LR	<b>%72.5</b>	%69.8	%68.7	%65.4

Tablo 10 ile ilgili genel bir çıkarım yapılırsa, 8'li sınıflandırmada modellerin sınıflandırma doğruluğu metriğinde, en yüksek değerlere 1. ve 4. senaryoların uygulanması sonucunda ulaşılmıştır.

Senaryolar boyunca 8'li sınıflandırmada modellerin, dengesiz veri setleri ile yapılan çalışmalarda dikkate alınması gereken bir metrik olan F1-Ölçütü'ndeki değişimin görüldüğü Tablo 11'deki sonuçlar değerlendirildiğinde ise: XGBoost'un %94 doğruluk oranı ile en başarılı olduğu senaryo 1. senaryodur.



LGBM'in %93.8 doğruluk oranı ile en başarılı olduğu senaryo da 1.senaryodur. RF'in %94.1 doğruluk oranı ile en başarılı olduğu senaryo 4. senaryodur. CatBoost'un %92.9 doğruluk oranı ile en başarılı olduğu senaryo 1. senaryodur. DT'nin %93 doğruluk oranı ile en başarılı olduğu senaryo 2. ve 4. senaryolardır. MLP'nin %86.8 doğruluk oranı ile en başarılı olduğu senaryo 1.senaryodur. KNN'nin %89.1 doğruluk oranı ile en başarılı olduğu senaryo 3.senaryodur. GNB'nin %42 doğruluk oranı ile en başarılı olduğu senaryo 4.senaryodur. LR'nin %70.9 doğruluk oranı ile en başarılı olduğu senaryo 1.senaryodur.

Tablo 11. 8'li sınıflandırmada senaryolar boyunca modellerin F1-Ölçütü değişimleri  
(F1-Criteria changes of models across scenarios in 8-class classification)

Algoritmalar	1.senaryo	2.senaryo	3.senaryo	4.senaryo
<i>XGBoost</i>	<b>0.940</b>	0.939	0.937	0.935
<i>LGBM</i>	<b>0.938</b>	0.936	0.934	0.932
<i>RF</i>	0.931	0.939	0.934	<b>0.941</b>
<i>CatBoost</i>	<b>0.929</b>	0.928	<b>0.929</b>	0.926
<i>DT</i>	0.928	<b>0.930</b>	0.928	<b>0.930</b>
<i>MLP</i>	<b>0.868</b>	0.857	0.865	0.861
<i>KNN</i>	0.876	0.876	<b>0.891</b>	0.888
<i>GNB</i>	0.269	0.310	0.269	<b>0.420</b>
<i>LR</i>	<b>0.709</b>	0.679	0.697	0.667

Tablo 11 ile ilgili genel bir çıkarım yapılırsa, 8'li sınıflandırmada modellerin F1-Ölçütü metriğinde, en yüksek değerlere 1. ve 4. senaryoların uygulanması sonucunda ulaşılmıştır. Özetle senaryolara göre modellerin 8'li sınıflandırmada F1-Ölçütü metriğindeki değişimleri ile doğruluk metriğindeki değişimleri benzerdir ve en başarılı sonuçlar, kategorik veri kodlama ve ölçeklendirme ön işlemlerinin uygulandığı 1.senaryo ile kategorik veri kodlama, ölçeklendirme, veri dengeleme ön işlemlerinin uygulandığı veri setinden XGBoost gömülü yöntemle öznitelik seçiminin yapıldığı, özetle tüm ön işlemlerin yapıldığı 4.senaryonun uygulanması ile elde edilmiştir.

## 5. Sonuçlar ve Öneriler (Conclusions and Recommendations)

Bu çalışmada, DarkWEB trafiğinin yüksek doğrulukta tespiti ve sınıflandırılması için veri setinin ön işlenmesi, ön işlenmiş veri setleri ve makine öğrenme algoritmaları ile DarkWEB trafiği tespit ve sınıflandırma modelleri oluşturulması, modellerin değerlendirilmesi olmak üzere üç aşamalı bir metodoloji önerilmiştir. Çalışmada önerilen metodoloji dört farklı senaryo ile uygulanmıştır. Metodolojinin 1.aşamasında, veri setine kategorik veri kodlama, ölçeklendirme, öznitelik seçimi ve veri dengeleme ön işlemleri ayrı ayrı ve birlikte uygulanarak 4 farklı senaryo için 4 farklı veri seti oluşturulmuştur. Metodolojinin 2.aşamasında, 1.aşamada oluşturulan veri setleri ve LR, GNB, KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost makine öğrenme algoritmaları kullanılarak DarkWEB trafiği tespit ve sınıflandırma modelleri oluşturulmuştur. Oluşturulan modeller ile **Encryption** (Şifreli, Standart), **Category** (Tor, Non-Tor, Non-VPN, VPN), **Subcategory** (Audio-Stream, Browsing, Chat, E-mail, P2P, Transfer, Video-Stream, VOIP) sınıfları olmak üzere 2'li, 4'lü, 8'li sınıflandırmalar yapılmıştır.

Metodolojinin 3.aşamasında oluşturulan modellerin performansları doğruluk, kesinlik, duyarlılık ve F1-Ölçütü metrikleri ile değerlendirilmiştir. 2'li ve 4'lü sınıflandırmada doğruluk oranları birbirine yakın ve KNN, MLP, DT, RF, XGBoost, LightGBM ve CatBoost ile oluşturulan modellerde %99.9-%99.3 arasında bir değer almıştır. 2'li sınıflandırmada GNB'de %96.8 ile en yüksek doğruluk oranı 2.senaryo ile elde edilmiştir. LR'de ise %98.6 ile en yüksek doğruluk oranı 1.senaryo ile elde edilmiştir. 4'lü sınıflandırmada, GNB'de %90.7 ile en yüksek doğruluk oranı 2.senaryo ile elde edilmiştir. LR'de ise %97.3 ile en yüksek doğruluk oranı, 1.senaryo ile elde edilmiştir. 8'li sınıflandırma ise en başarılı modeller, label encoding yöntemi ile kategorik veri kodlama, min-max ölçeklendirme ve XGBoost öznitelik seçimi ön işlemlerinin yapıldığı 2. senaryonun uygulanması sonucunda elde edilen %94 doğruluk oranıyla XGBoost ve RF ile kurulan modeller olmuştur. Veri dengelemenin öne çıktığı 3. senaryonun ve öznitelik seçimin öne çıktığı 2.senaryonun uygulanması ile beklenen performans artışı sağlanamamıştır. Bu sonuçların 3.senaryo için nedeninin, veri dengeleme için kullanılan ROS yönteminde, azınlık sınıfı örneklerinin tam kopyaları oluşturulduğu için kullanılan sınıflandırıcının, görünüşte doğru olan ancak aslında çoğaltılmış örnekleri kapsayan kurallar oluşturmuş ve sonuçta fazla uydurma olasılığını arttırmış olması sonucuna varılmıştır. Veri dengelemenin neden olduğu

aşırı öğrenmeyi azaltmak için GAN (Generative Adversarial Networks) gibi daha gelişmiş yöntemlerin kullanılması hedeflenmektedir. 2. senaryonun uygulanması ile beklenen performans artışını sağlamak için ise daha farklı öznitelik seçim yöntemleri ve eşik değerlerinin kullanılması önerilmektedir.

Gelecekte yapılacak çalışmalarda, DarkWEB trafiği tespit modellerinin performanslarınıca arttırmak için veri setine uygulanan ön işlemlerin kullanılacak her bir algoritmaya ve veri setine uygun seçilmesi, en doğru hiper-parametrelerin belirlenebilmesi için çok sayıda parametre kombinasyonunun denenmesine olanak sağlayacak kaynakların temin edilmesi, oluşturulacak modellerinin başarısının, güncel ve farklı veri setleri ile test edilerek güvenilirliği yüksek DarkWEB trafiği tespit ve sınıflandırma modelleri geliştirilmesi, ayrıca son yıllarda oldukça başarılı sonuçlar alınan derin öğrenme modellerinin kullanımı da hedeflenmektedir.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

- [1] G. Weimann, "Going Darker? The Challenge of Dark Net Terrorism", wilsoncenter.org, [Online]. Available: [https://www.wilsoncenter.org/sites/default/files/media/documents/publication/going\\_darker\\_challenge\\_of\\_dark\\_net\\_terrorism.pdf](https://www.wilsoncenter.org/sites/default/files/media/documents/publication/going_darker_challenge_of_dark_net_terrorism.pdf). [Accessed: Jun. 6, 2023].
- [2] R. Badhwar, *The CISO's Next Frontier: Dark Web & Dark Net*, Springer Nature Switzerland AG 2021.
- [3] K. Demertzis, K. Tsiknas, D. Takezis, C. Skianis and L. Iliadis, "Darknet traffic bigdata analysis and network management for real-time automating of the malicious intent detection process by a weight agnostic neural networks framework", *Electronics*, vol.10, no.7, pp.781, 2021. doi: 10.3390/electronics10070781
- [4] A. Bracci, M.Nadini, M. Aliopoulos, D. McCoy, I. Gray, A. Teytelboym, A. Gallo and A. Baronchelli, "Dark Web Marketplaces and COVID-19: before the vaccine," *EPJ Data Sci*, vol.10, no. 6, 2021. doi: 10.1140/epjds/s13688-021-00259-w
- [5] A.H. Lashkari, G. Kaur and A. Rahali, "DIDarknet: A Contemporary Approach to Detect and Characterize the Darknet Traffic using Deep Image Learning," *10th International Conference on Communication and Network Security, 2020, Tokyo*, pp. 1-13, November, 2020.
- [6] M. B. Sarwar, M. K. Hanif, R. Talib, M. Younas and M. U. Sarwar, "DarkDetect: Darknet Traffic Detection and Categorization Using Modified Convolution-Long Short-Term Memory," in *IEEE Access*, vol. 9, pp. 113705-113713, 2021, doi: 10.1109/ACCESS.2021.3105000.
- [7] L. A. Iliadis and T. Kaifas, "Darknet Traffic Classification using Machine Learning Techniques," *2021 10th International Conference on Modern Circuits and Systems Technologies (MOCASST), Thessaloniki, July 2021, Greece* [Online]. Available: IEEE Xplore, <https://ieeexplore.ieee.org/document/9493386>. [Accessed: 10 Sept. 2023].
- [8] S. Sridhar and S. Sanagavarapu, "DarkNet Traffic Classification Pipeline with Feature Selection and Conditional GAN-based Class Balancing," *2021 IEEE 20th International Symposium on Network Computing and Applications (NCA)*, Boston, MA, USA, 2021, [Online]. Available: IEEE Xplore, <https://ieeexplore.ieee.org/document/9685743>. [Accessed: 20 May. 2023].
- [9] Y. Li, Y. Lu and S. Li, "EZAC: Encrypted Zero-day Applications Classification using CNN and K-Means," *2021 IEEE 24th International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, Dalian, China, 2021, [Online]. Available: IEEE Xplore, <https://ieeexplore.ieee.org/document/9437716>. [Accessed: 12 Feb. 2023].
- [10] M. Ugurlu, İ. Dogru, ve R. S. Arslan, "Karanlık ağ trafiğinin makine öğrenmesi yöntemleri kullanılarak tespiti ve sınıflandırılması," *GUMMFD*, vol. 38, no. 3, pp. 1737-1746, 2023, doi: 10.17341/gazimmfd.1023147.
- [11] N. Rust-Nguyen, S. Sharma, and M. Stamp, "Darknet traffic classification and adversarial attacks using machine learning," *Comput. Secur*, vol. 127, pp.16, 2023. doi: 10.1016/j.cose.2023.103098
- [12] A. Almomani, "Darknet traffic analysis, and classification system based on modified stacking ensemble learning algorithms," *Inf Syst E-Bus Manage*, 2023. doi: 10.1007/s10257-023-00626-2
- [13] H. Mohanty, A. H. Roudsari, and A. Habibi Lashkari, "Robust stacking ensemble model for darknet traffic classification under adversarial settings," *Comput. Secur*, vol.120, Sep. 2022. doi: 10.1016/j.cose.2022.102830
- [14] Q. A. Al-Hajja, M. Krichen and W. A. Elhajja, "Machine-Learning-Based Darknet Traffic Detection System for IoT Applications," *Electronics*, vol. 11, no.4, pp.556, 2022. doi:11. 556. 10.3390/electronics11040556.
- [15] Y. Li and Y. Lu, "ETCC: Encrypted Two-Label Classification Using CNN," *Sec. and Commun. Netw.* vol.2021, pp.11, 2021. doi:10.1155/2021/6633250
- [16] M. Alimoradi, M. Zabihmayvan, A. Daliri, R. Sledzik and R. Sadeghi, "Deep Neural Classification of Darknet Traffic," In book:

Artificial Intelligence Research and Development, Edition: printChapter: 356, Publisher: IOS Press, 2022, pp.105-114

[17] A. H. Lashkari, G. Draper Gil, M. Mamun and A. Ghorbani, "Characterization of Encrypted and VPN Traffic Using Time-Related Features," *The International Conference on Information Systems Security and Privacy (ICISSP)*, Feb 2016, Italy, [Online]. Available: IEEE Xplore, <https://doi.org/10.5220/0005740704070414>. [Accessed: 10 Apr. 2023].

[18] A. H. Lashkari, G. Kaur and A. Rahali, "DIDarknet: A Contemporary Approach to Detect and Characterize the Darknet Traffic using Deep Image Learning," *10th International Conference on Communication and Network Security, November 2020, Tokyo, Japan*, [Online]. Available: <https://doi.org/10.1145/3442520.3442521>. [Accessed: 20 May. 2023].

[19] E. G. İlgün ve R. Samet, "Veri setine uygulanan ön işlemler ile makine öğrenimi yöntemi kullanılarak geliştirilen saldırı tespit modellerinin performanslarının artırılması," GUMMFD, vol. 39, no. 2, pp. 679–692, 2023, doi: 10.17341/gazimmfd.1122021.

[20] E. G. İlgün, "Veri setine uygulanan ön işlemlerin anomali tabanlı saldırı tespit modellerinin performansları üzerindeki etkisinin incelenmesi," Yüksek Lisans Tezi, Ankara Üniversitesi, Ankara, Türkiye, 2022.

[21] O. Kaynar, H. Arslan, Y. Görmez ve Y. E. Işık, "Makine Öğrenmesi ve Öznitelik Seçim Yöntemleriyle Saldırı Tespiti," *Bilişim Teknolojileri Dergisi*, 11 (2), pp.175-185, 2018. doi: 10.17671/gazibtd.368583

[22] A. Fernandez, S. Garcia, M. Galar, R.C. Prati, B. Krawczyk and F. Herrera, "Learning from Imbalanced Data Sets," *Cambridge International Law Journal*, pp. 83, 2018. doi:10.1007/978-3-319-98074-4

[23] J. Brownlee, "Random Oversampling and Undersampling for Imbalanced Classification," *machinelearningmastery.com*, Jan. 15, 2020. [Online]. Available: <https://machinelearningmastery.com/random-oversampling-and-undersampling-for-imbalanced-classification/on>. [Accessed: 12 Apr. 2023].

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## Comparison of Machine Learning Models For Traffic Volume Estimation at Smart Intesections

Seyitali İlyas<sup>a</sup>, Yalçın Albayrak<sup>b</sup>

Submitted: 19.11.2023 Revised: 15.12.2023 Accepted: 15.12.2023 doi: 10.30855/gmbd.0705S14

### ABSTRACT

**Keywords:** Smart Intersection, Digital Twin, Big Data, Machine Learning, Traffic Volume Estimation

<sup>a</sup> Akdeniz University,  
Faculty of Engineering,  
Department of Electrical and Electronics  
Engineering  
07000 - Antalya, Türkiye  
Orcid: 0000-0003-2009-3454  
e mail: [seyitaliant@gmail.com](mailto:seyitaliant@gmail.com)

<sup>b</sup> Akdeniz University,  
Faculty of Engineering,  
Department of Electrical and Electronics  
Engineering  
07000 - Antalya, Türkiye  
Orcid: 0000-0002-5632-0869

<sup>\*</sup>Corresponding author:  
[seyitaliant@gmail.com](mailto:seyitaliant@gmail.com)

The population growth and mobility of modern cities have made efficient management of the transportation systems increasingly critical. According to this, the digital twin concept has become a powerful tool for understanding, managing, and optimizing complex systems by creating a digital reflection of the physical world. Transportation is one of these areas, moreover, with the help of such smart intersections and technological infrastructure, large amounts of data are made up of estimation models which is one of the important elements of digital twins. This study aims to provide an academic understanding of which model should be chosen to have accurate and more effective results during the application of traffic value prediction in smart intersections. Hourly vehicle count data from the arrival branches of two smart intersections in Antalya were utilized for this. This data is separated as training and test data created based on learning machine models including Linear Regression Polynomial Regression, Support Vector Regression (SVR), and Random Forest Regression. Thus, traffic volume estimation was conducted for each branch at smart intersections. Forecasting models were evaluated using Mean Absolute Error (MAE) and Least Squares ( $R^2$ ) methods. Accordingly, it was seen that the Random Forest model performed better than the other proposed models.

## Akıllı Kavşaklarda Trafik Hacmi Tahmini İçin Makine Öğrenmesi Modellerinin Karşılaştırılması

### ÖZ

Modern şehirlerin artan nüfusu ve hareketliliği, ulaşım sistemlerinin verimli yönetimini gittikçe daha kritik hale getirmiştir. Bu bağlamda, dijital ikiz kavramı, fiziksel dünyanın dijital bir yansımını oluşturarak karmaşık sistemleri anlamak, yönetmek ve optimize etmek için güçlü bir araç haline gelmiştir. Ulaşım da bu alanlardan biridir ki akıllı kavşaklar gibi teknolojik altyapılar sayesinde büyük miktarda veri toplanmakta ve bu verilerle dijital ikiz mimarisinin önemli bir unsuru olan tahmin modelleri oluşturulmaktadır. Bu çalışma akıllı kavşaklarda trafik hacmi tahmini uygulamalarında daha etkili ve doğru sonuçlar elde etmek için hangi modelin seçilmesi gerektiğine dair akademik bir anlayış sunmayı amaçlamaktadır. Bunun için Antalya'da bulunan seçilmiş iki akıllı kavşağın her bir geliş kolu için saatlik araç sayım verileri kullanılmıştır. Bu veriler eğitim ve test verisi olarak ayrılmış olup Lineer Regresyon, Polinomal Regresyon, Destek Vektör Regresyonu (SVR) ve Rastgele Orman Regresyonu tabanlı makine öğrenmesi modelleri oluşturulmuştur. Böylece akıllı kavşaklarda her bir kol için trafik hacmi tahmini yapılmıştır. Ortalama Mutlak Hata (MAE) ve En Küçük Kareler ( $R^2$ ) yöntemleri ile tahmin modellerinin performans karşılaştırması yapılmıştır. Buna göre Rastgele Orman modelinin diğer önerilen modellere göre daha başarılı performans göstermiş olduğu görülmüştür.

**Anahtar Kelimeler:** Akıllı Kavşak, Dijital İkiz, Büyük Veri, Makine Öğrenmesi, Trafik Hacmi Tahmini

## 1. Giriş (Introduction)

Dijital ikiz teknolojisi ilk defa 2002 yılında Dr. Michael Grieves tarafından Ulusal Havacılık Uzay İdaresi'nin (NASA) Apollo Programı'nda oluşturulmuştur [1]. Dijital ikiz verilerin fiziksel ve sanal ortam arasında her iki yönde gerçek zamanlı tam entegrasyonu olarak tanımlanmaktadır. Burada amaç gerçekleştirilecek sorunları yaşanmadan tespit ederek maliyet kaybını engelleyecek eylemde bulunmaktır. Dijital ikiz teknolojisinde fiziksel nesnede yapılan bir değişiklik ile otomatik olarak dijital nesnede değişiklik meydana gelmekte olup bu durumun tersi de oluşabilmektedir [2, 3].

Dijital ikiz, dijital gölge, dijital model kavramları birbiriyle ilişkili ancak farklı kavramlardır ve literatürde yapılmış olan çalışmalar tanımlanırken bunların birbiriyle karıştırılabildiği görülmüştür. Dijital model, önceden var olan veya planlanan bir fiziksel nesnenin dijital versiyonu olarak tanımlanmaktadır. Dijital modelde, fiziksel sistem ile dijital model arasında hiçbir otomatik veri alışverişi olmamaktadır. Bu, dijital model oluşturulduktan sonra fiziksel nesnede yapılan bir değişikliğin dijital model üzerinde hiçbir şekilde etkisi olmayacağı anlamına gelmektedir. Dijital gölge kavramı ise fiziksel ve dijital nesne arasında tek yönlü bir akışa sahip olan bir dijital durum temsilidir [4, 5]. Fiziksel nesnedeki bir değişiklik, dijital nesnede bir değişikliğe yol açmaktadır ancak tersi durum gerçekleşmemektedir. Bu tanımlar ışığında dijital ikiz üç unsurdan oluşmaktadır: Nesnelerin İnterneti (IoT) sensörleriyle sağlanan geçmiş veriler, gerçek zamanlı veriler ve makine öğrenmesi algoritmalarıyla oluşturulan modeller kullanılarak elde edilen gelecekteki verilerdir [4, 6, 7].

Ulaşım konusunda dijital ikiz teknolojisi kapsamında büyük bütçeli uygulamalarının yapıldığı ancak uygulama yöntemlerinin detaylı içeriğine az değinildiği görülmüştür [8]. Bu amaçla Literatür incelemesinde dijital ikiz mimarisinin bileşenlerinden biri olan tahmin modellerinin oluşturulması ile ilgili çalışmalar incelenmiştir.

Janković vd. (2021) Sırbistan Cumhuriyeti'ndeki yollarda bulunan otomatik sayaçlarından tarih, saat, yön, araç sayısı özelliklerini içeren verileri toplayarak günlük ve saatlik trafik hacmi tahmin etmişlerdir. Bunun için Doğrusal Regresyon, Çok Katmanlı Algılayıcı, k-En Yakın Komşu, M5P, Rastgele Orman, REPTree algoritmalarıyla oluşturulmuş modeller kullanılmıştır. İlk senaryo da günlük trafik hacmi tahmini yapılmıştır. M5P algoritmasına (kolerasyon katsayısı eğitim için 0.9778, test için 0.9756) dayalı model en iyi performansı göstermiştir. İkinci senaryo için saatlik trafik hacmi tahmin edilmiştir. İkinci senaryo için en iyi sonuçları k-En Yakın Komşu algoritması vermiştir [9]. Bratsas vd. (2020) çalışmalarında, Yunanistan'ın Selanik karayolu ağından elde ettikleri trafik verilerini kullanarak araçların ortalama hızını tahmin etmişlerdir. Bu amaçla, Doğrusal Regresyon, Çok Katmanlı Algılayıcı, Destek Vektör Regresyonu (SVR), Rastgele Orman gibi makine öğrenmesi modellerini kullanmışlardır. Bu modellerin tahmin başarı oranlarını farklı senaryolar altında birbiriyle karşılaştırmışlardır. Sonuç olarak, Destek Vektör Regresyon modeli belirli koşullar altında daha istikrarlı bir performans sergilerken, Çok Katmanlı Algılayıcı Sinir Ağı (MLP-NN) modeli daha küçük hatalara sahip olmanın yanı sıra değişken koşullarda en iyi sonuçları vermiştir. Bu çerçevede, her iki modelin de farklı senaryolarda farklı avantajlara sahip olduğu gözlemlenmiştir [10]. Ali ve Hamed (2018) tarafından gerçekleştirilen çalışmada Suudi Arabistan'ın Al Ghat şehrindeki yıl, saat, kaza türü, konum, araç sayısı, sürücü vatandaşlık durumu, yaralı, ölü bilgilerini içermekte olan trafik veri setini kullanılarak, kazaya neden olan durumlar tahmin edilmiştir. Apriori algoritması ve Bulanık Kümeleme algoritması arasında yapılan performans karşılaştırmasında, Apriori algoritmasının daha başarılı sonuçlar verdiği gözlemlenmiştir [11]. Navarro vd. (2022) dört kollu sinyalizasyon kavşaktaki trafik akımlarını tahmin etmek için Münih Araştırma Merkezi'nden alınan veri kümesini kullanmışlardır. Tekrarlayan Sinir Ağları (RNN'ler), MLP-NN, Uzun Kısa Süreli Bellek (LSTM), Gradyan Arttırma, Rastgele Orman, Doğrusal Regresyon ve Stokastik Gradyan algoritmaları trafik akımı tahminindeki başarıları açısından karşılaştırılmıştır. Yapılan analizler, tüm makine öğrenmesi ve derin öğrenme algoritmalarının kurulacak akıllı kavşaklarda trafik yönetiminde uygulanabileceğini göstermiştir. Ancak, performans sonuçları incelendiğinde, MLP-NN'nin daha iyi sonuçlar verdiği ( $R^2$  0,93) ve aynı zamanda daha kısa bir eğitim süresinde (18 s) gerçekleştiği belirlenmiştir [12]. Hou vd. (2021) hava değişikliklerinin trafik akışı üzerindeki etkisini dikkate alarak yeni bir tahmin modeli oluşturmuşlardır. Önerilen modelin daha başarılı performans ortaya koyduğunu tespit etmişlerdir [13]. Alajali vd. (2018) bu çalışmada, Avustralya'nın Melbourne merkezi iş bölgesindeki kavşaklarda sensörlerden gelen trafik hacmi veri setiyle, kaza ve yol çalışmalarını içeren olay veri setlerini entegre ederek yeni özelliklerin tahmin modellerindeki hata değerlerine etkisini incelemişlerdir. Tahmin için Regresyon Ağaçları (RT), Gradyan Arttırıcı Karar Ağaçları (GBRT), Rastgele Orman (RF), Aşırı Gradyan Arttırma (XGBoost), SVR modellerini kullanmışlardır. Sadece sensör verileri kullanıldığında SVR, RT, GBRT, RF ve

XGBoost modelleri için Ortalama Kare Hata (MSE) değerlerinin sırasıyla 0.8883, 0.8838, 0.8772, 0.8815, 0.8773 olduğu belirlenmiştir. Ancak olay verileri sensör verileriyle entegre edildiğinde MSE'ler sırasıyla 0.8859, 0.8829, 0.8684, 0.8770 ve 0.8678 olarak elde edilmiştir. Bu sonuçlar, olay verilerinin entegrasyonunun tahmin modellerinin MSE değerini iyileştirdiğini göstermiştir. Özellikle XGBoost için en iyi MSE değeri elde edildiği görülmüştür [14].

Antalya Büyükşehir Belediyesi, TC. Ulaştırma ve Altyapı Bakanlığının Ulusal AUS Strateji Belgesi ve 2020-2023 Eylem Planı doğrultusunda 'İl Trafik Kontrol Merkezlerinin Kurulması' eylem planını tamamlayarak 'Akıllı Kavşaklar Projesi' ile trafik veri akışını sahada kurulumu yapılan 40 adet Akıllı Kavşaktan sağlamaya başlamıştır [15, 16]. Ancak bu Akıllı Kavşaklar dijital ikiz teknolojisi kapsamında değildir çünkü gelecek tahmini yapmamaktadır. Bu çalışmada Antalya ili özelinde ardışık akıllı kavşak verileri kullanılarak dijital ikiz mimarisi için altyapı oluşturulması planlanmaktadır. Bunun için Trafik Kontrol Merkezinde toplanan büyük veri akışıyla makine öğrenmesi tabanlı tahmin modelleri oluşturulmuştur [17]. Bu modellerin trafik hacmi tahminindeki performans başarıları ortaya koyulmuştur.

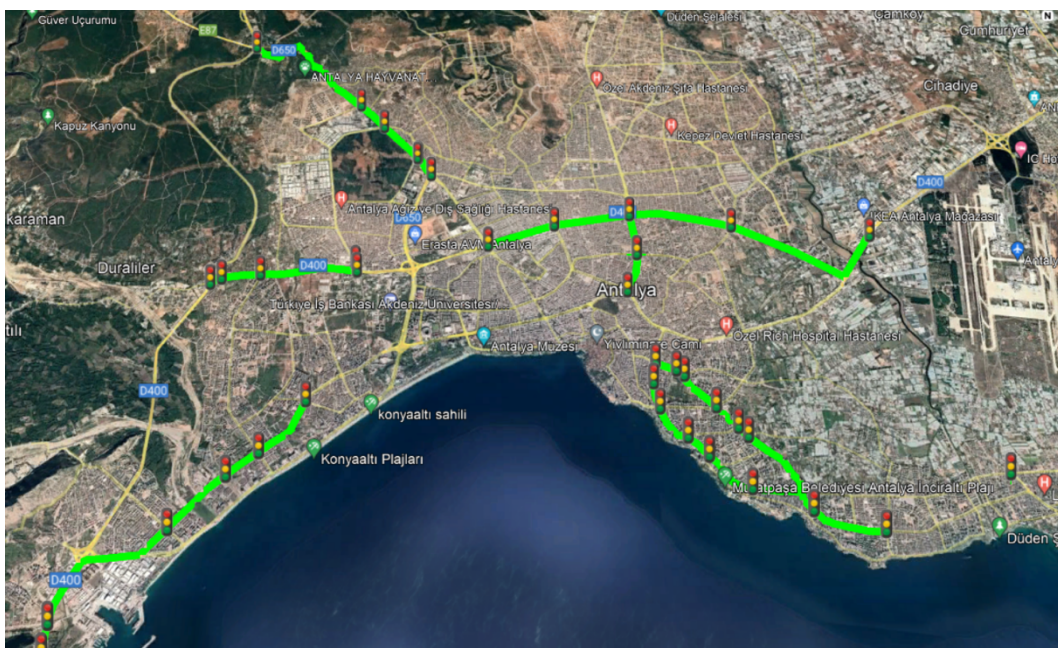
## 2. Metodoloji ve Yöntemler (Methodology And Methods)

Bu çalışmada Akıllı Kavşaklardan trafik hacmi verileri toplanarak Python yazılımında veriler düzenlenmiştir. Düzenlenen verilerle Python da Lineer Regresyon, Polinomal Regresyon, SVR ve Rastgele Orman Regresyonu makine öğrenme algoritmaları kullanılarak tahmin modelleri oluşturulmuştur. Daha sonra oluşturulan bu modellerin araç tahminindeki başarısını değerlendirmek için MAE ve en  $R^2$  yöntemleri kullanılmıştır.

### 2.1. Veri kümesi (Dataset)

Makine öğrenmesi modellerinin oluşturulması için veri setine ihtiyaç vardır. Yapılan çalışmada kullanılan veri setleri Atatürk Bulvarı ile Öğretmenler Caddesi kesişiminde bulunan (1 numaralı) ve Atatürk Bulvarı ile Gazi Mustafa Kemal Bulvarı kesişiminde bulunan (2 numaralı) 4 kollu kavşakların her bir kollundan alınmıştır. Python yazılımı kullanılarak kavşaklardaki her bir yön için tarih ve zaman serisini temsil eden bağımsız değişken verilerinin olduğu sütun ve saatlik araç sayımlarını temsil eden yön 1, yön 2, yön 3, yön 4 olarak adlandırılan bağımlı değişken verilerinin olduğu 4 sütundan oluşmaktadır. Veri kümesi içerisinde bulunan bağımlı ve bağımsız değişkenler Tablo 1'de veri tablosu üzerinde gösterilmiştir.

Şekil 1'de Antalya Büyükşehir Belediyesinin Trafik Kontrol Merkezine veri akışını yapan Akıllı Kavşakların Google haritalar üzerinden görüntüsü verilmiştir.



Şekil 1. Akıllı Kavşakların Google Earth Gösterimi  
(Representation of Smart Intersections on Google Earth)

Tablo 1’de Atatürk Bulvarı ile Gazi Mustafa Kemal Bulvarı kesişiminde bulunan (2 numaralı) kavşağa ait 10 satırlık örnek veri kümesi gösterilmiştir.

Tablo 1. Atatürk Bulvarı ile Gazi Mustafa Kemal Bulvarı kesişim kavşağına ait 10 Satırlık Örnek Veri Kümesi Tablosu (Sample Dataset Table for the intersection of Atatürk Street and Gazi Mustafa Kemal Street)

Tarih	Zaman	Yön 1 (araç/saat)	Yön 2 (araç/saat)	Yön 3 (araç/saat)	Yön 4 (araç/saat)	Toplam (araç/saat)
14.09.2022	00:00	836	314	629	159	1938
14.09.2022	01:00	532	173	390	110	1205
14.09.2022	02:00	245	116	244	63	668
14.09.2022	03:00	179	72	179	54	484
14.09.2022	04:00	137	58	175	41	411
14.09.2022	05:00	167	62	184	29	442
14.09.2022	06:00	321	116	483	60	980
14.09.2022	07:00	1059	365	1044	182	2650
14.09.2022	08:00	1797	594	1334	417	4142
14.09.2022	09:00	1697	626	1276	437	4036

1 numaralı kavşak verileri ise 2022-09-07 ile 2022-09-21 tarihleri arasındaki 15 günlük sayımdan oluşmaktadır. Veri kümesi 1800 adet bağımlı değişken, 360 adet bağımsız değişken olmak üzere toplamda 2160 veriden oluşmaktadır. 2 numaralı kavşak verileri 2022-09-07 ile 2022-09-14 tarihleri arasındaki 8 günlük sayımdan oluşmaktadır. Veri kümesi 960 adet bağımlı değişken, 192 adet bağımsız değişken olmak üzere toplamda 1152 veriden oluşmaktadır.

Tahmin modellerinin performansını objektif bir şekilde değerlendirmek için daha önce bilinmeyen veri kümesi gerekmektedir [18]. Bu sebeple 1 numaralı kavşak veri kümesi %20’si (3 gün) test verisi, %80’i eğitim verisi olarak, 2 numaralı kavşak veri kümesi %12,5’i test (1 gün) %87,5’i eğitim verisi olarak ayrılarak regresyon modellerinin oluşturulmasında kullanılmıştır.

## 2.2. Regresyon modellerinin oluşturulması (Creating regression models)

Lineer Regresyon, Polinomal Regresyon, Destek Vektör Regresyon, Rastgele Orman Regresyon algoritmaları bağımsız değişkenin ( $X$ ) bağımlı bir değişkene ( $Y$ ) olan istatistiksel ilişkisini açıklamak için kullanılmıştır. Veri kümesi eğitim verisi ile eğitilip tahmin modelleri oluşturulmuş ve test verisi ile de model başarısı gösterilmiştir.

### 2.2.1. Lineer regresyon modeli (Linear regression model)

Lineer regresyon modeli bir doğru denklemi kullanarak  $X$  değerlerinin  $Y$  değerlerine nasıl etki ettiğini gösterir. Lineer regresyon modeli, bu değişkenler arasındaki ilişkiyi doğrusal bir eğri ile ifade eder. Lineer regresyon modeli, bu eğriyi temsil eden denklemi kullanarak, bağımsız değişkenlerin  $Y$  değerlerini tahmin edebilecektir. Bu model, özellikle doğrusal bir ilişkinin olduğu durumlarda, öngörücü analiz ve tahmin yapmak için kullanılmaktadır. Lineer regresyon, Eşitlik.1’deki denklem ile ifade edilmektedir.

$$Y = a + bX + \varepsilon \quad (1)$$

Burada  $Y$  bağımlı değişkeni  $X$  bağımsız değişkeni,  $a$  kesme terimini,  $b$  eğim terimini ( $X$ ’teki birim artışın  $Y$ ’deki birim artışı ile ilişkisini),  $\varepsilon$  hata terimini (modelin gerçek değerlerden ne kadar sapabileceğini) ifade etmektedir [19].

### 2.2.2. Polinomal regresyon modeli (Polynomial regression model)

Polinomal regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki doğrusal olmayan ilişkiyi modellemek için kullanılan bir regresyon analiz yöntemidir. Polinomal regresyon, lineer regresyon modellerinden farklı olarak, bir polinom denklemi kullanarak bağımlı ve bağımsız değişkenler arasındaki ilişkiyi ifade etmektedir. Polinomal regresyon, yüksek dereceli polinomlar kullanarak, verilerin

uydurulması ve tahmininde daha esnek bir yaklaşım sağlamaktadır. Özellikle, verilerin doğrusal bir şekilde değişmediği veya bir eğri veya dalgalı desen gösterdiği durumlarda kullanılmaktadır. Polinomal regresyon, Eşitlik.2'deki denklemlerle ifade edilmektedir.

$$Y = b_0 + b_1X + b_2X^2 + b_3X^3 + \dots + b_nX^n + \varepsilon \quad (2)$$

Burada  $X$  bağımsız değişkeni,  $Y$  bağımlı değişkeni,  $b_1, b_2, b_3 \dots b_n$  polinom katsayılarını  $\varepsilon$  hata terimini ifade etmektedir [20].

### 2.2.3. Destek vektör regresyonu modeli (Support vector regression model)

SVR modeli, doğrusal olmayan bir hiper düzlemi kullanarak bir bağımlı değişkenin değerlerini bir veya daha fazla bağımsız değişkenle ilişkilendirmektedir. Bu model, çoğu regresyon probleminde kullanılan geleneksel yöntemlerden daha verimli bir şekilde çalışmaktadır. SVR modeli, Eşitlik.3'teki denklemlerle ifade edilmektedir.

$$Y = wX + b \quad (3)$$

Burada,  $Y$  bağımlı değişkeni,  $X$  bağımsız değişkenleri,  $w$  ağırlık vektörünü,  $b$  sabit terimi ifade etmektedir [21].

### 2.2.4. Rastgele orman modeli (Random forest model)

Rastgele Orman makine öğrenmesi modeli hem sınıflandırma hem de regresyon problemlerini çözmek için kullanılan bir öğrenme yöntemidir. Rastgele Orman modeli, birden fazla karar ağacını kullanarak tahminler yapmakta ve bu karar ağaçlarının sonuçlarını bir araya getirerek daha doğru bir tahmin sonuçları elde etmektedir.

Rastgele Orman modeli, aşağıdaki adımlardan oluşmaktadır:

- Eğitim verilerinden rastgele bir alt küme oluşturulur.
- Bu alt küme, rastgele seçilen özellikler üzerinde birçok karar ağacı eğitir.
- Oluşturulan her ağaç, rastgele bir şekilde alt özellikler ve veri noktaları seçerek oluşturulur.
- Her ağacın sonucu, oybirliğiyle veya ağırlıklı ortalamayla birleştirilir.

Rastgele Orman modeli, aşırı öğrenmeyi engellemek ve daha sağlam bir genelleme elde etmek amacıyla kullanılmaktadır. Her bir ağaç, farklı bir alt kümeden öğrenildiği için, model eğitim verilerine aşırı uyum sağlamamaktadır. Bu durum, daha genel bir model elde edilmesini sağlamaktadır.

Rastgele Orman modeli, özellikle yüksek boyutlu veri kümelerinde etkili olmakta olup ağaç sayısı, özellik seçimi ve derinlik gibi parametreleri ayarlamak suretiyle modelin doğruluğu artırılabilir [12, 22].

## 2.3. Model performansının değerlendirilmesi (Evaluation of model performance)

Önerilen modellerin performansı test edilmiştir. Deneysel aşamada oluşturulmuş olan modellerin performansını değerlendirmek için MAE ve  $R^2$  yöntemleri kullanılmıştır.

### 2.3.1. Ortalama mutlak hata (Mean absolute error)

Ortalama Mutlak Hata, bir tahminin gerçek değerden ortalama olarak ne kadar uzak olduğunu ölçen bir istatistiksel ölçüttür. MAE, her bir tahmin hatasının mutlak değerlerinin ortalamasını hesaplar. Mutlak değer, bir sayının işaretini göz ardı ederek o sayının pozitif değerini alır. Bu nedenle, MAE, bir tahminin gerçek değerden ne kadar farklı olduğunu ölçer, ancak bu farkın yönünü dikkate almaz.

MAE, özellikle regresyon modellerinin performansını ölçmek için kullanılır. Regresyon modeli, bir girdi değişkeniyle bir çıktı değişkeni arasındaki ilişkiyi modelleyen bir matematiksel fonksiyondur. MAE, modelin gerçek değerlerden ne kadar sapma gösterdiğini ölçerek, modelin ne kadar iyi performans gösterdiğini anlamamıza yardımcı olur. MAE Eşitlik.4'teki denklemlerle gösterilmektedir.



$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} = \left(\frac{1}{n}\right) \sum_{i=1}^n |e_i| \quad (4)$$

Yukarıdaki denklemlerde  $n$  veri noktalarının sayısını,  $y_i$  gerçek değeri (gözlem değeri),  $x_i$  tahmin edilen değeri (model tarafından üretilen değer),  $e_i$  mutlak hatayı ifade etmektedir.

### 2.3.2. R-kare (R-square)

Önerilen tahmin modellerinin performansını karşılaştırmak için R-Kare ( $R^2$ ) yöntemi kullanılmıştır. Bu yöntem, bağımlı ve bağımsız değişkenler arasındaki etkinin matematiksel model sonuçlarına dayalı olarak karşılaştırılmasını sağlamaktadır [23].  $R^2$ , belirli bir regresyon modelinin ne kadar iyi uyduğunu ölçen bir istatistiksel ölçüdür.  $R^2$  Eşitlik.4'teki denklemle hesaplanmaktadır.


$$R^2 = 1 - \left( \frac{\sum_{i=1}^n (y_i - x_i)}{\sum_{i=1}^n (y_i - x_0)} \right) \quad (5)$$

Yukarıdaki denklemde  $x_0$  ortalama değeri (en kötü yapılabilecek tahmin) ifade etmektedir.  $R^2$  değerinin bire yaklaşması durumunda modelin tahmin performansının yüksek olduğu, sıfıra yaklaşması durumunda modelin başarısız olduğu sonucu çıkarılabilmektedir [24].

## 3. Deney Sonuçları (Experiment Results)

Veri setinin genel yapısını görmek seçilecek tahmin modelleri açısından önem taşımaktadır. Veri setine göre, örneğin normal bir dağılıma sahip veriler için parametrik modeller (Lineer Regresyon gibi) daha uygun olabilirken, dağılımı bilinmeyen veriler için daha esnek modeller (Random Forest gibi) tercih edilebilmektedir.


Şekil 2'de Python çıktısı olarak elde edilmiş olan 1 numaralı ve 2 numaralı kavşaklara ait toplam trafik hacim verilerinin dağılımı gösterilmiştir. Burada her iki kavşak içinde sabah saatlerinde trafik yoğunluğunun daha az olduğu 1 numaralı kavşak için akşam 17:00:00 ile 18:00:00 (2022-09-07 ile 2022-09-21 tarihleri) arasındaki saatin pik saat, 2 numaralı kavşak için 18:00:00 ile 19:00:00 (2022-09-07 ile 2022-09-14 tarihleri) arasındaki pik saat olduğu belirlenmiştir.



Şekil 2. 1 Numaralı ve 2 Numaralı Kavşak Trafik Hacmi Verileri  
(Traffic Volume Data for Junction No. 1 and No. 2)


Trafik Akışının Yönetimi için geliş kollarındaki trafik hacminin bilinmesi, kavşakta trafik akışını düzenlemek açısından önemlidir. Özellikle yoğun saatlerde veya özel etkinliklerde, trafik akışını dengelemek ve trafik sıkışıklığını önlemek için bu bilgilere ihtiyaç vardır. Akıllı kavşaklarda sinyal süreleri kavşağa geliş kollarındaki yoğunluklara göre optimize edilmektedir.

Aşağıdaki şekilde 1 numaralı kavşak için 2022-09-07 ile 2022-09-21 tarihleri arası trafik hacim verileri gösterilmiştir. Yön 1 ve Yön 3'ten gelen araç sayılarının ana arter olmaları sebebiyle diğer yönlerden daha fazla olduğu, asıl trafik yoğunluğunun bu kollarında yaşandığı görülmüştür. Trafik hacim verilerine göre sıralama yapıldığında Yön 1, Yön 3, Yön 2, Yön 4 olacak şekilde kavşağa geliş güzergahları sıralanmıştır.



Şekil 3. 1 Numaralı Kavşak Toplam ve Tüm Geliş Kolları Trafik Hacim Verileri  
(Traffic Volume Data for Junction No. 1, Total and All Arrival Branches)

Aşağıdaki şekilde 2 numaralı kavşak için 2022-09-07 ile 2022-09-15 tarihleri arası trafik hacim verileri gösterilmiştir. Yön 1 ve Yön 3 güzergahlarından gelen trafik akışının birbirine yakın ve diğer yönlere göre daha fazla olduğu, Yön 2 ve Yön 4 güzergahlarından gelen trafik akışının birbirine yakın olduğu görülmüştür.



Şekil 4. 2 Numaralı Kavşak Toplam ve Tüm Geliş Kolları Trafik Hacim Verileri  
(Traffic Volume Data for Junction No. 2, Total and All Arrival Branches)

1 numaralı kavşak ve 2 numaralı kavşak kolları için oluşturulan modellerin analiz sonuçları Tablo 2 ve Tablo 3'te gösterilmiştir. Lineer Regresyon modelin Şekil 2 grafiğinde veri setinin dağılımından anlaşılacağı üzere MAE ve  $R^2$  değerleri açısından en düşük değerleri almıştır. Trafik hacmi tahmininde rastgele orman modellerine dayalı tahminlerin daha başarılı sonuçlar verdiği gözlenmiştir.

Tablo 2. 1 Numaralı Kavşak Kolları Tahmin Modelleri Performans Değerleri

Model	$y^1$ ' Güzergahı		$y^2$ ' Güzergahı		$y^3$ ' Güzergahı		$y^4$ ' Güzergahı	
	MAE	$R^2$	MAE	$R^2$	MAE	$R^2$	MAE	$R^2$
Lineer Regresyon	433,4680	0,3340	186,5940	0,4867	323,2860	0,4850	97,2162	0,4217
Polinomal Regresyon	201,5408	0,7888	84,3496	0,8603	124,8740	0,8931	52,8634	0,7519
Destek Vektör Regresyon	162,3194	0,8281	64,6678	0,9010	98,1503	0,9353	44,8088	0,8026
Rasgele Orman Regresyon	118,9882	0,9272	50,4261	0,9505	68,6889	0,9699	34,2801	0,9157

Tablo 3. 2 Numaralı Kavşak Kolları Tahmin Modelleri Performans Değerleri

Model	y <sup>1</sup> Güzergahı		y <sup>2</sup> Güzergahı		y <sup>3</sup> Güzergahı		y <sup>4</sup> Güzergahı	
	MAE	R <sup>2</sup>	MAE	R <sup>2</sup>	MAE	R <sup>2</sup>	MAE	R <sup>2</sup>
Lineer Regresyon	325,3016	0,4771	71,7533	0,6229	382,3645	0,3748	107,3552	0,5126
Polinomal Regresyon	124,2187	0,8869	56,1171	0,8269	172,7752	0,7928	39,6911	0,9114
Destek Vektör Regresyon	101,5467	0,9208	39,4431	0,9022	138,6960	0,8267	34,7533	0,9219
Rasgele Orman Regresyon	62,0924	0,9767	20,8846	0,9692	75,4847	0,9565	22,8378	0,9718

#### 4. Sonuçlar (Conclusion)

Bu çalışmada trafik hacim verilerinin öngörülmesi kapsamında Dijital İkiz mimarisinin yapısı incelenmiştir. Makine öğrenmesi algoritmaları kullanarak oluşturulan tahmin modelleriyle literatürdeki çalışmalardan farklı olarak Antalya'da seçilen Akıllı Kavşaklarda, trafik hacimleri tahmin edilmiştir. Doğrulama parametrelerine göre tahmin modelleri birbiriyle karşılaştırılmış ve başarı oranı yüksek tahmin modeli dijital ikiz mimarisinde uygulanmak üzere seçilmiştir. Böylece Antalya Büyükşehir Belediyesinin akıllı kavşaklarda işleyen adaptif trafik yönetim sisteminin dijital ikiz mimarisi kapsamında altyapısının oluşturularak iyileştirilmesi amaçlanmıştır.

Trafik ışıklarının ve trafik yönetim şemalarının planlanmasını ve işletilmesini desteklemek için trafik tahminlerinin oluşturulması dijital ikiz için önemli bir unsurdur. Gelecek trafik hacim verilerinin tahmin edilmesi, Akıllı Kavşaklarda oluşabilecek arıza, bakım gibi durumlarda kavşağın adaptif trafik yönetimi sağlayamayacak olması sebebiyle sinyalizasyon kavşağına sabit sinyal süresi verecek operatörlere yol gösterebilecektir. Operatörler gün içerisindeki farklı saatlerdeki trafik tahmin verine göre en uygun sinyal sürelerini çoklu planlar oluşturularak verebilecektir.

Bu amaçla çalışmada oluşturulmuş olan modellerden her iki kavşak ve tüm güzergahlar için Rasgele Orman Regresyon Modelinin MAE ve R<sup>2</sup> (0,91-0,98 arasında) performans parametreleri açısından diğer modellerden daha başarılı sonuçlar göstermiş olduğu görülmüştür. Tahmin modelleri başarı sırasına göre Rasgele Orman Regresyon Modeli, Destek Vektör Makineleri Modeli, Polinomal Regresyon Modeli, Lineer Regresyon Modeli olmak üzere belirlenmiştir. Böylece trafik hacmi yapılan Akıllı Kavşaklardaki veri türüne doğru göre hangi tahmin modellerinin seçilebileceği tespit edilmiştir.

Gelecekte yapılması hedeflenen çalışmalar:

- Bu çalışmada önerilen tahmin modellerinin benzetim programıyla oluşturulan ulaşım ağında uygulaması yapılarak trafik parametreleri açısından çıktılar elde edilecektir. Böylece literatürde çok rastlanılmayan bir şekilde tahmin modelleri ulaşım parametreleri açısından karşılaştırılacaktır.
- Daha fazla eğitim verisi toplanarak, modelin daha iyi geliştirilecek büyük veri kümesi, modelin daha iyi sonuçlar elde etmesine yardımcı olacaktır.
- Veri türüne göre doğru model seçimi tahmin başarısını artırmaktadır. Zaman serisi verileri için özel modeller (ARIMA, LSTM) oluşturularak daha büyük ve karmaşık veriler üzerinde tahmin başarıları araştırılacaktır.
- Bu çalışmada bağımsız değişken saatlik zaman dilimi olarak seçilmiştir. Gelecek çalışmalarda büyük veriler üzerinden günlerin ve ayların bağımsız değişken olarak eklenip modellerin daha iyi genelleme yapması beklenmektedir.

#### Teşekkür (Acknowledgment)

Çalışma '1649B032303124 'numaralı '2211-C Öncelikli Alanlara Yönelik Yurt İçi Doktora Programı' ile TÜBİTAK tarafından desteklenmiştir. Kullanılan gerçek trafik verilerini sağladığı için Antalya Büyükşehir Belediyesi, Ulaşım Planlama ve Raylı Sistem Dairesi Başkanlığı'na ve MOSAŞ GRUP'a kurumuna teşekkür ederiz.

## Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

## Kaynaklar (References)

- [1] İ. Aynacı, "Dijital ikiz ve sağlık uygulamaları," *İzmir Kâtip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, vol. 3, no. 1, pp. 70–79, 2020.
- [2] Z. Wang, K. Han and P. Tiwari, "Digital twin-assisted cooperative driving at non-signalized intersections," *IEEE Transactions on Intelligent Vehicles*, vol. 7, no. 2, pp. 198–209, Jun. 2022, doi: 10.1109/TIV.2021.3100465.
- [3] E. Tomanik, A. J. J. Reyes, V. Tomanik and B. Tormos, "Machine-learning-based digital twins for transient vehicle cycles and their potential for predicting fuel consumption," *Vehicles*, vol. 5, no. 2, pp. 583–604, May 2023, doi: 10.3390/vehicles5020032.
- [4] A. Fuller, Z. Fan, C. Day and C. Barlow, "Digital twin: Enabling technologies, challenges and open research," *IEEE access*, vol. 8, pp. 108952–108971, May 2020, doi: 10.1109/ACCESS.2020.2998358.
- [5] T. Y. Fujii, V. T. Hayashi, R. Arakaki, W. V. Ruggiero, R. Bulla, F. H. Hayashi and K. A. Khalil, "A digital twin architecture model applied with MLOps techniques to improve short-term energy consumption prediction," *Machines*, vol. 10, no. 1, Jan. 2022, doi: 10.3390/machines10010023.
- [6] H. Xu, A. Berres, S. B. Yoginath, H. Sorensen, P. J. Nugent, J. Severino, S. A. Tennille, A. Moore, W. Jones and J. Sany, "Smart mobility in the cloud: enabling real-time situational awareness and cyber-physical control through a digital twin for traffic," *IEEE Transactions on Intelligent Transportation Systems*, vol. 24, no. 3, pp. 3145–3156, March 2023, doi: 10.1109/TITS.2022.3226746.
- [7] J. Lai, Z. Chen, J. Zhu, W. Ma, L. Gan, S. Xie and G. Li, "Deep learning based traffic prediction method for digital twin network," *Cognitive Computation*, vol. 15, no. 5, pp. 1748–1766, September 2023, doi: 10.1007/s12559-023-10136-5
- [8] "Real-time transportation management" aimsun.com, [Online]. Available: <https://www.aimsun.com/real-time-transportation-management/>. [Accessed: Mar. 27, 2023.]
- [9] S. Janković, A. Uzelac, S. Zdravković, D. Mladenović, S. Mladenović and I. Andrijanić, "Traffic volumes prediction using big data analytics methods," *International Journal for Traffic and Transport Engineering*, vol. 2, no. 0, pp. 184–198, 2021, doi: 10.7708/ijtte2021.11(2).01.
- [10] C. Bratsas, K. Koupidis, J. M. Salanova, K. Giannakopoulos, A. Kaloudis and G. Aifadopoulou, "A comparison of machine learning methods for the prediction of traffic speed in urban places," *Sustainability (Switzerland)*, vol. 12, no. 1, Jan. 2020, doi: 10.3390/SU12010142.
- [11] F. M. N. Ali and A. A. M. Hamed, "Usage apriori and clustering algorithms in WEKA tools to mining dataset of traffic accidents," *Journal of Information and Telecommunication*, vol. 2, no. 3, pp. 231–245, Jul. 2018, doi: 10.1080/24751839.2018.1448205.
- [12] A. N. Espinoza, O. R. L. Bonilla, E. E. G. Guerrero, E. T. Cuatle, D. L. Mancilla, C. H. Mejia and E. I. Gonzalez, "Traffic flow prediction for smart traffic lights using machine learning algorithms," *Technologies (Basel)*, vol. 10, no. 1, p. 5, January 2022. <https://doi.org/10.3390/technologies10010005>
- [13] Y. Hou, Z. Deng and H. Cui, "Short-term traffic flow prediction with weather conditions: based on deep learning algorithms and data fusion," *Complexity*, vol. 2021, doi: 10.1155/2021/6662959.
- [14] W. Alajali, W. Zhou and S. Wen, "Traffic flow prediction for road intersection safety," in *2018 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCom/IOP/SCI)*, 812–820. October 2018, Guangzhou, China. Available: IEEE Xplore, <https://ieeexplore.ieee.org/document/8560129> [Accessed: 20 Sept. 2023].
- [15] "Strateji ve Eylem Planları - Haberleşme Genel Müdürlüğü," uab.gov.tr, Available: <https://hgm.uab.gov.tr/strateji-eylem-planlari>. [Accessed: Sept. 15, 2023].
- [16] "MAtchUP Antalya - Antalya Büyükşehir Belediyesi," matchupantalya.org, [Online]. Available: <http://www.matchupantalya.org/> [Accessed: Nov. 1, 2023].
- [17] A. Kemeç and H. Gül, "Antalya Büyükşehir Belediyesi örneğinde akıllı kent uygulamaları," *Kamu Yönetimi Ve Politikaları Dergisi*, 2(3), pp. 355–382.
- [18] M. Akın and Ş. Sağıroğlu, "Büyük veri perspektifinden trafik tahmini traffic prediction based on big data perspective," in *2019 1st International Informatics and Software Engineering Conference (UBMYK), 2019, Ankara, Turkey*, Available: IEEE Xplore <https://ieeexplore.ieee.org/document/8965545>. [Accessed: 02 Dec. 2023].
- [19] A. C. Müller and S. Guido, *Introduction to machine learning with Python*, O'Reilly Media, 2022.
- [20] J. Brownlee, *Deep learning with Python: develop deep learning models on Theano and TensorFlow using Keras*, Machine Learning

Mastery, 2016.

[21] A. Kowalczyk, *Support vector machines succinctly*, Synfusion Inc, 2017.

[22] A. Boukerche and J. Wang, "Machine learning-based traffic prediction models for intelligent transportation systems," *Computer Networks*, vol. 181, Nov. 2020. doi: 10.1016/j.comnet.2020.107530.

[23] "R Kare ve Düzeltmiş R Kare - Veri bilimi okulu," veribilimiokulu.com, Available: <https://www.veribilimiokulu.com/r-kare-ve-duzeltimis-r-kare/>, [Accessed: February. 16, 2023].

[24] "Regresyon analizi," wikipedia.org, Available: [https://tr.wikipedia.org/wiki/Regresyon\\_analizi](https://tr.wikipedia.org/wiki/Regresyon_analizi), [Accessed: May. 26, 2023].

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAE 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### Robustness Classification by Machine Learning from Vehicle Tire Surface Abrasions

Remzi Gürfidan<sup>a</sup>, Oğuzhan Kilim<sup>b</sup>, Tuncay Yiğit<sup>c</sup>, Bekir Aksoy<sup>d</sup>

Submitted: 17.11.2023 Revised: 08.12.2023 Accepted: 13.12.2023 doi:10.30855/gmbd.0705S15

#### ABSTRACT

The safety and durability of vehicle tires is an important variable in terms of driving safety and cost effectiveness. Different methods such as visual inspection, tire air pressure control, pattern depth measurements, rotation and balancing can be used to evaluate these factors. In this study, different machine learning algorithms such as ResNET50, DenseNET121, AlexNET, CNN, which are image-based, are used to analyse the images of the tire surface to determine the surface wear of the vehicle tires and to perform robustness classification. For the training of the models, 1447 vehicle tire surface images of different categories (very good, good, bad, very bad) were used. The dataset containing the images belongs to the authors of this study and is unique. In the future, it is aimed to make the dataset available for copyrighted use on an open platform. The results obtained from the trained models are compared. The CNN algorithm, which showed the most successful results, was selected as the final algorithm. In conclusion, this paper represents an important step towards solving safety and efficiency issues in the automotive industry by introducing a machine learning approach to detect surface wear and robustness classification of vehicle tires. This technology has the potential to optimize tire management and maintenance.

#### Araç Lastiği Yüzey Aşınmalarından Makine Öğrenmesi ile Sağlık Sınıflandırması

#### ÖZET

Araç lastiklerinin güvenliği ve dayanıklılığı, sürüş güvenliği ve maliyet etkinliği açısından önemli bir değişkendir. Bu faktörleri değerlendirmek için görsel inceleme, lastik hava basıncı kontrolü, desen derinliği ölçümleri, rotasyon ve balans ayarı gibi farklı yöntemler kullanılabilir. Bu çalışmada, araç lastiklerinin yüzey aşınmasını belirlemek için lastik yüzeyine ait görüntüleri analiz etmek ve sağlık sınıflandırması yapmak için görüntü tabanlı olan ResNET50, DenseNET121, AlexNET, CNN gibi farklı makine öğrenmesi algoritmaları kullanılmıştır. Modellerin eğitimi için farklı kategorilerde (çok iyi, iyi, kötü, çok kötü) 1447 araç lastik yüzey görüntüsü kullanılmıştır. Görüntüleri içeren veri kümesi bu çalışmanın yazarlarına aittir ve özgündür. Gelecekte veri setinin açık bir platformda telifli olarak kullanıma sunulması hedeflenmektedir. Eğitilen modellerden elde edilen sonuçlar karşılaştırılmıştır. En başarılı sonuçları gösteren CNN algoritması nihai algoritma olarak seçilmiştir. Sonuç olarak, bu makale, araç lastiklerinin yüzey aşınmasını ve sağlık sınıflandırmasını tespit etmek için bir makine öğrenimi yaklaşımı sunarak otomotiv endüstrisindeki güvenlik ve verimlilik sorunlarını çözmeye yönelik önemli bir adımı temsil etmektedir. Bu teknoloji, lastik yönetimi ve bakımını optimize etme potansiyeline sahiptir.

**Keywords:** Tire wear, tire durability, durability classification, machine learning, CNN

<sup>a</sup> Isparta University of Applied Sciences, Yalvac Vocational School of Technical Sciences; Computer Programming  
32100 - Isparta, Türkiye  
Orcid: [0000-0002-4899-2219](https://orcid.org/0000-0002-4899-2219)  
e mail: [remzigurfidan@isparta.edu.tr](mailto:remzigurfidan@isparta.edu.tr)

<sup>b</sup> Isparta University of Applied Sciences, Keçiborlu Vocational School; Computer Programming  
32100 - Isparta, Türkiye  
Orcid: [0000-0003-3365-7327](https://orcid.org/0000-0003-3365-7327)

<sup>c</sup> Süleyman Demirel University, Engineering Faculty, Computer Engineering  
32500 - Isparta, Türkiye  
Orcid: [0000-0001-7397-7224](https://orcid.org/0000-0001-7397-7224)

<sup>d</sup> Isparta University of Applied Sciences, Engineering Faculty; Mechatronics Engineering  
32100 - Isparta, Türkiye  
Orcid: [0000-0001-8052-9411](https://orcid.org/0000-0001-8052-9411)

<sup>\*</sup>Corresponding author: [remzigurfidan@isparta.edu.tr](mailto:remzigurfidan@isparta.edu.tr)

**Anahtar Kelimeler:** Lastik aşınması, lastik dayanıklılığı, dayanıklılık sınıflandırması, makine öğrenmesi, CNN

## 1. Introduction

Transportation is vital in modern life. Many people use their vehicles to get to work, to travel or for other activities of daily life. However, the safe movement of these vehicles and the prevention of accidents while traveling in traffic are critical for vehicle owners and other drivers. At this point, the role of vehicle tires cannot be ignored. Tires are the only part of a vehicle in contact with the road surface. It is crucial to monitor the interaction between the tire and the road to obtain important tire-road contact information. Vehicle tires are a critical component that directly affects the performance, fuel efficiency and, most importantly, safety of vehicles.

Tires that are frequently exposed to hard and uneven surfaces wear faster. Surface irregularities such as potholes, sharp stones and pits damage tires. Driving at high speeds causes tires to wear faster. This causes the tires to generate more heat, which increases wear. Tread sensors are used for this purpose and can monitor the interaction between the tire and the road, as well as determining the deflection of the tread elements within the contact patch. The types of sensors used are mainly accelerometers, piezoelectric or magnetic sensors [1]. Compared to manual inspection, computer vision-based methods offer great convenience for automated online inspections. However, besides significant computational complexity, feature extraction and selection are crucial steps in these techniques. As the number of categories increases, feature extraction becomes increasingly difficult. Identifying the most appropriate features describing different target categories remains up to the researcher's judgment and extensive experimentation. Each feature definition has to deal with a significant number of parameters that have to be tuned by the actuator. Artificial features also do not adequately represent all types of faults. As a result, traditional methods primarily focus on detecting single texture structures or specific types of defects [2].

A tire that can adjust its properties according to the vehicle's performance and operating conditions has the potential to improve safety. For example, a tire that can vary the inflation pressure can change the sliding stiffness and contact patch dimensions according to contact conditions (high or low adhesion) and tire wear. Furthermore, in the event of a tire failure, an active tire can send a warning message to the driver, allowing them to slow down safely [3].

Vehicle safety has long been a priority for the automotive industry, especially with the rise of autonomous vehicles. Real-time monitoring of the vehicle and its surroundings is essential. A smart tire system is a comprehensive monitoring solution that uses various sensors to directly detect tire pressure, temperature and other parameters. The Tire Pressure Monitoring System (TPMS) is a notable example of such intelligent systems. TPMS can measure tire pressure in real time and many researchers have developed efficient TPMSs using various devices. However, current TPMS can only provide basic information about the vehicle. To guarantee safe driving, it is crucial to provide additional complex data such as tire wear status and tire vertical load [4]. In this paper, considering the impact of the age and novelty of vehicle tires on transportation and driving safety, we will classify tire conditions with machine learning algorithms.

## 2. Related Works

A 2021 study presented a method based on image processing and machine learning to predict the lifespan of vehicle tires. An original image database was created for the study. Using image processing techniques, texture features of the tire image were extracted, and these features were classified with K-nearest neighbour (KNN). After the classification, the lifetime of the vehicle tires was estimated. Mean precision (MAP) and confusion matrix were used as evaluation criteria. According to the classification results, over 80% accuracy was obtained [5]. In a study where LabVIEW stereo vision and image processing methods were used together, the depth of the tire tread was measured, and the driver was informed when the tire tread depth dropped below 1.6 mm [6]. In the study for the classification of tire defects, classification accuracy was tried to be improved with limited samples in varying lighting environments. Deep learning-based algorithms were investigated to achieve high accuracy. Tire image contrast normalization and data augmentation were used to avoid overfitting problems. An average accuracy of 98.47% was achieved with the proposed CNN-based method [7]. Cui et al. developed an image reconstruction algorithm that automatically detects tire defects from X-ray images of vehicle tires. From their proposed work, they were able to detect the rough shape of these defects while revealing the defect locations. It is stated that the proposed method is not suitable for very large defects and defects that have severely damaged the tire tissue [8]. In a study combining Curvelet transform and Canny

edge detection, tire surface defects were detected by laser shear analysis. The detection results were evaluated with laser stereography images and compared with technological methods. Experimental results showed that the proposed method outperformed LoG, Canny, and Sobel edge detection methods in accurately detecting edges [2]. In a study conducted by Nguyen et al. in 2018, they proposed a wear model that considers history dependence and directional effects to predict the wear of new model tire treads. In their proposed model, they introduced directional damages to characterize the history of frictional sliding contact. The model also includes flash temperature, sliding speed and contact pressure. FEM simulation with different loading conditions was performed to analyse the model numerically and theoretically [9]. Chen et al. presented a nonlinear dynamic model of a multi-axle steering vehicle to predict the amount of lateral wear of vehicle tires. Based on simulation and experimental results, they proved that the nonlinear model is better than a linear model in calculating tire wear [10]. In a study using tree-based classification, they measured tire tread depth or tire pressure by calculating tire circumference. In this way, they calculated the tire rotation frequency, especially in older vehicles. Using mobile phone accelerometer and GPS data, this study predicted changes in tire pressure and tire condition with 80% accuracy [11].

Kim et al. developed an algorithm to estimate the wear rate of vehicle tires and evaluate the functionality of the tire. Tire wear and information from the vehicle tire were processed with estimation algorithms based on different combinations and the algorithm performances were quantitatively compared. They stated that all vehicle and tire information should be used together for the highest accuracy of tire wear prediction [12]. In 2020, Li et al. proposed a tire wear prediction algorithm based on the smart tire concept and finite element model analysis theory. They created a finite element model for a 205/55/R16 tire on ABAQUS software. They applied the finite element method to the model with load, tire pressure, wear and speed values. They predicted tire wear with an average error of 0.00874 mm with the algorithm they proposed using a neural network [13]. Kim et al. cited braking, acceleration, tread condition and tire contact force as important parameters in driving safety. In their study, they introduced a smart tire system using acceleration sensor, wireless signal carrier and tread classifier. They used an artificial neural network and a multilayer perceptron model as the tread classifier. As a result of their experiments, they predicted tread wear over 80% [14]. Poloni and Lu, in their study, evaluated the wear of a vehicle tire using the signals of on-board sensors. With the proposed method, they estimated whether a vehicle tire is worn and how long it can be used without replacement. In this estimation, they focused on rolling radius estimation [15]. Behroozinia et al. designed a computational method that detects defects in vehicle tires to investigate the concept of smart tires for monitoring the health of vehicle tires. By comparing the accelerations of defective and intact vehicle tires, they obtained information about the location and magnitude of the tire defect. To obtain this information, they used implicit dynamic analysis and created a finite element model of the tire [1]. The comparison table with similar studies in the literature is shown in Table 1.

Table 1. Comparison table with similar studies in the literature

Reference	Technique	Accuracy	Year
[5]	KNN	%80	2021
[7]	CNN	%98.47	2017
[11]	Tree-based classification	%80	2018
[13]	ANN Alg.	0.00874 AVG Error	2020
[14]	ANN & MPC	%80	2020
<b>This Work</b>	CNN	%99.72	2023

### 3. Proposed Method and Evaluation

A large dataset of vehicle tires was collected and carefully pre-processed to develop a successful machine learning model. The data preprocessing process was extensively designed to reduce noise, remove unwanted data, and enable the model to learn better. After data collection, the data was organized and cleaned. In this stage, missing data points were filled in to remove missing or corrupted data, and data anomalies were identified and corrected. In addition, the data was properly scaled and normalized to reduce noise in the dataset. Sample images of the dataset are shown in Figure 1. The dataset was obtained by the authors from never-used, in-use and retired vehicle tires. In addition, the classifications within the dataset were determined by 2 field experts.





Figure 1. Sample images of the dataset

A CNN (Convolutional Neural Network) model was then applied to process the data and train the model. This model could learn the complexity of the data thanks to convolutional layers. Pooling layers were used to reduce the size of the data and extract features. The flattening layer transformed the data into a flat vector and finally the density layers were used to produce the model's predictions. During the model training process, the dataset was split into training and validation datasets. The model started learning on the training data and then evaluated its performance on the validation data set. To improve the success rate of the model, hyperparameters were adjusted and regularization techniques were applied to avoid overfitting. Figure 2 shows the architecture of the CNN model.

