

# JISTA

*Journal of Intelligent Systems:  
Theory and Applications*

MARCH 2023

ISSN: 2651-3927



**VOL 6 NO 1**

ARTIFICIAL INTELLIGENT > MACHINE LEARNING > DEEP LEARNING  
<https://dergipark.org.tr/en/pub/jista>



## Editorial Boards

---

### Honorary Editors

---

Zekai Şen, zsen@medipol.edu.tr, Istanbul Medipol University, Turkey

Burhan Turksen, bturksen@etu.edu.tr, TOBB ETU, Turkey

Harun Taşkın, taskin@sakarya.edu.tr, Sakarya University, Turkey

### Editor-In-Chief

---

Özer Uygun, ouygun@sakarya.edu.tr, Sakarya University, Turkey

### Editors

---

Mehmet Emin Aydın, mehmet.aydin@uwe.ac.uk, University of the West of England, UK

John Yoo, jyoo@bradley.edu, Bradley, University, USA

Salih Tutun, salihtutun@wustl.edu, Washington University in St. Louis, USA

Omar Mefleh Al-Araidah, alarao@just.edu.jo, ordan University of Science and Technology, Jordan

Ayten Yılmaz Yalçın, ayteny@sakarya.edu.tr, Sakarya University, Turkey

Alper Kiraz, kiraz@sakarya.edu.tr, Sakarya University, Turkey

Caner Erden, cerden@subu.edu.tr, Sakarya University of Applied Sciences, Turkey

Muhammed Fatih Adak, fatihadak@sakarya.edu.tr, Sakarya University, Turkey

Muhammet Raşit Cesur, rasit.cesur@medeniyet.edu.tr, İstanbul Medeniyet University, Turkey

Zafer Albayrak, Sakarya University of Applied Sciences, Turkey

### Language Editor

---

Barış Yüce, b.yuce@exeter.ac.uk, Exeter University, United Kingdom

## **Editorial Advisory Board**

---

- Ali Allahverdi, ali.allahverdi@ku.edu.kw, Kuwait University, Kuwait
- Andrew Kusiak, andrew-kusiak@uiowa.edu, The University Of Iowa, United States of America
- Ayhan Demiriz, ademiriz@sakarya.edu.tr, Gebze Technical University, Turkey
- Barış Yüce, b.yuce@exeter.ac.uk, Exeter University, United Kingdom
- Cemalettin Kubat, kubat@sakarya.edu.tr, Istanbul Gelişim University, Turkey
- Dervis Karaboga, karaboga@erciyes.edu.tr, Erciyes University, Turkey
- Eldaw E. Eldukhri, eeldukhri@ksu.edu.sa, King Saud University, College of Engineering Al-Muzahmia Branch, Saudi Arabia
- Ercan Öztemel, eoztemel@marmara.edu.tr, Marmara University, Turkey
- Güneş Gençyılmaz, gunesgencyilmaz@aydin.edu.tr, Turkey
- Hamid Arabnia, hra@cs.uga.edu, University of Georgia, United States of America
- Lyes Benyoucef, lyes.benyoucef@Isis.org, Aix-Marseille University, Marseille, France
- Maged Dessouky, maged@rcf.usc.edu, University of Southern California, Los Angeles, United States of America
- Mehmet Savsar, mehmet.savsar@ku.edu.kw, Kuwait University, Kuwait
- Mohamed Dessouky, dessouky@usc.edu, University Of Southern California, Los Angeles, United States of America
- M.H. Fazel Zarandi, zarandi@aut.ac.ir, Amerikabir University Of Technology, Iran
- Türkay Dereli, dereli@gantep.edu.tr, Hasan Kalyoncu University, Turkey
- Witold Pedrycz, pedrycz@ee.ualberta.ca, University Of Alberta, Canada
- Yılmaz Uyaroğlu, uyaroglu@sakarya.edu.tr, Sakarya University, Turkey

## **Editorial Assistants**

---

- Enes Furkan Erkan, eneserkan@sakarya.edu.tr, Sakarya University, Turkey
- Elif Yıldırım, elifyildirim@sakarya.edu.tr, Sakarya University, Turkey






## Contents

### Research Articles

- 1. Makine Öğrenmesinde Kategorik Veri Kodlama Tekniğinin Kullanımına Alternatif Bir Çözüm Yöntemi** 1-11  
*Ender ŞAHİNASLAN, Mustafa GÜNERKAN, Önder ŞAHİNASLAN*
- 2. Kasislerin Yakıt Tüketimine Etkisinin RNN, LSTM, GRU Tekrarlayan Derin Öğrenme Algoritmaları ile Tespiti** 12-23  
*Mustafa Fatih, TOSUN Ali ŞENTÜRK*
- 3. Yerel Arama Bölümü Güncellenmiş Arı Algoritması ile Gezgin Satıcı Problemi Optimizasyonu** 24-33  
*Murat ŞAHİN*
- 4. A Real-Time Location System Design for Production Facilities Working under COVID-19 Pandemic Precautions** 34-42  
*Sena KIR*
- 5. Makine Öğrenmesi Yöntemleri Kullanılarak Öğrencilerin Kazanım Bilgileri ile Sınavlardaki Başarı Durumunun Tahmini** 43-51  
*Muhammed Fatih ADAK, Ömer DURALİOĞLU*
- 6. Tek Görüntü Süper Çözünürlük Uygulamaları İçin Görsel Kaliteyi İyileştirmeye Yönelik Yeni Bir Yaklaşım** 52-58  
*Fatih Mehmet ŞENALP*
- 7. Robot-Nesne Etkileşiminde Çok Kipli Hata Sezme** 59-66  
*Arda İNCEOĞLU, Gökhan İNCE, Yusuf YASLAN, Sanem SARIEL*
- 8. Yapay Öğrenme ile Farklı Akıllı Ulaşım Senaryoları Altında Araçtan Her Şeye Haberleşme Standardı Seçimi** 67-74  
*Hakan Alp EREN, Nihat ADAR, Ahmet YAZAR*
- 9. Derin Öğrenme Yöntemleri Kullanılarak BT Taramalarında Beyin Kanaması Teşhisinin Karşılaştırmalı Bir Analizi** 75-84  
*Tuğrul Hakan GENÇTÜRK, Fidan KAYA GÜLAĞIZ, İsmail KAYA*
- 10. Neural Coreference Resolution for Turkish** 85-95  
*Şeniz DEMİR*



# Makine Öğrenmesinde Kategorik Veri Kodlama Tekniğinin Kullanımına Alternatif Bir Çözüm Yöntemi

Ender Şahinaslan<sup>1</sup> , Mustafa Günerkan<sup>2</sup> , Önder Şahinaslan<sup>3\*</sup> 

<sup>1</sup> Trakya Üniversitesi, Bilgisayar Mühendisliği Bölümü, Edirne, Türkiye

<sup>2</sup> Maltepe Üniversitesi, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye

<sup>3</sup> Maltepe Üniversitesi, Bilişim Bölüm Başkanlığı, İstanbul, Türkiye

dr.endsa@gmail.com, mgunerkan@gmail.com, ondersahinaslan@maltepe.edu.tr

## Öz

Makine öğrenimi, derin öğrenme algoritmaları kullanarak insan zekâsını taklit eden bir teknolojidir. Öğrenme algoritmaları yalnızca sayısal veri kümeleri üzerinde çalışır. Kategorik veri kümeleri nitel veya nicel verilerden oluşur. Nitel veri setlerinin öğrenme algoritmalarında kullanılabilmesi için veri setinin sayısallaştırılması gerekmektedir. Sayısallaştırma için etiket kodlama, sıralı kodlama, toplam kodlama, ikili kodlama ve sıcak kodlama gibi birçok kodlama tekniği vardır ancak bu kodlama teknikleri performans, maliyet ve kullanım açısından bazı güçlükler ve yetersizlikleri barındırmaktadır. Diğer taraftan bir kodlama tekniği ile elde edilen eğitim çıktısının orijinalinin bilinmesine ihtiyaç duyulabilmektedir. Bu çalışma, kategorik verilerin sayısallaştırılmasında kodlama tekniklerinin kullanılmasından kaynaklanan yetersizliklere çözüm olabilecek, daha özgün ve daha iyi performansa sahip bir altyapı oluşturma arayışının bir sonucu olarak ortaya çıkmıştır. Geliştirilen yöntem uluslararası bir lojistik firmada 7 farklı kategoride toplam 46 kategorik özellik ve 80.154.139 adet veri üzerinden uygulanmıştır. Testlerin sonucuna göre veri setleri bazında %23.07 ile %300.13 arasında toplamda %153.62 performans kazancı elde edilmiştir. Bu sonuçlar, geliştirilen yöntemin daha başarılı ve uygulanabilir olduğunu göstermektedir. Çalışma, yüksek performans kazancı ve özgün yapısı ile benzer alanlarda kolaylıkla kullanılacak bir yapıya sahiptir. Makine öğrenmesinde kodlama tekniklerinin kullanımına alternatif bir çözüm sunmuştur.

**Anahtar kelimeler:** Kodlama, Makine Öğrenimi, Sistem Geliştirme, Teknoloji ve Yenilik, Veri Yönetimi.

## An Alternative Solution Method to Using Categorical Data Encoding Technique in Machine Learning

### Abstract

Machine learning is a technology that mimics human intelligence using deep learning algorithms. Learning algorithms only work on numerical datasets. Categorical datasets consist of qualitative or quantitative data. In order for qualitative data sets to be used in learning algorithms, the data set must be digitized. There are many coding techniques for digitization, such as label coding, sequential coding, total coding, binary coding and hot coding, but these coding techniques have some difficulties and inadequacies in terms of performance, cost and use. On the other hand, it may be necessary to know the original of the training output obtained with a coding technique. This study has emerged as a result of the search for a more original and better performing infrastructure that can be a solution to the inadequacies arising from the use of coding techniques in the digitization of categorical data. The developed method was applied on a total of 46 categorical features and 80.154.139 pieces of data in 7 different categories in an international logistics company. According to the results of the tests, a total of 153.62% performance gain was obtained between 23.07% and 300.13% on the basis of data sets. The study has a structure that can be used easily in similar areas with its high performance gain and original structure. It offered an alternative solution to the use of coding techniques in machine learning.

**Keywords:** Encoding, Machine Learning, Systems Development, Technology and Innovation, Data Management.

\* Sorumlu yazar.  
E-posta adresi: ondersahinaslan@maltepe.edu.tr

Alındı : 4 Temmuz 2022  
Revizyon : 14 Ekim 2022  
Kabul : 7 Kasım 2022

## 1. Giriş (Introduction)

Yapay zekâ ve makine öğrenmesi, akıllı sistemlerin inşasında ve geliştirilmesinde önemli rollere sahiptir. Makine öğrenimi, derin öğrenme algoritmaları kullanılarak insan zekâsını taklit eden bir bilgisayar teknolojisidir. Bu yeni teknoloji bilgisayar, bilişim, istatistik, bilgi ve kontrol teorisi, psikoloji, felsefe gibi birçok disiplin ve fikirlerden yararlanır (Mitchell, 1997). Makine öğrenimi, belirli görevleri gerçekleştirmek üzere sistemlerin verilerden öğrenebileceği, örüntüleri tanımlayabileceği ve minimum insan müdahalesi ile kararlar alabileceği fikrine dayanan bir yapay zekâ dalıdır (SAS, 2022). Makine öğrenimi yinelemeli verileri analizi sonucunda analitik bir model oluşturur. Kullanılan algoritmalar güvenilir sonuçlara ulaşmada önceki hesaplamaları kullanır. Öğrenme algoritmaları girdi olarak sayısal verilerden oluşan öznitelik matrisine ihtiyaç duyar. Kategorik verilerin kullanılabilir öznitelik matrisine dönüştürülebilmesi için kodlama yöntemleri kullanılır (Cerda vd., 2018). Bu kodlama tekniklerinin kullanımı bir çözüm sağlasa da bu defa kategorik veriler için hangi sayısal değerlerin atandığının bilinmemesi durumuyla karşılaşılabilir. Bu durum veri ön işleme evresinde anlaşılması ve çözülmesi gereken problemlerden biridir. Veri ön işleme süreci, verilerle ilgili sorunları gidermek ve veri analiz öncesine hazırlık yapmak için gerçekleştirilir (Famili vd., 1997). Kullanılacak algoritmaların daha doğru ve verimli sonuçlar üretmesine yardımcı olmak için veriler, asıl veri analizinden önce bir dizi ön işleme tabii tutulur (MarketResearch, 2022). Veri setleri güvenilir, tekrar edilebilir ve sayısal değerlerden oluşmalıdır. Verilerin sayısallaştırılmasında etiket kodlama, sıcak kodlama, sıralı kodlama, ikili kodlama, Helmert kodlama ve Hash kodlama gibi bilinen kodlama teknikleri vardır. Bu tekniklerden *Etiket Kodlama* tekniğinde her etikete alfabetik sıraya göre benzersiz bir tam sayı atanır (Sethi, 2022). Atanan değerler 0 ile başlar ve kategorik veri tür sayısından bir eksik olacak şekilde verilir (Scikit-Learn, 2022). Özniteliklerin sıralı olmadığı durumlarda yaygın kullanılan *One-Hot Kodlama* tekniğinde: her kategori için ikili sütun oluşturulur ve kategoriler her bir özellikteki benzersiz değerlere göre türetilir. Bu kategoriler manuel olarak da belirlenebilir (ScikitLearn-OneHotEncoder, 2022). *Ordinal Kodlama* tekniğinde: mevcut kategorilerin sayısının bilindiği durumda her kategoriye bir tam sayı atanarak nitelikler sıralı tam sayılara dönüştürülür (ScikitLearn-OrdinalEncoder, 2022). *Binary Kodlama* tekniğinde: kategorik veriler için her kategoriye sayısal bir değer atanır, ardından ikili gösterime dönüştürülür ve bu ikili biçimde temsil edilir (Seeger, 2018). *Helmert Kodlama* tekniğinde: kategorik bir değişkenin her seviyesi, sonraki seviyelerin ortalaması ile karşılaştırılır (Potdar vd., 2017). *Hash Kodlama* tekniğinde: farklı boyuttaki girdiler için sabit değerler üretilir ve bu değerler öznitelik olarak kullanılır (Turcanik ve Javurek, 2016).

Bu çalışma Türkiye dış ticaretinin yaklaşık %8'ini gerçekleştiren uluslararası lojistik bir firmanın 2010-2021 yılları arasındaki beyanname veri setleri üzerinde gerçekleştirilmiştir. Nitel özelliğe sahip kategorik verilerin varlığı, bu verilerin sayısallaştırma ihtiyacını doğurmuştur. Sayısallaştırma sürecinde kodlanması kolay ve performanslı olan etiket kodlama tekniği kullanılmıştır. Etiket kodlama tekniği kullanımı sonucunda elde edilen eğitim sonuçlarında kategorik verilere hangi sayısal değerlerin atandığı tam olarak elde edilememiştir. Bu tekniğin kullanımından kaynaklanan yetersizlik ve düşük performans problemi nedeniyle alternatif yöntem, yapı ve çözüme ihtiyaç duyulmuştur. Bu ihtiyacın giderilmesine yönelik araştırmalar sonucunda kategorik verilerin sayısallaştırılmasında bilinen tekniklere alternatif olabilecek bir yöntem geliştirilmiştir. Her iki yöntem yaklaşık 80 milyon veri üzerinden aynı laboratuvar koşullarında süre performans başarımlarını testlerine tabii tutulmuştur. Bu çalışmada önerilen yöntemin ciddi performans kazancına yardımcı olduğu görülmüştür.

Çalışmanın literatür bölümünde konuyla ilgili güncel çalışmalara, materyal ve yöntemler bölümünde çalışma ortamı, yöntem, veri seçimi, veri seti üzerinden yürütülen analiz, kodlama, uygulama ve test çalışmalarına ve kıyaslama yapabilmek için en çok bilinen ve kullanılan etiket kodlama çalışmasına yer verilmiştir. Çalışma sonucunda elde edilen sonuçlar bulgu bölümünde, sonuçların değerlendirilmesi ve çıkarımlar tartışma ve sonuç bölümlerinde sunulmuştur.

## 2. Literatür (Literature)

Çalışma konusuyla ilgili yapılan literatür taraması sonucunda günümüzde oldukça popüler ve farklı farklı alanlarda uygulama imkanı bulan makine öğrenmesine dayalı yöntemlerin uygulandığı çalışmalara yeterli sayıda ulaşılmamasına rağmen kodlama teknikleri üzerine yürütülen çalışmalara sınırlı sayıda ulaşılabilmektedir. (Jackson & Agrawal, 2019), çalışmada *Etiket kodlama*, *One-Hot kodlama* ve *Binary kodlama* tekniklerinin performansını ele almışlardır. Çalışma sonucunda en iyi performansı *Etiket kodlama* en düşük performansı ise tekniğinde *One Hot kodlama* tekniğinde bulmuşlardır. (Shen & Shafiq, 2019), kategorik verilerin sayısallaştırılmasında *Etiket* ve *One-Hot kodlama* tekniklerini kullanmışlardır. Kodlama süresi bakımından Label kodlama tekniğini daha avantajlı bulmuşlardır. (Jiang vd., 2020), üretim verileri üzerinden verim tahmini gerçekleştirmede kullandıkları kodlama teknikleri kıyaslamışlardır. (Yu vd., 2020), kredi sınıflandırmasında kayıp veri problemini çözmek için *One-Hot kodlama* tekniğine dayalı bir veri ön işleme yöntemi önermişlerdir. (Chandradeva vd., 2019), finansal işlem dolandırıcılığı tespitinde denetimli makine öğrenme algoritmaları kullanarak sahte işlem olaylarını %83 oranında tespit edebilmişlerdir. Kategorik verilerin kodlanmasında, Etiket kodlama tekniğinin makine öğrenme algoritması tarafından

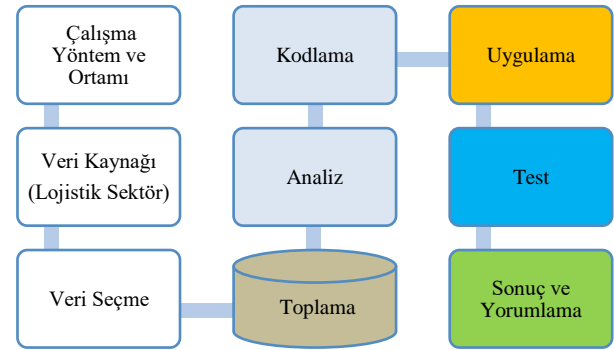


yorumlanma dezavantajı nedeniyle *One-Hot kodlama* tekniği kullanmışlardır. (Nerlikar vd., 2020), bilgisayar tabanlı saldırıları tespit ve analiz etmeyi amaçlamışlardır. Verimlilik için veri ön işleme aşamasında ilgisiz özellikleri kaldırmışlardır. *One-Hot kodlama tekniği* kullandıkları çalışmalarında %96,5 doğruluk oranı elde etmişlerdir (Chen vd, 2020), bulut ortamlarındaki ağlara izinsiz girişlerin tespitine odaklanmışlar, kodlama tekniği olarak *Etiket kodlama ve One-Hot kodlama* teknikleri kullanmışlardır. Oluşturdukları model ile %99,71 doğruluk değerine ulaşmışlardır. (Li, 2018), geçmiş kira verilerini kullanarak konut piyasası için objektif bir ölçüm sağlayamaya yarayan aylık konut kirasını doğru tahmin etmeye çalışmıştır. Çalışmasında verileri modele uygun hale getirmek için *Etiket kodlama ve One-Hot kodlama* tekniğini kullanmıştır. Kategori sayısının çok fazla olmadığı durumlarda *One-Hot kodlama* tekniğini önermiştir. (Chakrabarty, 2019) American Airlines iç hat uçuş bilgilerinin analizinde veri madenciliği ve makine öğrenimi yaklaşımları üzerinden uçuşun varış gecikmesini tahminine çalışmışlardır. Veri ön işleme sürecinde *Etiket kodlama ve One-Hot kodlama* tekniklerini kullanmışlardır. (Li vd., 2020), hasta sağlık verileri üzerinden kanser klinik son nokta tahmini yapmada derin öğrenmeye dayalı bir yaklaşım önerdikleri çalışmada *Etiket kodlama ve One-Hot kodlama* tekniklerini kullanmıştır. (Sharma vd., 2020), ağ güvenliğine yönelik saldırıların tespitinde sistemin normal davranışından herhangi bir sapma olup olmadığını anlamaya yönelik çalışmada makine öğrenme algoritmalarından yararlanmışlardır. Çalışma veri ön işleme süreçlerinde *Label kodlama ve One-Hot kodlama* tekniklerini kullanmışlardır. Çalışmada kullandıkları algoritmalarda %98 ile %100 arasında değişen doğruluk oranları elde etmişlerdir. (Al-Shehari ve Alsowail, 2021), kurum içi siber saldırıların doğuracağı zararların etkisini tespit etmede karar ağacı ve en yakın komşuluk gibi bilinen öğrenme tabanlı algoritmaları kullanmışlardır. Veri ön işleme süreçlerinde *Etiket kodlama ve One-Hot kodlama* tekniklerinden yararlanmışlardır. (Günernkan vd., 2022), gümrük beyanname oluşturma sürecinde öğrenmeye dayalı algoritmaların performansını ölçtükleri çalışmalarında kategorik verilerin çokluğu nedeniyle sayısallaştırma sürecinde *Etiket kodlama tekniğini* kullanmıştır. (Reilly vd, 2022), 10 yıllık bir dönemi kapsayan, ev içi yangın yaralanmalarının kategorik bir veri setini kullanmışlardır. Algoritmanın doğru sonuçlar üretmesinde *Label kodlama, One-Hot kodlama ve Ordinal kodlama* gibi kodlama tekniklerinden çalışmaya uygun olanın seçiminin önemine vurgu yapmışlardır. (Yılmaz Yalçiner ve Gelen Mert, 2021), bir konaklama işletmesi için doluluk oran tahmininde yapay sinir ağlarını kullanmışlardır. (Şahinaslan vd., 2022), Naive Bayes sınıflandırma algoritması aracılığıyla Youtube sosyal medya uygulamasında yer alan 15.082 veri setini üzerinden %65,56 oranında doğru sonuca ulaşmışlardır. (Kıran vd., 2022), kullandıkları veri özniteliklerini

dikkate alarak çalışmalarında derin öğrenme yöntemini tercih etmişlerdir. (Karasulu vd., 2022), insan kulağı görüntülerinden cinsiyeti belirlemek için derin öğrenme tabanlı melez bir yaklaşım geliştirmişler. Sayısal verilerin Bu çalışmalarda kullanılan kodlama tekniklerine ilişkin özel bir bilgiye rastlanmamıştır.