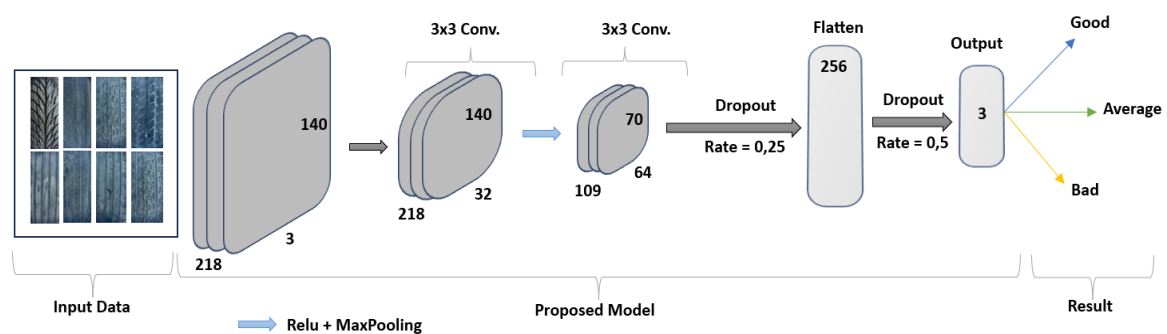


Figure 2. CNN model architecture

Feature maps are extracted using the Convolutional Layer, which applies a collection of filters (kernels) to the input data. By highlighting and identifying characteristics, the filtration process aids in the extraction of features from the incoming data. Layer Flattening Typically, 3D tensors are used as feature maps that are derived from the convolutional and pooling layers. These 3D tensors are flattened into a vector via the flatten layer. Data is fed into the fully connected levels using this. In other words, it flattens the CNN's output so that typical artificial neural network (ANN) layers can link to it. In addition to reducing size, the MaxPooling Layer is utilized in feature maps to draw attention to their most significant features. This layer chooses the biggest value inside a specified region to subsample. As features are moved to deeper layers of the network, this guarantees feature scalability while lowering the computing burden.

The graphs showing the success and loss values of the CNN (Convolutional Neural Network) algorithm are

very important visual representations that provide valuable information about the performance and training progress of the proposed classification model. In Figure 3, these graphs serve as a window into the model's learning journey, shedding light on the optimization process, and helping us understand how well the model fits the dataset. The success graph, usually denoted as accuracy, shows the model's ability to correctly classify data points over training periods. As the model learns, the accuracy curve reveals whether the model improves or plateaus, allowing us to measure how well the model performs on the training data. Constant and increasing accuracy indicates that the model is learning and generalizing effectively. In contrast, the loss graph shows the model's training loss, which measures the difference between the model's predictions and the actual target values. A decreasing loss curve is indicative of the model's capacity to minimize errors and improve its predictions. The loss function plays a fundamental role in guiding the model towards convergence and ideally towards lower loss values over time.

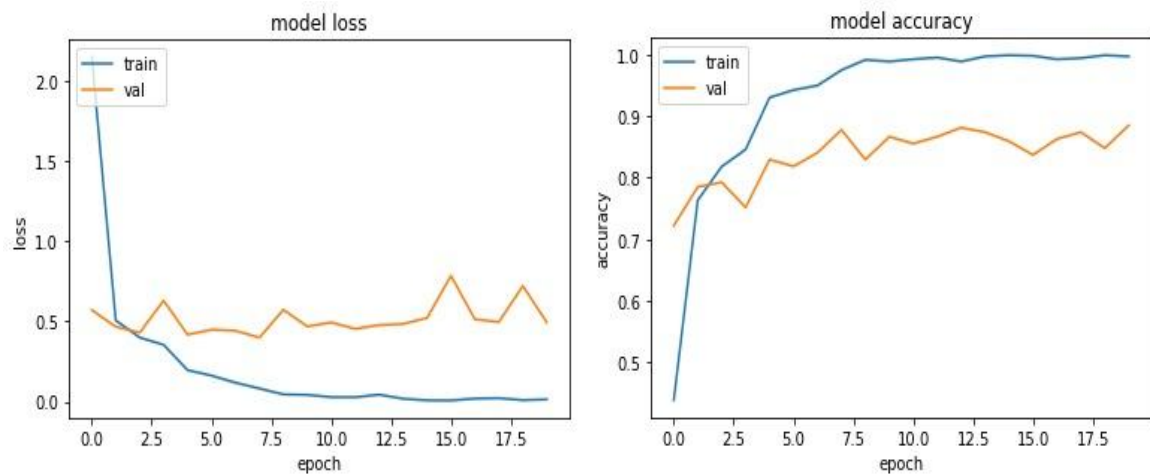


Figure 3. Variation graph of success and loss values

The dataset was divided into two parts, 80% training data and 20% test data. With the resulting dataset, 20 epochs of training were repeated. According to the Val\_accuracy metric, the CNN algorithm achieved 99.72% accuracy. In the CNN model, which gave the most successful result, the loss value decreased to 0.0130.




Figure 4. Complexity matrix of algorithms

Table 2 shows the values of the metrics obtained according to the training results of the CNN algorithm. In the current study, the most successful results on the dataset belong to the CNN model preferred in this study. Based on the values in this table, it is seen that the trained model is successfully trained, and the dataset is suitable for training.

Table 2. Metric values in training results

Metrics	Values	Metrics	Values
loss	0.0130	accuracy	0.9972
recall_m	0.9972	precision_m	0.9972
f1_m	0.9972	val_loss	0.4943
val_accuracy	0.8852	val_recall_m	0.8924
val_precision_m	0.8924	val_f1_m	0.8924

The reason for choosing the metric values shown in Table 2 is itemized below.

- Accuracy is the most basic metric that indicates the percentage of correct classification of a CNN model. Accuracy is the ratio of correctly classified instances to total data points.
- Precision refers to the proportion of instances that the model predicts as positive that are positive. This metric is important to reduce false positive predictions.
- Sensitivity indicates what proportion of truly positive samples are correctly identified by the model. It is important for reducing false negative predictions.
- The F1 score measures the balance between sensitivity and precision. This metric aims to minimize both false positives and false negatives.

#### 4. Conclusions

The success of this study highlights the future potential of automatic classification systems focusing on vehicle tires. The 99.72% success rate obtained shows how effective the CNN algorithm can be, especially for tire classification. This success can be an important tool for tire manufacturers and dealers operating in the automobile industry. This advanced classification system can increase efficiency in production processes and improve product quality by allowing defective tires to be quickly identified. At the same time, it can increase customer confidence and contribute to preventive maintenance practices to ensure safe driving conditions. In future work, integrating image processing techniques, including depth measurements on tire surfaces, could allow the system to become more comprehensive and predictive. This could enable more precise prediction of important factors such as tire life. Furthermore, such a system should be considered for use in sectors other than the automotive industry. For example, a similar classification system for tires of industrial equipment could improve the safety of vehicles used in manufacturing plants. In conclusion, this study not only demonstrates the potential of deep learning methods on vehicle tire classification, but also lays a foundation that can contribute to real-world solutions for industrial applications.

#### Conflict of Interest Statement

No conflict of interest was declared by the authors.

#### References

- [1] P. Behroozinia, S. Taheri, and R. Mirzaeifar, "Tire health monitoring using the intelligent tire concept," *Structural Health Monitoring* vol. 18, no. 2, pp. 390–400, Feb. 2018, doi:10.1177/1475921718756602.
- [2] Y. Zhang, T. Li, and Q. Li, "Defect detection for tire laser shearography image using curvelet transform based edge detector," *Optics & Laser Technology*, vol. 47, pp. 64–71, Apr. 2013, doi:10.1016/J.OPTLASTEC.2012.08.023.
- [3] F. Braghin, M. Brusarosco, F. Cheli, A. Cigada, S. Manzoni, and F. Mancosu, "Measurement of contact forces and patch features by means of accelerometers fixed inside the tire to improve future car active control," *Vehicle System Dynamics*, vol. 44, no. SUPPL. 1, pp. 3–13, 2006, doi:10.1080/00423110600867101.
- [4] H. Zhang, S. Zhang, Y. Zhang, X. Huang, and Y. Dai, "Abrasion status prediction with BP neural network based on an intelligent tire system," *2020 4th CAA International Conference on Vehicular Control and Intelligence, CVCI 2020*, pp. 619–622, Dec. 2020, doi:10.1109/CVCI51460.2020.9338547.
- [5] J. Zhu, K. Han, and S. Wang, "Automobile tire life prediction based on image processing and machine learning technology," *Advances in Mechanical Engineering*, vol. 13, no. 3, Mar. 2021, doi: 10.1177/16878140211002727
- [6] H. Bhanare and A. Khachane, "Quality Inspection of Tire using Deep Learning based Computer Vision," *International Research Journal of Engineering and Technology* vol. 6, no.11 pp.3555-3558, 2019, [Online]. Available: www.irjet.net [Accessed: Oct. 08, 2023].
- [7] X. Cui, Y. Liu, Y. Zhang, and C. Wang, "Tire Defects Classification with Multi-Contrast Convolutional Neural Networks," *International Journal of Pattern Recognition and Artificial Intelligence* vol. 32, no. 4, Dec. 2017, doi:10.1142/S0218001418500118.

- [8] X. Cui, Y. Liu, and C. Wang, "Defect automatic detection for tire X-ray images using inverse transformation of principal component residual," *2016 3rd International Conference on Artificial Intelligence and Pattern Recognition, AIPR 2016*, pp. 18–25, Oct. 2016, doi:10.1109/ICAIPR.2016.7585205.
- [9] V. H. Nguyen, D. Zheng, F. Schmerwitz, and P. Wriggers, "An advanced abrasion model for tire wear," *Wear*, vol. 396–397, pp. 75–85, Feb. 2018, doi:10.1016/J.WEAR.2017.11.009.
- [10] X. Chen, N. Xu, and K. Guo, "Tire wear estimation based on nonlinear lateral dynamic of multi-axle steering vehicle," *International Journal of Automotive Technology*, vol. 19, no. 1, pp. 63–75, Feb. 2018, doi:10.1007/S12239-018-0007-2/METRICS.
- [11] J. Siegel, R. Bhattacharyya, S. Sarma, and A. Deshpande, "Smartphone-based vehicular tire pressure and condition monitoring," *Lecture Notes in Networks and Systems*, vol. 15, pp. 805–824, 2018, doi:10.1007/978-3-319-56994-9\_56/COVER.
- [12] K. Kim, H. Park, and T. Kim, "Comparison of Performance of Predicting the Wear Amount of Tire Tread Depending on Sensing Information," *Sensors 2023, Vol. 23, Page 459*, vol. 23, no. 1, p. 459, Jan. 2023, doi:10.3390/S23010459.
- [13] B. Li, Z. Quan, S. Bei, L. Zhang, and H. Mao, "An estimation algorithm for tire wear using intelligent tire concept," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* vol. 235, no. 10–11, pp. 2712–2725, Feb. 2021, doi:10.1177/0954407021999483.
- [14] Y.-J. Kim, H.-J. Kim, J.-Y. Han, and S. Lee, "Classification of Tire Tread Wear Using Accelerometer Signals through an Artificial Neural Network," *Journal of the Korean Society of Industry Convergence*, vol. 23, no. 2\_2, pp. 163–171, 2020, doi:10.21289/KSIC.2020.23.2.163.
- [15] T. Poloni and J. Lu, "An Indirect Tire Health Monitoring System Using On-board Motion Sensors," *SAE Technical Papers*, vol. 2017-March, no. March, Mar. 2017, doi:10.4271/2017-01-1626.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## A Review on the Impact of Polylactic Acid (PLA) Material on Products Manufactured Using Fused Deposition Modeling (FDM) Additive Manufacturing Method

Abdullah Burak Keşkeççi<sup>a,\*</sup>, Merdan Özkahraman<sup>b</sup>, Hilmi Cenk Bayrakçı<sup>c</sup>

Submitted: 18.11.2023 Revised: 13.12.2023 Accepted: 15.12.2023 doi:10.30855/gmbd.0705S16

### ABSTRACT

**Keywords:** Additive Manufacturing (AM), Fused Deposition Modeling (FDM), Polylactic Acid (PLA), Strength testing, Polymer

<sup>a,\*</sup> Isparta University Of Applied Sciences, Technology Faculty, Dept. of Mechatronics Engineering 32200 - Isparta, Türkiye  
Orcid: 0000-0001-8432-7470  
e mail: aburakkeskekci@gmail.com

<sup>b,\*</sup> Isparta University Of Applied Sciences, Technology Faculty, Dept. of Mechatronics Engineering 32200 - Isparta, Türkiye  
Orcid: 0000-0002-3501-6497

<sup>c,\*</sup> Isparta University Of Applied Sciences, Technology Faculty, Dept. of Mechatronics Engineering 32200 - Isparta, Türkiye  
Orcid: 0000-0001-5064-7310

\*Corresponding author:  
aburakkeskekci@gmail.com

This compilation article extensively examines the role and impact of Polylactic Acid (PLA) material in products manufactured using Fused Deposition Modeling (FDM) method in additive manufacturing (AM). Presently, 3D printing technologies are rapidly proliferating across numerous industries and applications. Performance and impact in the FDM printing process can vary based on factors like; infill pattern, printing orientation, PLA's melting temperature, feed rate, and layer thickness. Infill patterns and printing orientation significantly affect the mechanical durability, surface quality, and printing duration of the product. Hence, the identification and optimization of suitable parameters are crucial for the effective utilization of PLA in 3D printing. This compilation gathers research from the existing literature regarding PLA's role and performance in the FDM printing process, encompassing PLA's structural and mechanical attributes, the influence of printing parameters and infill patterns, and the industrial applications of products manufactured using PLA. Specifically, the physical and chemical characteristics of PLA, optimization of printing parameters, geometry of infill patterns, printing orientation, and layer structure are examined. This study aims to provide a comprehensive reference regarding the characteristics and performance of PLA. It is intended to be a valuable resource for researchers, industry professionals, and academics engaged in the fields of design and engineering.

## Eriyik Yıgırdırmalı Modelleme (FDM) İmalat Yöntemi Kullanılarak Üretilen Ürünler Üzerinde Polilaktik Asit (PLA) Malzemenin Etkisine Dair Bir İnceleme

### ÖZ

Bu derleme, Eklemeli İmalat (AM) yöntemlerinden olan Eriyik Yıgırdırmalı Modelleme (FDM) yöntemi kullanılarak üretilen ürünlerde Polilaktik Asit (PLA) malzemenin rolünü ve etkisini geniş bir şekilde incelemektedir. Şu anda, 3D baskı teknolojileri pek çok endüstri ve uygulama alanında hızla yayılmaktadır. FDM baskı sürecindeki performans ve etki; dolgu deseni, baskı yönü, PLA'nın erime sıcaklığı, besleme hızı ve katman kalınlığı gibi faktörlere bağlı olarak değişebilir. Dolgu desenleri ve baskı yönü, ürünün mekanik dayanıklılığını, yüzey kalitesini ve baskı süresini önemli ölçüde etkiler. Bu nedenle, PLA'nın 3D baskıda etkili kullanımı için uygun parametrelerin belirlenmesi ve optimizasyonu hayati önem taşır. Bu derleme, PLA'nın FDM baskı sürecindeki rolü ve performansı hakkında mevcut literatürden araştırmalar toplar ve PLA'nın yapısal ve mekanik özelliklerini, baskı parametreleri ve dolgu desenlerinin etkisini ve PLA kullanılarak üretilen ürünlerin endüstriyel uygulamalarını kapsar. Özellikle, PLA'nın fiziksel ve kimyasal özellikleri, baskı parametrelerinin optimizasyonu, dolgu desenlerinin geometrisi, baskı yönü ve katman yapısı incelenmektedir. Bu çalışma, PLA'nın özellikleri ve performansı hakkında kapsamlı bir referans sağlamayı amaçlamaktadır. Tasarım ve mühendislik alanlarında çalışan araştırmacılar, endüstri profesyonelleri ve akademisyenler için değerli bir kaynak olmayı hedeflemektedir.

**Anahtar Kelimeler:** Eklemeli İmalat, Eriyik Yıgırdırmalı Modelleme, Polylactic Acid, Dayanım testi, Polimer

## 1. Introduction

Additive Manufacturing (AM) technologies have brought about a profound transformation in the manufacturing industry by enabling the production of intricate parts, offering opportunities for rapid prototyping, and facilitating functional manufacturing. In contrast to traditional manufacturing methods that involve subtractive processes like cutting or machining, additive manufacturing constructs three dimensional components layer by layer, providing unparalleled design flexibility and customization prospects. This capability has led to remarkable advancements in various sectors, including defense, aerospace, automotive, dentistry, and biomedicine [1, 2].

Fused Deposition Modeling (FDM) stands out as a widely adopted additive manufacturing technique, recognized for its versatility, cost effectiveness, and availability in desktop 3D printers [3]. FDM involves the gradual fusion of thermoplastic filaments, such as acrylonitrile butadiene styrene (ABS) or polylactic acid (PLA), to fabricate three dimensional objects. This technology has evolved from applications in rapid prototyping and visual aids to functional part production in industries like aerospace and biomedicine [4-6]. Nonetheless, the widespread adoption of FDM for functional part manufacturing has been hampered by certain limitations. Achieving optimal quality and mechanical properties in parts produced with FDM necessitates meticulous evaluation of various printing parameters, including configuration method, layer thickness, infill patterns, and feed rate. These parameters exert significant influence on the structural and mechanical performance of parts created through FDM [7, 8].

Among the array of materials suitable for FDM, PLA has emerged as a favored choice. PLA is an aliphatic polyester derived from renewable sources, such as starch, offering a more sustainable alternative in contrast to fossil based polymers. PLA's low melting temperature facilitates seamless processing in desktop 3D printers, rendering it a preferred option for hobbyists and small scale production endeavors [9]. Despite PLA's popularity, a comprehensive comprehension of its performance within the FDM process remains incomplete. While previous research has delved into the effects of various process parameters on FDM parts, there exists limited literature specifically addressing the mechanical properties of PLA based products manufactured using low cost 3D printers. Additionally, further research is imperative to explore the influence of printing orientation, layer thickness, and feed rate on the mechanical performance of PLA specimens [10, 11].

With the aim of bridging these gaps and delivering a comprehensive reference concerning the attributes and performance of PLA in the FDM 3D printing process, this review article endeavors to scrutinize the role and impact of PLA material in products created through FDM technology. By synthesizing existing research and conducting experimental analyses, this study strives to provide deeper insights into the structural and mechanical properties of PLA, the ramifications of printing parameters and infill patterns, and the industrial applications of products manufactured using PLA. The ultimate objective is to enhance our comprehension of PLA's attributes and performance and facilitate the effective utilization of FDM 3D printing technology. Within this article, the performance of PLA in the FDM process will be meticulously assessed through various parameter methodologies. It will explore the mechanical and structural characteristics of PLA based FDM printed parts and deliberate on the influence of printing parameters, infill patterns, and configurations on PLA's performance. Furthermore, it will delve into the industrial applications of PLA within FDM technology and contemplate potential future developments. This review aspires to serve as a valuable resource for 3D printing researchers, practitioners, and enthusiasts, imparting insights into the attributes and performance of PLA within the context of FDM 3D printing technology.

## 2. Fused Deposition Modeling (FDM)

Fused Deposition Modeling (FDM) represents a significant subtype within the realm of three dimensional (3D) printing technology. This methodology employs the layer by layer fusion of thermoplastic materials to fabricate 3D objects [12, 13]. The process initiates with the creation or scanning of a digital model, which is then transformed into an STL file format. Subsequently, a 3D printer deposits liquefied material onto a platform via a heated print head, progressively constructing each layer. Following the completion of each layer, the material undergoes rapid cooling and solidification, ultimately culminating in the production of the intended object [14, 15]. FDM has garnered wide recognition as a pivotal 3D printing technology utilized across diverse applications, including prototyping, custom part manufacturing, industrial design, and various others [16-18]. Figure 1 provides a schematic depiction of a printer employing this technique. This

manufacturing approach encompasses several crucial process parameters, the impacts of which are elucidated in the subsequent sections.

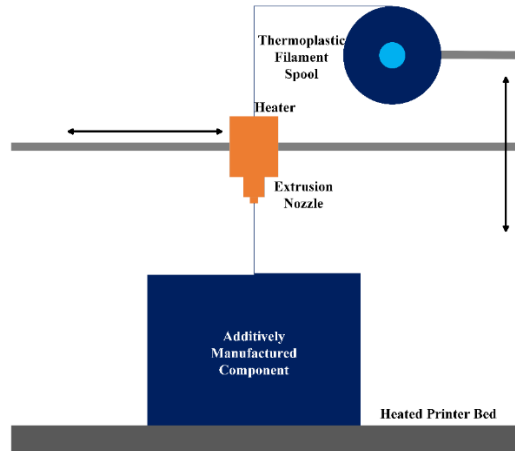


Figure 1. Schematic representation of FDM production

## 2.1. Manufacturing parameters

The Fused Deposition Modeling (FDM) process encompasses various process parameters that significantly impact both production efficiency and the ultimate characteristics of the final product. Crucial adjustable process parameters during the FDM process include layer thickness, build orientation, extrusion temperature, infill density, infill pattern, shell count, print speed, raster orientation, raster width, and post processing temperature (the latter being the final process parameter) [19]. The effects and significance of these fundamental process parameters are further elucidated below. Some schematic representations of FDM production parameters are presented in Figure 2.




Figure 2. Schematic representation of FDM production parameters for ASTM D638 model [20-22]

### 2.1.1. Layer thickness

Layer thickness is a critical process parameter in the domain of Fused Deposition Modeling (FDM) [23]. This parameter refers to the thickness of the layers formed during the extrusion process and is measured along the Z-axis, which corresponds to the vertical direction of the FDM apparatus. Typically, the layer thickness is smaller than the diameter of the extruder nozzle. It is a factor of paramount importance that exerts a significant influence on the results of FDM printing, requiring careful calibration. The determination of this parameter depends on various factors. Firstly, the diameter of the extruder nozzle plays a crucial role in determining the layer thickness; smaller nozzle diameters result in thinner layers. Furthermore, the material properties used in the process also impact the layer thickness [24, 25]. The material may require specific temperature and flow characteristics to achieve the desired layer thickness after extrusion.

Layer thickness has a profound impact on critical aspects of the final print, including surface roughness,

durability, and level of detail. Therefore, the precise adjustment of this parameter is an essential aspect of achieving the desired outcomes in FDM printing.

### 2.1.2. Build orientation

The term "build orientation" represents a significant process parameter in 3D printing. It determines the direction or position in which an object will be created during 3D printing [26, 27]. In other words, it serves as a reference for how the object will be oriented and in which direction the layers will be constructed. Build orientation can influence the final properties, strength, smoothness, and printing time of an object [28, 29]. For example, if an object is printed horizontally, it may require more supports and result in a longer printing time, but the final product may have a smoother surface. On the other hand, printing in a vertical direction can reduce the need for supports, result in a faster printing time, but may increase surface roughness. Build orientation should be carefully selected based on the requirements of the design, material properties, and desired outcomes. Choosing the correct build orientation is a critical decision that can impact the successful implementation of the 3D printing process.




Figure 3. Schematic representation of three different build orientations for FDM production.

### 2.1.3. Raster angle/raster orientation

The term "raster angle" or "raster orientation" represents another crucial process parameter used during 3D printing [30, 31]. It determines the angle or direction in which the layers of an object will be positioned during printing. Raster angle or raster orientation defines how the layers will be drawn and how these lines will be placed on the surface of the object. This parameter can affect the mechanical properties, surface roughness, and aesthetic appearance of the object [32]. The raster angle can either increase or decrease the durability of an object and influence the final printing result. It also affects the printing time and material usage. Raster angle or raster orientation should be carefully chosen based on the requirements of the 3D printing design, material properties, and desired outcomes. This parameter is a critical decision for the accurate and optimized production of an object.






Figure 4. Schematic representation of different raster angles and orientations in FDM production

#### 2.1.4. Layer height

Layer height refers to the thickness of the layers or slices used during the 3D printing process [33]. This parameter significantly affects how an object is constructed and influences the printing outcomes. Layer height determines the printing resolution. Thinner layer heights are used to achieve higher resolution and smoother surfaces, while thicker layer heights may result in faster prints with less detail [34]. 3D software or 3D printer settings allow users to adjust layer height according to their preferences. The selection of this parameter can vary depending on project requirements and design features. Choosing the right layer height is a critical decision with a significant impact on the results of 3D printing and should be adjusted carefully.

#### 2.1.5. Air gap

The parameter of paramount significance in the context of Fused Deposition Modeling (FDM) process is the air gap. FDM operates on the principle of progressively depositing layers of materials, such as plastic filament or wire, during 3D printing. Therefore, it is imperative for these materials to fuse effectively. The air gap represents a pivotal parameter responsible for establishing the separation between layers, either facilitating a secure bond between them or preventing the entrapment of air [35, 36]. Improper calibration of the air gap can lead to observable imperfections, fissures, or feeble connections on the surfaces of produced objects. This can subsequently compromise the structural integrity and endurance of the final product. Furthermore, the incorrect adjustment of the air gap can impede the proper amalgamation of layers, thus affecting the surface texture of the end product. The precise configuration of the air gap parameter may fluctuate based on the characteristics of the printing material, printing velocity, and the design intricacies of the object. Effectively calibrating the air gap parameter can significantly augment the efficacy of the FDM process, resulting in sturdier, more refined, and superior quality objects. Hence, meticulous fine tuning of the air gap parameter assumes a position of profound importance in the realm of FDM 3D printing.

#### 2.1.6. Extrusion temperature

Extrusion temperature is a vital process parameter in the Fused Deposition Modeling (FDM) process. This term refers to the temperature required to liquefy and layer thermoplastic filament or material used by a 3D printer for the proper creation of layers. Extrusion temperature is adjusted depending on the type and characteristics of the material being used. Correct melting and fluidity of the material at the right temperature ensure the firm bonding of layers and the desired quality of the print [37, 38]. Misadjustment of extrusion temperature can result in printing errors or material issues. Therefore, accurate adjustment of the extrusion temperature parameter is crucial for the quality and outcomes of FDM printing [39]. Manufacturer recommendations and trial and error methods can assist in achieving the correct extrusion temperature setting.

### 2.1.7. Print speed

Print speed, within the scope of 3D printing, represents the rate at which a 3D printer's print head fabricates objects, whether utilizing Fused Deposition Modeling (FDM) or other 3D printing methodologies [40]. This parameter exerts considerable influence over aspects such as inter layer bonding quality, printing duration, and the intricacies of the final product. Increased print speeds may lead to quicker results; however, an escalation in speed can have adverse effects on print quality, especially when producing complex or finely detailed objects. This may potentially result in heightened surface roughness or hinder the proper fusion of individual layers [41, 42]. The choice of an appropriate print speed should take into account factors such as design complexity, material properties, and the capabilities of the specific 3D printing equipment in use. Achieving the desired outcomes necessitates careful consideration of the optimal print speed. Consequently, the precise adjustment of the print speed parameter assumes paramount importance within the domain of 3D printing projects.

### 2.1.8. Infill pattern

Infill pattern refers to the pattern used to fill the interior of a 3D printed object [43-47]. This pattern determines how the material used to create the object's interior structure will be deposited and arranged. The infill pattern can affect the efficiency, strength, and material usage in the 3D printing process. For example, higher infill density (more fill) can make the object stronger but may require more material and extend printing time. Infill pattern can also influence the weight and cost of the object. 3D printer software typically offers various infill pattern options, including straight lines, hexagonal, square, and random patterns. The choice of infill pattern may vary depending on the intended use and design requirements of the object. Therefore, careful adjustment of the infill pattern parameter has a significant impact on the outcomes of 3D printing.

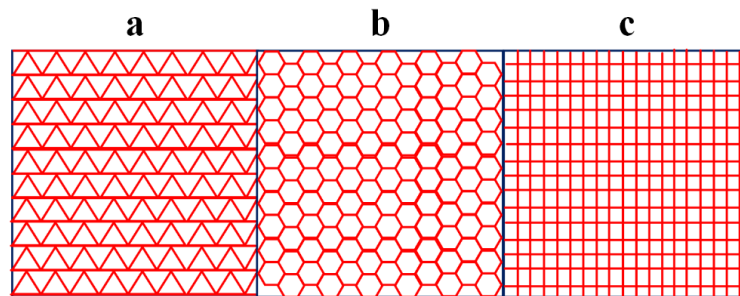


Figure 5. Schematic representation of different infill patterns

### 2.1.9. Infill density/interior infill percentage

This parameter determines how much of the interior of a 3D object will be filled. Infill density is usually expressed as a percentage (%) and represents the ratio of the filled portion of the object's interior structure to the total volume. This parameter balances material savings and object strength in 3D printing. Higher infill density results in a more solid interior structure, requiring more material but potentially increasing the object's strength. Lower infill density conserves material but may reduce the object's strength [44, 48]. 3D printer software often allows users to adjust infill density, giving designers control over the object's interior structure and strength. The choice of infill density may vary depending on the project's purpose, material cost, and printing time. Therefore, the selection of infill density is crucial and should be adjusted carefully.

### 2.1.10. Nozzle diameter

Nozzle diameter refers to the diameter of the print head at the tip of 3D printers. This parameter significantly affects how the filament or material used in 3D printing is extruded and impacts printing results. Nozzle diameter may vary between different 3D printer models and can be adjusted according to the user's preferences. Smaller nozzle diameters are typically used for achieving higher resolution and detailed prints, while larger nozzle diameters are preferred for faster printing with thicker layers [50, 51]. Nozzle diameter must match the selected material type and significantly influences printing results. The correct nozzle diameter selection affects the quality, speed, and outcomes of 3D printing. Therefore, 3D printer users often carefully evaluate and select the nozzle diameter that suits their project requirements. PLA (Polylactic Acid)

filament commonly comes in diameters of 1.75 mm and 2.85 mm, with the choice depending on the specific 3D printer model and project requirements. For instance, numerous desktop 3D printers are designed to work with a 1.75 mm filament diameter, whereas certain industrial 3D printers utilize larger 2.85 mm filament diameters. Consequently, the selection of the PLA filament diameter is contingent upon the 3D printer chosen and the demands of the project.

#### 2.1.11. Raster width

Raster width represents another significant process parameter used in Fused Deposition Modeling (FDM) or similar 3D printing processes. This term specifies the width at which the print head contacts the printing surface when creating the layers of a 3D object. Raster width determines how close or far apart layers will be, thereby affecting the printing outcome [55, 56]. Smaller raster widths can result in more detailed and smoother results but may extend the printing time and require more material. Larger raster widths can lead to faster printing and less material consumption but may increase surface roughness. Raster width should be adjusted based on project requirements, material properties, and printing speed. This parameter exerts a notable influence on the results of 3D printing and must be meticulously fine tuned to attain the desired equilibrium between quality and speed.

#### 2.1.12. Bed temperature

In the context of 3D printing, the term 'bed temperature' refers to the temperature of the printing platform or bed [57, 58]. This parameter holds paramount significance in ensuring the successful execution of the printing process, and this importance arises from the following factors:

- **Adhesion and Warping Control:** Maintaining the print platform at a specific temperature ensures the proper adhesion of the 3D printing material (e.g., PLA or ABS) to the print bed. This helps prevent undesired detachment of the object and deformation. Additionally, temperature control aids in managing warping, a phenomenon in which the material contracts and distorts as it cools.
- **Thermal Expansion Management:** Keeping the print platform at a specific temperature ensures the proper adhesion of the material and the accurate bonding of layers. This enhances the quality of the final product and ensures the layers adhere firmly.
- **Material Compatibility:** Different 3D printing materials perform optimally at different bed temperatures. Therefore, the bed temperature should be adjusted based on the type of material used. For example, PLA material typically requires a bed temperature between 60-70°C, while ABS adheres at higher temperatures (100-110°C).

In conclusion, bed temperature is a critical parameter in FDM 3D printing processes to enhance print quality, prevent adhesion issues, and ensure material compatibility [59]. Properly adjusting this parameter is essential for achieving successful and robust 3D prints.

#### 2.1.13. Number of contours

The term 'Number of Contours' denotes the quantity of layers forming both the internal structure and the outer surface of an object throughout the 3D printing process [60, 61]. The number of contours can impact the object's level of detail, durability, and final appearance. More contours can result in a sturdier and more detailed object but may increase print time and material consumption. Fewer contours can lead to faster prints and reduced material usage but may sacrifice detail. The number of contours can be adjusted through 3D software or printer settings. This parameter can vary depending on project requirements and design complexity, so selecting the right number of contours is crucial and should be done carefully.

#### 2.1.14. Contour width

Contour width represents the width of the contours or perimeter layers created during a 3D object's printing process. Contour width determines how thick the outer surface layers of the object will be and how these contours will be formed. This parameter can influence the print's outcome, the object's durability, and its aesthetic appearance. A wider contour width can result in thicker outer surface layers, while a narrower

contour width can yield more detailed and smoother surfaces. Contour width can be set through 3D software or printer settings and should be adjusted based on project requirements and design characteristics. Hence, the selection of contour width significantly influences the outcomes of 3D printing and necessitates meticulous calibration.

#### 2.1.15. Contour to contour air gap

Contour to contour air gap refers to the distance between successive contour or perimeter layers of an object during the 3D printing process [62, 63]. It determines the proximity of one layer to the next, thereby influencing the outcome of the print, the structural integrity of the object, and its surface quality. A greater Contour to Contour Air Gap results in increased spacing between layers, whereas a smaller gap leads to tighter layer bonding. This parameter can be fine tuned through 3D software or printer settings, and its selection may vary depending on project specifications, material characteristics, and design intricacies. Consequently, the choice of the Contour to Contour Air Gap significantly impacts the 3D printing results and necessitates meticulous adjustment.

#### 2.1.16. Feed rate

Feed rate refers to the rate of progression of a material or substance through a process or machine. This term is used in various industrial processes and manufacturing systems, including 3D printing [64, 65]. In the context of 3D printing, feed rate determines how filament or material is fed to the print head and how layers are built. This parameter affects printing speed and results [66]. A faster feed rate can expedite the printing process but may impact surface roughness and print quality. A slower feed rate may contribute to higher quality results but may extend printing time. Feed rate can be adjusted through 3D software or printer settings and may vary based on factors such as material type, layer height, and object complexity.

#### 2.1.17. Printing speed

In the context of the 3D printing process, the term "Printing Speed" denotes the rate at which the print head of a 3D printer traverses while progressively constructing each layer of an object. This speed balances printing quality with fast results [40, 67]. Higher printing speeds can often lead to faster results but may result in rougher surfaces and reduced detail [68]. Slower speeds, on the other hand, can provide smoother, more precise, and higher quality prints but may extend printing time. Printing speed should be adjusted based on factors such as material type, layer height, and object complexity.

#### 2.1.18. Pigmentation

The importance of pigmentation in production parameters, particularly in 3D printing processes like FDM, plays a critical role in product quality and aesthetics. Pigmentation not only determines the color and appearance of the final product but also has significant effects on its functionality and perceptibility [69]. Firstly, pigmentation can enhance the aesthetic appeal of a product. The choice of colors significantly affects the visual appeal and aesthetic value of an object. Colors can reflect the design language, intended use, and even brand identity of a product. Therefore, the correct color choice can increase the overall acceptance and attractiveness of a product. Additionally, pigmentation has an impact on the functionality of a product. Especially in industrial design, different colors can enhance the visibility of different components or functional areas. This can help users better understand and use the product. For example, marking different functional parts of medical devices with different colors can facilitate correct usage. Beyond this, pigmentation is essential for product identification. Color coding can help quickly and accurately identify specific parts or components. This can assist in error prevention and increased efficiency in processes such as maintenance, repair, or assembly. In conclusion, the role of pigmentation in FDM production parameters is versatile and critical for product quality. The color choice can enhance aesthetic value while improving functionality and identifiability. It is an important parameter to consider in design and manufacturing processes and can impact the end user experience.

#### 2.1.19. Relative humidity

Relative humidity denotes the percentage of water vapor existing in the atmosphere at a specific temperature, serving as an indicator of atmospheric moisture levels [70, 71]. It constitutes a pivotal parameter necessitating

scrutiny and regulation across various domains, encompassing material warehousing, the food industry, construction, meteorological prognostication, among others. This parameter delineates the concentration of water vapor within the air and exhibits variability contingent upon temperature. Typically, relative humidity is quantified as a percentage (%). For instance, a 50% relative humidity signifies that the air is halfway saturated with water vapor, while 100% relative humidity signifies complete saturation. Relative humidity assumes a position of significance in the context of Fused Deposition Modeling (FDM) for the following reasons:

- **Material Drying:** Filaments used in FDM, such as PLA or ABS, should be kept at low relative humidity levels during production. A humid filament can lead to undesired outcomes during printing, such as adhesion issues or surface quality degradation. Therefore, maintaining low relative humidity levels during filament drying and storage is crucial.
- **Printing Quality:** In the FDM process, it is essential for the material to flow and adhere correctly. High relative humidity can harm the internal structure of the filament, leading to printing problems. Conversely, low relative humidity can make the filament brittle. Hence, maintaining the correct relative humidity levels is vital for improving printing quality.
- **Material Performance:** Relative humidity can affect the performance of the material used in FDM. Relative humidity levels can influence properties such as durability, strength, and other physical attributes of the material. Paying attention to the relative humidity of the material can contribute to achieving the desired results.

In conclusion, controlling relative humidity in the FDM process is a critical factor that influences printing quality, material performance, and final results. Therefore, individuals involved in 3D printing should be attentive to relative humidity levels during the storage and usage of filaments.

## 2.2. Verification of production

Fused Deposition Modeling (FDM) technology employs a range of verification tests and parameters to evaluate the reliability and performance of 3D printing. These tests are crucial for assessing the quality and suitability of produced objects.

- **Tensile Strength Test:** This test measures how much force 3D printing material can withstand when subjected to tension. It is critical for evaluating product durability and strength. Similarly, the compression strength test determines how the material performs under compression forces.
- **Dimensional Accuracy Tests:** These tests assess how faithfully the printed object's dimensions match the intended design dimensions during the 3D printing process. They are used to ensure that the printed measurements fall within specified tolerances.
- **Printing Time and Surface Roughness:** Printing time and surface roughness are significant parameters that affect production efficiency and the final appearance and usability of the product. Printing time determines efficiency and production duration, while surface roughness influences the object's visual quality and usability.
- **Bending Strength Test:** The bending strength test evaluates how resistant an object is to bending forces. This is important for understanding how objects will behave under real world usage conditions.

All these tests are employed during the design and manufacturing phases to enhance the quality and efficiency of FDM 3D printing. Determining the appropriate parameters and routinely conducting these tests improve the quality of end products and mitigate potential issues. Figure 6 depicts a cause and effect diagram for FDM production parameters.



Figure 6. Fishbone Diagram for FDM Production Parameters [7]

### 3. Literature Review on Manufacturing Parameters

Research focused on the analysis of process parameters represents a critical area of investigation with the overarching objective of enhancing the efficiency of modern manufacturing processes while optimizing product quality. This line of research entails a systematic examination of fundamental process parameters used in various production techniques, including domains such as 3D printing, machining (including milling and turning), and additive manufacturing. The primary goal of such research endeavors is to comprehend, optimize, and contribute to the advancement of these processes, rendering them more sustainable and efficient. This is achieved by assessing the impact of these process parameters on the final product's quality and production efficiency.

In the specific context of 3D printing, process parameter analysis assumes critical importance as it aims to elucidate and enhance the effects of specific parameters during the layer by layer fabrication of objects. These parameters include, but are not limited to, layer height, printing speed, infill density, nozzle diameter, and temperature settings. These parameters are thoroughly examined within the scope of research, and their optimal combinations are determined through rigorous experimental studies and meticulous data analysis. This systematic approach serves to elevate overall result quality, enhancing print precision, durability, and surface finish.

In the field of process parameter analysis research, Design of Experiments (DOE) methodologies are commonly employed. These methodologies utilize statistical analysis and modeling techniques to discern the influence of various parameters on the final product's characteristics. Such investigations hold profound significance, not only for process refinement and quality enhancement but also for expanding the application horizons across diverse industrial sectors.

In summary, research efforts dedicated to the analysis of process parameters play a pivotal role in the quest to enhance efficiency, elevate quality standards, and foster innovation in contemporary manufacturing practices. This field of study is considered an indispensable component, propelling progress in critical domains such as manufacturing and 3D printing. Table 1 provides a comprehensive analysis of manufacturing parameters associated with the Fused Deposition Modeling (FDM) method using PLA material, as derived from the existing body of literature. It is noteworthy that all parameters listed in the table

have undergone rigorous testing through tensile strength experiments.

Table 1. Literature analysis of manufacturing parameters of the FDM method with PLA material

Reference	Experimental Tested Parameters	Parameter Values
[1]	Layer Height Raster Angle/Raster Orientation	0.4 mm, 0.3 mm, 0.2 mm 0°, 45°, 90°
[9]	Layer Thickness Raster Angle/Raster Orientation	0.1 mm, 0.12 mm, 0.15 mm, 0.18 mm, 0.2 mm 0°, 18°, 45°, 72°, 90°
[5]	Build Orientation Layer Thickness	Flat (F), On-edge (O), Upright (U) 0.06 mm, 0.12 mm, 0.18 mm, 0.24 mm
[8]	Feed Rate Extrusion Temperature Relative Humidity Pigmentation	20 mm/sn, 50 mm/sn, 80 mm/sn 180°C, 190°C, 200°C, 220°C, 240°C %16, %50, %98 Pink, Green, Gray, Transparent
[72]	Infill Pattern Raster Angle/Raster Orientation	Concentric, Grid, Triangle, Cross 3D, Zik Zak 0°, 45°, 90°
[73]	Infill Density Print Speed Extrusion Temperature Infill Pattern	%20, %100 100 mm/sn, 130 mm/sn 180°C, 220°C Gyroid, Cross 3D, Grid
[74]	Raster Angle/Raster Orientation Infill Density Print Speed Extrusion Temperature Layer Height Infill Pattern	175°, 180°, 185°, 205° %20, %50, %80, %100 70 mm/sn, 90 mm/sn, 120 mm/sn 170 mm/sn 175°C, 180°C, 185°C, 205°C 0.1 mm, 0.25 mm, 0.3 mm, 0.4 mm Diamond, Linear, Hexagonal
[75]	Extrusion Temperature Build Orientation Print Speed	200°C, 215°C, 220°C, 225°C, 235°C X, Y, Z, 45° 20 mm/sn, 40 mm/sn, 60 mm/sn
[76]	Layer Thickness Infill Pattern	0.150 mm, 0.175 mm, 0.200 mm Grid, Triangular, Honeycomb
[77]	Layer Thickness Extrusion Temperature Raster Angle/Raster Orientation Infill Density	0.1 mm, 0.2 mm 200°C, 220°C 0°, +45°, -45°, 90° %20, %40, %60
[78]	Raster Angle/Raster Orientation Layer Thickness Raster Width	0°, 45°, 90° 0.1 mm, 0.2 mm, 0.3 mm 0.5 mm, 0.6 mm, 0.7 mm
[79]	Infill Density Raster Angle/Raster Orientation Infill Pattern	%20, %100 0°, 30°, 45°, 90° Fast Honeycomb, Full Honeycomb Wiggle, Triangular, Grid, Rectilinear
[80]	Raster Angle/Raster Orientation Infill Density Print Speed	0° +45°, -45°, 90° %50, %75, %100 30 mm/sn, 60 mm/sn, 90 mm/sn
[81]	Raster Angle/Raster Orientation Infill Pattern	0°, +45°, -45°, 90° Straight, Honeycomb
[82]	Raster Angle/Raster Orientation	0°, 45°, 90°
[83]	Infill Pattern	Grid, Tri-hexagonal, Concentric
[84]	Layer Thickness Extrusion Temperature Infill Pattern	0.1 mm, 0.2 mm, 0.3 mm 205°C, 215°C, 225°C Cubic, Cubic sub Division, Quarter cubic

Table 1 presents a detailed literature analysis of various manufacturing parameters used in Fused Deposition Modeling (FDM) with Polylactic Acid (PLA) material, covering 17 different studies. The studies encompass a wide range of parameters such as layer height, raster angle/orientation, layer thickness, build orientation, feed rate, extrusion temperature, relative humidity, pigmentation, infill pattern, infill density, and print speed. These parameters show significant variability in their values. For instance, layer heights vary from 0.1 mm to 0.4 mm, extrusion temperatures from 175°C to 240°C, and print speeds from 20 mm/s to 170 mm/s. Despite the extensive range of parameters studied, some areas appear under researched. Traditional parameters like layer thickness and extrusion temperature are commonly focused, while factors like relative humidity and pigmentation are less explored. Future studies could benefit from focusing on these less explored parameters.

Overall, this analysis provides a comprehensive overview of the current state of research in FDM with PLA, highlighting extensive work in some areas while underlining the need for further research in others. Such studies are vital for advancing the field and enhancing practical applications of FDM 3D printing with PLA.

#### 4. Discussion and Conclusion

Numerous experimental design techniques and optimization methodologies have been employed to determine the optimal combination of variables within the Fused Deposition Modeling (FDM) process. The primary objective is to either maximize or minimize specific desired outcomes. These approaches serve the crucial purpose of identifying the most influential process parameters, evaluating interactions among these parameters, and quantifying the extent to which each FDM process parameter influences the output variables. In the preceding section, we presented a comparative analysis of various experimental design techniques and optimization methods, emphasizing their distinct characteristics. Comprehensive review and analysis of the Fused Deposition Modeling (FDM) process, particularly using PLA material, underscore the significance of optimizing various process parameters to enhance part quality. The presented table details an array of experimental parameters tested in various studies, including layer height, raster angle/orientation, layer thickness, build orientation, feed rate, extrusion temperature, relative humidity, pigmentation, infill pattern, and print speed. These parameters are pivotal in determining the dimensional precision, surface texture, and overall quality of the FDM produced parts.

The analysis reveals a diverse range of parameter values, indicating the breadth of experimental approaches in the field. For instance, layer height values range from 0.06 mm to 0.4 mm, while extrusion temperatures span from 175°C to 240°C. Such variations highlight the complex interplay of these parameters in FDM printing and the necessity to understand their individual and combined effects.

Interestingly, certain parameters, such as relative humidity and pigmentation, have not been as extensively explored as others like layer thickness and raster orientation. This observation opens new avenues for research, suggesting that these lesser studied parameters might significantly impact the FDM process's efficiency and output quality.

Furthermore, the incorporation of diverse infill patterns and densities, as well as varying print speeds, suggests a rich area for further exploration in optimizing FDM processes. The table underscores the potential for enhancing part quality by meticulously adjusting these parameters.

The significance of this research lies in its critical role in shaping the overall efficiency and quality of FDM processes. The noteworthy findings presented in this compilation underscore the necessity for further exploration in the following domains:

- FDM primarily finds compatibility with thermoplastic materials, leading to a substantial focus on thermoplastics like PLA and ABS in FDM research. However, there has been an extension of studies to encompass other thermoplastics such as PETG, Nylon, and various composite materials.
- Some FDM process parameters have received more extensive scrutiny in comparison to others. Parameters like raster orientation/raster angle, layer thickness, FDM part build orientation, and raster width have garnered heightened attention. Conversely, parameters like internal infill patterns, infill densities, extrusion temperatures, contour counts, and others have received comparatively less analysis.
- The majority of optimization efforts have centered around the optimization of either a single output variable or multiple output variables, albeit independently rather than concurrently. Consequently, there exists a compelling need for additional research in the domain of multi objective optimization, which addresses the simultaneous optimization of multiple output variables.
- Many optimization techniques are rooted in statistical methodologies. An interdisciplinary research approach could involve the development of FDM process parameter optimization techniques utilizing image processing, Machine Learning, and Deep Learning.
- Furthermore, it is imperative to evaluate and model uncertainty at various stages of the FDM process.



This includes considering uncertainty factors within the optimization algorithms and inherent uncertainties in the mathematical modeling of the FDM process.

## Conflict of Interest Statement

Authors of this paper state that there is no conflict of interest.

## References

- [1] B. M. M. Tymrak, M. Kreiger, and J. M. Pearce, "Mechanical properties of components fabricated with open-source 3-D printers under realistic environmental conditions," *Mater. Des.*, vol. 58, 2014, doi: 10.1016/j.matdes.2014.02.038i.
- [2] M. Sugavaneswaran and G. Arumaikkannu, "Analytical and experimental investigation on elastic modulus of reinforced additive manufactured structure," *Mater. Des.*, vol. 66, no. PA, pp. 29–36, Feb. 2015, doi: 10.1016/J.MATDES.2014.10.029.
- [3] M. Domingo-Espin, J. M. Puigoriol-Forcada, A. A. Garcia-Granada, J. Llumà, S. Borros, and G. Reyes, "Mechanical property characterization and simulation of fused deposition modeling Polycarbonate parts," *Mater. Des.*, vol. 83, pp. 670–677, 2015, doi: 10.1016/j.matdes.2015.06.074.
- [4] B. Rankouhi, S. Javadpour, F. Delfanian, and T. Letcher, "Failure Analysis and Mechanical Characterization of 3D Printed ABS With Respect to Layer Thickness and Orientation," *J. Fail. Anal. Prev.*, vol. 16, no. 3, pp. 467–481, 2016, doi: 10.1007/s11668-016-0113-2.
- [5] J. M. Chacón, M. A. Caminero, E. Garcia-Plaza, and P. J. Núñez, "Additive manufacturing of PLA structures using fused deposition modelling: Effect of process parameters on mechanical properties and their optimal selection," *Mater. Des.*, vol. 124, pp. 143–157, 2017, doi: 10.1016/j.matdes.2017.03.065.
- [6] D. Arup and Y. Nita, "A systematic survey of RUM process parameter optimization and their influence on part characteristics of nickel 718," *Sci. Rep.*, vol. 13, no. 1, 2023, doi: 10.1038/s41598-023-28674-1.
- [7] A. Jaisingh Sheoran and H. Kumar, "Fused Deposition modeling process parameters optimization and effect on mechanical properties and part quality: Review and reflection on present research," *Mater. Today Proc.*, vol. 21, pp. 1659–1672, 2020, doi: 10.1016/j.matpr.2019.11.296.
- [8] A. P. Valerga, M. Batista, J. Salguero, and F. Giroto, "Influence of PLA filament conditions on characteristics of FDM parts," *Materials (Basel)*, vol. 11, no. 8, 2018, doi: 10.3390/ma11081322.
- [9] A. Lanzotti, M. Grasso, G. Staiano, and M. Martorelli, "The impact of process parameters on mechanical properties of parts fabricated in PLA with an open-source 3-D printer," *Rapid Prototyp. J.*, vol. 21, no. 5, pp. 604–617, 2015, doi: 10.1108/RPJ-09-2014-0135.
- [10] J. Kotlinski, "Mechanical properties of commercial rapid prototyping materials," *Rapid Prototyp. J.*, vol. 20, no. 6, pp. 499–510, 2014, doi: 10.1108/RPJ-06-2012-0052.
- [11] O. A. Mohamed, S. H. Masood, and J. L. Bhowmik, "Optimization of fused deposition modeling process parameters: a review of current research and future prospects," *Adv. Manuf.*, vol. 3, no. 1, pp. 42–53, 2015, doi: 10.1007/s40436-014-0097-7.
- [12] K. Thrimurthulu, P. M. Pandey, and N. V. Reddy, "Optimum part deposition orientation in fused deposition modeling," *Int. J. Mach. Tools Manuf.*, vol. 44, no. 6, pp. 585–594, 2004, doi: 10.1016/j.ijmactools.2003.12.004.
- [13] A. Boschetto and L. Bottini, "Accuracy prediction in fused deposition modeling," *Int. J. Adv. Manuf. Technol.*, vol. 73, no. 5–8, pp. 913–928, 2014, doi: 10.1007/s00170-014-5886-4.
- [14] K. Rajan, M. Samykan, K. Kadirgama, W. S. W. Harun, and M. M. Rahman, *Fused deposition modeling: process, materials, parameters, properties, and applications*, vol. 120, no. 3–4. Springer London, 2022. doi: 10.1007/s00170-022-08860-7.
- [15] T. Grimm, "17. Fused deposition modeling: a technology evaluation," *Time-Compression Technol.*, vol. 11, no. 2, pp. 1–6, 2003, [Online]. Available: <http://www.trosol.com/fortus/downloads/WPGrimm.pdf>
- [16] O. S. Carneiro, A. F. Silva, and R. Gomes, "Fused deposition modeling with polypropylene," *Mater. Des.*, vol. 83, pp. 768–776, 2015, doi: 10.1016/j.matdes.2015.06.053.
- [17] A. Bellini and S. Güçeri, "Mechanical characterization of parts fabricated using fused deposition modeling," *Rapid Prototyp. J.*, vol. 9, no. 4, pp. 252–264, 2003, doi: 10.1108/13552540310489631.
- [18] D. K. Ahn, S. M. Kwon, and S. H. Lee, "Representation for surface roughness distribution of FDM processed parts," *ICSMA 2008 - Int. Conf. Smart Manuf. Appl.*, no. May 2008, pp. 490–493, 2008, doi: 10.1109/ICSMA.2008.4505572.
- [19] J. R. C. Dizon, A. H. Espera, Q. Chen, and R. C. Advincula, "Mechanical characterization of 3D-printed polymers," *Addit. Manuf.*, vol. 20, pp. 44–67, 2018, doi: 10.1016/j.addma.2017.12.002.

- [20] V. Shanmugam, M. V. Pavan, K. Babu, and B. Karnan, "Fused deposition modeling based polymeric materials and their performance: A review," *Polym. Compos.*, vol. 42, no. 11, pp. 5656–5677, 2021, doi: 10.1002/pc.26275.
- [21] K. G. J. Christiyani, U. Chandrasekhar, and K. Venkateswarlu, "A study on the influence of process parameters on the Mechanical Properties of 3D printed ABS composite," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 114, no. 1, 2016, doi: 10.1088/1757-899X/114/1/012109.
- [22] J. J. Laureto and J. M. Pearce, "Anisotropic mechanical property variance between ASTM D638-14 type i and type iv fused filament fabricated specimens," *Polym. Test.*, vol. 68, no. March, pp. 294–301, 2018, doi: 10.1016/j.polymertesting.2018.04.029.
- [23] O. Lužanin, D. Movrin, and M. Plan, "Effect of Layer Thickness, Deposition Angle, and Infill on Maximum Flexural Force in Fdm-Built Specimens," vol. 39, no. 1, 2014, [Online]. Available: <http://www.dpm.ftn.uns.ac.rs/jtp/download/2014/1/Article6.pdf>
- [24] W. Wu, P. Geng, G. Li, D. Zhao, H. Zhang, and J. Zhao, "Influence of layer thickness and raster angle on the mechanical properties of 3D-printed PEEK and a comparative mechanical study between PEEK and ABS," *Materials (Basel)*, vol. 8, no. 9, pp. 5834–5846, 2015, doi: 10.3390/ma8095271.
- [25] S. Farashi and F. Vafaee, "Effect of printing parameters on the tensile strength of FDM 3D samples: a meta-analysis focusing on layer thickness and sample orientation," *Prog. Addit. Manuf.*, vol. 7, no. 4, pp. 565–582, 2022, doi: 10.1007/s40964-021-00247-6.
- [26] M. F. Afrose, S. H. Masood, P. Iovenitti, M. Nikzad, and I. Sbarski, "Effects of part build orientations on fatigue behaviour of FDM-processed PLA material," *Prog. Addit. Manuf.*, vol. 1, no. 1–2, pp. 21–28, 2016, doi: 10.1007/s40964-015-0002-3.
- [27] M. F. Afrose, S. H. Masood, M. Nikzad, and P. Iovenitti, "Effects of Build Orientations on Tensile Properties of PLA Material Processed by FDM," *Adv. Mater. Res.*, vol. 1044–1045, pp. 31–34, 2014, doi: 10.4028/www.scientific.net/AMR.1044-1045.31.
- [28] S. Raut, V. S. Jatti, N. K. Khedkar, and T. P. Singh, "Investigation of the Effect of Built Orientation on Mechanical Properties and Total Cost of FDM Parts," *Procedia Mater. Sci.*, vol. 6, no. 1cmcp, pp. 1625–1630, 2014, doi: 10.1016/j.mspro.2014.07.146.
- [29] R. H. Hambali, K. Celik, P. Smith, A. Rennie, and M. Ucar, "Effect of build orientation on FDM parts: a case study for validation of deformation behaviour by FEA," *no. September*, pp. 20–21, 2010, [Online]. Available: <http://eprints.lancs.ac.uk/50979/>
- [30] I. Durgun and R. Ertan, "Experimental investigation of FDM process for improvement of mechanical properties and production cost," *Rapid Prototyp. J.*, vol. 20, no. 3, pp. 228–235, 2014, doi: 10.1108/RPJ-10-2012-0091.
- [31] A. W. Gebisa and H. G. Lemu, "Influence of 3D printing FDM process parameters on tensile property of ultem 9085," *Procedia Manuf.*, vol. 30, pp. 331–338, 2019, doi: 10.1016/j.promfg.2019.02.047.
- [32] I. J. Solomon, P. Sevel, and J. Gunasekaran, "A review on the various processing parameters in FDM," *Mater. Today Proc.*, vol. 37, no. Part 2, pp. 509–514, 2020, doi: 10.1016/j.matpr.2020.05.484.
- [33] R. D. Bintara, D. Z. Lubis, and Y. R. Aji Pradana, "The effect of layer height on the surface roughness in 3D Printed Polylactic Acid (PLA) using FDM 3D printing," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1034, no. 1, p. 012096, 2021, doi: 10.1088/1757-899x/1034/1/012096.
- [34] H. K. Dave et al., "Compressive Strength of PLA based Scaffolds: Effect of layer height, Infill Density and Print Speed," *Int. J. Mod. Manuf. Technol.*, vol. 11, no. 1, pp. 21–27, 2019.
- [35] T. Nancharaiah, D. Raju, and V. Raju, "An experimental investigation on surface quality and dimensional accuracy of FDM components," *J. Emerg. Technol.*, vol. 1, no. 2, pp. 106–111, 2010, [Online]. Available: [https://www.researchgate.net/profile/Tata-Nancharaiah-2/publication/267248480\\_An\\_experimental\\_investigation\\_on\\_surface\\_quality\\_and\\_dimensional\\_accuracy\\_of\\_FDM\\_components/link/s5c9af7be92851cf0ae9a0180/An-experimental-investigation-on-surface-quality-and-dimensional-accuracy-of-FDM-components.pdf](https://www.researchgate.net/profile/Tata-Nancharaiah-2/publication/267248480_An_experimental_investigation_on_surface_quality_and_dimensional_accuracy_of_FDM_components/link/s5c9af7be92851cf0ae9a0180/An-experimental-investigation-on-surface-quality-and-dimensional-accuracy-of-FDM-components.pdf)
- [36] M. F. Afrose, S. H. Masood, M. Nikzad, and P. Iovenitti, "Effects of Build Orientations on Tensile Properties of PLA Material Processed by FDM," *Adv. Mater. Res.*, vol. 1044–1045, pp. 31–34, 2014, doi: 10.4028/www.scientific.net/AMR.1044-1045.31.
- [37] J. W. Comb, W. R. Priedeman, and P. W. Turley, "FDM Technology Process Improvements," *Proc. Solid Free. Fabr. Symp.*, pp. 42–49, 1994.
- [38] B. Zharylkassyn, A. Perveen, and D. Talamona, "Effect of process parameters and materials on the dimensional accuracy of FDM parts," *Mater. Today Proc.*, vol. 44, pp. 1307–1311, 2021, doi: 10.1016/j.matpr.2020.11.332.
- [39] G. Kollamaram, D. M. Croker, G. M. Walker, A. Goyanes, A. W. Basit, and S. Gaisford, "Low temperature fused deposition modeling (FDM) 3D printing of thermolabile drugs," *Int. J. Pharm.*, vol. 545, no. 1–2, pp. 144–152, 2018, doi: 10.1016/j.ijpharm.2018.04.055.
- [40] L. Miazio, "Impact of Print Speed on Strength of Samples Printed in FDM Technology," *Agric. Eng.*, vol. 23, no. 2, pp. 33–38, 2019, doi: 10.1515/agriceng-2019-0014.
- [41] A. Nabavi-Kivi, M. R. Ayatollahi, P. Rezaeian, and N. Razavi, "Investigating the effect of printing speed and mode mixity on the fracture behavior of FDM-ABS specimens," *Theor. Appl. Fract. Mech.*, vol. 118, no. December 2021, p. 103223, 2022, doi: 10.1016/j.tafmec.2021.103223.

- [42] K. M. Agarwal, P. Shubham, D. Bhatia, P. Sharma, H. Vaid, and R. Vajpeyi, "Analyzing the Impact of Print Parameters on Dimensional Variation of ABS specimens printed using Fused Deposition Modelling (FDM)," *Sensors Int.*, vol. 3, no. September 2021, p. 100149, 2022, doi: 10.1016/j.sintl.2021.100149.
- [43] M. L. Dezaki and M. K. A. Mohd Ariffin, "The effects of combined infill patterns on mechanical properties in fdm process," *Polymers (Basel)*, vol. 12, no. 12, pp. 1–20, 2020, doi: 10.3390/polym12122792.
- [44] A. Pandzic, D. Hodzic, and A. Milovanovic, "Effect of infill type and density on tensile properties of pla material for fdm process," *Ann. DAAAM Proc. Int. DAAAM Symp.*, vol. 30, no. 1, pp. 545–554, 2019, doi: 10.2507/30th.daaam.proceedings.074.
- [45] D. Abbas, D. Mohammad Othman, H. Basil Ali, and C. Author, "Effect of infill Parameter on compression property in FDM Process," *Int. J. Eng. Res. and Application www.ijera.com*, vol. 7, no. 10, pp. 16–19, 2017, doi: 10.9790/9622-0710021619.
- [46] M. T. Biroz, D. Ledenyák, and M. Andó, "Effect of FDM infill patterns on mechanical properties," *Polym. Test.*, vol. 113, no. March, 2022, doi: 10.1016/j.polymertesting.2022.107654.
- [47] M. Qamar Tanveer, G. Mishra, S. Mishra, and R. Sharma, "Effect of infill pattern and infill density on mechanical behaviour of FDM 3D printed Parts- a current review," *Mater. Today Proc.*, vol. 62, pp. 100–108, 2022, doi: 10.1016/j.matpr.2022.02.310.
- [48] K. S. Kumar, R. Soundararajan, G. Shanthosh, P. Saravanakumar, and M. Ratteesh, "Augmenting effect of infill density and annealing on mechanical properties of PETG and CFPETG composites fabricated by FDM," *Mater. Today Proc.*, vol. 45, pp. 2186–2191, 2021, doi: 10.1016/j.matpr.2020.10.078.
- [49] M. Moradi, S. Meiabadi, and A. Kaplan, "3D Printed Parts with Honeycomb Internal Pattern by Fused Deposition Modelling: Experimental Characterization and Production Optimization," *Met. Mater. Int.*, vol. 25, no. 5, pp. 1312–1325, 2019, doi: 10.1007/s12540-019-00272-9.
- [50] W. Kiński and P. Pietkiewicz, "Influence of the Printing Nozzle Diameter on Tensile Strength of Produced 3D Models in FDM Technology," *Agric. Eng.*, vol. 24, no. 3, pp. 31–38, 2020, doi: 10.1515/agriceng-2020-0024.
- [51] I. Buj-Corral, A. Bagheri, A. Domínguez-Fernández, and R. Casado-López, "Influence of infill and nozzle diameter on porosity of FDM printed parts with rectilinear grid pattern," *Procedia Manuf.*, vol. 41, pp. 288–295, 2019, doi: 10.1016/j.promfg.2019.09.011.
- [52] R. Polak, F. Sedlacek, and K. Raz, "Determination of fdmprinter settings with regard to geometrical accuracy," *Ann. DAAAM Proc. Int. DAAAM Symp.*, no. August 2018, pp. 561–566, 2017, doi: 10.2507/28th.daaam.proceedings.079.
- [53] D. Syrylybayev, B. Zharylkassyn, A. Seisekulova, M. Akhmetov, A. Perveen, and D. Talamona, "Optimisation of Strength Properties of FDM Printed Parts — A," *Polymers (Basel)*, vol. 13, pp. 1–35, 2021.
- [54] M. Lalegani Dezaki, M. K. A. Mohd Ariffin, and S. Hatami, "An overview of fused deposition modelling (FDM): research, development and process optimisation," *Rapid Prototyp. J.*, vol. 27, no. 3, pp. 562–582, 2021, doi: 10.1108/RPJ-08-2019-0230.
- [55] A. Garg and A. Bhattacharya, "An insight to the failure of FDM parts under tensile loading: finite element analysis and experimental study," *Int. J. Mech. Sci.*, vol. 120, no. June 2016, pp. 225–236, 2017, doi: 10.1016/j.ijmecsci.2016.11.032.
- [56] D. Espalin, J. A. Ramirez, F. Medina, and R. Wicker, "Multi-material, multi-technology FDM: Exploring build process variations," *Rapid Prototyp. J.*, vol. 20, no. 3, pp. 236–244, 2014, doi: 10.1108/RPJ-12-2012-0112.
- [57] M. F. Afrose, S. H. Masood, M. Nikzad, and P. Iovenitti, "Effects of Build Orientations on Tensile Properties of PLA Material Processed by FDM," *Adv. Mater. Res.*, vol. 1044–1045, pp. 31–34, 2014, doi: 10.4028/www.scientific.net/AMR.1044-1045.31.
- [58] Y.-H. Choi, C.-M. Kim, H.-S. Jeong, and J.-H. Youn, "Influence of Bed Temperature on Heat Shrinkage Shape Error in FDM Additive Manufacturing of the ABS-Engineering Plastic," *World J. Eng. Technol.*, vol. 04, no. 03, pp. 186–192, 2016, doi: 10.4236/wjet.2016.43d022.
- [59] A. A. Rosli, R. K. Shuib, K. M. Ishak, Z. A. A. Hamid, M. K. Abdullah, and A. Rusli, "Influence of Bed Temperature on Warp, Shrinkage and," no. February 2019, 2020.
- [60] S. Deswal, R. Narang, and D. Chhabra, "Modeling and parametric optimization of FDM 3D printing process using hybrid techniques for enhancing dimensional preciseness," *Int. J. Interact. Des. Manuf.*, vol. 13, no. 3, pp. 1197–1214, 2019, doi: 10.1007/s12008-019-00536-z.
- [61] J. Giri, P. Shahane, S. Jachak, R. Chadge, and P. Giri, "Optimization of fdm process parameters for dual extruder 3d printer using artificial neural network," *Mater. Today Proc.*, vol. 43, pp. 3242–3249, 2021, doi: 10.1016/j.matpr.2021.01.899.
- [62] O. A. Mohamed, S. H. Masood, and J. L. Bhowmik, "Mathematical modeling and FDM process parameters optimization using response surface methodology based on Q-optimal design," *Appl. Math. Model.*, vol. 40, no. 23–24, pp. 10052–10073, 2016, doi: 10.1016/j.apm.2016.06.055.
- [63] S. B. Mishra, R. Malik, and S. S. Mahapatra, "Effect of External Perimeter on Flexural Strength of FDM Build Parts," *Arab. J. Sci. Eng.*, vol. 42, no. 11, pp. 4587–4595, 2017, doi: 10.1007/s13369-017-2598-8.
- [64] P. Pitayachaval and K. Masnok, "Feed rate and volume of material effects in fused deposition modeling nozzle wear," *2017 4th Int. Conf. Ind. Eng. Appl. ICIEA 2017*, pp. 39–44, 2017, doi: 10.1109/IEA.2017.7939175.

- [65] A. D. Mazurchevici, D. Nedelcu, and R. Popa, "Additive manufacturing of composite materials by FDM technology: A review," *Indian J. Eng. Mater. Sci.*, vol. 27, no. 2, pp. 179–192, 2020, doi: 10.56042/ijems.v27i2.45920.
- [66] K. A. Al-Ghamdi, "Sustainable FDM additive manufacturing of ABS components with emphasis on energy minimized and time efficient lightweight construction," *Int. J. Light. Mater. Manuf.*, vol. 2, no. 4, pp. 338–345, 2019, doi: 10.1016/j.ijlmm.2019.05.004.
- [67] et al., "Influence of printing speed on production of embossing tools using FDM 3d printing technology," *J. Graph. Eng. Des.*, vol. 8, no. 1, pp. 19–27, 2017, doi: 10.24867/jged-2017-1-019.
- [68] T. C. Yang and C. H. Yeh, "Morphology and mechanical properties of 3D printed wood fiber/poly(lactic acid) composite parts using Fused Deposition Modeling (FDM): The effects of printing speed," *Polymers (Basel)*, vol. 12, no. 6, p. 1334, 2020, doi: 10.3390/POLYM12061334.
- [69] A. Makuch, M. Bajkowskl, P. Skoczylas, and L. Majewski, "DSI method in study of elements made by fused deposition modelling (FDM)," *Przem. Chem.*, vol. 95, no. 1, pp. 84–88, 2016, [Online]. Available: <https://www.cheric.org/research/tech/periodicals/view.php?seq=1438088>
- [70] M. Demirtaş and E. Avcioglu, "Ambient Relative Humidity Effects on Mechanical Properties of FDM 3D Printed PLA Components," *Phys. Scr.*, vol. 98, May 2023, doi: 10.1088/1402-4896/acfcf.
- [71] J. Tyberg and J. H. Böhn, "FDM systems and local adaptive slicing," *Mater. Des.*, vol. 20, no. 2–3, pp. 77–82, 1999, doi: 10.1016/s0261-3069(99)00012-6.
- [72] Ö. ÖZMEN, H. K. SÜRMEEN, and A. SEZGİN, "3 Boyutlu Baskıda Do Biçiminin Çekme Dayaniminin Etkisi," *Mühendislik Bilim. ve Tasarım Derg.*, vol. 11, no. 1, pp. 336–348, 2023, doi: 10.21923/jesd.1095594.
- [73] S. BACAĞ, H. VAROL ÖZKAVAK, and M. M. SOFU, "Comparison of Mechanical Properties of 3D-Printed Specimens Manufactured Via FDM with Various Inner Geometries," *Iğdır Üniversitesi Fen Bilim. Enstitüsü Derg.*, vol. 11, no. 2, pp. 1444–1454, 2021, doi: 10.21597/jist.772977.
- [74] A. Alafaghani, A. Qattawi, B. Alrawi, and A. Guzman, "Experimental Optimization of Fused Deposition Modelling Processing Parameters: A Design-for-Manufacturing Approach," *Procedia Manuf.*, vol. 10, pp. 791–803, 2017, doi: 10.1016/j.promfg.2017.07.079.
- [75] S. Attoye, E. Malekipour, and H. El-Mounayri, "Correlation between process parameters and mechanical properties in parts printed by the fused deposition modeling process," *Conf. Proc. Soc. Exp. Mech. Ser.*, vol. 8, pp. 35–41, 2019, doi: 10.1007/978-3-319-95083-9\_8.
- [76] A. Chadha, M. I. Ul Haq, A. Raina, R. R. Singh, N. B. Penumarti, and M. S. Bishnoi, "Effect of fused deposition modelling process parameters on mechanical properties of 3D printed parts," *World J. Eng.*, vol. 16, no. 4, pp. 550–559, 2019, doi: 10.1108/WJE-09-2018-0329.
- [77] J. Fernandes, A. M. Deus, L. Reis, M. F. Vaz, and M. Leite, "Study of the influence of 3D printing parameters on the mechanical properties of PLA," *Proc. Int. Conf. Prog. Addit. Manuf.*, vol. 2018-May, pp. 547–552, 2018, doi: 10.25341/D4988C.
- [78] S. R. Rajpurohit and H. K. Dave, "Analysis of tensile strength of a fused filament fabricated PLA part using an open-source 3D printer," *Int. J. Adv. Manuf. Technol.*, vol. 101, no. 5–8, pp. 1525–1536, 2019, doi: 10.1007/s00170-018-3047-x.
- [79] C. Dudescu and L. Racz, "Effects of Raster Orientation, Infill Rate and Infill Pattern on the Mechanical Properties of 3D Printed Materials," *ACTA Univ. Cibiniensis*, vol. 69, no. 1, pp. 23–30, 2017, doi: 10.1515/aucts-2017-0004.
- [80] M. GÜNAY, S. GÜNDÜZ, H. YILMAZ, N. YAŞAR, and R. KAÇAR, "PLA Esaslı Numunelerde Çekme Dayanımı İçin 3D Baskı İşlem Parametrelerinin Optimizasyonu," *Politek. Derg.*, vol. 23, no. 1, pp. 73–79, 2020, doi: 10.2339/politek.422795.
- [81] M. M. Hanon, R. Marczis, and L. Zsidai, "Influence of the 3D printing process settings on tensile strength of PLA and HT-PLA," *Period. Polytech. Mech. Eng.*, vol. 65, no. 1, pp. 38–46, 2021, doi: 10.3311/PPme.13683.
- [82] T. Kozior and C. Kundera, "Evaluation of the Influence of Parameters of FDM Technology on the Selected Mechanical Properties of Models," *Procedia Eng.*, vol. 192, pp. 463–468, 2017, doi: 10.1016/j.proeng.2017.06.080.
- [83] M. Rismalia, S. Hidajat, I. Permana, B. Hadisujoto, M. Muslimin, and F. Triawan, "Infill pattern and density effects on the tensile properties of 3D printed PLA material," *J. Phys. Conf. Ser.*, vol. 1402, p. 44041, Dec. 2019, doi: 10.1088/1742-6596/1402/4/044041.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAE 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### Agricultural Product Recommendation System for Isparta Province Using Machine Learning Techniques

Gamze Yakut<sup>a</sup>, Rabia İlknur Çay<sup>b</sup>, Hasan Hüseyin Öztürk<sup>c</sup>

Submitted: 06.12.2023 Revised: 15.12.2023 Accepted: 18.12.2023 doi:10.30855/gmbd.0705S17

#### ABSTRACT

**Keywords:** soil fertility, artificial intelligence, randomforest, bagging algorithm

In rural areas, the failure to cultivate crops that are suitable for the soil's nutritional values and unwise practices like improper fertilization/irrigation can have negative consequences for both soil quality and crop yield. Soil analyses are important for determining the specific nutrient value ratios that agricultural areas possess. Farmers deciding what to plant in their fields without using soil analysis methods can lead to reduced crop yields in the following years. When choosing the crop to be harvested, parameters such as organic matter, pH, salinity, saturation, depth, potassium, phosphorus, and lime content should be examined. In addition, factors related to climatic and geographical characteristics such as sunlight, humidity, rainfall and altitude should also be taken into account when deciding which crop to grow in a particular region. This study aims to suggest the most productive crops to be grown in the desired region, taking into account the parameters analysing the soil structure and location-based climatic characteristics. To create a better model, exploratory data analysis methods were employed. Algorithms such as Random Forest, XG Boost and Bagging were used to make crop recommendations based on soil values. Among these models, it was observed that Bagging algorithm made the most accurate prediction with 63% accuracy rate. Additionally, a complexity matrix was used to evaluate the accuracy of our classification system.

<sup>a</sup> Isparta Uygulamalı Bilimler Üniversitesi, OSB MYO, Mekatronik Programı, Isparta, Türkiye  
Orcid: 0000-0002-8614-304X  
e mail: [gamzeyakut@isparta.edu.tr](mailto:gamzeyakut@isparta.edu.tr)

<sup>b</sup> Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği, Isparta, Türkiye  
Orcid: 0000-0002-2894-3540

<sup>c</sup> Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği, Isparta, Türkiye  
Orcid: 0009-0006-7082-1543

<sup>\*</sup>Corresponding author:  
[gamzeyakut@isparta.edu.tr](mailto:gamzeyakut@isparta.edu.tr)

### Makine Öğrenimi Teknikleri Kullanılarak Isparta İli İçin Tarımsal Ürün Önerme Sistemi

#### ÖZ

Kırsal bölgelerde, toprağın besin değerlerine uygun ürünlerin yetiştirilmemesi ve bilinçsiz gübreleme/sulama gibi uygulamalar, toprak kalitesi ve ürün verimi açısından olumsuz sonuçlar doğurmaktadır. Toprak analizleri, tarım alanlarının sahip olduğu özgün besin değeri oranlarını belirlemek için önemlidir. Çiftçilerin, toprak analiz yöntemlerini kullanmadan tarlalarında ne ekeceklerine karar vermeleri, ilerleyen yıllarda hasat edilecek ürünlerin verimini düşürebilir. Hasat edilecek ürünü seçerken organik madde, pH, tuzluluk, saturasyon, derinlik, potasyum, fosfor ve kireç gibi parametreler incelenmelidir. Ayrıca belirli bir bölgede hangi ürünün yetiştirileceğine karar verirken, güneş ışığı, nem, yağış ve rakım gibi iklim ve coğrafi özelliklerle ilgili faktörler de dikkate alınmalıdır. Bu çalışma, toprak yapısını analiz eden parametreleri ve konum bazlı iklim özelliklerini göz önüne alarak istenen bölgede yetiştirilecek en verimli ürünleri önermeyi amaçlamaktadır. Daha iyi bir model oluşturmak için keşifsel veri analizi yöntemleri kullanılmıştır. Toprak değerlerine dayalı olarak ürün önerileri yapmak için Random Forest, XG Boost ve Bagging gibi algoritmalar kullanılmıştır. Bu modeller arasında Bagging algoritmasının %63 doğruluk oranı ile en doğru tahminlemeyi yaptığı görülmüştür. Ayrıca, sınıflandırma sistemimizin doğruluğunu değerlendirmek için bir karmaşıklık matrisi kullanılmıştır.

**Anahtar Kelimeler:** toprak verimi, yapay zekâ, randomforest, bagging algoritması

## 1. Giriş (Introduction)

İnsanlık var olduğu günden beri doğrudan veya dolaylı olarak tarımla iç içe olmuştur. Temel ihtiyaçlarını karşılamının yanı sıra yaşam kalitesini daha da arttırmak için tarımı sürekli olarak kullanmıştır. Yaşadığı zamanın imkân tanıdığı teknolojik gelişmeleri çağın ihtiyaç ve gereklerine uygun bir şekilde tarımsal faaliyetlere entegre etmiştir. Böylece yaşadığı çevreyi sürekli olarak geliştirmiştir.

Tarım; bitkisel ve hayvansal mamullerin üretilmesi, işlenmesi, depolanması ve pazarlanması süreçlerini kapsayan bir bilim dalıdır [1],[2],[3]. İnsanlığın ilk zamanından bu yana tarım kültürü; üretim-tüketim faaliyetleri, tarım arazisi kullanım şekli gibi parametrelerde çeşitli evrelerden geçmiştir. İlk çağlarda ilkel yollarla ve tesadüflerle başlayan tarımsal üretim yöntemlerinin yerini günümüzde modern teknolojinin kullanıldığı teknikler almıştır [4]. Çağımızın en yeni gelişimi olan yapay zekâ sistemleri sağlık, eğitim, tarım, ulaşım, savunma sanayi gibi pek çok alanda öncelikli olarak kullanılmaktadır. Spesifik olarak tarımda; bitki hastalıkları, üretim planlamaları, zirai ürün- gübre kullanma miktarları ve periyotları, verimlilik tespiti, tarım robotları uygulamaları, sulama zamanı gibi konularda kısacası ekimi yapılan ürünün, tüketicinin eline geçene kadarki olan tüm süreçlerinde yapay zekâ kullanılmaktadır [5].

Günümüzde insan nüfusu geçmiş yıllara göre hızla artmaktadır [6]. Doğal kaynakların sürekli ve dikkatsizce kullanımı çevrenin tahrip edilerek bozulmasına ve hem insanlığın hem de diğer canlıların gelecek nesillerini tehdit etme noktasına ulaşmasına neden olmuştur [7]. Dünya üzerindeki tarıma elverişli alanların bu denli hızlı ve geri dönüşü zor bir şekilde tükeniyor olması, kullanılabilir su kaynaklarının azalması tarım kaynaklı yaşanan sorunlara çözüm arayışı konusunda ulusları birleştirmiştir [8],[9],[10]. Bu amaçla teknolojinin tarımla birlikte çalışmasını sağlayan sürdürülebilir tarım uygulamaları kullanılmaktadır. Böylece yeryüzü kaynakları akıllıca kullanılmış olacak ve uzun vadede doğal kaynaklar korunacaktır. Ayrıca üst seviyede tarımsal verimlilik de sağlanacaktır [5],[10],[11],[12]. Sürdürülebilir tarım uygulamalarının amaçlarına bakılacak olursa; insanların temel ihtiyaçlarını karşılamak, doğayı koruyup devamlılığını sağlamak, su ve toprak kalitesinin düşmesini engellemek, yenilenemeyen kaynakları daha nitelikli bir şekilde kullanmak, biyolojik çeşitliliği korumak, insanlığın yaşam kalitesini arttırmak gibi maddeler sayabilmektedir [11].

Her tarım alanının kendine ait karakteristik özellikleri vardır. Bu ayrıştırıcı özellikler sayesinde toprakta yetişen ürünlerin verimliliğinde de farklılıklar meydana gelmektedir. Toprak yapısına uygun ekim yapmamak, daha çok gübrelemeye neden olmakla birlikte istenilen verimin alınmadığı sonuçlar da doğurabilmektedir. Üstelik bu durum zaten kısıtlı olan su gibi doğal kaynakların tükenmesine neden olmaktadır [13]. Bu sorunların önüne geçebilmek için toprak uygun aralıklarda analiz ettirilmeli ve analiz sonuçları iklimsel bağlamda da değerlendirilmelidir. Böylece toprağa en uygun ürünün üretimine karar vermek sezonda elde edilen ürünün kalitesini ve miktarını arttırmaktadır. Artan ürün miktarı ve kalitesi çiftçiye ticareti sırasında dikkate değer ekonomik getiri sağlamaktadır.

Tüm bunlara rağmen yapılan bir araştırmaya göre toprak analiz sonuçlarında gübre seçimini yapan üreticilerin oranı %12.24'tür [14]. Üreticilerin %33.67'si gübre miktarını belirlerken kendi bilgi ve tecrübesine göre karar vermektedir. Üreticilerin düzenli olarak toprak analizi yaptırmamalarının nedenleri incelendiğinde; % 30.14' ü toprak analizini önemsemedikleri için, %20.15'i masraflı olduğu için, %19.18'i analiz sonuçlarına güvenmediği için, %16.44'ü toprak örneği nasıl alınır bilmediği için ve %13.70' i toprak analizini yaptırmamanın uzun sürdüğü gerekçesiyle toprak analizi yaptırmadıklarını belirtmişlerdir [14]. Bu istatistikî gerekçeler dikkate alındığında çiftçi ne kadar toprak yapısına uygun uygulamalar yaparsa hasatta elde edeceği verimi arttırmaktadır. Aynı zamanda tarımsal süreçte gübreleme-sulama gibi ekstra masraf olarak yaptığı harcamaların da önüne geçmiş olmaktadır. Bu amaçla bu çalışmada çiftçi tarafından ilgili kurumlarca analizi yapılan toprağın bünyesinde bulunan organik madde, pH, tuzluluk, satürasyon, derinlik, potasyum, fosfor ve kireç parametrelerini uygun aralıklarda kategorize ederek değerlendirilmektedir. Ek olarak lokasyon-iklim özellikleri de incelenip tarım alanının bulunduğu coğrafi koşulların iklim parametreleri de dikkate alınmaktadır. Bu sayede üretici mevcut tarım alanından en yüksek verimi alabileceği ürünü belirleyebileceği gibi aynı zamanda tercih edebileceği ürünler arasından seçim de yapabilmektedir. Bu seçim ürün kalitesi ve miktarını artırmanın yanı sıra toprak bünyesinin kalitesini de bozmadığı hatta desteklediği için gelecek yıllarda yapılacak olan tarım faaliyetlerine de yatırım sağlamaktadır. Ayrıca tarımı yapılacak ürün, toprağın yapısına göre seçileceği için gübreleme-sulama gibi ürün elde etme sürecinde çiftçiye ek masraf olan kalemlerin miktarında azalma sağlamaktadır. Çiftçi bu sayede ticaret yaparken elde ettiği ürünlerin kalitesindeki ve verimli ürün sayısındaki artış ile kazanmaktadır. Aynı zamanda ek giderlerinde azalma meydana geldiği için masraflardan kâr etmiş olmaktadır. Bir başka bakış açısıyla da toprak kendine yakın

olan ürünü yetiştirirken zorlanmamış ve diğer besin değerlerince de sömürülmemiş olduğu için gelecek yıllar için kendini hazırlayabilecektir.

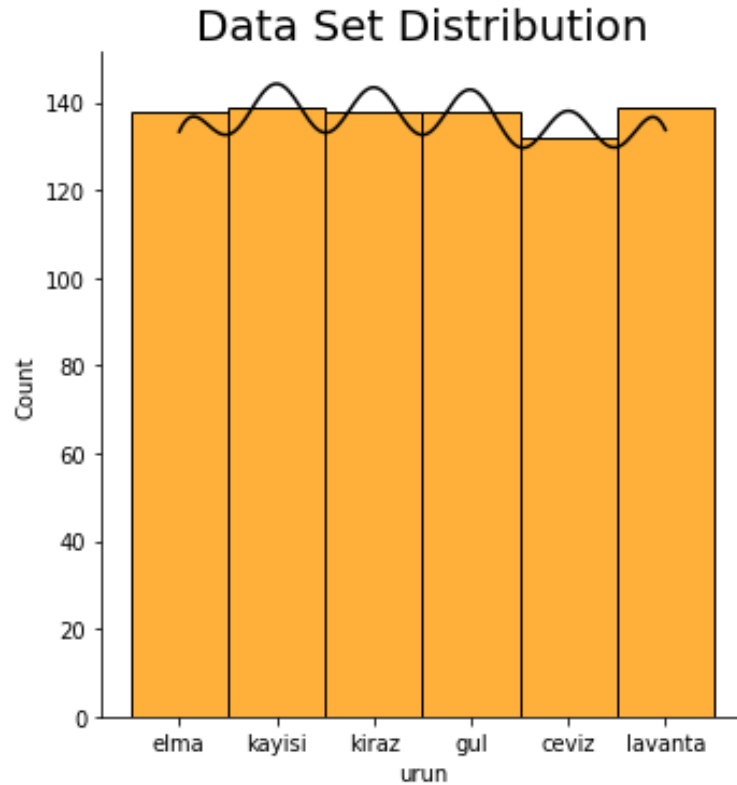
## 2. Materyal-Metot (Material-Method)

Bu çalışma ile topraktan alınan verilerin yapay zekâ yardımıyla mahsule uygunluğunun araştırılması gerçekleştirilmektedir.

### 2.1. Materyal (Material)

#### 2.1.1. Toprak analiz veriseti (Soil analysis dataset)


Isparta İl Tarım ve Orman Müdürlüğü ve Isparta İl Özel İdare'si tarafından sağlanan 7500+ gerçek toprak verisi analizi yapılan tarım alanlarının karakteristik özelliklerini yansıtan parametreleri (il, ilçe, köy, tarım şekli, derinlik, potasyum, fosfor, kireç, organik madde, toplam tuz, pH, saturasyon, ürün) içerecek şekilde Excel tablosu haline getirilmiştir. Veri seti dağılımı Şekil 1'de verilmiştir.



Şekil 2. Veri seti dağılımı (Dataset distribution)

#### 2.1.2. Random Forest algoritması (Random Forest algorithm)

Random Forest en popüler makine öğrenimi yöntemlerinden birisidir. Random Forest algoritması, rastgele karar ağaçlarının birleşiminden oluşan denetimli sınıflandırma algoritmalarındandır. Hem sınıflandırma hem de regresyon problemlerinin çözümünde kullanılmaktadır. Random Forest algoritmasının temel amacı sınıflandırma işlemleri esnasında birden fazla karar ağacı üreterek sınıflandırma değerini yükseltmektir. Bir başka deyişle birbirinden bağımsız olarak çalışan birçok karar ağacının bir araya gelerek aralarından en yüksek puan alan değerini seçilmesi işlemidir [15][16].



Şekil 2. Random Forest algoritması (Random Forest algorithm)

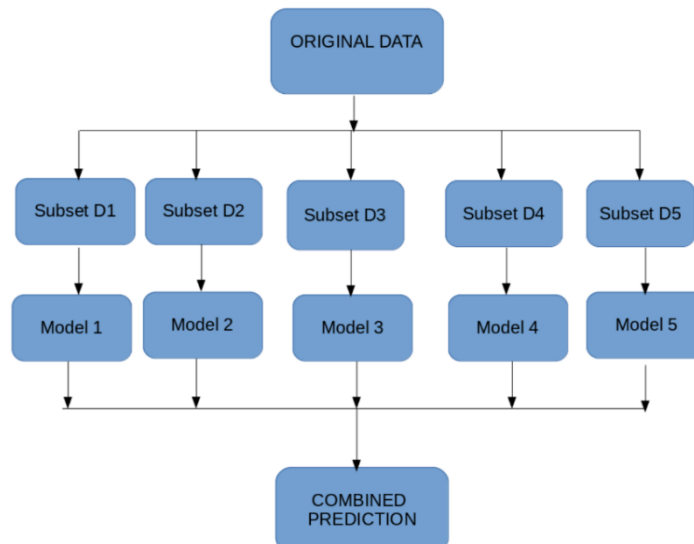
### 2.1.3. XG Boost algoritması (XG Boost algorithm)

XG Boost, diğer araştırma alanlarında karmaşık süreçlerin modellenmesinde çok güçlü olduğu kanıtlanmış bir makine öğrenimi algoritmasıdır. XG Boost (eXtreme Gradient Boost) yöntemi ilk olarak 2016 yılında Chen tarafından tanıtılmış ve otomotiv üretimi, bina soğutma yükünün tahmin edilmesi ve HVAC sistemleri için arıza tespiti gibi diğer birçok uygulamada kullanılmıştır. Temelde XG Boost algoritması Gradient Boosting algoritmasının optimize edilmiş bir türüdür. XG Boost, ağacı oluştururken maksimum derinlik değerini kullanır. Oluşturulan ağaç, aşağı yönde aşırı ilerleme gösterirse, budama gerçekleştirilir. Böylece aşırı öğrenmenin önüne geçilir. Gradient Boosting algoritması, kayıp fonksiyonun hesaplanmasında birinci dereceden fonksiyon kullanırken, XG Boost bu hesaplamaları ikinci dereceden fonksiyonlar kullanarak gerçekleştirir. Ayrıca paralel çalışma özelliği, diğer algoritmalara göre sonuca daha kısa sürede ulaşılmasını sağlar [17] [18].

### 2.1.4. Bagging algoritması (Bagging algorithm)

Bagging yöntemi Breiman tarafından 1996 yılında geliştirilmiştir. Bagging, orijinal eğitim veri kümesinin rastgele örneklenmiş alt kümeleri üzerinde bireysel öğrencileri eğitmek için kullanılan bir yöntemdir. Çalışma mantığı,

- Orijinal veri kümesinden çoklu alt kümeler oluşturulur,
- Bu alt grupların her birinde bir temel model (zayıf model) oluşturulmuştur,
- Modeller paralel olarak çalışır ve birbirinden bağımsızdır,
- Nihai tahminler, tüm modellerden gelen tahminler birleştirilerek belirlenir, şeklindedir [19][20].




Şekil 3. Bagging algoritması (Bagging algorithm)



## 2.2. Metot (Method)

Bu çalışmanın geliştirilme aşaması; veri setinin oluşturulması ve etiketlenmesi, arayüz tasarımı ve yapay zekâ yazılımı olarak üç kısımda incelenmektedir. Arayüz tasarımı için Qt Designer programı, yapay zekâ yazılımının gerçekleştirilmesinde Python programlama dili kullanılmıştır. Çalışmaya ait iş akış diyagramı Şekil 4'te verilmiştir.




Şekil 4. İş akış şeması (Workflow diagram)

### 2.2.1. Veri setinin oluşturulması (Creation of the data set)

Gerçek tarım alanlarında yapılmış olunan analiz sonuçlarından Excel tablosu oluşturularak kullanıma uygun bir hale getirilmiştir. Veri setinde en çok bulunan 5 ürün rastgele 139'ar tane ve 1 ürün rastgele 130 tane seçilmiştir. Veri setinde sırası ile “elma, kayısı, kiraz, gül, ceviz ve lavanta” verileri yer almaktadır.

### 2.2.2. Qt designer ile arayüz tasarımı (Interface design with Qt designer)

Çalışmanın kişiler tarafından rahatça kullanılabilmesi amacıyla Qt Designer programında veri setine uygun değerlerin girilebildiği bir arayüz gerçekleştirilmiştir. Veri setinde yer alan “ilçe, köy, tarım şekli, potasyum, fosfor, kireç, organik madde, toplam tuz ve pH” değerlerinin girilebildiği uygun “line edit” yapıları kullanılmıştır. Girilen değerlerin tahmini yapıldığında en uygun sonuç görseli arayüzde gösterilmektedir. Arayüz Şekil 5'te verilmiştir.




Şekil 5. Kullanıcı arayüzü (User interface)

### 2.2.3. Yapay zekâ algoritmaları ve denemesi (Artificial intelligence algorithms and experimentation)

Çalışmada, korelasyonu artırmak ve daha iyi bir tahmin modeli geliştirmek için veri seti üzerinde keşifsel veri analizleri (aykırı değerlerin çıkarılması, eksik verilerin tamamlanması, vb.) uygulanmıştır. Random Forest, XG Boost ve Bagging algoritmaları kullanılarak toprak değerlerine göre (ilçe, köy, tarım şekli, potasyum, fosfor, kireç, organik madde, toplam tuz ve pH) toprağın yatkın olduğu bitki (ürün) tahmini gerçekleştirilmiştir.

### 3. Bulgular (Findings)

Çalışmaya ait korelasyon grafiği Şekil 6'da verilmiştir. Korelasyon grafiği incelendiğinde verilerin "ürün" sütunu ile benzerliği ya çok düşük ya da negatiftir. Bu, modelin öğrenimini zorlaştıran bir durumdur. Bu tarz veriler ile eğitim yapılırken ensemble yöntemler kullanmak daha güçlü tahminler elde edilmesine olanak tanır.



Şekil 6. Veri seti korelasyon grafiği (Data set correlation chart)


### 3.1. Model performanslarının metriklerle karşılaştırması (Comparison of model performances with metrics)

Çalışmada, Isparta bölgesindeki toprak verilerine ait "ilçe, köy, tarım şekli, potasyum, fosfor, kireç, organik madde, toplam tuz ve pH" değerleri giriş ve "ürün" değerleri de çıkış parametresi olarak belirlenmiştir. Python programlama dilinde kodlanan yazılım ile veri seti; Random Forest, XG Boost ve Bagging sınıflandırma algoritmaları ile tahminlenmiştir. Bu tahminleme sonucunda accuracy değeri en iyi iki algoritma Random Forest ve Bagging olarak bulunmuştur. F1\_score'a bakıldığında Bagging algoritması daha iyi iken Random Forest biraz daha başarısız olmuştur. Şekil 6'daki korelasyon için gerçekleştirilen tahminlemeye ait sonuçlar tablo 1'de verilmiştir.

Tablo 1. Korelasyon için gerçekleştirilen tahmin sonuçları (Estimation results for correlation)

Performans ölçütü	Random Forest	XG boost	Bagging
Accuracy	0.6242	0.6121	0.6424
F1_score	0.6113	0.6071	0.6368
R <sup>2</sup>	0.0401	0.0004	0.061

Şekil 6'daki korelasyon için model değerlendirme grafiği Şekil 7'de verilmiştir.




Şekil 7. Model değerlendirme grafiği (Model evaluation chart)

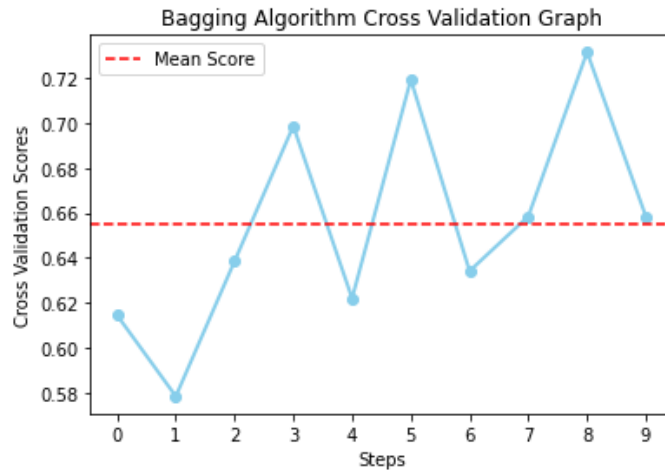
Yukarıdaki tablo ve grafiklerde görüldüğü gibi korelasyonun çok düşük olduğu veri setinde, modeller iyi bir tahminde bulunmuşlardır. Modeller F1\_score performans değerlendirme ölçütüne göre karşılaştırıldığında Random Forest %61, XG Boost %60 ve Bagging algoritmasının %63 ile en doğru tahminlemeyi yaptığı görülmektedir. Bagging algoritmasındaki hiper parametre olarak kullanılan model karar ağacı, ağaç sayısı 100, maksimum örneklem 0.8, ve rastgelelik 1 olarak ayarlanmıştır.

### 3.1.1. Çapraz doğrulama (Cross validation)


Gerçekleştirilen çalışmada veriler, 10 parça çapraz doğrulama yöntemi ile eğitilerek teste tabi tutulmuştur. Alt küme sayısı 10 olarak seçilmiştir. Random Forest algoritması için ortalama skor 0.6444, Bagging algoritması için ortalama skor 0.6554 ve XG Boost algoritması için ortalama skor 0.6360 olmuştur. Random Forest, Bagging ve XG Boost algoritmaları için çapraz doğrulama grafikleri şekil 8, 9 ve 10'da verilmiştir.



Şekil 8. Random Forest algoritması çapraz doğrulama grafiği (Random Forest algorithm cross-validation graph)



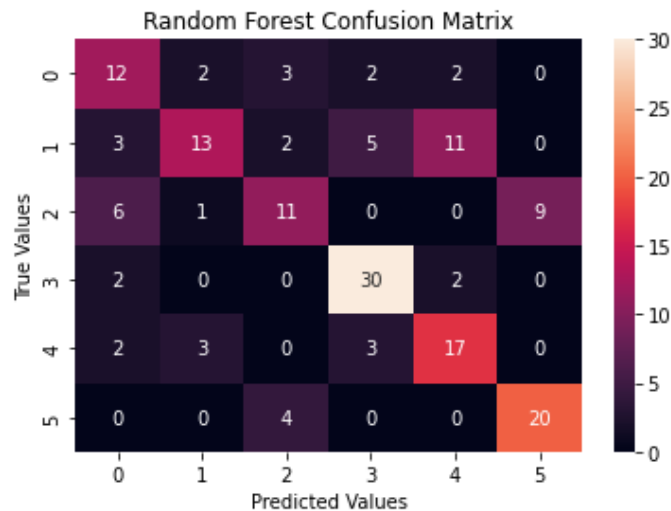
Şekil 9. Bagging algoritması çapraz doğrulama grafiği (Bagging algorithm cross-validation chart)



Şekil 10. XG Boost algoritması çapraz doğrulama grafiği (XG Boost algorithm cross-validation chart)

### 3.1.2. Karmaşıklık matrisi karşılaştırması (Complexity matrix comparison)

Bu çalışmada sınıflandırmanın doğruluğunu hesaplamak için kullanılan bir diğer yöntem karmaşıklık (confusion) matrisidir. Random Forest modeli, label encoding değeri 0 olan ürünü %48 doğru tahmin ederken label encoding değeri 1 olan ürünü %68, label encoding değeri 2 olan ürünü %55, label encoding değeri 3 olan ürünü %81, label encoding değeri 4 olan ürünü %53 ve label encoding değeri 5 olan ürünü de %68 doğru tahmin etmiştir. Şekil 11'de Random Forest algoritmasına ait karmaşıklık matrisleri verilmiştir.




Şekil 11. Random Forest algoritması karmaşıklık matrisi ısı haritası grafiği (Random Forest algorithm complexity matrix heat map chart)

Bagging modeli, label encoding değeri 0 olan ürünü %55 doğru tahmin ederken label encoding değeri 1 olan ürünü %78, label encoding değeri 2 olan ürünü %53, label encoding değeri 3 olan ürünü %77, label encoding değeri 4 olan ürünü %52 ve label encoding değeri 5 olan ürünü de %68 doğru tahmin etmiştir. Şekil 12’de Bagging algoritmasına ait karmaşıklık matrisleri verilmiştir.



Şekil 12. Bagging algoritması karmaşıklık matrisi ısı haritası grafiği (Bagging algorithm complexity matrix heat map chart)


XG Boost modeli, label encoding değeri 0 olan ürünü %42 doğru tahmin ederken label encoding değeri 1 olan ürünü %73, label encoding değeri 2 olan ürünü %57, label encoding değeri 3 olan ürünü %76, label encoding değeri 4 olan ürünü %51 ve label encoding değeri 5 olan ürünü de %66 doğru tahmin etmiştir. Şekil 13’te XG Boost algoritmasına ait karmaşıklık matrisleri verilmiştir.



Şekil 13. XG Boost algoritması karmaşıklık matrisi ısı haritası grafiği (XG Boost algorithm complexity matrix heat map chart)

### 3.1.3. Model performanslarının zamansal karşılaştırılması (Temporal comparison of model performances)

Kullanılan modellerin, 165 adet veriden oluşan test veri setini ne kadar sürede tahmin ettikleri Python’da bulunan time kütüphanesi ile belirlenmiştir. Time kütüphanesinde bulunan time metodu ile modellerin tahmin süreleri saniye cinsinden hesaplanmış ve milisaniyeye çevrilmiştir. Bu hesaplamalar sonucunda XG Boost algoritması 3.162ms, Random Forest algoritması 6.420ms ve Bagging algoritması 9.433ms sürelerinde tahminde bulunmuşlardır. En hızlı model XG Boost olmasına karşın veriler üzerinde genelleme yeteneği en düşük olan modeldir. Hesaplama sonuçları Şekil 14’te verilmiştir.



Şekil 14. Modellerin tahminde bulunma süreleri (Prediction times of models)

### 3.1.4. Modelin gerçek veriler ile test sonucu (Test result of the model with real data)

Yapılan denemeler sonucunda tasarlanan programda toprak verileri girildikten sonra doğruluk olarak en uygun bulunan Bagging algoritmasına göre sonuç vermektedir. Örnek olarak girilen gerçek toprak verilerinin ilçe, köy, tarım şekli, potasyum, fosfor, kireç, organik madde, toplam tuz ve pH parametrelerine göre öneri sonucu Tablo 2’de verilmektedir.

Tablo 2. Giriş parametrelerine göre sonuç değeri (Result value according to input parameters)

Giriş parametreleri	Girilen Değerler
İlçe	Senirkent
Köy	Büyükcabaca
Tarım şekli	Sulu
Potasyum	210.8925
Fosfor	2.1870
Kireç	16.8866
Organik madde	1.7328
Toplam tuz	0.0085
pH	7.63
Satürasyon	63”
Çıkış parametresi	Ürün
Tahmin Sonucu	Elma

Tabloda verilen değerler gerçek toprak verisidir ve mevcut halde elma yetiştirilmektedir. Tahminleme sonucunda toprağın elmaya yakın olduğu Bagging algoritması ile önerilmiştir.

## 4. Sonuç ve Öneriler (Conclusion and Recommendations)

Yapay zekâ yöntemleri ile Isparta şehrinde toprak değerlerine göre en çok yetiştirilen 6 ürüne ait verilerin kullanılması ile bir makine öğrenimi modeli geliştirilmiş ve tasarlanan arayüzden girilen toprak değerlerine göre o toprağın yakın olduğu bitki önerme sistemi gerçekleştirilmiştir. Çalışmada giriş parametreleri olarak “ilçe, köy, tarım şekli, potasyum, fosfor, kireç, organik madde, toplam tuz ve pH” ve çıkış parametresi “ürün” olarak belirlenmiştir. Ürün tahmini için Isparta İl Tarım ve Orman Müdürlüğü ve Isparta İl Özel İdare’si tarafından sağlanan 7500+ gerçek toprak verisi uygun şekilde Excel tablosu haline getirilmiş ve incelemeler yapılmıştır. Kategorik ifadeler label encoder yöntemi ile sayısal hale getirilmiştir. Üç farklı algoritma ile tahminlenen test veri setinde accuracy, F1\_score, mean absolute error, mean squared error,  $r^2$  ve confusion matrix olarak en iyi sonucu Bagging algoritması vermiştir. Zamansal olarak da Random Forest ve Bagging

algoritmalarına göre XG Boost algoritması daha hızlı tahminleme yapmıştır.

Çalışmanın sonuçları değerlendirildiğinde giriş parametrelerinin içinde çiftçinin yetiştirmeyi tercih ettiği ürünler de bulunmaktadır. Mevcut yetişen ürünlerden yola çıkılarak yetiştirilmesi verimli olan ürünlerin tespiti sağlanmıştır. Model eğitilirken çiftçinin yetiştirmeyi tercih ettiği ürünler kullanılmış olduğu için gerçek veri sayısının değişimine bağlı olarak uygun bulunacak üründe de değişiklik olabilecektir. Bu da veri sayısının artmasına bağlı olarak daha doğru tahminleme sağlayacaktır.

Gerçek çiftçiler tarafından yapılan analizler sonucu oluşturulan veri setinin mevcut dağılımına bakılarak da görüleceği üzere korelasyon negatif çıkmaktadır. Buna bağlı olarak Bagging algoritması ile elde edilen %63'lük değer yapay zekâ tahminlemesi için düşük bir değer gibi görünse de aslında elde edilen sonucun, toprağın yatkinlik değerini verdiği unutulmamalıdır. Başka bir deyişle eğer yapay zekadan alınan değer %99-98 gibi değerler olsaydı, bu toprakta sistemin bize önerdiği üründen başka bir ürün yetiştirilemez demek olacaktır. Örneğin kullanılan algoritma ile verilen değerlere göre %98 elma yetişir önermesi ile, mevcut tarım alanında elmadan başka ürün yetiştirmek mümkün değildir sonucu elde edilecekti. Öte yandan tahminlenen sonuçla sistem; "büyük olasılıkla elma yetiştirebilirsin- daha düşük olasılıkla kiraz da yetiştirebilirsin" önermesini vermektedir. Ayrıca elde edilen sonuç ne kadar yüksek olursa bu durum toprağın anaç yapısına uygun olmayan bir yanılığa neden olacaktır. Bu sonuç doğal olarak kullanıcıyı yanıltmış olacak ve çiftçiyi tekdüze bir seçime zorlayacaktır. Böylece toprağın aslında aynı anda birden fazla ürüne yatkin olduğunu ama üretimi tercih edilen ürüne göre elde edilecek verimin değişiklik gösterdiği sonucuna da varılmaktadır. Bunlara ek olarak toprağın özelliklerinin yanında iklim değerlerinin önemi de büyüktür. Kullanılan toprak verileri ilçe, köy gibi parametreler ile dolaylı yoldan iklim parametreleri barındırsa da bölgenin gerçek iklim özellikleri ile bu tahminler daha doğru sonuçlar ortaya çıkarabilecektir.

#### **Teşekkür** (Acknowledgment)

Bu çalışmada kullanılan toprak analiz verileri Isparta İl Tarım ve Orman Müdürlüğü ve Isparta İl Özel İdare'sinden sağlanmıştır. Destekleri için bu kurumlara teşekkür ederiz.

#### **Çıkar Çatışması Beyanı** (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

#### **Kaynaklar** (References)

- [1] H. C. Bayrakçı, R. S. Çiçekdemir and M. Özkahraman, "Tarım Arazilerinde Harcanan Su Miktarını Yapay Zekâ Teknikleri Kullanarak Belirlenmesi," *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, vol. 9, no. 6, pp. 237-250, Ara. 2021, doi:10.29130/dubited.1015690
- [2] Türk Dil Kurumu, [sozluk.gov.tr](https://sozluk.gov.tr) [Online] Available: <https://sozluk.gov.tr>. [Erişim tarihi: 15 Aralık 2023].
- [3] Z. Doğan, S. Arslan and A. Berkman, "Türkiye'de Tarım Sektörünün İktisadi Gelişimi ve Sorunları: Tarihsel Bir Bakış", *Niğde Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, vol. 8, no. 1, pp. 29-41, Ocak 2015, ISSN: 2148-5801, e-ISSN: 1308-4216.
- [4] M. Direk, *Tarım Tarihi ve Deontoloji*, Eğitim Akademi Yayınevi, 2012.
- [5] İ. Terzi, M. M. Özgüven, Z. Altaş and T. Uygun, "Tarımda Yapay Zekâ Kullanımı," *International Erciyes Agriculture, Animal Food Sciences Conference, 24-27 April 2019, Erciyes University, Kayseri, Turkey*, 2019, pp. 245-255.
- [6] H. Ekdahl, "Agricultural Technology and the Total System," *Journal of Agricultural Engineering Research*, vol. 76, no. 3, pp. 249-250, 2000. doi:10.1006/jaer.2000.0575
- [7] H. H. Tıraş, "Sürdürülebilir Kalkınma ve Çevre: Teorik Bir İnceleme," *Kahramanmaraş Sütçü İmam Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, vol. 2, no. 2, pp. 57-73, Haz. 2012.
- [8] K. Temizel and Y. Koç, "Coğrafi Bilgi Sisteminin Hassas Tarımda Uygulanmasının Yararları: Gübreleme Örneği," *Anadolu Tarım Bilimleri Dergisi*, vol. 30, no. 2, pp. 130-135, Jul. 2015, doi:10.7161/anajas.2015.30.2.130-135
- [9] İ. Boz, A. Şahin, M. Paksoy, F. H. Giray and M. Direk, "Çevre Amaçlı Tarımsal Arazilerin Korunması Programının (ÇATAK) Yayılması ve Benimsenmesi," *TÜBİTAK Projesi Kesin Sonuç Raporu*, Proje No: 110O747, 2013. Available: <https://search.trdizin.gov.tr/tr/yayin/detay/613804>. [Erişim tarihi: 15 Aralık 2023].
- [10] E. Kılavuz and İ. Erdem, "Dünyada Tarım 4.0 Uygulamaları ve Türk Tarımının Dönüşümü," *Social Sciences*, vol. 14, no. 4, pp. 133-157, Oct. 2019. doi:10.12739/NWSA.2019.14

- [11] M. F. Baran, A. Çelik ve K. Bellitürk, *Türkiye’de Sürdürülebilir Tarım Uygulamaları: Zorluklar ve Potansiyeller*. Ankara: İksad Publishing House, 2021.
- [12] B. Güzel ve E. Okatan, *Tarım ve Yapay Zekâ. Yapay Zekânın Değiştirdiği Dinamikler*. İstanbul: Eğitim Yayınevi, 2022, pp. 199-224.
- [13] B. Çakmak, M. Yıldırım ve T. Aküzüm, “Türkiye’de Tarımsal Sulama Yönetimi, Sorunlar ve Çözüm Önerileri,” *TMMOB 2. Su Politikaları Kongresi, Ankara, Türkiye, 20-22 Mart 2008*, pp. 215-224.
- [14] H. Yılmaz, V. Demircan and M. Gül, “Üreticilerin Kimyasal Gübre Kullanımında Bilgi Kaynaklarının Belirlenmesi ve Tarımsal Yayım Açısından Değerlendirilmesi,” *Süleyman Demirel Üniversitesi Ziraat Fakültesi Dergisi*, vol. 4, no.1, pp. 31-44, 2009, ISSN: 1304-9984.
- [15] S. Ren, X. Cao, Y. Wei and J. Sun, “Global Refinement of Random Forest,” *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 2015*, pp. 723-730, doi: 10.1109/CVPR.2015.7298672
- [16] E. Akdağlı, “Makine Öğrenmesinde Random Forest Algoritması,” *medium.com*, 4 Mart 2021. [Çevrimiçi]. Mevcut: <https://ece-akdagli.medium.com/makine-%C3%B6%C4%9Frenmesinde-random-forest-algoritmas%C4%B1-a79b044bbb31>. [Erişim: 14 Aralık 2023].
- [17] M. Hao, S. Hejiang, L. Junjie and W. Shen, “Developing Window Behavior Models for Residential Buildings Using Xgboost Algorithm,” *Energy and Buildings*, vol. 205(2019), pp. 1-8, 2019. doi:10.1016/j.enbuild.2019.109564
- [18] A. C. Kelle and H. Yüce, “MQTT Trafığında DoS Saldırılarının Makine Öğrenmesi ile Sınıflandırılması ve Modelin SHAP ile Yorumlanması,” *Journal of Materials and Mechatronics*, vol. 3, no. 1, pp. 50–62, 2022, doi:10.55546/jmm.995091
- [19] G. Ngo, R. Beard and R. Chandra, “Evolutionary Bagging for Ensemble Learning,” *Neurocomputing*, vol. 510, pp. 1-14, 2022. doi:10.1016/j.neucom.2022.08.055
- [20] Ş. Ay, “Ensemble Learning-Bagging ve Boosting,” *medium.com*, 16 Aralık 2019. [Çevrimiçi]. Mevcut: <https://medium.com/deep-learning-turkiye/ensemble-learning-bagging-ve-boosting-50643428b22b>. [Erişim: 15 Aralık 2023].

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license





# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### Clustering of OECD Countries by Exported and Imported Product Groups

Okan Dağ<sup>a</sup>

Submitted: 24.11.2023 Revised: 08.12.2023 Accepted: 09.12.2023 doi:10.30855/10.30855/gmbd.0705S18

#### ABSTRACT

**Keywords:** Import, Export, Clustering, OECD, Expectation Maximisation, Canopy

<sup>a,\*</sup> Suleyman Demirel University, Faculty of Economics and Administrative Sciences, Department of Business Administration, Isparta Türkiye  
Orcid: 0000-0001-9756-722X  
e mail: okandaq@gmail.com

\*Corresponding author:  
okandaq@gmail.com

The world has become a global market with the development of communication and transportation technologies. In order to increase the benefit that can be obtained from the market, countries evaluate the products to be exported and imported by making use of various analyses. In the study, it is aimed to cluster the countries according to the product groups they import and export. In this way, countries will be able to dominate the markets where they can import some products that cannot be produced due to various reasons such as natural resources, cost, climatic conditions, labour force or that require high costs. In addition, countries will be able to create a market for the products they produce or develop within their borders if appropriate conditions are provided. For this purpose, OECD countries consisting of 37 countries are considered in this study. While the data to be used in the analysis of the study are obtained from the World Trade Organisation; the data cover the period between 2012-2021. Cluster analysis techniques were used in the analysis of the study in which 18 exported and imported product groups were used. During the analysis, cluster analysis techniques suitable for the numerical data structure were used. Expectation Maximisation and Canopy were the most appropriate techniques for clustering OECD countries. In the study, countries were divided into four groups in terms of exports and imports, while the number of clusters was obtained from the formulation frequently used in the literature. Considering the results obtained, although Canopy algorithm and Expectation Maximisation algorithm produce similar clusters, it is observed that the country distributions in Canopy algorithm are more balanced.

### OECD Ülkelerinin İhracat ve İthal Edilen Ürün Gruplarına Göre Kümelenmesi

#### ÖZ

Dünya, iletişimin ve taşıma teknolojilerinin gelişimiyle birlikte küresel bir pazar haline gelmiştir. Pazardan alınabilecek faydanın artırılması için ülkeler çeşitli analizlerden yararlanarak ihracat ve ithal edilecek ürünlerin değerlendirmesini yapmaktadır. Yapılan çalışmada ülkelerin ithal ve ihracat ettikleri ürün gruplarına göre kümelenmesi amaçlanmıştır. Bu sayede ülkeler doğal kaynaklar, maliyet, iklim koşulları, işgücü gibi çeşitli sebeplerden dolayı üretilmeyen veya yüksek maliyet gerektiren bazı ürünleri ithal edebilecek pazarlara hâkim olabilecektir. Ayrıca ülkeler, uygun koşulların sağlanması halinde ülke sınırları içerisinde ürettikleri ya da geliştirdikleri ürünlere bir pazar oluşturma imkânı bulabilecektir. Bu amaçla çalışmada 37 ülkeden oluşan OECD ülkeleri ele alınmıştır. Çalışmanın analizinde kullanılacak veriler Dünya Ticaret Örgütü'nden elde edilirken; veriler 2012-2021 yılları arasında kapsamaktadır. İhracat ve ithal edilen 18 ürün grubunun kullanıldığı çalışmada, kümeleme analizi tekniklerinden yararlanılmıştır. Analiz sırasında sayısal veri yapısına uygun olan kümeleme analizi teknikleri çalışılmıştır. OECD ülkelerinin kümelenmesi sırasında en uygun sonucu veren teknikler, Beklenti Maksimizasyonu ve Canopy olmuştur. Çalışmada ülkelerin ihracat ve ithalat bakımından dört gruba ayrılırken, küme sayısı literatürde sıklıkla kullanılan formülasyondan elde edilmiştir. Elde edilen sonuçlara bakıldığında Canopy algoritması ve Beklenti Maksimizasyonu algoritması birbirine benzer kümeler ortaya koysa da Canopy algoritmasındaki ülke dağılımlarının daha dengeli olduğu gözlemlenmiştir.

**Anahtar Kelimeler:** İthalat, İhracat, Kümeleme, OECD, Beklenti Maksimizasyonu, Canopy

## 1. Giriş (Introduction)

Teknolojinin gelişmesi ve dünyanın küresel bir pazara dönüşmesiyle birlikte piyasadaki rekabet ortamı da artmıştır. Rekabetçi ortamın oluşması, firmaları ve ülkeleri katma değer yaratmaya itmektedir. Küreselleşmenin de etkisiyle bu rekabet; firmaları, endüstrileri hatta ülkeleri kapsar hale gelmektedir.

Ülkeler, bu rekabetin bir tarafı olarak vatandaşların refah seviyelerini artırabilmek adına rekabet güçlerini artırmaya ve bu avantajın sürdürülebilirliğini sağlamaya çalışmaktadır. Ülkeler rekabet avantajı sağlayabilmek ve bunu sürdürülebilir bir yapıya dönüştürebilmek adına çeşitli stratejiler geliştirmektedir. Bu doğrultuda ülkeler, ülke sınırları içerisinde üretim kapasitesi bulunan ürün, mal ve hizmetin geliştirilmesi ve katma değer katılması konusunda yapılacak çalışmaların yanında; üretim kapasitesinin yeterli olmadığı ürün ya da ürün gruplarını daha uygun şartlar altında temin edebileceği seçenekler üzerine de araştırmalar yapmaktadır.

Yapılan literatür incelemesi sonucunda ülkelerin ihracat ve ithal edilen ürün gruplarına göre analiz edildiği bir çalışmaya rastlanmamıştır. Ülkelerin hem rekabet gücü yüksek olan ürünlerini ortaya koymak adına hem de kendisi ile benzer ithalat ve ihracat hacmine sahip ülkeleri görmesi geliştirilecek stratejiler konusunda ülkelere yardımcı olabilecektir. Ülkeler için problem teşkil eden bu durum yapılan analiz neticesinde çözüme kavuşturulabilecektir. Literatürde çoğunlukla belli ürün grupları üzerinde çalışmalar yapıldığı gözlemlenmiştir. Bunun yanı sıra yapılan çalışmalarda OECD ülkelerinin ürün grupları baz alınarak kümeleme analizine tabi tutulmadığı görülmüştür. Bundan dolayı yapılan çalışmada OECD ülkeleri ve ürün gruplarının tamamı analize dahil edilerek özgün bir çalışma yapılmak istenmiştir.

Bu çalışmada da OECD ülkelerinin ihracat ve ithal edilen ürün grupları açısından kümelenebilirliği amaçlanmaktadır. Bu bağlamda Dünya Ticaret Örgütü'nden elde edilen 18 ürün grubu ele alınmıştır. Kümeleme analizi algoritmalarından Beklenti maksimizasyonu ve Canopy kullanılarak gerçekleştirilen analiz neticesinde OECD ülkeleri ihracat ve ithal edilen ürün grupları bakımından kümelere ayrılmıştır. Çalışmada benzer ürün gruplarını ihracat eden ülkeler ile benzer ürün gruplarını ithal eden ülkelerin kümeleme işlemi gerçekleştirilmiştir. Çalışmanın sonunda elde edilen kümelerin değerlendirilmesi detaylı bir şekilde yapılmıştır.

## 2. Literatür Taraması (Literature Review)

### 2.1. Beklenti maksimizasyonu algoritması ile ilgili yapılan bazı çalışmalar (Some studies on the expectation maximization algorithm)

Çalışmanın bu bölümünde analiz sırasında yararlanılan kümeleme algoritmalarından olan Beklenti Maksimizasyonu ile ilgili yapılmış olan bazı çalışmalara yer verilmiştir. Bu amaçla yerli ve yabancı literatür taranmış ve yazınlardan bazıları bu başlık altında aktarılmıştır.

Aktaş, vd. [1] tarafından yapılan çalışmada OECD ülkelerinin mobil ve kablolu internet kullanım oranlarına göre kümelenebilirliği amaçlanmıştır. Çalışmada yararlanılan veriler 2012-2015 ve 2016-2019 yılları olmak üzere iki grup halinde değerlendirilmiştir. Çalışmada ilk olarak Entropi ve CRITIC yöntemleriyle kriter ağırlıkları belirlenmiş; ardından EM yöntemi ile kümeleme analizi gerçekleştirilmiştir. Bu işlemin ardından oluşan beş küme arasındaki farklılıkların analiz edilmesinde Kruskal Wallis testi uygulanmıştır.

Karaatlı ve Yıldız [2] tarafından yapılan çalışmada, mevduat bankalarının finansal yapılarının kümeleme analizi ile incelenmesi amaçlanmıştır. Çalışmada 2017 yılından itibaren faaliyet göstermekte olan yirmi mevduat bankası ele alınmıştır. Çalışmanın analizinde Beklenti Maksimizasyonu algoritmasından yararlanılmış ve dört küme elde edilmiştir. Bu işlemin ardından Tek Yönlü Anova ve Kruskal Wallis teknikleriyle kümeler arası anlamlı bir fark olup olmadığı incelenmiştir.

Adeyiga, vd. [3] tarafından yapılan çalışmada, suçlu profillerinin kümelenebilirliği amaçlanmıştır. Bu doğrultuda kümeleme işlemi sırasında Beklenti Maksimizasyonu, K-Means ve Hiyerarşik yöntem kullanılmıştır. Yapılan analizler sonucunda Beklenti Maksimizasyonu algoritmasının diğer algoritmalara oranla çok daha iyi sonuçlar verdiği görülmüştür.

Ali ve Hamed [4] tarafından yapılan çalışmada, Al-Ghat şehrinde gerçekleşen trafik kazaları üzerine bir analiz gerçekleştirilmesi amaçlanmıştır. Çalışmada 946 trafik kazası 8 kriter baz alınarak değerlendirilmiştir. Analiz

sırasında Apriori ve Beklenti Maksimizasyonu algoritmalarından yararlanılmıştır. Yapılan değerlendirme sonucunda Apriori algoritmasının Beklenti Maksimizasyonu algoritmasından daha başarılı sonuçlar ortaya koyduğu görülmüştür.

Widya ve Suderma [5] tarafından yapılan çalışmada kadın kooperatiflerin kümelenmesi amaçlanmıştır. Çalışma Bali'de yer alan Gianyar eyaletinde yer alan kadın kooperatiflerini kapsamaktadır. Çalışmanın analizinde kümeleme algoritmalarından olan Beklenti Maksimizasyonu algoritması kullanılmıştır.

## 2.2. Canopy algoritması ile ilgili yapılan bazı çalışmalar (Some studies on the Canopy algorithm)

Çalışmada yararlanılan bir diğer kümeleme algoritması olan Canopy ile ilgili yapılmış çalışmalardan bazılarının aşağıda yer verilmiştir.

Avşar [6] tarafından yapılan çalışmada, demiryollarının değerlendirilmesi amaçlanmaktadır. Çalışmanın analizi sırasında kümeleme analizi algoritmalarından Canopy kullanılmış ve dört küme oluşturulmuştur. 2016-2020 yılları arasındaki verilerin baz alındığı çalışmada benzer demiryolu uzunluğuna sahip ülkelerin kümelenmesi gerçekleştirilmiştir. Çalışmada Türkiye İngiltere, Macaristan gibi ülkelerle Küme 4'te yer almaktadır.

Karaatlı, vd. [7] tarafından yapılan çalışmada, ülkelerin insani gelişmişlik endeksine göre kümelenmesi amaçlanmaktadır. Bu doğrultuda ilk olarak Entropi yöntemi kullanılarak kriter ağırlıkları belirlenmiş ardından kümeleme analizi gerçekleştirilmiştir. Çalışmada Canopy algoritmasından yararlanılırken ülkeler dokuz kümeye ayrılmıştır. Çalışmanın sonucuna bakıldığında ülkelerin ekonomik ve kişisel özgürlükler bakımından farklılıklar barındırdığı gözlemlenmiştir.

Kocabıyık, vd. [8] tarafından yapılan çalışmada borsada işlem gören hisse senetlerinin kümelenmesi amaçlanmaktadır. Bu doğrultuda BIST 30 endeksinde işlem gören hisse senetleri baz alınmıştır. Daha sonra belirlenen kriterler eşliğinde kümeleme algoritmalarından olan Canopy algoritmasından yararlanılmıştır. Çalışmada kullanılmak üzere Covid-19 öncesi ve Covid-19 olmak üzere iki veri seti hazırlanmıştır. Yapılan analiz sonucunda BIST 30 endeksinde işlem gören hisse senetlerinden 19 tanesinin her iki dönemde de aynı küme içerisinde yer aldığı gözlemlenmiştir.

## 2.3. İhracat ve ithalat ile ilgili yapılan bazı çalışmalar (Some studies on exports and imports)

Çalışmanın bu bölümünde ihracat ve ithalat ile ilgili yapılmış çalışmalardan bazılarının yer verilmiştir.

Duman [9] tarafından yapılan çalışmada, Türkiye'nin ihracat seviyesi ve hangi ürün çeşitlerinde üstün olduğunun analiz edilmesi amaçlanmıştır. Çalışmanın analizinde 2000-2020 yılları arası baz alınmıştır. Analiz sonuçlarına göre Türkiye'nin SITC sınıflandırması baz alındığında emek ve sermaye yoğun sektörlerde daha fazla ihracat gerçekleştirdiği sonucuna varılmıştır.

Karataş [10] tarafından yapılan çalışmada Türkiye'nin net kar pay kayması analizine tabi tutulması amaçlanmıştır. Çalışmada 2019 ve 2020 yılına ait ilk üç çeyrek verileri baz alınarak analiz gerçekleştirilmiştir. Yapılan analiz neticesinde sanayi ara girdilerinden olan enerji ve demir çelikte ithalat ve ihracat paylarında benzer düşüşler, gıda ve eczacılık ürünlerinde ise Türkiye'nin ihracatçı olarak dikkat çektiği görülmüştür.

Sarıçoban [11] tarafından yapılan çalışmada ülkelerin standart ürün grupları çerçevesinde karşılaştırmalı üstünlüklerinin analiz edilmesi amaçlanmıştır. Çalışmada RCEP anlaşmasının tarafı olan on beş ülke analize dahil edilirken; 2011-2020 yıllarına ait veriler Blassa İndeksi ile hesaplanmıştır. Elde edilen sonuçlara göre ülkelerin yoğunlukla tarımsal, imalat sanayi ve hammadde ürün gruplarında uzmanlaştığı sonucuna varılmıştır.

Nasrullah, vd. [12] tarafından yapılan çalışmada, Çin'in orman ürün grubu ticaretini etkileyen faktörlerin ortaya konması amaçlanmıştır. Çalışmada 2001-2018 yıllarına ait panel verilerden yararlanılmıştır. Birim kök test ve Hausman testi sonucunda elde edilen veriler bakıldığında, GSYH ve GDPC'nin ticaret üzerinde pozitif bir etkiye sahip olduğu görülmüştür. Bunun yanı sıra mesafenin ise ticaret ile ters yönlü bir ilişki içerisinde olduğu gözlemlenmiştir. Aynı zamanda bu çalışmada, büyük ekonomilere veya kısa mesafeli ülkelere ihracatı ve ithalatı teşvik etmenin daha olumlu olacağı sonucuna varılmıştır.

Kuşat [13] tarafından yapılan çalışmada, ülkelerin rekabet gücünün ölçülmesi amaçlanmaktadır. Bu doğrultuda Türkiye ile BRICS ülkeleri ele alınmış ve ürün gruplarına göre değerlendirme gerçekleştirilmiştir. Çalışmanın analizinde Açıklanmış Karşılaştırmalı Üstünlükler Endeksi kullanılmıştır. Analiz sonucuna bakıldığında Türkiye'nin BRICS ülkelerine sadece Gıda ve Canlı Hayvanlar Mal Grubu'nda rekabet üstünlüğü kurduğu görülmüştür.

### 3. Metot (Method)

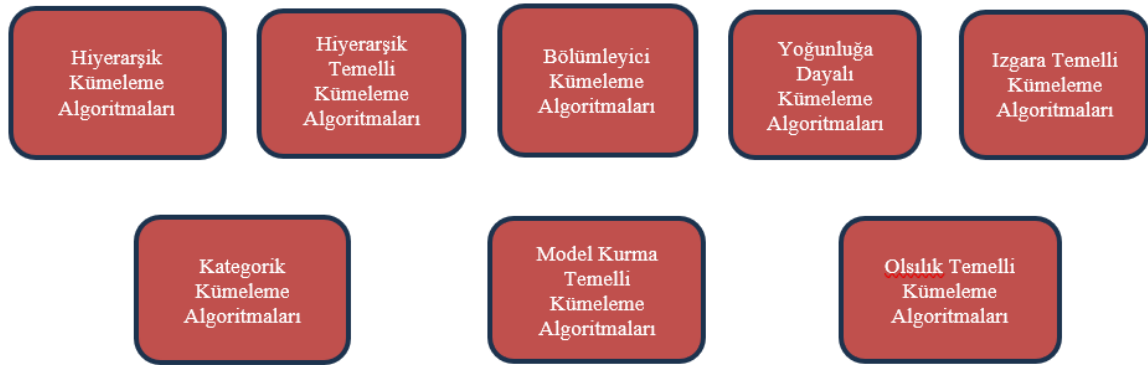
Çalışmanın bu aşamasında kümeleme analizine ve analiz sırasında kullanılan Beklenti Maksimizasyonu algoritmasına detaylı bir şekilde yer verilmiştir.

#### 3.1. Veri madenciliği ve kümeleme analizi (Data mining and cluster analysis)

Veri madenciliği devasa büyüklükteki veri setlerinden anlamlı bilgiler ortaya koyma süreci olarak tanımlanabilmektedir. Ortaya anlamlı bilgiler çıkarma sürecinde birtakım teknikler kullanılmaktadır. Veri madenciliğinde kullanılan bu teknikler tahmin edici ve tanımlayıcı olmak üzere iki başlık altında toplanabilmektedir. Sınıflandırma ve regresyon teknikleri tahmin edici, kümeleme ve birliktelik analizi ise tanımlayıcı tekniklerdir [14].

Kümeleme analizi, veri madenciliği alanında kullanılan en önemli analiz tekniklerinden biridir. Kümeleme analizinde amaç, benzer özelliklere sahip nesnelerin aynı küme içerisinde yer almasını sağlamaktır. Bir başka ifadeyle küme içi homojen; kümeler arası ise heterojen bir yapı oluşturmayı hedeflemektedir. Sınıflandırma tekniklerinde sınıflar önceden belirliken, kümeleme analizinde nesnelerin atanacağı kümeler önceden belli değildir [15].

Kümeleme algoritmaları 1990'lı yıllara kadar sadece hiyerarşik ve bölümleyici ana başlıkları altında toplanabilirken; günümüzde teknolojinin ilerlemesiyle birlikte farklı gruplar altında incelenmeye başlamıştır [16]. Veri madenciliğinde yararlanılan kümeleme algoritmaları, sekiz ana başlık altında ele alınabilmektedir.



Şekil 1. Kümeleme algoritmalarının sınıflandırılması (Classification of clustering algorithms)

Yapılan çalışmada kullanılan algoritmalarından Beklenti Maksimizasyonu algoritması Olasılık Temelli Kümeleme Algoritmaları Arasındadır. Çalışmada yararlanılan algoritmalarından Canopy ise Bölümleyici Kümeleme algoritmaları arasındadır. Çalışmada yararlanılan iki algoritmaya aşağıda detaylı bir biçimde yer verilmiştir.

#### 3.2. Beklenti maksimizasyonu (Expectation maximisation)

Kümeleme analizi sırasında en çok kullanılan algoritmalarından olan Beklenti Maksimizasyonu algoritması Dempster, Liard ve Rubin tarafından 1977 tarihinde geliştirilmiştir. Beklenti Maksimizasyonu algoritması eksik verilerin bulunduğu durumlarda maksimum olasılık tahminleri yapan iteratif bir algoritma olarak öne çıkmaktadır. Beklenti maksimizasyonu algoritmasının bir diğer özelliği ise kesin uzaklık ölçütlerinden yararlanmak yerine tahmine dayalı ölçütlerden yararlanmasıdır [17].

Beklenti maksimizasyonu algoritması iki adımdan meydana gelmektedir. İlk adım olan E adımında gözlenen verilerin parametrelerine dair kestirmelerden yararlanılarak kayıp veri ile alakalı en iyi olasılık tahminleri

gerçekleştirilmektedir. B adımının formülize edilmiş hali Eşitlik 1’de gösterilmiştir.

$$Z_{gi} = E(z_{gi} | \mathbf{x}; \pi, \theta) = (\pi_{-g} f(\mathbf{x}; \theta_g)) / (\sum_{(g=1)}^k \pi_{-g} f(\mathbf{x}; \theta_g)) \quad (1)$$

M adımında ise tahmini gerçekleştirilen kayıp veri yerine konularak tüm veri üzerinden maksimum olabilirlik hesaplanmaktadır. Bu iki adım her iteratif işlemde tekrar edilmektedir. M adımının formülize edilmiş haline Eşitlik 2’de yer verilmiştir. [18], [19].

$$\begin{aligned} \ln \tilde{L}(\pi, \theta; \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n, \mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_n) \\ = \sum_{(i=1)}^n \sum_{(g=1)}^k \ln [\pi_{-g} f(\mathbf{x}_i; \theta_g)] \end{aligned} \quad (2)$$

### 3.2. Canopy (Canopy)

Canopy algoritması, McCollum, Nigam ve Ungar tarafından 2000 yılında geliştirilmiştir. Bölümleyici ve hiyerarşik kümeleme algoritmalarının büyük veri setleri karşısında yetersiz kalmasıyla ortaya atılmıştır. Canopy algoritması iki adımdan meydana gelmektedir. İlk adımda veri setleri basit uzaklık ölçülerinden yararlanılarak kümelenebilir. İkinci adımda ise k-means gibi bir algoritmadan yararlanılarak ilk adımda elde edilen kümelerin iyileştirilmesi sağlanmaktadır. İlk adımdan sonra meydana kümelere Canopy; bir başka ifadeyle kubbe adı verilmektedir. İlk adımda basit uzaklık ölçülerinden yararlanılması ve ikinci adımda her bir kubbenin ayrı bir veri dizisi gibi ele alınmasından dolayı kümeleme süreci oldukça hızlıdır [20].

## 4. OECD Ülkelerinin İhracat ve İthal Edilen Ürün Gruplarına Göre Kümelenebilirliği (Clustering of OECD Countries by Exported and Imported Product Groups)

Ülkelerin gerçekleştirmiş olduğu ithalat ve ihracat miktarları ürün grupları baz alınarak Dünya Ticaret Örgütü tarafından listelenmektedir. Çalışmanın bu bölümünde Dünya Ticaret Örgütü’nden [21] elde edilen bu verilerden yararlanılarak OECD ülkelerinin toplam on sekiz ürün grubuna göre kümelenebilirliği amaçlanmıştır. Çalışmada 2012-2021 yıllarına ait verilerin aritmetik ortalaması baz alınmış ve yapılan kümeleme işlemi ithalat ve ihracat bazlı olmak üzere ayrı ayrı gerçekleştirilmiştir. Analiz sırasında ise kümeleme analizi algoritmalarından Beklenti Maksimizasyonu algoritmasından yararlanılmıştır.

Çalışmada kullanılan kriterlere ait kodlar ve karar matrisine Tablo 1’de ve ihracat edilen ürün gruplarına ait karar matrisine Tablo 2’de ve ithal edilen ürün gruplarına ait karar matrisine Tablo 5’te yer verilmiştir.

Tablo 1. Çalışmada kullanılan kriter bilgileri (Criteria information used in the study)

KOD	KRİTER	KOD	KRİTER
K1	Toplam Ticari Mal	K10	Makine ve Nakliye Ürünleri
K2	Tarımsal Ürün	K11	Ofis ve Telekom Ekipmanları
K3	Gıda	K12	Elektronik Bilgi İşlem ve Ofis Ekipmanları
K4	Yakıt ve Madencilik Ürünleri	K13	Telekomünikasyon Ekipmanları
K5	Yakıtlar	K14	Entegre Devreler ve Elektronik Bileşenler
K6	İmalat	K15	Taşıma Ekipmanları
K7	Demir ve Çelik	K16	Otomotiv Ürünleri
K8	Kimyasallar	K17	Giyim
K9	İlaç	K18	Tekstil

Tablo 2’de yer alan ve ihracat edilen ürün gruplarına ait olan değerler WEKA programına dahil edilerek veri setine uygun olan tüm kümeleme algoritmaları çalıştırılmıştır. Beklenti Maksimizasyonu ve Canopy algoritmalarının karşılaştırmalı sonuçlarına yer verilmiştir.

Kriter sayısının fazla olmasından dolayı ihracat edilen ürün gruplarına ait verilerin yer aldığı karar matrisi tablosu ikiye ayrılarak Tablo 2 ve Tablo 2’nin devamı şeklinde verilmiştir.