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

Makine öğrenme algoritmalarının çalıştırılabilmesi için veri setlerindeki özniteliklerin sayısal değerlere sahip olması gerekir. Nitel özelliklere sahip kategorik verilerin sayısallaştırılması gerekir. Sayısallaştırma için birçok kodlama tekniği mevcuttur ancak bu kodlama teknikleri performans, maliyet ve kullanımından kaynaklı bazı zorluk ve yetersizlikleri barındırmaktadır. Bu sorunun çözümüne katkı sunacak yeni bir yol-yöntem arayışına ihtiyaç duyulmuştur. Uluslararası bir lojistik firmada karşılaşılan benzer bir sorunun çözümünde alternatif bir yöntem geliştirilmiştir. Elde edilen başarılı sonucun literatüre kazandırılması amaçlanmıştır. Yürütülen çalışmalara ait ana süreç aşamaları Şekil 1'de gösterilmektedir.



Şekil 1. Çalışma süreç aşamaları (Study process stages)

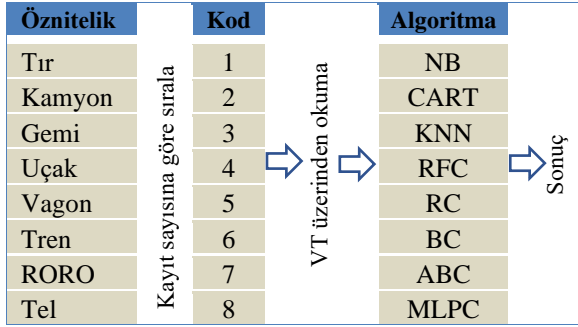
Yürütülen çalışmanın ana süreçleri çalışma ortamının hazırlanması, veri kaynağının belirlenmesi, seçilen verilerin toplanması, öz niteliklerin belirlenmesi, veri analizi, kodlama, uygulama, test ve sonuçların değerlendirme aşamalarından oluşmaktadır.

#### 3.1. Çalışma ortamı (Study environment)

Bu çalışma, Windows 10 Pro 64 bit işletim sistemi, işlemci Intel(R) Xeon(R) Gold 6154 CPU @ 3.00 GHz 2.99 GHz işlemcili, x64 tabanlı işlemci mimarisine ve 11.7 GB yüklü belleğe(RAM) sahip olan bir bilgisayar üzerinde gerçekleştirilmiştir. Çalışılan veri setleri ve eşleştirme tabloları için MSSQL Server Management Studio v17.9 VT yönetim sistemi kullanılmıştır. Veri öznitelik analiz ve tablo kayıt işlemlerinde T-SQL kullanılmıştır. Uygulama geliştirme, kodlama ve test işlemlerinde Spyder IDE 5.1.5 editörü ve Python 3.9.7 64 bit programlama dili kullanılmıştır. Performans testleri VT'nın az kullanıldığı gün ve saatte gerçekleştirilmiştir.

### 3.2. Yöntem (Method)

Bu çalışmada mevcut bir takım kodlama tekniklerinin kullanımına alternatif olabilecek bir yöntem geliştirilerek buna ait uygulama ve testler gerçekleştirilmiştir. Geliştirilen yöntemle ait işlem aşamaları Şekil 2’de gösterilmektedir.




Şekil 2. İşlem adımları (Process steps)

Çalışmada kullanılacak verilerin ön inceleme ve analizi sonucunda kategorik veri öznitelikleri belirlenir. Veri setinin öznitelikleri belirlenirken delphi metodu kullanılmıştır. Uzmanlardan yararlanılarak bir uzlaşma veya karara varılmıştır. Burada da gümrük mevzuatı bilgisi olan kişilere bilgi alanı tahmininde kullanılacak özniteliklerin tespiti için sorular sorularak modeller belirlenmiştir. Modellerin ilk eğitim sonuçları değerlendirilerek özniteliklerin üzerinden geçilerek değişiklikler yapılmıştır. Bu süreç kabul edilebilir başarı oranlarına ulaşıncaya kadar tekrarlanarak modellere son hali verilmiştir. Bu öznitelik kayıtları, veri tabanı(VT) üzerinde oluşturulan tablo üzerinde kaydedilir. Her bir özneliğe ait veri kayıt sayıları hesaplanır. Elde edilen kayıt sayıları büyükten küçüğe sıralanır. Sıralamaya uygun şekilde en fazla veri hacmine sahip olan veri kategorisine 1, ardından gelene 2, daha sonra 3 şeklinde ardışık olarak artırım yapılır. Belirlenen tam sayı değeri ilgili tablo üzerinde açılmış olan ‘kod’ veri alanına işlenir. Üretilen bu sayısal kodlar makine öğrenme uygulamalarında kullanılır. Geliştirilen bu yöntemde öğrenme algoritmaları kullanımından önce her hangi bir kodlama tekniği kullanımına ihtiyaç duyulmaz. Geliştirilen yöntemin bilinen bir kodlama yöntemi ile kıyaslaması yapılarak sonuçların değerlendirilmesi gerçekleştirildi.

### 3.3. Veri kaynağı (Data source)

Çalışmada uluslararası bir lojistik firmanın 2010 ve 2021 yılları arasındaki beyanname üzerinde yer alan 7 ayrı veri setinde toplam 80154139 adet kayıt kullanılmıştır. Çalışmada kullanılan veri setlerinden ‘taşıma şekli’ veri seti türünü detay olarak incelediğimizde bu veri türünde toplam 4064131 adet veri tespit edilmiştir. Bu verilerin 2010-2021 yılları arasındaki dağılım grafiği Şekil 3’de gösterilmektedir.



Şekil 3. Taşıma şekli verilerinin yıllara göre dağılımı (Distribution of mode of transport data by years)

Sunulan bu verilere setinde en az veri 277.288 adetle 2010 yılında gerçekleşirken en fazla veri 396.520 adetle 2017 yılında gerçekleşmiştir. Yıllık ortalaması yaklaşık 340.000 adettir. Çalışmada kullanılan diğer veri seti tür ve adetleri veri seçme bölümünde açıklanmaktadır.

### 3.4. Veri seçimi (Data selection)

Bu çalışma lojistik veri kaynağı beyanname kayıtları üzerinde yer alan kategorik verilerden seçilen ‘teslim şekli’, ‘taşıma şekli’, ‘sevk ülke’, ‘döviz türü’, ‘birim’, ‘uluslararası anlaşma’, ‘ödeme şekli’ öznitelikleri üzerinde gerçekleştirilmiştir. Seçilen bu yedi farklı veri setine ait kayıt sayıları Tablo 1’de gösterilmektedir.

Tablo 1. Veri kümesi kayıt sayıları (Dataset record counts)

Veri Seti	Kayıt Sayısı
Teslim Şekli	4034742
Taşıma Şekli	4064131
Sevk Ülke	4031130
Döviz Türü	4065936
Birim	22015778
Uluslararası Anlaşma	22000635
Ödeme Şekli	19941787
Toplam	80154139

### 3.5. Veri Toplama (Data collection)

Sürecin bu aşamasında beyanname kayıtlarından seçimi yapılan kategorik veriler MS SQL VT üzerinde oluşturulan eşleştirme tablosu üzerinde toplanmıştır. Öznitelikler bilgileri gruplanarak sayıları geçici bir tabloya alınmıştır. Geçici tablo üzerindeki veriler en çok olan bilgiye göre tersten sıralanarak eşleştirme tablosuna eklenmiştir. Kategorik veri taşıma türü özneliğine ait verilerin eşleştirme tablosunda toplanmasına ilişkin T-SQL sözdizimi örneği Şekil 4’de gösterilmiştir.

```
select bordervehiclemode, sayi=COUNT(*)
into #gec
from MLGumrukDosyaTasimaSekli group by bordervehiclemode

insert into gnlparml (modul, grup, kod, aciklama, updttime, upduser)
select 'ML', 'VEHMODE', bordervehiclemode,
ROW_NUMBER() OVER(ORDER BY sayi desc), GETDATE(), 3676
from #gec order by sayi desc

drop table #gec
```

Şekil 4. Veri toplama sözdizimi örneği (Data collection syntax example)



### 3.6. Analiz (Analysis)

Çalışma kapsamında ele alınan her bir kategorik veri tür ve kayıt sayıları bakımından analiz edilerek öz nitelik sayılarına ulaşmaya çalışıldı. Kategorik temelde toplanan verilerin analiz ve değerlendirilmesi sonucunda toplam 53 adet öz nitelik belirlendi. Bu verilere ait belirlenen öz nitelik sayıları Tablo 2’de gösterilmektedir

**Tablo 2.** Veri seti öz nitelik sayıları (Dataset attribute counts)

Veri Seti	Öznitelik Adet
Teslim Şekli	9
Taşıma Türü	8
Sevk Ülke	10
Döviz Türü	6
Birim	7
Uluslararası Anlaşma	6
Ödeme Şekli	7

### 3.7. Kodlama (Coding)

Bu aşamada kullanılan yöntem; her bir kategorik veri üzerinde yer alan öz nitelikler bazında kayıt sayıları tespit edilip, büyükten küçüğe sıralandıktan sonra kayıt sayısı en yüksek olana 1, ardından gelene 2, daha sonraki sayıya 3 olacak şekilde ardışık tamsayı kodlaması yapılarak eşleştirme tablosuna işlenir. Taşıma türü verilerine ait veri seti kod ve kayıt sayıları Tablo-3’de verilmektedir.

**Tablo 3.** Kodlama örneği (Coding example)

Taşıma Türü	Kod	Kayıt Sayısı
TIR	1	1471167
KAMYON	2	1057390
GEMİ	3	833475
UCAK	4	617526
VAGON	5	79251
TREN	6	4240
RORO	7	1071
TEL	8	11

Taşıma türüne göre kayıt sayıları büyükten küçüğe sıralanmıştır. Sıralama sonucunda göre 1.471.167 adet veri ile en fazla kayıt sayısına sahip ‘TIR’ taşıma türü kod değerine (1) tamsayı değeri ile kodlanmıştır. KAMYON 1.057.390 adet veri ile ikinci büyük veriye sahip olup buna karşılık kod değeri (2), 833.475 adet veri ile üçüncü sırada GEMİ(3), UCAK(4), VAGON(5), TREN(6), RORO(7), elektrik hatları üzerinden gerçekleştirilen elektrik ithalat-ihracatı anlamına gelen TEL öz niteliğine 8 ataması yapılmıştır. Benzer şekilde her bir kategorik veri üzerinden ayrı bir çalışma yapılarak ilgili kategorik verilerin öz niteliklerine kod ataması yapılarak VT eşleştirme tablosuna kaydedilmiştir. Böylece her bir veri setinde yer alan öz nitelikler farklı bir tamsayı ile kodlanmıştır.

### 3.8. Uygulama (Practice)

Uygulamada beyanname kategorik verileri ile eşleştirme tablosunda yer alan kodlama verileri anahtar alanlar üzerinden eşleştirildi. Böylece başka her hangi bir kodlama tekniğine ihtiyaç duyulmadan uygulamaların çalıştırılması mümkün oldu. Sayısallaştırılmış olan bu veriler VT eşleştirme tablosundan okunarak makine öğrenme algoritmaları üzerinde çalıştırıldı. Eğitim sonuçları ikili(binary) dosyada saklandı ve tahminleme parametresi olarak kullanıldı. Ele alınan kategorik verilerden biri olan taşıma şekli veri setindeki öz niteliklere ait sayısal(kod) değerlerinin VT üzerinden okunmasına dair Python programında yazılan SQL sorgusuna ait sözdizimi örneği Şekil 5’de gösterilmektedir.

```
import pandas as pd
import pyppodb
from sklearn.model_selection import train_test_split

connection=pyppodb.connect('DRIVER=SQL_SERVER;SERVER=SERVER;DATABASE=OBName;UID=UID;PWD=Password')
c = connection.cursor()
c.execute("""
SELECT H.firnumber
, customoffice =P1.EncodedCode
, regime = P2.EncodedCode
, declaration1 = P3.EncodedCode
, declaration2 = P4.EncodedCode
, entryoffice = P5.EncodedCode
, internalvehiclemode = P6.EncodedCode
, bordervehiclemode = P7.EncodedCode
, bordervehiclcode
FROM H,CustomOfficeP1,FaizimSekli H
LEFT OUTER JOIN gnlparml P1 ON (P1.Modul = 'NL' AND P1.Type = 'CUSTOFFICE' AND P1.Code = H.customoffice)
LEFT OUTER JOIN gnlparml P2 ON (P2.Modul = 'NL' AND P2.Type = 'REGIME' AND P2.Code = H.regime)
LEFT OUTER JOIN gnlparml P3 ON (P3.Modul = 'NL' AND P3.Type = 'DECL1' AND P3.Code = H.declaration1)
LEFT OUTER JOIN gnlparml P4 ON (P4.Modul = 'NL' AND P4.Type = 'DECL2' AND P4.Code = H.declaration2)
LEFT OUTER JOIN gnlparml P5 ON (P5.Modul = 'NL' AND P5.Type = 'CUSTOFFICE' AND P5.Code = H.entryoffice)
LEFT OUTER JOIN gnlparml P6 ON (P6.Modul = 'NL' AND P6.Type = 'VEHMODE' AND P6.Code = H.internalvehiclemode)
LEFT OUTER JOIN gnlparml P7 ON (P7.Modul = 'NL' AND P7.Type = 'VEHMODE' AND P7.Code = H.bordervehiclemode)
""")
```

**Şekil 5.** Veritabanı okuma sözdizimi (Database read syntax)

Çalışmada ele alınan kategorik verisi için benzer SQL söz dizim cümleleri yazılarak uygulanmıştır. Böylece öğrenme algoritmalarının kullanabileceği sayısal değerlere ulaşılmıştır. Kurulan bu altyapı üzerinden veri seti eğitim çalışmaları yürütülmüştür. Gaussian Naive Bayes(NB), karar ağaçları (CART), en yakın komşuluk(KNN), rastgele orman(RFC), ridge(RC), torbalama(BC), artırma(ABC) ve MLPC sınıflandırma algoritmaları kullanılarak taşıma şekli veri setinin eğitimine ilişkin Python sözdizimi örneği Şekil 6’da gösterilmektedir.

```
models = []
models.append(('NB', GaussianNB()))
models.append(('CART', DecisionTreeClassifier()))
models.append(('KNN', KNeighborsClassifier()))
models.append(('RFC', RandomForestClassifier()))
models.append(('RC', RidgeClassifier()))
models.append(('BC', BaggingClassifier()))
models.append(('ABC', AdaBoostClassifier()))
models.append(('MLPC', MLPClassifier()))
test_size = 0.25
seed = 7
results = []
names = []
for name, model in models:
    X_train, X_test, Y_train, Y_test = train_test_split(X, Y, test_size=test_size, random_state=seed)
    model.fit(X_train, Y_train)
    result = model.score(X_test, Y_test)
    results.append(result)
    names.append(name)
msg = '%s: %f' % (name, result)
print(msg)
```

**Şekil 6.** Veri seti eğitimi sözdizimi (Dataset training syntax)

Eğitim çalışmalarında ‘test\_size’ parametresi %25 olarak seçilmiştir. Seçilen test size oranı, farklı test size oranlarına göre en iyi sonucu vermiştir. Rastgele sayı üretici değerinin verildiği ‘seed’ parametresi 7 seçilmiş ve yine yapılan denemelerde en iyi sonuç bu değer ile alınmıştır. Önerilen modelde herhangi bir kodlama tekniği kullanımına ihtiyaç duyulmamıştır. Eğitim

verilerinin ikili dosya olarak saklamasında Pickle kütüphanesinden yararlanılmıştır. İkili dosya saklama sözdizimi örneği Şekil 7’de gösterilmektedir.

```
dataframe = pd.DataFrame(c.fetchall(), columns = ['firmnumber', 'customsoffice', 'regime',
                                                'declaration1', 'declaration2', 'entryoffice',
                                                'internalvehiclemode', 'bordervehiclemode'])
array=dataframe.values
X = array[:,0:8]
Y = array[:,8]

model=BaggingClassifier()
X_train, X_test, Y_train, Y_test = train_test_split(X, Y, test_size=0.25, random_state=7)
model.fit(X_train, Y_train)
filename="TasimaSekli_Model.pickle"
dump(model, open(filename, "wb"))
```

Şekil 7. Dosya saklanma sözdizimi (File storage syntax)

Makine öğrenme algoritmaları tahmininde sayısal değerler kullanır. Çalışmada VT eşleştirme tablosundaki kategorik verilerin sayısal kod karşılıkları kullanılarak tahminleme gerçekleştirildi. Taşıma şekli kategorik verisinin torbalama sınıflandırma model tahminine ilişkin Python sözdizimi örneği Şekil 8’de gösterilmiştir

```
tasimasekli_model=BaggingClassifier()
filename="TasimaSekli_Model.pickle"
tasimasekli_model = load(open(filename, "rb"))
predictedbordervehiclemode = tasimasekli_model.predict([[dftt.get('firmnumber')[0],
dftt.get('customsoffice')[0],
dftt.get('regime')[0],
dftt.get('declaration1')[0],
dftt.get('declaration2')[0],
dftt.get('entryoffice')[0],
dftt.get('internalvehiclemode')[0],
dftt.get('bordervehiclemode')[0]]][0])

if predictedbordervehiclemode != dftt.get('bordervehiclemode')[0] :
insertsql = "INSERT INTO MLislemSomuc (islemid, islemverilyon, islem, sirket, yil, departman,
dosyano, girilendeger, tahmindeger, instime, insuser)
VALUES (?, ?, ?, ?, ?, ?, ?, ?, GETDATE(), ?)
..."
c.execute(insertsql, [islemid, islemverilyon, int(dftt.get('sirket')[0]),
int(dftt.get('yil')[0]), dftt.get('departman')[0],
int(dftt.get('dosyano')[0]), dftt.get('bordervehiclemode')[0],
predictedbordervehiclemode, user])
c.commit()
```

Şekil 8. Model tahmini sözdizimi (Model prediction syntax)

### 3.9. Test (Test)

Bu çalışmada önerilen yöntem ile etiket kodlama tekniği ayrı ayrı performans başarımlarına tabii tutulmuştur. Bu testler aynı veri setleri ve çalışma koşullarında gerçekleştirilmiştir

### 3.10. Etiket kodlama tekniği (Label encoding )

Performans testlerinin kıyaslanması amacıyla kullanımı kolay ve bilinen etiket kodlama tekniği tercih edilmiştir. Bu teknik kategorik verileri alfabetik olarak sıralar ve ilk sıradaki bilgiye 0 değeri atayarak devam eder (Li, 2018). Çalışmada kullanılan taşıma türü veri seti etiket kodlama tekniğine uygun şekilde kodlandığında oluşan kod değer ve kayıt sayıları Tablo 4’te gösterilmektedir.

Tablo 4. Etiket kodlama örneği (Label encoding example)

Taşıma Türü	Kod	Kayıt Sayısı
GEMI	0	833475
KAMYON	1	1057390
RORO	2	1071
TEL	3	11
TIR	4	1471167
TREN	5	4240
UCAK	6	617526
VAGON	7	79251

Kullanılan veri setlerinden taşıma şekli veri setinde yer alan kategorik verilerin sayısallaştırılmasında

kullanılan etiket kodlama tekniğine dair Python programı üzerinde taşıma şekli veri setinin kodlamasına ait sözdizimi örneği Şekil 9’da gösterilmektedir.

```
connection=pyyodbc.connect('DRIVER=SQL SERVER;SERVER=SERVER;DATABASE=DBName;UID=UID;PWD=Password')
c = connection.cursor()
c.execute("""
SELECT firmnumber, customsoffice, regime, declaration1, declaration2,
entryoffice, internalvehiclemode, bordervehiclemode, bordervehiclemode
FROM MLGumrukDosyaTasimaSekli
...
)
dataframe = pd.DataFrame(c.fetchall(), columns = ['firmnumber', 'customsoffice', 'regime', 'declaration1',
'declaration2', 'entryoffice', 'internalvehiclemode',
'bordervehiclemode', 'bordervehiclemode'])

le = LabelEncoder()
dataframe.customsoffice=le.fit_transform(dataframe.customsoffice)
dataframe.regime=le.fit_transform(dataframe.regime)
dataframe.declaration1=le.fit_transform(dataframe.declaration1)
dataframe.declaration2=le.fit_transform(dataframe.declaration2)
dataframe.entryoffice=le.fit_transform(dataframe.entryoffice)
dataframe.internalvehiclemode=le.fit_transform(dataframe.internalvehiclemode)
dataframe.bordervehiclemode=le.fit_transform(dataframe.bordervehiclemode)
```

Şekil 9. Etiket kodlama sözdizimi (Label encoding syntax)

Önerilen model altyapısında sadece VT okuma süre maliyeti varken kodlama yöntemi kullanılması durumunda ek olarak kodlama süre maliyeti de söz konusudur.