Tablo 2. İhraç edilen ürün gruplarına ait karar matrisi (Decision matrix for exported product groups)

ÜLKELER	K1	K2	K3	K4	K5	K6	K7	K8	K9
ABD	15732062	1735163	1425315	2021261	1564843	10147306	160751	2166437	530192
Almanya	14518372	941034	814006	765688	367724	12543021	299124	2393696	874142
Avusturalya	2484741	376353	308679	1603045	704780	280855	6484	72495	32054
Avusturya	1728543	171798	134560	97380	39556	1437541	87002	236016	112712
Belçika	4497345	495408	434628	563860	419030	3348013	163912	1367098	552402
Çekya	1816889	108741	83653	71664	42496	1622221	48484	116073	27434
Danimarka	1076371	234577	202861	82877	66516	744510	13053	228147	155793
Estonya	159993	25275	14696	22766	19158	108467	2143	10190	919
Finlandiya	705198	70712	18638	106673	65900	502026	47251	67561	10228
Fransa	5500636	764046	703500	309327	189120	4318271	149699	1058872	355358
Kore C.	5580461	126232	73363	542758	416875	4892161	263810	714096	37311
Hollanda	6742380	1090483	906241	1193225	957684	4416487	132302	1134225	377481
İngiltere	4670529	323833	297644	618419	426305	3215126	68487	716558	320398
İrlanda	1451232	147471	140311	28454	13785	1264540	1925	865769	451232
İspanya	3198460	577759	540798	349877	238354	2203013	98855	442041	138791
İsrail	614859	23459	19473	18672	11283	564199	1420	155564	52051
İsveç	1608329	165210	100405	196670	119900	1219296	70745	203927	95426
İsviçre	3197938	97827	92661	97112	32585	2172641	16531	1038559	751057
İtalya	5178187	494451	457969	311477	190805	4246606	204297	688744	284763
İzlanda	50509	23469	23103	20242	772	6443	1545	945	504
Japonya	7013228	113542	61865	313286	123299	6105660	324073	756781	52470
Kanada	4410436	681044	504718	1285863	976358	2074067	68241	372322	74731
Kolombiya	430709	73754	58382	251913	246802	85407	6815	33347	4286
Letonya	151041	46798	30088	12085	8636	90229	5086	13370	4786
Litvanya	314877	65525	56128	54639	48954	193309	3465	48039	7731
Lüksemburg	168571	15839	13546	7846	514	141021	23524	17534	2868
Macaristan	1146929	105697	97689	54572	37877	974270	13474	136047	58603
Meksika	4134881	327515	305664	406808	302701	3234450	40309	141190	16826
Norveç	1224186	127923	119183	833950	760834	217708	13376	69166	7879
Polonya	2392348	340646	308819	153279	69646	1889889	53361	221552	38549
Portekiz	629443	91615	76610	60017	45123	473670	16465	57274	12327
Slovakya	861734	43362	35371	51039	32314	764666	41775	38445	5180
Slovenya	396754	30792	21458	35383	19355	330019	14729	71621	44483
Şili	733597	215472	167946	415063	7704	94666	3221	34823	1800
Türkiye	1698026	195389	187160	126908	59024	1279356	113782	104384	12066
Yeni Zelanda	386902	296786	249581	20842	8623	81828	2270	20153	3629
Yunanistan	356598	75744	68720	144160	114052	129274	8730	40991	18296

\*Ürün gruplarına göre mal ihracatı - yıllık (Milyon ABD Doları)

Tablo 2. İhraç edilen ürün gruplarına ait karar matrisi – devamı (Decision matrix for exported product Groups - continued)

ÜLKELER	K10	K11	K12	K13	K14	K15	K16	K17	K18
ABD	5264523	1460375	504124	466740	489512	1627964	1307782	134209	58105
Almanya	7075350	712132	260262	247424	204443	3283715	2472773	143711	210250
Avusturalya	119585	26885	11912	13266	1708	42598	20552	2175	2573
Avusturya	687379	96681	19611	59242	17829	247335	182288	21470	28672
Belçika	965637	96149	40217	41589	14345	511700	459619	58885	90408
Çekya	1024160	263468	138389	109611	15469	404152	370107	27440	20790
Danimarka	276734	41175	18506	19435	3231	43446	25037	11390	41626
Estonya	52003	17213	840	15732	640	10496	6700	1832	2489
Finlandiya	219195	17706	4215	10001	3491	58807	33510	3039	3477
Fransa	2072257	211491	45692	79171	86625	1095051	514897	49830	118736
Kore C.	3178977	1287525	231518	242910	813094	1044350	675366	101838	20621
Hollanda	2123244	1050491	464121	449040	137331	363524	210815	57168	111285
İngiltere	1610162	193639	77393	84023	32224	712233	503492	36735	81046
İrlanda	209947	108774	48601	11887	48287	46256	3203	1899	3218
İspanya	1026061	41131	13845	22448	4838	653789	543870	43674	131958
İsrail	167601	74239	14421	23101	36721	26670	1482	7776	1428
İsveç	628564	104023	23790	75680	4553	248110	215434	9214	21956
İsviçre	421923	33845	11057	10358	12429	60824	22045	11602	20284
İtalya	1819551	99115	31865	45737	21515	552177	380906	122392	240166
İzlanda	2577	103	65	28	8	859	70	78	37
Japonya	4082177	661860	160283	117893	383687	1821241	1468940	65623	6165
Kanada	1139449	86332	28087	42552	15692	720378	586758	17724	14886
Kolombiya	15104	1000	211	448	343	6272	5362	3184	5046
Letonya	34171	12621	2148	9959	516	8503	6043	2909	3059
Litvanya	61955	10749	4008	6182	560	17639	12404	6510	7462
Lüksemburg	55122	19984	2907	16344	732	13078	8753	5915	1016
Macaristan	625916	149251	45783	94904	8563	247958	217607	9378	7509
Meksika	2461914	662510	271120	359347	32044	1119719	1022477	25949	43096
Norveç	113379	12372	4694	6553	1125	31230	8482	1994	1298
Polonya	898092	160112	55363	99624	5127	376026	278792	28161	63599
Portekiz	171969	21725	2500	15600	3626	84726	72412	22057	35117
Slovakya	513960	129837	15928	111029	2880	267051	256776	8424	13509
Slovenya	150881	8959	1815	5902	1239	75895	68713	7308	3778
Şili	21038	2838	635	2130	73	10202	6694	2603	2871
Türkiye	480722	22606	2691	18551	1366	257485	210709	120162	159740
Yeni Zelanda	27028	4474	1323	2165	988	6050	1817	2275	2021
Yunanistan	32740	9382	5318	3630	436	5900	1717	5239	8880

\*Ürün gruplarına göre mal ihracatı – yıllık (Milyon ABD Doları)

Yapılan çalışmada küme sayısı belirlenirken literatürde sıklıkla kullanılan formülasyonundan yararlanılmıştır [22]. Yararlanılan formülasyona Eşitlik 3'te yer verilmiştir. Bu çalışma için yapılan hesaplamalar sonucunda n yerine alternatif sayısı 37 yazıldığında sonuç 4,301 çıkmaktadır. Bu bağlamda bu çalışma için uygun küme sayısı dört olarak belirlenmiştir.

$$k = (n/2)^{1/2} \quad (3)$$

k= Küme Sayısı


n=Alternatif Sayısı

Tablo 3'te Beklenti Maksimizasyonu algoritmasından elde edilen kümeleme sonuçları yer alırken; Tablo 4'te ise Canopy algoritması kullanılarak elde edilen kümeleme sonuçlarına yer verilmiştir.

Tablo 3. İhracat verilerine ait beklenti maksimizasyonu kümeleme sonuçları (Expectation Maximization Clustering Results for Export Data)

KÜME 0	KÜME 1	KÜME 2	KÜME 3
ABD	Avustralya	Avusturya	Fransa
Almanya	Estonya	Belçika	Hollanda
	Finlandiya	Çekya	Kore C.
	İsrail	Danimarka	Japonya
	İzlanda	İngiltere	Meksika
	Kolombiya	İrlanda	
	Letonya	İspanya	
	Litvanya	İsveç	
	Lüksemburg	İsviçre	
	Norveç	İtalya	
	Portekiz	Kanada	
	Slovenya	Macaristan	
	Şili	Polonya	
	Yeni Zelanda	Slovakya	
	Yunanistan	Türkiye	

Beklenti Maksimizasyonu algoritmasına ait sonuçların yer aldığı Tablo 3'e bakıldığında Küme 0'da sadece ABD ve Almanya'nın bulunduğu görülmektedir. Bu iki ülke en büyük ihracat hacmine sahip ülkeler olarak dikkat çekerken, K6, K8, K9, K10, K13, K14, K17 (imalat, kimyasallar, ilaçlar, makine-nakliye ürünleri, telekomünikasyon ekipmanları, entegre devreler-elektronik bileşenler, tekstil) kodlu ürün gruplarında benzer ihracat hacmine sahip oldukları gözlemlenmiştir. Küme 3'e bakıldığında Küme 0'dan sonra en yüksek ihracat hacmine sahip ülkeler bu küme içerisinde yer almışlardır. Ülkelerin K6, K10, K13 (imalat, makine-nakliye ürünleri, telekomünikasyon ekipmanları) kodlu ürün gruplarında benzer ihracat hacmine ulaştıkları gözlenmiştir. Küme 2'ye bakıldığında Türkiye'nin bu grupta yer aldığı görülmektedir. Çoğunlukla GSYİH'sı yüksek olan ülkelerin yer aldığı bu grupta K11 ve K13 (elektronik bilgi işlem-ofis ekipmanları, entegre devreler-elektronik bileşenler) kodlu ürün gruplarının ihracat hacimleri benzerdir.



Grafik 1. İhraç Edilen Ürün Gruplarına Göre Ülkelerin Beklenti Maksimizasyonu (Expectation Maximization of Countries by Exported Product Groups)


Grafik 1'e bakıldığında Beklenti Maksimizasyonu algoritması kullanılarak yapılan kümeleme analizi sonucunda ülkelerin kümelere dağılımı görülmektedir. Bu doğrultuda Küme 0'a bakıldığında 2 ülkenin bu küme içerisinde yer aldığı gözlemlenirken; OECD ülkelerinin %5'inin Küme 0'a atandığı sonucuna varılmaktadır. Küme 1'e bakıldığında; 15 ülkeyle %41, Küme 2; 15 ülkeyle %45 ve Küme 3; 5 ülkeyle %13 orana sahip olduğu görülmüştür.



Tablo 4. İhracat verilerine ait Canopy algoritması kümeleme sonuçları (Canopy algorithm clustering results of export data)

KÜME 0	KÜME 1	KÜME 2	KÜME 3
Avustralya	ABD	Finlandiya	Estonya
Avusturya	Almanya	Kolombiya	İsrail
Belçika	Hollanda	Portekiz	İzlanda
Çekya	Japonya	Slovakya	Letonya
Danimarka	Kore C.		Litvanya
Fransa			Lüksemburg
İngiltere			Slovenya
İrlanda			Şili
İspanya			Yeni Zelanda
İsveç			Yunanistan
İsviçre			
İtalya			
Kanada			
Macaristan			
Meksika			
Norveç			
Polonya			
Türkiye			

Canopy algoritmasına ait sonuçların yer aldığı Tablo 4'e bakıldığında Türkiye'nin ve GSYİH'sı yüksek olan ülkelerin Küme 0'da yer aldığı görülmektedir. Özellikle K2 ve K13 (tarımsal ürünler ve telekomünikasyon ekipmanları) kodlu ürün gruplarında benzer hacme sahip olan ülkelerin bu küme altında toplandığı görülmektedir. Küme 1'e bakıldığında yüksek ihracat hacmine sahip olan ve sektöre yön veren ülkelerin bu grupta yer aldığı gözlemlenmiştir. K7, K10, K12 ve K13 (demir çelik, makine ve nakliye ürünleri, elektronik bilgi işlem ve ofis ekipmanları, telekomünikasyon ekipmanları) kodlu ürün gruplarında benzer ihracat hacmine sahip olan bu ülkeler daha çok elektronik ve makine-teçhizat ağırlıklı ihracat gerçekleştirmektedir. Küme 2'ye bakıldığında K2, K8 ve K14 (tarımsal ürün, kimyasallar, entegre devreler ve elektronik bileşenler) kodlu ürün gruplarında benzer ihracat hacmine sahip ülkelerin bu küme altında toplandığı görülmektedir. Son olarak Küme 3'e bakıldığında ise, K17, K18 (tekstil, giyim) kodlu ürün gruplarında benzerlik gösteren ülkelerin özellikle tekstil ve giyim ürün gruplarında ihracat yaptığı gözlemlenmiştir.



Grafik 2. İhraç Edilen Ürün Gruplarına Göre Ülkelerin Canopy Algoritmasına Göre Kümelere Dağılımı (Distribution of Countries by Exported Product Groups into Clusters According to Canopy Algorithm)

Grafik 2'ye bakıldığında Beklenti Maksimizasyonu algoritması kullanılarak yapılan kümeleme analizi sonucunda ülkelerin kümelere dağılımı görülmektedir. Bu doğrultuda Küme 0'a bakıldığında 18 ülkenin bu küme içerisinde yer aldığı gözlemlenirken; OECD ülkelerinin %49'unun Küme 0'a atandığı sonucuna varılmaktadır. Küme 1'e bakıldığında; 5 ülkeyle %13, Küme 2; 4 ülkeyle %11 ve Küme 3; 10 ülkeyle %27 orana sahip olduğu görülmüştür.

Kriter sayısının fazla olmasından dolayı ithal edilen ürün gruplarına ait verilerin yer aldığı karar matrisi tablosu ikiye ayrılarak Tablo 5 ve Tablo 5'in devamı şeklinde verilmiştir.

Tablo 5. İthal edilen ürün gruplarına ait karar matrisi (Decision matrix for imported product groups)

ÜLKELER	K1	K2	K3	K4	K5	K6	K7	K8	K9
ABD	24575974	1705309	1462923	3103607	2552418	18637332	384018	2424383	1048895
Almanya	11924268	1145395	974329	1716886	1199713	8785810	299365	1678463	558231
Avusturalya	2303922	160840	145511	319923	285397	1666770	28894	229225	93576
Avusturya	1803813	176663	139383	229362	147303	1370981	48774	240074	102041
Belçika	4317815	443906	391520	759417	583600	3055661	111949	1076132	435804
Çekya	1634434	115220	95450	161333	108546	1349114	68587	186169	49584
Danimarka	972481	164921	139803	84537	68899	709829	27055	123668	47846
Estonya	179087	23059	17609	25306	22330	125484	6118	20562	5104
Finlandiya	729281	74271	57786	162071	115825	472147	19799	84429	23590
Fransa	6417726	681793	604749	894209	740087	4780361	142808	893647	301114
Kore C.	5003174	359526	289359	1694806	1335860	2929116	165572	497205	66058
Hollanda	5987424	756660	657279	1287964	1064385	3908740	121198	784170	262838
İngiltere	6668406	708405	628239	853058	634342	4479582	83566	749557	307716
İrlanda	897190	101998	96596	77388	66212	688027	8547	194005	86237
İspanya	3520753	441544	398890	674320	543112	2365644	91398	531458	168344
İsrail	726460	68896	61780	108478	97956	544497	18464	86394	24335
İsveç	1587484	192111	170457	225454	180072	1149280	50686	182246	47451
İsviçre	2859608	137064	121218	171833	107016	1710745	32013	504623	294138
İtalya	4685804	583673	481886	891290	663818	3117337	188436	752380	275793
İzlanda	60861	7228	6588	14444	7527	39124	721	5310	1629
Japonya	7333039	816561	694698	2312230	1817290	4064238	83521	711078	261738
Kanada	4570769	400717	360696	490552	353819	3374675	107944	490515	140911
Kolombiya	536023	67719	62961	55148	46307	405933	21607	103873	26564
Letonya	180769	34736	29420	22308	19398	120422	6969	22395	6818
Litvanya	339026	51159	42960	76548	69949	207990	8718	50679	11782
Macaristan	1093824	75104	62301	128735	101571	874296	27060	137999	47407
Meksika	4277692	295883	252020	431964	332723	3240081	111322	451824	52332
Norveç	846489	92881	81926	95253	46619	652090	20775	80702	22103
Polonya	2397999	244739	205524	276641	193328	1827978	103903	340981	70928
Portekiz	794861	131403	116788	128290	107240	533722	25035	112407	30185
Slovakya	841228	60592	50229	96181	70039	681204	29793	72808	20917
Slovenya	381831	40053	31228	57255	36943	283652	17144	66048	26628
Şili	715148	73509	68613	134347	123479	505071	17020	83032	15526
Türkiye	2335473	190416	132558	568169	261642	1401170	116898	322521	50512
Yeni Zelanda	406334	49733	46529	55200	47399	296425	5209	44238	10285
Yunanistan	590931	84848	78713	193869	171857	311539	11070	93176	35952

\*Ürün gruplarına göre mal ithalatı - yıllık (Milyon ABD Doları)

Tablo 5. İthal edilen ürün gruplarına ait karar matrisi – devamı (Decision matrix for imported product groups -continued )

ÜLKELER	K1	K2	K3	K4	K5	K6	K7	K8	K9
ABD	24575974	1705309	1462923	3103607	2552418	18637332	384018	2424383	1048895
Almanya	11924268	1145395	974329	1716886	1199713	8785810	299365	1678463	558231
Avusturalya	2303922	160840	145511	319923	285397	1666770	28894	229225	93576
Avusturya	1803813	176663	139383	229362	147303	1370981	48774	240074	102041
Belçika	4317815	443906	391520	759417	583600	3055661	111949	1076132	435804
Çekya	1634434	115220	95450	161333	108546	1349114	68587	186169	49584
Danimarka	972481	164921	139803	84537	68899	709829	27055	123668	47846
Estonya	179087	23059	17609	25306	22330	125484	6118	20562	5104
Finlandiya	729281	74271	57786	162071	115825	472147	19799	84429	23590
Fransa	6417726	681793	604749	894209	740087	4780361	142808	893647	301114
Kore C.	5003174	359526	289359	1694806	1335860	2929116	165572	497205	66058
Hollanda	5987424	756660	657279	1287964	1064385	3908740	121198	784170	262838
İngiltere	6668406	708405	628239	853058	634342	4479582	83566	749557	307716
İrlanda	897190	101998	96596	77388	66212	688027	8547	194005	86237
İspanya	3520753	441544	398890	674320	543112	2365644	91398	531458	168344
İsrail	726460	68896	61780	108478	97956	544497	18464	86394	24335
İsveç	1587484	192111	170457	225454	180072	1149280	50686	182246	47451
İsviçre	2859608	137064	121218	171833	107016	1710745	32013	504623	294138
İtalya	4685804	583673	481886	891290	663818	3117337	188436	752380	275793
İzlanda	60861	7228	6588	14444	7527	39124	721	5310	1629
Japonya	7333039	816561	694698	2312230	1817290	4064238	83521	711078	261738
Kanada	4570769	400717	360696	490552	353819	3374675	107944	490515	140911
Kolombiya	536023	67719	62961	55148	46307	405933	21607	103873	26564
Letonya	180769	34736	29420	22308	19398	120422	6969	22395	6818
Litvanya	339026	51159	42960	76548	69949	207990	8718	50679	11782
Macaristan	1093824	75104	62301	128735	101571	874296	27060	137999	47407
Meksika	4277692	295883	252020	431964	332723	3240081	111322	451824	52332
Norveç	846489	92881	81926	95253	46619	652090	20775	80702	22103
Polonya	2397999	244739	205524	276641	193328	1827978	103903	340981	70928
Portekiz	794861	131403	116788	128290	107240	533722	25035	112407	30185
Slovakya	841228	60592	50229	96181	70039	681204	29793	72808	20917
Slovenya	381831	40053	31228	57255	36943	283652	17144	66048	26628
Şili	715148	73509	68613	134347	123479	505071	17020	83032	15526
Türkiye	2335473	190416	132558	568169	261642	1401170	116898	322521	50512
Yeni Zelanda	406334	49733	46529	55200	47399	296425	5209	44238	10285
Yunanistan	590931	84848	78713	193869	171857	311539	11070	93176	35952


\*Ürün gruplarına göre mal ithalatı – yıllık (Milyon ABD Doları)

Tablo 5'te ithal edilen ürün gruplarına ait olan değerler yer almaktadır. Mevcut karar matrisi WEKA programına dahil edilerek veri setine uygun olan tüm kümeleme algoritmaları çalıştırılmıştır. Çalışmada Beklenti Maksimizasyonu ve Canopy algoritmalarının karşılaştırmalı sonuçlarına yer verilmiştir.

Tablo 6. İthalat verilerine ait Beklenti Maksimizasyonu algoritması kümeleme sonuçları  
(Expectation Maximization algorithm clustering results for import data)

KÜME 0	KÜME 1	KÜME 2	KÜME 3
Avusturya	Avusturya	Almanya	ABD
Çekya	Belçika	Fransa	
Danimarka	İspanya	Hollanda	
Estonya	İtalya	İngiltere	
Finlandiya	Kanada	Japonya	
İrlanda	Meksika	Kore C.	
İsrail	Polonya		
İsveç	Türkiye		
İsviçre			
İzlanda			
Kolombiya			
Letonya			
Litvanya			
Macaristan			
Norveç			
Portekiz			
Slovakya			
Slovenya			
Şili			
Yeni Zelanda			
Yunanistan			

Beklenti Maksimizasyonu algoritmasına ait sonuçların yer aldığı Tablo 6'ya bakıldığında Küme 0'da yer alan ülkelerin K7 (demir çelik) kodlu ürün grubunda benzer ithalat hacmine sahip oldukları görülmektedir. Küme 1'e bakıldığında K1, K3, K4, K5, K6, K15, K17, K18 (toplam ticari mal, gıda, yakıt ve madencilik, yakıt, imalat, taşıma ekipmanları, tekstil, giyim) kodlu ürün gruplarının ithalatında benzerlik göstermektedir. Birçok ürün grubunda benzerlik taşıyan ülkelerin yer aldığı bu grupta Türkiye de bulunmaktadır. Küme 2'de gelişmiş ülkelerin yer aldığı gözlemlenirken, özellikle K1, K3, K6, K10, K12, K13 (toplam ticari mal, gıda, imalat, makine ve nakliye, elektronik bilgi işlem ve ofis ekipmanları, telekomünikasyon ekipmanları) kodlu ürün gruplarında benzer hacimlere sahip oldukları sonucuna varılmıştır. bu grupta yer alan ülkelerin benzerlik gösteren ürün gruplarına bakıldığında elektronik ve makine ağırlıklı olduğu gözlenmektedir. Son olarak Küme 3'e bakıldığında sadece Amerika Birleşik Devletleri'nin bu kümede yer aldığı görülmektedir. Hacimsel olarak diğer ülkelerden ayrılan Amerika Birleşik Devletleri birçok ürün grubunda lider konumdadır.




Grafik 3. İhraç Edilen Ürün Gruplarına Göre Ülkelerin Beklenti Maksimizasyonu Algoritmasına Göre Kümelere Dağılımı  
(Distribution of Countries by Exported Product Groups into Clusters According to Expectation Maximization Algorithm)

Grafik 3'e bakıldığında Beklenti Maksimizasyonu algoritması kullanılarak yapılan kümeleme analizi sonucunda ülkelerin kümelere dağılımı görülmektedir. Bu doğrultuda Küme 0'a bakıldığında 22 ülkenin bu küme içerisinde yer aldığı gözlemlenirken; OECD ülkelerinin %59'unun Küme 0'a atandığı sonucuna varılmaktadır. Küme 1'in; 8 ülkeyle %22, Küme 2'nin; 6 ülkeyle %16 ve Küme 3'ün; 1 ülkeyle %3 orana sahip olduğu görülmüştür.

Tablo 7. İthalat verilerine ait Canopy algoritması kümeleme sonuçları (Canopy algorithm clustering results of import data)

KÜME 0	KÜME 1	KÜME 2	KÜME 3
Avusturya	ABD	Danimarka	Estonya
Avusturya	Almanya	Finlandiya	İzlanda
Belçika	Fransa	İrlanda	Letonya
Çekya	Hollanda	İsrail	Litvanya
İngiltere	Japonya	Kolombiya	Lüksemburg
İspanya	Kore C.	Macaristan	Yeni Zelanda
İsveç		Norveç	
İsviçre		Portekiz	
İtalya		Slovakya	
Kanada		Slovenya	
Meksika		Şili	
Polonya		Yunanistan	
Türkiye			

Tablo 7'ye bakıldığında ithalat hacmi en yüksek olan ülkelerin Küme 1'de toplandığı görülmektedir. Özellikle K4, K6 ve K11 (yakıtlar, demir-çelik ve elektronik bilgi işlem-ofis ekipmanları) kodlu ürün gruplarında benzer ortalamalar yakaladıkları görülmektedir. Küme 0'a bakıldığında, Türkiye'nin ve genellikle GSYİH'sı yüksek olan ülkelerin aynı küme altında toplandığı gözlemlenirken; K1, K5, K7, K10, K14, K15 ve K16 (tarımsal ürünler, imalat, kimyasallar, ofis-telekom ekipmanları, taşıma ekipmanları, otomotiv ürünleri ve tekstil) kodlu ürün gruplarında benzerlik gösterdikleri ortaya konmuştur. Küme 4'e bakıldığında ise ithalat hacmi daha küçük olan ülkelerin aynı küme altında toplandığı görülmektedir. K6, K12 ve K17 (demir-çelik, telekomünikasyon ekipmanları ve giyim) kodlu ürün gruplarında benzer hacme sahip oldukları ortaya konmuştur.



Grafik 4. İhrac Edilen Ürün Gruplarına Göre Ülkelerin Canopy Algoritmasına Göre Kümelere Dağılımı  
(Distribution of Countries by Exported Product Groups into Clusters According to Canopy Algorithm)

Grafik 4'e bakıldığında Beklenti Maksimizasyonu algoritması kullanılarak yapılan kümeleme analizi sonucunda ülkelerin kümelere dağılımı görülmektedir. Bu doğrultuda Küme 0'a bakıldığında 13 ülkenin bu küme içerisinde yer aldığı gözlemlenirken; OECD ülkelerinin %35'inin Küme 0'a atandığı sonucuna varılmaktadır. Küme 1'in; 6 ülkeyle %16, Küme 2'nin; 12 ülkeyle %33 ve Küme 3'ün; 6 ülkeyle %16 orana sahip olduğu görülmüştür.

#### 4. Sonuç (Conclusion)

Küreselleşen rekabetle birlikte dış ticaretin önemi her geçen gün artmaktadır. Üretim kapasitesi bulunan ürün gruplarındaki rekabet üstünlüğünü ele geçirmek isteyen ülkeler çeşitli stratejiler geliştirerek bu ürünlerin ihracatını sürdürülebilir hale getirmek istemektedir. Ülkeler aksi durumlarda ise göreceli yetersiz olduğu ürün gruplarında ise ithalata yönelmektedir.

Literatüre bakıldığında ürün gruplarıyla ilgili bir adet çalışmaya rastlanmıştır. Pelit [23] tarafından yapılan çalışmada, Türkiye'nin ülke gruplarına göre ithalat ve ihracat bakımından kümeleme analizi ile incelendiği görülürken, çalışmada kümeleme analizi tekniklerinden olan k-means kullanılmıştır.

Yapılan çalışmada ise Dünya Ticaret Örgütü'nden elde edilen ürün gruplarına göre ihracat ve ithalat verilerinden yararlanılarak benzer eğilim gösteren OECD ülkelerinin kümelenmesi amaçlanmıştır. Çalışmada ilk olarak WEKA paket programına veriler girilmiş daha sonra sayısal veri setine uygun kümeleme algoritmaları çalıştırılmıştır. Yapılan analiz neticesinde en uygun sonucun Beklenti Maksimizasyonu algoritmasından elde edildiği gözlemlenmiştir.

Yapılan analiz sonucunda aynı grupta yer alan ülkelerin benzer gelişmişlik seviyelerine sahip ülkeler olduğu gözlemlenirken, benzer ürün gruplarının ithalatını ve ihracatını gerçekleştirdiği gözlemlenmiştir.

Mevcut ürün grupları baz alınarak yapılan kümeleme işleminde ülkeler ilk olarak ithal edilen ürün gruplarına göre kümelenmiştir. Küme 1'e bakıldığında büyük ekonomilere sahip ülkelerden olan Amerika, Almanya, Fransa, Hollanda, Japonya ve Kore Cumhuriyeti aynı kümede yer alırken, yakıtlar, demir-çelik ve elektronik bilgi işlem-ofis ekipmanları gibi ürün gruplarını göreceli daha az gelişmiş ülkelere temin ettiği görülmektedir. Türkiye'nin de yer aldığı Küme 0'a bakıldığında ise tarımsal ürün, imalat, otomotiv ekipmanları gibi ürün gruplarını ithal ettiği görülmektedir.

Mevcut ürün grupları baz alınarak yapılan kümeleme işleminde ülkeler son olarak ihraç edilen ürün gruplarına göre kümelenmiştir. Küme 0'a bakıldığında bu kümede sadece ABD ve Almanya'nın yer aldığı görülmektedir. İmalat, kimyasallar, ilaçlar, makine-nakliye ürünleri, telekomünikasyon ekipmanları, entegre devreler-elektronik bileşenler, tekstil gibi ürün gruplarında rekabet üstünlükleri bulunurken, bu ürünleri nispeten daha az gelişmiş ülkelere ihraç ettikleri gözlemlenmiştir. Türkiye'nin de yer aldığı Küme 2'ye bakıldığında ise çoğunlukla GSYİH'sı yüksek olan ülkelerin bu kümede yer aldığı görülmektedir. Bu kümede yer alan ülkelerin çoğunlukla elektronik bilgi işlem-ofis ekipmanları, entegre devreler-elektronik bileşenler gibi ürün gruplarının ihracatçısı olduğu ortaya konmuştur.

Bundan sonra yapılacak olan çalışmalarda diğer ülke grupları ele alınabilir, farklı algoritmalarla yararlanılarak farklı sonuçlar ortaya konulabilir. Buna ek olarak spesifik olarak seçilecek ürün grupları ile ikili ülke karşılaştırmaları yapılabilir.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

- [1] B. K. Aktaş, N. Ömürbek and M. Karaatlı, "Entopi-CRITIC temelli EM algoritması ile internet kullanımı açısından OECD ülkelerinin kümelenmesi," *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, vol.12, no.24, pp.648-679, 2021. doi: 10.36543/kauibfd.2021.027.
- [2] M. Karaatlı and E. Yıldız, "Mevduat bankalarının finansal yapılarının kümeleme analizi ile incelenmesi," *BMIJ*, vol.9, no.1, pp.1-17, 2021. doi: 10.15295/bmij.v9i1.1594.
- [3] J. A. Adeyiga, S. O. Olabiyisi and E. O. Omidiora, "A comparative analysis of selected clustering algorithms for criminal profiling," *Nigerian Journal of Technology*, vol. 39, pp.464-471, 2020. doi: 10.4314/njt.v39i2.16.
- [4] F. M. N. Ali and A. A. M. Hamed, "Usage Apriori and clustering algorithms in WEKA tools to mining dataset of traffic accidents," *Journal of Information and Telecommunication*, vol. 2, no.3, pp.231-245, 2018. doi: 10.1080/24751839.2018.1448205.
- [5] P. A. Widya and M. Suderma, "Implementation of EM algorithm in data mining for cluster female cooperative," *International Journal of Engineering and Emerging Technology*, vol.3, no.1, pp.75-79, 2018. doi: 10.24843/IJEET.2017.v02.i01.
- [6] İ. İ. Avşar, "Türkiye ve Avrupa Birliği ülkelerinin demiryolu hat uzunluğuna göre kümelenmesi," *Tarsus Üniversitesi Uygulamalı Bilimler Fakültesi Dergisi*, vol.3, no.1, pp.13-25, 2023.
- [7] M. Karaatlı, T. Karataş and N. Ömürbek, "Ülkelerin insani özgürlük endeksine göre kümelenmesi," *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, vol.20, no.3, pp.271-286, 2020. doi: 10.18037/ausbd.801788.
- [8] T. Kocabiyik, M. Karaatlı and K. B. Aktaş, "Borsa İstanbul 30 endeksinde yer alan hisse senetlerinin kümelenmesi: Covid-19 öncesi ve Covid-19 dönemi incelemesi," *İşletme Araştırmaları Dergisi*, vol.13, no.3, pp.2537-2551, 2021. doi: 10.20491/isarder.2021.1276.
- [9] B. Erkan and İ. Duman, "Türkiye'nin SITC ve ISIC sınıflandırmasına göre ihracat verilerinin değerlendirilmesi (2000-2020)," *Uluslararası Türk Dünyası Sosyal Bilimler Sempozyumu, Aralık 2-3 2022, İzmir, Türkiye, 2022*, pp.1-15.

- [10] A. Karataş, "COVID 19'un Türkiye dış ticaretine kısa dönem etkilerinin ürün grubu bazında incelenmesi," *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, vol.10, no.3, pp.2129-2152, 2021. doi: 10.15869/itobiad.877872.
- [11] K. Sarıçoban, "RCEP ülkelerinin dış ticareti ve standart ürün grupları bazında ihracattaki karşılaştırmalı üstünlükleri," *Elektronik Sosyal Bilimler Dergisi*, vol.21, no.84, pp.1991-2012, 2022. doi: 10.17755/esosder.1140018.
- [12] M. Nasrullah, L. Chang, K. Khan, M. Rizwanullah and F. Zulfiqar, "Determinants of forest product group trade by gravity model approach: a case study of China," *Forest Policy and Economics*, vol.113, pp.1-14, 2020. doi: 10.1016/j.forpol.2020.102117.
- [13] N. Kuşat, "Açıklanmış karşılaştırmalı üstünlüklere göre Türkiye-BRICS rekabet gücü analizi (2008-2019)," *Kocatepe İktisadi ve İdari Bilimler Fakültesi Dergisi*, vol.23, no.1, pp.94-111, 2021. doi: 10.33707/akuiibfd.839333.
- [14] A. Albayrak and Ş. K. Yılmaz, "Veri madenciliği: karar ağacı algoritmaları ve İMKB verileri üzerine bir uygulama," *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, vol.14, no.1, pp.31-52, 2009.
- [15] J. Sun, J. Liu and L. Zhao, "Clustering algorithm research," *Journal of Software*, vol.19, no.1, pp.48-61, 2008.
- [16] Ö. Pasin, "Sağlık Alanında Yapılan Araştırmalarda Kümeleme Algoritmalarının Kullanımı: Bir Uygulama," Yüksek Lisans Tezi, Düzce Üniversitesi Sağlık Bilimleri Enstitüsü, Düzce, Türkiye, 2015.
- [17] A. P. Dempster, N. M. Laird and D. B. Rubin, "Maximum likelihood from incomplete data via the EM algorithm," *Journal of the Royal Statistical Society*, vol.39, no.1, pp.1-38, 1977.
- [18] L. Bruzzone and F. Prieto, "An adaptive semiparametric and context-based approach to unsupervised change detection in multitemporal remote-sensing images," *IEEE Transactions on Geoscience and Remote Sensing*, vol.11, no.4, pp.452-466, 2002.
- [19] C. Bal and K. Özdamar, "Eksik gözlem sorununun türetilmiş veri setleri yardımıyla çözülmesi," *Osmangazi Üniversitesi Tıp Fakültesi Dergisi*, vol.26, no.2, pp.67-76, 2004.
- [20] H. Akpınar, *Data: Veri Madenciliği Veri Analizi*, Ankara: Papartya, 2017.
- [21] World Trade Organisation, [Online]. Available: <https://www.wto.org>. [Accessed: 11/10/2023].
- [22] B. Everitt, *Cluster Analysis*, London: Heinemann Educational Books, 1974.
- [23] İ. Pelit, "Türkiye'nin ülke gruplarına göre ithalat ve ihracatının kümeleme analizi ile incelenmesi: 2013-2022 dönemi", *İşletme ve İktisat Çalışmaları Dergisi*, vol.11, no.2, pp.103-113, 2023.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## Predicting Yield and Vegetative Growth in Apples Using Mathematical Modeling Methods

Hamit Armağan<sup>a</sup>, Ersin Atay<sup>b</sup>

Submitted: 26.11.2023 Revised: 19.12.2023 Accepted: 19.12.2023 doi:10.30855/gmbd.0705S19

### ABSTRACT

**Keywords:** machine learning,  
fourier regression,  
mathematical modeling

<sup>a</sup> Süleyman Demirel Üniversitesi,  
Rektörlük, Enformatik Bölümü, 32200  
Isparta/TÜRKİYE  
Orcid: 0000-0002-8948-1546  
e-mail: hamitarmagan@sdu.edu.tr

<sup>b</sup> Burdur Mehmet Akif Ersoy Üniversitesi,  
Burdur Gıda Tarım ve Hayvancılık Meslek  
Yüksekokulu Burdur/TÜRKİYE  
Orcid: 0000-0003-0810-3779

\*Corresponding author:  
hamitarmagan@sdu.edu.tr

This study aims to predict the yield and vegetative growth of 'Golden Reinders' apple trees grafted on M.9 rootstock over the economic lifespan of an orchard (15 years). Mathematical models with high determination coefficients were applied to data collected during the first 7 years following orchard establishment in the "Göller Yöresi" region. Fifteen trees were selected after orchard establishment, and their yield and trunk diameter values were recorded over a 7-year period. Regression models for yield and vegetative growth were developed using data processed with the Matlab program. Results were comparatively evaluated, revealing the power regression model as prominent in determining the year-tree trunk diameter relationship, while the Fourier regression model took precedence in establishing the tree trunk diameter-yield relationship. The study concludes that understanding how yield and vegetative growth evolve throughout the economic lifespan of apple orchards can be effectively achieved through such modeling approaches.

## Matematiksel Modelleme Yöntemleri ile Elmada Verim ve Vejetatif Gelişimin Tahmin Edilmesi

### ÖZ

Bu çalışmada elma ağaçlarında yüksek belirleme katsayısına sahip matematiksel modellemelerle bahçe tesisini takip eden ilk 7 yıl verisine dayalı olarak bahçenin ekonomik ömrünü (15 yıl) kapsayacak şekilde verim ve vejetatif gelişimin tahmin edilmesi amaçlanmıştır. Göller Yöresi şartlarında yürütülen çalışmada M.9 anaçlı 'Golden Reinders' elma çeşidine ait ağaçlar kullanılmıştır. Bahçe tesisini takiben toplamda 15 ağaç belirlenmiş ve 7 yıl boyunca aynı ağaçların verim ve gövde çapı değerleri belirlenmiştir. Matlab programı yardımıyla toplanan verilere dayalı verim ve vejetatif gelişim regresyon modellemeleri yapılmıştır. Sonuçlar karşılaştırmalı olarak değerlendirilmiş ve yıl-ağaç gövde çapı ilişkisinin belirlenmesinde kuvvet regresyon modeli, ağaç gövde çapı-verim ilişkisinin belirlenmesinde ise fourier regresyon modeli ön plana çıkmıştır. Elma bahçelerinin ekonomik ömrü boyunca verim ve vejetatif gelişim nasıl bir seyir izler sorusunun cevabının ancak bu tarz modellemeler yardımıyla cevaplanabileceği sonucuna varılmıştır.

**Anahtar Kelimeler:**  
makine öğrenmesi,  
fourier regresyon,  
matematiksel modelleme



## 1. Giriş (Introduction)

Tarımsal üretimde verimi arttırmaya yönelik çalışmalar hız kesmeden devam etmektedir [1]. Tarımda yapay zekâ modellerinin kullanımı bu çalışmaların en önemlileri arasında yer almaktadır [2]. Yapay zekâ modellerinin temeli matematiksel ve istatistiksel yöntemlerdir [3]. Matematiksel fonksiyon ve algoritmalarla veri kümelerinin modellenmesi ile araştırılan konuya yönelik tahminlerin yapılabilmesine olanak sağlanmaktadır [4], [5].

Regresyon modelleri, girdi ve çıktı değişkenleri arasında matematiksel fonksiyonlar ile sürekli değişkenlere ait yanıtları tahmin eder [6]–[8]. Regresyon yöntemi ile modelleme, bağımlı değişken ile bağımsız değişken arasındaki ilişkinin bir fonksiyon ile temsil edilmesidir [6], [9]. Bu fonksiyonun temel amacı modellenen sistem ile ilgili tanım kümesindeki değerlere bağlı olarak tahminlerin hesaplanmasıdır [6]. Pek çok regresyon modeli bulunmaktadır (doğrusal, doğrusal olmayan, üstel ve logaritmik gibi) [9]–[12]. Birçok durumda, tek girdi değişkeni kullanan doğrusal regresyon, ilişkili modellerde yeterli tahmin gücü sunamayabilir [6]. Bu durum, araştırmacıları, regresyon modeli için girdi olarak aynı anda iki ya da daha fazla değişkenin kullanıldığı çoklu doğrusal olmayan regresyon modeline yöneltmiştir [13]–[15].

Son yıllarda tarımsal üretimde matematiksel modellere dayalı farklı yapay zeka teknolojilerinin kullanımı verimi artırma ve maliyetleri düşürme konusunda dikkat çekici sonuçlar sağlamıştır [1], [16], [17]. Mevcut tarım teknolojilerine entegre edilen güvenilir modeller; verim artışı, hastalık teşhisi ve sulama etkinliğinin artırılmasında rol oynamaya başlamıştır [3], [18]. Elma bahçeleri özelinde kullanılabilir matematiksel modelleme yöntemlerinin geliştirilmesi ticari bahçelerin daha rekabetçi bir noktaya ulaşabilmesi açısından kritiktir [19]. Böylelikle işlemler yoğun mesai gerektiren faaliyetlerde işgücü gereksinimi planlayabilme ve pazarlama organizasyonlarını daha etkin şekilde gerçekleştirebilme potansiyeline sahip olabilirler [19], [20].

Türkiye’de tarım sektörü, ekonomik büyüklük olarak hizmet ve sanayi sektörlerinin ardından üçüncü sırada gelmektedir (TÜİK, 2023). Son verilere göre Türkiye’de 306 milyar TL bitkisel üretim değeri içerisinde meyve üretiminin payı %28, meyve üretim değeri içerisinde elma üretiminin payı ise %11 olarak gerçekleşmiştir (TÜİK, 2023). İthalat ve ihracat verileri incelendiğinde, Türkiye’nin elmada her zaman ihracat fazlası veren bir ülke olduğu görülmektedir. 2020 yılı itibarı ile Türkiye elma ihracatı (1.52 milyon ton; aynı yıl 4.30 milyon ton olan toplam ülke üretiminin %35.34’ü) ve ihracat-ithalat farkı (1.24 milyon ton) rekor seviyeye ulaşmıştır (TÜİK, 2023). Türkiye tarihte ilk defa 2021 yılında dünya elma üretiminde ABD’nin de önüne geçerek Çin’in ardından dünyada sıralamasında ikinciliğe yükselmiştir (FAOSTAT, 2023).

Elmanın ülke tarımı için büyük öneme sahip olduğu açıktır. Bununla birlikte Türkiye’de hemen hemen tüm tarım sektöründe olduğu gibi elma endüstrisinde de ileri tarım teknolojilerine geçiş süreci oldukça sancılı şekilde devam etmektedir [19], [23], [24]. Nitekim tarım sektörünün modernleşmesi ve yapay zekaya dayalı uygulamaların daha hassas şekilde ele alınması ülke kaynaklarının daha etkin şekilde kullanılabilmesi açısından önem arz etmektedir.

Bu bağlamda çalışmada; elma ağaçlarında yüksek belirleme katsayısına sahip matematiksel modellemelerle bahçe tesisini takip eden ilk 7 yıl verisine dayalı olarak bahçenin ekonomik ömrünü (15 yıl) kapsayacak şekilde verim ve vejetatif gelişimin tahmin edilmesi amaçlanmıştır.

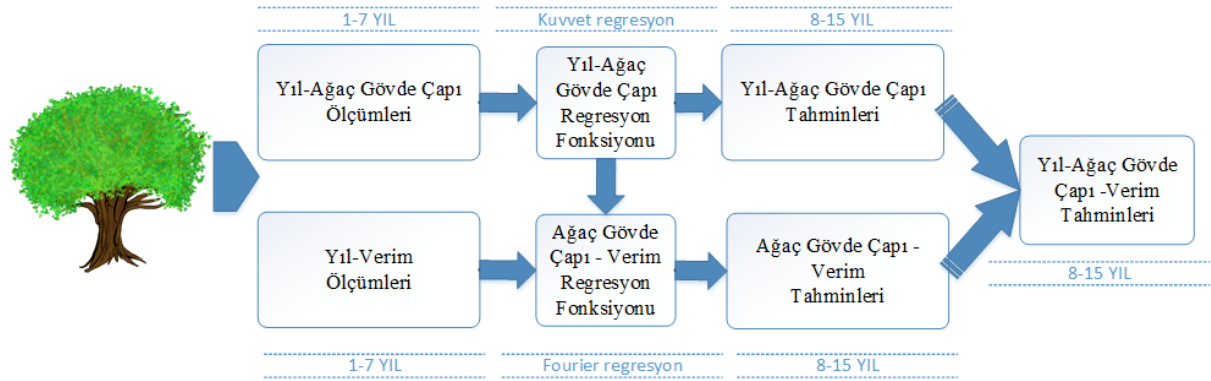
## 2. Materyal ve Metot (Material and Method)

### 2.1. Materyal (Material)

Çalışma Göller Yöresi şartlarında yürütülmüştür. Bitkisel materyal olarak 4 × 1 m aralıklarla dikilmiş (250 ağaç/dekar) M.9 anacına aşılı ‘Golden Reinders’ çeşidi elma ağaçları kullanılmıştır. Bahçe Merkezkaç sistemine göre terbiye edilmiştir. Bahçe düzenli aralıklarla damla sulama yöntemiyle sulanmış ve tüm kültürel işlemler lokal koşullara göre gerçekleştirilmiştir. Deneme süresince yörede ilkbahar geç donları ya da dolu gibi herhangi bir olumsuz iklim olayı yaşanmamıştır.

## 2.2. Veri toplama (Data collection)

Bahçeden 15 ağaç belirlenerek etiketlenmiş ve bahçe tesisini takip eden ilk 7 yıl verim ve vejetatif gelişim verileri boyunca aynı ağaçlardan toplanmıştır. Hasat zamanında ağaç verimi (kg/ağaç) değerleri kaydedilmiştir. Vejetatif gelişimi belirlemek için ağaç gövde çapı değerleri aşı noktasının 15 cm üzerinden dijital kumpas yardımıyla ölçülmüştür. Elmada ağaçlarında verim ve vejetatif gelişimin tahmin edilmesine ait veri toplama ve modelleme süreçleri şekil 1’de verilmiştir.



Şekil 1. Matematiksel modelleme yöntemleri ile elmada verim ve vejetatif gelişimin tahmin edilmesine ait süreçler  
(Processes of estimating yield and vegetative development in apples using mathematical modeling methods)

## 2.3. Matematiksel modelleme (Mathematical modeling)

Verim ve vejetatif gelişim verileri düzgün dağılım göstermediği için, çalışmada doğrusal olmayan çoklu regresyon teknikleri kullanılmıştır. Verim değerleri genotipe ve çevresel faktörlere bağlı olarak yıllar bazında değiştiği için Ağaç Gövde Çapı-Verim İlişkisinin belirlenmesinde fourier regresyon modeli kullanılmıştır. Yıl-Ağaç Gövde Çapı İlişkisinin belirlenmesinde ise 5 farklı model (polinom regresyon, üstel regresyon, logaritmik regresyon, fourier regresyon ve kuvvet regresyonu) kullanılmıştır. Uygun regresyon modelini belirlemede uzman görüşü temeline dayanan bir uzman sistem yöntemi kullanılmıştır. Uzmanlar, regresyon modellerinin seçimindeki deneyim ve bilgilerini kullanarak analizin doğruluğunu artırmışlardır [3], [4], [6], [7].

Çalışmada denenilen/kullanılan regresyon modelleri aşağıda listelenmiştir. Listede 1, 2, 3, 4 ve 5 numaraları sırasıyla polinom, üstel, logaritmik, fourier ve kuvvet regresyon modellerini temsil etmektedir.

$$f(x) = ax^2 + bx + c \quad (1)$$

$$f(x) = ae^{(bx)} + ce^{(dx)} \quad (2)$$

$$f(x) = a \ln(x) + b \quad (3)$$

$$f(x) = a + b \cos(wx) + c \sin(wx) \quad (4)$$

$$f(x) = ax^b \quad (5)$$

### 2.3.1. Polinom regresyon (Polynomial regression)

Polinom regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi ifade etmek için polinom fonksiyonlarını kullanarak bir regresyon modeli oluşturma yöntemidir. Genel olarak n. dereceden bir polinom regresyon modeli şu şekildedir:

$$y = a_0 + a_1x + a_2x^2 + \dots + a_nx^n \quad (6)$$

Burada  $a_0, a_1, a_2, \dots, a_n$  katsayıları modelin öğrenilmiş parametreleridir ve regresyon analizi ve lineer denklem sistemleri ile değerleri hesaplanır. Polinom regresyon uygulanırken, modelin derecesinin seçilmesi

önemlidir. Çünkü düşük dereceli bir model veri setindeki karmaşıklığı yakalayamazken, benzer şekilde yüksek dereceli model de aşırı uyuma yol açabilmektedir.

### 2.3.2. Üstel regresyon (Exponential regression)

Üstel regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi ifade etmek için üstel fonksiyonları kullanarak bir regresyon modeli oluşturma tekniğidir. Genel olarak birinci dereceden bir üstel regresyon modeli şu şekildedir:

$$y = a_0 + a_1 e^{(a_2 x)} \quad (7)$$

Burada  $a_0$  ve  $a_1$  katsayıları modelin öğrenilmiş parametreleridir.  $x$  bağımsız,  $y$  bağımlı değişken olup  $e$  Euler sayısıdır.

### 2.3.3. Logaritmik regresyon (Logarithmic regression)

Logaritmik regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi ifade etmek için logaritmik fonksiyonları kullanan bir regresyon türüdür. Genel olarak logaritmik regresyon modeli şu şekildedir:

$$y = a_0 + a_1 \ln(x) \quad (8)$$

burada  $a_0$  ve  $a_1$  katsayıları modelin öğrenilmiş parametreleridir.  $x$  bağımsız,  $y$  bağımlı değişken olup "ln" doğal logaritma fonksiyonudur.

### 2.3.4. Fourier regresyon (Fourier regression)

Fourier regresyonu, bir periyodik fonksiyonu (veri setlerinin periyodik bir grafiğe sahip olması) sinüs ve kosinüs terimlerinin toplamı olarak ifade eden bir regresyon yöntemidir. Genel olarak Fourier regresyon modeli şu şekildedir:

$$f(x) = y = a_0 + \sum_{i=1}^n a_i \cos(iwx) + b_i \sin(iwx) \quad (9)$$

Burada  $f(x)$  periyodik fonksiyon ve  $a_0$ ,  $a_n$  ve  $b_n$  Fourier katsayılarıdır.

### 2.3.5. Kuvvet regresyonu (Power regression)

Bağımsız değişkenin bir bağımlı değişken üzerinde üstel bir etkiye sahip olduğu durumları modellemek için kullanılan regresyon yöntemidir. Temel kuvvet regresyon modeli;

$$f(x) = ax^b \quad (10)$$

şekindedir, burada  $a$  ve  $b$  regresyon katsayılarıdır.

## 3. Sonuçlar ve Tartışma (Results and Discussion)

### 3.1. Yıl-Ağaç gövde çapı ilişkisi (Year-Tree trunk diameter relationship)

Bu çalışmada, ağaç gövde çapı artışını tahmin etmek amacıyla farklı regresyon modelleri kullanılmış ve bu modellerin performansları karşılaştırılmıştır. Toplamda 15 deneme ağacı için polinom, üstel, logaritmik, kuvvet ve Fourier regresyon modelleri oluşturulmuş, bu modellerin hata ve yaklaşım değerleri Tablo 1'de detaylı olarak sunulmuştur. Ayrıca, her bir deneme ağacının yıllar bazında ölçülen gövde çapı değerleri, regresyon modelleriyle karşılaştırmak amacıyla Şekil 2'de görselleştirilmiştir.

Uzman görüşleri, ilerleyen yıllarda (8-15. yıllar) ağaç gövde çapında azalma olmayacağı sonucuna varmıştır. Bu bağlamda, ağaç gövde çapının ilk 7 yıl artış hızına bağlı olarak kuvvet regresyon fonksiyonunun en uygun model olduğu belirlenmiştir. Farklı regresyon modellerinin etkili bir şekilde kullanılabileceği ve uzman görüşlerinin bu süreçte kritik bir rol oynadığı görülmüştür.

Kuvvet regresyon modelinin 15 ağaç için uygulanmasıyla elde edilen hata ve yaklaşım değerleri aşağıda verilmiştir.

$$\begin{aligned} 0.9623 &\leq \text{RSQUARE} \leq 0.9948 \\ 0.4535 &\leq \text{MAE} \leq 2.5498 \\ 1.2839 &\leq \text{MAPE} \leq 6.2976 \\ 0.55 &\leq \text{RMSE} \leq 2.9655 \end{aligned}$$

Bu sonuçlar, modelin veri setine uyum sağladığı ayrıca verim değerlerini tahmin etmede de güvenilir olduğunu göstermektedir.

Sonuç olarak, bu çalışma, farklı regresyon modellerinin kullanılmasıyla ağaç gövde çapı artışını tahmin etme konusunda kuvvetli bir yöntem sunmaktadır. Uzman görüşleriyle bütünleşmiş regresyon modelleri, ağaç büyümesi stratejileri için değerli bilgiler sağlayabilir. Gelecekteki çalışmalarda daha geniş veri setleri ve uzun vadeli ölçümlerle model performansının daha fazla doğrulanmasını sağlayacaktır.

Tablo 1. Ağaç gövde çapı-Yıl ilişkisinin belirlenmesinde kullanılan regresyon modelleri ile hata ve yaklaşım değerleri (Regression models and error and approximation values used in determining the tree trunk diameter-year relationship)

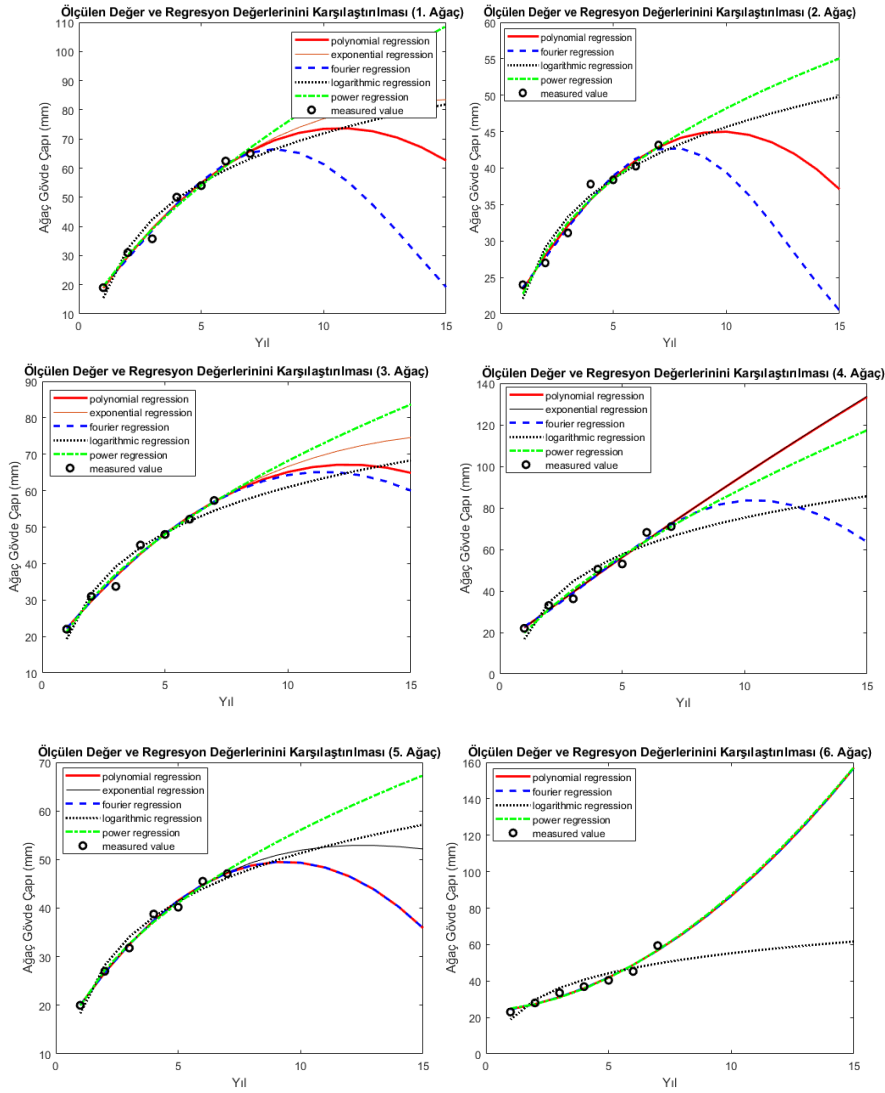
Ağaç No	Regresyon Modeli	R <sup>2</sup>	MAE	MAPE	RMSE
1	$f(x) = ax^2 + bx + c$	0.9868	1.5050	3.5305	1.8290
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9862	1.5318	3.5659	1.8638
	$f(x) = a \ln(x) + b$	0.9589	2.5755	7.5121	3.2215
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9879	1.4926	3.8016	1.7446
	$f(x) = ax^b$	0.9839	1.6346	3.7634	2.0170
2	$f(x) = ax^2 + bx + c$	0.9749	0.8792	2.6753	1.0579
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9722	0.8560	2.3486	1.1143
	$f(x) = a \ln(x) + b$	0.9453	1.3322	4.3926	1.5636
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9765	0.8736	2.5090	1.0239
	$f(x) = ax^b$	0.9663	1.0160	3.2826	1.2270
3	$f(x) = ax^2 + bx + c$	0.9834	1.1291	2.9987	1.5148
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9834	1.0978	2.9187	1.5166
	$f(x) = a \ln(x) + b$	0.9520	1.9099	5.6285	2.5773
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9834	1.1493	3.0527	1.5145
	$f(x) = ax^b$	0.9818	1.1340	3.1757	1.5874
4	$f(x) = ax^2 + bx + c$	0.9759	2.3853	5.0768	2.6271
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9759	2.3868	5.0806	2.6272
	$f(x) = a \ln(x) + b$	0.9090	4.5606	11.2386	5.1088
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9766	2.3904	5.3560	2.5880
	$f(x) = ax^b$	0.9693	2.5498	6.2976	2.9655
5	$f(x) = ax^2 + bx + c$	0.9920	0.6552	1.7531	0.8216
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9920	0.6618	1.7325	0.8235
	$f(x) = a \ln(x) + b$	0.9757	1.3420	4.2757	1.4344
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9920	0.6552	1.7531	0.8216
	$f(x) = ax^b$	0.9907	0.7532	1.9638	0.8904

Tablo 1. (Devam) Ağaç gövde çapı-Yıl ilişkisinin belirlenmesinde kullanılan regresyon modelleri ile hata ve yaklaşım değerleri  
(Regression models and error and approximation values used in determining the tree trunk diameter-year relationship)

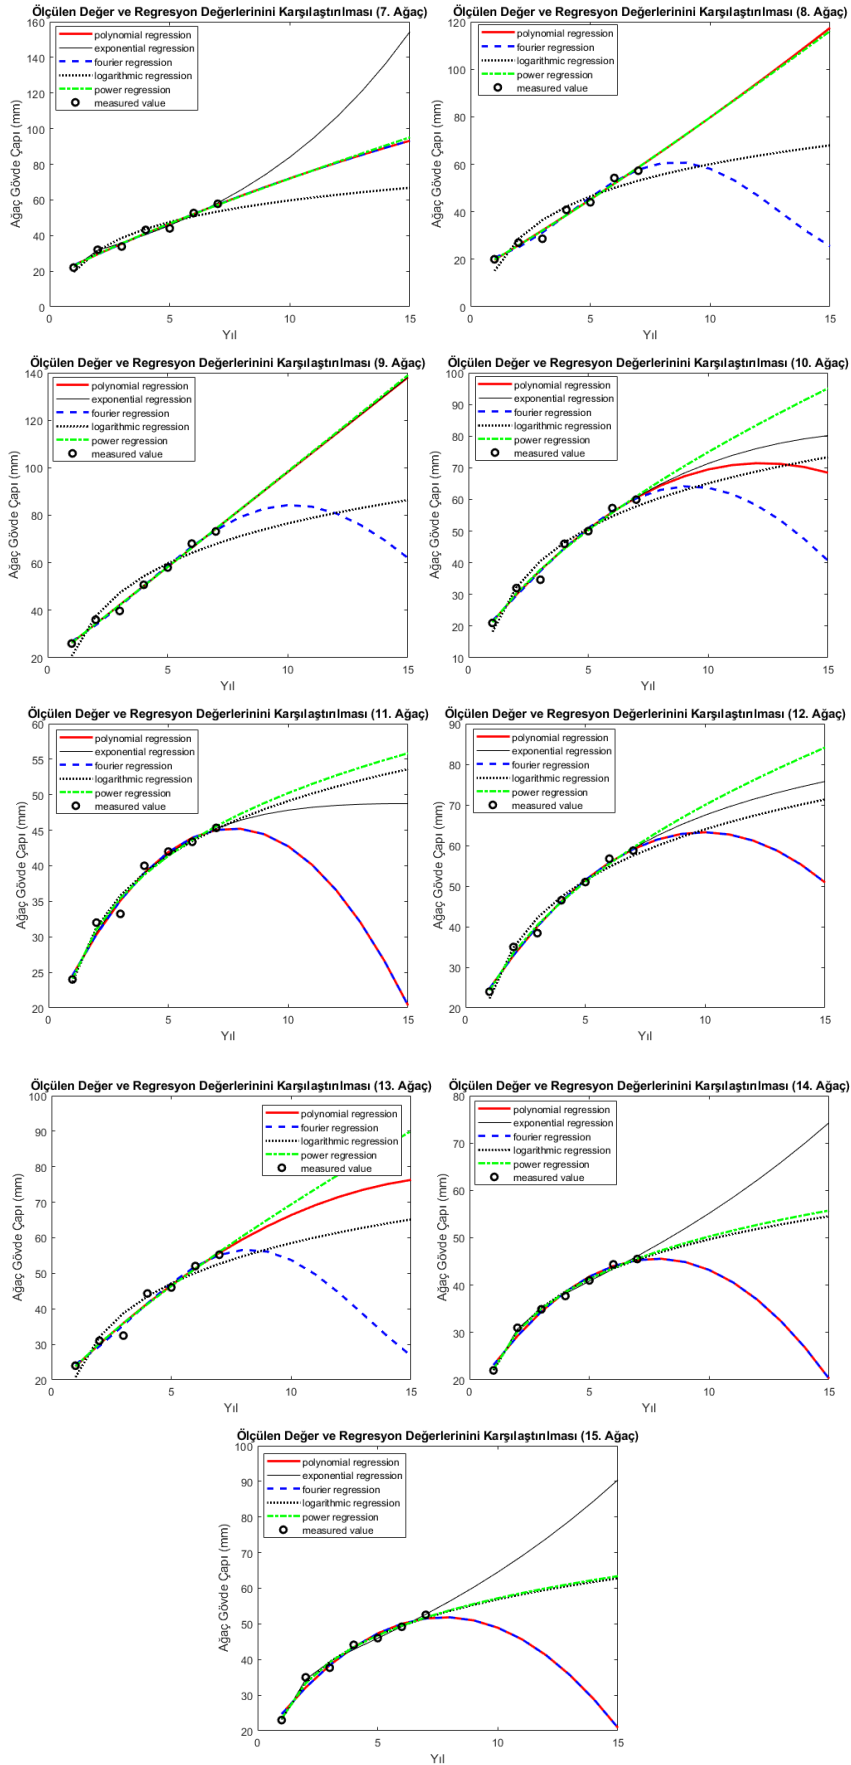
Ağaç No	Regresyon Modeli	R <sup>2</sup>	MAE	MAPE	RMSE
6	$f(x) = ax^2 + bx + c$	0.9641	1.8799	4.9186	2.1073
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9908	0.8030	2.6053	1.0636
	$f(x) = a \ln(x) + b$	0.8171	4.0161	10.4852	4.7533
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9641	1.8799	4.9186	2.1073
	$f(x) = ax^b$	0.9623	1.9584	5.2739	2.1594
7	$f(x) = ax^2 + bx + c$	0.9754	1.5918	4.4650	1.8019
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9831	1.1743	2.8240	1.4934
	$f(x) = a \ln(x) + b$	0.9292	2.5823	6.7785	3.0575
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9754	1.5918	4.4650	1.8019
	$f(x) = ax^b$	0.9763	1.5735	4.2983	1.7694
8	$f(x) = ax^2 + bx + c$	0.9770	1.7290	4.7035	1.9932
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9825	1.4424	4.3296	1.7357
	$f(x) = a \ln(x) + b$	0.8904	3.8027	11.7342	4.3471
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9809	1.6444	4.7697	1.8134
	$f(x) = ax^b$	0.9772	1.7121	4.5910	1.9810
9	$f(x) = ax^2 + bx + c$	0.9921	1.1635	2.5264	1.4314
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9921	1.1636	2.5265	1.4314
	$f(x) = a \ln(x) + b$	0.9181	4.1420	9.5639	4.5983
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9930	1.1672	2.7638	1.3437
	$f(x) = ax^b$	0.9921	1.1782	2.5679	1.4308
10	$f(x) = ax^2 + bx + c$	0.9853	1.3605	3.5613	1.6045
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9851	1.3678	3.5529	1.6145
	$f(x) = a \ln(x) + b$	0.9547	2.1610	6.0508	2.8143
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9856	1.3672	3.7119	1.5870
	$f(x) = ax^b$	0.9846	1.3542	3.3932	1.6418
11	$f(x) = ax^2 + bx + c$	0.9767	0.8717	2.5753	1.0819
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9775	0.8063	2.3562	1.0631
	$f(x) = a \ln(x) + b$	0.9757	0.7693	2.2292	1.1066
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9767	0.8716	2.5748	1.0817
	$f(x) = ax^b$	0.9775	0.8044	2.2534	1.0637
12	$f(x) = ax^2 + bx + c$	0.9904	0.9393	2.4680	1.1399
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9905	0.9351	2.3809	1.1348
	$f(x) = a \ln(x) + b$	0.9750	1.4555	3.6824	1.8390
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9904	0.9393	2.4680	1.1399
	$f(x) = ax^b$	0.9909	0.8931	2.1604	1.1078
13	$f(x) = ax^2 + bx + c$	0.9728	1.3347	3.5562	1.7871
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9746	1.3311	3.6253	1.7254
	$f(x) = a \ln(x) + b$	0.9224	2.4450	7.0368	3.0182
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9751	1.2826	3.5166	1.7083
	$f(x) = ax^b$	0.9717	1.3491	3.5306	1.8228

Tablo 1. (Devam) Ağaç gövde çapı-Yıl ilişkisinin belirlenmesinde kullanılan regresyon modelleri ile hata ve yaklaşım değerleri  
(Regression models and error and approximation values used in determining the tree trunk diameter-year relationship)

Ağaç No	Regresyon Modeli	R <sup>2</sup>	MAE	MAPE	RMSE
14	$f(x) = ax^2 + bx + c$	0.9849	0.8038	2.5344	0.9371
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9959	0.3976	0.9976	0.4899
	$f(x) = a \ln(x) + b$	0.9943	0.4681	1.2420	0.5747
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9849	0.8038	2.5344	0.9371
	$f(x) = ax^b$	0.9948	0.4535	1.2839	0.5500
15	$f(x) = ax^2 + bx + c$	0.9744	1.2980	3.6251	1.4877
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9919	0.5555	1.4136	0.8384
	$f(x) = a \ln(x) + b$	0.9884	0.8576	2.1972	1.0006
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9744	1.2980	3.6251	1.4877
	$f(x) = ax^b$	0.9885	0.8705	2.2674	0.9973



Şekil 2. Çalışmada kullanılan 15 ağaçta yıllar bazında ölçülen ağaç gövde çapı değerlerinin regresyon modelleriyle karşılaştırılması  
(Comparison of tree trunk diameter values measured on a yearly basis in the 15 trees used in the study with regression models)




Şekil 2. (Devam) Çalışmada kullanılan 15 ağaçta yıllar bazında ölçülen ağaç gövde çapı değerlerinin regresyon modelleriyle karşılaştırılması  
(Comparison of tree trunk diameter values measured on a yearly basis in the 15 trees used in the study with regression models)

### 3.2. Ağaç gövde çapı-verim ilişkisi (Tree trunk diameter-yield relationship)

Bu çalışmanın sonuçları, ağaç gövde çapı ile verim arasındaki ilişkiyi anlamak ve gelecekteki verim değerlerini tahmin etmek için etkili bir model geliştirmek adına önemli bilgiler sunmaktadır. Fourier regresyon modeli, ağaç verim değerlerindeki periyodik desenleri başarıyla tanımlayarak (Şekil 3-A, 3-B), Rsquare değeri 0.9890 ve rmse değeri 7.9125 ile oldukça yüksek bir doğruluk sağlamıştır. Bu sonuçlar, modelin gözlemlenen veri setine iyi uymakla birlikte verim değerlerini tahmin etmede de güvenilir olduğunu göstermektedir.

Araştırmanın temel bulgularından biri, Fourier regresyonunun ağaçların verimini etkileyen karmaşık faktörleri periyodik değişimlerle birleştirebilme yeteneğidir. Bu, ağaç verimini etkileyen genotip ve çevresel faktörlerin karmaşıklığını anlama ve modelleme açısından önemli olabilmektedir. Bu regresyon modeli, ağaçların gövde çapı ile verim arasındaki ilişkiyi daha iyi anlamak ve bu ilişkiyi gelecekteki verim tahminleri için kullanmak isteyen araştırmacılara güçlü bir araç sağlamaktadır.

Sonuçlar, elde edilen ağaç gövde çapı-verim regresyon modelinin genotip ve çevresel faktörlere bağlı olarak ağaç verimini tahmin etme konusunda güçlü bir araç olduğunu göstermektedir. Bu, tarım endüstrisinde, verim artışını planlamak ve yönetmek adına önemli bir bilgi kaynağı olabilir.



Şekil 3. (a) Ağaç gövde çapı-verim regresyon fonksiyonu (b) Ağaç gövde çapı-verim-yıl ilişkisi  
(a) Tree trunk diameter-yield regression function (b) Tree trunk diameter-yield-year relationship)

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

- [1] T. Ayoub Shaikh, T. Rasool, and F. Rasheed Lone, "Towards leveraging the role of machine learning and artificial intelligence in precision agriculture and smart farming," *Comput. Electron. Agric.*, vol. 198, p. 107119, Jul. 2022, doi: 10.1016/J.COMPAG.2022.107119.
- [2] M. Pathan, N. Patel, H. Yagnik, and M. Shah, "Artificial cognition for applications in smart agriculture: A comprehensive review," *Artif. Intell. Agric.*, vol. 4, pp. 81–95, Jan. 2020, doi: 10.1016/J.AIIA.2020.06.001.
- [3] K. G. Liakos, P. Busato, D. Moshou, S. Pearson, and D. Bochtis, "Machine Learning in Agriculture: A Review," *Sensors 2018*, Vol. 18, Page 2674, vol. 18, no. 8, p. 2674, Aug. 2018, doi: 10.3390/S18082674.
- [4] T. U. Rehman, M. S. Mahmud, Y. K. Chang, J. Jin, and J. Shin, "Current and future applications of statistical machine learning algorithms for agricultural machine vision systems," *Comput. Electron. Agric.*, vol. 156, pp. 585–605, Jan. 2019, doi: 10.1016/J.COMPAG.2018.12.006.
- [5] I. Keramatlou, M. Sharifani, H. Sabouri, M. Alizadeh, and B. Kamkar, "A simple linear model for leaf area estimation in Persian walnut (*Juglans regia* L.)," *Sci. Hortic. (Amsterdam)*, vol. 184, pp. 36–39, Mar. 2015, doi: 10.1016/j.scienta.2014.12.017.
- [6] P. Freund, R. J. and Wilson, W. J., Sa, *Regression analysis: Statistical Modeling of a response variable* (2nd ed). California, USA, Elsevier.
- [7] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Comput. Electron. Agric.*, vol. 147, pp. 70–90, Apr.



2018, doi: 10.1016/J.COMPAG.2018.02.016.

[8] S. Chen et al., "Rapid estimation of leaf nitrogen content in apple-trees based on canopy hyperspectral reflectance using multivariate methods," *Infrared Phys. Technol.*, vol. 111, p. 103542, Dec. 2020, doi: 10.1016/J.INFRARED.2020.103542.

[9] J. K. Basak et al., "Regression Analysis to Estimate Morphology Parameters of Pepper Plant in a Controlled Greenhouse System," *J. Biosyst. Eng.*, vol. 44, no. 2, pp. 57–68, Jun. 2019, doi: 10.1007/S42853-019-00014-0/FIGURES/11.

[10] I. Boldina and P. G. Beninger, "Strengthening statistical usage in marine ecology: linear regression," *J. Exp. Mar. Bio. Ecol.*, vol. 474, pp. 81–91, Jan. 2016, doi: 10.1016/j.jembe.2015.09.010.

[11] V. Strijov and G. W. Weber, "Nonlinear regression model generation using hyperparameter optimization," *Comput. Math. with Appl.*, vol. 60, no. 4, pp. 981–988, Aug. 2010, doi: 10.1016/J.CAMWA.2010.03.021.

[12] N. Panigrahi and B. S. Das, "Evaluation of regression algorithms for estimating leaf area index and canopy water content from water stressed rice canopy reflectance," *Inf. Process. Agric.*, vol. 8, no. 2, pp. 284–298, 2021, doi: 10.1016/j.inpa.2020.06.002.

[13] X. Ye, S. Abe, and S. Zhang, "Estimation and mapping of nitrogen content in apple trees at leaf and canopy levels using hyperspectral imaging," *Precis. Agric.*, vol. 21, no. 1, pp. 198–225, Feb. 2020, doi: 10.1007/S11119-019-09661-X/FIGURES/15.

[14] H. Armağan, "Color Based Segmentation with k-Means Clustering Algorithm and Numerical Analysis of the Effect of Color Spaces on Image Quantities.," *El-Cezeri*, vol. 9, no. 4, pp. 1506–1517, Dec. 2022, doi: 10.31202/ECJSE.1141148.

[15] H. Armağan, E. Atay, X. Crété, P.-E. Lauri, M. Ersoy, and O. Oral, "Deep Learning-Based Prediction Model of Fruit Growth Dynamics in Apple," *In Smart Applications with Advanced Machine Learning and Human-Centred Problem Design*, Cham: Springer International Publishing, 2023, pp. 367–373.

[16] M. Altalak, M. A. Uddin, A. Alajmi, and A. Rizg, "Smart Agriculture Applications Using Deep Learning Technologies: A Survey," *Appl. Sci.*, vol. 12, no. 12, Jun. 2022, doi: 10.3390/app12125919.

[17] J. G. A. Barbedo, "Detection of nutrition deficiencies in plants using proximal images and machine learning: A review," *Comput. Electron. Agric.*, vol. 162, pp. 482–492, Jul. 2019, doi: 10.1016/J.COMPAG.2019.04.035.

[18] M. S. Suchithra and M. L. Pai, "Improving the prediction accuracy of soil nutrient classification by optimizing extreme learning machine parameters," *Inf. Process. Agric.*, vol. 7, no. 1, pp. 72–82, Mar. 2020, doi: 10.1016/J.INPA.2019.05.003.

[19] E. Atay, X. Crété, D. Loubet, and P. E. Lauri, "Diurnal and Seasonal Growth Responses of Apple Trees to Water-Deficit Stress," *Erwerbs-Obstbau*, vol. 65, pp. 1–6, 2022, doi: 10.1007/s10341-022-00689-4.

[20] S. Huang, X. Fan, L. Sun, Y. Shen, and X. Suo, "Research on Classification Method of Maize Seed Defect Based on Machine Vision," *J. Sensors*, vol. 2019, 2019, doi: 10.1155/2019/2716975.

[21] "TÜİK,2023." [Online]. Available: <https://data.tuik.gov.tr/Kategori/GetKategori?p=Tarim-111> [Accessed Nov. 26, 2023].

[22] "FAOSTAT." [Online]. Available: <https://www.fao.org/faostat/en/#data> [Accessed Nov. 26, 2023].

[23] E. Atay, B. Hucbourg, A. Drevet, and P. É. Lauri, "Effects of preharvest deficit irrigation treatments in combination with reduced nitrogen fertilization on orchard performance of nectarine with emphasis on postharvest diseases and pruning weights," *Acta Sci. Pol. Hortorum Cultus*, vol. 18, no. 1, pp. 207–217, 2019, doi: 10.24326/asphc.2019.1.21.

[24] E. Atay and F. Koyuncu, "Branch induction via prolepsis in apple nursery trees," *Acta Hort.*, vol. 1139, pp. 439–444, 2016, doi: 10.17660/ActaHortic.2016.1139.76.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## Using Artificial Intelligence Methods in Detecting Deformed Highway Lines Using Unmanned Aerial Vehicles

Bekir Aksoy<sup>a</sup>, Muzaffer Eylence<sup>b</sup>, Asım Sinan Yüksel<sup>c</sup>, Seyit Ahmet İnan<sup>d</sup>

Submitted: 19.11.2023 Revised: 15.12.2023 Accepted: 15.12.2023 doi:10.30855/ gmbd.0705S20

### ABSTRACT

**Keywords:** Deep Learning, Unmanned Aerial Vehicle, Image Processing

<sup>a</sup> Isparta Uygulamalı Bilimler Üniversitesi,  
Teknoloji Fakültesi,  
Mekatronik Mühendisliği  
32200 - ISPARTA, Türkiye  
Orcid: 0000-0001-8052-9411  
e mail: [bekiraksoy@isparta.edu.tr](mailto:bekiraksoy@isparta.edu.tr)

<sup>b</sup> Isparta Uygulamalı Bilimler Üniversitesi,  
Teknoloji Fakültesi,  
Mekatronik Mühendisliği  
32200 - ISPARTA, Türkiye  
Orcid: 0000-0001-7299-8525

<sup>c</sup> Süleyman Demirel Üniversitesi,  
Mühendislik Fakültesi,  
Bilgisayar Mühendisliği  
32200 - ISPARTA, Türkiye  
Orcid: 0000-0003-1986-5269

<sup>d</sup> Süleyman Demirel Üniversitesi,  
Rektörlük  
32200 - ISPARTA, Türkiye  
Orcid: 0000-0002-9489-7714

\*Corresponding author:  
[bekiraksoy@isparta.edu.tr](mailto:bekiraksoy@isparta.edu.tr)

**Anahtar Kelimeler:** Derin Öğrenme, İnsansız Hava Aracı, Görüntü İşleme

With the rapid advancement of technology, the use of artificial intelligence (AI) is increasing in various sectors such as education, health, security and defense. A critical application of AI is highway management, especially with the rise of autonomous vehicles. The focus of this study is to address the problem of deformations in highway marking lines that pose challenges for autonomous vehicles and affect traffic safety. The research involves using unmanned aerial vehicle (UAV) to create an original image dataset of highway lines. This data set will be processed with image enhancement techniques and deep learning models. The first stage involves cleaning the images from foreign matter. Deep learning models will then identify potential line deformations. These models will be developed and trained for optimum accuracy using various performance metrics. In the study, the mobilenet v3 model, trained with the images in the data set, reached an accuracy rate of 89.58%, the resnet50 v2 model 77.78% and the Convolutional Neural Network model 92.55%. The ultimate goal is to implement a real-time system to accurately detect and report differences in highway lines by combining the UAV with the computer system on the ground. This will ensure timely notification to authorities and help prevent traffic safety problems related to line deformations. This approach demonstrates the practical applications of artificial intelligence in improving road safety and autonomous vehicle navigation.

## İnsansız Hava Araçları Kullanılarak Deforme Olmuş Karayolu Çizgilerinin Tespitinde Yapay Zekâ Yöntemlerinin Kullanılması

### ÖZ

Teknolojinin hızla ilerlemesiyle birlikte yapay zekanın (YZ) eğitim, sağlık, güvenlik ve savunma gibi çeşitli sektörlerde kullanımı giderek artıyor. Yapay zekanın kritik bir uygulaması, özellikle otonom araçların yükselişiyle birlikte otoyol yönetimidir. Bu çalışmanın odak noktası, otonom araçlar için zorluklar oluşturan ve trafik güvenliğini etkileyen otoyol işaretleme çizgilerindeki deformasyonlar sorununu ele almaktır. Araştırma, otoyol hatlarının orijinal bir görüntü veri kümesini oluşturmak için insansız hava aracının (İHA) kullanılmasını içeriyor. Bu veri seti, görüntü iyileştirme teknikleri ve derin öğrenme modelleriyle işlenecektir. İlk aşama, görüntülerin yabancı maddelerden temizlenmesini içerir. Daha sonra derin öğrenme modelleri potansiyel hat deformasyonlarını belirleyecektir. Bu modeller, çeşitli performans ölçümleri kullanılarak optimum doğruluk için geliştirilecek ve eğitilmiştir. Yapılan çalışmada veri setindeki görüntüler ile eğitimi gerçekleştirilen MobileNet v3 modeli %89,58, Resnet50 v2 modeli %77,78 ve Evrişimsel Sinir Ağı modeli ise %92,55 doğruluk oranına ulaşılmıştır. Nihai hedef, İHA'yı yerdeki bilgisayar sistemiyle birleştirerek otoyol hatlarındaki farklılıkları doğru bir şekilde tespit etmek ve raporlamak için gerçek zamanlı bir sistem uygulamaktır. Bu, yetkililere zamanında bildirim yapılmasını sağlayacak ve hat deformasyonlarıyla ilgili trafik güvenliği sorunlarının önlenmesine yardımcı olacaktır. Bu yaklaşım, yapay zekanın yol güvenliğini ve otonom araç navigasyonunu iyileştirmedeki pratik uygulamalarını gösteriyor.

## 1. Giriş (Introduction)

Otonom araçlar, insan müdahalesine ihtiyaç duymadan hareket edebilen, gelişmiş sensörler, yapay zeka ve robotik sistemler ile donatılmış araçlardır. Otonom araç teknolojisinin temelleri, 1980'lerde başlamış ve özellikle DARPA (Defense Advanced Research Projects Agency) tarafından desteklenen yarışmalar aracılığıyla geliştirilmiştir. Carnegie Mellon Üniversitesi'nde geliştirilen ALVINN sistemi, yapay sinir ağlarını kullanarak temel düzeyde otonom sürüş yeteneklerini sergilemiştir [1]. 2004 ve 2005 yıllarında gerçekleştirilen DARPA Grand Challenge, otonom araç teknolojisinin gelişiminde de önemli bir rol oynamıştır. Bu yarışmalar sırasında, Stanford ve Carnegie Mellon üniversiteleri tarafından geliştirilen Stanley ve Boss araçları, çöl ortamında belirlenen rotaları başarıyla tamamlamıştır [2]. 2009'da başlayan Google'ın Otonom Araç Projesi (günümüzdeki adıyla Waymo), bu teknolojiyi daha geniş çapta tanıtmış ve alanın öncü şirketlerinden biri haline getirmiştir [3]. Sensör ve yapay zeka teknolojilerindeki ilerlemeler, lidar, radar ve kamera destekli otonom araçların daha güvenli ve verimli çalışmasını sağlamıştır. Gelecekte, otonom araçların yaygınlaşması için yasal ve düzenlemelerin oluşturulması, güvenlik standartlarının oluşturularak toplumda daha geniş bir çerçevede kullanılması hedeflenmektedir [4].

Otonom araçlardaki teknolojik ilerlemelerin yanı sıra, İnsansız Hava Araçları (İHA) sistemleri ile birçok alanda yaygın olarak kullanılacağı düşünülmektedir. Ticari ve özel kullanımlar, İHA'ların mahremiyet, kabul ve güvenlik özelliklerinden ziyade diğer hava sahası kullanıcılarıyla etkileşimi içermektedir. Kentsel hava hareketliliği alanındaki çalışmalar, İHA'ların yeni bir ulaşım aracı olarak kullanılmasına olan talebide arttırmaktadır [5]. Son yıllarda, küçük İHA'larda, tasarım, çalışma metodolojileri, uçuş özellikleri ve navigasyon kontrolünde önemli gelişmeler kaydedilmiştir. İHA'lar fotoğrafçılık, rotalama, arama-kurtarma operasyonları, güç hatları ve sivil yapıların denetimi gibi alanlarda yaygın olarak kullanılması ile yeteneklerini ve verimliliklerini artırmıştır [6]. Son yıllarda İHA sistemleri mikroişlemci teknolojisindeki gelişmeler ile birlikte sıklıkla akıllı otonom kontrol sistemlerinde kullanılmaya başlanmıştır [7]. İHA'larda akıllı otonom sistemlerin kullanılmaya başlanması ile birlikte İHA'ların gövdesine monte edilen kamera veya sensörler vasıtasıyla elde edilen veriler toplanarak yapay zeka teknolojileri ile analiz edilip anlamlı sonuçlar çıkartılarak toplum hayatına önemli katkılar sağlamıştır.

Yapay Zeka (YZ), insan benzeri zeka gösteren makineleri, özellikle bilgisayar sistemlerini tasarlamak ve geliştirmek için kullanılan bilim ve mühendislik alanıdır [8]. Bu alandaki gelişmeler, özellikle makine öğrenimi ve derin öğrenme alanlarında, son yıllarda önemli bir ivme kazanmıştır. Yapay Zeka, veri analizi, desen tanıma ve öğrenme süreçlerini içermekte ve bu süreçler, doğal dil işleme, robotik ve algılama gibi birçok alanda uygulanmaktadır [9]. Derin öğrenme, yapay sinir ağlarına dayalı bir öğrenme yöntemi olup YZ'nin gelişiminde büyük bir dönüm noktası olmuştur [10]. YZ'nin önemli bileşenlerinden olan makine öğrenimi, algoritmaların veri setleri üzerinde eğitilerek, veri analizi ve tahmin yapabilme yeteneklerini geliştirme süreci olarak tanımlamak mümkündür. Breiman ve diğerleri tarafından geliştirilen rastgele ormanlar ve boosting gibi makine öğrenme yöntemleri, sınıflandırma ve regresyon problemlerinin çözümünde yaygın olarak kullanılmaktadır [11]. Makine öğreniminin alt bileşeni olan derin öğrenme ise çok katmanlı yapay sinir ağlarını kullanarak daha karmaşık öğrenme problemlerinin çözümünde kullanılmaktadır. Derin öğrenme, görüntü, ses tanıma, doğal dil işleme gibi karmaşık görevlerde sıklıkla kullanılmaktadır.

Gerçekleştirilen çalışma ile ilgili akademik çalışmalar incelendiğinde Na ve diğerleri çalışmalarında Görüntü İşleme ve Derin Öğrenme ile Demiryolu Aracının Pantograf Kontak Şeridi Üzerindeki Deformasyonun tahmininde %94 doğruluk oranı ile başarı elde etmişlerdir [12]. Bir diğer çalışmada ise karmaşık yol koşullarında yol sürüş videosu ve Tusimple veri seti kullanılarak şerit tespit algoritması için simülasyon test deneyleri yapmışlardır. Deneysel sonuçlar, yolda sürüş videosuna dayalı ortalama tespit doğruluğunun %98,49'a, ortalama işlem süresinin ise 21,5 ms'ye ulaştığını tespit etmişler, Tusimple veri setinde ise ortalama tespit doğruluğu %98,42'ye, ortalama işlem süresi ise 22,2 ms'ye olarak elde etmişlerdir [13]. Liu ve diğerleri çalışmalarında düşük ışık koşullarında görüntüler oluşturarak üretken rekabetçi ağları kullanan ve şerit dedektörünün çevresel uyarlanabilirliğini artıran, stil aktarımına dayalı bir veri geliştirme yöntemi önermişlerdir. Yöntem SIM-CycleGAN, ışık koşulları aktarımı ve şerit algılama ağı olmak üzere üç bölümden oluşmaktadır [14]. Punagin ve Punagin yapmış oldukları çalışmada OpenCV kullanılarak yapılandırılmış yollarda şerit tespit tekniklerinin analizi gerçekleştirmede Udacity'den almış oldukları görüntüler üzerinde görüntü ön işleme sırasında Laplacian, Sobel ve Canny kenar tespit yöntemleri gibi farklı kenar tespit yöntemleri incelemişlerdir. İnceleme sonucunda Canny kenar tespitinin diğerlerine göre daha başarılı olduğunu ifade etmişlerdir [15]. Bir diğer çalışmada ise Joy ve diğerleri bilgisayarlı görme tekniklerini kullanarak gerçek zamanlı yol şeridi tespitini gerçekleştirmişlerdir. Çalışmada RGB görüntüsü gri tonlamaya

dönüştürüldükten sonra gürültü giderme işlemini gerçekleştirmek için Gaussian filtreleme yöntemini kullanmışlardır. Canny Kenar Dedektörü vasıtasıyla da yoğunlukta önemli değişiklikler olan kenarları algılamışlardır [16]. Chng ve diğerleri yapmış oldukları çalışmada RONELD: aktif şerit tespiti için güçlü sinir ağı çıkışı geliştirmişlerdir. Çalışmalarında derin öğrenme olasılık haritası çıktılarında aktif şeritleri tanımlamak, izlemek ve optimize etmek için aktif şerit algılama (RONELD) yöntemine yönelik gerçek zamanlı, sağlam bir sinir ağı çıktı geliştirmesi sunmuşlardır [17]. Bibi ve diğerleri yapmış oldukları çalışmada derin öğrenme yöntemleri kullanarak VANET'teki Yol Anormalliklerinin Edge Yapay Zeka Tabanlı Otomatik Tespiti ve Sınıflandırılması işlemlerini gerçekleştirmişlerdir. Çalışmalarında Otonom araçlar tarafından yol anormalliklerinin otomatik olarak algılanması ve Edge AI ve VANET'e dayalı olarak gelecek araçlara yol bilgisi sağlanması için yeni bir sistem önermişlerdir [18]. Luo ve diğerleri çalışmalarında derin öğrenme yaklaşımlarıyla yol anomalisi tespit etmişlerdir. Çalışmalarında geleneksel yol anormalliklerinin yanı sıra, araç perspektifinden ek anomaliler de eklemişlerdir. Veri setini Derin Beslemeli Ağ, Evrişimli Sinir Ağı ve Tekrarlayan Sinir Ağı ile sınıflandırma problemini çözmüşlerdir [19].


Gerçekleştirilen çalışmada, otonom uçuş gerçekleştirebilen İHA'nın gövdesinde yer alan kamera vasıtasıyla karayolu çizgilerine ait özgün bir veri seti oluşturulmuştur. Oluşturulan veri seti bozulmuş, silinmiş ve renklendirilmiş görüntü olmak üzere etiketlenerek YZ eğitimi için hazırlanmıştır. Etiketlenen veri seti MobileNet v3, Resnet50 v2 ve Evrişimsel Sinir Ağı (ESA) derin öğrenme modelleri ile eğitilmiş ve en yüksek doğruluk sonucunu veren ESA modeli çalışmada kullanılmıştır.

## 2. Materyal ve Metot (Material and Method)

### 2.1. Materyal (Material)

#### 2.1.1. Verisetinin oluşturulması (Creating the dataset)

Gerçekleştirilen çalışmada, otonom araçların silinmiş veya hasar görmüş karayolu şeritlerini tespit etmelerine yardımcı olmak amacıyla, İHA kullanılarak veri seti oluşturulmuştur. Veri seti, silinmiş, bozulmuş veya yeniden renklendirilmiş karayolu şeritlerinden oluşmaktadır. İHA'nın, trafiğe kapalı yollarda farklı hava koşullarında, günün farklı saatlerinde ve farklı yüksekliklerden toplanan görüntülerle veri setinin çeşitliliği artırılarak toplam 437 adet görüntü elde edilmiştir Şekil 1'de çalışmada kullanılan görüntülere ait örnek bir görsel verilmiştir.



Şekil 1. Verisetinden örnek görüntüler  
(Sample images from the Dataset)

#### 2.1.2. MobileNet v3 (MobileNet v3)

MobileNet v3, Howard et al. tarafından 2019 yılında tanıtılan ve derin öğrenme ile bilgisayarlı gözü alanlarında kullanılan sinir ağı mimarisidir [20]. Bu mimari, özellikle mobil ve edge cihazları gibi kaynak kısıtlı ortamlar için tasarlanmıştır. MobileNet v3'ün temel amacı, az sayıda parametre ve düşük hesaplama gereksinimi ile yüksek verimlilik sağlamaktır [21]. MobileNet v3 mimarisinin en dikkat çekici özelliklerinden birisi de derinlik bazlı ayrılabilir konvolüsyonların kullanılmasıdır. Bu yaklaşım, modelin boyutunu ve hesaplama yükünü önemli ölçüde azaltmaktadır [22]. Ayrıca, MobileNet v3, Neural Architecture Search (NAS) teknolojisi kullanarak optimal ağ yapısını belirlemede ve bu sayede modelin verimliliğini ve performansını artırmaktadır [23].

MobileNet v3, H-Mish adı verilen yeni bir aktivasyon fonksiyonu kullanmaktadır. Bu fonksiyon, modelin doğruluk oranını artırırken hesaplama maliyetini düşürmektedir. Böylece kaynak kısıtlı cihazlarda önemli bir avantaj sağlamaktadır [24]. Mimarinin kullanıldığı başlıca uygulama alanları arasında görüntü sınıflandırma, nesne algılama ve yüz tanıma problemleri bulunmaktadır [25].

### 2.1.2. Resnet50 v2 (Resnet50 v2)

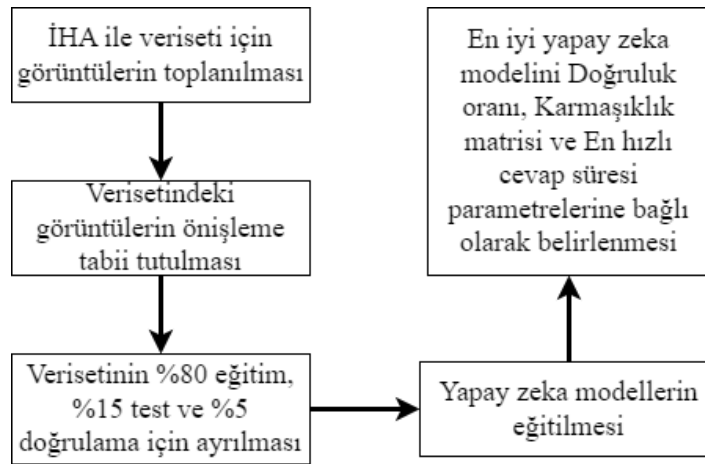
Bu ağ, Microsoft Research tarafından 2016 yılında tanıtıldı ve hızla görüntü işleme ve makine öğrenimi toplulukları arasında popülerlik kazandı [26]. ResNet50 v2'nin başarısı, özellikle görüntü tanıma ve sınıflandırma görevlerinde yüksek doğruluk oranlarına ulaşmasından kaynaklanmaktadır. Bu model, çeşitli görüntü sınıflandırma yarışmalarında ve gerçek dünya uygulamalarında etkili bir şekilde kullanılmıştır [27]. ResNet50 v2'nin temel özelliği, "kalıntı öğrenme" veya "artık öğrenme" olarak bilinen bir yaklaşım ile derin ağ katmanlarının etkin bir şekilde eğitilmesine imkân sağlamaktadır [28].

### 2.1.3. Evrişimsel sinir ağları (Convolutional neural networks)

ESA, derin öğrenme alanında yaygın olarak kullanılan, özellikle görsel veri işlemede etkili olan derin öğrenme modelidir. ESA, insan görsel korteksinin çalışma şekline esinlenerek geliştirilmiştir [10]. ESA'lar, çok katmanlı yapay sinir ağları olup evrişimsel katmanlar, havuzlama (pooling) katmanları ve tam bağlı (fully connected) katmanlarında oluşmaktadır [29]. Evrişimsel katmanlar, veri üzerinde yerel filtreler uygulayarak özellik haritaları oluşturur. Havuzlama katmanları ise bu özellik haritalarını küçültür, hesaplama yükünü azaltır ve ağırlık öğrenme kapasitesini artırır. Son olarak, tam bağlı katmanlar, sınıflandırma veya regresyon görevlerini gerçekleştirir. ESA'lar, görsel nesne tanıma, yüz tanıma, tıbbi görüntü analizi gibi birçok alanda başarıyla kullanılmaktadır [30]. Özellikle görüntü ve video analizi alanında, ESA'lar diğer yapay sinir ağlarına göre daha başarılı sonuçlar vermektedir. ESA'ların kullanımı, büyük veri setleri ve güçlü bilgisayar kaynakları gerektirir. Ağın eğitimi sırasında, büyük miktarda etiketlenmiş veri ile ağırlıklandırma iteratif olarak ayarlanır. Bu süreç, genellikle arka yayılım (backpropagation) algoritması ile gerçekleştirilir [31]. Ayrıca, ağırlık performansını artırmak için veri artırma (data augmentation) ve düzenleme (regularization) teknikleri gibi farklı yöntemler kullanılmaktadır [32].

## 2.2. Metot (Method)

Gerçekleştirilen çalışmanın iş akış diyagramı Şekil 2'de gösterilmiştir.



Şekil 2. İş akış diyagramı (Workflow diagram)

Çalışmada ilk olarak İHA kullanılarak, karayollarındaki bozulmuş veya silinmiş trafik şeritlerine ait toplam 437 adet görüntü toplanmıştır. Elde edilen görüntüler derin öğrenme modelleri ile uyumlu hale getirilmek üzere 512x512x3 piksel boyutlarına yeniden boyutlandırılmıştır. Yeniden boyutlandırılan görüntüler üzerinde, poligon etiketleme teknikleri kullanılarak etiketlenmiş ve sınıflandırılmıştır. Çalışmanın ikinci aşamasında veri seti, eğitim, doğrulama ve test olmak üzere %80, %15 ve %5'lik oranlarda bölünmüştür. Çalışmanın üçüncü aşamasında MobileNet v3, ResNet50 v2 ve özelleştirilmiş bir ESA tabanlı modeli kullanılarak eğitilmiştir. Eğitim esnasında 20 epoch ile eğitim gerçekleştirilmiştir. Her bir eğitim için

modellerin cevap süreleri saniye açısından ölçülmüştür. 20 epochdan sonra sonuçlar önemli bir değişim görülmediği için eğitim işlemi sonlandırılarak eğitim sonuçları ile doğrulama veri setindeki sonuçlar karşılaştırılarak aşırı öğrenmenin olmadığı tespit edilmiştir. Çalışmanın son aşamasında ise elde edilen sonuçlar grafik, tablo ve karmaşıklık matrisi olarak verilmiştir.


### 3. Bulgular ve Tartışma (Results and Discussion)

Yapılan çalışmada derin öğrenme modellerinin eğitim sonuçları tablo 1 de gösterilmiştir.

Tablo 1. Derin öğrenme modellerinin doğruluk sonuçları (Accuracy results of deep learning models)


Derin Öğrenme Modelleri	Doğruluk Değeri	Eğitim Süresi (saniye)
MobileNet v3	%89,58	763
Resnet50 v2	%77,78	795
ESA	%92,55	835

Tablo 1 incelendiğinde üç farklı derin öğrenme modelinden ESA modelinin diğer modellere göre daha yüksek bir doğruluk sonucu verdiği görülmektedir. Ayrıca tablo 1’de derin öğrenme modellerinin zamansal açıdan kıyaslandığında MobileNetv3 modelinin en başarılı model olduğu görülmektedir. Gerçekleştirilen çalışmada Şekil 3 ile Şekil 5 arasında verilen grafikler ile modellerinin doğruluk değerleri izlenmiştir.




Şekil 3. MobileNet v3 doğruluk grafiği (MobileNet v3 accuracy chart)

Şekil 3 incelendiğinde MobileNet v3 derin öğrenme modelinin eğitim sonucu oluşan doğruluk grafiği verilmiştir. Grafik incelendiğinde modelin doğruluk oranı %89,58 de kaldığını ve modelin bu değerden daha yüksek bir doğruluk değerine ulaşamadığı tespit edilmiştir.



Şekil 4. Resnet50 v2 doğruluk grafiği (Resnet50 v2 accuracy chart)

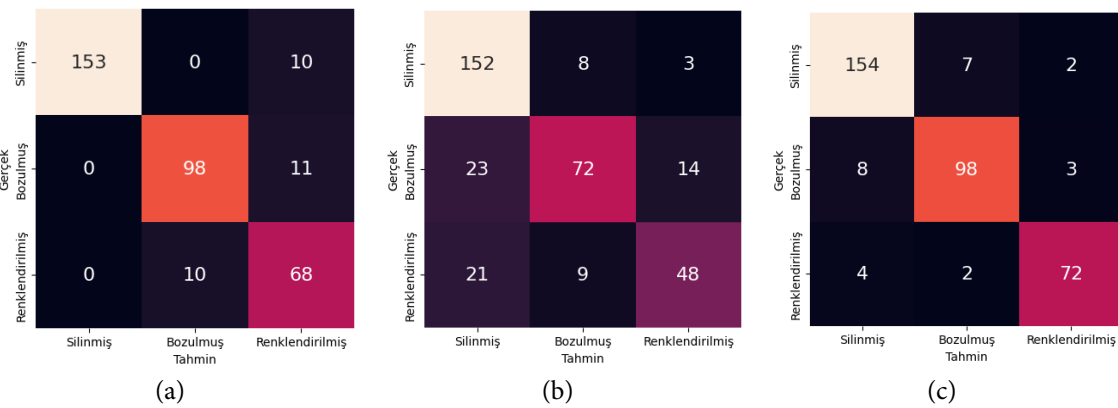
Şekil 4 incelendiğinde ResNet50 v2 derin öğrenme modelinin eğitim sonucu oluşan doğruluk grafiği verilmiştir. Grafik incelendiğinde modelin doğruluk oranı %77,78 de kaldığını ve modelin bu değerden daha yüksek bir doğruluk değerine ulaşamadığı tespit edilmiştir.



Şekil 5. ESA modelinin doğruluk grafiği (Accuracy graph of ESA model)

Şekil 5 incelendiğinde ESA yöntemine ait grafik incelendiğinde modelin doğruluk oranı %92,55 de kaldığını ve modelin bu değerden daha yüksek bir doğruluk değerine ulaşamadığı tespit edilmiştir.

Çalışmanın son aşamasında şekil 6 incelendiğinde MobileNet v3 modelinde silinmiş sınıfa ait olan 153 adet görüntü doğru sınıflandırılırken 10 adet görüntü renklendirilmiş sınıfa ait olarak sınıflandırılmıştır. Bozulmuş sınıfa ait olan 98 adet görüntü doğru sınıflandırılırken 11 adet görüntü ise renklendirilmiş sınıfa ait olarak sınıflandırılmıştır. Son olarak 68 adet renklendirilmiş sınıfa ait görüntü doğru sınıflandırılırken 10 adet görüntü ise bozulmuş sınıfa ait olarak sınıflandırılmıştır. Resnet50 v2 modelinde ise 152 adet silinmiş sınıfa ait görüntü doğru sınıflandırılırken, 8 adet görüntü bozulmuş, 3 adet görüntü ise renklendirilmiş sınıfa ait olarak yanlış sınıflandırılmıştır. 72 adet bozulmuş sınıfa ait görüntü doğru sınıflandırılırken 23 adet görüntü silinmiş sınıfa, 14 adet görüntü ise renklendirilmiş olarak yanlış sınıflandırılmıştır. Renklendirilmiş sınıfa ait 48 adet görüntü doğru sınıflandırılırken 21 adet görüntü silinmiş sınıfa, 9 adet görüntü ise bozulmuş sınıfa ait olarak yanlış sınıflandırılmıştır. ESA modeli ise 154 silinmiş sınıfa ait görüntü doğru sınıflandırılırken 7 adet görüntü bozulmuş sınıfa, 2 adet görüntü ise renklendirilmiş sınıfa ait olarak yanlış sınıflandırılmıştır. 98 adet bozulmuş sınıfa ait görüntü doğru sınıflandırılırken 8 adet görüntü silinmiş sınıfı, 3 adet görüntü ise renklendirilmiş sınıfa ait olarak yanlış sınıflandırılmıştır. 72 adet renklendirilmiş sınıfa ait görüntü doğru sınıflandırılırken 4 adet görüntü silinmiş sınıfa, 2 adet görüntü ise bozulmuş sınıfa ait olarak yanlış sınıflandırılmıştır.



Şekil 6. (a) MobileNet v3 (b) Resnet50 v2 (c) Kendi modelimizin karmaşıklık matrisi (confusion matrix of all models)

Gerçekleştirilen çalışma günümüzde karayollarındaki önemli problemlerden birisi olan deforme olmuş trafik

şerit çizgilerinin derin öğrenme yöntemleri ile tespiti gerçekleştirilmiştir. Derin öğrenme yöntemleri ile gerçekleştirilen eğitimlerde doğruluk ve zaman açısından kıyaslamalar gerçekleştirilmiştir. Kıyaslama sonunda doğruluk açısından ESA derin öğrenme mimarisi en başarılı mimari iken zamansal açıdan en başarılı yöntem MobileNet v3 olarak belirlenmiştir.

#### 4. Sonuçlar (Results)

Gelişen teknoloji sayesinde, insanların gerçekleştirdiği birçok işlemin makineler tarafından daha düşük hata oranları ile yerine getirilmesi, teknolojik ilerlemenin en önemli parametrelerinden birisidir. Özellikle otonom araçların yol güvenliğini riske atmadan güvenli bir sürüş deneyimi sunabilmesi, bu alandaki temel amaçlardan biridir. İHA'lar donatıldığı kamera ve sensörler sayesinde, dış ortam şartlarından bağımsız olarak potansiyel tehditleri öngörebilmeleri ve otonom sürüş yapabilen araçların sürüş güvenliğini daha güvenli bir hale getirmek için deforme olmuş trafik şeritlerini belirleme aşamasında önemli bir rol oynamıştır. Çalışmada, otonom sürüş yapan araçların trafik şeritlerini daha detaylı algılamalarını ve özellikle hatalı, bozuk veya silinmiş şerit işaretlerini daha dikkatli bir şekilde tespit etmelerini sağlamak amacıyla derin öğrenme mimarileri yeni bir yaklaşım sunulmuştur. Derin öğrenme mimarilerden ESA tabanlı mimarinin doğruluk açısından %90'nın üzerinde doğruluk oranı ile başarılı olduğu tespit edilmiştir. Bu doğruluk oranı ile karayollarındaki deforme olmuş karayolu çizgilerinin başarılı bir biçimde tespiti gerçekleştirilmiştir. Böylece çalışma kapsamında geliştirilen derin öğrenme mimarili yöntem ile otonom araçların trafikteki güvenliğini artırmak adına önemli bir adım atılmıştır. Bu sayede, otonom sürüş teknolojisinin karşılaştığı zorlukların üstesinden gelinmesine ve yol güvenliğinin artırılmasına yönelik somut gelişmeler kaydedilmiştir. Gelecek çalışmalarda geliştirilen derin öğrenme mimarili yöntemin İHA'lar kullanılarak gerçek zamanlı olarak tespiti hedeflenmektedir.

#### Teşekkür (Acknowledgment)

Çalışma 5. Uluslararası Mühendislikte Yapay Zeka ve Uygulamalı Matematik Konferansı'nda özet metin olarak sunulmuştur.

#### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

#### Kaynaklar (References)

- [1] S. Thrun, M. Montemerlo, H. Dahlkamp, D. Stavens, A. Aron, J. Diebel, P. Fong, J. Gale, M. Halpenny, G. Hoffmann, K. Lau, C. Oakley, M. Palatucci, V. Pratt, P. Stang, S. Strohband, C. Dupont, L. E. Jendrossek, C. Koelen, C. Markey, C. Rummel, J. van Niekerk, E. Jensen, P. Alessandrini, G. Bradski, B. Davies, S. Ettinger, A. Kaehler, A. Nefian and P. Mahoney, "Stanley: the robot that won the darpa grand challenge," *J. Field Robotics*, vol. 23, pp. 661-692, 2006. [doi:10.1002/rob.20147](https://doi.org/10.1002/rob.20147)
- [2] C. Urmson, J. Anhalt, D. Bagnell, C. Baker, R. Bittner, M. N. Clark, J. Dolan, D. Duggins, T. Galatali, C. Geyer, M. Gittleman, S. Harbaugh, M. Hebert, T. M. Howard, S. Kolski, A. Kelly, M. Likhachev, M. McNaughton, N. Miller, K. Peterson, B. Pilnick, R. Rajkumar, P. Rybski, B. Salesky, Y. W. Seo, S. Singh, J. Snider, A. Stentz, W. Whittaker, Z. Wolkowicki, J. Zigar, H. Bae, T. Brown, D. Demitriash, B. Litkouhi, J. Nickolaou, Va. Sadekar, W. Zhang, J. Struble, M. Taylor, M. Darms and D. Ferguson, "Autonomous driving in urban environments: boss and the urban challenge," *J. Field Robotics*, vol 25, pp. 425-466, 2008. [doi:10.1002/rob.20255](https://doi.org/10.1002/rob.20255)
- [3] Waymo, "Waymo's journey," <http://www.waymo.com>. [Online]. Available: <http://www.waymo.com> [Accessed September 2023].
- [4] D. J. Fagnant and K. Kockelman, "Preparing a nation for autonomous vehicles: opportunities, barriers and policy recommendations," *Transportation Research Part A: Policy and Practice*, vol. 77, pp. 167-181, 2015 [doi:10.1016/j.tra.2015.04.003](https://doi.org/10.1016/j.tra.2015.04.003).
- [5] R. Merkert and J. Bushell, "Managing the drone revolution: A systematic literature review into the current use of airborne drones and future strategic directions for their effective control," *Journal of air transport management*, vol. 89, pp. 101929, 2020. [doi:10.1016/j.jairtraman.2020.101929](https://doi.org/10.1016/j.jairtraman.2020.101929).
- [6] F. Ahmed, J. C. Mohanta, A. Keshari, and P. S. Yadav, "Recent advances in unmanned aerial vehicles: a review," *Arabian Journal for Science and Engineering*, vol. 47, pp. 7963-7984, 2022. [doi:10.1007/s13369-022-06738-0](https://doi.org/10.1007/s13369-022-06738-0)
- [7] G. Macrina, L. D. P. Pugliese, F. Guerriero and G. Laporte, "Drone-aided routing: a literature review," *Transportation Research Part C: Emerging Technologies*, vol. 120, pp. 102762, 2020. [doi:10.1016/j.trc.2020.102762](https://doi.org/10.1016/j.trc.2020.102762).
- [8] H. Wang, T. Fu, Y. Du, W. Gao, K. Huang, Z. Liu, P. Chandak, S. Liu, P. Van Katwyk, A. Deac, A. Anandkumar, K. Bergen, C. P. Gomes, S. Ho, P. Kohli, J. Lasenby, J. Leskovec, Y. Liu, A. Manrai, D. Marks, B. Ramsundar, L. Song, J. Sun, J. Tang, P. Veličković, M.



- Welling, L. Zhang, C. W. Coley, Y. Bengio and M. Zitnik, "Scientific discovery in the age of artificial intelligence," *Nature*, vol. 620, pp. 47-60, 2023. doi:10.1038/s41586-023-06221-2.
- [9] S. J. Russell and P. Norvig, "Artificial intelligence a modern approach," London: Pearson, 2021
- [10] Y. LeCun, Y. Bengio and G. Hinton. "Deep learning," *nature*, vol. 521, pp. 436-444, 2015. doi:10.1038/nature14539.
- [11] L. Breiman, "Random forests," *Machine learning*, vol. 45, pp. 5-32, 2001. doi:10.1023/A:1010933404324.
- [12] K. M. Na, K. Lee, S. K. Shin and H. Kim, "Detecting deformation on pantograph contact strip of railway vehicle on image processing and deep learning," *Applied Sciences*, vol. 10, pp. 8509, 2020. doi:10.3390/app10238509.
- [13] J. Cao, C. Song, S. Song, F. Xiao and S. Peng, "Lane detection algorithm for intelligent vehicles in complex road conditions and dynamic environments," *Sensors*, vol. 19, pp. 3166, 2019. doi:10.3390/s19143166.
- [14] T. Liu, Z. Chen, Y. Yang and H. Li "Lane detection in low-light conditions using an efficient data enhancement: Light conditions style transfer," *In 2020 IEEE intelligent vehicles symposium (IV)*, 2020, Las Vegas, NV, USA, 2020. pp. 1394-1399. IEEE. doi:10.1109/IV47402.2020.9304613.
- [15] A.Punagin and S.Punagin, "Analysis of lane detection techniques on structured roads using OpenCV," *International Journal for Research in Applied Science and Engineering Technology*, vol.8, pp. 2994-3003. doi:10.22214/ijraset.2020.5502.
- [16] S.Joy, B. S. Mamta, T. B. Mukesh, M. M. Ahmed, and U. Kiran, "Real time road lane detection using computer vision techniques in python," *In 2022 International Conference on Automation, Computing and Renewable Systems (ICACRS), December 2022, Pudukkottai, India*, 2022, pp. 1228-1232. doi: 10.1109/ICACRS55517.2022.10029238.
- [17] Z. M. Chng, J. M. H. Lew and J. A. Lee, "RONELD: Robust Neural Network Output Enhancement for Active Lane Detection," *25th International Conference on Pattern Recognition (ICPR), 2020, Milan, Italy*, 2021, pp. 6842-6849, doi: 10.1109/ICPR48806.2021.9412572.
- [18] R. Bibi, Y. Saeed, A. Zeb, T. M. Ghazal, T. Rahman, R. A. Said, S. Abbas, M. Ahmad and M. A. Khan, "Edge ai-based automated detection and classification of road anomalies in VANET using deep learning," *Computational intelligence and neuroscience*, 2021, pp. 1-16. doi:10.1155/2021/6262194.
- [19] D. Luo, J. Lu and G. Guo, "Road Anomaly Detection Through Deep Learning Approaches," *in IEEE Access*, vol. 8, pp. 117390-117404, 2020, doi: 10.1109/ACCESS.2020.3004590.
- [20] A. Howard, M. Sandler, G. Chu, L. C. Chen, B. Chen, M. Tan, W. Wang, Y. Zhu, R. Pang, V. Vasudevan, Q. V. Le and H. Adam; "CCNet: criss-cross attention for semantic segmentation," *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), Oct 27-Nov. 2, 2019, Seoul, Korea (South)*, 2019, pp. 1314-1324
- [21] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," *In Proceedings of the IEEE conference on computer vision and pattern recognition, 2018, Salt Lake City, USA*, 2018. pp. 4510-4520. IEEE.
- [22] F. Chollet, "Xception: Deep learning with depthwise separable convolutions." *In Proceedings of the IEEE conference on computer vision and pattern recognition, 2017, Honolulu, Hawaii*, 2017. pp. 1251-1258. IEEE.
- [23] B. Zoph, V. Vasudevan, J. Shlens, and Q. V. Le, "Learning transferable architectures for scalable image recognition." *In Proceedings of the IEEE conference on computer vision and pattern recognition, 18-23 June, 2018, Salt Lake City, USA*, 2018. pp. 8697-8710.
- [24] M. Tan, and Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks." *In International conference on machine learning, 10-15 June, Long Beach, USA*, 2019, pp. 6105-6114.
- [25] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.Y. Fu, and A.C. Berg, "Single shot multibox detector." *In Computer Vision-ECCV 2016: 14th European Conference, 11-14 Oct., 2016, Amsterdam, Netherlands*, 2016, pp. 21-37.
- [26] A. Canziani, A. Paszke, and E. Cukurciello, "An analysis of deep neural network models for practical applications", arxiv.org, 2016. [Online]. Available <https://arxiv.org/abs/1605.07678> [Accessed September 2023].
- [27] G. Huang, Z. Liu, L. Van Der Maaten and K. Q. Weinberger, "Densely Connected Convolutional Networks," *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, Honolulu, HI, USA*, 2017, pp. 2261-2269. doi: 10.1109/CVPR.2017.243.
- [28] K. He, X. Zhang, S. Ren, and J. Sun, "Identity mappings in deep residual networks." *In Computer Vision-ECCV 2016: 14th European Conference, 11-14 Oct., 2016, Amsterdam, Netherlands*, 2016, pp. 630-645..
- [29] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks." *Advances in neural information processing systems*, vol. 25, pp. 1-9, 2012.
- [30] G. Litjens, T. Kooi, B. E. Bejnordi, A. A. A. Setio, F. Ciompi, M. Ghafoorian, J.A.W.M. van der Laak, B. van Ginneken and C.I. Sánchez, "A survey on deep learning in medical image analysis." *Medical image analysis*, vol. 42, pp. 60-88, 2017. doi:10.1016/j.media.2017.07.005
- [31] D. E. Rumelhart, G. E. Hinton and R. J. Williams, "Learning representations by back-propagating errors." *nature*, vol. 32, no.6088, pp. 533-536, 1986. doi:10.1038/323533a0

[32] I. Goodfellow, Y. Bengio and A. Courville, *Deep learning*, Cambridge, MA: MIT press. 2016.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICALAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### Hyperparameter Optimization in Polynomial Kernel SVM Algorithms and its Application

Hamit Armağan<sup>a</sup>

Submitted: 27.11.2023 Revised: 21.12.2023 Accepted: 22.12.2023 doi:10.30855/gmbd.0705S21

#### ABSTRACT

**Keywords:** machine learning, svm, bayesian optimization

<sup>a\*</sup> Süleyman Demirel Üniversitesi,  
Rektörlük, Enformatik Bölümü, 32200  
Isparta/TÜRKİYE  
Orcid: 0000-0002-8948-1546  
e mail: hamitarmagan@sdu.edu.tr

\*Corresponding author:  
hamitarmagan@sdu.edu.tr

In this study, regression analyses and parameter optimizations of support vector machines (SVMs) with different polynomial kernels were performed. Using linear-svm, quadratic-svm and cubic-svm regression algorithms, the performance of each model is examined through an optimization process on the Box-Constraint, Kernel Scale, Epsilon and Standardize parameters. Setting these parameters correctly is critical for the error and approximation metrics of the model. The optimization process was performed with Matlab Regression Learner using the Bayesian Optimization algorithm. Hyperparameter optimized polynomial-based regression models can predict nutrient deficiency in plants with high accuracy. In particular, accurate determination of calcium content in leaves is important to increase fertilization success during the fruit development period in apple trees. In the application part of our study, data sets obtained by digitizing leaf surfaces and data sets obtained from chemical laboratory analysis were modeled. This study using SVM algorithms provides a more efficient model than chemical methods in terms of cost and time.

### Polinom Çekirdekli SVM Algoritmalarında Hiper-Parametre Optimizasyonu ve Uygulaması

#### ÖZ

Bu çalışmada, destek vektör makinelerinin (SVM) farklı polinom çekirdeklerini içeren regresyon analizleri ve parametre optimizasyonları ele alınmıştır. Svm-linear, svm-quadratic ve svm-cubic regresyon algoritmaları kullanılarak her bir modelin performansı, box-constraint, kernel scale, epsilon ve standardize parametreleri üzerinde gerçekleştirilen optimizasyon süreciyle incelenmiştir. Bu parametrelerin doğru bir şekilde ayarlanması, modelin hata ve yaklaşım metrikleri için kritik önem taşımaktadır. Optimizasyon süreci, Bayesian Optimization algoritması kullanılarak matlab regression learner ile gerçekleştirilmiştir. Hiperparametre optimizasyonu yapılmış polinom tabanlı regresyon modelleri, bitkilerde besin elementlerinin eksikliğini yüksek doğrulukla tahmin edebilmektedirler. Özellikle yapraklardaki kalsiyum miktarının doğru bir şekilde belirlenmesi, elma ağaçlarında meyve gelişim döneminde gübreleme başarısını artırmak açısından önem taşımaktadır. Çalışmamızın uygulama bölümünde yaprak yüzeylerinin sayısallaştırılması ile elde edilen veri setleri ile kimyasal laboratuvar analizlerinden elde edilen veri seti modellenmiştir. SVM algoritmaları kullanılarak yapılan bu çalışma, maliyet ve zaman açısından kimyasal yöntemlere göre daha verimli bir model sunmaktadır.

**Anahtar Kelimeler:**  
makine öğrenmesi,  
svm,  
bayesian optimization

## 1. Giriş (Introduction)

Yapay zeka algoritmalarında veriler arasındaki ilişkileri modellemek için polinom çekirdekli regresyon algoritmaları çok kullanılan yöntemlerdir. Birçok durumda, tek girdi değişkeni kullanan lineer regresyon, günlük hayattaki olaylarla ilişkili modellerde yeterli tahmin gücü sunamayabilir [1]–[3]. Bu durum araştırmacıları, regresyon modeli için girdi olarak aynı anda iki ya da daha fazla değişkenin kullanıldığı lineer olmayan regresyon tekniklerine yönelmiştir [4]–[6]. Bu modellerin yazılım algoritmalarında tek başına ya da optimize edilmeden kullanılmaları regresyon uygulamalarında istenen başarının elde edilememesine neden olmaktadır. Bazı veri kümeleri için regresyon uygulamalarında polinom derecesinin artırılması ya da algoritmada kullanılan parametrelerin optimize edilmesi gerekmektedir. Ancak, polinom derecesindeki artışlar modelin karmaşıklaşmasına ya da aşırı uyum (overfitting) riskinin ortaya çıkmasına neden olmaktadır [5], [7]–[9]. Bu durum yazılım algoritmalarının kullanılabilirliğini azaltmakta ve işlem süresini uzatmaktadır. Parametre optimizasyonu ile parametrik matematiksel modelleri kullanan algoritmaların daha başarılı ve hızlı olması sağlanmaktadır [10]–[12].

Bu çalışmada kullanılan görüntü işleme tabanlı tahmin modelleri svm-linear, svm-quadratic ve svm-cubic regresyon algoritmalarıdır. Bu modeller, özellikle regresyon analizleri için kullanılan destek vektör makinelere farklı polinom çekirdeklerini temsil etmektedir. Her bir modelin performansını optimize etmek amacıyla, box constraint, kernel scale, epsilon ve standardize gibi kritik parametreler üzerinde optimizasyon süreci gerçekleştirilmiştir. Bu parametrelerin doğru bir şekilde ayarlanması, modelin tahmin yeteneklerini ve genel performansını artırmak için kritik öneme sahiptir [1], [2], [6], [13].

Optimizasyon süreci, "Bayesian Optimization" algoritması kullanılarak gerçekleştirilmiştir. Bu algoritma, modelin hiperparametre uzayını tarayarak en iyi kombinasyonu bulmayı amaçlar. Bayesian Optimization, modelin performansını sürekli olarak izler, daha iyi sonuçlar elde edilebilecek yeni hiperparametre kombinasyonlarını deneyerek optimizasyon sürecini günceller [2]. Bu sayede, her bir regresyon modeli için en uygun parametre seti belirlenmiş ve bu modellerin elma ağaçlarında besin elementlerinin değerini tahmin etme yetenekleri maksimum seviyeye çıkartılmıştır [14], [15].

Ticari bahçelerde meyve gelişim döneminde toprak ve ağaçlardan alınan veriler bahçe yönetim etkinliğini artırır. Veriye dayalı olmayan ya da hatalı veriye dayanan uygulamalar sonucunda kullanılan kimyasallar toprağın ve çevrenin gereksiz kirletilmesine, ekonomik olarak maliyetlerin artmasına ve iş gücü kaybına neden olmaktadır [12], [16]. Bilgisayarla görü tabanlı modeller kullanılarak bitkilerin beslenme durumunun doğru tespiti oldukça önemlidir. Bu yöntemlerle bitkilerde besin maddelerinin eksikliği ya da fazlalığı yüksek doğrulukta tahmin edilebilmektedir.

Yapraklardaki kalsiyum değeri, ağaç beslenmesini değerlendirmek için etkili parametrelerden biridir. Elma ağaçlarında meyve gelişim döneminde yapraklardaki kalsiyum miktarının tespiti gübreleme başarısını arttırmak açısından önemlidir. Fakat bu analizlerin yapılması maliyetli ve zaman alıcıdır [17]–[19].

Bu çalışmanın amacı, laboratuvar ortamında kimyasal yöntemlerle ölçülen yaprak kalsiyum içeriğini, görüntü analizi ve polinom çekirdekli svm algoritmalarını kullanarak tahmin etmektir. Bu modeller, numune alma işlemini ve maliyetini azaltabilir ve özellikle numunelerin işlenmesinin zor olduğu durumlarda hassasiyeti artırabilir. Yapraklardaki kalsiyum miktarının doğru bir şekilde belirlenmesi, meyve üretimi ve bahçe yönetimi için önemlidir. Standart laboratuvar analizleri güvenilir olsa da zaman alıcı ve maliyetlidir. Bu amaçla, yaprakların sayısal analizi ve regresyon modelleri ile ağaçların besin element analizlerinin yapılması, çevresel sürdürülebilirliği ve bahçe verimliliğine katkı sağlayacaktır.

## 2. Materyal ve Metot (Material and Method)

### 2.1. Materyal (Material)

Çalışmada kullanılan görüntüler "Göller Yöresi" bölgesinde yer alan ticari bir elma bahçesinden alınmıştır. Yaprak örnekleme, besin elementi içerikleri kararlı hale geldiği dönem olan tam çiçeklenme tarihinden 111 gün sonra konu uzmanları tarafından yapılmıştır. Yaprak örnekleme için güneş gören dalların orta kısmında yer alan ~80 yaprak sapsarı ile birlikte koparılmıştır. Her bir ağaç farklı bir ürün yükünü temsil edecek şekilde

toplamda 20 ağaç belirlenerek etiketlenmiş ve yaprak analiz örnekleri/verileri aynı ağaçlardan toplanmıştır. Çalışmada bitki besin elementi analizleri yapılmış olup, bu analizler Burdur Mehmet Akif Ersoy Üniversitesi Bilimsel ve Teknoloji Uygulama ve Araştırma Merkezinde laboratuvarlarında gerçekleştirilmiştir.

## 2.2. Veri toplama (Data collection)

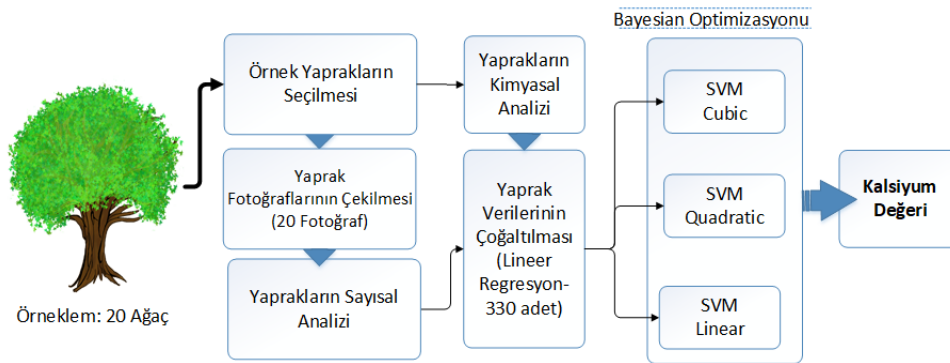
Regresyon algoritmalarında kullanılmak üzere çekilen resimler 4032x3024 boyutunda olup, 24 bit derinliğinde, 72 dpi çözünürlükte ve sRGB renk uzayı ile renkleri temsil edilmektedir. Görüntü işleme çalışmalarında kolaylık sağlaması için resimler ön işleme tabi tutulmuştur. Bu ön işlemden ağaçta yer alan yapraklar diğer nesnelere ve gölgelerinden ayırma işlemi için görüntü bölütleme işlemi uygulanmıştır. Görüntü bölütleme, görüntüdeki piksellerin özelliklerine bağlı olarak bir görüntüyü birden çok parçaya veya bölgeye ayırmak için kullanılan bir yöntemdir. Görüntü bölütleme ile ön planı arka plandan ayırma işlemi, renk ya da şekil benzerliklerini kümeleme en çok kullanılan uygulamalarıdır. Bu çalışmada görüntü bölütleme işlemi için matlab image segmenter uygulamasında yer alan grafik kesim graph cut yöntemi kullanılmıştır (Şekil 1). Grafik kesim, bir görüntüyü ön plan ve arka plan öğelerine ayırmak için kullanılan bölümlenme tekniğidir. Grafik kesim yöntemi hızlı bölümlenme için grafik teorisini kullanmaktadır. Tanımlanan ön plan ve arka plan bilgilerine göre pikseller arası bağlantı ağırlığı belirlenir ve algoritma pikseller arasındaki bağlantı ağırlıklarına göre görüntüdeki nesnelere bölünmesini sağlar.

## 2.3. Veri çoğaltma (Synthetic data generation)

Veri çoğaltma işlemleri iki aşamalı olarak uygulanmıştır. İlk olarak çekilen fotoğraflar arka plan gürültüleri temizlendikten sonra kırmızı(r), yeşil(g) ve mavi(b) renk kanallarının değeri sıfırdan büyük olan pikseller eşit eleman sayılarından oluşacak şekilde alt kümelere ayrılmıştır. Alt küme sayısı 330 olarak seçilmiştir.

$$y = f(r, g, b) \quad (1)$$

Bu işlem ile  $f(r, g, b)$  fonksiyonunun tanım kümesindeki eleman sayısı lineer regresyon yöntemi kullanılarak 20'den, 330'a çıkarılmıştır. Her ağaçtan 4 yaprak alınmıştır. Çekilen her fotoğrafta aynı ağaçtan alınan dört yaprak kullanılmıştır. Veri toplama, çoğaltma ve matematiksel modellerin kullanımı Şekil 1'de detaylı gösterilmiştir.



Şekil 1. Polinom tabanlı SVM algoritmalarında veri toplama, çoğaltma ve tahminleme süreçleri (Data collection, synthetic data generation and prediction processes in polynomial kernel SVM algorithms)

## 2.4. Matematiksel model ve parametreler (Mathematical model and parameters)

SVM modeli, regresyon görevinde kullanılan bir makine öğrenimi algoritmasıdır. Bu model, veri setindeki örnekler arasında en iyi uyum sağlayan bir hiperdüzlemi bulmaya çalışarak hedef değişkenin tahminini gerçekleştirir. Destek vektör makinelerinin (SVM) regresyonu için kullanılan hiperparametreler, modelin hata ve yaklaşım değerlerini etkileyen önemli araçlardır [19], [20].

C(Cost), hata noktalarının ne kadar ihmal edilebileceğini kontrol eden bir parametredir. Büyük C(cost) değerleri, modelleme hatasına daha fazla ceza verir ve modelin eğitim veri setine daha fazla uymasını sağlar.

Ancak, aşırı uyuma yol açabilir. Küçük C değerleri genelleme yeteneğini artırabilir ancak eğitim veri setindeki hatalara hassas değildir [21]-[23].

Epsilon ( $\epsilon$ ), regresyon hatasının kabul edilebilir bir sınırdan ne kadar sapma göstermesine izin verileceğini kontrol eder. Epsilon değeri büyüdükçe, model regresyon hatasına daha fazla tolerans göstermektedir [21]-[23].

Kernel, SVM'de veri noktalarını bir özellik uzayına dönüştürmek için kullanılan bir fonksiyondur. Regresyon kernel fonksiyonlarının genel fonksiyonu denklem 1'de verilmiştir.

$$K(x, y) = (\gamma \cdot x \cdot y + r)^d \quad (2)$$

Denklem 2'de  $\gamma$  kernel katsayısı, d polinom derecesi ve r sapma değeridir. Hiperparametrelerin en uygun değerlerini bulmak için çapraz doğrulama yöntemi ve farklı hiperparametre kombinasyonlarını denemek içinde Bayesian Optimizasyon algoritması kullanılmıştır.

Veri setinde toplam 330 gözlem bulunmakta olup, tahmin yapmak için 3 adet tahminci değişken (R,G,B) kullanılmıştır. Hedef değişken "Ca" olarak belirlenmiştir. Modelin performansı, 5 katlı çapraz doğrulama yöntemi kullanılarak değerlendirilmiştir.

Deneyimdeki veri seti üzerinde gerçekleştirilen 5 katlı çapraz doğrulama, modelin genelleme yeteneğini değerlendirmek ve performansını daha güvenilir bir şekilde ölçmek için kullanılmıştır. Her bir iterasyonda veri seti rastgele beşe bölünmüş, model dört katmanda eğitilmiş ve beşinci katmanda test edilmiştir. Bu işlem beş kez tekrarlanarak genel performans değerlendirmesi sağlanmıştır [18], [19], [23].

Bu otomatikleştirilmiş regresyon analizi deneyimi, veri bilimi ve makine öğrenimi alanındaki uygulamalara hızlı ve etkili bir çözüm sunmaktadır. SVM modeli, tahmin değişkeni "Ca" üzerindeki ilişkileri anlamak ve model performansını değerlendirmek için kullanılmıştır. Elde edilen sonuçlar, modelin belirli bir veri setinde başarılı bir şekilde genelleme yapabilme yeteneğini yansıtmaktadır.


Hiperparametreler; box constraint (C), modelin karmaşıklığını kontrol eden bir hiperparametredir. [0.001, 1000] aralığında gerçel sayılar içerir ve logaritmik bir dönüşümle işlenmiştir. Kernel scale, SVM'nin çekirdek fonksiyonlarının ölçeğini belirleyen bir hiperparametredir ve [0.001, 1000] aralığında gerçel sayılar içerir ve logaritmik bir dönüşümle işlenmiştir. Epsilon, SVM regresyonunun hatası olan epsilon değerini belirler. [3.2158, 321575.7631] aralığındaki gerçel sayılar içerir ve logaritmik bir dönüşümle işlenmiştir. Standardize(standartlaştırma), veri setini standartlaştırma durumunu belirleyen bir hiperparametredir "true" veya "false" değerlerini alabilir.

Bu hiperparametreler, modelin karmaşıklığını, hatasını ve standartlaştırma durumunu kontrol eden önemli araçlardır. Bayesian Optimizasyon, bu hiperparametre setini optimize ederek modelin daha iyi bir performans göstermesini sağlar.

Bayesian Optimization sürecindeki işlem basamakaları; hiperparametre uzayı, İlk olarak, modelin optimize edilecek hiperparametrelerinin bir uzayı belirlenir. Bu uzay, box constraint, kernel scale, epsilon, standardize gibi hiperparametreleri içerir. Hiperparametrelere başlangıç değeri ataması yapılır. Amaç fonksiyonu belirlenir. Bu fonksiyon, modelin performansını ölçen bir metrik üzerinden tanımlanır. Belirlenen cost(C) dahilinde hiperparametre uzayında iteratif olarak değerlendirme yapılır. Her adımda, modelin performansı ölçülür ve bu değere bağlı olarak bir sonraki hiperparametre seti belirlenir. Belirlenen cost(C) içinde en iyi performansı sağlayan hiperparametre seti bulunur. Bu set, Bayesian Optimization sürecinin sonucudur. İteratif bir süreç olarak, her bir döngüde hiperparametre seçimi, model eğitimi, performans değerlendirmesi ve güncelleme adımları tekrarlanarak en iyi hiperparametre setinin bulunması hedeflenir.

### 3. Sonuçlar ve Tartışma (Results and Discussion)

#### 3.1. SVM-Linear algoritması (SVM-Linear algorithm)



Şekil 2. Bayesian Optimization yöntemi kullanılarak SVM-Linear algoritmasında elde edilen optimize edilmiş parametrelerin hata ve yaklaşım performansları


(Error and approximation performances of optimized parameters obtained in the SVM-Linear algorithm using the Bayesian Optimization method)

Destek vektör makinesi (SVM) modelinin hiperparametre optimizasyonu için kullanılan Bayesian Optimization yöntemi, belirlenen hiperparametre setinin doğrulama performansını ayrıntılı olarak şekil 2'de verilmiştir. Aynı zamanda, Bayesian Optimization yöntemiyle elde edilen hiperparametre kombinasyonları arasında en yüksek başarıya sahip olan ilk 10 sonuç tablo 1'de paylaşılmıştır. Bu doğrultuda belirlenen hiperparametre seti ile geliştirilen Destek Vektör Makinesi (SVM) modeli, yüksek R kare değeriyle veriyi etkili bir şekilde açıklamakta ve düşük Root Mean Square Error (RMSE) değeriyle tahminlerin gerçek değerlere yakın olduğunu göstermektedir. Bayesian Optimization stratejisi kullanılarak belirlenen hiperparametre seti ve oluşturulan SVM modelinin; doğrulama verisi üzerinde başarılı bir performans sergilediğini göstermektedir.

Tablo 1. Bayesian Optimization yöntemi kullanılarak SVM-Linear algoritmasında elde edilen optimize edilmiş parametreler ve doğrulama performanslarının kombinasyonları ( Sıralama RMSE değerine göre yapılmış olup ilk 10 değeri göstermektedir. Toplam kombinasyon sayısı 30 dur.)

(Combinations of optimized parameters and verification performances obtained in the SVM-Linear algorithm using the Bayesian Optimization method (The ranking is made according to the RMSE value and shows the first 10 values. The total number of combinations is 30.))


BoxConstraint	Kernel Scale	Epsilon	Validation RMSE	Validation Rsquared
<b>413.2376902</b>	0.149042976	26.72295986	347.7663911	0.989816633
<b>0.026945007</b>	0.028940967	28.96798805	348.3532578	0.989782235
<b>3.35792329</b>	0.129978567	20.90234852	350.402532	0.989661664
<b>3.682985661</b>	0.068124603	19.84131668	350.9247292	0.989630827
<b>87.31014359</b>	0.270066044	17.74144123	351.7494962	0.989582029
<b>1.427989577</b>	0.167288076	11.59887758	353.8129505	0.989459441
<b>0.001101378</b>	0.004131366	8.959736054	354.7195096	0.989405357
<b>3.140283237</b>	0.147229454	8.530972267	354.8003963	0.989400525
<b>173.8278945</b>	0.285662457	7.559932223	355.4594489	0.989361111
<b>0.034528455</b>	0.015737249	5.650026688	355.8737029	0.989336299



Şekil 3. SVM- Linear algoritmasında gerçek değer ve tahmin yanıtının karşılaştırma performansları  
(Comparison performances of actual value and predicted responses in the SVM- Linear algorithm)

Şekil 3'te diyagonal çizgi ideal durumu temsil eder; yani, gerçek ve tahmin edilen değerler arasındaki uyumu gösterir. Görsel olarak bu çizgiye yakın bir dağılım, modelin gerçek değerlere yakın ve tutarlı tahminlerde bulunduğunu gösterir. Bu durum, belirlenen hiperparametre seti ve Bayesian Optimization'u kullanılarak oluşturulan SVM modelinin veriyi etkili bir şekilde açıkladığını ve doğrulama verisi üzerinde yüksek performans sergilediğini göstermektedir.