## 4. Bulgular (Results)

Çalışmada, lojistik bir firmanın 2010-2021 yılları arasında üretilen gümrük beyannameleri üzerinde belirlenen 46 kategorik özneliğe sahip yedi veri setini oluşturan 80154139 adet veri ile çalışılmıştır. Çalışma, sayısal olmayan verilerin öğrenme algoritmalarında kullanılıp, eğitilebilmesi için sayısal etiket dönüştürmede bilinen kodlama tekniklerinden etiket kodlama yöntemi ile bu tekniğin süre maliyetini iyileştirmek için geliştirilen ve bu çalışmada sunulan yöntemin başarımlarını değerlendirmek için test ve kıyaslama çalışması yürütülmüştür. Yapılan kıyaslamalardan birisi veri seti öznelikleri bakımından olup, buna ilişkin sonuçlar Tablo 5’de gösterilmektedir. Veri setlerindeki kategorik öznelik sayısı (n=46), sayısal öznelik sayısı(n=7) bulunmuştur.

Tablo 5. Veri seti öznelik sayıları (Dataset attribute counts)

Veri Seti	Sayısal Öznelik(n)	Kategorik Öznelik(n)
Teslim Şekli	1	8
Taşıma Türü	1	7
Sevk Ülke	1	9
Döviz Türü	1	5
Birim	1	6
Uluslararası Anlaşma	1	5
Ödeme Şekli	1	6
Toplam	7	46

Bu çalışmada önerilen yöntemle bilinen kodlama tekniklerinden etiket kodlama tekniği aynı çalışma platformları aynı veri setlerinin Tablo 5’de belirtilen öznelikler üzerinden ayrı ayrı performans testine tabii tutulmuştur. Gerçekleştirilen testler sonucunda elde edilen bulguları iki ayrı yöntem üzerinden ele alındığında şu şekilde bulunmuştur.

#### 4.1. Önerilen yöntem sonuçları (Suggested method results)

Bu çalışmada kodlama teknik kullanımına alternatif olarak sunulan yöntemin uygulanmasında her hangi bir kodlama tekniği kullanılmadığından kodlama süresine yönelik bir süre performans ölçümü söz konusu olmadığından bu yönde bir başarı testini gerçekleştirilmemiştir. VT okuma başlangıç ve bitiş sürelerinin tespitine yönelik çalışılan testlerden elde edilen bulgular Tablo 6' da sunulmaktadır. VT okuma sürelerine ait bulgular saat, dakika, saniye cinsindedir.

**Tablo 6.** Önerilen yöntem VT okuma süreleri (Suggested method DB reading times)

Veri Seti	Başlama zamanı	Bitiş zamanı
Teslim Şekli	13:37:32.671657	13:38:21.362509
Taşıma Türü	13:46:08.992893	13:46:54.534876
Sevk Ülke	13:52:09.026631	13:53:03.291126
Döviz Türü	13:56:59.626856	13:57:36.069051
Birim	14:01:59.033092	14:06:10.337286
Uluslararası A.	14:48:46.971833	14:52:05.053243
Ödeme Şekli	15:02:31.388658	15:05:47.188537

#### 4.2. Etiket kodlama sonuçları (Label coding results)

Kategorik veriler etiket kodlama tekniği kullanılarak sayısallaştırılmıştır. Etiket kodlama yöntemin uygulanmasında süre performansını etkileyen iki temel unsur vardır. Birincisi seçilen kodlama tekniğinin kullanımından kaynaklı süre, ikincisi VT okuma süresidir. Bu yöntemde uygulama süre performans değeri ölçümlenirken bu iki işlemde geçen sürelerin toplamı dikkate alınır. Çalışılan veriler üzerinden etiket kodlama işlemine başlama ve bitiş süreleri saat, dakika, saniye cinsinden Tablo 7'de gösterilmektedir.

**Tablo 7.** Etiket kodlama süreleri (Label encoding times)

Veri Seti	Başlama zamanı	Bitiş zamanı
Teslim Şekli	13:43:53.993317	13:44:11.116580
Taşıma Türü	13:48:46.550163	13:49:00.272876
Sevk Ülke	13:55:27.136143	13:55:48.097437
Döviz Türü	13:59:45.200095	13:59:53.715373
Birim	14:28:26.834826	14:34:57.854834
Uluslararası A.	14:58:43.443704	15:00:03.465403
Ödeme Şekli	15:13:09.899093	15:14:17.992492

Etiket kodlama yöntemi uygulanan bir makine öğrenme uygulamasında çalışma süresini etkileyen diğer unsur VT okuma süresidir. Bu çalışmada kullanılan veri seti öznitelikleri üzerinde etiket kodlama tekniği kullanılarak gerçekleştirilen testler sonucunda elde edilen VT okuma sürelerine ait bulgular Tablo 8'de verilmektedir. Tabloda yer alan VT okuma başlama-bitiş süreleri saat, dakika, saniye cinsindedir.

**Tablo 8.** Etiket kodlama tekniği VT okuma süreleri (Label encoding technique DB reading times)

Veri Seti	Başlama zamanı	Bitiş zamanı
Teslim Şekli	13:43:04.062545	13:43:53.992317
Taşıma Türü	13:48:01.683201	13:48:46.550163
Sevk Ülke	13:54:28.217643	13:55:27.136143
Döviz Türü	13:59:08.864947	13:59:45.200095
Birim	14:18:12.281741	14:28:26.792822
Uluslararası A.	14:53:07.702644	14:58:43.380701
Ödeme Şekli	15:07:04.156517	15:13:09.855097

## 5. Tartışma (Discussion)

Makine öğrenme uygulamalarında VT eşleştirme tablosuna işlenmiş olan ilgili kategorik veri özniteliklerin sayısal değerleri kullanılmıştır. Bu çalışmada kodlama tekniklerinin kullanımına alternatif olarak önerdiğimiz yöntemde herhangi bir kodlama tekniğine ihtiyaç duymadan kullanılan 46 öznitelige sahip yedi veri setini oluşturan 80.154.139 adet veri üzerinden eğitim ve tahmin çalışmaları başarılı bir şekilde yürütülmüştür. Sayısallaştırma sürecinde en çok kullanılan kategorik veri için en düşük sayısal değer kullanımında daha yüksek oranda başarılı sonuç elde edildiği deneyimlenmiştir.

Önerdiğimiz yeni yaklaşımın başarımlarını görmek için aynı ortam ve veriler üzerinde etiket kodlama tekniği kullanılarak testler gerçekleştirilmiştir. Karşılaştırmada etiket kodlama tekniğinin seçilmesinde bu tekniğin bilinen, kullanımı kolay ve daha önce deneyimlediğimiz bir teknik olması etkindir. Karşılaştırma amacıyla yapılan test sonuçları VT okuma, kodlama ve birlikte değerlendirilmiştir.


#### 5.1. VT okuma süre kazançları (DB read time gains)

VT okuma süre kazançları bakımından elde edilen bulgular çalışmamızda önerdiğimiz yöntem ile bilinen etiket kodlama tekniği bakımından kıyaslanma sonuçları Tablo 9'da gösterilmektedir. VT okuma süre değerlerinin milisaniye cinsinden verilmiştir. Kazanç yüzdesi ise önerilen yöntemin bilinen etiket kodlama yöntemi karşısında elde ettiği performans kazanç yüzdesidir.

**Tablo 9.** VT okuma performans süreleri (DB reading times)

Veri Seti	Önerilen yöntem	Etiket kodlama	Kazanç (%)
Teslim Şekli	48691	49930	2,54
Taşıma Türü	45542	44867	-1,48
Sevk Ülke	54264	58919	8,58
Döviz Türü	36442	36335	-0,29
Birim	251304	614511	144,53
Uluslararası A.	198081	335678	69,47
Ödeme Şekli	195800	365699	86,77
Toplam	830124	1505939	81,41

VT okuma performans kazanç oranları incelendiğinde önerilen yöntemin taşıma türü(%1,48) ve döviz türünde(%0,29) oranında performans oranı düşük oranda da olsa negatif bir sonuç elde edilmiştir. Ancak bu verilere nazaran oldukça daha yüksek veriye sahip birim(%144,53), ödeme şekli(%86,77) ve uluslararası anlaşma(%69,47) veri setlerinde ise yüksek kazanç değerleri elde edilmiştir. Çalışma veri setinin tümü (n=80.154.139) üzerinden değerlendirmeye tabii tutulduğunda %81,41 gibi yüksek bir oranda başarımla elde edilmiştir. Elde edilen VT okuma kazanç yüzdelere ilişkin grafik Şekil 10'da gösterilmektedir.



Şekil 10. VT okuma kazanç yüzde grafiği (DB reading gain percentage graph)

VT okuma üzerine gerçekleştirilen zaman performans kazanç yüzdeleri incelendiğinde 'taşıma türü' ve 'döviz türü'ne ait veri setlerinde önerdiğimiz yöntemin diğer yöntemlere göre önemsiz sayılabilecek bir oranda da olsa başarısız olduğu görülmektedir. Ancak diğer veri setlerinde özellikle kayıt sayısı fazla olan veri setlerinde ciddi performans artışı sağladığı görülmüştür.

Önerdiğimiz yöntemde VT okuma sürecinde özneliklerin sayısal değerlerini almak için ek olarak eşleştirme tablosuna bağlantı kurma maliyetiyle karşılaşılacak olsa da bunun uygulama çalışma süresi üzerinde önemli bir etkisinin olmayacağı yönündeki görüş kabul edilmiştir.

### 5.2. Kodlama süre maliyetleri (Encoding time costs)

Makine öğrenme uygulamasında bilinen bir kodlama tekniğinin kullanımında; verinin kodlanma işlemi uygulama esnasında gerçekleştirildiğinden bu kodlama işleminden kaynaklı bir süre maliyeti söz konusudur. Veri setleri öznelikleri üzerinden etiket kodlama tekniği kullanarak gerçekleştirdiğimiz test sonucunda kodlamada geçen sürelerin milisaniye biriminde gösterimi Tablo 10'da gösterilmektedir.

Tablo 10. Kodlama başarımları süreleri (Encoding success times)

Veri Seti	Önerilen yöntem	Etiket kodlama (ms)
Teslim Şekli	N/A	17123
Taşıma Türü	N/A	13723
Sevk Ülke	N/A	20961
Döviz Türü	N/A	8515
Birim	N/A	391020
Uluslararası A.	N/A	80022
Ödeme Şekli	N/A	68093

Uygulamada karşılaşılan bu kodlama süre maliyetlerinin aksine önerdiğimiz yöntemin uygulanması durumunda veri sayısallaştırma işlemi makine uygulamalarının çalışma esnasında değil uygulamalar çalıştırılmadan önce gerçekleştirilmekte ve VT eşleştirme tablosu üzerine kaydedilmektedir. Bu yüzden önerdiğimiz yöntemde makine öğrenme uygulamalarının çalıştırılması sırasında herhangi bir kodlama yapılmadığından süre maliyeti söz konusu değildir.

### 5.3. Uygulama toplam süre kazançları (Application total time earnings)

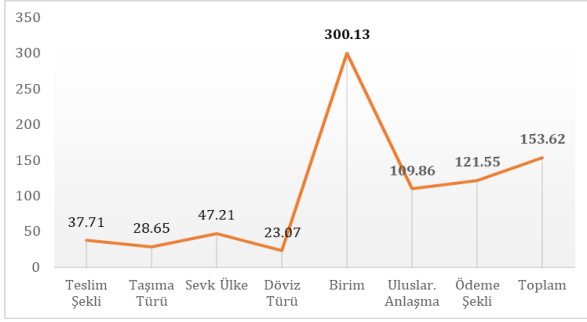
Bir makine öğrenme uygulaması bakımından yapılacak değerlendirmede toplam süre kazanç değerlendirmesinde bulunulur. Önerilen yöntemde etkili olan sadece VT okuma performans sonuçları dikkate alınırken herhangi bir kodlama yöntemi kullanılması durumunda VT okuma süresi yanında kodlama da geçen süre toplamın birlikte değerlendirilmesi gerekmektedir. Elde edilen uygulama süre performans kazanım sonuçları milisaniye biriminden Tablo 11'de gösterilmektedir.

Tablo 11. VT okuma performans süreleri (DB read performance times)

Veri Seti	Önerilen yöntem	Etiket kodlama	Kazanç (%)
Teslim Şekli	48691	67053	37,71
Taşıma Türü	45542	58590	28,65
Sevk Ülke	54264	79880	47,21
Döviz Türü	36442	44850	23,07
Birim	251304	1005531	300,13
Uluslararası A.	198081	415700	109,86
Ödeme Şekli	195800	433792	121,55
Toplam	830124	2105396	153,62

Elde edilen uygulama süre performans değerleri incelendiğinde veri seti bazında en düşük %23,07 oranla döviz türü veri kategorisinde, en yüksek oran ise birim öznelik veri türünde %300,13 bulunmuştur. Uygulama bütününe etki eden toplam süre bakımında ele alındığında toplam süre başarımları oranı %153,62 bulunmuştur. Uygulamanın bütünü üzerinden sağlanan süre performans gücü ve edinilen zaman kazancının ana nedeni uygulanan yöntemlerin farklılığından kaynaklanmaktadır. Önerdiğimiz ve başarılı bir şekilde uyguladığımız bu yeni yöntemde uygulama esnasında herhangi bir kodlama tekniği kullanılmamaktadır. Başarımları testlerini yapıldığı etiket kodlama tekniğinden bağımsız uygulama esnasında kullanılacak her bir kodlama tekniğinin bir süre maliyeti olacaktır. Önerilen yöntemde ise veri sayısallaştırma işlemi uygulama öncesi VT üzerinde gerçekleştirilmektedir. Uygulama üzerinde çalışılan testlerden elde edilen süre değerleri üzerinden elde edilen süre kazanç başarımları yüzde grafiği Şekil 11'de gösterilmektedir.

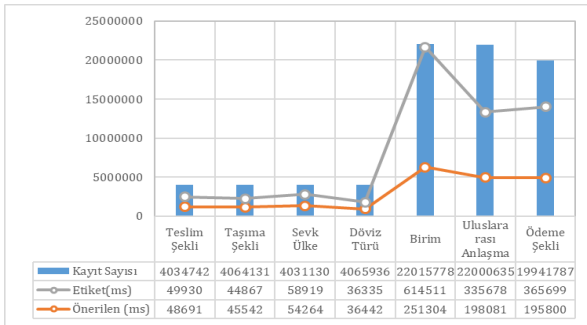




Şekil 11. Uygulama zamanı kazanç yüzde grafiği (Application time gain percent graph)

#### 5.4. Süre performansına etki unsurlar (Factors affecting time performance)

Her iki yöntemde veri seti öznelikleri üzerinden elde edilen çalışma süreleri veri öznelik ve hacmi bakımından incelenmiştir. Bu amaçla kategorik veri sayısallaştırmasında, önerilen yöntem ile etiket kodlama yönteminin bu veri setleri üzerindeki çalışma sürelerinin milisaniye biriminden elde edilen bulgular üzerinden oluşturulan tablo ve grafik Şekil 12’de gösterilmiştir.



Şekil 12. Veri seti adet, yöntem ve çalışma süreleri (Data set quantity, method and run times)

Çalışılan testlerden elde edilen bulgular değerlendirildiğinde kategorik veri özneliklerindeki kayıt sayılarındaki artışın çalışma süresi üzerinde etkili olduğu, kullanılan yöntem ve teknik açısından ise bir birlerine benzer paralellikte artış ve azalış gösterdiği gözlemlenmektedir. Ancak veri seti hacmi arttıkça önerdiğimiz yöntemin daha az sürede daha başarılı performans gösterdiği tespit edilmiştir. Birim ve uluslararası anlaşma kategorilerinde gözlenen benzer veri adetlerine sahip iki veri setindeki belirgin olan süre ayrışmasının nedeni irdelendiğinde ilgili veri setlerindeki öznelik sayısı ve veri niteliğinin etkili olduğu saptanmıştır. Diğer bir taraftan birim veri seti öznelik sayısı bakımından en az kayıt sayısı ve performans artışı (%300,13) bakımından en yüksektir. Yine kayıt sayısı fazla olan birim, uluslararası anlaşma ve ödeme şekli veri setlerindeki performans artışı dikkat çekici derecede yüksek bulunmuştur. Uygulama süre performans artışının öznelik sayısı ile ters, kayıt sayısı ile doğru orantılı bir ilişkiye sahip olduğu görülmüştür.

Çalışma bulgularımızı diğer araştırma sonuçlarıyla değerlendirmek istediğimizde makine öğrenmesine dayalı güncel pek çok çalışma olmasına rağmen önerdiğimiz yöntem ve bunun sağladığı süre performans kazancına dair her hangi bir çalışmaya rastlayamadık. Diğer taraftan makine öğrenme algoritmalarına dayalı uygulamaların başarımları ve performansında veri seti büyüklüğünün etkisinin yer aldığı (Tekin & Tunalı, 2019) tarafından yapılan çalışmada, veri seti hacminin sınıflandırma başarımları üzerinde etkili olduğu, veri setinin küçük olmasının başarımları düşürdüğü vurgulanmıştır. (Calp ve Akcayol, 2020), risk tahminine yönelik yapay sinir ağları ile geliştirdikleri internet tabanlı uygulamanın başarımları test çalışma sonucuna göre farklı alanlarda daha fazla veri sayısı kullanımının daha yüksek doğruluk düzeyinde performanslı sonuçlara ulaşımlardır. Bu çalışmalar birlikte değerlendirdiğinde makine öğrenme algoritmalarının kullanıldığı uygulamalarda veri hacminin sınıflandırma başarımları üzerinde olumlu bir etkiye sahip olduğuna ulaşabiliriz. (Takçı, 2018), kalp krizinin önceden tahminine yönelik yaptığı çalışmada makine öğrenme algoritmalarının uygulanmasında öznelik seçiminin işlem süresi üzerinde etkili olduğunu vurgulanmıştır. (Bilgin ve Oğuz, 2021) gerçekleştirdikleri çalışmada veri sınıflandırma ve kümelenmesinden kaynaklı bellek tüketimini azaltmaya yönelik yeni bir yöntem önermişlerdir. (Ma ve Zhang, 2020), Londra seyahat veri setini kullanarak seyahat tercih seçimini tahmin etmeye yönelik çalışmada kategorik özelliklerin daha iyi modellenme ve anlaşılmasında kodlamanın önemine vurgu yaparak Label kodlama ve One-Hot gibi kodlama tekniklerinin başarımının sınırlı kalabileceğine dikkat çekmişlerdir. Tüm bu çalışmalar veri hacmi, veri seti özneliği, kodlama tekniği ve sınıflandırma yöntemi, çalışma ortam ve altyapısının uygulama performans ve etkinliği üzerinde etkili olduğunu göstermektedir. Çalışmamızda sunduğumuz alternatif çalışma yönteminde her hangi bir kodlama tekniğinin kullanılmaması, veri seti özneliği seçimi ve VT alt yapısı sayesinde diğer çalışmalarda belirtilen kazançlara ek kazanç elde edilmiştir.

Özetle makine öğrenimi uygulamalarında kullanılan kodlama tekniklerine alternatif olarak çalışılan ve başarılı bulunan bu çalışma yöntem ve kurulan altyapı sayesinde veriler daha okuma aşamasındayken sayısal olarak alınmaktadır. Çalışmamızda sunmuş olduğumuz yöntem veri okuma süresini daha efektif hale getirmiştir. Yine önerdiğimiz bu yöntemde herhangi bir kodlama tekniğinin kullanılmaması olması kodlama tekniği kullanan yaklaşımlara göre ciddi süre performans kazancı sağlamıştır. Çalışma, yüksek performans kazancı ve özgün yapısı ile benzer veri seti ve çalışma alanlarında kolay bir şekilde uygulanabilecek benzersiz bir yapıya sahiptir. Makine öğrenmesinde kodlama tekniklerinin kullanımına alternatif ve etkili bir çözüm geliştirilerek literatüre kazandırılmıştır.



## 6. Sonuç (Conclusions)

Bir makine öğrenme uygulamasında sayısal olmayan verilerin öğrenme algoritmalarında kullanılabilmesi için sayısal veriye dönüşmesi gerekmektedir. Bu amaçla bir takım kodlama yöntemleri kullanılmaktadır. Bu bilinen yöntemlerin kullanımının bazı kolaylıklar yanında uygulama üzerinde belli bir süre maliyeti vardır. Günümüzde neredeyse her alanda zamanla adeta yarışıldığı bir dönemde en küçük bir zaman kaybı ciddi derecede olumsuz bir etkiye sahip probleme dönüşebilmektedir. Bu çalışma, uluslararası faaliyet gösteren, Türkiye iç piyasanın yaklaşık %8 işlem hacmine sahip bir lojistik bir firmada yürütülen makine öğrenmesi uygulama çalışmalarında rastlanan süre probleminin iyileştirilmesine yönelik yapılan bir araştırma sonucunda üretilmiştir. 2010-2021 yılları arasında üretilen gümrük beyannameleri üzerinde belirlenen 46 özneliğe sahip yedi veri setini oluşturan 80.154.139 adet veri ile çalışılmıştır. Sunduğumuz bu alternatif çalışma önerisi ile bilinen kodlama tekniklerinden etiket kodlama tekniği aynı çalışma ortam ve veriler üzerinden ayrı ayrı süre performans testlerine tabii tutulmuştur. Sonuç olarak, makine öğrenme uygulamalarında kullanılan kodlama yöntemine alternatif bir çalışma modeli çalışılmıştır. Geliştirilen bu yeni yaklaşımla bilinen etiket kodlama tekniği uygulama süre performans düzeyleri karşılaştırmalı olarak incelenmiştir. Bu süre başarımlarına göre alternatif olarak önerdiğimiz yöntemin bilinen kodlama tekniğinin kullanımına karşı kategorik veri bazında en az %23,07 en fazla %300,13 oranında başarı göstermiştir. Uygulama bütünü üzerinden yapılan değerlendirmelerde daha büyük veri setinde daha yüksek başarımlarına ulaşılmıştır. Uygulama bütünü üzerinden yapılan değerlendirmelerde daha büyük veri setinde daha yüksek başarımlarına (%153,62) ulaşılmıştır.

Bu çalışma, sahada karşılaşılan gerçek bir problemin çözümüne yönelik araştırma sonucunda geliştirilen, uygulanabilir yapısı, elde edilen kazanç ve başarılı sonuçların varlığı, elde edilen deneyim ve tecrübelerin aktarılması, makine öğrenim çalışmalarında kodlama tekniği kullanımına alternatif bir yöntem önerisi getirmesi ve bu alanın gelişimine katkı sunacak nitelikte olması bakımından kıymetlidir. Çalışma, elde edilen yüksek orandaki süre performans kazancı yanında kolay sayılabilen kullanımıyla benzer saha çalışmalarında uygulanabilir nitelikte olup kodlama tekniklerinin kullanımına alternatif bir çözüm önerisi sunmaktadır.

## Kaynaklar (References)

Al-Shehari T., Alsowail R. A., 2021. An insider data leakage detection using one-hot encoding, synthetic minority oversampling and machine learning techniques. *Entropy*, 23(10), 1258, doi:10.3390/e23101258

Bilgin, T., Oğuz, M., 2021. A new approach to minimize memory requirements of frequent subgraph mining algorithms. *Politeknik Dergisi*, 24(1), 237-246

Calp, M., Akcayol, M., 2020. Design and Implementation of Web Based Risk Management System Based on Artificial Neural Networks for Software Projects: WEBRISKIT. *Pamukkale Univ Muh Bilim Derg.*, 26(5), 993-1014

Chakrabarty, N., 2019. A data mining approach to flight arrival delay prediction for american airlines. 9th Annual Information Technology, Electromechanical Engineering and Microelectronics Conference (IEMECON). doi:10.1109/iemeconx.2019.8876970

Cerda, P., Varoquaux, G., Kégl, B., 2018. Similarity encoding for learning with dirty categorical variables. *Machine Learning*, 107(8-10), 1477-1494. doi:10.1007/s10994-018-5724-2

Chandradeva, L. S., Jayasooriya, I., Aponso, A. C., 2019. Fraud Detection Solution for Monetary Transactions with Autoencoders. *National Information Technology Conference(NITC)*. doi:10.1109/nitc48475.2019.9114519

Chen, L., Xian, M., Liu, J., & Wang, H., 2020. Intrusion detection system in cloud computing environment. *International Conference on Computer Communication and Network Security (CCNS)*. doi:10.1109/ccns50731.2020.00037

Famili, A., Shen, W.-M., Weber, R., Simoudis, E., 1997. Data preprocessing and intelligent data analysis. *Intelligent Data Analysis*, 1(1), 3-23. doi:10.3233/ida-1997-1102

Günerkan M., Şahinaslan E., Şahinaslan Ö., 2022. Gümrük beyannamesi sürecinde öğrenmeye dayalı algoritmaların etkinliğinin incelenmesi. *Acta Infologica*, doi: 10.26650/acin.1057060

Jackson, E., & Agrawal, R., 2019. Performance evaluation of different feature encoding schemes on cybersecurity logs. *IEEE*, 1-9. doi:10.1109/southeastcon42311.2019.9020560

Jiang, D., Lin, W., Raghavan, N., 2020. A novel framework for semiconductor manufacturing final test yield classification using machine learning techniques. *IEEE* 197885-197895. doi:10.1109/access.2020.3034680

Karasulu, B., Yücalar, F., Borandag, E., 2022. İnsan kulağı görüntüleri kullanarak cinsiyet tanıma için derin öğrenme tabanlı melez bir yaklaşım. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37 (3) , 1579-1594 . doi: 10.17341/gazimmfd.945188

Kıran, E. , Karasulu, B. & Borandag, E. (2022). Gemi Çeşitlerinin Derin Öğrenme Tabanlı Sınıflandırılmasında Farklı Ölçeklerdeki Görüntülerin Kullanımı . *Journal of Intelligent Systems: Theory and Applications* , 5 (2) , 161-167 . DOI: 10.38016/jista.1118740

Li, J., 2018. Monthly housing rent forecast based on lightgbm (light gradient boosting) model. *International Journal of Intelligent Information and Management Science*, 7(6). <http://www.hknccp.org/Public/upload/goods/2019/09-03/5d6e145f40393.pdf>

Li, Y., Zhu, Z., Wu, H., Ding, S., & Zhao, Y., 2020. CCAE: Cross-field categorical attributes embedding for cancer clinical endpoint prediction. *Artificial Intelligence in Medicine*, 107, doi:10.1016/j.artmed.2020.101915



MarketResearch., 2022. Types of data & measurement scales: nominal, ordinal, interval, and ratio. <https://www.marketresearchmethods.com/types-of-data-nominal-ordinal-interval-ratio/>, 13.05.2022

Ma, Y., Zhang, Z. 2020. Travel mode choice prediction using deep neural networks with entity embeddings. *IEEE*, 8, 64959-64970, doi: 10.1109/access.2020.2985542.

- Mitchell, T. M., 1997. Machine learning. New York: McGraw-Hill
- Nerlikar, P., Pandey, S., Sharma, S., Bagade, S., 2020. Analysis of intrusion detection using machine learning techniques. *International Journal of Computer Networks and Communications Security*, 8(10), 84-93
- Potdar, K., Pardawala, T.S., Pai, C.D., 2017. A comparative study of categorical variable encoding techniques for neural network classifiers. *International journal of computer applications*, 175(4), 7-9. doi:10.1207/s15328031us0301\_3
- Reilly, D., Taylor, M., Fergus, P., Chalmers, C., Thompson, S., 2022. The categorical data conundrum: Heuristics for classification problems - A case study on domestic fire injuries. *IEEE Access*, 10, 70113-70125.
- Sharma, N., Bhandari, H.V., Yadav, N.S., Shroff, H.V.J., 2020. Optimization of IDS using filter-based feature selection and machine learning algorithms". *Int. J. Innov. Technol. Explor. Eng*, 10(2), 96-102.
- SAS., 2022. Makine Öğrenimi Nedir ve Neden Önemlidir, "[https://www.sas.com/tr\\_tr/insights/analytics/machine-learning.html](https://www.sas.com/tr_tr/insights/analytics/machine-learning.html) ", 15.06.2022
- Scikit-Learn., 2022. sklearn.preprocessing.LabelEncoder. scikit-learn:<https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.LabelEncoder.html>, 13.05.2022
- ScikitLearn-OneHotEncoder., 2022. One Hot Encoder "<https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.OneHotEncoder.html#sklearn.preprocessing.OneHotEncoder>", 13.05.2022
- ScikitLearn-OrdinalEncoder., 2022. Ordinal Encoder. "<https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.OrdinalEncoder.html#sklearn.preprocessing.OrdinalEncoder>", 13.05.2022
- Seeger, C., 2018. An investigation of categorical variable encoding techniques in machine learning: binary versus one-hot and feature hashing. "<https://www.diva-portal.org/smash/get/diva2:1259073/Fulltext01.pdf>"
- Sethi, A., 2022. Categorical encoding | one hot encoding vs label encoding. "<https://www.analyticsvidhya.com/blog/2020/03/one-hot-encoding-vs-label-encoding-using-scikit-learn/>", 13.05.2022
- Shen, J., Shafiq, M. O., 2019. Learning mobile application usage - A deep learning approach. 18th IEEE International Conference On Machine Learning And Applications (ICMLA). doi:10.1109/icmla.2019.00054
- Şahinaslan, Ö., Dalyan, H., Şahinaslan, E., 2022. Naive bayes sınıflandırıcısı kullanılarak youtube verileri üzerinden çok dilli duygu analizi. *Bilişim Teknolojileri Dergisi*, 15(2), 221-229. doi: 10.17671/gazibtd.999960
- Takçı, H., 2018. Improvement of heart attack prediction by the feature selection methods, *Turkish Journal of Electrical Engineering and Computer Science*, 26 (1), 1-10
- Tekin, M., Tunalı, V., 2019. Prioritization of software development demands with text mining techniques. *Pamukkale Univ Muh Bilim Derg.*, 25(5), 615-620
- Turcanik, M., Javurek, M., 2016. Hash function generation by neural network. 1-5. 10.1109/NTSP.2016.7747793
- Yılmaz Yalçın, A., Gelen Mert, M.B., 2021. Estimating the occupancy rate of an accommodation business using artificial neural networks . *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi* , (47) , 209-218 . doi: 10.30794/pausbed.828902
- Yu, L., Zhou, R., Chen, R., Lai, K. K., 2020. Missing data preprocessing in credit classification: one-hot encoding or imputation? *Emerging Markets Finance and Trade*, 1-11. doi:10.1080/1540496x.2020.1825935



# Kasislerin Yakıt Tüketimine Etkisinin RNN, LSTM, GRU Tekrarlayan Derin Öğrenme Algoritmaları ile Tespiti

Mustafa Fatih Tosun<sup>1\*</sup> , Ali Şentürk<sup>2</sup> 

<sup>1</sup> Isparta Uygulamalı Bilimler Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Isparta, Türkiye

<sup>2</sup> Isparta Uygulamalı Bilimler Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Isparta, Türkiye

mtosun32@gmail.com, alisenturk@isparta.edu.tr

## Öz

Bu çalışmada, trafiği düzenlemek için kullanılan kasislerde, araçların yavaşlama ve hızlanmasının yakıt tüketimine etkisinin belirlenmesi amaçlanmıştır. Bunun için, kasis bulunan güzergâhlarda kullanılan aracın OBD-II portundan Arduino ile gerçek zamanlı hız ve yakıt tüketimi verileri alınmıştır. Alınan veriler ön işleme tabi tutulmuştur. Yakıt tüketimini tahmin etmek için Tekrarlayan Sinir Ağları (RNN), Uzun Kısa Süreli Bellek (LSTM), Geçitli Tekrarlayan Birim (GRU) tekrarlayan derin öğrenme modelleri geliştirilmiştir. Ön işlemden geçen veriler modellerin eğitiminde kullanılmıştır. Geliştirilen modellerde hiperparametre optimizasyonu yapılmıştır. Böylece katman sayısı, katmanlardaki hücre sayısı, hücrelerin aktivasyon fonksiyonları ve öğrenme oranı belirlenmiştir. Doğrulama setinde en düşük %63 ortalama kare hatası elde edilmiştir. Geliştirilen modeller kullanılarak farklı kasisler ve hız senaryolarının yakıt tüketimine olan etkileri tahmin edilmeye çalışılmıştır. Kasislerden geçiş için belirlenen hız ve zaman verileri kullanılarak yakıt tüketiminin kasis etkisi boyunca %16,30 ile %31,03 arasında arttırdığı sonucuna ulaşılmıştır.

**Anahtar kelimeler:** Yakıt Tüketimi, Kasis, OBD-II, Derin öğrenme, RNN, LSTM, GRU

## The Detection of the Effect of Bumpers on Fuel Consumption with RNN, LSTM, GRU Recurrent Deep Learning Algorithms

### Abstract

This study is aimed to determine the effect of vehicle deceleration and acceleration on fuel consumption in the bumps which are used to regulate traffic. For this, real-time fuel consumption and speed data are acquired with Arduino from the OBD-II port of the vehicle driven on routes with bumps. Recurrent Neural Networks (RNN), Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) deep learning models are developed to predict fuel consumption. The preprocessed data is used to train the models. Hyperparameter optimization is conducted in the developed models. Thus, the number of layers and the units in the layers, the activation functions and the learning rate is specified. The lowest mean square error is obtained as 63% in the validation set. The effects of different speed scenarios on fuel consumption are predicted by using the models. In conclusion, fuel consumption increased between 16.30% and 31.03% during the impact of the bumps, by using the speed and time calculated for the bumps.

**Keywords:** Fuel Consumption, Bump, OBD-II, Deep Learning, RNN, LSTM, GRU

### 1. Giriş (Introduction)

Ülkemizde artan trafiğin düzenlenmesi için yollarda hız kesici engeller (kasis) kullanılmaktadır. Her ne kadar kasisler trafiği düzenlemede etkili yöntemler olsa da standartlara uygun yapılmamış

kasisler araçların gereğinden çok fazla yavaşlamasına veya zarar görmesine, sürüş konforunu olumsuz etkilenmesine sebep olmaktadır. Trafik yoğunluğunun az olduğu saatlerde de kasisten geçen aracın hızının, hız sınırlarının altına düşmeye zorlanmaktadır.

Günümüzde bütün araçlarda standart olarak Elektronik Kontrol Ünitesi (Electronic Control Unit-

\* Sorumlu yazar.  
E-posta adresi: mtosun32@gmail.com

Alındı : 6 Temmuz 2022  
Revizyon : 26 Eylül 2022  
Kabul : 24 Aralık 2022

ECU) bulunmaktadır. Araçlarda ECU ile diğer elektronik cihazlar arasındaki iletişim Kontrol Alan Ağı (Control Area Network - CAN) ile sağlanmaktadır. Yerleşik Teşhis (On-board Diagnostic - OBD-II) CAN veri yoluna bağlı olan, arıza teşhisi ve aracın verilerinin raporlanması için kullanılan bir ara yüzüdür.

Bu çalışmada, OBD-II ara yüzünden elde edilen veriler kullanılarak kasislerin yakıt tüketimine etkilerinin makine öğrenmesi ile tahmin edilmesi gerçekleştirilmiştir. Bunun için OBD-II ara yüzünden elde edilen veriler kullanılarak Yinelemeli Sinir Ağları (Recurrent Neural Network - RNN), Uzun Kısa Süreli Bellek (Long Short Term Memory - LSTM) ve Geçitli Tekrarlayan Birimler (Gated Recurrent Unit - GRU) derin öğrenme mimarileri ile eğitilmiştir. Derin öğrenme algoritmalarından elde edilen sonuçlara göre kasislerin farklı sürüş senaryolarında yakıt tüketimine etkisinin analizleri yapılmıştır.

Yakıt tüketimi tahmini ile ilgili çalışmalar aşağıda verilmiştir. Coşkun (2008) yaptığı çalışmada CAN veri yolu protokolünü kullanarak araç takip sistemi uygulaması gerçekleştirilmiştir. Bu uygulamada GPS uydularından alınan konum, hız, yön gibi bilgileri CAN protokolü ile araçtan toplanan yakıt seviyesi, sıcaklık, motor devri, ses, görüntü vb. gibi uygulamanın gerektirdiği birçok bilgi ile birleştirip GSM alt yapısını kullanarak bir merkeze gönderilmiş ve kullanıcılar internet üzerinden bu bilgilere ulaşabilmesi sağlanmıştır. Cueva-Fernandez vd. (2014) yaptıkları çalışmada, karayolu taşıtları için bütünleşik bir platform tasarlamışlardır. Tasarlanan platform ile son kullanıcılar için, birbirleri ile iletişim halinde olan araçlardan ve araç sensörlerinden gerçek zamanlı olarak elde edilen bilgiler kullanılarak zengin internet uygulamaları üretilmesini amaçlanmıştır. Kowalik (2018) yaptığı çalışmada arıza tespit cihazı (OBD-II) kullanarak bir veri toplama ortamının nasıl oluşturulabileceğini ve bir araçtan nasıl veri elde edileceğini açıklamıştır. Çalışma arızalı termostatu olan bir arabadan toplanan veri analizinin ön sonuçlarını içermektedir. Kowalik ve Szpyrka (2019) yaptığı çalışmada bir arabadan gerçek zamanlı veri alımı için veri toplama ortamı oluşturmuşlardır. OBD-II kullanılarak aracın elektronik kontrol birimlerinden (ECU) veriler toplanmıştır. Toplanan veriler Torque PRO uygulamasını çalıştıran akıllı telefon veya internet uygulaması üzerinden gerçek zamanlı olarak sunuculara aktarılabilir. Toplanan veriler hem çevrimiçi hem de çevrimdışı olarak analiz edilebilir.

Wickramanayake ve Bandara (2016) yaptığı çalışmada bir otobüsün yakıt verimliliğini iyileştirmek için mesafe, yük, sürücü davranışları ile birlikte yol koşulları, hava şartları ve trafik durumunu dikkate almışlardır. Yakıt tüketimini tahmin etmek için makine öğrenmesi metodlarından

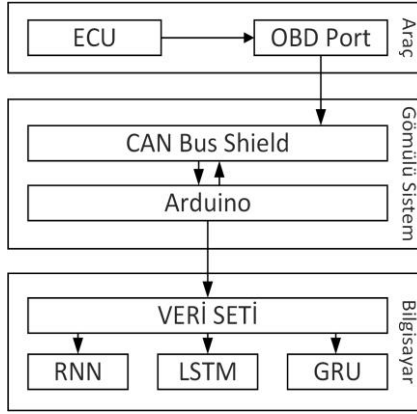
rastgele orman, gradyan azalma ve sinir ağları metodları karşılaştırmalı olarak kullanılmıştır. Syahputra (2016) yaptığı çalışmada, nöro-bulanık mantık yöntemi kullanarak araç yakıt tüketimini tahmin etmiştir. Elde edilen sonuçlara göre yakıt tüketimine etki eden faktörler silindir sayısı, yer değiştirme, beygir gücü, ağırlık, hızlanma ve model yılı olarak belirlemiştir. Perrotta vd. (2017) yaptığı çalışmada damperli kamyonların yakıt tüketimi tahmininde Destek Vektör Makinesi (SVM) (Support Vector Machine), Rastgele Orman (RF) (Random Forest) ve Yapay Sinir Ağı (ANN) (Artificial Neural Networks) modellerini geliştirmiş ve performansları karşılaştırmışlardır. Yakıt tüketimini etkileyen sensör ve yol bilgilerini toplamışlardır. Yeni ve daha doğru yakıt tüketiminin hesaplanması için araç sensör verilerinin yanı sıra modele yol bilgileri de eklenmiştir. Bu üç yöntemde yüksek hassasiyetli modeller geliştirmek mümkün olmasına rağmen, RF'nin SVM ve ANN'den çok az da olsa daha iyi performans gösterdiğini ifade etmişlerdir. Şen (2020) yaptığı çalışmada makine öğrenmesi ile yakıt tüketimini iyileştirmeyi amaçlamıştır. Burada aracın ECU'sundan hız, RPM (Revolutions Per Minute - Dakikadaki Devir), fren pedalı konumu, su sıcaklığı ve MAF (Manifold Air Flow- Kütle Hava Akış Sensörü) verileri toplanmıştır. Toplanan veriler makine öğrenmesi algoritmaları kullanarak anlık yakıt tüketimi tahmini yapmayı amaçlamıştır. Ayrıca araçtan alınan sensör verilerinin anlık yakıt tüketimine etkisi gözlemlenmiştir. Uyanık vd. (2020) yaptığı çalışmada konteyner yük gemisinin yakıt tüketimini makine öğrenmesi ile tahmin etmişlerdir. Ana motor devri, ana motor silindiri değerleri, süpürme havası, şaft göstergeleri gibi parametreler yakıt tüketimini etkileyen faktörler olarak seçilmiştir. Tahmin işlemi için Çoklu Lineer Regresyon, Ridge ve Lasso Regresyon, Destek Vektör Regresyon, Ağaç Tabanlı Algoritmalar, Boosting Algoritmaları gibi farklı yapay zekâ modelleri kurulmuştur. Modellerin doğruluğu, K-kat çapraz doğrulama ile belirlenmiştir. Tahmin modellerinin doğruluğunu değerlendirmek için ortalama karesel hata, ortalama mutlak hata, belirleme katsayısı gibi hata metrikleri kullanılmış ve değişkenler arası korelasyon analiz işlemleri gerçekleştirilmiştir.

## **2. Materyal ve Metodoloji (Material and Methodology)**

Bu çalışmada kasislerin yakıt tüketimine etkisinin belirlenmesi amaçlanmıştır. Veri toplama işlemi için 2009 model Ford Fiesta marka araç kullanılmıştır. Araçtan veriler Arduino Uno ve CAN veri yolu kartı (CAN Bus shield) ile OBD-II üzerinden alınmıştır. Elde edilen veriler Seri haberleşme (UART) ile bilgisayara aktarılmıştır. Bu veriler yakıt tüketimini tahmin etmede kullanılacak

olan derin öğrenme modelleri için veri setini oluşturmuştur.

Yapılan çalışmada aracın yakıt tüketimini hesaplamada, tekrarlayan derin öğrenme algoritmaları olan RNN, LSTM ve GRU kullanılmıştır. Tasarlanan sistemin blok diyagramı Şekil 1’de verilmiştir.



Şekil 1. Blok diyagram (Block diagram)

### 2.1. Yerleşik teşhis - OBD-II (On board diagnostic - OBD-II)

CAN, mikrodenetleyiciler ve protokolü destekleyen elektronik cihazlar arasında merkezi sisteme ihtiyaç duymadan haberleşmelerini sağlayan çift yönlü seri haberleşme protokolüdür. CAN otomotiv sektöründe araç içi iletişimi sağlamaktadır (Lokman vd., 2019).

OBD (on-board diagnostics - yerleşik teşhis) araçta bulunan bütün elektronik aşşamların birbiriyle haberleşmesini sağlayan CAN veri yoluna erişmek için kullanılan standarttır. Bu standart, araçta bulunan statik durumlar ve elektriksel (sensör değerleri) değişimleri teşhis ve raporlama işlemlerini gerçekleştirmektedir. Böylece araç hakkında ve araçtaki birçok alt sistemlerin durumuna erişerek araç durumu hakkında tespitler yapmamıza olanak sağlamaktadır. Bu erişim sayesinde araç kullanıcıları ve teknik servis çalışanları araç hakkında daha fazla bilgi sahibi olmaktadır (Amarasinghe vd., 2015).