### 3.2. SVM-Quadratic algoritması (SVM-Quadratic algorithm)



Şekil 4. Bayesian Optimization yöntemi kullanılarak SVM- Quadratic algoritmasında elde edilen optimize edilmiş parametrelerin hata ve yaklaşım performansları  
(Error and approximation performances of optimized parameters obtained in the SVM-Quadratic algorithm using the Bayesian Optimization method)

Destek vektör makinesi (SVM) modelinin hiperparametre optimizasyonu için Bayesian Optimization yöntemi kullanılarak belirlenen hiperparametre setinin doğrulama performansı şekil 4'de verilmiştir. Ayrıca Bayesian Optimization yöntemi kullanılarak elde edilen hiperparametre kombinasyonlarından en yüksek başarıya sahip ilk 10 sonuç tablo 2'de paylaşılmıştır.

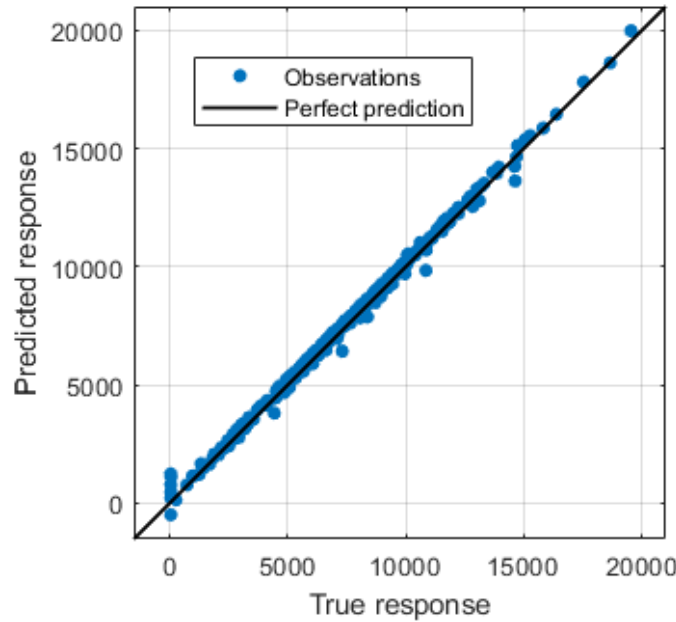


Tablo 2. Bayesian Optimization yöntemi kullanılarak SVM-Quadratic algoritmasında elde edilen optimize edilmiş parametre ve doğrulama performans kombinasyonları (sıralama RMSE değerine göre yapılmış olup ilk 10 değeri göstermektedir. Toplam kombinasyon sayısı 30 dur.)

(Combinations of optimized parameters and verification performances obtained in the SVM- Quadratic algorithm using the Bayesian Optimization method (The ranking is made according to the RMSE value and shows the first 10 values. The total number of combinations is 30.))

BoxConstraint	Kernel Scale	Epsilon	Validation RMSE	Validation Rsquared
161.9773328	0.557191839	312.3473457	295.7931324	0.992632972
967.9262171	0.875948995	346.9786153	297.271893	0.992559127
433.4541301	0.311059872	240.5526151	299.6919974	0.992437481
304.829562	0.771002448	207.0737476	302.4558597	0.99229735
13.13843562	0.325438467	150.3384645	312.7825197	0.991762392
3.380708157	0.270484319	114.9687094	322.2166498	0.991257973
2.994487851	0.242315929	98.55338541	326.5159236	0.991023131
0.429380191	0.050528408	65.25387426	335.7532089	0.990508026
3.397631434	0.085163718	51.95381339	339.7573508	0.990280277
0.265001018	0.001016695	25.42854692	348.7772761	0.989757345


Belirlenen hiperparametre seti ile elde edilen SVM modeli, yüksek R kare değeri ile veriyi yüksek oranda açıklamakta ve düşük RMSE değeri ile tahminlerin gerçek değerlere yakın olduğunu göstermektedir. Bayesian Optimization stratejisi kullanılarak elde edilen hiperparametre seti ve SVM modelinin, doğrulama verisi üzerinde yüksek performans sergilediğini göstermektedir.



Şekil 5. SVM-Quadratic algoritmasında gerçek değer ve tahmin yanıtlarının karşılaştırma performansları (Comparison performances of actual value and predicted responses in the SVM- Quadratic algorithm)

Şekil 5'de, SVM-Quadratic regresyon modelinin gerçek ve tahmini değerlerini karşılaştırmak için kullanılmıştır. Bu grafik, modelin gerçek verilere yaklaşımını değerlendirmek adına önemli bir araçtır. İyi bir modelde, gerçek ve tahmin değerleri tam olarak örtüşür ve diyagonal çizgi oluşturmaktadır. Grafik üzerindeki her noktanın diyagonal çizgiden uzaklığı, o tahminin hatasını ifade eder. Grafikte de görüleceği gibi gerçek değerler ve tahmin değerleri yüksek oranda örtüşmekte ve diyagonal çizgi oluşturmaktadır.

### 3.3. SVM-Cubic algoritması (SVM-Cubic algorithm)



Şekil 6. Bayesian Optimization yöntemi kullanılarak SVM-Cubic algoritmasında elde edilen optimize edilmiş parametreler ve doğrulama performansları  
(Error and approximation performances of optimized parameters obtained in the SVM-Cubic algorithm using the Bayesian Optimization method)

Bu çalışmada, destek vektör makinesi (SVM) modeli için Bayesian Optimization yöntemi kullanılarak belirlenen hiperparametre setinin doğrulama performansı incelenmiştir. Bu sonuçlara göre, belirlenen hiperparametre seti ile elde edilen SVM modelinin yüksek performans sergilediğini göstermektedir. Düşük RMSE değeri, modelin tahminlerinin gerçek değerlere yakın olduğunu, yüksek R kare değeri ise modelin veriyi yüksek oranda açıkladığını göstermektedir.

Bayesian Optimization'ın kullanılması, belirlenen hiperparametre setini optimize etmede etkili olmuştur. Bu sonuçlar, SVM modelinin belirli bir problem üzerinde başarılı bir şekilde uyarlandığını ve hiperparametre optimizasyonunun bu başarıyı artırdığını göstermektedir. Özellikle, BoxConstraint ve Kernel Scale gibi hiperparametrelerin model performansındaki etkisi önemlidir. Standardizasyonun false olması, veri setinin standartlaştırılmadığını göstermektedir. Ayrıca Bayesian Optimization yöntemi kullanılarak elde edilen hiperparametre kombinasyonlarından en yüksek başarıya sahip ilk 10 sonuç tablo 3'de ve doğrulama performansı da şekil 7'de verilmiştir.


Tablo 3. Bayesian Optimization yöntemi kullanılarak SVM-Cubic algoritmasında elde edilen optimize edilmiş hiperparametreler ve doğrulama performans kombinasyonları ( sıralama RMSE değerine göre yapılmış olup ilk 10 değeri göstermektedir. Toplam kombinasyon sayısı 30 dur.)

(Combinations of optimized parameters and verification performances obtained in the SVM-Cubic algorithm using the Bayesian Optimization method  
(The ranking is made according to the RMSE value and shows the first 10 values. The total number of combinations is 30.))

BoxConstraint	Kernel Scale	Epsilon	Validation RMSE	Validation Rsquared
941.8442131	0.417461642	250.7642617	300.9392457	0.992374403
78.10845401	0.289259491	326.2277033	302.4268688	0.992298826
142.2002401	2.60377804	255.1919797	305.3886486	0.992147247
929.7379756	1.873427275	385.3543677	308.1705874	0.992003526
995.9629942	8.300488299	321.5053366	312.7371392	0.991764782
997.0468113	1.672638739	131.1677841	319.5328459	0.991402995
181.6804707	0.234791432	92.64252791	329.4120231	0.99086318
670.7817518	0.776443467	35.48066837	345.8667607	0.98992758
5.092075509	0.100515873	18.30578891	351.8103139	0.989578426
31.77291005	0.506563232	17.66780319	351.822748	0.989577689

Şekil 7, SVM-Cubic regresyon modelinin hata ve yaklaşım değerini gösteren bir grafikdir. Grafikte, modelin gerçek değerlere olan yaklaşımını ve tahmin yeteneği görselleştirilmiştir. İdeal bir modelde, gerçek ve tahmin edilen değerler birbirine çok yaklaşıp ve bu durum diyagonal bir çizgi oluşturur. Grafikte her noktanın diyagonal çizgiden uzaklığı, o noktanın tahmin hatasını temsil eder.

Gözlemlendiği üzere, SVM-Cubic regresyon modeli tarafından gerçekleştirilen tahminler ile gerçek veriler arasında yüksek bir uyum söz konusudur. Grafikteki noktaların genel eğilimi, diyagonal bir çizgi oluşturacak şekilde gerçek ve tahmin değerlerinin yakın olduğunu göstermektedir. Bu durum, modelin verileri etkili bir şekilde öğrendiğini ve genellemeye uygun bir performans sergilediğini işaret etmektedir.



Şekil 7. SVM-Cubic algoritmasında gerçek değer ve tahmin yanıtının karşılaştırma performansları (Comparison performances of actual value and predicted responses in the SVM-Cubic algorithm)

### 3.4. Karşılaştırma ve değerlendirme (Comparison and evaluation)

RMSE değerleri, SVM Quadratic modelinin RMSE değeri (295.7931324), diğer iki modele göre daha düşüktür. Düşük RMSE, modelin daha iyi tahminler yaptığını göstermektedir. Rsquared (R kare) değerleri; SVM Quadratic modelinin R squared değeri (0.992632972), diğer modellere göre daha yüksektir. Bu durum, SVM Quadratic modelinin veriyi daha iyi açıkladığını göstermektedir. Hiperparametre değerleri; SVM Cubic modeli, diğerlerine göre daha yüksek BoxConstraint ve Kernel Scale değerlerine sahiptir. Bu durum, SVM Cubic modelinin daha karmaşık bir yapıya sahip olduğunu göstermektedir. Sonuç olarak; SVM Quadratic modeli, düşük RMSE ve yüksek R squared değerleri ile modelin daha iyi bir performans sergilediğini göstermektedir.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

- [1] H. Fattahi and N. Babanouri, "Applying Optimized Support Vector Regression Models for Prediction of Tunnel Boring Machine Performance," *Geotech. Geol. Eng.*, vol. 35, no. 5, pp. 2205–2217, Oct. 2017. doi:10.1007/S10706-017-0238-4/TABLES/8.
- [2] V. Strijov and G. W. Weber, "Nonlinear regression model generation using hyperparameter optimization," *Comput. Math. with Appl.*, vol. 60, no. 4, pp. 981–988, Aug. 2010. doi:10.1016/J.CAMWA.2010.03.021.
- [3] P. Yu, M. Y. Low, and W. Zhou, "Design of experiments and regression modelling in food flavour and sensory analysis: a

- review,” *Trends Food Sci. Technol.*, vol. 71, pp. 202–215, Jan. 2018. doi:10.1016/j.tifs.2017.11.013.
- [4] A. Kamilaris and F. X. Prenafeta-Boldú, “Deep learning in agriculture: A survey,” *Comput. Electron. Agric.*, vol. 147, pp. 70–90, Apr. 2018. doi: 10.1016/J.COMPAG.2018.02.016.
- [5] P. Freund, R. J., Wilson, W. J., Sa, *Regression analysis: Statistical Modeling of a response variable (2nd ed)*. California, USA: Elsevier, 2006.
- [6] N. Panigrahi and B. S. Das, “Evaluation of regression algorithms for estimating leaf area index and canopy water content from water stressed rice canopy reflectance,” *Inf. Process. Agric.*, vol. 8, no. 2, pp. 284–298, 2021. doi:10.1016/j.inpa.2020.06.002.
- [7] I. Keramatlou, M. Sharifani, H. Sabouri, M. Alizadeh, and B. Kamkar, “A simple linear model for leaf area estimation in Persian walnut (*Juglansregia L.*),” *Sci. Hortic. (Amsterdam)*, vol. 184, pp. 36–39, Mar. 2015. doi:10.1016/j.scienta.2014.12.017.
- [8] Basak, J. K., Qasim, W., Okyere, F. G., Khan, F., Lee, Y. J., Park, J., and Kim, H. T. , “Regression Analysis to Estimate Morphology Parameters of Pepper Plant in a Controlled Greenhouse System,” *J. Biosyst. Eng.*, vol. 44, no. 2, pp. 57–68, Jun. 2019. doi:10.1007/S42853-019-00014-0/FIGURES/11.
- [9] H. Armağan, “Color Based Segmentation with k-Means Clustering Algorithm and Numerical Analysis of the Effect of Color Spaces on Image Quantities.,” *El-Cezeri*, vol. 9, no. 4, pp. 1506–1517, Dec. 2022. doi:10.31202/ECJSE.1141148.
- [10] K. G. Liakos, P. Busato, D. Moshou, S. Pearson, and D. Bochtis, “Machine Learning in Agriculture: A Review,” *Sensors*, Vol. 18, no. 8, p. 2674, Aug. 2018. doi: 10.3390/S18082674.
- [11] T. U. Rehman, M. S. Mahmud, Y. K. Chang, J. Jin, and J. Shin, “Current and future applications of statistical machine learning algorithms for agricultural machine vision systems,” *Comput. Electron. Agric.*, vol. 156, pp. 585–605, Jan. 2019. doi:10.1016/J.COMPAG.2018.12.006.
- [12] M. Pathan, N. Patel, H. Yagnik, and M. Shah, “Artificial cognition for applications in smart agriculture: A comprehensive review,” *Artif. Intell. Agric.*, vol. 4, pp. 81–95, Jan. 2020. doi:10.1016/J.AIIA.2020.06.001.
- [13] “K-means clustering based image segmentation - MATLAB imsegkmeans.” [Online]. Available: <https://www.mathworks.com/help/images/ref/imsegkmeans.html> [Accessed Sep. 22, 2022].
- [14] M. Shahhosseini, G. Hu, and H. Pham, “Optimizing ensemble weights and hyperparameters of machine learning models for regression problems,” *Mach. Learn. with Appl.*, vol. 7, p. 100251, 2022. doi:10.1016/j.mlwa.2022.100251.
- [15] P. M. Granitto, H. D. Navone, P. F. Verdes, and H. A. Ceccatto, “Weed seeds identification by machine vision,” *Comput. Electron. Agric.*, vol. 33, no. 2, pp. 91–103, 2002. doi:10.1016/S0168-1699(02)00004-2.
- [16] J. G. A. Barbedo, “Detection of nutrition deficiencies in plants using proximal images and machine learning: A review,” *Comput. Electron. Agric.*, vol. 162, pp. 482–492, Jul. 2019. doi:10.1016/J.COMPAG.2019.04.035.
- [17] X. Ye, S. Abe, and S. Zhang, “Estimation and mapping of nitrogen content in apple trees at leaf and canopy levels using hyperspectral imaging,” *Precis. Agric.*, vol. 21, no. 1, pp. 198–225, Feb. 2020. doi:10.1007/S11119-019-09661-X/FIGURES/15.
- [18] Chen, S., Hu, T., Luo, L., He, Q., Zhang, S., Li, M., Cui, X. and Li, H, “Rapid estimation of leaf nitrogen content in apple-trees based on canopy hyperspectral reflectance using multivariate methods,” *Infrared Phys. Technol.*, vol. 111, p. 103542, Dec. 2020. doi:10.1016/J.INFRARED.2020.103542.
- [19] Morellos, A., Pantazi, X. E., Moshou, D., Alexandridis, T., Whetton, R., Tziotziou, G., Weibensohn, J., Bill, R. and Mouazen, , “Machine learning based prediction of soil total nitrogen, organic carbon and moisture content by using VIS-NIR spectroscopy,” *Biosyst. Eng.*, vol. 152, pp. 104–116, Dec. 2016. doi:10.1016/J.BIOSYSTEMSENG.2016.04.018.
- [20] G. Liu, S. Mao, and J. H. Kim, “A mature-tomato detection algorithm using machine learning and color analysis,” *Sensors (Switzerland)*, vol. 19, no. 9, pp. 1–19, 2019. doi:10.3390/s19092023.
- [21] C. Lisu, S. Yuanyuan, and W. Ke, “Rapid diagnosis of nitrogen nutrition status in rice based on static scanning and extraction of leaf and sheath characteristics,” *Int. J. Agric. Biol. Eng.*, vol. 10, no. 3, pp. 158–164, May 2017. doi:10.25165/IJABE.V10I3.1860.
- [22] M. Yang, D. Xu, S. Chen, H. Li, and Z. Shi, “Evaluation of Machine Learning Approaches to Predict Soil Organic Matter and pH Using vis-NIR Spectra,” *Sensors*, vol. 19, no. 2, p. 263, Jan. 2019. doi:10.3390/S19020263.
- [23] M. Altalak, M. A. Uddin, A. Alajmi, and A. Rizg, “Smart Agriculture Applications Using Deep Learning Technologies: A Survey,” *Appl. Sci.*, vol. 12, no. 12, Jun. 2022. doi:10.3390/app12125919.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAE 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



# GAZİ

## JOURNAL OF ENGINEERING SCIENCES

### Generating Synthetic Images from Real MR Images Using Deep Learning Methods

Ercüment Güvenç <sup>a</sup>, Gürcan Çetin <sup>b</sup>, Mevlüt Ersoy <sup>c</sup>

Submitted: 19.11.2023 Revised: 22.12.2023 Accepted: 23.12.2023 doi:10.30855/gmbd.0705S22

#### ABSTRACT

One of the most important technological developments in the field of medicine is Computed Tomography and Magnetic Resonance imaging techniques. This technique allows the size and shape of tumor areas in body tissues to be determined, making it easier for specialists to determine the type of tumor as well as whether it is benign or malignant. Various deep learning-based computer software have been developed to accurately detect tumor areas in tissue. Due to the lack of image data used in deep learning studies, a limitation naturally arises in studies in this field. In order to eliminate the lack of image data in these studies, image augmentation can be performed using deep learning methods as well as data augmentation methods using various image processing techniques. In this study, Generative Adversarial Networks, a deep learning technique, were employed to duplicate brain MR images and generate synthetic images. After the resulting MR images were made usable by undergoing various pre-processing, similarity rates to real images were calculated using metrics such as Peak Signal-to-Noise Ratio, Structural similarity index and Mean Square Error, and by looking at these rates, realistic images were added to the data set and the data set was expanded.

**Keywords:** Deep Learning,  
Generative Adversarial Networks,  
Image Processing

<sup>a</sup> Muğla Sıtkı Koçman University,  
Department of Informatic  
48000 - Muğla, Türkiye  
Orcid: 0000-0003-0053-9623  
e mail: eguenc@mu.edu.tr

<sup>b</sup> Muğla Sıtkı Koçman University,  
Faculty of Technology,  
Department of Information Systems  
Engineering  
48000 - Muğla, Türkiye  
Orcid: 0000-0003-3186-2781

<sup>c</sup> Suleyman Demirel University,  
Faculty of Engineering,  
Department of Computer Engineering  
32260 - Isparta, Türkiye  
Orcid: 0000-0003-2963-7729

<sup>\*</sup>Corresponding author:  
eguenc@mu.edu.tr

### Derin Öğrenme Yöntemleri Kullanılarak Gerçek MR Görüntülerinden Sentetik Görüntülerin Üretilmesi

#### ÖZ

Tıp alanındaki en önemli teknolojik gelişmelerden biri Bilgisayarlı Tomografi ve Manyetik Rezonans görüntüleme teknikleridir. Bu teknik, vücut dokularındaki tümör alanlarının boyutunun ve şeklinin belirlenmesine olanak tanyarak, uzmanların tümörün tipinin yanı sıra iyi huylu veya kötü huylu olup olmadığını belirlemesini kolaylaştırır. Dokudaki tümör alanlarını doğru bir şekilde tespit etmek için çeşitli derin öğrenme tabanlı bilgisayar yazılımları geliştirilmiştir. Derin öğrenme çalışmalarında kullanılan görüntü verilerinin eksikliğinden dolayı bu alanda yapılan çalışmalarda doğal olarak bir sınırlılık ortaya çıkmaktadır. Bu çalışmalarda görüntü verisi eksikliğini gidermek amacıyla çeşitli görüntü işleme teknikleri kullanılarak veri büyütme yöntemlerinin yanı sıra derin öğrenme yöntemleri kullanılarak da görüntü büyütme gerçekleştirilebilmektedir. Bu çalışmada, beyin MR görüntülerini çoğaltmak ve sentetik görüntüler oluşturmak için derin öğrenme tekniği olan Üretken Çekişmeli Ağlar kullanıldı. Elde edilen MR görüntüleri çeşitli ön işlemlerden geçirilerek kullanılabilir hale getirildikten sonra Tepe Sinyal-Gürültü Oranı, Yapısal benzerlik indeksi ve Ortalama Karesel Hata gibi metrikler kullanılarak gerçek görüntülere benzerlik oranları hesaplanmış ve bu oranlara bakılarak gerçekçi sonuçlar elde edilmiştir. Veri setine görseller eklenmiş ve veri seti genişletilmiştir.

**Anahtar Kelimeler:** Derin  
Öğrenme, Üretken Çekişmeli  
Ağlar, Görüntü İşleme

## 1. Introduction

With the advancement of computers in today's world, the processing of large datasets in the field of artificial intelligence and the generation of results can be achieved rapidly. Particularly in studies using deep learning models, the inadequacy of computer resources has been attempted to be addressed with the use of cloud systems in recent years. However, in conducted studies, the creation of datasets has emerged as a significant challenge, requiring considerable effort and performance, especially in studies using image data.

In studies, especially in the field of medical image processing, errors and deficiencies in the results obtained are encountered due to the insufficient availability of MR images. Various data augmentation processes have been employed in the literature to address this data deficiency, and it has been observed that research results are positively affected.

In recent years, machine learning and its subfield, deep learning, have become quite popular in artificial intelligence studies in various fields. Artificial intelligence mimics the logic of the human brain to solve problems related to decision-making and prediction [1]. Therefore, deep learning, like artificial intelligence, is based on a series of algorithms inspired by the structure and functioning of the brain. Deep learning has become a popular area in data science, being used in various fields such as medical, robotics, image recognition, image generation, autonomous vehicles, natural language processing, space, and defense industries [2].

Deep neural networks, which use large-scale data, have demonstrated better performance in extracting semantic information from images compared to classical image processing techniques. The approaches proposed in deep learning have also shown significant success in image generation. In this study, Generative Adversarial Networks (GAN), introduced by Ian Goodfellow in 2014 and widely used in various fields today, were employed for the generation of synthetic MR images.

Challenges in obtaining data for training in artificial intelligence studies, the laborious nature of real-world data collection, and the requirement for expertise from different disciplines in the labeling processes are limitations in this field. For instance, difficulties in obtaining MR images in a real hospital environment include the presence of different types of tumors, limited numbers of individuals with the same disease, or the inability to capture a standard image quality. Therefore, research is often conducted using ready-made datasets, such as ImageNet, CIFAR10/100, and BRaTS. However, upon examining these datasets, it becomes evident that datasets containing MR images are limited for high-performance deep learning models.

Synthetic data generation processes are often preferred in many studies as a solution to performance issues arising from the lack of images in datasets in deep learning studies using medical images or insufficient images in face recognition models. The inadequacy of deep learning models used due to the lack of image data in training is a common issue in the foundations of these studies. Therefore, the deficiency of image data in the datasets used during the training of these models has been attempted to be addressed through the generation of synthetic images, leading to significant improvements in model performance. In this study, some methods used for generating synthetic image data to address the deficiency of image data are discussed, and methods preferred for calculating the similarity ratios of generated images to real images are mentioned.

## 2. Method

### 2.1. Dataset

In the conducted study, MR images used in the segmentation of brain tumors were preferred. It is crucial for artificial intelligence-based studies that the tumor regions on MR images are accurately labeled. This is because the goal of artificial intelligence studies is to predict results closest to expert opinions. The calculation of these results and the ability to make predictions are directly related to the training of the deep neural network. For this training to be conducted accurately, the data in the dataset must be correctly labeled.

Especially in deep learning studies involving image data, ready-made datasets are preferred due to the difficulty of accessing labeled image data [3]. Ready-made datasets are prepared by various experts at universities worldwide, and competitions are organized in specified fields after the labeling of images is completed. One such dataset is the BraTS dataset, known as the "Multimodal Brain Tumor Segmentation

Challenge." In the conducted study, images from the Flair sequence of the BRATS dataset were chosen as the source of synthetic image data to be generated. Images from different sequences in the dataset are shown in Figure 1.




Figure 1. MR images in different sequences in the dataset

## 2.2. Image augmentation methods

Upon reviewing the conducted studies, it is observed that, in addition to image processing methods, various deep learning-based methods have also been employed for image data augmentation. Image processing techniques such as Translation, Cropping, Rotation, and Color Space are preferred, and in deep learning-based methods, the Generative Adversarial Network (GAN) method is among the preferred techniques for generating synthetic image data.

### 2.2.1. Image processing methods

**Translation:** Horizontal axis translation is much more common than vertical axis rotation. This data augmentation method is one of the easiest to apply, and it has yielded successful results in datasets such as CIFAR-10 and ImageNet [4].

**Color Space:** Enlargements in the color channels by performing simple matrix operations to increase or decrease the brightness of an image is another practical method for data augmentation. RGB values can be easily modified with this method [4].

**Cropping:** Image cropping is a practical image processing technique that involves cropping the central part of each image for image data with mixed height and width dimensions. In addition, the random cropping method can be used to achieve an effect similar to the rotation process. In random cropping, changes are made to the size of the image in pixels [4].

**Rotation:** The rotation method is performed by rotating the image to the right or left on an axis between  $1^\circ$  and  $359^\circ$ . The rotation degree parameter is crucial for data augmentation using the rotation method. Mild rotations between 1 and 20 or -1 and -20, for example, can be useful in tasks such as step recognition, as seen in some ready-made datasets. However, as the rotation degree increases, distortions in the labels of the data may occur [4].

**Generative Adversarial Networks - GAN:** Deep neural networks that utilize large-scale data have demonstrated better performance in extracting semantic information from images compared to classical image processing techniques. The approaches proposed in deep learning have also shown significant success in image generation. The first model developed for generating images using deep neural networks was proposed by Ian Goodfellow in 2014. The Generative Adversarial Network (GAN) model is heavily used in various fields such as style transfer, tabular data generation, image enhancement, sound transfer, and artificial face generation.

The GAN model has been successfully employed for tasks such as generating entirely new faces that have never existed before, in addition to its widespread use in style transfer, tabular data generation, image enhancement, and voice transfer [5].




Figure 2. GAN architecture

The structure of the GAN model consists of two distinct deep networks, as seen in Figure 2: the generator and the discriminator. These two networks in the GAN structure work adversarially, learning from each other in a competitive manner.

The discriminator, a deep network, attempts to distinguish generated images by comparing them to real images, while the generator, another deep network, tries to produce images that are as close as possible to the real images based on the input noise signals. In this way, the discriminator and generator networks are competitively trained. The training process continues until a certain number of iterations are reached, and after the training of the networks is completed, the generator network produces new images resembling real images [6].

Generative Adversarial Networks (GANs) have become popular in recent years for data augmentation processes. In the study titled "GAN-Based Synthetic Brain MR Image Generation," Changhee Han et al. successfully generated synthetic MR images using specific slices from MR images in the BRATS 2016 dataset with DCGAN and WGAN models. They demonstrated that these models could be used for generating medical images [7].

The GAN model creates artificial data from a dataset while preserving features similar to the original dataset. The successful performance of Generative Adversarial Networks in image generation has made it an important model among data augmentation methods [4].

### 2.3. Synthetic Image Data Generation

The DCGAN model (Deep Convolutional Generative Adversarial Network) used in the study is structurally similar to the standard GAN model. In this model, deep convolutional neural networks have been added to the standard GAN architecture. This feature allows DCGAN to process larger and more complex images more efficiently, leading to more stable results. In the standard GAN architecture, the output size from the previous layer is adjusted to be equal to the input size of the previous layer, whereas the DCGAN architecture can modify these dimensions using image slices. As a result, the model used is made more suitable for processing larger and more complex images. The architectural structure of the DCGAN model used in the application is illustrated in Figure 3.



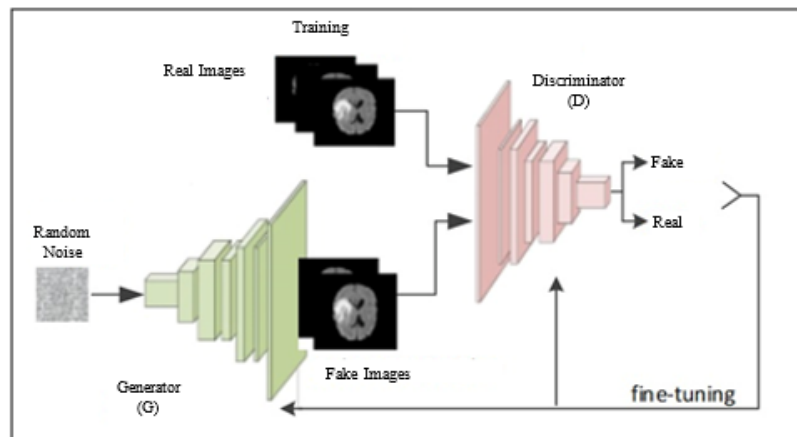


Figure 3. The structure of the DCGAN model used in the application

According to Figure 3, the Generator network (G) takes a random noise vector and then performs the "up-sampling" process to create feature maps at different scales. The goal of training the Generator network is to learn real examples and generate fake examples to deceive the Discriminator network (D). This process is achieved by minimizing the distribution distance between generated and real examples. Each "up-sampling" operation is followed by a batch normalization layer and an activation function. All activation functions, except the tanh function in the final layer, are applied as ReLU. The Discriminator network takes both generated and real examples, and its training objective is to distinguish generated examples from real images. The objective function value of the Discriminator network represents the likelihood of the input example being real, making it a binary classification problem. This training process continues until the Discriminator network cannot distinguish input examples from real images (loss function value = 0) [8].

In the conducted study, 144 MR images from 210 patients in the dataset, where the tumor regions were identified as clear by expert doctors, were used as the training dataset for the DCGAN model. The prepared DCGAN model, trained on Colab Pro, generated approximately 250,000 images over an approximate working time of 8-10 hours. The similarities of the generated images to the real images were compared based on the processing steps of real images, and the number of model iterations (epochs) was determined. Some sample images from the DCGAN model at specific iterations are shown in Figure 4.




Figure 4. The images generated by the DCGAN model at specific iterations are as follows

The generated images are created in the same dimensions as the real MR images, with a size of 240x240 pixels. Due to the large number of generated images and the need to distinguish those that are similar to MR images, expert doctor opinions are required. However, to overcome the challenges of time and labor, an attempt has been made to establish an automatic classifier by calculating image similarity coefficients mentioned in the literature.

To determine whether the synthetic image data meets the desired criteria, it is essential to calculate the similarity of the generated images to real images or obtain an expert opinion. Considering the challenges of consulting an expert and the time that would be lost, the importance of automatically calculating similarities in a computer environment for faster results becomes significant. Various methods are used to perform these calculations, including Mean Square Error (MSE), Structural Similarity Index (SSIM), and Peak Signal-to-Noise Ratio (PSNR).

**Mean Square Error (MSE):** Mean Square Error (MSE) is a commonly used similarity measure in image processing studies. This metric calculates the average of the squared differences between pixel values of two

images. MSE is expressed by the following formula:

$$\text{MSE}(I, J) = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n (I(i, j) - J(i, j))^2 \quad (1)$$

Here, I and J represent the two compared images, and m and n denote the dimensions of the images. The closer the value of MSE is to zero, the more similar the two images are considered.

The use of MSE is prevalent, especially to quantitatively express how similar or different one image is compared to another. However, MSE has some disadvantages. For instance, small differences in pixel values can lead to large errors and may exhibit inconsistency with differences perceived by the human eye. Therefore, when used alone, MSE might not adequately reflect perceptual similarity [9].

In this context, the use of MSE is often preferred in combination with other similarity measures to obtain more reliable results.

**Structural Similarity Index (SSIM):** The Structural Similarity Index (SSIM) is a similarity measure used in image processing to evaluate the structural similarity between two images. It is designed to better mimic the perception of the human eye and often outperforms simple error metrics like Mean Square Error (MSE) in many scenarios.

SSIM provides a similarity index incorporating three fundamental components: brightness, contrast, and structure. In general, SSIM is expressed by the following formula:

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_x\sigma_y + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (2)$$

Here, x and y represent the two compared images,  $\mu_x$  and  $\mu_y$  are the mean values of the images,  $\sigma_x^2$  and  $\sigma_y^2$  are the variances,  $\sigma_{xy}$  is the covariance, and C1 and C2 are small constants preventing division by zero errors.

The value of SSIM typically ranges between -1 and 1, where values closer to 1 indicate a higher similarity between the two images. SSIM can be more sensitive to contrast reductions and structural changes, leading to results that are closer to the perception of the human eye.

Among image similarity metrics, SSIM is a preferred metric, especially in applications such as medical imaging, video quality assessment, and similar fields where a more nuanced evaluation of image similarity is required [10].

**Peak Signal-to-Noise Ratio (PSNR):** Peak Signal-to-Noise Ratio (PSNR) is a metric commonly used in image processing, especially for assessing image quality. It measures the similarity between the original and processed images and is generally considered as an error metric. A higher PSNR value indicates increased similarity between two images.

PSNR is associated with Mean Square Error (MSE) and is typically expressed by the following formula:

$$\text{PSNR} = 10 \cdot \log_{10} \left( \frac{\text{Max Pixel Value}^2}{\text{MSE}} \right) \quad (3)$$

In this formula, the Max Pixel Value represents the maximum value a pixel can take, depending on the image format. MSE expresses the mean value of the squared errors between the original and processed images. PSNR is usually measured in decibels.

One advantage of PSNR is its simple and fast computation. However, it is known that PSNR does not fully reflect the perception of the human eye and may be inadequate in certain situations. Particularly, when errors have different effects on different regions of the image, the performance of PSNR may decrease.

Therefore, PSNR is generally not used alone for image quality assessment; it is often used in conjunction with

other similarity metrics and human eye evaluations to provide a more comprehensive evaluation [9].

These metrics are used to objectively assess how close the generated images are to the real ones. However, each metric has its own advantages and limitations; therefore, it is generally recommended to use multiple metrics together.

Acceptable value ranges for metrics are general guidelines and can vary depending on specific use cases. The interpretation of values should take into account visual quality and similarity, and acceptable similarity ranges should be determined based on a specific application.

### 3. Results and Discussion

In the conducted study, the DCGAN model was employed to generate synthetic images. For synthetic image generation with the DCGAN model, 120 images were selected as training data, and synthetic images were generated until reaching 10,000 epochs. A method was developed to select synthetic MR images that resemble the real MR images from the generated 10,000 synthetic images. According to this method, samples selected from the real dataset images were compared with the generated synthetic MR images using MSE, SSIM, and PSNR algorithms to reveal similarity ratios. Thus, the automatic separation of numerous images within synthetic MR images was achieved, facilitating the image separation process compared to the expert-based image separation process in previous studies.

In the study, 12 randomly selected real MR images from the dataset were compared individually with the generated 10,000 synthetic MR images. The automatically separated synthetic MR images, based on the valid values in the similarity algorithms, were copied to different folders, aiming to ease the workload of medical experts. The valid boundaries for similarity ratios were determined separately for each of the three algorithms. The synthetic MR images that met these criteria were separated into different folders. For the MSE algorithm, the threshold value was set at 0.0145, determined as the value closest to 0, and images below this threshold were grouped in a folder as real MR images. The same process was repeated for 12 randomly selected real MR images. This process was conducted for the SSIM algorithm, with a threshold of 0.11, and the automatically selected synthetic MR images were copied to a different folder created for the SSIM algorithm. Finally, for the PSNR algorithm, an acceptable similarity ratio range of 60-80 dB, commonly preferred for 16-24-bit grayscale images, was determined. The results obtained by the algorithms are presented in Table 1 after performing these processes for three different algorithms.

Table 1. Number of Images Automatically Separated According to Algorithms

MR Index	Number of Synthetic MR Images Separated Based on Valid Similarity Ratios			
	Compared Real MR Image	MSE	SSIM	PSNR
7	Brats18_2013_7_1_flair.ni_z036	182	295	8391
8	Brats18_CBICA_AAB_1_flair.ni_z033	319	155	8097
12	Brats18_CBICA_AME_1_flair.ni_z023	75	67	8175
62	Brats18_TCIA01_411_1_flair.ni_z005	19	40	8712
72	Brats18_TCIA02_171_1_flair.ni_z020	357	88	8266
79	Brats18_TCIA02_321_1_flair.ni_z021	285	109	8324
87	Brats18_TCIA02_605_1_flair.ni_z015	4	53	8623
92	Brats18_TCIA03_199_1_flair.ni_z027	10	140	7885
94	Brats18_TCIA03_498_1_flair.ni_z024	14	62	8635
96	Brats18_TCIA04_328_1_flair.ni_z020	95	227	8368
110	Brats18_TCIA08_205_1_flair.ni_z030	177	169	7804
119	Brats18_TCIA08_469_1_flair.ni_z019	27	88	8620

In Table 1, the index numbers and names of 12 real MR images randomly selected from the data set are given, and the numbers of synthetic MR images that are automatically separated as a result of comparing these images with 10000 MR images produced using the determined algorithms are given. When the comparison

was made using the MSE algorithm in Table 1, the most similar image among the synthetic MR images was the image with index number 72. As a result of comparing the same image with the SSIM algorithm, 88 images were selected, and as a result of comparing it with PSNR, 8266 images were selected. In the comparison made using the SSIM algorithm, the most similar image was the image with index number 7, while 182 images were selected as a result of comparing this image with the MSE algorithm, and 8391 images were selected as a result of the comparison with PSNR. While the most similar image selection using the PSNR algorithm was achieved with the image with index number 62, 19 images could be selected as a result of comparing this image with the MSE algorithm, and 40 images could be selected as a result of the comparison with SSIM. According to the table, 1564 images were parsed with the MSE algorithm, 1493 with the SSIM algorithm and a total of 99900 images were parsed with the PSNR algorithm.

Table 2 shows the number of MR images that can be added to the training data as a result of the verification of these separated synthetic MR images by the specialist doctor and their ratios to the separated images.

Table 2. Number of synthetic MR images verified by the expert

MR Index	Compared Real MR Image	Number and ratio of images separated by the expert								
		MSE			SSIM			PSNR		
7	Brats18_2013_7_1_flair.ni_z036	182	13	7.14%	295	69	23.39%	8391	868	10.34%
8	Brats18_CBICA_AAB_1_flair.ni_z033	319	216	67.71%	155	59	38.06%	8097	861	10.63%
12	Brats18_CBICA_AME_1_flair.ni_z023	75	14	18.67%	67	8	11.94%	8175	871	10.65%
62	Brats18_TCIA01_411_1_flair.ni_z005	19	3	15.79%	40	5	12.50%	8712	878	10.08%
72	Brats18_TCIA02_171_1_flair.ni_z020	357	122	34.17%	88	12	13.64%	8266	873	10.56%
79	Brats18_TCIA02_321_1_flair.ni_z021	285	46	16.14%	109	14	12.84%	8324	867	10.42%
87	Brats18_TCIA02_605_1_flair.ni_z015	4	1	25.00%	53	11	20.75%	8623	869	10.08%
92	Brats18_TCIA03_199_1_flair.ni_z027	10	4	40.00%	140	39	27.86%	7885	877	11.12%
94	Brats18_TCIA03_498_1_flair.ni_z024	14	6	42.86%	62	12	19.35%	8635	915	10.60%
96	Brats18_TCIA04_328_1_flair.ni_z020	95	13	13.68%	227	34	14.98%	8368	867	10.36%
110	Brats18_TCIA08_205_1_flair.ni_z030	177	136	76.84%	169	60	35.50%	7804	865	11.08%
119	Brats18_TCIA08_469_1_flair.ni_z019	27	7	25.93%	88	8	9.09%	8620	978	11.35%

When the values in Table 2 are examined, it is observed that the images with high rates of verification are the images selected using the MSE algorithm. According to Table 2, the real MR image in which the most correct image was selected was the image with index number 110 with an accuracy of 76.84%. When this image was compared with the MSE algorithm, 177 similar images were found and 76.84% of them were determined to be the desired type of MR image. When the values of the same image for other algorithms were examined, it was determined that there were 169 images separated using the SSIM algorithm and 35.5% of these images were the desired type of MR image. In the PSNR algorithm, 865 of 7804 images were determined to be suitable.

When the ratios of verified images to parsed images according to the algorithms in Table 2 were examined, it was determined that the images parsed by the MSE algorithm and SSIM algorithms were more similar to the real MR image. While it has been determined that in these two algorithms, attention is paid to the similarity of the images separated from the produced synthetic images to the compared MR image, the PSNR algorithm pays attention to depth, resolution, etc. apart from the similarity of the two images in the comparison. Since it includes features such as, it considered the images in almost the entire data set to be similar.

Figure 5 shows the ratio of the separated images and expert-verified images as a result of comparing the algorithms with the synthetic MR images produced according to each image selected from the data set. According to Figure 5, it was seen that the images parsed with the MSE algorithm were more similar to the selected images.




Figure 5. Rates of images verified according to algorithms

Some studies in the literature show that the production of medical images using the GAN method helps improve the performance of classification or clustering algorithms. In their study for the detection of abnormalities in the brain, Raja and Vijayachitra developed a different method using Gan, K-means and MobileNet algorithms and models. In this study, they used the Gan model to produce synthetic images from real MR images. According to the results of the study, the proposed model achieved the best scores among different models with 98% image similarity rate, 99% accuracy rate and 98% F1-score values [11].

In another study, Kazuhiro and his colleagues created a training data set from MR images of the T1 sequence and used the DCGAN method to obtain new images from these images. In the study, images were examined by 5 different radiologists to distinguish the images produced by DCGAN. As a result, it has been revealed that the images produced by the DCGAN model can be used in the enlargement of the data set [12].

In this study, a method was applied to eliminate the lack of data sets that are frequently encountered in deep learning studies carried out with medical image data. In this method, it is aimed to prevent loss of labor and time in the verification phase of MR images produced with GAN while eliminating the missing training data in studies based on the processing of medical images. At this point, this study carries out an automatic image selection and parsing process based on the similarities of real and synthetic images with MSE, SSIM and PSNR algorithms, taking into account the type of synthetic images produced. In other words, instead of selecting thousands of synthetic images produced one by one, it is aimed to automatically select those that are similar to the sample images and then consult an expert opinion.

When we look at the numbers in Table 1 based on the results, it is observed that the MSE and SSIM algorithms produce values close to each other, while the images selected by the PSNR algorithm are almost all of the images produced. Here, since MSE and SSIM algorithms are similar algorithms, similar results were obtained as a result of the comparison processes. As a result of the parsing processes performed with the MSE algorithm, a total of 1564 images were selected from 10000 synthetic MR images, and when these images were parsed by the specialist doctor, it was determined that 581 of them could be added to the training data as MR images. Here, the ratio of images selected by the MSE algorithm to verified images was 37.15%. The SSIM algorithm selected 1493 images and 331 of these images were verified by the specialist doctor. The success rate of the SSIM algorithm was calculated as 22.17%. Since the PSNR algorithm makes comparisons by focusing more on the quality of the image, the results here show that it is not correct to use the PSNR algorithm for the purpose of this study. Because when we look at the comparison results obtained with the PSNR algorithm, it is seen that almost 80% of 10000 synthetic images are selected for each real image and that there are many images that do not resemble MR images. In the parsing process performed with the PSNR algorithm, a total of 99900 images were selected in 12 comparisons, and as a result of the verification of these images, 10589 images were selected, resulting in a low verification rate of 10%.

In line with these results, while MSE and SSIM algorithms are preferable algorithms in the stage of parsing medical images by comparing them according to their similarities and determining the data to be added to the training data set, it has been clearly seen that the PSNR algorithm is not suitable for the purpose of the study.

It turns out that the MSE and SSIM algorithms used in the study are preferable image processing algorithms in order to reduce the time lost and labor spent in the post-reproduction stage of the images in different studies where images similar to the biomedical image types preferred in this study are used and in studies where synthetic images or similar images in different data sets are used. has been placed.

## Conflict of Interest Statement

The authors declare that there is no conflict of interest.

## References

- [1] A.G. Eker and N. Duru, "Medikal görüntü işleme derin öğrenme uygulamaları," *Acta Infologica*, vol. 5, no. 2, pp. 459-474, 2021. doi:10.26650/acin.927561
- [2] U. Kaya, A. Yılmaz and Y. Dikmen, "Sağlık alanında kullanılan derin öğrenme yöntemleri," *Avrupa Bilim ve Teknoloji Dergisi*, vol. 16, pp. 792-808, August 2019. doi:10.31590/ejosat.573248
- [3] H. Chen, Z. Qin, Y. Ding, L. Tian and Z. Qin, "Brain tumor segmentation with deep convolutional symmetric neural network," *Neurocomputing*, vol. 392, pp. 305-313, 2020. doi: 10.1016/j.neucom.2019.01.111
- [4] G. Çelik and M. F. Talu, "Çekişmeli üretken ağ modellerinin görüntü üretme performanslarının incelenmesi," *BAUN Fen Bil. Enst. Dergisi*, vol. 22, pp. 181-192, 2020. doi: 10.25092/baunfbed.679608
- [5] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, Aaron Courville and Yoshua Bengio, "Generative adversarial nets," *Proceedings of the 27th International Conference on Neural Information Processing Systems, 2014*, Available: NeurIPS Proceedings, [https://proceedings.neurips.cc/paper\\_files/paper/2014/hash/5ca3e9b122f61f8f06494c97b1afccf3-Abstract.html](https://proceedings.neurips.cc/paper_files/paper/2014/hash/5ca3e9b122f61f8f06494c97b1afccf3-Abstract.html). [Accessed: 20 August. 2023].
- [6] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning", *J Big Data*, vol. 6, pp. 60, 2019. doi: 10.1186/s40537-019-0197-0
- [7] Y. Liu, J. Zhang, T. Zhao and Z. Wang, "Reconstruction of the meso-scale concrete model using a deep convolutional generative adversarial network (DCGAN)", *Construction and Building Materials*, vol. 370, 2023. doi:10.1016/j.conbuildmat.2023.130704
- [8] R. Gonzalez and R. Woods, *Digital Image Processing*, Edition. 3, NJ: Pearson, 2008.
- [9] Z. Wang, A. Bovik, H. Sheikh and E. Simoncelli, "Image quality assessment: From error visibility to structural similarity," *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600-612. doi:10.1109/TIP.2003.819861.
- [10] M. Raja and S. Vijayachitra, "A hybrid approach to segment and detect brain abnormalities from MRI scan", *Expert Systems with Applications*, vol. 16, pp. 1-9, 2023. doi:10.1016/j.eswa.2022.119435
- [11] K. Kazuhiro, R. A. Werner, F. Toriumi, M. S. Javadi, M. G. Pomper, L. B. Solnes, F. Verde, T. Higuchi and S. P. Rowe, "Generative adversarial networks for the creation of realistic artificial brain magnetic resonance images", *Tomography*, vol. 4, no. 4, pp. 159-163, 2018. doi:10.18383/j.tom.2018.00042
- [12] C. Han, H. Hayashi, L. Rundo, R. Araki, W. Shimoda, S. Muramatsu, Y. Furukawa, G. Mauri and H. Nakayama, "GAN-based synthetic brain MR image generation," *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), Washington, DC, USA, 2018*, pp. 734-738. doi:10.1109/ISBI.2018.8363678.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICALAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## Determination and Comparison of Gamma Radiation Levels of Dried Fruits and Vegetables

Ismail Serkan Üncü<sup>a\*</sup>, Çağatay Bilge Keleş<sup>b</sup>

Submitted: 20.11.2023 Revised: 27.12.2023 Accepted: 27.12.2023 doi:10.30855/gmbd.0705S23

### ABSTRACT

**Keywords:** Gamma radiation, dried fruits and vegetables, gamma radiation levels

<sup>a,\*</sup> Isparta University Of Applied Sciences, Technology Faculty, Dept. of Electrical Electronics Engineering 32200 - Isparta, Türkiye  
Orcid: 0000-0003-4345-761X  
e mail: serkanuncu@isparta.edu.tr

<sup>b</sup> Isparta University Of Applied Sciences, Technology Faculty, Dept. of Electrical Electronics Engineering 32200 - Isparta, Türkiye  
Orcid: 0000-0001-6804-9327

\*Corresponding author:  
serkanuncu@isparta.edu.tr

Humans need food consumption to survive. Today, the effects of the fruits and vegetables we eat on our body are being investigated biologically. However, the radiation exposure taken from these foods to our body is not well known. Therefore, the radiation levels of these dried fruits and vegetables were determined with a special detector for approximately eight months in order to determine the level of gamma radiation from dried fruits and vegetables. Since our measurements are at hourly level, when we change 0.25 mSv/year hourly, the reference value is taken as  $2.85 \times 10^{-5}$  mSv/h. The dried fruits and vegetables in the experimental study are greenhouse tomato, organic tomato, rose petal, rose bud, lavender, apple, Jerusalem artichoke, bell pepper, bean, green pepper, cherry stalk, eggplant. Apart from these fruits and vegetables, gamma radiation levels were determined in the samples of sav soil and yalvac soil. The data obtained from the measurements were examined graphically and it was determined that the highest gamma radiation was in Jerusalem artichoke and the lowest level was in organic tomatoes. The result obtained here is that the gamma radiation in fruits and vegetables grown in soil and underground is high. Thus, this study is important because the radiation taken into our body through food can cause various diseases and hereditary disorders. The absence of a previous similar study in this field in our country will serve as a reference for similar studies to be conducted in the future.

## Kurutulmuş Meyve ve Sebzelerin Gama Radyasyon Düzeylerinin Belirlenmesi ve Karşılaştırılması

### ÖZ

İnsanoğlunun hayatta kalabilmesi için gıda tüketimine ihtiyacı vardır. Günümüzde yediğimiz meyve ve sebzelerin vücudumuz üzerindeki etkileri biyolojik olarak araştırılmaktadır. Ancak bu besinlerin vücudumuza aldığı radyasyonun etkisi çok iyi bilinmemektedir. Bu nedenle kurutulmuş meyve ve sebzelerin gama radyasyon düzeyinin belirlenmesi amacıyla yaklaşık sekiz ay boyunca bu kurutulmuş meyve ve sebzelerin radyasyon seviyeleri özel bir dedektörle belirlendi. Ölçümlerimiz saatlik düzeyde olduğundan saatlik  $0,25$  mSv/yıl değiştirdiğimizde referans değeri  $2,85 \times 10^{-5}$  mSv/h olarak alınmaktadır. Deneysel çalışmadaki kurutulmuş meyve ve sebzeler sera domatesi, organik domates, gül yaprağı, gül goncası, lavanta, elma, yer elması, dolmalık biber, fasulye, yeşil biber, kiraz sapı, patlıcandır. Bu meyve ve sebzelerin dışında sav toprağı ve yalvac toprağı örneklerinde de gama radyasyon düzeyleri belirlendi. Ölçümlerden elde edilen veriler grafiksel olarak incelendi ve en yüksek gama radyasyonunun yer elması, en düşük seviyenin ise organik domateste olduğu belirlendi. Buradan elde edilen sonuç toprakta ve yeraltında yetişen meyve ve sebzelerde gama radyasyonunun yüksek olduğudur. Dolayısıyla gıda yoluyla vücudumuza alınan radyasyonun çeşitli hastalıklara ve kalıtsal bozukluklara neden olabilmesi nedeniyle bu çalışma önemlidir. Ülkemizde bu alanda daha önce benzer bir çalışmanın bulunmaması, gelecekte yapılacak benzer çalışmalara referans teşkil edecektir.

**Anahtar Kelimeler:** Gama radyasyonu, kurutulmuş meyve ve sebzeler, gama radyasyonu seviyeleri

### 1. Introduction

Radioactivity is the process by which the unstable atomic nucleus undergoes spontaneous decay and becomes more stable, while emitting radiation to its surroundings in the form of particles or electromagnetic waves. The atomic nucleus that undergoes decay and emits radiation is called a radionuclide. The stability of a nucleus depends on the ratio between the neutron and the proton in the nucleus.

Generally, nuclei with an n/p ratio of less than 1.5 are stable or less stable, and nuclei larger than this value are unstable. Radionuclides with too many neutrons tend to convert a neutron into a proton in order to reach a more stable structure. Radioactivity can be natural or artificial. Figure 1 shows the path of a gamma or x-ray photon after hitting a surface. There are two reasons for using red LED light to make photosynthesis more stable and powerful. First, McCree curves show that wavelengths of red color between 600-700 nm are absorbed with high efficiency by pigments in plants; The second reason is that the most efficient color in lights is red at a wavelength of 660 nm, which is close to the highest level of chlorophyll absorption. In another study is to determine the natural radiation found in dried apricots. it has been investigated how much radiation Malatya apricot receives from nature during the growth stage and whether it is within the limits set by the International Atomic Energy Agency (IAEA) [1].




Figure 1. Gamma or X-Ray photon reflection

If the decayed radionuclide is found in nature or occurs spontaneously by the decay of other radionuclides in nature, it is called natural radioactivity. If radionuclides are produced by humans with external effects, it is called artificial radioactivity [2]. Depending on whether radiation has the ability to ionize atoms and molecules in the environment it interacts with, ionizing radiation (X-rays, γ-rays, alpha radiations, beta radiations, cosmic rays, neutrons, some of the ultraviolet) and non-ionizing radiation (infrared, radio waves, microwaves), visible light, low energy part of ultraviolet) are classified in two main categories [3]. The classification of radiation is shown in Figure 2.

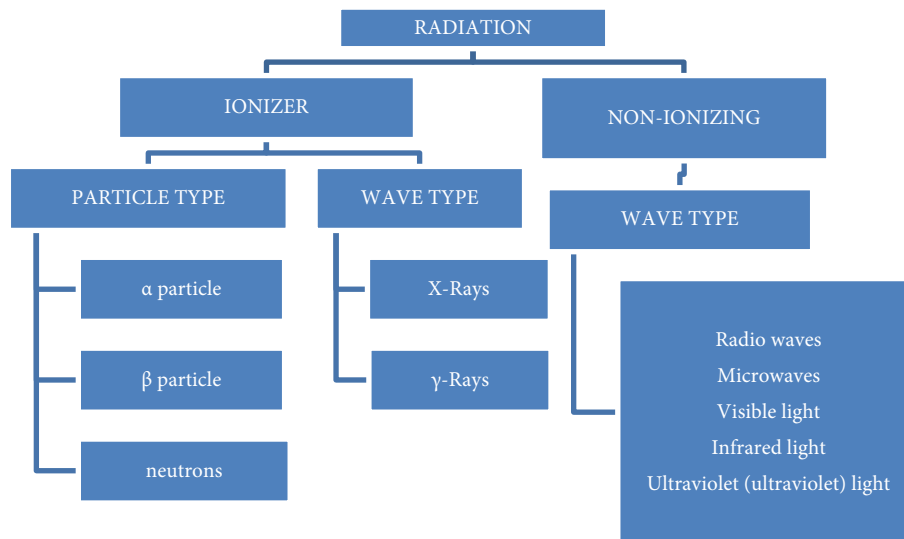


Figure 2. Classification of radiation

The unstable nucleus that emerges after neutron, alpha or beta radioactive decays in the nucleus can remain in the excited energy level and can go from the unstable state to the stable state with a second decay (by



emitting a photon). Photons emitted during this transition are called gamma rays ( $\gamma$ -rays). Gamma radiation, which emerges as a result of natural decay mechanisms, has energies between 0.1 and 10 MeV [4]. Three basic interactions that gamma rays can have with matter, depending on their energies, are given below (Table 1):

Table 1. Three basic interactions that gamma rays can have with matter, depending on their energies

Photoelectric Event	0.01 MeV to ~0.5 MeV
Compton Scattering from	0.1 MeV to ~10 MeV
Pair Formation starts at	1.02 MeV

Gamma rays with high penetration can enter the body directly and transfer their energy to the internal organs. Living things exposed to gamma radiation can be adversely affected. On the other hand, gamma rays, which are used in medical diagnosis and treatment such as X-rays, are armored with high-density materials such as lead and barite concrete. Naturally sourced  $\gamma$ -rays, which have the energy to pass through a few centimeters of lead, indirectly ionize the environment they are in.

Considering the distribution of natural radiation sources among themselves; It can be said that cosmic rays contribute to the natural radioactivity at the level of 0.39 mSv/year, gamma radiation at the level of 0.46 mSv/year, radon at the level of 1.30 mSv/year, and food and intrabody irradiation at the level of 0.25 mSv/year [5]. Since our study subject is gamma radiation in vegetables and fruits, this is an example of radiation exposure with intra-body irradiation. Therefore, the 0.25 mSv/year radiation level will be our reference level [6].

## 2. Materials and Methods

### 2.1. Importance and characteristics

Technical specifications of the device used: ASM-990 series; They are easy-to-use devices that detect alpha, beta, gamma, neutron or x-ray radiation, with an operating range of 1  $\mu$ R/hr to 1 R/hr or 1 to 5000000. It can measure different types of radiation depending on the probe selection. The results of the measured values and selectable parameters are instantly displayed on the analog/digital display.

With the probes of the device, it can work with Geiger-Mueller (GM) detectors, neutron probes, proportional counters and scintillation sensors between 500-1300 volts. The ASM-990 is used in health physics, medical physics and testing applications. Radiation safety officers (RSO), nuclear medicine laboratories, diagnostic x-ray and hospital emergency technicians and health physicists determine the radiation level instantly. Figure 3 shows the ASM-990 and the Geiger Müller device.



Figure 3. ASM-990-GM Probe (Model 489-110D)

The LCD screen on the device shows the digitized average of the graphic value. The length of the screen on the device is 5.6 cm. Measurement results range from 0.0001 to 1 million depending on the probe selected and the units activated. In addition, the LCD screen displays selected units of measurement, status icons and real-time clock. The error rate in the standard deviation is 10%. The temperature ranges from -10 °C to +50 °C. Relative humidity is between 0% and 95%. After 5 seconds, it can report the value of the measured item. It can measure 150 hours with existing batteries. The measurement units of the measuring device are shown in Figure 4. The units in the red lines are the units used in our preliminary study and show the units that we will continue to measure from now on.

$\mu\text{R/hr}$	mR/hr	R/hr
$\mu\text{rem/hr}$	mrem/hr	rem/hr
$\mu\text{Sv/hr}$	mSv/hr	Sv/hr
CPM	CPS	
DPM $^{99\text{m}}\text{Tc}$	DPS $^{131}\text{I}$	
Bq $^{125}\text{I}$	kBq $^{123}\text{I}$	MBq $^{201}\text{Tl}$
$\mu\text{Ci } ^{67}\text{Ga}$	mCi $^{18}\text{F}$	Ci $^{57}\text{Co}$
$\mu\text{R}$	mR	R
$\mu\text{rem}$	mrem	rem
$\mu\text{Sv}$	mSv	Sv
C (counts)	kC	MC
D (disintegrations)	kD $^{99\text{m}}\text{Tc}$	MC $^{131}\text{I}$

Figure 4. Unity values of the device in radiation measurement

## 2.2. Experimental procedure

With the ASM-990 detector, a total of 252000 measurements of 350 hours were carried out from dried greenhouse tomatoes, organic tomatoes, rose petals, rose buds, lavender and apple samples. When the average of the measurements was taken, it was seen that the greenhouse tomato had more gamma radiation than the organic tomato. The gamma dose level of the greenhouse tomato was found to be 140 nSv/h, and the gamma dose level of the organic tomato was found to be 72 nSv/h. The average gamma radiation level of rose petal was found to be approximately 128 nSv/h, that of rose bud 108 nSv/h, that of lavender 81 nSv/h, and that of apple 70 nSv/h. UNSCEAR reports that the indoor gamma dose rate level is 84 nGy/hr and the average absorbed gamma dose rate in outdoor air is 59 nGy/hr worldwide. Serving within the body of the Turkish Atomic Energy Agency (TAEK), RESA shares the data obtained with the European Radiological Data Exchange Platform. According to RESA data between January 1st and March 25th, 2016, Turkey's average outdoor gamma dose rate was reported as 92 nSv/hour. When these values are considered, it is seen that greenhouse tomato, rose leaf and rose bud are above these values. Lavender and apple were found to be close to the Turkey average. It is the evaluation of the graphical analysis of dried fruits whose gamma radiation level is examined and examined as the change of gamma dose levels according to the hour [7-9].

When measuring dried fruits and vegetables, the humidity and temperature of the environment is an important parameter. Therefore, the humidity and temperature of the environment were measured using the Raspberry Pi shown in Figure 5. To establish this circuit, Raspberry Pi (1), Breadboard (1), DHT11 Temperature and Humidity Sensor (1), 10k $\Omega$  resistor (1) and three Jumper cables (3 female-male) are used [10-11].




Figure 5. Raspberry Pi with DHT11 Integrated

Humidity and temperature values were measured using this circuit. There are codes that allow reading of humidity and temperature values from this system. The humidity and temperature values of the environment are important when determining the radiation level. Radiation varies according to humidity and temperature level. While measuring the gamma radiation levels in dried fruits, they were also analyzed together with the humidity and temperature values of the environment. In Figure 5., the humidity-temperature measurements of the environment were made with the integrated system installed using the humidity-temperature sensor and pressure sensor together with the Raspberry Pi. While looking at the gamma radiation level of dried fruits, the humidity and temperature values of the environment were also measured in the same hour and minute. It is thought that our system will continue to measure dried fruits until the final thesis period, and by taking more measurements, our experiments will be completed with an article study [11-13].

Asm-990 Radiation measuring device can measure alpha, beta and gamma radiation levels with its probes. The display of the ASM-990 device produced by the Fluke Biomedical company, which we determined the gamma radiation levels in dried fruits and vegetables that we have made and will continue to do, together

with the samples measured, is as in Figure 6.



Figure 6. Device and measurement samples

### 2.3. Findings and discussion

Figure 7 and figure 8 show a graphical study showing the gamma radiation level of organic tomatoes, greenhouse tomatoes.




Figure 7. Hourly variation of gamma dose level of organic tomato




Figure 8. Hourly variation of gamma dose level of greenhouse tomato

The average of the gamma dose level of the greenhouse tomato was found to be  $1.4 \times 10^{-4}$  mSv/h (4.9 times higher than the reference value), while the average of the gamma dose level of the organic tomato was  $7.2 \times 10^{-5}$  mSv/h (2.6 times higher than the reference value) was found. If we look at these two graphs, we can see that the greenhouse tomato has a much higher gamma radiation level than the organic tomato. As it can be understood from this analysis, organic tomatoes are seen as healthy in terms of radiation.

Figure 9 and figure 10 show a graphical study showing the gamma radiation level of the rose petal and the humidity-temperature values during the measurement.




Figure 9. Gamma radiation level of Rose Petal




Figure 10. Humidity and Temperature Values of Rose Petals

Figure 11 and figure 12 show a graphical study showing the gamma radiation level and humidity-temperature values during the measurement of rose buds.




Figure 11. Gamma radiation level of rose bud




Figure 12. Humidity and temperature values of rose buds

The history of the rose is at least as old as the history of humanity. The place and importance of the rose flower in human history is truly magnificent. In every period of history, the rose has attracted the attention of humanity and has become the favorite and the envoy of queens, sultans and rulers. Isparta is the first in the world in rose cultivation. Due to this situation, many products are obtained from the rose, which is an important source of livelihood in the region. At the beginning of these are foods such as rose water, rose jam, rose sherbet. In addition, important cosmetic products are obtained from roses. These are; Shampoo, cream, perfume, essence, oil and soap are products that people prefer personally. These products enter our body as food or as contact. It is very important to determine the radiation level of the rose, which the people of the region use almost from many sources. The results of rose petals and rose buds show that the rose bud has a much lower radiation level than the rose petal.

Figure 13 and Figure 14 show a graphical study showing the gamma radiation level of the lavender flower and the humidity-temperature values during the measurement.




Figure 13. Gamma radiation level of lavender




Figure 14. Humidity and temperature values of lavender

Lavender is the common name of plant species of Mediterranean origin that make up the genus *Lavandula* from the Lamiaceae family. Members of the lavender genus, which grow in a wide area from the islands of the Atlantic Ocean to the countries around the Mediterranean and to India, are plants with bush-like appearance and blooming blue, purplish or red flowers in the form of massive spikes. Lavender grows in the mountains at altitudes between 1000-1800 m. The flowers, which are dried and put in the cabinets, protect the clothes from insects. The essence used in dyeing is obtained from the English lavender (*Lavandula angustifolia*) species that grows at approximately 500 meters. Blackhead (*Lavandula stoechas*) flowers, which grow in the scrub regions of Western Anatolia, are used as a pain reliever and expectorant. The gamma radiation level of lavender, which is widely consumed and used, was measured as  $8.1 \times 10^{-5}$  mSv/h (2.8 times higher than the reference value).

Figure 15 and figure 16 show a graphical study showing the apple's gamma radiation level and humidity-temperature values during measurement.




Figure 15. Gamma radiation level of apple




Figure 16. Humidity and temperature values of apples

Apple is a type of fruit grown from the Rosaceae family. It is known that the name known as "alma" in Old Turkish comes from the word "al" (red), which is the color of the fruit. It is thought that the apple first appeared in Northern Anatolia, the Southern Caucasus, regions in the southwestern part of Russia, and around Central Asia (east of Kazakhstan). The species has spread all over the world from Central Asia. It has a very high nutritional value. The gamma radiation level of the apple, which is consumed too much, was found to be  $7 \times 10^{-5}$  mSv/h (2.4 times more than the reference value).

Figure 17 and figure 18 show a graphical study showing the gamma radiation level and humidity-temperature values during the measurement of the Jerusalem artichoke.




Figure 17. Gamma dose level of Jerusalem artichoke






Figure 18. Humidity and temperature variation of Jerusalem artichoke

The average of the gamma dose level of the Jerusalem artichoke is 19 times higher than the reference value and has the highest radiation level among all measurements. This product is consumed a lot by people who eat vegetarian. Due to this situation, it is reported by the World Health Organization that the radiation that will be taken into our body due to Jerusalem artichoke may cause mutations over time and cause many types of cancer.

Figure 19 and figure 20 show a graphical study showing the gamma radiation level of the soil and the humidity-temperature values during the measurement.




Figure 19. Gamma dose level of Sav soil

Sav is a town in the central district of Isparta. It is located on the Isparta-Antalya road. The name of the town before 2020 was Savköy (Wikipedia-2021). The geological units in the Isparta plain, where the city is established, are autochthonous and allochthonous. The geological unit belonging to the city center is; It is an alluvium consisting of clay, silt, sand and gravel. The origins of travertine in this alluvial unit are composed of tuffite, pumice, tuff and volcanic rocks. By looking at the gamma radiation of the soil here, the average of the gamma dose level of the savory soil was found to be  $3.33 \times 10^{-4}$  mSv/h (11.7 times higher than the reference value).

Figure 21 shows the graphic analysis showing the gamma radiation level of Yalvaç soil. The average moisture value of the soil measured in temperature and humidity values is 45%, and the average temperature value is 23 °C.




Figure 20. Gamma dose level of Yalvaç soil

Yalvaç is a district of Isparta province. The district is a very old settlement. As a result of the researches carried out in Yalvaç, the history of the settlement dates back to the Late Neolithic period and the Chalcolithic Age. Since Yalvaç has a very old settlement, it is thought that it would be important to examine the gamma dose level of the soil sample here.

Due to this situation, the gamma dose level of the soil here was examined and its average was found to be  $3.36 \times 10^{-4}$  mSv/h (11.8 times higher than the reference value). Figure 21 shows the graphic analysis showing the gamma radiation level of bell pepper. The average moisture value of the soil measured in temperature and humidity values is 48%, and the average temperature value is 22 °C.




Figure 21. Gamma dose level of bell pepper

The homeland of pepper is the Americas. The first pepper cultivation in history BC. It is known that it was made in 7500 BC and is among the first plant species grown in America, and the pepper culture spread rapidly from America to Europe and from there to China and India. It is very important to determine the level of radiation taken into our body from pepper, which is consumed too much in Turkey. It is obvious how much more radiation level can be obtained when the gamma dose level of bell pepper is found to be  $2.36 \times 10^{-4}$  mSv/h (8.28 times higher than the reference value).

Figure 22 and Figure 23 show a graphical study showing the bean's gamma radiation level and humidity-temperature values during measurement.




Figure 22. Bean gamma dose level




Figure 23. Moisture and temperature variation of beans

Bean (*Phaseolus vulgaris*) is an annual herbaceous plant originating from the genus *Phaseolus* of the legumes (Fabaceae) family, originating in Central America. Today, beans; It has been reported by various researchers that it has two gene pools, namely Central America (Mesoamerica) and South America (Andean) regions. In Turkey, juicy dishes are made as fresh and dried beans, and it is one of the most important vegetables of the Mediterranean table, used in salad making. The amount of radiation received by the bean, which is consumed too much, by intra-body irradiation is important. Therefore, by looking at the gamma radiation level of dried beans, it was found to be  $2.1 \times 10^{-4}$  mSv/h (7.36 times more than the reference value).

Figure 24 shows the graphic analysis showing the gamma radiation level of pepper. The average moisture value of the soil measured in temperature and humidity values is 44%, and the average temperature value is 20 °C.