OBD-II sistemleri standart bir teşhis konektörüne sahiptir ve standart elektrik sinyali protokollerini ve mesajlaşma formatlarını kullanmaktadır. Konektörde aracın ECU’suna erişim için iletişim pinlerinin yanı sıra güç kaynağı pinleri bulunmaktadır (Vilgenoğlu, 2019).

### 2.2. Araçtan veri alınması ve yakıt tüketiminin hesaplanması (Acquiring data from the vehicle and calculating the fuel consumption)

Araçtan verilerin alınması için CAN bus shield modülü kullanılmıştır. Bu modül, ATmega328 mikrodenetleyici üzerine kurulu bir Arduino Uno kartı tarafından programlanıp ve kontrol edilebilir.

Kart üzerinde MCP2515 CAN bus kontrol entegresi ve MCP2551 CAN alıcı/verici entegresi bulunmaktadır (Amarasinghe vd., 2015).

Araçtaki yakıt tüketiminin belirlenmesi amacıyla hız ve MAF değerleri kullanılmıştır. Bu veriler heksadesimal formatta araçta üretilir. Araçtaki anlık değerleri okumak için OBD Mod-1 kullanılır. İstek yapılan verilerin her birisinin kendisine ait PID numarası vardır. Örneğin aracın anlık olarak hız verisine ulaşmak için OBD-II üzerinden 0x0D PID’si ile istek yapılır. Araçtan bu isteğe cevap olarak gönderilen 8 bayt verinin dördüncü baytı (A) aracın km/saat biriminde anlık hız verisidir. Verilen cevap 0 ile 255 arasında bir değerdir.

Araçta bulunan kütle hava akış sensöründen elde edilen verilerle MAF değerini hesaplamak mümkündür. Bunun için OBD-II üzerinden 0x10 PID’si ile istek yapılır. Araç bu isteğe sekiz bayt veri ile cevap verir. Döndürülen bu verinin dördüncü ve beşinci baytları (A ve B) ile Eşitlik 1’de gösterildiği gibi MAF değeri hesaplanır. Hesaplanan değer birimi gram/sn olup 0 ile 655 arasındadır.

$$MAF = \frac{256A + B}{100} \quad (1)$$

Yakıt tüketimi, 100 kilometrelik sürüş boyunca tüketilen yakıtın litre cinsinden ifade edilebilir. Bu çalışmada yakıt tüketiminin anlık hesaplanmasında dizel motorlu araç kullanılmıştır. Anlık yakıt tüketimi ise, sadece araç hareket halindeyken ve motor çalışır durumdayken anlık yakıt debisi ve aracın hızından hesaplanmaktadır. Yakıt debisi ve aracın anlık hızını hesaplamak için aracın OBD-II ara yüzünden yararlanılmaktadır. OBD-II yakıt tüketimi verisini doğrudan göndermemektedir. Bunun yerine yakıt tüketimi hesaplanmasında kullanılacak diğer parametreler OBD-II’den alınabilir. Bu parametreler Motor Yakıt Oranı (0x5E) ile aracın hız bilgisi veya MAF (0x10) değeri veya emme manifoldu basıncı (0x0B) ve emme havası sıcaklığıdır (0x0F) (Meseguer, 2015). Bu çalışmada yakıt tüketimini hesaplamada Eşitlik 2 kullanılmıştır.

$$Yakıt\ Tüketimi = \frac{MAF \times 3600}{AFR_A \times FD} \quad (2)$$

Eşitlik 2’de MAF kütle hava akışı (g/s),  $AFR_A$  gerçek hava-yakıt oranı (1 gram yakıtı yakmak için gerekli hava miktarı) ve FD yakıt yoğunluğunu (g/l) temsil etmektedir. Gerçek hava-yakıt oranı dizel araçlar için 14,5 benzinli araçlar için 14,7’dir. Yakıt yoğunluğu ise dizel araçlarda 750 g/l, benzinli araçlar için 820 g/l’dir.

### 2.3. Veri setinin ön işlenmesi (Preprocessing the data set)

Araçtan veriler düzenli zaman aralıklarında alınamamaktadır. Dolayısıyla ardışık iki veri

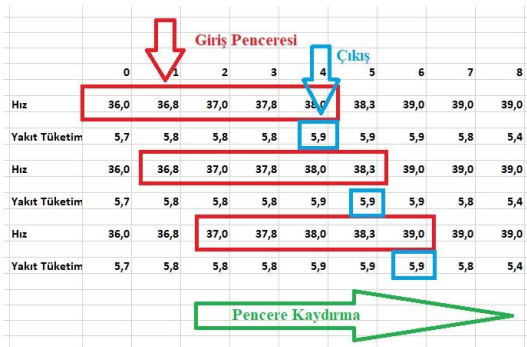


arasındaki süreler farklı olabilmektedir. Makine öğrenmesinde kullanılacak verilerin eşit gecikmelerle elde edilmesi gerektiğinden veri setinde olmayan ms'lerdeki hız ve yakıt tüketimleri için uygun değerlerin belirlenmesi gerekmektedir. Bu işlem için doğrusal interpolasyon yöntemi kullanılmıştır.

Doldurulan verilerden veri seti elde etmek için belirli aralıklarla örnekleme yapılmıştır. Örnekleme zamanı 300 milisaniye olarak belirlenmiştir. Her 300 ms'de yakıt tüketimi ve hız verisinin belirlenmesi için veri setinde araçtan alınan ve interpolasyon ile elde edilen 149 önce ve 150 sonraki verinin ortalaması alınarak veri seti hazırlama işlemi tamamlanmıştır. Dolayısıyla hazırlanan veri setinde 300 ms aralıklı zamanlarda hız ve yakıt verileri bulunmaktadır.

Veriler düzenlendikten sonra verilerin ardışıl hale getirilmesi, eğitim ve test için bölünmesi ve normalizasyon işlemleri yapılmıştır.

Sistemi eğitmek için pencere kaydırma yöntemi kullanılmıştır. Pencere boyutu 5, 10 ve 15 veriden oluşmaktadır. Şekil 2'de 5'li pencere gösterilmektedir.



Şekil 2. Pencere kaydırma metodu (Sliding window method)

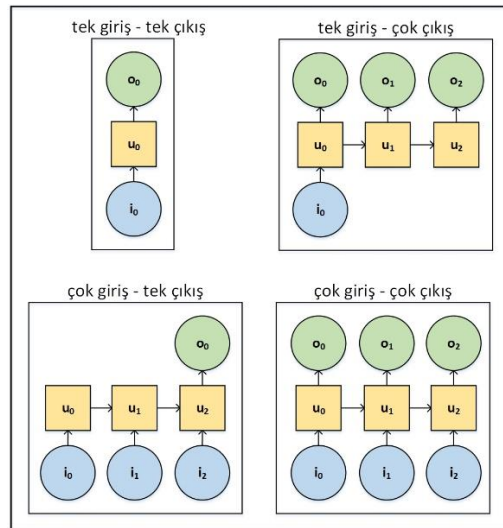
Araçtan OBD-II arayüzünden veriler 3 farklı sürüşte alınmıştır. Bu sürüşler aracın farklı tipte kasislerdeki 25 adet geçişten oluşmuştur. Bununla birlikte aracın farklı hızlarda sürülmesi, bu hızlara ulaşma ve yavaşlama verileri de mevcuttur. Her 3 veri grubu kendi içinde 10 eşit kısma ayrılmıştır. Her kısım ise kendi içinde %60'ı eğitim ve %40'ı test için bölünmüştür.

Makine öğrenmesi algoritmalarında kullanılan verilerin aralığının farklı olması algoritmanın başarısını olumsuz yönde etkilediği için veriler normalize edilir. Bu çalışmada da hız ve yakıt tüketimi verileri arasındaki ölçek farklılıkları bulunmaktadır. Hız verileri 0 ile 59 arasında değişirken yakıt tüketimi ise; 2,1 ile 21,7 arasında değişmektedir. Veriler normalize edilerek 0 ile 1 aralığında olması sağlanmıştır.

## 2.4. Tekrarlayan derin öğrenme algoritmaları (Recurrent deep learning algorithms)

Bu çalışmada aracın hızına göre yakıt tüketiminin tahmin edilmesi gerçekleştirilmiştir. Aracın hızlanırken belli bir hızdaki tükettiği yakıt ile yavaşlarken aynı hızda tükettiği yakıt farklıdır. Bu durumda aracın hem hızlanırken hem de yavaşlarken yakıt tüketimini doğru belirleyebilmek için daha önceki hızlarının unutulmaması gerekmektedir. Dolayısıyla önceki adımları hatırlayabilen derin öğrenme yapılarına ihtiyaç duyulmaktadır. Bu çalışmada belirtilen adımların işlendiği birimler ünite olarak isimlendirilmiştir.

RNN, LSTM, GRU tekrarlayan derin öğrenme algoritmalarının farklı kullanım şekilleri bulunmaktadır. Bunlar tek giriş - tek çıkış, tek giriş - çok çıkış, çok giriş - tek çıkış, çok giriş - çok çıkıştır. Bu kullanım şekilleri Şekil 3'te gösterilmiştir. Şekilde  $i$  giriş,  $o$  çıkış,  $u$  ise üniteleri temsil etmektedir. Yapılan çalışmada çok giriş - tek çıkış türü tekrarlayan derin öğrenme yapısı kullanılmıştır. Giriş verisi 5, 10 veya 15 adet 300 ms aralıklı ardışıl hız, çıkış verisi ise yakıt tüketimidir.



Şekil 3. Tekrarlayan derin öğrenme modelleri (Recurrent deep learning models)


Yapılan çalışmada tahminler ortalama kare hata (mean square error - MSE) metriği ile ölçülmüştür. MSE derin öğrenme modellerinin tahmini ile gerçek değerler arasındaki farkın karelerinin toplamının tahmin sayısına bölünmesi ile elde edilir. MSE'nin matematik ifadesi Eşitlik 3'te gösterilmiştir.

$$MSE = \frac{1}{m} \sum_{i=1}^m (Y_i - \hat{Y}_i)^2 \quad (3)$$

## 2.5. Tekrarlayan sinir ağları - RNN (Recurrent Neural Networks - RNN)

RNN'ler ardışıl verilerin veya zaman serilerinin tahmin edilmesinde kullanılan bir çeşit yapay sinir ağıdır (Somuncu vd., 2021). Bir RNN ünitesinin yapısı Şekil 4'te gösterilmiştir.

RNN ünitesinde yapılan işlemin ifadesi Eşitlik 4'te gösterilmiştir.  $W$  ağırlık,  $b$  bias,  $h_t$  hücrenin  $t$  zamanındaki çıktı verisi,  $x_t$  ise  $t$  zamanındaki girdi verisi için kullanılmıştır.




Şekil 4. RNN ünitesi (RNN unit)

$$h_t = f(W_h h_{t-1} + W_x x_t + b) \quad (4)$$

Yapay sinir ağlarında olduğu gibi RNN sistemlerini eğitmek için de gradyan inişi (gradient descent) ve geri yayılım algoritması kullanılır. RNN hücrelerinde zamanda geri yayılım algoritması kullanıldığında, ünite sayısının fazla olması durumunda kaybolan veya patlayan gradyan problemlerine sebep olmaktadır. Bundan dolayı önceki zamanlardaki verinin sonraki zamanlara aktarılması için RNN modellerini temel alan LSTM ve GRU modelleri geliştirilmiştir (Fu vd., 2018).

## 2.6. Uzun kısa süreli bellek - LSTM (Long Short Term Memory - LSTM)

LSTM algoritması, RNN algoritmasının önceki ünitelerindeki ağırlık güncellemelerinde yaşanan gradyan değerinin sifıra yaklaşması sonucunda eğitimin kaybolması durumunu çözen bir algoritmadır. Bu algorithmada RNN yöntemindeki eksiklikleri gideren hafıza blokları adı verilen birimler bulunmaktadır. Hafıza bloklarında üç farklı kapı mevcuttur. Bu kapılar 5'te gösterildiği gibi sırasıyla unutma, giriş ve çıkış kapılarıdır (Wang vd., 2020).

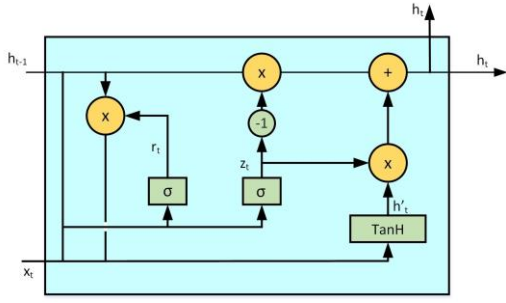


Şekil 5. LSTM ünitesi (LSTM unit)

Unutma kapısında veri setindeki hangi bilgilerin korunacağı ya da korunmayacağı belirlenmektedir. Girdi olan verilere, derin öğrenmenin giriş katmanında normalleştirme işlemi uygulanır. Normalleştirme işlemi sonunda veri sıfır değerine yakınsa verinin değerinin unutulması gerektiği düşünülür. Normalleştirilmiş veri bir değerine yakın ise verinin korunması sağlanmalıdır. Giriş kapısında ise önceki gizli durumdan gelen veri ile girdi verisi sigmoid aktivasyon fonksiyonunda işleme tabi tutulmaktadır. Unutma kapısında olduğu gibi aktivasyon işlemi sonucunda elde edilen değer bir değerine yakınsa verinin hedef çıktığı tahminde önemli olduğu anlamına gelmektedir. Bu adım sonrasında yapılan işlemlerin daha düzenli olabilmesi için giriş kapısından ve gizli durumdan gelen veriler TanH aktivasyon fonksiyonuna iletilir. TanH ile sigmoid aktivasyon fonksiyonlarından elde edilen çıktılar hangi bilgilerin tutulup hangi bilgilerin unutulacağına karar verilebilmesi için çarpılmaktadır. Bu çarpma işlemi sonrasında elde edilen değer gizli durum olarak tanımlanmaktadır (Wang vd., 2020).

## 2.7. Geçitli tekrarlayan birimler - GRU (Gated Recurrent Units - GRU)

GRU mimarisinde, LSTM yapısına göre kapıların sayısı azaltılmıştır. Böylece yapıda meydana gelen karmaşıklığı azaltarak, hesaplama performansının artırılması sağlanmıştır. GRU, bir LSTM ünitesindeki unutma ve giriş kapısını güncelleme kapısı olarak birleştirmektedir. Bunun sonucunda gizli durum ve hücre durumunun birleştirilmesi ile LSTM modelinin daha hafif bir versiyonu elde edilmektedir (Zang ve Kabuka, 2018). GRU ünitesi Şekil 6'da gösterilmiştir.




Şekil 6. GRU ünitesi (GRU unit)

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

Araç hızı ile yakıt tüketimini tahmin etmek için farklı derin öğrenme modelleri geliştirilmiştir. Bu modellerde kullanılmak üzere veri setinde her bir veri 300 ms'deki hız ve yakıtı göstermek üzere toplam 8553 veri bulunmaktadır. RNN, LSTM ve GRU modellerinde 5, 10 ve 15 veriden oluşan 3 farklı pencere boyutu kullanılmıştır. Verilerin %60'ı eğitim için, %40'ı ise test için ayrılmıştır.

RNN, LSTM, GRU tekrarlayan derin öğrenme modelleri için hiperparametre optimizasyonu yapılmıştır. Derin öğrenme modelinde tekrarlayan 1, 2 veya 3 tekrarlayan derin öğrenme katmanı bulunmaktadır. Her bir katmanda 8-256 arasında ünite bulunmaktadır.

Örnek olması için 2 katman 2 üniteli tekrarlayan derin öğrenme yapısı Şekil 7'de gösterilmiştir.



Şekil 7. Tekrarlayan derin öğrenme yapısı (Recurrent deep learning structure)

Bellek katmanlarından sonra 1-3 arasında tam bağlantı katmanı mevcuttur. Düğüm ve ünitelerde Sigmoid, TanH, ReLU aktivasyon fonksiyonları kullanılmıştır. Eğitim esnasında aşırı öğrenmenin önüne geçmek için her bir katmandan sonra %0 ile %40 arasında bırakma yapılmıştır. Öğrenme oranları  $10^{-1}$ ,  $10^{-2}$ ,  $10^{-3}$  veya  $10^{-4}$  olarak seçilmiştir. Hiperparametre optimizasyonunda kullanılan parametreler Şekil 8'de gösterilmektedir.

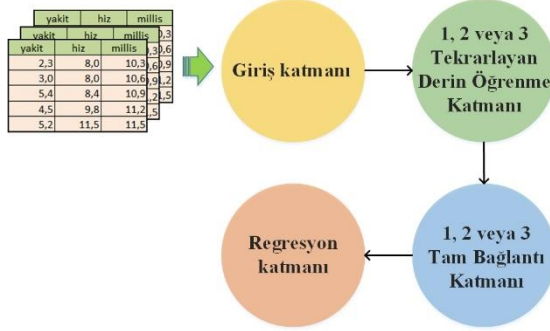
Üç pencere boyutunda her bir model rastgele arama ile her birisinde 2 yürütme olmak üzere 300 denemeye tabi tutulmuştur. Dolayısıyla toplam 2700 farklı modelde 5400 yürütme gerçekleştirilmiştir. Kullanılan hiperparametrelerle elde edilen sistemin test setindeki performansı 5 adımda iyileşmeyi bıraktığında sistemin eğitimi durdurulmuştur.

Hiperparametre Optimizasyonu						
Model	RNN, LSTM, GRU					
Pencere	5	10	15			
Tekrarlayan Katman Sayısı	1	2	3			
Tam Bağlantı Katmanı	1	2	3			
Ünite - Düğüm Sayısı	8	16	32	64	128	256
Aktivasyon Fonksiyonu	ReLU	TanH	Sigmoid			
Bırakma Yüzdeleri	0	10	20	30	40	
Öğrenme Oranı	$10^{-1}$	$10^{-2}$	$10^{-3}$	$10^{-4}$		

Şekil 8. Hiperparametre optimizasyonu parametreleri (Hyperparameter optimization parameters)

### 3.1. Önerilen modellerin performans bulguları (Performance results of the proposed models)

Verilerin eğitilmesi ve test işleminde kullanılan tekrarlayan derin öğrenme modellerinin temel yapısı Şekil 9'da gösterilmektedir. Bu şekilde, tekrarlayan derin öğrenme katmanında RNN, LSTM veya GRU ünitelerden bir tanesi bulunmaktadır.



**Şekil 9.** Tekrarlayan derin öğrenme modelleri blok diyagramı (Block diagram of the recurrent deep learning models)

Hiperparametre optimizasyonunda tahmin doğrulukları en yüksek RNN, LSTM, GRU modelleri için elde edilen eğitim ve doğrulama kayıpları Tablo 1'de verilmektedir.

**Tablo 1.** Derin öğrenme modelleri en düşük hata sonuçları (Lowest error results of the deep learning models)


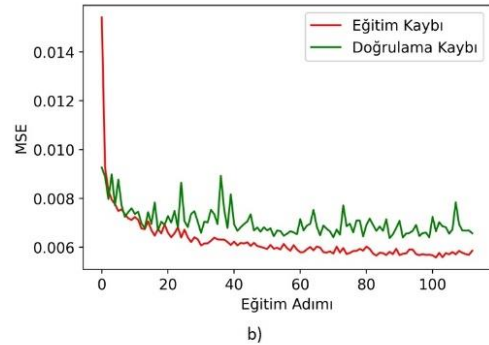
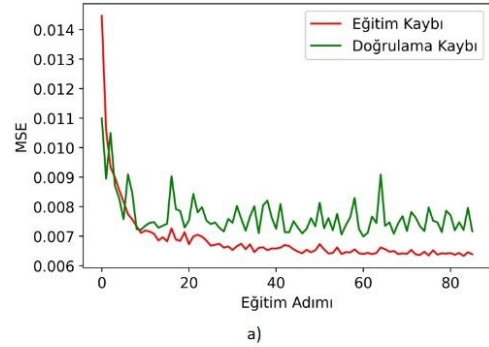
Yöntem	Pencere Sayısı	Eğitim Kayıpları	Doğrulama Kayıpları
RNN	5	0,0064	0,0071
RNN	10	0,0057	0,0064
RNN	15	0,0056	0,0062
LSTM	5	0,007	0,0075
LSTM	10	0,0127	0,011
LSTM	15	0,0058	0,0063
GRU	5	0,0063	0,007
GRU	10	0,0077	0,0072
GRU	15	0,006	0,0064

Tablo 1'de eğitim ve doğrulama kaybını (MSE) en aza indiren modellerin pencere boyutu 15 olan RNN, LSTM ve GRU modelleri olduğu görülmektedir. En performanslı çalışan model LSTM-15'te eğitim kaybının 0,0058'e ve doğrulama kaybının 0,0063'e kadar düştüğü görülmüştür. Bununla birlikte farklı denemelerde RNN, LSTM ve GRU modellerinin tahmin hatalarının birbirine çok yakın çıktığı gözlenmiştir.

Tablo 2'de hiperparametre optimizasyonu sonucu tahmin hatası en düşük olan derin öğrenme modelleri, bu modellerde kullanılan aktivasyon fonksiyonları, modeldeki ünite-düğüm sayıları ve eğitilen parametre sayıları verilmiştir. Hiperparametre optimizasyonu sonucu hatası en düşük modellerin çoğunun tek katman tekrarlayan

derin öğrenme ve tam bağlantı katmanından oluştuğu görülmektedir. Tek katmanlı modeller dışında LSTM-10'da üç tane LSTM katmanı ve GRU-15'te iki tane GRU katmanı olduğu görülmüştür. Birden fazla tam bağlantı katmanı olan modellerde hata oranları yüksek çıkmıştır. Kullanılan aktivasyon fonksiyonları TanH, ReLU ve Sigmoid olmasına rağmen TanH ve ReLU Sigmoid fonksiyonuna göre daha performanslı sonuç vermektedir. Eğitilen parametre sayısı en fazla olan modeller 99,073 ile LSTM-15 ve GRU-15 modelleridir. En az olan model ise 5,441 parametre ile LSTM-5 modelidir. Bütün modellerde 1 tane regresyon katmanı bulunmaktadır.

Şekil 10'da RNN modellerinin eğitim ve doğrulama kayıpları verilmektedir. Şekil 10'da pencere boyutu 5, 10 ve 15 olan RNN modelinin eğitim ve doğrulama kayıpları gösterilmektedir. RNN-5 86. adımda, RNN-10 113. adımda ve RNN-15 111. adımda eğitim işlemini sonlandırmıştır.




**Şekil 10.** a) 5, b) 10, c) 15 pencere boyutlu RNN eğitim ve doğrulama kayıpları (Train and validation losses of a) 5, b) 10, c) 15 window-sized RNN)

**Tablo 2.** Hatayı en aza indiren hiperparametreler ve toplam parametre sayıları (Hyperparameters that minimize the error and the total number of parameters)

Model		Aktivasyon	Ünite- Düğüm Sayısı	Bırakma Yüzdeleri	Eğitilen Parametre Sayısı	Toplam Eğitilen Parametre Sayısı
RNN 5	RNN Katmanı	TanH	128	30	16640	49921
	Tam Bağlantı Katmanı	ReLU	256	10	33024	
	Regresyon Katmanı		1		257	
RNN 10	RNN Katmanı	TanH	128	20	16640	33281
	Tam Bağlantı Katmanı	ReLU	128	10	16512	
	Regresyon Katmanı		1		129	
RNN 15	RNN Katmanı	TanH	64	20	4224	12673
	Tam Bağlantı Katmanı	ReLU	128	10	8320	
	Regresyon Katmanı		1		129	
LSTM 5	LSTM Katmanı	TanH	32	10	1088	5441
	Tam Bağlantı Katmanı	ReLU	128	20	4224	
	Regresyon Katmanı		1		129	
LSTM 10	1. LSTM Katmanı	TanH	32	40	1088	8113
	2. LSTM Katmanı	TanH	16	0	784	
	3. LSTM Katmanı	TanH	64	0	5184	
	Tam Bağlantı Katmanı	Sigmoid	16	10	1040	
	Regresyon Katmanı		1		17	
LSTM 15	LSTM Katmanı	TanH	256	10	66048	99073
	Tam Bağlantı Katmanı	ReLU	128	10	32896	
	Regresyon Katmanı		1		129	
GRU 5	GRU Katmanı	ReLU	256	20	66048	99073
	Tam Bağlantı Katmanı	ReLU	128	20	32896	
	Regresyon Katmanı		1		129	
GRU 10	GRU Katmanı	TanH	64	30	4224	21121
	Tam Bağlantı Katmanı	ReLU	256	20	16640	
	Regresyon Katmanı		1		257	
GRU 15	1. GRU Katmanı	TanH	128	20	16640	82817
	1. GRU Katmanı	TanH	128	20	32896	
	Tam Bağlantı Katmanı	TanH	256	10	33024	
	Regresyon Katmanı		1		257	




Şekil 11’de LSTM modellerin eğitim ve doğrulama kayıpları verilmektedir. Şekil 11 a’da pencere boyutu 5 olan LSTM, b’de pencere boyutu 10 olan LSTM ve c’de pencere boyutu 15 olan LSTM modelinin eğitim ve doğrulama kayıpları gösterilmektedir. LSTM-5 32. adımda, LSTM-10 30. adımda ve LSTM-15 86. adımda eğitim işlemini sonlandırmıştır.




Şekil 11. a) 5, b) 10, c) 15 pencere boyutlu LSTM eğitim ve doğrulama kayıpları (Train and validation losses of a) 5, b) 10, c) 15 window-sized LSTM)

Şekil 12’de GRU modellerin eğitim ve doğrulama kayıpları verilmektedir. Şekil 12 a’da pencere boyutu 5 olan GRU, b’de pencere boyutu 10 olan GRU ve c’de pencere boyutu 15 olan GRU modelinin eğitim ve doğrulama kayıpları gösterilmektedir. GRU-5 67. adımda, GRU-10 59. adımda ve GRU-15 67. adımda eğitim işlemini sonlandırmıştır.




Şekil 12. a) 5, b) 10, c) 15 pencere boyutlu GRU eğitim ve doğrulama kayıpları (Train and validation losses of a) 5, b) 10, c) 15 window-sized GRU)


Şekil 13, Şekil 14 ve Şekil 15’te tahmin doğruluğu en yüksek olan modellerin yakıt tüketimi tahminleri gösterilmiştir. Sol y eksenini yakıt tüketimini, sağ y eksenini ise hızı göstermektedir. Mavi çizgi ölçülen hızı, yeşil çizgi ölçülen yakıt tüketimini, kırmızı çizgi ise modellerin tahmini sonucu elde edilen yakıt tüketimini göstermektedir.



Şekil 13. RNN-5 modeli yakıt tüketim tahmini, hız ve gerçek yakıt tüketimi (RNN-5 model fuel consumption prediction, speed and actual fuel consumption)



**Şekil 14.** LSTM-5 modeli yakıt tüketim tahmini, hız ve gerçek yakıt tüketimi (LSTM-5 model fuel consumption prediction, speed and actual fuel consumption)



**Şekil 15.** GRU-15 modeli yakıt tüketim tahmini, hız ve gerçek yakıt tüketimi (GRU-15 model fuel consumption prediction, speed and actual fuel consumption)

Kasislerdeki yakıt tüketiminin aracın markası, modeli, yakıt türü, motor hacmi, ağırlığı, araçtaki yük miktarı, yolun eğimi gibi pek çok parametreye göre değişkenlik göstereceği aşikardır. Bu çalışmanın amacı ise kasislerin ortalama bir araçta, yakıt tüketimine yaklaşık etkisinin araştırılmasıdır. Bundan dolayı makine öğrenmesi modelleri sadece hız ve yakıt tüketimi bilgileri ile eğitilmiştir. Yine de yakıt tüketim tahminlerinin karşılaştırılması Tablo 3'te verilmiştir. Tabloda RMSE kök ortalama kare hatası (root mean square error), MAE ortalama mutlak hata (mean absolute error) için kullanılmıştır.

**Tablo 3.** Modellerin önceki çalışmalarla karşılaştırması (Comparison of the models with the previous studies)

Çalışma	Model	RMSE	MAE	R <sup>2</sup>
Wickrama-nayake ve Bandara (2016)	RF	0,0404	0,02295	-
	Gradient Boosting	0,0471	0,02585	-
	ANN	0,04740	0,02756	-
Perrotta vd. (2017)	SVM	5,12	3,56	0,83
	RF	4,64	3,21	0,87
	ANN	4,88	3,46	0,85
Panapakidis vd. (2020)	SVM	2,190	1,697	-
	LSTM	1,936	1,398	-
Bu çalışma	RNN-15	0,2487	0,0599	0,664
	LSTM-15	0,2522	0,0612	0,654
	GRU-15	0,2459	0,0604	0,638

Tablo 4'te gerçek sürüş esnasında kasislerden geçişlerdeki hız ve zaman bilgileri gösterilmektedir. Bu tabloda "Giriş Hızı" kasis için yavaşlamaya başlamadan önceki hızı, "En Düşük Hız" kasis kaynaklı en düşük

hızı, "Yavaşlama Süresi" Giriş Hızı ile En Düşük Hız arasında geçen süreyi, "Çıkış Hızı" kasisin etkisinin geçtiği ve kasisin önceki benzer sabit hıza geçildiği hızı, "Hızlanma Süresi" En Düşük Hızla Çıkış Hızı arasındaki geçen süreyi ifade etmektedir.


**Tablo 4.** Gerçek zamanlı kasis geçiş bilgileri (Real-time bump transition data)

Giriş Hızı (km/sa)	Yavaşlama Süresi (sn)	En Düşük Hız (km/sa)	Hızlanma Süresi (sn)	Çıkış Hızı (km/sa)
38	4,4	15	6,6	42
45	3,7	23	8,5	50
48	6,7	20	5,9	47
50	5,2	22	9,6	52
55	7,7	22	7,6	58
60	5,2	16	10,3	60


Tablo 4'teki veriler kullanılarak hızın belirtilen zamanlardaki doğrusal olarak azalma ve artmaları Şekil 16'da gösterilmiştir. Burada y eksenini kasisin geçiş esnasında oluşan hızı, x eksenini ise kasisin geçme süresini göstermektedir.

Şekil 17'de bulunan grafik Şekil 16'da hesaplanan kasis yavaşlama ve hızlanmaları için tahmin edilen yakıt tüketimlerini göstermektedir. Yakıt tüketim tahmini hiperparametre optimizasyonu sonucu en performanslı çalışan model olan RNN-15 kullanılarak yapılmıştır.

Tablo 5'te kasisin geçiş sırasında harcanan yakıt miktarı ve kasisin etkisi boyunca gidilen mesafe verilmektedir. Ayrıca aynı mesafe kasis olmadan sabit "Giriş Hızında" gidildiğinde harcanan yakıt miktarı ve kasisli yolda sabit hıza göre fazla harcanan yakıt miktarı yüzdesel olarak verilmiştir.



**Şekil 16.** Kasisin geçiş esnasında doğrusal yavaşlama ve hızlanma (Linear deceleration and acceleration during bump transition)



**Şekil 17.** Kasisten geçiş sırasındaki yakıt tüketim tahmini (Fuel consumption prediction during bump transition)

**Tablo 5.** Kasisten kaynaklı yakıt artış oranları (Fuel increase rates due to bump)

Kasis Tahmin Yakıt (lt/100km)	Sabit Hız Yakıt (lt/100km)	Fazla Harcanan Yakıt Yüzdesi	Gidilen Mesafe (m)
0,0062	0,0048	28,38	085,38
0,0095	0,0073	31,03	119,17
0,0090	0,0077	16,30	118,17
0,0116	0,0100	16,37	149,67
0,0150	0,0118	27,11	166,75
0,0154	0,0128	20,98	161,50

Tablo 5'te görüldüğü gibi aynı mesafedeki yolda kasis olmadığı durumda fazla harcanan yakıt miktarı %16,3 ile %31,03 arasında değişmektedir. Kasisteki hızlanma süresi ve kasis çıkış hızının yüksek olması kasisten kaynaklı yakıt tüketiminin artmasına sebep olduğu görülmektedir.

#### 4. Sonuçlar (Conclusions)

Bu çalışmada trafik akışını yavaşlatmak için yaygın olarak kullanılan hız kesici tümseklerin yakıt tüketimine etkisi incelenmiştir. Bunun için araç sürüşü esnasında hız ve yakıt verileri alınmış ve bu veriler tekrarlayan derin öğrenme modellerinin eğitilmesinde kullanılmıştır. Eğitilen modellerde hiperparametre optimizasyonu yapılmış ve en düşük %63 ortalama kare hatası elde edilmiştir. En az tahmin hatasını veren model olan 15 ardışıl verili RNN modeli ile yapılan yakıt tahmini ve hesaplamalar neticesinde bir kasisin %16,30 ile %31,03 arasında daha fazla yakıt sarfiyatına sebep olduğu tespit edilmiştir. Bu tespit her ne kadar kullanılan araç için geçerli olsa da genel olarak araçlardan elde edilecek hız-yakıt verileri ile benzer tahminlerin yapılabilmesi mümkündür. Aynı zamanda yolun eğimi, aracın taşıdığı ağırlık, motor hacmi, yakıt türü gibi parametrelerin kasilerdeki yakıt sarfiyatını etkilemesi kaçınılmazdır. Ancak yapılan çalışma ortalama bir aracın kasisten kaynaklı fazla yakıt sarfiyatı ile ilgili genel bir fikir vermektedir. Şehirlerde çok sayıda

bulunan kasilerin üzerinden geçen araçların sayısı da göz önüne alındığında ciddi miktarda yakıt tüketimine sebep olabileceği anlaşılmaktadır. Kasilerde belirli standartların uygulanmaması, geçiş esnasında aracın zarar görmesi, sürüş konforunun azalmasına ve günün tüm saatlerinde kasisten kaynaklı gereğinden fazla yavaşlamaya da sebep olmaktadır. Bundan dolayı kasilerin kullanılması yerine araçların hızlarının elektronik olarak tespit edilmesi gibi daha modern yöntemlerin kullanılmasının daha uygun olduğu düşünülmektedir.

#### Teşekkür (Acknowledgment)

Bu çalışmada yer alan derin öğrenme modellerinin eğitimleri TÜBİTAK ULAKBİM, Yüksek Başarım ve Grid Hesaplama Merkezinde (TRUBA kaynaklarında) gerçekleştirilmiştir.


#### Kaynaklar (References)

- Amarasinghe, M., Kottegoda, S., Arachchi, A. L., Muramudalige, S., Bandara, H. M. N. D., Azeez, A., 2015. "Cloud-based driver monitoring and vehicle diagnostic with OBD-II telematics". 2015 Fifteenth International Conference on Advances in ICT for Emerging Regions (ICTer), 243–249. <https://doi.org/10.1109/ICTER.2015.7377695>
- Coşkun, U. 2008. "Controller Area Network Uygulaması". Yüksek Lisans Tezi, Gebze Teknik Üniversitesi, Yüksek Teknoloji Enstitüsü
- Cueva-Fernandez, G., Espada, J. P., García-Díaz, V., García, C. G., Garcia-Fernandez, N., 2014. "Vitruvius: An expert system for vehicle sensor tracking and managing application generation". Journal of Network and Computer Applications, 42, 178–188. <https://doi.org/https://doi.org/10.1016/j.jnca.2014.02.013>
- Fu, Y., Lou, F., Meng, F., Tian, Z., Zhang, H., Jiang, F., 2018. "An Intelligent Network Attack Detection Method Based on RNN". 2018 IEEE Third International Conference on Data Science in Cyberspace (DSC), 483–489. <https://doi.org/10.1109/DSC.2018.00078>
- Kowalik, B. 2018. "Introduction to car failure detection system based on diagnostic interface". In 2018 International Interdisciplinary PhD Workshop (IIPhDW (pp. 4-7). IEEE.
- Kowalik, B., Szyrka, M. 2019. "Online environment for data acquisition from car sensors". Automatyka/Automatics, 23(1), 7-7.
- Lokman, S.-F., Othman, A. T., Abu-Bakar, M.-H., 2019. "Intrusion detection system for automotive Controller Area Network (CAN) bus system: a review". EURASIP Journal on Wireless Communications and Networking, 2019(1), 184. <https://doi.org/10.1186/s13638-019-1484-3>
- Meseguer, J., E., Calafate, C., T., Cano, J., C., Manzoni, P., 2015. "Assessing the Impact of Driving Behavior on Instantaneous Fuel Consumption". 12th Annual IEEE Consumer Communications and Networking Conference (CCNC), 443–448. <https://doi.org/10.1109/CCNC.2015.7158016>
- Perrotta, F., Parry, T., Neves, L. C., 2017. "Application of machine learning for fuel consumption modelling of

- trucks”. 2017 IEEE International Conference on Big Data (Big Data), 3810–3815.  
<https://doi.org/10.1109/BigData.2017.8258382>
- Somuncu, E., Atasoy, N., 2021. “Evrişimli tekrarlayan sinir ağı ile metin görüntüleri üzerinde karakter tanıma uygulaması gerçekleştirilmesi”. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 37 (1), 17-28. DOI: 10.17341/gazimmfd.866552
- Syahputra, R., 2016. “Application of neuro-fuzzy method for prediction of vehicle fuel consumption”. Journal of Theoretical and Applied Information Technology, 86(1).
- Şen, B., 2020. “Estimating instant fuel consumption by machine learning and improving fuel consumption”. Yüksek Lisans Tezi, Galatasaray Üniversitesi Fen Bilimleri Enstitüsü
- Uyanık, T., Karatüğ, Ç., Arslanoğlu, Y., 2020. “Machine learning approach to ship fuel consumption: A case of container vessel”. Transportation Research Part D: Transport and Environment, 84, 102389.  
<https://doi.org/https://doi.org/10.1016/j.trd.2020.102389>
- Vilgenoğlu, E., 2019. “Real-time vehicle monitoring and on-board diagnostic system”. Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü
- Wang, J., Du, Y., Wang, J., 2020. “LSTM based long-term energy consumption prediction with periodicity. Energy”, 197, 117197.  
<https://doi.org/10.1016/j.energy.2020.117197>
- Wang, W., Liu, H., Lin, W., Chen, Y., Yang, J.-A., 2020. “Investigation on Works and Military Applications of Artificial Intelligence”. IEEE Access, 8, 131614–131625.
- Wickramanayake, S., Bandara, D., 2016. “Fuel consumption prediction of fleet vehicles using Machine Learning: A comparative study”. 2nd International Moratuwa Engineering Research Conference, MERCon 2016, 90–95.  
<https://doi.org/10.1109/MERCon.2016.7480121>
- Zhang, D., Kabuka, M, R., 2018. “Combining weather condition data to predict traffic flow: a GRU-based deep learning approach IET Intelligent Transport Systems”, 12(7), 578-585.



# Yerel Arama Bölümü Güncellenmiş Arı Algoritması ile Gezgin Satıcı Problemi Optimizasyonu

Murat Şahin<sup>1\*</sup> 

<sup>1</sup> Kontrol Sistemleri Geliştirme Müdürlüğü, Roketsan A. Ş., Ankara, Türkiye

msahin@roketan.com.tr

## Öz

Klasik optimizasyon yöntemleri ile çok sayıda bağlantıya sahip gezgin satıcı problemlerinin çözülebilmesi zordur. Bu kapsamda, aramalarını optimum bir çözüme yönlendiren meta-sezgisel algoritmalar tercih edilmektedir. Bu çalışmada, bu meta-sezgisel algoritmalarından biri olan ve bal arılarının yiyecek arama yöntemlerinden esinlenerek geliştirilen Arı Algoritması incelenmiştir. Çalışmanın amacı, Arı Algoritmasının gezgin satıcı problemlerinin çözümüne yönelik etkinliğinin artırılmasıdır. Klasik Arı Algoritması içerisine Değişken Çoklu Ekleme operatörü eklenmiş ve yakın komşuluk bölgeleri içerisinde arama yapılarak, farklı gezgin satıcı problemleri için testler yapılmıştır. Yapılan testler sonucunda bu algoritma ile literatürdeki diğer Arı Algoritmalarına göre çok daha iyi sonuçlar elde edildiği görülmüştür. Geliştirilen algoritma ile 100 şehirlik problemlerde sapma değerleri %1,40-2,80 aralığından %0,11-0,50 aralığına ve 200 şehirlik problemlerde de %8,10-9,67 aralığından %2,00-2,79 aralığına indirildiği gözlemlenmiştir.

**Anahtar kelimeler:** Arı Algoritması, değişken çoklu ekleme, gezgin satıcı problemi, komşuluk, optimizasyon

## Traveling Salesman Problem Optimization with Local Search Section Updated Bees Algorithm

### Abstract

Solving traveling salesman problems with many connections with classical optimization methods is challenging. In this context, meta-heuristic algorithms that direct their searches to an optimum solution are preferred. In this study, the Bee Algorithm, one of these meta-heuristic algorithms inspired by the foraging methods of honey bees, was examined. The study aims to increase the Bees Algorithm's effectiveness in solving traveling salesman problems. The Variable Multiple Insertion operator has been added to the Classical Bee Algorithm, and optimizations have been made for different traveling salesman problems by searching within close neighborhood regions. As a result of the tests, it was seen that much better results were obtained with this algorithm compared to other Bee Algorithms in the literature. The algorithm has reduced from 1.40-2.80% to 0.11-0.50% in problems of 100 cities and from 8.10-9.67% to 2.00-2.79% in issues of 200 cities.

**Keywords:** The Bees Algorithm, optimization, the traveling salesman problem, variable multiple insertion, neighborhood

### 1. Giriş (Introduction)

Optimizasyon, belirli şartlar altında en iyi çözümü bulma işlemidir ve mühendislik çalışmalarının önemli bir parçasıdır. Mühendisliğin tasarım, geliştirme ve üretim gibi alanlarında yapılan çalışmalarda, harcanılan çabayı, maliyeti minimuma indirmek veya kazancı maksimuma çıkarmak hedeflenir. Bu hedeflerin amaç fonksiyonları belirli kısıtlar altında formüle edilir ve

optimizasyon çalışmaları ile fonksiyonların maksimum veya minimum değerini veren değişkenler bulunur. (Rao, 2019).