Figure 24. Gamma dose level of black pepper

Hot pepper is the name given to different types of peppers with a hot taste. The long ones are called pointed and the smaller ones are called gin peppers. It is of American origin. It is used as a food and medicine material all over the world. Capsicum has been part of the human diet in America since 7500 BC. With the arrival of Europeans in America, it spread first in Spain and Portugal, then all over Europe and the world. By investigating the radiation level obtained from this product consumed on our tables, a gamma dose level of  $2.2 \times 10^{-4}$  mSv/h (7.7 times higher than the reference value) was obtained as a result of experimental studies. Attention should be paid to the consumption of these products, which are 7.7 times higher than the reference value.

Figure 25 and figure 26 show a graphical study showing the radiation level of the cherry stem and the humidity-temperature values during the measurement.




Figure 25. Gamma dose level of cherry stem




Figure 26. Humidity and temperature variation of cherry stalk

The homeland of the cherry, which is from the Rosaceae family, is the South Caucasus and North Anatolian lands. It is produced mostly in Aegean and Marmara Regions in Turkey. It is usually used plain or in desserts. It is especially recommended for children in developmental age and anemia patients, as it increases blood cells. Cherry stalk, which has attracted a lot of attention recently, is used in tea, water and cosmetic masks. The gamma radiation level taken into the body from this plant, which has so many uses, was found to be  $2.5 \times 10^{-4}$  mSv/h (8.8 times higher than the reference value).

Figure 27 and figure 28 show a graphical study showing the radiation level of eggplant and the humidity-temperature values during measurement.




Figure 27. Gamma dose level of aubergine




Figure 28. Humidity and temperature change in eggplant

Eggplant is a perennial variety that belongs to the Solanaceae family and grows as an annual in temperate climates and as a small tree in tropical climates. The first cultivation of eggplant was carried out in India in the 5<sup>th</sup> century BC. After this date, it was brought to Africa, then to the Eastern Mediterranean and Europe. It was brought to Europe by the Spanish in the 16<sup>th</sup> century. Eggplant, which was used as an ornamental plant when it was first brought to Europe, ranks 6<sup>th</sup> in the world among the fresh vegetables produced. Humans are the only living creatures that consume eggplant due to its low nicotine content. While it is a perennial plant in the tropics, it is an annual in climatic zones outside this zone.

In Turkey, it is mostly consumed in the form of imambayildi, karniyarik dishes and fries. Salad is also made. Radiation examination of the eggplant, which has a high consumption, was performed and the measurement result was obtained as  $2,4 \times 10^{-4}$  mSv/h (9.6 times more than the reference value).

Our experimental studies were carried out together with the graphical analysis of the hourly variation of gamma dose levels. According to these measured results, the change in gamma dose levels may vary according to the temperature, humidity and amount of ventilation of the environment.

### 3. Discussion and Conclusion

We stated that the gamma dose level of food and intrabody irradiation is 0.25 mSv/year. Since our measurements are hourly, when we change 0.25 mSv/year hourly, it becomes  $2.85 \times 10^{-5}$  mSv/h. Thus, the studies we have done show that the gamma dose level that we take into the body and that we are exposed to from the soil is much higher than this reference value. The average of the measurement results is as follows:

The average of the gamma dose level of the greenhouse tomato was found to be  $1.4 \times 10^{-4}$  mSv/h (4.9 times higher than the reference value), while the average of the gamma dose level of the organic tomato was  $7.2 \times 10^{-5}$  mSv/h (2.6 times higher than the reference value) was found.

Average gamma dose level of rose petal is approximately  $1.28 \times 10^{-4}$  mSv/h (4.5 times higher than reference value), rose bud  $1.08 \times 10^{-4}$  mSv/h (3.8 times higher than reference value), lavender 8, It was found to be  $1 \times 10^{-5}$  mSv/h (2.8 times more than the reference value), while that of apples was  $7 \times 10^{-5}$  mSv/h (2.4 times more than the reference value).

The average gamma dose level of Jerusalem artichoke is  $5.44 \times 10^{-4}$  mSv/h (19 times more than the reference value), the gamma dose level of the savanna soil is  $3.33 \times 10^{-4}$  mSv/h (11.7 times more than the reference value), the gamma dose level of the yalvaç soil mean level was found to be  $3.36 \times 10^{-4}$  mSv/h (11.8 times higher than the reference value). The gamma dose level of bell pepper is  $2.36 \times 10^{-4}$  mSv/h (8.28 times more than the reference value),  $2.1 \times 10^{-4}$  mSv/h of beans (7.36 times more than the reference value),  $2.2 \times 10^{-4}$  mSv of green pepper /h (7.7 times more than reference value),  $2.5 \times 10^{-4}$  mSv/h of cherry stem (8.8 times more than reference value),  $2,4 \times 10^{-4}$  mSv/h (9.6 times more than reference value) of eggplant The mean gamma dose levels were

measured. It is an important issue to note that all measured values are many times higher than the reference value, and it is an important issue to note that the Jerusalem artichoke has the highest gamma radiation average. It is noteworthy that the reference value is high in the measurements of products grown underground.

The fact that the fruits and vegetables we eat in order to maintain our daily life are exposed to too much radiation when we take them into the body and the possible disease reveals how much human health is threatened.

The absence of a similar study in this field in our country will serve as a reference for similar studies to be conducted in the future.

## Conflict of Interest Statement

Authors of this paper state that there is no conflict of interest.

## References

- [1] A. Şa, "Malatya'da Yetişen Kayıslarda Doğal Radyasyon Miktarı Tayini" Harran University, Institute of Science, Master Thesis, Şanlıurfa, Türkiye, 2022.
- [2] IAEA, "International Atomic Energy Agency. Radiation, people and the environment," *iaea.org*, IAEA/PI/A.75/04-00391, 2004. [Online]. Available: <https://www.iaea.org/sites/default/files/radiation0204.pdf>, [Accessed: Sept. 18, 2023].
- [3] A. Karadem, "Radon concentration measurements in caves with CR-39 detectors", Süleyman Demirel University, Institute of Science and Technology, Master Thesis, Isparta, Türkiye, 2011.
- [4] S. Akkoyun, "Direction Determination of Gamma Rays". Ankara University, Institute of Science and Technology, Master Thesis, Ankara, Türkiye, 2003.
- [5] A. S. Durrani, and I. Radomir eds. *Radon measurements by etched track detectors-applications in radiation protection, earth sciences*, London: World Scientific, 1997.
- [6] M. Tzortzis, H. Tsertos, S. Christofides, G. Christodoulides, "Gamma radiation measurements and dose rates in commercially-used natural tiling rocks (granites)." *Journal of environmental radioactivity*, vol.70, pp.223-225, May 2003.
- [7] N. Karunakara, I. Yashodhara, K. S. Kumara, R.M. Tripathi, S.N. Menon, S. Kadam, M.P. Chougankar, "Assessment of ambient gamma dose rate around a prospective uranium mining area of South India—a comparative study of dose by direct methods and soil radioactivity measurements." *Results in Physics*, vol. 4, pp. 22-27, June 2014. doi:10.1016/j.rinp.2014.02.001.
- [8] M. Karataşlı, "Hatay ve çevresinde çevresel gama radyasyon ölçümü." *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, vol.18.3, pp.780-785, December 2018.
- [9] H. M. Khan, M. Ismail, K., Khan, K. Akhter, "Measurement of radionuclides and gamma-ray dose rate in soil and transfer of radionuclides from soil to vegetation, vegetable of some Northern area of Pakistan using  $\gamma$ -ray spectrometry". *Water, Air, & Soil Pollution*, vol.219, pp.129-142, October 2011. doi 10.1007/s11270-010-0693-5.
- [10] A. Kumar, G.A. Shanmugha Sundaram, B.K. Sharma, S. Venkatesh, R. Thiruvengadathan, "Advances in gamma radiation detection systems for emergency radiation monitoring." *Nuclear Engineering and Technology* vol. 52, pp.2151-2161, May 2020. doi:10.1016/j.net.2020.03.014.
- [11] S. Moontaha, M.S. Rahman, M.S. Islam, S. Yeasmin, "Real-Time Environmental Gamma Radiation Dose Rate Measurement around Major Nuclear and Radiological Facilities in Bangladesh", *International Journal of Scientific Research and Management (IJSRM)*, vol.6, no.3, pp. 57-63, April 2018. doi: 10.18535/ijssrm/v6i3.fe03"
- [12] Y. Wu, S. Yan, J. Fan.,F. Zhang, Y. Xiang, Y. Xiang, J. Zheng, J. Guo, "Responses of growth, fruit yield, quality and water productivity of greenhouse tomato to deficit drip irrigation", *Scientia Horticulturae*, vol.275, pp. 102-111, January 2021. doi:10.1016/j.scienta.0639s
- [13] S. Firouzi, A. Khorshidi, J. Soltani-Nabipour, S. Mohsen, Z. M. Reza Ay, "Evaluation of gamma and electron radiations impact on vitamins for onion preservation," *Applied Radiation and Isotopes*, vol. 167, pp.67-77., October 2021. doi:10.1016/j.apradiso.2020.109442.

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## Crack Control in Buildings with a CNN-based Image Processing Measurement System Method

Ismail Serkan Üncü<sup>a</sup>, Mehmet Kayakuş<sup>b</sup>, Celal Alp Yavru<sup>c</sup>, Nabi İbadov<sup>d</sup>

Submitted: 05.12.2023 Revised: 20.12.2023 Accepted: 20.12.2023 doi:10.30855/gmbd.0705S24

### ABSTRACT

Cracks in buildings are a source of concern as they may indicate structural problems. Cracks in buildings are one of the major problems with concrete structures, as they affect the appearance of the building, compromise the integrity of the masonry, jeopardize building safety, and reduce the durability of the structure. Cracks in buildings can be a cause for concern and may indicate a potential structural problem that could jeopardize the safety and stability of the building. Understanding the root causes of these cracks is crucial to determining appropriate preventive measures and repair methods. In this study, crack and slope control in buildings was performed with an image processing-based measurement system developed using CNN deep learning algorithms. A dataset of 294 photographs was used for the study. The data were subjected to image processing, preprocessing, and detection with CNN. The accuracy rate is 0.9716 for the VGG-16 architecture and 0.9513 for the Inception-V3 architecture. It was concluded that there is no significant difference between the accuracy rates of the architectures. All vertical and horizontal cracks with a thickness of 2 mm and a continuity of 4 cm were detected. Thus, crack control in buildings can be done quickly and reliably, and building safety will be ensured.

**Keywords:** Building crack, Deep learning, Image Processing, Artificial Intelligence

<sup>a</sup> Isparta Uygulamalı Bilimler Üniversitesi,  
Teknoloji Fakültesi,  
Elektrik-Elektronik Mühendisliği  
Bölümü, 32200 - Isparta, Türkiye  
Orcid: 0000-0003-4345-761X  
e mail: serkanuncu@isparta.edu.tr

<sup>b</sup> Akdeniz Üniversitesi,  
Manavgat Sosyal ve Beşeri Bilimler  
Fakültesi,  
Yönetim Bilişim Sistemleri Bölümü  
07600 - Antalya, Türkiye  
Orcid: 0000-0003-0394-5862

<sup>c</sup> Isparta Uygulamalı Bilimler Üniversitesi,  
Teknoloji Fakültesi,  
Elektrik-Elektronik Mühendisliği  
Bölümü, 32200 - Isparta, Türkiye  
Orcid: 0000-0003-4932-0382

<sup>d</sup> Warsaw University of Technology,  
Faculty of Civil Engineering,  
Civil Engineering Department, Warsaw,  
Poland  
Orcid: 0000-0003-3588-9551

\*Corresponding author:  
mehmetkayakus@akdeniz.edu.tr

**Anahtar Kelimeler:** Bina çatlağı,  
Derin öğrenme, Görüntü İşleme,  
Yapay Zeka

## Binalarda Çatlak Kontrolünde CNN Tabanlı Görüntü İşleme Ölçüm Sisteminin Kullanılması

### ÖZ

Binadaki çatlaklar yapısal sorunlara işaret edebileceğinden endişe kaynağıdır. Binalarda çatlaklar, binanın görünüşünü etkilediği gibi, duvarın bütünlüğünü bozmakta, yapı güvenliğini tehlikeye atmakta ve yapının dayanıklılığını azalttığı için beton yapıların önemli sorunlarından biridir. Binalardaki çatlaklar endişe kaynağı olabilir ve binanın güvenliğini ve sağlamlığını tehlikeye atabilecek potansiyel bir yapısal soruna işaret edebilir. Bu çatlakların temel nedenlerini anlamak, uygun önleyici tedbirlerin ve onarım yöntemlerinin belirlenmesinde çok önemlidir. Bu çalışmada binalarda çatlak ve eğim kontrolü CNN derin öğrenme algoritmaları kullanılarak geliştirilen görüntü işleme temelli ölçüm sistemi ile gerçekleştirilmiştir. Çalışma için 294 fotoğraftan oluşturulan veri seti kullanılmıştır. Veriler görüntü işleme ön işlemlerden geçirilerek CNN ile tespiti gerçekleştirilmiştir. Doğruluk oranı VGG-16 mimarisinde 0,9716, Inception-V3 mimarisinde 0,9513'tür. Mimarilerin doğruluk oranları arasında önemli bir fark olmadığı sonucuna varıldı. İnşaatlarda kalınlığı 2 mm büyük 4 cm sürekliliği olan tüm dikey ve yatay çatlakların tespiti yapılmıştır. Böylece hızlı, güvenilir bir şekilde binalardaki çatlak kontrolü yapılabilecek ve bina güvenliği sağlanacaktır.



## 1. Giriş (Introduction)

Binalar ve diğer inşa edilmiş yapılar sürekli hareket halindedir ancak genellikle bu hareketler fark edilemeyecek kadar küçüktür. Bu hareket kusurlardan, zemin koşullarındaki değişikliklerden, temel oturmalarından, bina dokusundaki değişikliklerden vb. kaynaklanabilmektedir. Ancak binanın bu hareketi karşılayamaması durumunda çatlama meydana gelmesi olasıdır. Bina hareketinin neden olduğu çatlakların ve diğer bozulmaların görünümü, bina sakinleri için görsel açıdan itici ve rahatsız edici olabilir ve bunlar onarılmadığı takdirde yapının bütünlüğünü, güvenliğini ve sağlamlığını etkileyebilir.

Yollar, köprüler, binalar ve su kütlelerini içeren kilit altyapıdan kusur tespiti yapmak için çeşitli araçlar ve varlıklar elde etmek için yılda milyonlarca dolar harcanmaktadır. Yollar, köprüler, binalar ve kaldırımlar gibi sivil yapılar genellikle deprem gibi doğal afetlerden, patlama gibi feci olaylardan veya günlük kullanımdan kaynaklanabilecek aşırı fiziksel strese maruz kalmaktadır. Bu tür olaylar ya yapının tamamen çökmesine neden olabilir ya da genellikle çatlaklar şeklinde temsil edilen fiziksel hasara yol açabilir. Genellikle, altyapı bileşeninin yüzeyinde mikroskobik düzeyde çatlaklar ortaya çıkar. Bu çatlaklar bileşeni zayıflatır, yüklemeye kapasitesini azaltır ve yüzeyde süreksizliklere yol açar. Bu tür çatlaklar erken bir aşamada tespit edilirse, daha fazla hasar azaltılabilir. Ancak fark edilmeyen çatlaklar yüzeye yayılabilir ve yapının tamamen çökmesine neden olarak ölümlere, yaralanmalara ve maddi kayıplara neden olabilir [1].

İnşaat mühendisliğinde bina çatlakları genellikle tasarım, inşaat, çevre ve kullanım etkilerinden kaynaklanır. Bina çatlakları kaçınılmazdır. Çatlak, gerçek beton yüzeydeki önemli hasarlardan biridir. Çatlaklar, bölündüğü ancak ayrılmadığı katı bir malzemenin yüzeyinde ortaya çıkan küçük koyu çizgilerdir. Malzemenin büzülmesi ve genişmesi, değişen temeller, erken kuruma, aşırı yüklemeye, hidrostatik basınç, düzensiz karışım, şişen toprak, yetersiz toprak yatağı, sürünme hasarı, çökme ve çiftçilik, herhangi bir beton yüzeyde çatlaklara neden olabilir. Yorulma çatlakları, blok çatlakları, kenar çatlakları, boyuna çatlaklar, enine çatlaklar ve yansıma çatlakları en yaygın çatlak türleridir. Çıplak göz çatlakları basit kusurlar olarak görebilir. Bununla birlikte, küçük bir çatlak daha büyük ve daha tehlikeli bir soruna dönüşebilir. Arka plandaki karmaşık doku deseni nedeniyle bazı çatlakları görmek zordur [2].

Yapısal çatlaklar her türlü binada yaygın olarak görülen bir durumdur. Yapının uzun ömürlü olmasını sağlamak için mühendislerin sıklıkla bunların nedenlerini araştırması ve uygun onarımlar ve iyileştirici önlemler alması gerekir. Onarımların ve çözümlerin etkili olabilmesi için mühendisin çatlakların çeşitli oluşum nedenleri hakkında doğru bir anlayışa sahip olması önemlidir. Sebepleri araştırmak için yerin, şeklin, büyüklüğün, derinliğin, davranışın ve diğerlerinin dikkatli bir şekilde gözlemlenmesi gerekir. Doğal olaylardan inşaat hatalarına ve bakım sorunlarına kadar çeşitli faktörler binalarda çatlak oluşumuna katkıda bulunabilir. Çatlakların altında yatan nedenleri araştırarak bunları önlemek ve yapılarının uzun vadeli dayanıklılığını sağlamak için proaktif adımlar atılabilir [3].

Bina çatlaklarının en yaygın nedenlerinden biri yerleşimdir. Bu, temelin altındaki toprak sıkıştığında veya kaydığına, temelin batmasına veya yerleşmesine neden olduğunda meydana gelir. Bu, duvarlarda, tavanlarda ve bina zeminlerinde çatlaklara neden olabilir. Deprem, su baskını ve fırtına gibi doğal nedenler binalarda çatlaklara neden olabilir. Bu olaylar binanın kaymasına veya hareket etmesine neden olarak duvarlarda ve diğer yapısal elemanlarda çatlaklara yol açabilir. Nem ayrıca binalardaki çatlakların önemli bir nedeni olabilir. Su binanın içine sızdığına yapıyı zayıflatabilir ve malzemelerin genişleşip büzülmesine neden olarak çatlaklara neden olabilir. Aşırı sıcaklık değişiklikleri malzemelerin genişlemesine ve büzülmesine neden olarak çatlaklara neden olabilir. Bu özellikle donma-çözülme döngüleri gibi aşırı sıcaklık dalgalanmalarının olduğu alanlar için geçerlidir. Standartların altında malzemelerin kullanılması veya bina bileşenlerinin yanlış montajı dahil olmak üzere kötü inşaat uygulamaları, binada çatlaklara yol açabilir. Yakındaki inşaatlardan, trafikten veya ağır makinelerden kaynaklanan titreşimler binada çatlaklara neden olabilir. Asitlere veya diğer aşındırıcı maddelere maruz kalmanın neden olduğu spesifik kimyasal reaksiyonlar, yapı malzemelerini zayıflatabilir ve çatlaklara neden olabilir. Binalardaki çatlakların altında yatan nedenleri anlamak, bunların oluşmasını önlemek ve yapının güvenliğini ve sağlamlığını sağlamak için bunlara derhal müdahale etmek açısından çok önemlidir [4, 5].

Geleneksel bina çatlak ölçüm teknikleri, genişlik test cihazı, büyüteç gibi basit araçlardan oluşur; bunlar yalnızca düşük verimlilik sağlamakla kalmaz, aynı zamanda çalışanların uzun süre tehlikeli çalışma koşullarında kalmasına neden olur. Bu çalışma, görüntü işleme temelli ölçüm sistemini kullanarak binalarda

çatlak ve eğimi kontrol etmek için CNN derin öğrenme algoritmalarını kullandı. Çalışma, 294 fotoğraftan oluşan veri seti kullanarak yürütüldü. Görüntü işleme ön işlemleri, verilerin CNN ile tespitini sağladı.

## 2. Literatür (Literature)

Bina çatlaklarının ve sağlığının incelenmesi yaygın çalışılan bir araştırma konusudur. Geleneksel ölçüm sistemlerinin yerini yapay zekâ ve görüntü işleme sistemleri almaya başlamıştır. Bu bölümde binalarda çatlak kontrol sistemleri ele alınmıştır.

Yang ve arkadaşları duvarların ve kaldırımların görüntülerindeki çatlakların piksel düzeyinde segmentasyonu için tamamen evrişimli ağ (FCN) adı verilen bir CNN varyasyonu kullanıldı. FCN modeli, birden çok türde çatlak görüntüsü kullanılarak eğitilmiştir. FCN modeli tarafından tahmin edilen çatlak segmentlerini temsil etmek için yalnızca bir piksel genişliğine sahip piksel iskeletleri kullanılır. Bu çatlakların uzunluk, genişlik ve topoloji gibi morfolojik özellikleri daha sonra bu iskeletler kullanılarak ölçülür. Doğrulama için, model tarafından elde edilen çatlak segmentleri, zemin gerçeği ve FCN model çatlak tespit sistemleri tarafından üretilen sonuçlarla karşılaştırılır. Çatlak segmentasyon sistemi tarafından elde edilen genel doğruluk %97,96'dır [6].

Pauly ve arkadaşları kaldırım görüntülerindeki çatlakları tespit etmek için CNN'yi kullandı. Amerika Birleşik Devletleri'ndeki (ABD) kaldırımlardan akıllı telefonlar kullanılarak toplam 500 görüntü toplandı. Her görüntünün çözünürlüğü  $3264 \times 2448$  idi. Her görüntü daha sonra  $99 \times 99$  piksellik yamalara bölündü. Daha sonra, bu yamalar çatlaklı veya çatlaklı olarak etiketlendi. Deneysel sonuçlar, sinir ağının derinliğini artırarak daha iyi performans sonuçları elde edildiğini gösterdi. Bu çatlak tespit sistemi tarafından %91,3'lük bir doğruluk kaydedildi [7].

Soni araştırmasında beton çatlak resimlerinde anlamsal bölünme için derinlemesine, tamamen konvolüsyonel düzenlemeye (FCN) dayalı bir çatlak tespit tekniği önermektedir. FCN kodlayıcısında 40.000 adet  $227 \times 227$  piksel resimden oluşan açık, güvenilir bir çatlak veri kümesi üzerinde resim karakterizasyonu için değerlendirilmiştir. Çalışmanın başarı oranı %90 olmuştur [8].

Sohn ve arkadaşları izleme süresi boyunca çok zamanlı görüntülerdeki çatlakların değişimini ölçmek için bir çatlak izleme sistemi geliştirmişlerdir. Dijital kameradan bir dizi görüntü çekmişler ve görüntü işleme tekniklerini kullanarak dijital görüntülerden beton çatlaklarını çıkarmışlardır. Taşınabilir kameranın konumu ve yönü her pozlama süresinde değiştiği için aynı çatlakların görüntü koordinatları ve yönelimi değişebilmektedir. Çatlak değişikliklerini (genişlik ve uzunluk) izlemek için, her görüntüden çıkarılan çatlakların görüntü koordinatlarını, beton yüzeyin aynı nesne koordinatlarına dönüştürmek kritik öneme sahiptir. Çalışmalarında, bu geometrik ilişki, değiştirilmiş yinelenen Hough dönüşümü (MIHT) algoritmasını temel alan iki boyutlu projektif dönüşüm kullanılarak otomatik olarak kurtarılmış ve bunun sonucunda dönüşüm parametreleri çözülmüştür. Bunun sonucu olarak beton numunesindeki çatlakların değişimi başarıyla tespit edilmiş ve doğru bir şekilde ölçülmüştür [9].

Yamaguchi and Hashimoto çalışmalarında bir beton yüzey görüntüsü için süzülme modeline dayalı yeni bir çatlak tespit yöntemi geliştirmişlerdir. Bu yöntemde süzme işlemi otomatik olarak çıkarılan kenar noktalarından başlamakta, dolayısıyla hesaplama süresini azaltmak için her işlemin tüm görüntü bölgesinde tekrarlanmasına ihtiyaç kalmamaktadır [10].

Zheng ve Zhang çalışmalarında beton yapı hasarını anlamak için çatlak tespit modeli oluşturmuşlardır. Beton yapının verdiği hasarı çözmek için evrişimli sinir ağı modeli temel alınarak bir model önermişlerdir. Görüntü segmentasyon teknolojisi yardımıyla bina yüzeyinin özellikleri çıkarılmakta ve bina çatlaklarını tespit etmek için veriler derin öğrenme yöntemiyle analiz edilmiştir [11].

Kawamura ve arkadaşları hassas çatlak tespiti amacıyla görüntü işleme parametrelerinin yarı otomatik optimizasyonu için genetik algoritma kullanan bir yöntem önerdi. Ancak bu yöntemler, çatlakların bağlantısı gibi çatlakların temel özelliklerini dikkate almamaktadır. Wavelet dönüşümü gibi global işleme yöntemleri, tüm görüntünün özelliklerine odaklanmaktadır [12].

Ito ve arkadaşları çalışmalarında ince çatlak çıkarma yoluyla beton blokların muayenesi için otomatik bir ölçüm sistemi geliştirmişlerdir. Yüksek çözünürlüklü bir kamera kullanılarak, entegre görüntü işleme teknikleri kullanılarak çatlakların özellikleri otomatik olarak çıkarmışlardır. Bu önerilen yöntem yalnızca çok

ince çatlakların çıkarılmasını sağlamakla kalmayıp aynı zamanda yüksek kalitede çatlak analizini de gerçekleştirmektedir [13].

Hutchinson ve Chen çalışmalarında çatlak tespiti için görüntü işleme tekniklerinden faydalanmıştır. Çalışmalarında, çatlak tespiti için Canny filtresi ve Wavelet dönüşümünü kullandılar. Her pikselin çatlak olup olmadığını değerlendirmek için en uygun eşik seçimine karar verdiler [14].

Lu (2010), dijital görüntü işleme teknolojisine dayalı beton bina çatlak ölçümünün iki önemli yönünün görüntü işleme ve çatlak genişliği yorumunu inceledi ve bir çatlak genişliği ölçüm yöntemi önerdi [15]. Zhou ve arkadaşları beton yapıların çatlak tanımlama algoritmasını incelemiş ve mekansal özelliklere dayalı niceliksel bir analiz yöntemi önermiştir [16].

### 3. Materyal ve Yöntem (Material and Method)

Bu çalışmada, binadaki sütunların fotoğraflarını çekmek için bir kamera kullanılmış, böylece bilgisayar işlemleri sütunların yere ne kadar dik olduğunu belirlenmiştir. Fotoğraf çekerken hata yapmamak için, zeminin yatay düzlemine 90° dik olarak konumlandırılmış bir elektronik jiroskop kullanılmıştır. Çalışmada çatlak hesaplama için CNN algoritması ve görüntü işleme yöntemleri kullanılmıştır.

#### 3.1. Yapay Zekâ

Yapay zekâ, bir bilgisayarın veya bilgisayar kontrollü robotun, genellikle akıllı varlıklarla ilişkili görevleri yerine getirme yeteneğidir. 1950'li yılların başında Alan Turing'in "Makineler Düşünebilir Mi?" sorusuyla makine öğrenmesi kavramı ortaya çıkmış, Bilgisayar Bilimci ve Bilişsel Bilimci "John McCarthy" tarafından "Yapay Zekâ" terimi ilk kez düzenlenen yapay zekâ konferansı olan "Dartmouth Konferansı"nda 1956 yılında kullanılmıştır. Yapay zekanın alt çalışma alanlarından biri olan makine öğrenmesi, makinenin kendiliğinden mevcut matematiksel ve istatistiksel verileri kullanarak çıkarımlar yapabilmesi, bu çıkarımlar ışığında bilinmeyen noktalara dair tahminlerde bulunabilmesini sağlayan yöntemlerdir. 1967'de en yakın komşuları algoritması ile ilk makine öğrenmesi oluşturuldu. Makine öğrenimi sağlık, eğitim, iletişim başta olmak üzere birçok alanda kullanılmaktadır [17, 18].

Derin öğrenme bir veya daha fazla gizli katman içeren yapay sinir ağları ve benzeri makine öğrenme algoritmalarını kapsayan çalışma alanıdır. "Derin öğrenme" ifadesi ilk kez 2000'lerde ya da civarında, Igor Aizenberg ve meslektaşları tarafından yapay sinir ağları çalışmalarında kullanılmıştır [19].

#### 3.2. Evrişimli Sinir Ağları (Convolutional Neural Networks)


1980'lerde geliştirilmeye başlanan CNN mimarisi, 2012 yılına kadar makine öğrenmesi alanında kullanılmadı. 2012 yılında, büyük veri kümelerinin de kullanılmasıyla birlikte CNN mimarisi bu alanda da kullanılmaya başlandı. Evrişimli bir sinir ağı (CNN veya convnet), makine öğreniminin bir alt kümesidir. Farklı uygulamalar ve veri türleri için kullanılan çeşitli yapay sinir ağlarından biridir. Evrişimli sinir ağı, özellikle görüntü işleme ve tanıma görevleri için tasarlanmış bir tür derin öğrenme algoritmasıdır. CNN, derin öğrenme algoritmalarına yönelik bir tür ağ mimarisidir ve özellikle piksel verilerinin işlenmesini içeren görevler için kullanılır. Nesne tespiti, yüz tanıma, sahte haber tespiti CNN'lerin yaygın olarak kullanıldığı alanlardan bazılarıdır [20].

CNN hem zaman serilerindeki hem de görüntü verilerindeki önemli bilgileri ortaya çıkarabilen bir sinir ağı türüdür. Alternatif sınıflandırma modelleriyle karşılaştırıldığında CNN'ler, ham girdi görüntülerinden hiyerarşik özellik temsillerini otomatik olarak öğrenebildikleri için daha az ön işleme gerektirir. Yerel kalıpları tespit etmek için filtreler uygulayan evrişimli katmanlar aracılığıyla görüntülerdeki çeşitli nesne ve özelliklere önem verme konusunda uzmandırlar [21].

Bir CNN'in mimarisi insan beyninin bağlantı modeline benzemektedir. Beynin milyarlarca nörondan oluşması gibi, CNN'lerin de belirli bir şekilde düzenlenmiş nöronları vardır. Aslında, bir CNN'nin nöronları, görsel uyarıların işlenmesinden sorumlu olan beynin ön lobu gibi düzenlenmiştir. Bu düzenleme, görsel alanın tamamının kapsanmasını sağlar ve böylece geleneksel sinir ağlarının, görüntülerin düşük çözünürlüklü parçalar halinde beslenmesi gereken parça parça görüntü işleme probleminden kaçınılmasını sağlar. Eski ağlarla karşılaştırıldığında CNN, görüntü girişlerinin yanı sıra konuşma veya ses sinyali girişlerinde daha iyi

performans sağlar [22].

Derin öğrenme Şekil 1'de görüldüğü gibi CNN'si üç katmandan oluşur: Evrişim katmanı, havuzlama katmanı ve tam bağlantılı (FC) katmanı. Evrişimsel katman ilk katman, FC katmanı ise son katmandır. Evrişim katmanından FC katmanına doğru CNN'nin karmaşıklığı artar. CNN'nin bir görüntünün daha büyük bölümlerini ve daha karmaşık özelliklerini, sonunda nesneyi bütünüyle tanımlayana kadar başarılı bir şekilde tanımlamasına olanak tanıyan şey, bu artan karmaşıklığıdır [23].



Şekil 1. CNN katmanları (CNN layers)

Evrişimsel katmanı, hesaplamaların çoğunluğu, CNN'nin temel yapı taşı olan evrişim katmanında gerçekleşir. İkinci bir evrişim katmanı, ilk evrişim katmanını takip edebilir. Evrişim süreci, bu katmanın içindeki bir çekirdeğin veya filtrenin görüntünün alıcı alanları boyunca hareket ederek görüntüde bir özelliğin mevcut olup olmadığını kontrol etmesini içerir. Birden fazla yinelemede çekirdek, görüntünün tamamını tarar. Her yinelemeden sonra giriş pikselleri ile filtre arasında bir nokta çarpımı hesaplanır. Nokta dizisinden elde edilen sonuç, özellik haritası veya evrilmiş özellik olarak bilinir. Sonuçta görüntü bu katmanda sayısal değerlere dönüştürülür ve bu da CNN'nin görüntüyü yorumlamasına ve ilgili desenleri çıkarmasına olanak sağlar [24].

Havuzlama katmanı, evrişim katmanı gibi, havuzlama katmanı da giriş görüntüsü boyunca bir çekirdeği veya filtreyi tarar. Ancak evrişim katmanından farklı olarak havuz katmanı, girişteki parametre sayısını azaltır ve aynı zamanda bir miktar bilgi kaybına da neden olur. Olumlu tarafı, bu katmanın karmaşıklığı azaltması ve CNN'nin verimliliğini artırmasıdır [25].

Tamamen bağlı katmanı, önceki katmanlarda çıkarılan özelliklere dayanarak CNN'de görüntü sınıflandırmasının gerçekleştiği yerdir. Burada tam bağlı, bir katmandaki tüm girişlerin veya düğümlerin bir sonraki katmanın her aktivasyon birimine veya düğümüne bağlı olduğu anlamına gelir [26].

### 3.2. Jiroskoplar (Gyroscopes)

Jiroskop, taban hareketinden bağımsız olarak yönelimi koruyabilen ve üzerinde çeşitli yönlerde serbestçe dönebilen dönen bir diske sahip olan bir cihaz olarak tanımlanır. Bu nedenle dönme gerçekleşirken bu dönme ekseninin yönü değişmez. Bu, açısal momentumun korunumu kavramının kullanımını kolaylaştırır [27].

Jiroskop ilk kez 1817'de Alman fizikçi Johann Bohnenberger tarafından icat edildi. Bir gimbal ile asılı dönen bir diskten oluşan bu cihaz Dünya'nın dönüşünü göstermek için kullanıldı [28]. 1852'de Fransız fizikçi Jean-Bernard-Léon Foucault, "Foucault jiroskopu" adını verdiği yeni bir jiroskop türü icat etti. Foucault'nun jiroskopu Bohnenberger'inkinden daha doğruydü ve Dünya'nın dönüşünün ilk hassas ölçümlerini yapmak için kullanıldı [29]. 19. yüzyılın sonlarında jiroskoplar navigasyon, stabilizasyon ve rehberlik gibi çeşitli pratik uygulamalarda kullanılmaya başlandı. 1885 yılında Alman mucit Hermann Anschütz-Kaempfe ilk pratik jiroskop pusulasını icat etti. Jiroskop pusulaları gemilerde ve uçaklarda rotada kalmalarına yardımcı olmak için kullanıldı [30]. Jiroskoplar aynı zamanda ilk uçak ve uzay araçlarında da yönlerini stabilize etmelerine ve kontrol etmelerine yardımcı olmak için kullanıldı. 1910 yılında Amerikalı mucit Elmer Sperry, uçuş sırasında uçakları dengelemek için kullanılan ilk uçak jiroskopunu icat etti [31].

Bu çalışma için tasarlanan jiroskop inşaatların yapımı sırasında kolonların dikliğini tespit etmek için kameranın yeryüzüne dik olmasını sağlamaktadır. Şekil 2'de çalışmada kullanılan kameralı elektronik jiroskop yer almaktadır.




Şekil 2. Çalışma için kameralı elektronik jiroskop  
(Electronic gyroscope with camera for operation)

Devre üzerindeki LCD ekrandan eğim açısı ve kamera hata değeri de görülebilmektedir. Bu çalışma için tasarlanan jiroskop inşaatların yapımı sırasında kolonların dikliğini tespit etmek için kameranın yeryüzüne dik olmasını sağlamaktadır.


### 3.2. Görüntü işleme (Image processing)

Çalışmada ilk olarak görüntü gri tonlamaya dönüştürülmüştür. Dijital fotoğrafçılıkta bir görüntü dönüştürme tekniğidir. Her türlü renk bilgisini ortadan kaldırır ve geriye yalnızca grinin farklı tonlarını bırakır; en parlak olanı beyaz ve en koyu olanı siyahtır. Ara tonları genellikle ana renkler (kırmızı, mavi ve yeşil) için eşit parlaklık seviyesine sahiptir. Gri tonlama, algoritmaların basitleştirilmesine yardımcı olur ve hesaplama gereksinimleriyle ilgili karmaşıklıkları ortadan kaldırır [32]. Şekil 3'te gri seviye dönüşümü uygulanmış kolon fotoğrafı görülmektedir.




Şekil 3. Gri seviye dönüşümü uygulanmış kolon  
(Column with gray level transformation)

Eşikleme, görüntünün analiz edilmesini kolaylaştırmak için görüntünün piksellerini değiştirdiğimiz bir tür görüntü bölümlenmesidir. Eşiklemeye, bir görüntüyü renkli veya gri tonlamalı bir ikili görüntüye, yani yalnızca siyah beyaz olan bir görüntüye dönüştürürüz. Eşikleme tekniğinde standart bir eşik değeri belirlenerek her piksel değeri eşik değeriyle karşılaştırılır. Piksel değeri belirtilen eşik değerinden küçükse değer 0'a, aksi takdirde maksimum değere ayarlanır. Eşikleme işleminden sonra sütun Şekil 4'te görülmektedir [33, 34].



Şekil 4. Gri seviyeli görüntünün eşikleme işlemi sonraki görüntüsü  
(Image of gray level image after thresholding)



Şekil 5. Kolonun Kenar çıkarma algoritmasının uygulanmasından sonraki görüntü  
(Image of the column after applying the edge extraction algorithm)

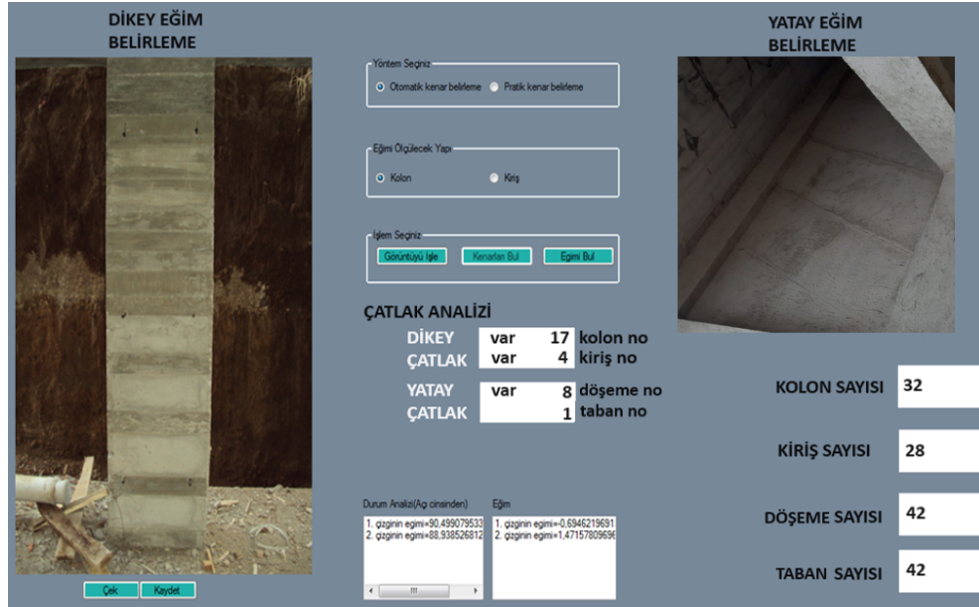
#### 4. Bulgular ve Tartışma (Results and Discussion)

Jiroskop üzerine monte edilmiş bir kamera, çeşitli yapılardan çeşitli kolon ve kirişlerin fotoğraflarını çekmek için kullanıldı ve bunlar daha sonra bina kolonlarının eğimini hesaplayan yazılımı oluşturmak için bilgisayar ortamına aktarıldı.

Bu çalışma sonucunda inşaat aşamasındaki bina kolonlarının dikliğini hesaplayan sistemin mekanik ve yazılım kısmı tamamlanmıştır. Çalışmada Şekil 6 görüldüğü gibi çeşitli binaların kolon ve kirişlerinden fotoğraflar alınarak bilgisayar ortamına aktarılmıştır. Şekil 7 'de program arayüz görüntüsü verilmiştir.




Şekil 6. Ölçüm alanı  
(Measurement area)




Şekil 7. Yazılım arayüzü  
(Software interface)

Duvar yüzey görünüm kalitesini belirlemek amacıyla filtreleme ve önişleme işlemlerinden sonra hesaplamalar yapılmıştır. Görüntü ikili görüntüye dönüştürüldükten sonra, beyaz pikseller sayılarak gerçek kusur alanları hesaplanmıştır. Fiziksel alanı referans olarak ölçmek için deneysel ölçüm yazılımı ImageJ kullanılmıştır. Duvar ve döşeme yüzeyine ölçü cetveli yerleştirilerek 100 mm<sup>2</sup>'ye karşılık gelen piksel değerleri belirlenmiştir. Şekil 8'te 100 mm<sup>2</sup>'lik bir alanın ölçüm adımları resimde verilmiştir.




Şekil 8. 100 mm<sup>2</sup>'lik bir alanın ölçüm adımları  
(Measurement steps of a 100 mm<sup>2</sup> area)



Şekil 9. Hesaplama yöntemi ve değerleri  
(Calculation method and values)

Bu görüntülerden alınan örneklere göre Şekil 10'daki görüntü veri seti oluşturulmuştur.



Şekil 10. Görüntü veri seti  
(Image data set)

Bu fotoğraflar sırasıyla gri seviyeli resme dönüştürme, eşikleme, çeşitli görüntü işleme filtrelerinden geçirme, kenar çıkarma algoritmalarıyla resmin işlenmesi, eğim hesaplama gibi aşamalardan geçirilmiştir. Kolonların dikliği ve kirişlerin yataylık derecesi görüntü işleme yazılım programı tarafından çeşitli işlemlerden geçirilerek başarı ile hesaplanmıştır. Kolon ve kirişin görüntülerinin işlenmesi sonucu elde edilen doğruların eğimleri açı cinsinden ve radyan olarak ayrı ayrı hesaplanmıştır.

Çalışmada veriler %20 eğitim ve %80 test verisi olarak ayrılmıştır. Veriler, çeşitli CNN mimarileri kullanılarak eğitilmiştir. CNN mimarilerinden VGG-16 mimarisi kullanılarak 'surface crack detection' veri seti eğitildi. Bu mimarinin eğitimi sonucunda doğruluk oranı 0,9716 oldu. Inception-V3 mimarisi ile yapılan eğitimin en yüksek doğruluk oranı 0,9513'tür. Mimarilerin doğruluk oranları arasında önemli bir fark olmadığı sonucuna varıldı. Çalışmada kalınlığı 2 mm ve devamlılığı 4 cm olan hem dikey hem de yatay tüm çatlaklar bulunmuştur.

### 3. Sonuçlar ve Tartışma (Results and Discussion)

İnşaat aşamasında bina kolonlarının diklik oranlarını belirleyen sistemin mekanik ve yazılım bileşenleri bu araştırmanın bir sonucu olarak tamamlanmıştır. Çalışmada çeşitli kolon ve kiriş fotoğrafları kullanılarak kolonların diklik oranını ve kirişlerin yataylık derecesini belirlemek için kenar çıkarma yöntemlerini kullanan bir algoritma hazırlandı. Kolon ve kiriş fotoğrafları işlendikten sonra, çizgilerin eğimleri açı ve radyan cinsinden bağımsız olarak belirlenmiştir.

Araştırma için 294 fotoğraf içeren bir veri seti kullanılmıştır. Doğruluk oranı VGG-16 mimarisinde 0,9716, Inception-V3 mimarisinde 0,9513'tür. Mimarilerin doğruluk oranları arasında önemli bir fark olmadığı sonucuna varıldı. Kalınlığı 2 mm ve devamlılığı 4 cm olan hem dikey hem de yatay tüm çatlaklar bulunmuştur.

Tasarımdaki hatalar, kalıp yağlarının uygunsuz kullanımı, betonarme kalıp yüzey malzemesinin türü, kalıplanmış beton yüzeylerde beton kabuğun mekanik ve fiziksel özelliklerini bozan yüzey kusurlarının



belirlenmesine ve önlenmesine yardımcı olacaktır.

İnşaat sektörü için şantiyelerin yapım aşamalarında kolon dikliğinin hesaplanmasına bu çalışma sayesinde yeni bir açıdan yaklaşılmıştır. Bu araştırma, rüzgâr türbini kuleleri, baz istasyonu kuleleri ve yüksek gerilim elektrik direkleri gibi bina dışındaki diğer alanlarda da kullanılabilir.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

- [1] H. S. Munawar, A. W. Hammad, A. Haddad, C. A. P. Soares and S. T. Waller, "Image-based crack detection methods: A review" *Infrastructures*, vol. 6, no. 8, pp. 115-135, 2021. doi: 10.3390/infrastructures6080115
- [2] M. Gonthina, R. Chamata, J. Duppalapudi and V. Lute, "Deep CNN-based concrete cracks identification and quantification using image processing techniques", *Asian Journal of Civil Engineering*, vol. 24, no. 3, pp. 727-740, 2023. doi: 10.1007/s42107-022-00526-9
- [3] G. L. Golewski, "The phenomenon of cracking in cement concretes and reinforced concrete structures: the mechanism of cracks formation, causes of their initiation, types and places of occurrence, and methods of detection—a review". *Buildings*, vol. 13, no. 3, pp. 765. 2023. doi: 10.3390/buildings13030765
- [4] C. J. Chitte and Y. N. Sonawane, "Study on causes and prevention of cracks in building". *International Journal for Research in Applied Science and Engineering Technology*, vol. 6, no. 3, pp. 453-461, 2018. doi: 10.22214/ijraset.2018.3073
- [5] Construction Placements, "Cracks in Buildings: Understanding the Causes, Prevention, and Repair Methods", *constructionplacements.com*, March 2, 2023. [Online]. Available: <https://www.constructionplacements.com/cracks-in-buildings>. [Accessed: Oct. 2023].
- [6] X. Yang, H. Li, Y. Yu, X. Luo, T. Huang and X. Yang, "Automatic pixel-level crack detection and measurement using fully convolutional network". *Computer-Aided Civil and Infrastructure Engineering*, vol. 33, pp. 1090-1109, 2018. doi: 10.1111/mice.12412
- [7] L. Pauly, D. Hogg, R. Fuentes and H. Peel, "Deeper networks for pavement crack detection". In *Proceedings of the 34<sup>th</sup> ISARC*, pp. 479-485, April 2017. doi: 10.22260/ISARC2017/0066
- [8] A. N. Soni, "Crack Detection in buildings using convolutional neural Network", *Journal for Innovative Development in Pharmaceutical and Technical Science*, vol. 2, no. 6, pp. 54-59, May 2019.
- [9] H. G. Sohn, Y. M. Lim, K. H. Yun and G. H. Kim, "Monitoring crack changes in concrete structures", *Computer-Aided Civil and Infrastructure Engineering*, vol. 20, no. 1, pp. 52-61, 2005. doi: 10.1111/j.1467-8667.2005.00376.x
- [10] T. Yamaguchi and S. Hashimoto, "Automated crack detection for concrete surface image using percolation model and edge information". *Proceedings of the 32<sup>nd</sup> annual conference on IEEE industrial electronics, Paris, France, April 2007*, New York: IEEE., 2007, pp. 3355-3360. doi: 10.1109/IECON.2006.348070
- [11] M. Zheng, Z. Lei and K. Zhang, "Intelligent detection of building cracks based on deep learning", *Image and Vision Computing*, vol. 103, pp. 103987, 2020. doi: 10.1016/j.imavis.2020.103987
- [12] K. Kawamura, A. Miyamoto, H. Nakamura and R. Sato, "Proposal of a crack pattern extraction method from digital images using an interactive genetic algorithm", *JSCE Journal*, vol. 60, no. 742, pp. 115-141, 2003. doi: 10.2208/jscej.2003.742\_115
- [13] A. Ito, Y. Aoki and S. Hashimoto, "Accurate extraction and measurement of fine cracks from concrete block surface image", in *28th Annual Conference of the Industrial Electronics Society. IECON 02, Sevilla, Spain, 5-8 Nov. 2002*, Piscataway, NJ: IEEE, 2002. pp. 2202-2207.
- [14] T. C. Hutchinson and Z. Chen, "Improved image analysis for evaluating concrete damage", *Journal of Computing in Civil Engineering, American Society of Civil Engineers*, vol. 20, no. 3, pp. 210-216, 2006. doi: 10.1061/(ASCE)0887-3801(2006)20:3(210)
- [15] X.P. Luo, J. Tian, Y. Zhu, J. Wang and R. Dai, "A survey on image segmentation methods", *Pattern Recognition*, vol. 12, no.3, pp. 300-312, 1999.
- [16] Q. X. Zhou, H. Q. Yuan, and Y. Y. Tao, "Research on 3D data model of apparent damage features for concrete structures". *Journal of Wuhan University of Technology*, vol. 32, no. 11, pp. 31-35, 2010.
- [17] M. Kayakuş ve F.Y. Açıkgöz, "Twitter'da makine öğrenmesi yöntemleriyle sahte haber tespiti", *Abant Sosyal Bilimler Dergisi*, vol. 23, no. 2, pp. 1017-1027, 2023. doi: 10.11616/asbi.1266179
- [18] M. Kayakuş, M. Terzioğlu, D. Erdoğan, S.A. Zetter, O. Kabas, and G. Moiceanu, "European Union 2030 carbon emission target: The case of Turkey", *Sustainability*, vol. 15, no. 17, pp. 13025, 2023. doi: 10.3390/su151713025

- [19] M. A. Kızrak ve B. Bolat, B, “Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma”, *Bilişim Teknolojileri Dergisi*, vol. 11, no. 3, 263-286, 2018. doi: 10.17671/gazibtd.419205
- [20] M. Kayakuş, and F. Y. Açıkgöz, “Classification of news texts by categories using machine learning methods,” *Alphanumeric Journal*, vol. 10, no. 2, pp. 55-166 2022. doi: 10.17093/alphanumeric.1149753
- [21] N. Ketkar, J. Moolayil, N. Ketkar and J. Moolayil, J. “Convolutional neural networks”, *Deep Learning with Python: Learn Best Practices of Deep Learning Models with PyTorch*, pp. 197-242, 2021. doi: 10.1007/978-1-4842-5364-9\_6
- [22] F. Türk, “Covid-19 Diagnosis using a deep learning ensemble model with chest X-Ray images”, *Computer Systems Science & Engineering*, vol. 45, no. 2, pp. 1357-1373, 2023. doi: 10.32604/csse.2023.030772
- [23] M.F. Aydoğdu, V. Celik, and M.F. Demirci, “Comparison of three different CNN architectures for age classification”, in *2017 IEEE 11th International conference on semantic computing (ICSC)*, pp. 372-377, 2017. doi: 10.1109/ICSC.2017.61
- [24] T.C. Lu, “CNN Convolutional layer optimisation based on quantum evolutionary algorithm”, *Connection Science*, vol. 33, no. 3, pp. 482-494, 2021. doi: 10.1080/09540091.2020.1841111
- [25] D. Yu, H. Wang, P. Chen and Z. Wei, (2014). “Mixed pooling for convolutional neural networks”, *Rough Sets and Knowledge Technology: 9<sup>th</sup> International Conference*, Shanghai, China, 2014, pp. 364-375. doi: 10.1007/978-3-319-11740-9\_34
- [26] K. Liu, G. Kang, N. Zhang and B. Hou, "Breast Cancer Classification Based on Fully-Connected Layer First Convolutional Neural Networks," *IEEE Access*, vol. 6, pp. 23722-23732, 2018, doi: 10.1109/ACCESS.2018.2817593.
- [27] W.F. Osgood, “On the gyroscope”, *Transactions of the American Mathematical Society*, vol. 23, no. 3, pp. 240-264, 1992. doi: 10.1090/S0002-9947-1922-1501201-7
- [28] F. J. Wagner and A. Trierenberg, “The machine of bohnenger: bicentennial of the gyro with cardanic suspension”, *Proceedings in Applied Mathematics and Mechanics*, vol. 10, no.1, pp. 659-660, 2010. doi: 10.1002/pamm.201010322
- [29] M.W. Davidson, “Pioneers in optics: jean-bernard-leon foucault and willebrord snell”, *Microscopy Today*, vol. 19, no.1, pp. 44-46, 2011. Doi: 10.1017/S155192951000115X
- [30] J. Broelmann, “Hermann anschütz-kaempfe-richtungsweiser ohne spuren”, *Deutsches Schiffsarchiv*, vol. 25, pp. 41-55, 2002.
- [31] F.S. Wickware, “Elmer sperry and his magic top”, *Scientific American*, vol. 169, no.2, pp. 66-84, 1943. Doi: 10.1038/scientificamerican0843-66
- [32] I.S. Üncü and M. Kayakuş, “Analysis of visibility level in road lighting using image processing techniques”, *Scientific Research and Essays*, vol. 5, no. 18, pp. 2779-2785, 2010.
- [33] L.K. Huang and M.J.J. Wang, “Image thresholding by minimizing the measures of fuzziness”, *Pattern recognition*, vol. 28, no. 1, pp. 41-51, 1995. doi: 10.1016/0031-3203(94)E0043-K
- [34] V.M. Dharampal, “Methods of image edge detection: A review”, *Electrical & Electronic Systems*, vol. 4, no. 2, pp. 2332-0796, 2015. doi: 10.4172/2332-0796.1000150

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICALAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



# GAZI

## JOURNAL OF ENGINEERING SCIENCES

### Hyper Parameter Analysis in Recognition of Handwritten Digits Using Convolutional Neural Network

Tuncay Yiğit<sup>a</sup>, Şerafettin Atmaca<sup>b</sup>, Remzi Gürfidan<sup>c</sup>, Recep Çolak<sup>d</sup>

Submitted: 28.11.23 Revised: 18.12.2023 Accepted: 19.12.2023 doi:10.30855/gmbd.0705S25

#### ABSTRACT

**Keywords:** Convolutional Neural Network, Hyperparameter Tuning, Deep Learning

<sup>a,\*</sup> Süleyman Demirel University,  
Faculty Of Engineering,  
Dept. of Computer Engineering  
32200 - Isparta, Türkiye  
Orcid: 0000-0001-7397-7224  
e mail: tuncayyigit@sdu.edu.tr

<sup>b</sup> Isparta University Of Applied Science,  
Dept. of Information Technology  
32200 - Isparta, Türkiye  
Orcid: 0000-0003-2407-1113

<sup>c</sup> Isparta University Of Applied Science,  
Yalvaç Technical Sciences Vocational  
School  
32200 - Isparta, Türkiye  
Orcid: 0000-0002-4899-2219

<sup>d</sup> Isparta University Of Applied Science,  
Distance Education Vocational School  
32200 - Isparta, Türkiye  
Orcid: 0000-0002-7119-6202

\*Corresponding author:  
serafettinatmaca@isparta.edu.tr

**Anahtar Kelimeler:** Evrişimli Sinir Ağı, Hiper parametre, Derin Öğrenme

Recognition of handwritten digits has recently gained importance and attracted the attention of many scientists, as it is used in many machine learning, deep learning and computer vision applications. Hyperparameter optimization involves determining a set of values aimed at increasing accuracy in both classification and prediction. It is also aimed to optimize the performance in feature selection by regulating the parameters selected by the algorithms more accurately. In this study, a convolutional neural network was used to recognize handwritten digits using the MNIST dataset. There are many open source hyperparameter libraries that deep learning developers can use to determine hyperparameters. In the developed model, hyperparameter optimization techniques were applied using Optuna, HyperOpt and Scikit-optimize libraries and the results were evaluated. Optimization times for hyperparameter libraries and the change in the success rate in recognizing handwritten digits were analyzed. The model trained with randomly given parameters achieved 78.45%, 97.13%, 75.62%, 76.95%, 97.46% and 97.27% accuracy, while the model trained with optimized hyperparameters achieved 99.26% accuracy.

### Evrişimli Sinir Ağı Kullanarak El yazısı Rakamların Tanınmasında Hiper Parametre Analizi

#### ÖZ

El yazısı rakamların tanınması birçok makine öğrenimi, derin öğrenme ve bilgisayarla görme uygulamalarında kullanıldığından, son zamanlarda önem kazanmış ve birçok bilim insanının ilgisini çekmiştir. Hiper parametre optimizasyonu, hem sınıflandırma hem de tahmin etmede doğruluğu artırmayı amaçlayan bir dizi değerlerin belirlenmesini içermektedir. Ayrıca algoritmalar tarafından seçilen parametreler daha doğru şekilde düzenlenerek özellik seçiminde performansın optimize edilmesi de amaçlanmaktadır. Bu çalışmada MNIST veri seti kullanılarak el yazısı ile yazılmış rakamların tanınmasında evrişimli sinir ağı kullanılmıştır. Hiper parametre belirlemede derin öğrenme geliştiricilerinin kullanabileceği birçok açık kaynaklı hiper parametre kütüphanesi mevcuttur. Geliştirilen modelde Optuna, HyperOpt ve Scikit-optimize kütüphaneleri kullanılarak hiper parametre optimizasyon tekniklerinin uygulaması yapılmış ve sonuçlar değerlendirilmiştir. Hiper parametre kütüphaneleri için optimizasyon süreleri, el yazısı rakamların tanınmasında başarı oranındaki değişim analiz edilmiştir. Rastgele verilmiş parametrelerle eğitilen model %78,45, %97,13, %75,62, %76,95, %97,46 ve %97,27 doğruluk elde ederken, optimize edilmiş hiper parametrelerle eğitilen model ile %99,26 doğruluk elde etmiştir.

## 1. Giriş (Introduction)

Günümüzde, Yapay Zeka (YZ) bir çok alanda yaygın bir şekilde kullanılır hale gelmiştir. Teknolojide yaşanan gelişmelerle birlikte bilgisayarların işlem gücündeki artış, büyük miktardaki verilerin analiz edilmesini hızlandırmıştır. Yapay Zeka genel olarak insan zekasının yapabileceği işlemleri, bilgisayar teknolojileri ile yapılması olarak tanımlanmıştır [1]. Son yıllarda çeşitli denetimli ve denetimsiz öğrenme problemlerinin üstesinden gelmek için derin öğrenmeye dayalı yöntemlere büyük ilgi gösterildi. En yaygın kullanılan ve iyi bilinen yaklaşımlar arasında, girdi verilerinden önemli özellikleri otomatik olarak çıkarabilen bir tür sinir ağı olan evrişimli sinir ağları (CNN'ler) yer almaktadır. Evrişimli sinir ağlarının özellikleri, özellikle de çok boyutlu girdilerden özelliklerin çıkarılmasındaki yeterlilikleri, onları bilgisayarlı görme alanındaki sorunları çözmek için cazip bir seçenek haline getirmektedir [2]. Örüntü tanıma alanındaki önemli araştırma merkezlerinden biri de MNIST(Değiştirilmiş Ulusal Standartlar ve Teknoloji Enstitüsü)'tir. MNIST el yazısı rakam veritabanı, mükemmel araştırma ve pratik uygulamaları nedeniyle örüntü tanıma araştırmalarında büyük önem taşımaktadır. MNIST veri kümesi, her biri 28 x 28 piksel boyutunda olan ve makine öğrenimi modellerinin eğitimi ve test edilmesi için özel olarak oluşturulmuş 70.000 el yazısı rakamdan oluşur. Bu araştırma alanındaki en önemli gelişmelerden biri MNIST veri seti ve rakam tanıma için evrişimli sinir ağlarının (CNN) geliştirilmesidir [3].

Derin öğrenme algoritmaları genellikle eğitim süresi ve doğruluk gibi performans faktörlerini önemli ölçüde etkileyebilen kullanıcı tanımlı belirli hiper parametre değerlerine ihtiyaç duyar [4]. Hiper parametreler, ağ yapısının ve eğitim sürecinin çeşitli özelliklerinin değerlerini belirler. Hiper parametre örnekleri arasında öğrenme oranı, katman sayısı, gizli katmanlar, filtreler, bırakma oranı, yineleme sayısı, yığın boyutu, aktivasyon işlevi, optimize edici ve düzenleme yer alır. Bu parametrelerin ayarlanması, bir derin öğrenme modelinin geliştirilmesinde önemli bir adımdır. Hiper parametre ayarı manuel veya otomatik olarak yapılabilir. Ancak değerlerin manuel olarak seçilmesi verimli bir yöntem değildir ve daha fazla zaman alabilir [5]. Hiper parametre optimizasyonun temel amacı, hiper parametre ayarlama sürecini otomatikleştirerek kullanıcıların öğrenme modellerini gerçek sorunlara verimli bir şekilde uygulamasını sağlamaktır [6].

Bu çalışmada, öncelikle MNIST veri seti ile el yazısı rakamların evrişimli sinir ağı ile tanınması açıklanmış, derin öğrenme uygulamalarında kullanılan açık kaynak hiper parametre optimizasyon çerçeveleri incelenmiş ve Optuna, HyperOpt, Scikit-optimize kütüphaneleri kullanılarak hiper parametre optimizasyon tekniklerinin uygulaması yapılmıştır.

## 2. Literatür Taraması (Literature Review)

Bergstra vd. yapmış oldukları çalışmada, farklı hiper parametre optimizasyon algoritmalarını incelemektedir. Izgara arama, rastgele arama, Bayes optimizasyonu ve sıralı model tabanlı optimizasyon (SMBO) yöntemleri üzerinde durulmaktadır. Algoritmanın güçlü yönleri, zayıf yönleri ve kullanım senaryoları hakkında bilgiler sunulur [7]. Lindauer vd. Bayes Optimizasyonu için güçlü ve uyarlanabilir bir sistem olan SMAC3'ü geliştirmişlerdir. Bu model, kullanıcıların minimum sayıda yapılandırmayı değerlendirerek performansını hızlı bir şekilde artırmaya olanak tanır ve algoritmaları, veri kümeleri ve uygulamaları için en iyi sonuçları veren hiper parametre ayarlarını etkili bir şekilde belirlemelerine olanak tanır. [8]. Liv vd. yapmış oldukları çalışmada, bandit tabanlı bir hiper parametre optimizasyon yöntemi olan Hyperband üzerine bir çalışma yapmışlardır. Hyperband, bir dizi rasgele yapılandırmayı hızla ortadan kaldırarak en iyi performans gösteren hiper parametreleri bulmayı amaçlar. Makale, farklı uygulama senaryolarında Hyperband yaklaşımının etkinliğini, verimliliğini ve performansını tartışmaktadır [9]. Chooi vd. el yazısı karakter tanıma için evrişimli sinir ağına dayalı bir algoritma geliştirmeyi amaçlamışlardır. Oluşturulan modelde her karakter, saf özellik çıkarım sistemine girdi görevi gören ikili değerlerle tanımlanmıştır. Önerilen metod ile karakterlerin tanınma oranını %88,70 doğrulukla tespit edilmiştir. [10]. Khanday vd. yapmış oldukları çalışmada CIFAR10 ve FashionMNIST veri setlerini kullanarak görüntü sınıflandırmada filtre boyutunun hiper parametresi optimize etmişlerdir. Çeşitli filtre boyutlarına göre modellerin doğruluğu üzerindeki etkilerini analiz etmişlerdir. Deneyin sonuçları, filtre boyutu arttıkça doğruluğun azaldığını göstermektedir [11]. Seng vd, araştırmalarında MNIST veri setini analiz etmek için fast.ai'yi kullanmışlardır. Bu analizin odak noktası, CNN ResNet-18 modelini el yazısı rakamları doğru bir şekilde tanıyacak şekilde eğitmektir. Çalışmada GoogLeNet, ResNet-50, ResNeXt-50, MobileNet v2 ve Wide ResNet-50 olmak üzere beş farklı model kullanılmış ve nihai amaç, el yazısı rakamların tanınmasında hangi mimarinin en yüksek hassasiyeti sağladığını belirlemektir. Ayrıca araştırmacılar, beş modelin tamamı için eğitim süresini, en üst sıradaki hata oranlarını, ilk beş hata


oranını ve model boyutlarını karşılaştırmışlardır. [12]. Shao vd. eğitimde hızlı yakınsama oranıyla MNIST el yazısı rakam veri setinin tanınma oranını daha da artırmak için bir CNN modeli geliştirmiştir. Ortaya konulan model, özellik çıkarımını kolaylaştıran üç evrişim ve aktivasyon katmanından oluşan çok katmanlı bir derin öğrenme yapısını içermektedir. Ayrıca sınıflandırmayı mümkün kılmak için iki adet tamamen bağlantılı katman dahil edilmiştir. Tanıma performansını arttırmak için modelin hiper parametreleri optimize edilmiştir. Bu hiper parametreler toplu büyüklükleri, çekirdek boyutlarını, toplu normalleştirmeyi, aktivasyon fonksiyonunu ve öğrenme oranını içerir [13]. Bischl ve arkadaşları çalışmalarında, hiper parametre performans değerlendirme, hiper parametre optimizasyonunun makine öğrenimi işlem hatlarıyla nasıl birleştirileceği, çalışma zamanı iyileştirmeleri ve paralelleştirme de dahil olmak üzere hiper parametre optimizasyonu yürütülürken yapılması gereken önemli seçimler hakkında pratik tavsiyelerde bulunmuşlardır. [14]. Baldominos vd. bu çalışmada, CNN topolojilerinin tasarımını otomatikleştirmek için nöroevrimden yararlanmışlardır. Bunu başarmak için birleşik bir çerçeve oluşturmuşlar ve genetik algoritmalara ve gramer evrimine dayanan iki yenilikçi yaklaşım tasarlamışlardır. [15].

### 3. Meteryal ve Metot (Material and Method)

Bu bölümde el yazısı rakamların tanınmasında kullanılan MNIST veri seti, kullanılan evrişimli sinir ağı modeli, hiper parametre optimizasyonu ve açık kaynak hiper parametre kütüphaneleri incelenmiştir.


#### 3.1. Veri seti (Data set)

MNIST veri tabanı, rakamların tanınması için 0 ile 9 arasında değişen rakamlardan 60000 eğitim ve 10000 test verisi içermektedir. Her rakam 28\*28 boyutunda ve 784 piksellik gri seviyeli bir görüntüdür [16]. Veri setine ait bazı örnekler Şekil 1’de verilmiştir.



Şekil 1. MNIST veri seti örnekleri [17] (MNIST dataset examples)

Rakamlara ait verinin her pikseli, o pikselin parlaklığını veya koyuluğunu gösteren tek bir piksel değeriyle ilişkilendirilir; daha yüksek sayılar daha koyuyu gösterir. Bu piksel değeri 0 ile 255 arasında bir tamsayıdır. 0 ile 9 arasındaki rakamlara ait veri sayıları Şekil 2’de verilmiştir.



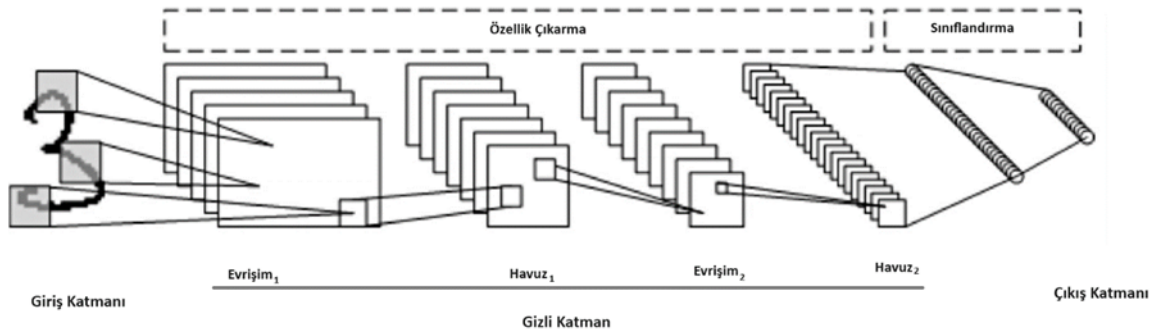
Şekil 2. Veri büyüklükleri (Data sizes)

MNIST, el yazısı rakamları tanımayı amaçlayan modellerin geliştirilmesi ve değerlendirilmesi için önemli bir veri kümesidir. Bu veri seti, araştırmacılara ve uygulayıcılara çeşitli rakam tanıma modellerinin performansını ve insan el yazısındaki varyasyonları ele alma kapasitelerini değerlendirme fırsatı sunar. MNIST, yıllar boyunca bilgisayarla görme ve makine öğrenimi alanında bir unsur olmuştur. Bu veri kümesi kullanılarak dijital görüntü tanıma için çok sayıda teknik geliştirilmiş ve değerlendirilmiştir. MNIST, çeşitli rakam tanıma

modellerini denemek ve karşılaştırmak için sağlam bir platform görevi görmektedir. Ayrıca, rakam görüntü tanıma alanındaki yeni kavramları, metodolojileri ve algoritmaları keşfetmek için bir temel oluşturmaktadır.