Tüm optimizasyon problemlerini verimli bir şekilde çözmek için kullanılacak tek bir yöntem yoktur. Bu nedenle, farklı tipte optimizasyon problemlerinin çözümü için bir dizi optimizasyon yöntemi geliştirilmiştir. Bu yöntemlerden matematiksel optimizasyon teknikleri; öngörülen bir kısıtlamalar seti altında çeşitli değişkenlerden oluşan bir fonksiyonun

\* Sorumlu yazar.  
E-posta adresi: msahin@roketan.com.tr



minimumunu bulmakta yararlıdır. Stokastik süreç teknikleri; bir dizi rasgele değişken tarafından tanımlanan problemleri analiz etmek için kullanılabilir. İstatistiksel yöntemler; kişinin deneysel verileri analiz etmesini ve fiziksel durumun en doğru halini elde etmek için ampirik modeller oluşturmasını sağlar (Manea vd., 2019). Geleneksel olmayan optimizasyon yöntemleri olarak da adlandırılan modern optimizasyon yöntemleri ise, son yıllarda, karmaşık mühendislik problemlerini çözmek amacıyla ortaya çıkmıştır. Yöntemlerin temelinde sezgisel fikri bulunmaktadır (Khan vd., 2015). Bu yöntemlerin çoğu biyolojik, moleküler, böcek sürüsü ve nörobiyolojik sistemlerin belirli özelliklerine ve davranışlarına dayanmaktadır. Aramalarını optimal bir çözüme doğru yönlendirmek için, doğanın ilkelerini taklit ederler. Tepe tırmanışı (hill climbing) ve rastgele yürüme (random walk) gibi standart arama algoritmalarından en önemli farklılıklardan biri, tek bir çözüm yerine her yineleme için bir çözüm popülasyonu kullanmasıdır. Bir optimizasyon probleminin tek bir optimum değeri varsa, tüm popülasyon üyelerinin bu optimum çözüme yaklaşması beklenir (Hussain vd., 2019). Meta-sezgisel algoritmalar günümüzde büyük veri analizinden, 3 boyutlu paketleme ve depolama problemlerine kadar birçok farklı alanda kullanılmaktadır (Bayraktar vd., 2021; Erdem vd., 2021).

Meta-Sezgisel algoritmaların tercih edildiği alanlardan biri de Gezgin Satıcı Probleminin de (GSP) dahil olduğu kombinatoriyal optimizasyon problemleridir. GSP, çok sayıda şehirde satış yapacak bir satış elemanının, bu şehirleri ziyaret ederken minimum yol kat etme prensibine dayanır (Daoqing ve Mingyan, 2020). Bilgisayar ağlarının oluşturulması, lojistik planlama, otonom araçların hareket planı vb. birçok alanda kullanılmaktadır (Xie vd., 2019). Literatürde inceleme yapıldığında GSP optimizasyonu için, Aslan Sürüsü Optimizasyonu (Daoqing ve Mingyan, 2020), Karınca Kolonisi Optimizasyonu (Mavrovouniotis vd., 2017), Yapay Arı Kolonisi Algoritması (Dong vd., 2019), Benzetiilmiş Tava Algoritması (Wang vd., 2019) ve Genetik Algoritma (Al-Furhud ve Ahmed, 2020) gibi sezgisel algoritmaların kullanıldığı görülmektedir.

Popüler meta-sezgisel algoritmalarından birisi de Arı Algoritması'dır (AA). Pham ve arkadaşları tarafından 2005 yılında önerilen AA, popülasyon temelli arama algoritmasıdır. Algoritma, bal arılarının nektar kaynağı arama davranışlarını taklit eder. Temelde, rastgele arama ile birlikte bir tür komşu bölge araması yapar ve hem tümlşik hem de fonksiyonel optimizasyon için kullanılabilir (Pham vd., 2006). Temel algoritmanın bünyesinde herhangi bir denklem bulunmaz, bu nedenle diğer algoritmalara göre daha basit bir yapısı vardır. Basit yapısına rağmen, birçok farklı uygulama alanında kullanılabilir esnek ve güçlü bir algoritmadır (Zarchi ve Attaran, 2017). AA'nın; mekanik parçaların tasarımlarının optimize edilmesi (Nafchi vd., 2012), kontrol sistemleri optimizasyonu (Coban ve Ercin,

2012), robotik parçaların tasarımı (Acar vd., 2018), devre tasarımı optimizasyonu (Mollabakhshi ve Eshghi, 2013), araç yönlendirme planlaması (Alzaqebah vd., 2018), elektrik motoru tasarımı optimizasyonu (Braiwish vd., 2014) gibi birçok farklı alanda başarı ile kullanıldığı bilinmektedir. Bununla birlikte algoritmanın, GSP kapsamında iyileştirme çalışmaları devam etmektedir. 51 şehirlik problemler (Koç, 2010) ile başlayan bu çalışmalar, sonraki yıllarda 100 şehirlik (Otri, 2011) ve 200 şehirlik (Zeybek vd., 2021; Ismail vd., 2020) problemler ile devam etmiştir. İlgili çalışmalar incelendiğinde, 100 şehrin üzerindeki problemler için en iyi değerlere yaklaşmadığı görülmektedir. Bu durum, bu çalışmanın hazırlanmasındaki ana motivasyon kaynağı olmuştur. Makalenin ikinci bölümünde AA'nın genel yapısı detaylı bir şekilde incelenmiştir. Üçüncü bölümde GSP'nin yapısı ve AA'nın uygulanışı ele alınmıştır. Bu bölümde lokal arama kapsamında daha önce kullanılan standart operatörlere ek olarak değişken çoklu ekleme operatörü eklenmiştir. Komşuluk araması ise yakın bölgeleri kapsayacak şekilde daraltılmıştır. Dördüncü bölümde ise test sonuçları ve analizler mevcuttur.

## 2. Arı Algoritması (The Bees Algorithm (BA))

AA, popülasyon tabanlı bir arama algoritmasıdır. Algoritma, lokal ve global arama bölümü olmak üzere, temel olarak 2 bölümden oluşur. Önemli parametreler; keşif (scout) arıların sayısı ( $n$ ), yerel arama için iyi bölgelerin (best site) sayısı ( $m$ ), yerel arama için elit bölgelerin (elite site) sayısı ( $e$ ), elit bölgelere yollanan arıların (recruited bees) sayısı ( $nep$ ), iyi bölgelere yollanan arıların sayısı ( $nsp$ ), komşuluk boyutu ( $ngh$ ) ve yineleme sayısıdır ( $I$ ) (Baronti vd., 2020).

Algoritmanın sözde-kodu Şekil 1'de verilmiştir. Algoritma, parametrelerin belirlenmesi ile başlar (1. adım). Daha sonra keşif arılar  $n$  adet arama alanına rastgele yerleştirilir ve ilk popülasyon oluşturulur (2. adım). İlk popülasyon, minimizasyon problemleri için küçükten büyüğe, maksimizasyon problemleri için ise büyükten küçüğe doğru sıralanır (3. adım). Sonraki adımda lokal arama bölümü başlar ve ilk olarak elit bölge araması yapılır (5-11 adımlar). Her elit bölge için  $nep$  sayıda,  $ngh$  komşuluk sınırları içerisinde rastgele denemeler yapılır. Bu denemeler sonucunda bulunan en iyi değer, önceki popülasyondaki değerden daha iyi ise ilgili bölge için kaydedilir. 12-18 adımlar arasında ise iyi bölge araması yapılır. Her iyi bölge için  $nsp$  sayıda,  $ngh$  komşuluk sınırları içerisinde rastgele denemeler yapılır ve elit bölgede olduğu gibi bu denemeler sonucunda bulunan en iyi değer, önceki popülasyondaki değerden daha iyi ise ilgili bölge için kaydedilir.

Sonraki adımlarda global arama işlemi gerçekleştirilir (19-21).  $n$  bölge içinde, lokal aramanın yapılmadığı bölgeler için rastgele yeni değerler atanır. Bu bölüm özellikle lokal minimumlara takılmamak için önemlidir. Lokal aramada ulaşılamayan bölgelerde daha iyi değerler var ise onlara ulaşılmasını sağlayabilir.



Sonraki adımda popülasyon yeniden sıralanır ve elit-iyi bölgeler güncellenir. Böylece her yinelemede, elit bölgelerde daha çok arama yapılacaktır. Bu adımlar, belirli sonlandırma kriteri karşılanana kadar tekrarlanır (Baronti vd., 2020; Yüce vd., 2014).

```

1: Algoritma parametrelerini belirle
2: İlk popülasyonu rastgele üret
3: Popülasyonu sırala
4: while (durdurma kriteri sağlanmadıysa) do
// Elit bölge
5:   for i=1:e
6:     for j=1:nep
7:       n(i) için ngh komşuluk araması yap
8:       n(i)'nin en iyi komşusunu belirle
9:     end
10:    En iyi komşu, n(i)'den iyi ise kayı et
11:  end
// İyi bölge
12:  for i=e+1:m
13:    for j=1:nsp
14:      n(i) için ngh komşuluk araması yap
15:      n(i)'nin en iyi komşusunu belirle
16:    end
17:    En iyi komşu, n(i)'den iyi ise kayı et
18:  end
// Global arama
19:  for i=m+1:n
20:    Rastgele yeni bölgeler üret
21:  end
22:  Popülasyonu sırala
23: end while

```

**Şekil 1. AA Sözde Kodu**  
(Pseudo Code of the BA)

### 3. AA ile GSP Optimizasyonu (Optimisation of TSP with the BA)

GSP'de turun maliyeti doğrudan turun uzunluğuna bağlıdır. Birbirini izleyen iki şehir arasındaki mesafe aşağıdaki şekilde tanımlanır (Karaboğa ve Görkemli, 2019):


$$d(T(i), T(i+1)) = \sqrt{(x_i - x_{i+1})^2 + (y_i - y_{i+1})^2} \quad (1)$$

x ve y, şehirlerin koordinatlarını gösterir. Denklem (2)'de toplam tur mesafesinin hesaplanması gösterilmiştir (Karaboğa ve Görkemli, 2019):

$$\sum_{i=1}^{n-1} d(T(i), T(i+1)) + d(T(n), T(1)) \quad (2)$$

Denklemden, n toplam şehir sayısını temsil eder. GSP'ye yönelik hazırlanan optimizasyon algoritmalarında, arama bölümleri ve komşuluk tanımları sürekli problemlerden farklıdır. Genel olarak güzergah üzerindeki şehirlerin konumu belirli kurallara göre değiştirilerek daha az maliyetle yeni güzergahlar bulunmaya çalışılır. AA için, Ismail ve ark. lokal arama bölümünde (Ismail vd., 2020) Takas, Ekleme ve Ters Çevirme olmak üzere üç farklı operatör önermişlerdir. Takas operatöründe rastgele seçilen iki şehrin sırası

birbirine değiştirilir (Ismail vd., 2020). Bu çalışmada ise birinci şehir tüm şehirler içinden rastgele seçilirken, ikinci şehir ilkinin yakın komşuluğunda rastgele seçilir. Şekil 2 ve 3'te takas operatörünün uygulanışı ve sözde kodu verilmiştir.



**Şekil 2. Takas İşlemi (Swap)**


```

1: ss:şehir sayısı
2: n_i:seçili rota
3: Function Takas (n_i,ss)
4: Rastgele 1. sayıyı üret s1
// (1 - ss arasında)
5: Komşulukta s2 seç
// (s1 hariç)
6: n_i(s2)=n_i(s1)
7: n_i(s1)=n_i(s2)
8: End Function

```

**Şekil 3. Takas İşlemi Sözde Kodu (Pseudocode of Swap)**

Ekleme operatöründe, rastgele seçilen bir şehrin sıralaması, yakın komşulukta rastgele seçilen farklı bir sıraya eklenir (Ismail vd., 2020). Şekil 4'te örnek üzerinden gösterilmiştir. Görüldüğü üzere ilk güzergahdaki 2 numaralı şehrin yeri, 4 numaralı şehirden sonraki bölüme eklenmiş ve çok daha iyi bir güzergah elde edilmiştir.



**Şekil 4. Ekleme İşlemi (Insertion)**


Tersine çevirme operatöründe ise, rastgele belirlenen iki şehir arasındaki sıralama tersine çevrilir (Ismail vd., 2020). Şekil 6'da örnek üzerinden gösterilmiştir. İlk güzergahdaki 2 ve 4 numaralı şehirler arasındaki sıralama tersine çevrilmiştir.

```

1: ss:şehir sayısı
2: n_i:seçili rota
3: Function Ekleme (n_i,ss)
4: Rastgele 1. sayıyı üret s1
5: Yakın Komşulukta s2 seç
// (s1 ve s1-1 hariç)
6: if s1<s2
7:   n_i=n_i([1:s1-1 s1+1:s2 s1 s2+1:end])
8: else
9:   n_i=n_i([1:s2 s1 s2+1:s1-1 s1+1:end])
10: end
11: End Function

```

**Şekil 5.** Ekleme İşlemi Sözde Kodu (Pseud Code of Insertion)



**Şekil 6.** Tersine Çevirme İşlemi (Reversion)

```


1: ss:şehir sayısı
2: n_i:seçili rota
3: Function TersCevirç (n_i,ss)
4: Rastgele 1. sayıyı üret s1
5: Komşulukta 2. sayıyı üret s2
6: if s1<s2
7:   n_i(s1:s2)= n_i(s2:-1:s1)
8: else
9:   n_i(s1:-1:s2)= n_i(s2:s1)
10: end
11: End Function

```

**Şekil 7.** Tersine Çevirme İşlemi Sözde Kodu (Pseud Code of Reversion)

Bu çalışmada 3 operatöre ek olarak değişken çoklu ekleme operatörü eklenmiştir. Şekil 3'ten görüldüğü üzere, ekleme operatörünün güzergah üzerindeki etkisi çok güçlüdür. Özellikle şehir sayısının 100 ve üzerinde olduğu problemlerde, birden fazla şehrin yakın bölgelerde bulunduğu ve topluca yer değişimine uygun olduğu görülmektedir. Tek şehirli ekleme operatörünün aksine, rastgele belirlenen bir bölgeden birden çok ve değişken sayıda şehirler alınır. Sayının değişken olması ise, kümelenen şehir sayısının da değişken olmasından kaynaklanmaktadır. Bu şehirler komşulukta belirlenen ikinci alana yerleştirilir. Çoklu seçim yapılırken, seçilecek şehir sayısı ise deneysel çalışmalar ile belirlenmiştir.

Değişken çoklu ekleme operatörünün güzergah üzerindeki etkisi Şekil 7'de ve sözde kodu Şekil 8'de gösterilmiştir.



**Şekil 7.** Değişken Çoklu Ekleme İşlemi (Variable Multiple Insertion)

```

1: ss:şehir sayısı
2: n_i:seçili rota
3: Function ÇokluEkleme(n_i,ss)
4: Rastgele sayı üret c (2-7 arasında)
5: Rastgele 1. bölgeyi seç s1
6: for i=1:c
7:   dizi(i)=(s1+i-1)
8: end
9: Komşulukta rastgele 2. bölgeyi seç s2
10: if s1<s2
11:   n_i=n_i([1:s1-1 s1+c:s2 s1:s1+c-1 s2+1:end])
12: else
13:   n_i=n_i([1:s2 s1:s1+c-1 s2+1:s1-1 s1+c:end])
14: end
15: End Function

```

**Şekil 8.** Değişken Çoklu Ekleme İşlemi Sözde Kodu (Pseud Code of Variable Multiple Insertion)

Çalışmada geliştirilen algoritmanın sözde kodu Şekil 9'da gösterilmiştir. Görüldüğü üzere genel AA yapısı içerisinde 4 farklı operatör seçimi bulunmaktadır. Her bir yinelemede, bu operatörlerden biri rastgele seçilerek uygulanmaktadır. Elit bölgelerde daha fazla sayıda arama yapılmaktadır. (21-36 arası bölümler, 5-20 arası bölüm ile aynı olup sadece *nep* yerine *nsp* gelmektedir.)

Algoritma parametreleri belirlenirken diğer kombinatoriyal problemlere yönelik hazırlanan çalışmalarda kullanılan değerler dikkate alınmıştır (Alzaqebah vd., 2018; Zeybek vd., 2021; Ismail vd., 2020; Yuce vd., 2014). Bu çalışmalarda popülasyon sayıları 20 ile 100 aralığında değişmektedir. İşlem gücünü düşürmek amacıyla popülasyon sayısı 20 olarak belirlenmiştir. GSP'lerdeki olası çözümlerin sayısı doğrudan şehir sayısına bağlıdır ve  $(n-1)!/2$  ile ifade edilir (Ahmed, 2010). Bu durumda rastgele oluşturulmuş bir rotanın optimum rotaya yakın olması pek olası değildir. Bu nedenle çalışmada lokal arama bölgesi de 20 olarak belirlenmiştir ve global arama bölümü kullanılmamıştır. (Analiz bölümünde global aramanın da olduğu denemeler gerçekleştirilmiş ve sonuçlar gösterilmiştir.) Elit bölge sayısı popülasyonun %20'si yani 4 olarak belirlenmiştir. Elit bölgede arama için 300 arı, diğer bölgelerde de 100 arı kullanılmıştır. Tüm parametreler Tablo 1'de verilmiştir. Algoritmanın tekrarlanabilirliğini görmek amacıyla, tüm problemler için ard arda 10ar test yapılmıştır.

```

1: Algoritma parametrelerini belirle
2: İlk popülasyonu rastgele üret
3: Popülasyonu sırala
4: while (durdurma kriteri sağlanmadıysa) do
5:   for i=1:e
6:     for j=1:nep
7:       Rastgele sayı üret s (1-4)
8:       if s==1
9:         Takas(n(i))
10:      elseif s==2
11:        Ekleme(n(i))
12:      elseif s==3
13:        TersCevir(n(i))
14:      else
15:        CokluEkleme(n(i))
16:      end
17:      n(i)'nin en iyi komşusunu belirle
18:    end
19:    En iyi komşu, n(i)'den iyi ise kayıt et
20:  end
21:  for i=e+1:m
22:    for j=1:nsp
23:      Rastgele sayı üret s (1-4)
24:      if s==1
25:        Takas(n(i))
26:      elseif s==2
27:        Ekleme(n(i))
28:      elseif s==3
29:        TersCevir(n(i))
30:      else
31:        CokluEkleme(n(i))
32:      end
33:      n(i)'nin en iyi komşusunu belirle
34:    end
35:    En iyi komşu, n(i)'den iyi ise kayıt et
36:  end
37:  Popülasyonu sırala
38: end while

```

**Şekil 9.** GSP için AA Sözde Kodu  
(BA Pseudo Code for TSP)

Algoritmayı test etmek amacıyla TSPLIB (Library of Traveling Salesman Problem) kütüphanesi içerisinde, farklı sayılara ve yerleşim planlarına sahip problemlerden bazıları seçilmiştir (TSPLIB, 2020). Sonuçları optimum değerlerle karşılaştırmak için, hem 10 tekrarın ortalamalarının hem de bu tekrarlar içerisinde bulunan en iyi değerlerin yüzde olarak

sapmaları da hesaplanmıştır. Bu kapsamda (3) ve (4)'te verilen eşitlikler kullanılmıştır (Ismail vd., 2020).

**Tablo 1.** AA Parametreleri  
(BA Parameters)

<i>Parametre Tipi</i>	<i>Parametre Değeri</i>
Toplam test sayısı	10
İterasyon sayısı	1000
Keşif arısı sayısı (n)	20
Elit bölge sayısı (e)	4
İyi bölge sayısı (m)	20
Elit bölgedeki arı sayısı (nep)	300
İyi bölgedeki arı sayısı (nsp)	100
Komşuluk (ngh)	10

$$S_{ort} = \frac{(Ort.-Opt.)}{(Opt.)} * 100\% \quad (3)$$

$$S_{min} = \frac{(Min.-Opt.)}{(Opt.)} * 100\% \quad (4)$$


Eşitliklerde “Ort.” ile testlerin ortalama değeri, “Opt.” ile problemin bilinen optimum değeri, “Min.” ile testlerde elde edilen en iyi değer gösterilmektedir.

#### 4. Deneysel Çalışmalar ve Sonuçlar (Experimental Studies and Results)

Algoritma Matlab R2018a programında geliştirilmiştir. Çalışmaların yapıldığı bilgisayar, Lenovo Thinkpad, Intel Core i5-8265U CPU 1.60 GHz, 8 GB RAM ve Windows 10 Pro özelliklerine sahiptir

##### 4. 1. Algoritmanın Analizi (Analysis of Algorithm)

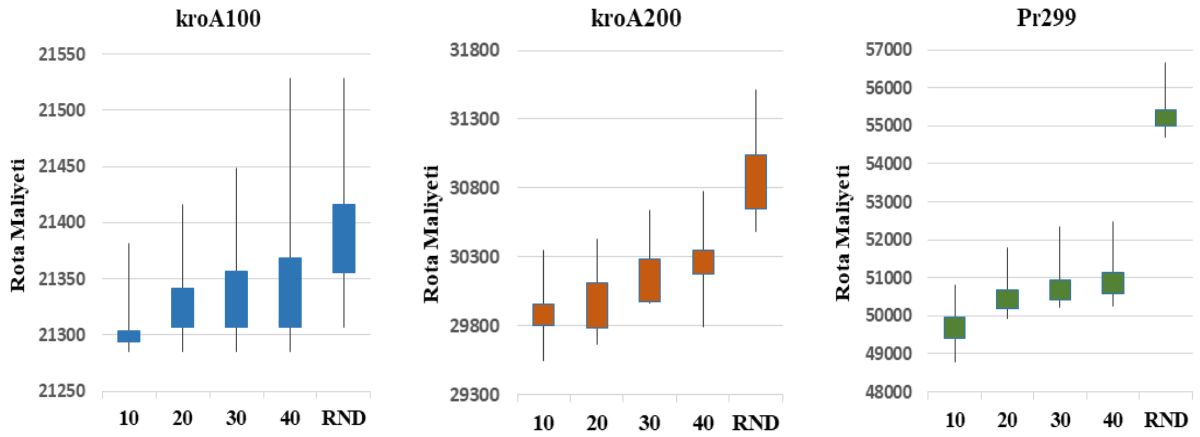
Algoritmayı analiz etmek için 100, 200 ve 299 şehirlik problemler için deneyler gerçekleştirilmiştir. Her deney için 10 farklı tekrar yapılmış ve sonuçlar kutu grafiklerinde gösterilmiştir. İlk analiz çalışması, çoklu ekleme operatörü için seçilecek şehir sayısı limitini belirlemek için yapılmıştır. Bu kapsamda şehir sayılarının üst limiti 4 ile 10 arasında değiştirilmiştir. Analiz sonuçları Şekil 10'da gösterilmiştir.