### 3.2. Evrişimli Sinir Ağı (Convolutional Neural Network)

Derin öğrenme, sınıflandırma, tanıma ve algılama gibi alanlarda karmaşık, doğrusal olmayan problemlerin üstesinden gelmek için oldukça etkili bir yöntem haline gelmiştir. Araştırmalarda yaygın olarak kullanılan derin öğrenme, birden fazla katmana sahip bir veya daha fazla yapay sinir ağı modeline dayanır [18]. Hayvanlardaki görsel korteksinin organizasyonuna dayanan [19] Evrişimli Sinir Ağı (CNN), görüntüler gibi ızgara benzeri bir yapıya sahip verileri analiz etmek için özel olarak oluşturulmuş bir derin öğrenme modelidir [20]. Bu yaklaşım 1989 yılında LeCun ve meslektaşları tarafından rapor edilmiş ve bilgisayarla görmede etkili sonuçlar göstermiştir [21]. Bir evrişimli sinir ağı giriş katmanı, çıkış katmanı ve çoklu gizli katmandan oluşur. Gizli katman, yinelemeli evrişim ve havuzlama katmanlarından oluşan bir ağ oluşturur ve sonuçta bir veya daha fazla tam bağlantılı katman elde edilir [22]. CNN'in mimarisi aşağıda açıklanmış ve Şekil 3'de gösterilmiştir.



Şekil 3. MNIST veri seti için CNN yapısına genel bakış (Overview of CNN structure for MNIST dataset)

#### 3.2.1. Giriş katmanı (Input layer)

Evrişimli Sinir Ağı'nın ilk katmanı olan bu bölüm ağa ham veri girişini gerçekleştirir ve görüntünün piksel değerlerini tutar [23]. Bu katmandaki veri boyutunun önemi, modelin performansını optimize etmenin anahtarıdır. Daha yüksek giriş görüntü boyutları daha iyi görüntü seçim seçenekleri sunarken, aynı zamanda test süresini uzatabilecek ve ağ performansını artırabilecek yüksek bellek ve eğitim süresi gereksinimleri de taşır. Giriş görüntüsü boyutu için daha az sayıda düğüm seçmek bellek gereksinimlerini azaltır ve eğitim süresini kısaltır [24]. Bu sebeple hazırlanan CNN modelinde giriş katmanına 28x28 çözünürlüğünde görseller sunulmaktadır.

#### 3.2.2. Evrişim katmanı (Convolutional layer)

Evrişim katmanı CNN'in temel bir bileşenidir ve bir çıktı oluşturmak için iki girdiyi konvolüsyonlayarak çalışır. Dikey ve yatay kayan filtreler aracılığıyla tüm bölgeyi kapsayan giriş görüntüsünün özelliklerini kaydeder [25]. Evrişim Katmanı giriş verileri ve bir çekirdek alınarak gerçekleştirilen bir özellik haritası çıkarmak için giriş verilerine uygulanır. Görüntü girdileri için çekirdek, 0 ve 1'lerden oluşan 2 boyutlu bir dizidir ve elde edilen çıktı şekli çekirdek boyutlarına bağlıdır. Filtre, tüm genişliği tarayana kadar belirli bir Adım Değeri ile giriş görüntüsü boyunca yatay olarak hareket eder. Ardından, aynı Adım Değeri ile görüntünün başına dikey olarak geri atlar ve tüm görüntü taranana kadar işlemi tekrarlar. Bu çıktı bir sonraki aşama için girdi görevi görür [26]. Oluşturulan evrişim modeli 1, 2 veya 3 katman olacak şekilde tasarlanmıştır.

#### 3.2.3. Havuz katmanı (Pooling layer)

Havuzlama katmanı, hesaplama yükünü azaltmak için ağ parametrelerini en aza indirmeyi amaçlar. Bu katman özellik haritalarının çözünürlüğünü azaltarak kayma varyansına ulaşmaya çalışır. Bu işlem görüntüde piksel kaybı oluşturabilirken bir sonraki katman için daha az hesap yükü oluşturur. Tipik olarak, iki evrişim katmanı arasına yerleştirilir ve bir havuzlama katmanının her bir özellik haritası, önceki evrişim katmanına

karşılık gelen özellik haritasına bağlanır [27]. Oluşturulan modelde havuz katmanı 1 ile 5 katman arasında olacak şekilde tasarlanmıştır.

### 3.2.4. Aktivasyon katmanı (Activation Layer)

Aktivasyon fonksiyonları, giriş verilerindeki doğrusal olmayan özelliklerin yakalanmasına yardımcı olarak uygulanan matematiksel işlemlerdir. Bu ağın daha karmaşık özellikleri öğrenmesini sağlar [28]. Bu çalışmada Sigmoid ve ReLU fonksiyonları uygulanmıştır. Şekil 4'te fonksiyonlara ait grafikler verilmiştir.

**Sigmoid Fonksiyonu:** Doymuş fonksiyonlardan biridir. Girdi aralığını 0 ile 1 arasına sıkıştırır. Çıktılarını olasılık değerleri olarak yorumlayabilmesi nedeniyle ikili sınıflandırma problemlerinde son katmanın aktivasyon fonksiyonu olarak yaygın kullanımı vardır [29]. Sigmoid fonksiyonu matematiksel olarak aşağıdaki gibi ifade edilir:


$$f(x) = 1/(1 + e^{-x}) \quad (1)$$

Bu fonksiyon, girdi değerleri arttıkça 1'e yaklaşır ve girdi değerleri negatifleştikçe 0'a yaklaşır.

**ReLU Fonksiyonu:** Giriş değeri pozitifse onu olduğu gibi bırakır, negatifse sıfıra eşitler [30]. Yani, ReLU fonksiyonunun matematiksel ifadesi şöyledir:

$$f(x) = \max(0, x) \quad (2)$$

ReLU, özellikle derin sinir ağlarında kullanıldığında eğitimi hızlandırabilir ve daha iyi sonuçlar elde edebilir. Bunun nedeni, ReLU'nun türevinin büyük çoğunlukla 1 veya 0 olmasıdır, bu da gradientleri daha iyi iletebilir hale getirir.



Şekil 4. Sigmoid ve ReLU Fonksiyon Grafikleri[34]  
(Sigmoid and ReLU Function Graphs)

### 3.2.5. Tam bağlantılı katmanlar (Fully connected layer)

Bu katman genelde CNN'in son katmanları olarak kullanılmaktadır. Hedef çıktı sonucuna ulaşmak için gerekli olan belirli "bileşen" karışımını belirleyerek önceki katmanın özelliklerinin matematiksel bir toplamını gerçekleştirirler. Tam bağlantılı bir katmanda, her bir çıktı özellik öğesinin hesaplanmasında önceki katmanın tüm özellik öğeleri kullanılır [31].

### 3.2.6. Çıkış katmanı (Output layer)

İleri beslemeli bir sinir ağında, çıkış katmanı nöron birimleri sabit kalır ve önceki nöronlarla tam bağlantılar kurar. Tahmin yapmak için nihai eşik görevi görürler [27].

## 3.3. Hiper parametre optimizasyonu (Hyper parameter optimization)

Hiper parametre optimizasyonu (HPO), sınıflandırma ve tahmin doğruluğunu iyileştirmeyi, özellik seçim performansını artırmayı ve daha hassas çalışmalar için algoritmalar tarafından seçilen parametreleri daha uygun şekilde ayarlamayı amaçlayan bir değerler kümesidir. Hiper parametre optimizasyonu, belirli bir zaman diliminde hiper parametre değerlerinin optimum kombinasyonunu bulmayı amaçlayan bir işlemdir.

Bu hedeflere ulaşmak için en uygun test algoritmasını seçmek çok önemlidir [32]. HPO algoritması yalnızca ayrık, sıralı ve sürekli değişkenleri optimize etmekle kalmaz, aynı zamanda hangi değişkenlerin optimize edilmesi gerektiğini de belirler [33]. Izgara Arama, Rastgele Arama, Bayes yöntemi Genetik Algoritma ve Parçacık Sürü Optimizasyonu en çok kullanılan hiper parametre optimizasyon teknikleri olarak karşımıza çıkmaktadır.

Makine öğrenimi algoritmalarında hiper parametrelerin ince ayarı, ortaya çıkan modelin performansı üzerinde doğrudan etkisi olan çok önemli bir süreçtir. Hiper parametrelerin ayarları manuel olarak ayarlanabilir veya otomatik olarak optimize edilebilir.

- *Manuel hiper parametre ayarı*, hiper parametre değerlerinin uzman bilgisine dayalı olarak ve deneme yanılma yoluyla belirlenmesi yöntemidir. Bu yaklaşımda, deneyimli uzmanların bilgi ve deneyimleri, hiper parametrelerin optimal değerlerini etkili bir şekilde belirleyebilir. Ancak, manuel kurulum zaman alıcı ve hataya açık olabilir [34].
- *Otomatik hiper parametre ayarı*, hiper parametre değerlerini otomatik olarak belirlemek için makine öğrenimi algoritmalarında kullanılan bir yöntemdir. Bu yaklaşım genellikle önceden belirlenmiş bir arama stratejisi veya optimizasyon algoritması kullanır. Örneğin izgara arama, rastgele arama, Bayes optimizasyonu ve genetik algoritmalar gibi yöntemler kullanılabilir. Otomatik hiper parametre ayarı, hiper parametrelerin optimal değerini daha etkili ve verimli bir şekilde bulmaya yardımcı olabilir [35].

### 3.3.1. Açık kaynak hiper parametre optimizasyon çerçeveleri (Open source hyper parameter optimization frameworks)

HPO sorunlarının üstesinden gelmek için derin öğrenime geliştiricilerinin kullandığı için birçok açık kaynak hiper parametre kitaplığı mevcuttur [36]. Bu bölümde, çalışmada kullanılan açık kaynaklı HPO kütüphaneleri olan Optuna, HyperOpt ve Scikit-optimize yer verilmiştir.

Hyperopt , optimizasyon algoritmaları olarak RS ve BO-TPE içeren bir HPO çerçevesidir. Yalnızca tek bir modeli destekleyen diğer bazı kitaplıkların aksine, Hyperopt, hiyerarşik hiperparametreleri modellemek için birden çok model kullanabilir. Ek olarak Hyperopt, hiperparametre kombinasyonlarını depolamak için merkezi veritabanı olarak MongoDB kullandığından paralelleştirilebilir. Hyperopt-sklearn ve hyperas , Hyperopt'u scikit-learn ve Keras kitaplıklarına uygulayan iki kütüphanedir [36].

2019'da geliştirilen açık kaynaklı bir hiperparametre ayarlama optimizasyonu olan Optuna, hiperparametre optimizasyonunun uyum-deneme ve hata hesaplama sürecini otomatikleştirir [37]. Optuna, hedefli bir API yaklaşımı kullanarak en iyi performans için optimum hiperparametre değerlerini belirler.

Skopt olarak da bilinen Scikit-optimize, Bayesian optimizasyon ve sıralı model tabanlı optimizasyon yöntemlerini birleştiren esnek bir kütüphanedir. Hiperparametrelerin verimli bir şekilde ayarlanmasını sağlayan basit optimizasyon fonksiyonları sağlar [38].

## 4. Deneysel Sonuçlar (Experimental Results)

Bu çalışmada Mnist veri seti kullanılarak el yazısı rakamların derin öğrenme ile tespiti ve hiper parametre optimizasyonu kullanılarak öğrenme başarısının artırılması ve optimizasyon analizlerini ortaya koymak hedeflenmiştir. Hiper parametre optimizasyonu için açık kaynak kodlu Hyperopt, Optuna ve Scikit-Optimize kütüphaneleri kullanılmıştır. Rastgele parametrelerle model çalıştırılmış ve elde edilen sonuçlar Tablo 1' de verilmiştir.

Tablo 1. Rastgele parametrelerle elde edilen sonuçlar (Results obtained with random parameters)

Optimize edicinin öğrenme oranı	Dönüşüm katmanlarının sayısı	Her yoğun katmandaki düğüm sayısı	Her yoğun katmandaki düğüm sayısı	Tüm katmanlar için aktivasyon fonksiyonu	Başarı Yüzdesi%		
					Optuna	HyperOpt	Sci-Opt
1e-05	2	3	256	Relu	78.45	75.62	76.95
1e-03	3	4	150	Relu	97.13	97.46	97.27



El yazısı rakamların tanınması için geliştirilen modelin eğitimi ve analizler, Python programlama dili kullanılarak I5 11400h işlemci, 40 GB Ram ve GTX 1650 Ekran kartına sahip bir bilgisayarda gerçekleştirilmiştir. Geliştirilen CNN modeli için epoch sayısı 3 ve batch size değeri 128 olarak belirlenmiştir. Her hiper parametre tekniği için hiper parametre uzayı 10 kez çalıştırılmıştır. Çalışmada kullanılan hiper parametre uzayı Tablo 2' de verilmiştir.

Tablo 2. Hiper parametre uzayı (Hyperparameter space)

Optimize edicinin öğrenme oranı		Dönüşüm katmanlarının sayısı		Her yoğun katmandaki düğüm sayısı		Yoğun katmandaki düğüm sayısı		Tüm katmanlar için aktivasyon fonksiyonu	
EY	ED	EY	ED	EY	ED	EY	ED	Kategori	
0.000001	0.01	1	3	1	5	5	512	Relu	Sigmoid

ED: En düşük, EY: En yüksek

El yazısı rakamların tanınması için kullanılan Mnist veri setinin %25, %50, %75 ve %100'ü kullanılarak eğitim ve test verileri oluşturulmuştur. Model, veri setindeki toplam örneklem büyüklüğünün yüzde 10'u kullanılarak rastgele oluşturulan bir örnek kümesi ile test edilmiştir. Hyperopt, Optuna ve Scikit-Optimize kütüphaneleri kullanılarak derin öğrenme modeli optimize edilmiştir.

*Optimizasyon 1.* Veri Setinin %25'i kullanılarak el yazısı rakamların derin öğrenme ile tespiti

Optimizasyon sonuçlarında başarı oranı en yüksek sonuç HyperOpt kütüphanesi ile elde edilmiştir. Optuna kütüphanesinin eğitim sürecinin diğer kütüphanelere oranla daha kısa olduğu gözlemlenmiştir. Veri setinin yüzde 25'i kullanılarak elde edilen optimizasyon sonuçları Tablo 3.' de verilmiştir

Tablo 3. Veri Setinin %25'i için optimizasyon sonuçları (Optimization results for 25% of the Data Set)

	Optimizasyon süresi	Başarı Yüzdesi%
HyperOpt	415 saniye	98,80
Optuna	151 saniye	97,33
Scikit-Optimize	355 saniye	97,89

*Optimizasyon 2.* Veri Setinin %50'si kullanılarak el yazısı rakamların derin öğrenme ile tespiti

Optimizasyon sonuçlarında başarı oranı en yüksek sonuç Optuna kütüphanesi ile elde edilmiştir. HyperOpt kütüphanesinin eğitim sürecinin diğer kütüphanelere oranla daha kısa olduğu gözlemlenmiştir. Veri setinin yüzde 50'si kullanılarak elde edilen optimizasyon sonuçları Tablo 4.' de verilmiştir.

Tablo 4. Veri Setinin %50'si için optimizasyon sonuçları (Optimization results for 50% of the Data Set)

	Optimizasyon süresi	Başarı Yüzdesi%
HyperOpt	720 saniye	97,75
Optuna	280 saniye	98,06
Scikit-Optimize	798 saniye	97,46

*Optimizasyon 3.* Veri Setinin %75'i kullanılarak el yazısı rakamların derin öğrenme ile tespiti

Optimizasyon sonuçlarında başarı oranı en yüksek sonuç HyperOpt kütüphanesi ile elde edilmiştir. Optuna kütüphanesinin eğitim sürecinin diğer kütüphanelere oranla daha kısa olduğu gözlemlenmiştir. Veri setinin yüzde 75'i kullanılarak elde edilen optimizasyon sonuçları Tablo 5.' de verilmiştir.

Tablo 5. Veri Setinin %75'i için optimizasyon sonuçları (Optimization results for 75% of the Data Set)

	Optimizasyon süresi	Başarı Yüzdesi%
HyperOpt	1073 saniye	98,70
Optuna	392 saniye	98,61
Scikit-Optimize	1492 saniye	97,17

*Optimizasyon 4.* Veri Setinin %100'ü kullanılarak el yazısı rakamların derin öğrenme ile tespiti

Optimizasyon sonuçlarında başarı oranı en yüksek sonuç HyperOpt kütüphanesi ile elde edilmiştir. Optuna kütüphanesinin eğitim sürecinin diğer kütüphanelere oranla daha kısa olduğu gözlemlenmiştir. Veri setinin yüzde 100'ü kullanılarak elde edilen optimizasyon sonuçları Tablo 6.' de verilmiştir.

Tablo 6. Veri Setinin %100'ü için optimizasyon sonuçları (Optimization results for 100% of the Data Set)

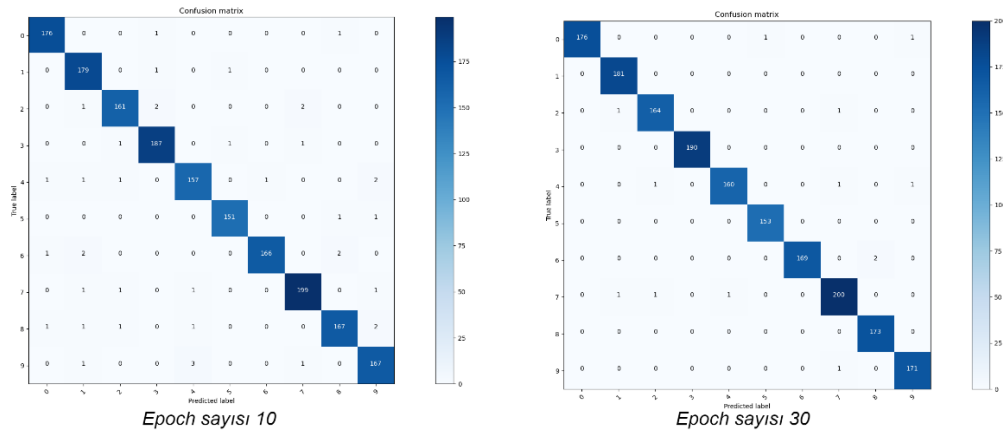
	Optimizasyon süresi	Başarı Yüzdesi%
HyperOpt	1756 saniye	98,87
Optuna	853 saniye	98,59
Scikit-Optimize	1547 saniye	98,49

### Optimizasyon 5. Epoch(döngü) sayısının değişimi

Eğitim süreci boyunca tüm eğitim verilerinin ağı sunulma sayısına epoch sayısı denir. CNN modeli için epoch sayısı 10 ve 30 olarak belirlenmiş veri setinin %25'i kullanılmıştır. Diğer optimizasyon denemelerinde Optuna kütüphanesinin diğer kütüphanelere göre daha kısa zamanda hiper parametre optimizasyonu sağladığı için Optuna kütüphanesi kullanılmıştır. Epoch değerinin artırılması modelin süresini uzatırken başarı oranının da artmasını sağlamıştır. Elde edilen sonuçlar ve parametreler Tablo 7.' de verilmiştir. Ek olarak, analiz sonucunda elde edilen karmaşıklık matris tablosu Şekil 5'te gösterilmiştir.

Tablo 7. Epoch değeri 10 ve 30 için optimizasyon sonuçları (Optimization results for epoch value 10 and 30)

Epoch	Optimizasyon süresi	Parametre		Başarı Yüzdesi%
10	960 saniye	activation	relu	97,71
		learning_rate	0.009081356705666793	
		num_conv_layers	3	
		filters	32	
		Kernel_size	5	
		Strides	1	
		num_dense_layers	2	
		units	303	
		optimizer_name	RMSprop	
30	2160 saniye	activation	relu	99,26
		learning_rate	0.0035201802253737057	
		num_conv_layers	2	
		filters	16	
		Kernel_size	5	
		Strides	1	
		num_dense_layers	1	
		units	36	
		optimizer_name	Adam	



Şekil 5. Epoch değeri 10 ve 30 için karmaşıklık matrisi  
(Confusion matrix for epoch value 10 and 30)

## 5. Sonuçlar ve Tartışma (Results and Discussion)

MNIST veri seti kullanılarak el yazısı rakamların evrişimli sinir ağı ile yüksek doğruluk ile tanınabilmektedir. Bu çalışmada, el yazısı rakamların tanınmasında açık kaynak kodlu hiper parametre optimizasyonu kütüphanelerinden Optuna, HyperOpt ve Scikit-Optimize kullanılmış, hiper parametrelerin ve epoch değerinin el yazısı tanımadaki başarısı değerlendirilmiştir. Kullanılan hiper parametre optimizasyon kütüphanelerinin farklı veri seti büyüklüklerinde optimizasyon süreleri ve başarıları analiz edilmiştir. Optimizasyon süresi incelendiğinde, Optuna kütüphanesi diğer hiper parametre optimizasyon kütüphanelerine göre daha kısa sürede tamamlamıştır. Başarı yüzdeleri birbirlerine yakın olsa da HyperOpt kütüphanesi diğer kütüphanelerden daha öndedir. Veri seti büyüklüğü ve epoch değerinin artması el yazısı rakamların tanınmasında başarı yüzdesini artırmıştır. Optimize edilmiş hiper parametrelerle eğitilen model, %99 doğruluk elde etmiştir. En iyi performansı elde etmek için yapılan çeşitli deneyler, belirli bir öğrenme hızı, dönem sayısı ve gizli katman düğümlerinin sayısı kombinasyonunun modelin genel performansını iyileştirdiğini göstermiştir. Ancak hiper parametre optimizasyon işleminin bilgisayar kaynakları ve zaman açısından maliyetli olduğunu belirtmek gerekir. Optimum hiper parametreleri belirlemek için daha büyük bir hiper parametre arama alanı veya daha fazla hesaplama gücü gerekebilir. Sonuç olarak bu çalışma, hiper parametre optimizasyonunun MNSIT veri seti üzerindeki el yazısı rakam tanıma çalışmalarında başarıyla uygulanabileceğini ve açık kaynak hiper parametre optimizasyon kütüphanesinin modelin performansını önemli ölçüde artırabileceğini göstermektedir. Hiper parametre analizi sonuçları, modelin performansının hiper parametre seçiminden önemli ölçüde etkilendiğini göstermektedir. Bu nedenle, el yazısı rakam tanıma için bir evrişimli sinir ağı kullanılırken, uygun hiper parametrelerin seçilmesi önemlidir. Elde edilen sonuçlar, doğru hiperparametre seçiminin modelin başarısını büyük ölçüde etkilediğini göstermektedir. Bu bulgular, benzer uygulamalarda model performansını artırmak için kullanılabilir ve ileriye yönelik araştırmalara ışık tutabilir.

## Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

## Kaynaklar (References)

- [1] W. Ertel, *Introduction to Artificial Intelligence*, Springer Cham., 2017
- [2] A. Baldominos, Y. Saez, and P. Isasi, "A survey of handwritten character recognition with MNIST and EMNIST," *Applied Sciences*, vol. 9, no. 15. Aug. 01, 2019. doi: 10.3390/app9153169.
- [3] E. Kussul, T. Baidyk, "Improved method of handwritten digit recognition tested on MNIST database", *Image and Vision Computing*, vol.22, no.12, pp. 971-981, 2004, doi: 10.1016/j.imavis.2004.03.008.
- [4] L. Li, K. Jamieson, G. DeSalvo, A. Rostamizadeh, and A. Talwalkar, "Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization," *Journal of Machine Learning Research*, vol. 18, no. 185, pp. 1–52, 2018.
- [5] R. S. Humera and R. Zaheer, "Impact of Hyperparameters on Model Development in Deep Learning," in *Proceedings of International Conference on Computational Intelligence and Data Engineering*, Springer, 2021, pp. 57–67.

- [6] R. Elshawi, M. Maher, and S. Sakr, "Automated Machine Learning: State-of-The-Art and Open Challenges," Jun. 2019, [Online]. Available: <http://arxiv.org/abs/1906.02287>. [Accessed: Dec. 28, 2023].
- [7] J. Bergstra, R. Bardenet, Y. Bengio, and B. Kégl, "Algorithms for hyper-parameter optimization" in *Proceedings of the 24th International Conference on Neural Information Processing Systems NIPS 2011*. 2011, pp. 2546–2554.
- [8] M. Lindauer, K. Eggensperger, M. Feurer, A. Biedenkapp, D. Deng, C. Benjamins, T. Ruhkopf, R. Sass, and F. Hutter, "SMAC3: A Versatile Bayesian Optimization Package for Hyperparameter Optimization", *The Journal of Machine Learning Research*, vol. 23, no. 1, Jan. 2022.
- [9] L. Li, K. Jamieson, A. Rostamizadeh, and A. Talwalkar, "Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization," *Journal of Machine Learning Research*, vol.18, no.1, pp.6765–6816, Jan 2017, doi: 10.5555/3122009.3242042.
- [10] S. L. Chooi and A. S. Ghafar, "Handwritten Character Recognition Using Convolutional Neural Network", *Progress in Engineering Application and Technology*, vol. 2, no. 1, pp. 593–611, Jun. 2021.
- [11] O. M. Khanday, S. Dadvandipour, and M. A. Lone, "Effect of filter sizes on image classification in CNN: A case study on CFIR10 and fashion-MNIST datasets," *IAES International Journal of Artificial Intelligence*, vol. 10, no. 4, pp. 872–878, Dec. 2021, doi: 10.11591/ijai.v10.i4.pp872-878.
- [12] L. Ming Seng, B. Bang Chen Chiang, Z. Arabee Abdul Salam, G. Yih Tan, and H. Tong Chai, "MNIST handwritten digit recognition with different CNN architectures," *Journal of Applied Technology and Innovation*. vol. 5, no.1,pp. 7-10, 2021.
- [13] H. Shao, E. Ma, M. Zhu, X. Deng, and S. Zhai, "MNIST Handwritten Digit Classification Based on Convolutional Neural Network with Hyperparameter Optimization," *Intelligent Automation and Soft Computing*, vol. 36, no. 3, pp. 3595–3606, 2023, doi: 10.32604/iasc.2023.036323.
- [14] B. Bischl, M. Binder, M. Lang, T. Pielok, J. Richter, S. Coors, J. Thomas, T. Ullmann, M. Becker, A. Boulesteix, D. Deng, M. Lindauer, "Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges," *Wiley Interdiscip Rev Data Min Knowl Discov*, vol. 13, Dec. 2023, doi: 10.1002/widm.1484.
- [15] A. Baldominos, Y. Saez, and P. Isasi, "Evolutionary convolutional neural networks: An application to handwriting recognition," *Neurocomputing*, vol. 283, pp. 38–52, 2018, doi: 10.1016/j.neucom.2017.12.049.
- [16] Y. LeCun, "The MNIST database of handwritten digits.", 1998. [Online]. Available: <http://yann.lecun.com/exdb/mnist/>, [Accessed: Dec. 28, 2023].
- [17] M. Wu and Z. Zhang, "Handwritten Digit Classification using the MNIST Data Set Handwritten Digit Classification using the MNIST Data Set 1," 2014. [Online]. Available: <https://www.researchgate.net/publication/228685853> [Accessed: Dec. 28, 2023].
- [18] L. Alzubaidi, J. Zhang, A. J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, J. Santamaría, M. A. Fadhel, M. Al-Amidie and L. Farhan, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions", *J Big Data* vol.8, no.53, pp. 1-74, Mar 2021. <https://doi.org/10.1186/s40537-021-00444-8>
- [19] D. H. Hubel and T. N. Wiesel, "Receptive fields and functional architecture of monkey striate cortex," *J Physiol*, vol. 195, no. 1, pp. 215–243, 1968, doi: [10.1113/jphysiol.1968.sp008455](https://doi.org/10.1113/jphysiol.1968.sp008455).
- [20] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, "Convolutional neural networks: an overview and application in radiology", *Insights into Imaging*, vol. 9, no. 4, pp. 611–629, Aug. 01, 2018. doi: 10.1007/s13244-018-0639-9.
- [21] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, L. D. Jackel, "Backpropagation Applied to Handwritten Zip Code Recognition," *Neural Computation*, vol. 1, no. 4, pp. 541–551, 1989, doi: 10.1162/neco.1989.1.4.541.
- [22] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Association for Computing Machinery*, vol.60, pp. 84-90, June 2017, doi: 10.1145/3065386
- [23] M. Krichen, "Convolutional Neural Networks: A Survey," *Computers*, vol. 12, no. 8, 2023, doi: 10.3390/computers12080151.
- [24] Ö. İnik Ve E. Ülker, "Derin Öğrenme Ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri", *Gbad*, Vol. 6, no. 3, pp. 85–104, 2017.
- [25] S. Ali, Z. Shaukat, M. Azeem, Z. Sakhawat, T. Mahmood, and K. ur Rehman, "An efficient and improved scheme for handwritten digit recognition based on convolutional neural network," *SN Appl Sci*, vol. 1, no. 9, Sep. 2019, doi: 10.1007/s42452-019-1161-5.
- [26] M. Sahu and R. Dash, "A Survey on Deep Learning: Convolution Neural Network (CNN)," 2021, *Smart Innovation, Systems and Technologies*, vol.153, pp. 317–325, 2021. doi: 10.1007/978-981-15-6202-0\_32.
- [27] J. Gu, Z. Wang, J. Kuen, L. Ma, A. Shahroudy, B. Shuai, T. Liu, X. Wang, G. Wang, J. Cai and T. Chen, "Recent advances in convolutional neural networks," *Pattern Recognit*, vol. 77, pp. 354–377, 2018, doi: [10.1016/j.patcog.2017.10.013](https://doi.org/10.1016/j.patcog.2017.10.013).
- [28] W. Ouyang, B. Xu, J. Hou, and X. Yuan, "Fabric Defect Detection Using Activation Layer Embedded Convolutional Neural Network," *IEEE Access*, vol. 7, pp.70130-70140, Apr. 2019, doi: 10.1109/ACCESS.2019.2913620.

- [29] M. Tanaka, "Weighted sigmoid gate unit for an activation function of deep neural network," *Pattern Recognit Lett*, vol. 135, pp. 354–359, 2020, doi: 10.1016/j.patrec.2020.05.017.
- [30] M. Coşkun, A. Uçar, Ö. Yildirim, and Y. Demir, "Face recognition based on convolutional neural network," in *2017 International Conference on Modern Electrical and Energy Systems (MEES)*, 2017, pp. 376–379. doi: 10.1109/MEES.2017.8248937.
- [31] S. L. Hijazi, R. Kumar, and C. Rowen, "Using Convolutional Neural Networks for Image Recognition," *Cadence Design Systems Inc*, 2015. [Online]. Available: <https://api.semanticscholar.org/CorpusID:6212567>
- [32] F. Yılmaz and M. C. Kasapbaşı, "Eeg Sinyalleri İle Epilepsi Krizinin Tahminlenmesinde Rassal Orman Algoritması İle Hiper Parametre Optimizasyonun Uygulanması," *İstanbul Ticaret Üniversitesi Teknoloji Ve Uygulamalı Bilimler Dergisi*, vol. 3, no. 2, pp. 189–203, 2021.
- [33] T. Bartz-Beielstein, "Hyperparameter Tuning and Optimization Applications," in *Hyperparameter Tuning for Machine and Deep Learning with R*, Springer, 2023, pp. 165–175.
- [34] J. Bergstra, J. B. Ca, and Y. B. Ca, "Random Search for Hyper-Parameter Optimization Yoshua Bengio," *Journal of Machine Learning Research*, vol.13, no.10, pp.281-305. Feb 2012.
- [35] F. Hutter, L. Kotthoff, and J. Vanschoren, "Automated Machine Learning: Methods, Systems, Challenges," *Automated Machine Learning*, pp. 113–134. Springer. 2019.
- [36] L. Yang And A. Shami, "On hyperparameter optimization of machine learning algorithms: Theory and practice," *Neurocomputing*, vol.415, pp.295-316,November 2020. <https://doi.org/10.1016/j.neucom.2020.07.061>
- [37] T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama, "Optuna: A Next-Generation Hyperparameter Optimization Framework," in *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, in KDD '19*. New York, NY, 2019, pp. 2623–2631. doi: 10.1145/3292500.3330701.
- [38] "scikit-optimize: Sequential model-based optimization in Python — scikit-optimize 0.7.3 documentation. (n.d.)." [Online]. Available: <https://scikit-optimize.github.io/>. [Accessed: Dec. 28, 2023].

\* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAE 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license



GAZİ

JOURNAL OF ENGINEERING SCIENCES

## Determining Cyberbullying Status of Turkish Tweets with Gpt-3 Classification Model

Çilem Koçak<sup>a</sup>, Tuncay YİĞİT<sup>b</sup>

Submitted: 21.11.23 Revised: 19.12.2023 Accepted: 20.12.2023 doi:10.30855/gmbd.0705S26

### ABSTRACT

**Keywords:** Cyberbullying, Twitter, Artificial intelligence, Text Classification, GPT-3

<sup>A,\*</sup> Isparta University Of Applied Sciences,  
Yalvaç Technical Sciences Vocational  
School - Isparta, Türkiye  
Orcid: [0000-0002-4516-2076](https://orcid.org/0000-0002-4516-2076)  
e mail: [cilemkocak@isparta.edu.tr](mailto:cilemkocak@isparta.edu.tr)

<sup>b</sup> Süleyman Demirel University,  
Faculty Of Engineering,,  
Dept. of Computer Engineering  
Isparta, Türkiye  
Orcid: [0000-0001-7397-7224](https://orcid.org/0000-0001-7397-7224)

\*Corresponding author:  
[cilemkocak@isparta.edu.tr](mailto:cilemkocak@isparta.edu.tr)

Regardless of whether they are young or old, people have quickly stepped into the internet world with phones, tablets, computers and smart devices, which are among today's communication technologies. With the increase in the number of social media users, some negativities are encountered. The most important problem encountered on social media is cyber bullying. Although cyberbullying may seem like daily dialogues between social media users or groups, the incidence of cyberbullying increases day by day with the diversification of shared information, content, and agenda in social media environments. This paper evaluates the performance of a GPT-3 classification model for the task of classifying tweets from tweeters as those that contain cyberbullying or those that do not. The model was first trained and tested on Turkish tweets. It resulted in an accuracy of 55% in total. After the data was translated to English and the model was retrained and tested, accuracy was increased to 66%. Precision, recall, and F1 score for both classes of tweets were 0.65, 0.68, and 0.67, respectively, for tweets without cyberbullying and 0.67, 0.64, and 0, respectively, for tweets with cyberbullying. It was found to be 65. Cyberbullying The confusion matrix of the model showed that 17 tweets correctly contained cyberbullying, while 9 tweets incorrectly contained cyberbullying. The results of this paper show that GPT-3 can be used for the task of classifying tweets into those that contain cyberbullying and those that do not with a reasonable degree of accuracy.

## Gpt-3 Sınıflandırma Modeli İle Türkçe Tweetlerin Siber Zorbalık Durumlarının Belirlenmesi

### ÖZ

İnsanlar genç yaşlı fark etmeksizin günümüz iletişim teknolojilerinden olan telefon, tablet, bilgisayar ve akıllı cihazlar ile internet dünyasına hızlı bir şekilde adım atmışlardır. Sosyal medya kullanıcı sayısının artışı ile de bazı olumsuzluklarla karşılaşmaktadır. Sosyal medya da karşılaşılan en önemli sorun da siber zorbalık durumlarıdır. Siber zorbalık sosyal medya kullanıcıları ya da gruplar arasında gerçekleşen günlük diyaloglar gibi görünse de paylaşılan bilgi, içerik, gündem sosyal medya ortamlarının çeşitlenmesi ile günden güne karşılaşma durumu artmaktadır. Bu makale, tweetlerden alınan tweetlerin siber zorbalık içerenler ve içermeyenler olarak sınıflandırma görevi için bir GPT-3 sınıflandırma modelinin performansını değerlendirmektedir. Model ilk olarak Türkçe tweet'ler üzerinde eğitilmiş ve test edilmiştir. Toplamda da %55'lik bir doğrulukla sonuçlanmıştır. Veriler İngilizce'ye çevrildikten ve model yeniden eğitilip test edildikten sonra doğruluk %66'ya yükseltilmiştir. Her iki tweet sınıfı için kesinlik, hatırlama ve F1 puanı, siber zorbalık içermeyen tweet'ler için sırasıyla 0,65, 0,68 ve 0,67 ve siber zorbalık içeren tweet'ler için sırasıyla 0,67, 0,64 ve 0,65 olarak bulunmuştur. Siber zorbalık Modelin karışıklık matrisi, 17 tweet'in doğru bir şekilde siber zorbalık içerdiğini, 9'unun ise yanlış bir şekilde siber zorbalık içerdiğini görülmüştür. Bu makalenin sonuçları, GPT-3'ün tweet'leri siber zorbalık içerenler ve makul bir doğruluk derecesi ile içermeyenler olarak sınıflandırma görevi için kullanılabileceğini göstermektedir.

**Anahtar Kelimeler:** Siber zorbalık,  
Twitter, Yapay zeka,  
Metin Sınıflandırma, GPT-3

## 1. Giriş (Introduction)

Telefon ve bilgisayar teknolojilerinin gelişmesi kullanım durumunun ve sosyal medya platformlarındaki sayının artışı ile siber zorbalık davranışlarının görülme olasılığı da artmaktadır. Siber zorbalık mağdurları, kullanıcılar tarafından elektronik iletişim araçları ile tehdit edilmekte, sıklıkla yazılı hakaret içeren mesajlar almakta, sahte kimlik ile birini kötü gösterme gibi eylemlerle karşı karşıya kalmaktadırlar. Bu durumda zorba ve kurban arasındaki karşılıklı ilişkiler sorunları ortaya çıkmaktadır [1]. Bu sorunlar insan arasındaki arkadaşlık ve duygusal ilişkilerinin bozulması, farklı görüş ve düşüncelere sahip olan kişiler arasında olan yazılı atışmalar nedenleriyle oluşan intikam duygusundan ortaya çıktığı düşünülmektedir [2]. Siber zorbalık davranışının sergilenmesi için gerçekleştirildiği araç ve ortam fark etmeksizin mağdur üzerinde yıkıcı bir sonuç ortaya çıkarma, kırma, küçük düşürme, aşağılama ve kurbanda kalıcı izler bırakılması istenmekle birlikte mağdurun toplum ilişkileri olumsuz yönde etkilenmekte ayrıca duygusal, sosyal ve psikolojik olarak zarar vermektedir.

Bu makale, metin sınıflandırması kullanarak siber zorbalık tespiti için makine öğrenimi algoritmalarının kullanımına ilişkin bir çalışma sunmaktadır. Siber zorbalık günümüz toplumunda önemli bir sorundur ve onu tespit etmek için etkili ve verimli yöntemlere ihtiyaç duyulmaktadır. Bu nedenle, bu makale siber zorbalık tespiti için makine öğrenimi algoritmalarının potansiyelini keşfetmeyi amaçlamaktadır. Spesifik olarak, çevrimiçi metinlerden siber zorbalığı tespit etmek için denetimli bir makine öğrenimi algoritmasına dayalı bir metin sınıflandırma yaklaşımı önerilmektedir. Bu yaklaşımın performansını mevcut yöntemlerle karşılaştırılmış ve bir siber zorbalık belgeleri külliyatındaki etkinliğini değerlendirilmektedir. Sonuçlar, önerilen yöntemin doğruluk açısından mevcut yaklaşımlardan daha iyi performans gösterdiğini göstermektedir. Ayrıca bulgularımızın çıkarımlarını tartışıyor ve bu konuda gelecekte yapılabilecek olası çalışmaları önerilerde bulunmaktayız.

## 2. Siber Zorbalık (Cyber Bullying)

Siber zorbalık, e-posta, metin mesajları, sosyal medya veya diğer çevrimiçi platformlar gibi dijital dünyada gerçekleşen bir zorbalık biçimidir [3]. Gençler arasında giderek artan bir endişe kaynağıdır ve duygusal sıkıntı, depresyon ve hatta intihar gibi ciddi sonuçları olabilir. Siber zorbalık, birini taciz etmek, tehdit etmek veya utandırmak için dijital teknolojiyi kullanmayı içerir. Kırıcı mesajlar veya resimler göndermeyi, acımasız yorumlar göndermek için sahte hesaplar oluşturmayı veya birinin kişisel bilgilerini rızası olmadan paylaşmayı içerebilir. Ayrıca, kurbanın kötü görünmesini sağlamak için çevrimiçi içeriğin manipüle edilmesini veya kurbanın istenmeyen resimlerini çevrimiçi olarak yayınlamayı da içerebilir. Siber zorbalığın etkileri yıkıcı olabilir. Siber zorbalık kurbanları utanç, izolasyon ve depresyon duyguları yaşarlar. Ayrıca kaygı, yorgunluk ve düşük benlik saygısı yaşayabilirler. Ek olarak, siber zorbalık kurbanları baş ağrısı, uyku güçlüğü ve mide ağrısı gibi fiziksel semptomlar yaşayabilir [4]. Son yıllarda teknolojinin yaygınlaşması ve gençlerin çevrimiçi geçirdikleri sürenin artması nedeniyle siber zorbalığın yaygınlığı arttı. Bu nedenle, siber zorbalık belirtilerinin farkında olmak ve bunu önlemek için adımlar atmak önemlidir. Siber zorbalık örnekleri arasında birine kaba mesajlar veya resimler göndermek, kırıcı yorumlar göndermek için sahte sosyal medya hesapları oluşturmak ve birinin kişisel bilgilerini rızası olmadan kullanmak yer alır. Ayrıca, birinin utanç verici resimlerini yayınlamayı veya kurbanı kötü göstermek için çevrimiçi içeriği manipüle etmeyi içerebilir. Siber zorbalık birçok şekilde olabilir ve belirtilerin farkında olmak ve bunu önlemek için adımlar atmak önemlidir [5].

Siber zorbalık ile fiziksel ortamda gerçekleştirilen zorbalık türleri her ne kadar zorbalığın gerçekleştirildiği ortam farklı olsa da birbirlerine benzemektedirler. Siber zorbalık davranışlarının sergilenmesi için ortam farkı olarak internet ortamı, sosyal medya gereçleri kullanılmaktadır. Zorbalar birçok yöntemle siber zorbalık yapmaktadırlar. Sık karşılaşılan ve sınıflandırılan siber zorbalık çeşitleri;

- ✓ “Siber takip; Bir kişiyi sanal ortamlarda sürekli takip halinde tutmak,
- ✓ Karalamak; Bir kişi ile ilgili asılsız, zararlı ve kaba beyanlarda bulunmak,
- ✓ Kendini Başkası Gibi Göstermek; İnternet ortamlarında kendi kimliğini gizleyerek hayali biri ya da başkasının kimliğine bürünmek,
- ✓ Taciz Etme; Bir kişiye kırıcı veya cinsel içerikli mesajlar göndermek,
- ✓ Kışkırtmak; Bir kişiyi yapmaması gereken durumlar için teşvik etmek,
- ✓ Gezinti ve Düzenbazlık; Bir kişi hakkında utandırıcı ve özel bilgileri yaymak yayınlamak,
- ✓ Ayırma; Bir kişiyi bir gruptan çıkarmak veya gruba dâhil etmemek gibi türleri bulunmaktadır”.[1]

### 3. Materyal ve Yöntem (Material and Method)

Siber Zorbalığı Tespit Algoritmaları:

Naive Bayes: Naive Bayes algoritmaları, metinde kullanılan kelime ve kelime öbeklerini analiz ederek metnin siber zorbalık olup olmadığını sınıflandırmak için kullanılır[6].

Metin Sınıflandırması: Bu algoritma genellikle metni siber zorbalık veya değil olarak sınıflandırmak için kullanılır. Bu, sözdizimi, duyarlılık ve dil gibi çeşitli özellikler kullanılarak yapılır[7].

Kümeleme: Kümeleme algoritmaları, verilerdeki siber zorbalığa işaret eden kalıpları belirlemek için kullanılabilir. Örneğin, siber zorbalığı tanımlamak için benzer yorumları gruplamak için kümeleme kullanılabilir[8].

Anormallik Tespiti: Anormallik tespit algoritmaları, sıra dışı olan ve siber zorbalığa işaret edebilecek davranış veya yorumları belirlemek için kullanılabilir[8].

Sinir Ağları: Sinir ağları, daha sonra siber zorbalığı tespit etmek için kullanılacak verilerdeki kalıpları öğrenmek için kullanılabilir[8].

BERT: Transformers'tan Çift Yönlü Kodlayıcı Temsilleri, doğal dil işleme (NLP) ön eğitim tekniğine dayalı bir derin öğrenme algoritmasıdır. BERT, 2018 yılında Google tarafından geliştirildi ve o zamandan beri dünyanın en güçlü NLP modellerinden biri haline geldi. BERT'nin amacı, en alakalı anlamı belirlemek için bağlamı kullanarak bilgisayarların metindeki belirsiz dilin anlamını anlamalarına yardımcı olmaktır. Örneğin, BERT, sözcükler bağlam dışında kullanılsa bile bir cümlenin amacını belirleyebilir. BERT, bilgisayarların kullanıcı sorgularını yorumlamasına ve ilgili yanıtları üretmesine yardımcı olan doğal dil anlama (NLU) modelleri oluşturmak için de kullanılır. BERT, çok çeşitli dillerde soru yanıtlama, duygu analizi ve diğer doğal dil görevleri için kullanılmıştır [9].

GPT-3 (Generative Pre-trained Transformer 3): OpenAI tarafından geliştirilmiş gelişmiş bir Doğal Dil İşleme (NLP) modelidir. 175 milyar parametre kapasitesiyle şimdiye kadar oluşturulmuş en büyük ve en güçlü sinir ağıdır. GPT-3, milyonlarca web sayfasından oluşan devasa bir veri kümesi üzerinde eğitilmiştir ve metin oluşturma yetenekleriyle insan benzeri metinler üretebilir. Soru yanıtlama, çeviri, özetleme ve duygu analizi gibi çeşitli NLP görevlerinde dikkate değer bir performans göstermiştir. Gücü, sınırlı eğitim verilerinden genelleme yapma yeteneğinde ve çok çeşitli görevlere uygulanmasına izin veren ölçeklenebilirliğinde yatmaktadır [10].

#### 3.1. BERT (Bidirectional Encoder Representations from Transformers)

Metin sınıflandırması için BERT kullanmanın ana avantajı, metinden bağlamsal bilgileri yakalama yeteneğidir. Bu, yalnızca metindeki tek tek sözcükleri dikkate alan sözcük torbası veya TF-IDF gibi diğer geleneksel yöntemlere göre çok büyük bir avantajdır. Ayrıca BERT, metindeki uzun vadeli bağımlılıkları yakalayabildiği için LSTM'ler veya CNN'ler gibi diğer derin öğrenme modellerinden önemli ölçüde daha güçlüdür. Ek olarak, BERT çeşitli metin sınıflandırma görevlerinde kullanılabilir. İncelemelerdeki duyarlılığı sınıflandırmak, haber makalelerindeki konuları tespit etmek veya müşteri sorgularının amacını sınıflandırmak için kullanılabilir. Belge özetleme, soru yanıtlama ve diğer birçok görev için de kullanılabilir. Genel olarak BERT, metin sınıflandırma görevleri için son derece güçlü ve çok yönlü bir araçtır. Metindeki uzun vadeli bağımlılıkları yakalamasına izin veren kelimelerin bağlamsal temsillerini öğrenme yeteneğine sahiptir. Ayrıca, duygu analizinden belge özetlemeye kadar çeşitli görevlerde kullanılabilir. İşte BERT önceden eğitilmiş ağıнын artıları ve eksileri.

Artıları:

- BERT, bağlamı diğer ağlardan daha iyi kodlayabilir ve dilin nüanslarını anlamasına olanak tanır.
- BERT, çeşitli doğal dil işleme görevlerinin üstesinden gelmek için kullanılabilen bir derin öğrenme mimarisidir.
- BERT, manuel özellik mühendisliği ihtiyacını azaltarak kendi kendine öğrenme yeteneğine sahiptir.
- BERT, belirli görevler için ince ayar yapılarak daha doğru sonuçlar üretebilir. Eksileri:
- BERT, hesaplama açısından pahalıdır ve eğitilmesi için çok sayıda GPU kaynağı gerektirir.
- BERT, uzun cümleleri doğru bir şekilde temsil etme yeteneğini sınırlayan uzun metin dizilerini



kodlamakta güçlük çekiyor.

- Bir kara kutu modeli olduğu için BERT'in sonuçlarını yorumlamak zor olabilir.
- BERT, metnin anlamını doğası gereği anlamıyor ve belirli görevler için ek manüel özellik mühendisliği gerektiriyor [9].

### 3.2. GPT-3 (Generative Pre-Trained Transformer 3)

GPT-3, metnin sınıflandırılma biçiminde devrim yaratan, çığır açan bir doğal dil işleme (NLP) teknolojisidir. GPT-3, metindeki kalıpları belirlemek ve içeriğine göre kategorilere ayırmak için derin öğrenmeyi kullanır. Bu, GPT-3'ün makaleler, blog gönderileri, sosyal medya gönderileri ve diğer yazılı materyaller gibi metinleri hızlı ve doğru bir şekilde sınıflandırabileceği anlamına gelir. GPT-3 güçlü bir araçtır çünkü daha doğru sınıflandırmalar yapmak için metnin konusu ve yazarın üslubu gibi bağlamsal bilgileri kullanabilir. Örneğin, GPT-3, sporla ilgili bir blog gönderisini, konular birbiriyle ilişkili olsa bile, siyasetle ilgili bir blog gönderisinden farklı olarak tanıyabilir. GPT-3, sağlık, eğitim, finans ve daha fazlası gibi çeşitli alanlarda metinleri tanımlamak ve sınıflandırmak için kullanılmaktadır. Ayrıca sohbet botları ve otomatik müşteri hizmetleri sistemleri oluşturmak için kullanılmaktadır [10].

GPT-3, çok sayıda eğitim verisinden öğrenme yeteneği nedeniyle güçlü bir metin sınıflandırma aracıdır. Bu verileri kalıpları algılamak ve metni geleneksel yöntemlerden daha doğru bir şekilde sınıflandırmak için kullanılabilir. GPT-3, manüel olarak etiketlenmiş verilere ihtiyaç duymadan metni de sınıflandırabilir, bu da onu geleneksel yöntemlerden çok daha verimli hale getirmiştir. Bu, GPT-3'ün metni daha hızlı ve daha az hatayla sınıflandırabileceği anlamına gelmektedir. GPT-3, makaleler, blog gönderileri, sosyal medya gönderileri, müşteri hizmetleri konuşmaları ve daha fazlasını içeren çok çeşitli metinleri sınıflandırmak için yaygın bir şekilde kullanılmaktadır. Ayrıca, müşteri sorgularını anlayabilen ve otomatik yanıtlar sağlayabilen yapay zeka destekli sohbet botları ve müşteri hizmetleri sistemleri oluşturmak için de kullanılmaktadır [8].

GPT-3, insan müdahalesine ihtiyaç duymadan metni doğru bir şekilde sınıflandırma yeteneği nedeniyle kısa sürede metin sınıflandırma için en popüler araçlardan biri haline gelmiştir. GPT-3, daha doğru sınıflandırmalar yapmak için metnin konusu ve yazarın üslubu gibi bağlamsal bilgileri kullanır. GPT-3, makaleler, blog gönderileri, sosyal medya gönderileri, müşteri hizmetleri konuşmaları ve daha fazlasını içeren çok çeşitli metinleri sınıflandırmak için kullanılmaktadır. Ayrıca, müşteri sorgularını anlayabilen ve otomatik yanıtlar sağlayabilen yapay zeka destekli sohbet botları ve müşteri hizmetleri sistemleri oluşturmak için de sıklıkla kullanılmaktadır. GPT-3, metnin sınıflandırılma biçiminde devrim yaratmakta ve işletmeler, araştırmacılar ve daha fazlası için paha biçilmez bir araç haline gelmektedir [11].

Artıları:

- GPT-3, doğru metin sınıflandırma sonuçları üretebilen gelişmiş bir doğal dil işleme (NLP) modelidir.
- GPT-3, karmaşık kalıpları tanımasını ve daha doğru sonuçlar üretmesini sağlayan geniş bir eğitim veri setine (175 milyar parametre) sahiptir.
- GPT-3, mevcut uygulamalara ve hizmetlere kolayca entegre edilebilir, bu da onu metin sınıflandırma görevleri için uygun maliyetli bir çözüm haline getirir.
- GPT-3, kelime dağarcığı dışındaki kelimeleri işlemek için yerleşik bir özelliğe sahiptir ve bu da onu yüksek doğruluk gerektiren metin sınıflandırma görevleri için güvenilir bir araç haline getirir.

Eksileri:

- GPT-3, çalışması için büyük bilgi işlem kaynakları gerektiren pahalı bir çözümdür.
- GPT-3, doğru sonuçlar elde etmek için modeli eğitmek ve ince ayar yapmak için çok zaman gerektirir.
- GPT-3, kısa metin kalıplarını tanımlayamadığı için kısa metin sınıflandırma görevleri için uygun değildir.
- GPT-3'ün İngilizce dışındaki dilleri tanıma yeteneği sınırlıdır.

### 3.3. BERT ve GPT-3'ün karşılaştırılması (Comparison of BERT and GPT-3)

Metin sınıflandırması için BERT ve GPT-3'ü karşılaştırırken dikkate alınması gereken birkaç faktör vardır. Birincisi, BERT, dildeki daha ince nüansları yakalamasına izin veren çift yönlü eğitim kullandığından GPT-3'ten daha sağlam bir modeldir. İkincisi, BERT, GPT-3'ten daha geniş bir metin külliyatı üzerinde önceden eğitilmiştir ve ona dil hakkında daha fazla bilgi verir. Üçüncüsü, BERT, metin sınıflandırma görevlerinde

GPT-3'ten çok daha hızlıdır ve bu da onu gerçek zamanlı uygulamalar için daha uygun hale getirmektedir. Son olarak BERT, GPT-3'e kıyasla uzun vadeli bağımlılıkları yakalamada daha iyi olduğu görülmektedir. Sonuç olarak, hem BERT hem de GPT-3, metin sınıflandırması için güçlü modellerdir. Ancak BERT, sağlamlığı, daha büyük önceden eğitilmiş veri topluluğu, daha hızlı performansı ve uzun vadeli bağımlılıkları yakalama yeteneği nedeniyle görev için daha uygunluğu tartışmalıdır.

### 3.4. Eğitim verileri (Training data)

Bu veri seti, üç yüksek lisans öğrencisi tarafından siber zorbalık içeren (1) veya içermeyen (0) olarak etiketlenen 7574 tweet'ten oluşmaktadır. Veriler Twitter'dan elde edilmiş ve bir tweet'in siber zorbalık içerip içermediğini doğru bir şekilde sınıflandırmak için makine öğrenimi algoritmalarının eğitiminde kullanılması amaçlanmaktadır. Etiketler, öğrenciler tarafından tweet'in içeriğini analiz edilerek belirlenmiştir. Ancak, ön işleme işlemlerinden sonra sadece 150 örnek seçilmiştir. 0. sınıf için 75, 1. sınıf için 75. 100 örnek eğitime, kalanı ise teste ayrılmıştır.

## 4. Sonuçlar (Results)

İlk adımda GPT-3 modelinde, Türkçe tweet'ler içeren orijinal verilerle eğitim yapılmıştır. Eğitimden sonra, orijinal test verileriyle test edilmiştir.

Table 1. Türkçe Tweetler için Gpt-3 performans sonuçları (Gpt-3 performance results for Turkish Tweets)

	Precision	Recall	F1-score	Support
0	0.60	0.35	0.44	25
1	0.53	0.76	0.62	25
Accuracy			0.55	
Macro avg	0.56	0.55	0.53	50
Weighted avg	0.56	0.55	0.53	50

Yukarıdaki performans sonuçları, modelin genel doğruluğu olan %55'lik bir doğruluk göstermektedir. Bu, modelin test edildiği 51 örnekten 55'inin sonucunu doğru bir şekilde tahmin edebildiği anlamına gelmektedir. Tablonun ilk satırı, 0,60 kesinlik, 0,35 geri çağırma ve 0,44 F1 puanı ile sınıf 0'a karşılık gelmektedir. Bu, modelin sınıf 0 örneklerinin %60'ını doğru bir şekilde tanımlayabildiği, ancak yalnızca %35'ini hatırladığı görülmüştür. F1 puanı kesinlik ve hatırlamanın harmonik ortalamasıdır ve bu durumda 0,44'tür. Tablonun ikinci satırı, 0,53 kesinlik, 0,76 hatırlama ve 0,62 F1 skoru ile sınıf 1'e karşılık gelmektedir. Bu, modelin 1. sınıf örneklerin %53'ünü doğru bir şekilde tanımlayabildiği ve %76'sını hatırlayabildiği görülmüştür F1 puanı 0,62'dir. Makro ortalama, her iki sınıf puanının ortalamasıdır ve bu durumda 0,53'tür. Ağırlıklı ortalama da 0,53'tür, bu da modelin her iki sınıfta da benzer performans gösterdiğini gösterir. Genel olarak, model, daha yüksek hatırlama ve F1 puanı ile gösterildiği gibi, sınıf 1'de sınıf 0'dan biraz daha iyi performans göstermektedir. Bununla birlikte, nispeten düşük puanların gösterdiği gibi, model hala her iki sınıfta da optimum performans göstermemektedir.

Nispeten başarısız olan sonuçların ardından Train ve test veri setlerindeki tüm tweetler İngilizceye çevrilerek tekrar train and test işlemleri gerçekleştirildi. İkinci modelin performans sonuçları Tablo 2'de görülebilir.

Table 2. İngilizce Tweetler için Gpt-3 performans sonuçları (Gpt-3 performance results for English Tweets)

	Precision	Recall	F1-score	Support
0	0.65	0.68	0.67	25
1	0.53	0.76	0.62	25
Accuracy			0.66	
Macro avg	0.66	0.66	0.66	50
Weighted avg	0.66	0.66	0.66	50


Bu GPT-3 sınıflandırma modeli, siber zorbalık içermeyen tweet'leri sınıflandırmak için 0,65 ve siber zorbalık içeren tweet'leri sınıflandırmak için 0,67 kesinliğe sahiptir. Bu, modelin bir tweet'in siber zorbalık içerip içermediğini doğru bir şekilde sınıflandırabildiğini göstermekte ve siber zorbalık içermeyen tweet'ler için ise geri çağırma puanı 0,68'dir. Buda, modelin siber zorbalık içermeyen tweet'lerin çoğunu doğru bir şekilde tanımlayabildiğini gösterirken, siber zorbalık içeren tweet'ler için hatırlama puanı 0,64'tür ve bu da modelin Siber zorbalık içeren tweetlerin çoğunu hatırlayabildiği anlamına gelmektedir. Her iki sınıf için f1 puanı sırasıyla 0.67 ve 0.65'tir. f1 puanı, modelin hem kesinlik hem de hatırlama puanlarını hesaba katan bir

doğruluk ölçüsüdür. Modelin, her iki tweet sınıfını da oldukça yüksek bir doğruluk derecesi ile doğru bir şekilde sınıflandırabildiğini göstermektedir. Genel olarak, GPT-3 sınıflandırma modelinin doğruluğu 0,66'dır ve bu, tweet'leri siber zorbalık içeren ve siber zorbalık içermeyen tweet'leri makul bir doğruluk derecesi ile sınıflandırabildiğini göstermektedir.

Table 3. İngilizce Tweetler için Bert performans sonuçları (Bert performance results for English Tweets)

	Precision	Recall	F1-score	Support
0	0.33	0.04	0.07	25
1	0.49	0.92	0.64	25
Accuracy			0.48	
Macro avg	0.41	0.48	0.36	50
Weighted avg	0.41	0.48	0.36	50

Bu performans raporu ise bir sınıflandırma algoritması içindir. Kesinlik, geri çağırma ve f1 puanı her sınıf (0 ve 1) için değerlendirilmektedir. Destek değeri, her sınıfa ait örnek sayısını gösterir. 0 sınıfı için kesinlik 0,33, geri çağırma 0,04 ve f1 skoru 0,07'dir. Bu, modelin, sınıf 0'a ait olduğu tahmin edilen örneklerin yalnızca %33'ünü doğru bir şekilde sınıflandırabildiği ve sınıf 0'ın gerçek üyelerinin yalnızca %4'ünü tanımlayabildiği anlamına gelmektedir. 0,07'lik f1 puanı oldukça düşüktür ve modelin bu sınıfta iyi performans göstermediğini göstermektedir. 1. sınıf için kesinlik 0,49, geri çağırma 0,92 ve f1 puanı 0,64'tür. Bu, modelin 1. sınıfa ait olduğu tahmin edilen örneklerin %49'unu doğru bir şekilde sınıflandırabildiği ve 1. sınıfa ait gerçek üyelerin %92'sini tanımlayabildiği anlamına gelmektedir. 0,64'lük f1 puanı oldukça yüksektir ve model bu sınıfta iyi performans gösterdiği anlamına gelmektedir. Genel olarak, modelin doğruluğu 0,48'dir ve bu oldukça düşüktür. Makro ortalamalı ise f1 puanı 0,36'dır ve bu puanda oldukça düşüktür. Bu da genel olarak İngilizce'den Türkçe'ye çevrilen Tweet'lerin kullanıldığı siber zorbalık sınıflandırmasında bile modelin iyi performans göstermediğini göstermektedir.



Şekil 1. İngilizce Tweetler için Gpt-3 Hata Matrisi Sonuçları (Gpt-3 Confusion Matrix Results for English Tweets)

Tweetlerin siber zorbalık içerip içermediğini sınıflandırmaya çalışan bir GPT-3 sınıflandırıcısının karışıklık matrisi, tweetlerin 17'sinin siber zorbalık içeriyor olarak doğru bir şekilde sınıflandırıldığını, 8'inin ise yanlış bir şekilde siber zorbalık içermediğini göstermektedir. Öte yandan, 9 tweet yanlışlıkla siber zorbalık içeriyor olarak sınıflandırılırken, 16 tweet doğru bir şekilde siber zorbalık içermiyor olarak sınıflandırılmıştır.

## 5. Tartışma ve Sonuç (Results and Discussion)

Hem GPT-3 English hem de BERT English, tweet'leri siber zorbalık içeren ve içermeyen olarak sınıflandırma yetenekleri açısından değerlendirilmiştir. GPT-3, 0,66'lık bir doğruluk elde etmiş ve bu, her iki tweet sınıfını

da oldukça yüksek bir doğruluk derecesi ile doğru bir şekilde sınıflandırabildiğini göstermiştir. Öte yandan BERT, genel olarak İngilizce'den Türkçe'ye çevrilen tweet'leri kullanarak siber zorbalık sınıflandırmasında bile iyi performans göstermediğini belirten 0,48'lik bir doğruluk elde etmiştir. BERT için makro ortalama f1 puanı 0,36 olarak görülmüş ve bu puan oldukça düşük olarak görülmektedir. Bu modellerin sonuçları, tweet'lerdeki siber zorbalığı sınıflandırmak için hem GPT-3'ün hem de BERT'nin doğruluğunu artırmak için daha fazla çalışma yapılması gerektiğini göstermektedir. Performansı GPT-3'ünkinden önemli ölçüde düşük olduğundan, özellikle daha fazla araştırma BERT'nin doğruluğunu artırmaya odaklanmalıdır. Ayrıca, diğer dillerden İngilizce'ye çevrilen tweet'leri sınıflandırmak için her iki modelin doğruluğunu artırmaya yönelik yöntemler üzerinde araştırma yapılmalıdır.

GPT-3 Türkçe, 0.60 kesinlik, 0.35 hatırlama ve 0.44 F1 puanı ile sınıf 0 ile %55 doğrulukla gerçekleştirilmiş olup, sınıf 1, 0.53 kesinliğe, 0.76 hatırlamaya ve 0.62 F1 puanına sahiptir. Her iki sınıfın makro ortalaması 0,53, ağırlıklı ortalaması ise 0,53'tür. GPT-3 English, siber zorbalık içermeyen tweet'leri sınıflandırmak için 0,65 ve siber zorbalık içeren tweet'ler için 0,67 kesinliğe sahip olduğu görülmektedir. Siber zorbalık içermeyen tweetlerin geri çağırma puanı 0,68, siber zorbalık içeren tweetlerin geri çağırma puanı ise 0,64 olarak sonuçlanmıştır. Her iki sınıf için f1 puanı sırasıyla 0.67 ve 0.65 ve modelin genel doğruluğu 0.66'dır. BERT İngilizce tweetlerde, sınıf 0 için 0,33 kesinliğe, 0,04 hatırlamaya ve 0,07 f1 puanına sahiptir. 1. sınıf için kesinlik 0.49, geri çağırma 0.92 ve f1 skoru 0.64'dür. Modelin genel doğruluğu 0,48 ve makro ortalamalı f1 puanı 0,36 olarak görülmektedir. GPT-3 İngilizce karışıklık matrisi, tweet'lerin 17'sinin doğru bir şekilde siber zorbalık içeriyor olarak sınıflandırıldığını, 8'inin ise yanlışlıkla siber zorbalık içermiyor olarak göstermiştir. Genel olarak, modellerin hiçbiri optimum performans göstermemiş, GPT-3 ve BERT İngilizce modelleri en kötü performansı göstermiştir.

Tweetlerdeki siber zorbalığı sınıflandırmak için BERT'nin doğruluğunu artırmak gerekmektedir ve bunun için daha fazla araştırma yapılmalıdır. Bu, modelin ön eğitimi için yeni mimarileri ve farklı teknikleri keşfetmeye öncelik verilebilir. Diğer dillerden İngilizce'ye çevrilmiş tweet'leri sınıflandırırken hem GPT-3'ün hem de BERT'nin doğruluğunu artırmaya yönelik yöntemler hakkında daha fazla araştırma yapılmalıdır. Bu, dile özel ön eğitim için yöntemleri keşfetmeyi ve farklı diller için ince ayar yapmak gerekmektedir. İspanyolca, Fransızca ve Almanca gibi diğer dillerde ve Instagram ve Facebook gibi diğer sosyal medya türlerinde siber zorbalığı tespit etmeye yönelik yöntemler geliştirmek için araştırma yapılmalı, bilgiyi aktarmak için transfer öğrenme tekniklerini kullanmanın etkililiği araştırılmalıdır.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

### Kaynaklar (References)

- [1] D. M. Gezgin, and C. Çuhadar, "Bilgisayar ve öğretim teknolojileri eğitimi bölümü öğrencilerinin siber zorbalığa ilişkin duyarlılık düzeylerinin incelenmesi." *Eğitim Bilimleri Araştırmaları Dergisi*, 2(2), 93-104. December 2012 Doi:[10.24106/kefedergi.702927](https://doi.org/10.24106/kefedergi.702927)
- [2] M. Özdemir, and F. Akar, "Lise öğrencilerinin siber-zorbalığa ilişkin görüşlerinin bazı değişkenler bakımından incelenmesi." *Educational Administration: Theory and Practice* 2011, Vol. 17, Issue 4, pp: 605-626 Kuram ve Uygulamada Eğitim Yönetimi 2011, Cilt 17, Sayı 4, ss: 605-626. May 2011, Doi:[10.14527/kuvey.2014.005](https://doi.org/10.14527/kuvey.2014.005)
- [3] H. T. Tanrıku, Kınay, and O. T. Arıcak, "Siber Zorbalığa İlişkin Duyarlılık Ölçeği: Geçerlik ve Güvenirlik Çalışması", *Trakya Üniversitesi Eğitim Fakültesi Dergisi*, vol. 3, no. 1, 2013. March 2013, Doi:[10.24315/trkefd.305449](https://doi.org/10.24315/trkefd.305449)
- [4] T. Arıcak, S. Siyahhan, A. Uzunhasanoglu, S. Saribeyoglu, S. Ciplak, N. Yılmaz, and C. Memmedov, "Cyberbullying among Turkish adolescents." *Cyberpsychology & behavior*, 11(3), 253-261. Jun 2008 Doi:[10.1089/cpb.2007.0016](https://doi.org/10.1089/cpb.2007.0016)
- [5] T. Ayas, and M. B. Horzum, "Öğretmenlerin sanal zorbalık algılarının çeşitli değişkenlere göre incelenmesi." *International Online Journal of Educational Sciences*, 3(2), 619-640. Doi:[10.31805/acjes.433205](https://doi.org/10.31805/acjes.433205)
- [6] S. Akhter, (2018, December). "Social media bullying detection using machine learning on Bangla text." In *2018 10th International Conference on Electrical and Computer Engineering (ICECE)* (pp. 385-388). IEEE. 10 February 2018, Doi:[10.1109/ICECE.2018.8636797](https://doi.org/10.1109/ICECE.2018.8636797)
- [7] M. G. Hussain, T. Al Mahmud, and W. Akhtar, "An approach to detect abusive bangla text." In *2018 International Conference on Innovation in Engineering and Technology (ICIET)* (pp. 1-5). IEEE. March 2019, Doi:[10.1109/CIET.2018.8660863](https://doi.org/10.1109/CIET.2018.8660863)
- [8] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, and I. Polosukhin, "Attention is all you need." *31st Conference on Neural Information Processing Systems (NIPS2017)*, Long Beach, CA, USA.

[9] J. Devlin, M. W. Chang, K. Lee, and K. Toutanova, "Bert: Pre-training of deep bidirectional transformers for language understanding", *arxiv.org*, Oct. 2018. [Online]. Available: <https://arxiv.org/abs/1810.04805>. [Accessed: Nov. 12, 2023].

[10] T. Brown, B. Mann, N. Ryder, M. Subbiah, J.D. Kaplan, P. Dhariwal, and D. Amodei, "Language models are few-shot learners." *Advances in Neural Information Processing Systems 33 (NeurIPS 2020)* 33, 1877-1901, arXiv:2005.14165

[11] *Models - OpenAI API*. (n.d.). [Online]. Available: <https://beta.openai.com/docs/models/gpt-3> [Accessed: June 10, 2022,].

\* *This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAME 2023) and the abstract was published as an e-book.*

This is an open access article under the CC-BY license