Şekil 10. Çoklu Ekleme Operatörü Analizi (Analysis of Variable Multiple Insertion)

Çoklu ekleme operatöründe, üst limit olarak 6, 7 ve 8 değerleri için en iyi sonuçların elde edildiği görülmüştür. Bunlar arasından en iyisi 7 olduğu için, operatörde şehir sayıları 2 ile 7 arasında rastgele değişecek şekilde ayarlanmıştır. Operatörün kullanılmadığı durum ise Şekil 10'da "0" ile

gösterilmiştir. İkinci analiz çalışması komşuluk değeri için gerçekleştirilmiştir. Bu kapsamda en yakın 10, 20, 30, 40 komşu için ve ayrıca yakın komşuluğun olmadığı yani rastgele aramanın yapıldığı deneyler gerçekleştirilmiştir. Analiz sonuçları Şekil 11'de gösterilmiştir.



Şekil 11. Komşuluk Analizi (Analysis of Neighborhood)

Şekil 11'den görüleceği üzere en iyi sonuçlara, yakın komşuluk değerlerinde ulaşılmaktadır. Harita üzerinde şehirler arası bağlantıları kendilerine yakın komşular üzerinden gerçekleştirmek rota maliyetlerini düşürmektedir. Algoritmada komşuluk limit değeri 10 olarak belirlenmiştir. Operatörlerde seçim yapılırken ikinci şehir, ilk belirlenen şehire en yakın 10 komşu şehir arasından rastgele belirlenmektedir. Grafiklerde RND ile komşuluk sınırlamasının olmadığı durum gösterilmiştir. Üçüncü analiz çalışması global aramanın etkinliği üzerine gerçekleştirilmiştir. Global arama için popülasyon sayısı 100'e çıkarılmıştır, bunlardan 20'si lokal arama bölgesi, 80'i global arama bölgesidir. Analiz sonuçları Tablo 2'de gösterilmiştir. Tablodan görüldüğü üzere global aramanın dahil olduğu durum ile olmadığı durum arasındaki değerler çok yakındır. Bu nedenle algoritmada global arama bölümü kullanılmamıştır.

Tablo 2. Global Arama Sonuçları (Results of Global Search)

GSP (Opt.)	Global Olmadan		Global Dahil	
	S_min	S_ort	S_min	S_ort
KroA100 (21282)	0.02	0.11	0.02	0.11
KroA200 (29368)	0.62	2.00	0.60	2.04
Pr299 (48191)	1.20	3.40	1.27	3.37

## 4. 2. Deneysel Çalışmalar (Experimental Studies)

Deneylerde kullanılan problemlerin isimleri, optimum rota uzunlukları ve testlerde elde edilen sonuçlar Tablo 3'te verilmiştir. Tabloda Ort. Süre ile en iyi değerlerin bulunma süreleri gösterilmiştir. Tablodan görüleceği üzere 52 ile 124 arasında şehire sahip problemler için bilinen en iyi değerlere veya %0.03'lere

varan sapma değerlerine ulaşılmıştır. Bu problemlerde 10 testin ortalamasında da %0.50'den küçük sapma değerleri elde edilmiştir. 200 şehirlik problemlerin çözümlerinde ise ortalama değerler %2.00-2.79 aralığında elde edilmiştir. 1000 iterasyonluk çalışma süreleri; 100 şehirlik problemler için 20 saniye, 200 şehirlik problemler için ise 80 saniye civarlarında olmuştur. (Çalışma süreleri Matlab'daki tic-toc fonksiyonları ile hesaplanmıştır.)

Algoritmayı kıyaslamak için, farklı yapıda AA ile gerçekleştirilmiş son güncel çalışmalar seçilmiştir. Karşılaştırma sonuçları Tablo 4'te verilmiştir. Bu çalışmada elde edilen sonuçlar İyileştirilmiş Arı

Algoritması (I-AA) altında verilmiştir. Karşılaştırılan çalışmaların ilkinde Ismail ve ark. (Ismail vd., 2020) çalışmalarında lokal arama için Takas, Ekleme ve Ters Çevirme operatörlerini kullanmışlardır. Komşuluk aramalarında tüm bölgeyi kullanmışlar ve yakın komşuluklara öncelik verilmemiştir. (Bu algoritmanın sonuçları Tablo 4.'te Klasik Arı Algoritması (K-AA) altında verilmiştir.) İkinci çalışmada ise Zeybek ve ark. (Zeybek vd., 2021), lokal arama bölümünde Bakış Noktası (Vantage Point) yöntemini kullanmışlardır. (Bu algoritmanın sonuçları Tablo 4.'te Bakış Noktası Arı Algoritması (BN-AA) altında verilmiştir.)


**Tablo 3.** GSP Verileri ve Test Sonuçları (TSP Data and Test Results)

GSP (Opt.)	Min.	Ort.	S_min	S_ort	Ort. Süre (s)
Berlin52 (7542)	7544	7544	0.03	0.03	7.98
Pr76 (108159)	108159	108277	0	0.11	17.17
KroA100 (21282)	21285	21304	0.02	0.11	27.36
KroB100 (22141)	22139	22251	0	0.50	24.86
KroC100 (20749)	20750	20814	0.01	0.31	22.41
KroD100 (21389)	21294	21449	0	0.28	25.40
KroE100 (22068)	22073	22141	0.02	0.33	25.22
Pr124 (59030)	59030	59095	0	0.11	26.88
Pr144 (58537)	58535	58731	0	0.33	41.11
Ch150 (6528)	6564	6660	0.56	2.03	36.18
KroA150 (26524)	26671	26954	0.55	1.62	44.87
KroB150 (26130)	26275	26425	0.56	1.13	39.18
KroA200 (29368)	29549	29955	0.62	2.00	79.98
KroB200 (29437)	30056	30258	2.10	2.79	80.73
Pr226 (80369)	80860	81397	0.61	1.28	86.11
Gil262 (2378)	2454	2471	3.22	3.91	95.43
Pr299 (48191)	48771	49828	1.20	3.40	110.83
Lin318 (42029)	43589	44090	3.71	4.90	111.05
Pcb442 (50778)	53715	55011	5.78	8.33	136.3

Tablo 4'te bu çalışmada geliştirilen algoritmanın, AA ile gerçekleştirilen diğer güncel çalışmalar (Zeybek vd., 2021; Ismail vd., 2020) ile kıyaslandığında çok daha iyi sonuçlar elde ettiği görülmektedir. 100 şehirlik problemlerde ortalama %0.25-0.50 aralığında sapmalarla optimum değerlere ulaşabilmektedir. Diğer algoritmaların ulaşabildiği en iyi değer KroE100 için %1.39 olabilmektedir. KroE100 için I-AA ile %0.33 sapma değeri ile çözüm üretilmiştir. Şehir sayısının artması ile beraber diğer algoritmalar ile olan sapma değerleri

farkları da artmaktadır. 200 şehirlik problemlerde I-AA ile %2.00-2.79 aralığında sapma değerleri elde edilirken, BN-AA ile %8.10-9.67 sapma değerlerine ulaşılabilmiştir. Diğer algoritmalarla göre en belirgin fark değişken çoklu ekleme operatörünün bulunmasıdır. Bu operatör sayesinde, bir adımda çok sayıda şehrin yeri değiştirilerek, daha az sürede daha iyi rotalar elde edilebilmektedir. Diğer önemli faktör ise yakın komşuluk seçimleridir. Testlerde elde edilen en iyi sonuçlardan bazıları Şekil 12'de gösterilmiştir.





Şekil 12. GSP Testleri Sonuçları (Results of TSP Tests)

## 5. Sonuçlar (Conclusions)

Bu çalışmada, lokal arama bölgesi güncellenmiş AA ile Gezgin Satıcı Problemlerinin çözümü üzerinde durulmuştur. Lokal arama bölümüne, genellikle kullanılan Takas, Ekleme ve Ters Çevirme operatörlerine ek olarak, değişken çoklu ekleme operatörü eklenmiştir ve arama işlemi yakın komşuluğu

kapsayacak şekilde daraltılmıştır. Bu iyileştirmelerin etkileri, AA ile yapılan diğer çalışmalar ile kıyaslandığında doğrudan görülmektedir. 100 şehirlik problemlerde 10 deneme içerisinde, en iyi çözümlere veya %0.02lik sapma değerleri ile çözümlere ulaşılabilmektedir. 150 şehirlik problemlerde %0.5 civarında, 200 şehirlik problemlerde %0.6-2.1 aralığında ve 318 şehirlik problemde ise %3.71

civarında sapma değerleri ile çözümlere ulaşılabilmiştir. Bu değerlerin diğer çalışmaların sonuçlarından çok daha iyi olduğu karşılaştırma tablosunda görülmektedir. Çözüm süreleri ise 100 şehirli problemler için 20 saniye, 200 şehirli problemler için 80 saniye civarında olmuştur. Benzer çalışmalarda sürelerle ilgili bilgi olmadığı için karşılaştırma yapılamamıştır. Bu

çalışmada elde edilen sonuçlar, diğer araştırmacıların çalışmalarına yönelik karşılaştırma fırsatı da vermektedir. Gelecek çalışmalar kapsamında özellikle 200 üzeri şehire sahip problemler için, lokal arama bölümüne farklı operatörler eklenerek iyileştirme çalışmaları yapılabilir.

**Tablo 4.** Algoritmaların Karşılaştırılması (Comparison of Algorithms)

GSP (Opt.)	I-AA		K-AA		BN-AA	
	S_min	S_ort	S_min	S_ort	S_min	S_ort
Berlin52 (7542)	0.03	<b>0.03</b>	-	-	<b>0</b>	0.63
KroA100 (21282)	<b>0.02</b>	<b>0.11</b>	0.88	2.02	0.42	1.70
KroB100 (22141)	<b>0</b>	<b>0.50</b>	2.15	3.33	0.26	1.74
KroC100 (20749)	<b>0.01</b>	<b>0.31</b>	1.06	2.85	0.09	1.81
KroD100 (21389)	<b>0</b>	<b>0.28</b>	0.01	2.37	0.86	2.84
KroE100 (22068)	<b>0.02</b>	<b>0.33</b>	0.9	1.94	0.23	1.39
KroA150 (26524)	<b>0.55</b>	<b>1.62</b>	3.78	5.08	3.06	4.70
KroB150 (26130)	<b>0.56</b>	<b>1.13</b>	3.69	5.08	2.73	3.79
KroA200 (29368)	<b>0.62</b>	<b>2.00</b>	7.43	9.69	7.16	8.10
KroB200 (29437)	<b>2.10</b>	<b>2.79</b>	8.79	10.47	8.05	9.67
Lin318 (42029)	<b>3.71</b>	<b>4.90</b>	-	-	7.02	7.57

## Kaynaklar (References)

- Acar, O., Kalyoncu, M., Hassan, A. (2018). The Bees' Algorithm for Design Optimization of a Gripper Mechanism, *Journal of Selcuk-Technic (ICENTE'18) Special Issue*, 69-86.
- Ahmed, Z. H. (2010). Genetic Algorithm for the Traveling Salesman Problem Using Sequential Constructive Crossover Operator. *International Journal of Biometrics ve Bioinformatics (IJBB)*, 3(6), 96-105. doi: 10.14569/IJACSA.2020.0110275.
- Al-Furhud, M. A., Ahmed, Z. H. (2020). Genetic Algorithms for the Multiple Travelling Salesman Problem. (IJACSA) *International Journal of Advanced Computer Science and Applications*, Vol. 11, No. 7, pp. 553-560.
- Alzaqebah, M., Jawarneh, S., Sarim, H. M., Abdullah, S. (2018). Bees Algorithm for Vehicle Routing Problems with Time Windows, *International Journal of Machine Learning and Computing*, Vol. 8, No. 3, 236-240.
- Baronti, L., Castellani, M., Pham, D. T. (2020). An analysis of the search mechanisms of the bees algorithm, *Swarm and Evolutionary Computation*, 59, 100746.
- Bayraktar, T., Ersöz, F., & Kubat, C. (2021). Effects of Memory and Genetic Operators on Artificial Bee Colony Algorithm for Three-Dimensional Bin Packing Problem (No. 5754). *EasyChair*.
- Braiwish, N. Y., Anayi, F. J., Fahmy, A. A., Eldukhri, E. E. (2014). Design optimisation of Permanent Magnet Synchronous Motor for electric vehicles traction using the Bees Algorithm, *49th International Universities Power Engineering Conference (UPEC)*, Cluj-Napoca, Romania.
- Daoqing, Z., Mingyan, J. (2020). Parallel Discrete Lion Swarm Optimization Algorithm for Solving Traveling Salesman Problem. *Journal of Systems Engineering and Electronics*, Vol. 31, No. 4, pp.751 – 760.
- Coban, R., Ercin, O. (2012). Multi-objective Bees Algorithm to Optimal Tuning of PID Controller, *Çukurova University Journal of the Faculty of Engineering and Architecture*, 27(2), 13-26.
- Dong, X., Lin, Q., Xu, M., Cai, Y. (2019). Artificial bee colony algorithm with generating neighbourhood solution for large scale coloured traveling salesman problem. *IET Intelligent Transport Systems*, Vol. 13 Iss. 10, pp. 1483-1491.
- Erdem, E., Aydın, T., & Erkayman, B. (2021). Flight scheduling incorporating bad weather conditions through big data analytics: A comparison of metaheuristics. *Expert Systems*, 38(8), e12752.
- Hussain, K., Salleh, M. N. M., Cheng, S., Shi, Y. (2019). Metaheuristic research: a comprehensive survey, *Artificial Intelligence Review*, volume 52, 2191-2233.
- Internet: The TSPLIB Symmetric Traveling Salesman Problem Instances, <http://elib.zib.de/pub/mp-testdata/tsp/tsplib/tsp/index.html>, 22.12.2020.
- Ismail, A. H., Hartono, N., Zeybek, S., Pham, D. T. (2020). Using the Bees Algorithm to solve combinatorial optimisation problems for TSPLIB, *IOP Conf. Series: Materials Science and Engineering* 847, 1-9.

- Karaboga, D., Gorkemli, B. (2019). Solving Traveling Salesman Problem by Using Combinatorial Artificial Bee Colony Algorithms, *International Journal on Artificial Intelligence Tools* Vol. 28, No. 1, 1950004, 1-28.
- Khan, S., Asjad, M., Ahmad, A., (2015). Review of Modern Optimization Techniques. *International Journal of Engineering and Technical Research* V4(04), 984-988.
- Koc E. (2010). Bees algorithm: theory, improvements and applications Thesis (Cardiff University, UK).
- Manea,D., Titan, E., Serban, R. R., Mihai, M. (2019). Statistical applications of optimization methods and mathematical programming. *Proceedings of the International Conference on Applied Statistics* 1(1), 312-328.
- Mavrovouniotis, M., Müller, F. M., Yang, S. (2017). Ant Colony Optimization With Local Search for Dynamic Traveling Salesman Problems. *IEEE Transactions on Cybernetics*, Vol. 47, No. 7, pp. 1743-1756.
- Mollabakhshi, N., Eshghi, M. (2013). Combinational circuit design using bees algorithm, *IEEE Conference Anthology*, China.
- Nafchi, A. M., Moradi, A., Ghanbarzadeh, A., Yaghoubi, S., Moradi, M. (2012). An Improved Bees Algorithm For Solving Optimization Mechanical Problems, *20th Annual International Conference on Mechanical Engineering- ISME*, School of Mechanical Eng., Shiraz University, Shiraz, Iran.
- Otri S. (2011). Improving the bees algorithm for complex optimisation problems Thesis (Cardiff University, UK).
- Pham, D.T., Ghanbarzadeh, A., Koc, E., Otri, S., Rahim, S., Zaidi, M. (2006). The Bees Algorithm-A Novel Tool for Complex Optimisation Problems, *Intelligent production machines and systems*, 454-459.
- Rao, S., S. (2019). *Engineering Optimization Theory and Practice*. John Wiley & Sons, New Jersey, A.B.D.
- Xie, J., Carrillo, L. R. G., Jin, L. (2019). An Integrated Traveling Salesman and Coverage Path Planning Problem for Unmanned Aircraft Systems. *IEEE Control Systems Letters*, Vol. 3, No. 1, pp. 67-72.
- Wang, L., Cai, R., Lin, M., Zhong, Y. (2019). Enhanced List-Based Simulated Annealing Algorithm for Large-Scale Traveling Salesman Problem. *IEEE Access* Year: 2019 | Volume: 7, pp. 144366-144380.
- Yuce, B., Mastrocinque, E., Lambiase, A., Packianather, M. S., Pham, D. T. (2014). A multi-objective supply chain optimisation using enhanced Bees Algorithm with adaptive neighbourhood search and site abandonment strategy, *Swarm and Evolutionary Computation* Volume 18, October, 71-82.
- Zarchi, M., Attaran, B. (2017). Performance improvement of an active vibration absorber subsystem for an aircraft model using a bees algorithm based on multi-objective intelligent optimization, *Engineering Optimization* Volume 49, Issue 11, 1905-1921.
- Zeybek S., A. H. Ismail, N. Hartono, M. Caterino, K. Jiang. (2021). An Improved Vantage Point Bees Algorithm to Solve Combinatorial Optimization Problems from TSPLIB, *Macromolecular Symposia*, 396, 2000299, pp. 1-4.



# A Real-Time Location System Design for Production Facilities Working under COVID-19 Pandemic Precautions

Sena Kır<sup>1\*</sup> 

<sup>1</sup> Sakarya University, Department of Industrial Engineering, Sakarya, Turkey  
senas@sakarya.edu.tr

## Abstract

By reason of the COVID-19 pandemic, essential digital transformations are taking place in many areas of business life. Although the most important one of these transformations is due to the widespread use of the remote working model, the production sector does not have the opportunity to switch to such a model completely. Therefore, it is inevitable to maintain social distance to prevent the spread of COVID-19 while working in production facilities. In this study, a real-time location system (RTLS) model is proposed to keep track of social distance in production facilities and to ensure occupational health safety (OHS) at the same time. Since the social distance rule is essential for every production facility, the most important feature of the proposed system is that it can easily be integrated into the standard personnel tracking system in almost every enterprise. Besides, the proposed RTLS is designed as an efficient system based on ultra-wideband and radio-frequency identification, which can operate as a closed-loop monitoring system within itself. An adequately installed RTLS can monitor the position of employees in real-time and provides to intervene in the situation instantly when necessary. In case of a violation of social distance or a situation against OHS, it can be prevented instantly by the proposed system. It is also a useful model in the management of emergencies.

**Keywords:** COVID-19, digital transformation, occupational health and safety, radio-frequency identification, real-time location system, ultra-wideband.

## COVID-19 Pandemi Önlemleri Altında Çalışan Üretim Tesisleri için Gerçek Zamanlı Konumlandırma Sistemi Tasarımı

### Öz

COVID-19 pandemisi nedeniyle iş hayatının birçok alanında önemli dijital dönüşümler yaşanmaktadır. Bu dönüşümlerden en önemlisi uzaktan çalışma modelinin yaygınlaşmasından kaynaklı olarak üretim sektörü tam anlamıyla böyle bir modele geçme imkânına sahip değildir. Bu nedenle üretim tesislerinde çalışırken COVID-19'un yayılmasını önlemek için sosyal mesafeyi korumak kaçınılmazdır. Bu çalışmada, üretim tesislerinde sosyal mesafenin takibi ve aynı zamanda iş sağlığı güvenliğinin (İSG) sağlanması için gerçek zamanlı konumlandırma sistemi (RTLS) modeli önerilmiştir. Sosyal mesafe kuralı her üretim tesisi için gerekli olduğundan önerilen sistemin en önemli özelliği hemen her işletmede standart personel takip sistemine kolaylıkla entegre edilebilmesidir. Ayrıca önerilen RTLS, kendi içinde kapalı çevrim izleme sistemi olarak çalışabilen, ultra geniş bant ve radyo frekansı tanımlamaya dayalı verimli bir sistem olarak tasarlanmıştır. Yeterli bir şekilde kurulmuş bir RTLS, çalışanların pozisyonunu gerçek zamanlı olarak izleyebilir ve gerektiğinde duruma anında müdahale edilmesini sağlar. Sosyal mesafenin ihlali veya İSG'ye aykırı bir durum olması halinde önerilen sistem ile anlık olarak engellenebilmektedir. Ayrıca acil durumların yönetimi içinde faydalı bir modeldir.

**Anahtar Kelimeler:** COVID-19, dijital dönüşüm, iş sağlığı ve güvenliği, gerçek zamanlı konumlandırma sistemi, radyo frekansı ile tanımlama, ultra geniş bant.

## 1. Introduction

The COVID-19 pandemic has affected the whole world since December 2019, threatens human health and

life not only with death rates but also its adverse effects on working life. Kudyba (2020) emphasizes that the COVID-19 pandemic has brought a Y2K type disruption to many enterprises and that enterprises are accelerating

\* Corresponding Author  
E-mail: senas@sakarya.edu.tr

Received : 27 Oct 2021  
Revision : 30 Sep 2022  
Accepted : 13 Jan 2023

their digital transformation processes as a remedy. Considering that the epidemic has caused digital technologies to accelerate (Soto-Acosta, 2020), it would not be wrong to say that many different industry areas will be affected by the digital transformation process, and this effect will continue after the epidemic.

Enterprises have entered a compulsory digital transformation process while fulfilling consumer demands due to providing less interactive working environments and keeping the productivity of remote workers high (Dwivedi et al., 2020). In this context, Papadopoulos et al. (2020) discussed that SMEs especially live in the digitalization process to secure enterprises continuity during the pandemic process. Similarly, Bartsch et al. (2020) researched remote working service sector employees' work performance in the virtual environment in this digitalization process. Papagiannidis et al. (2020) provide important insights into the potential of critical lessons to be learned from this first significant pandemic in the digital age and how enterprises can be better prepared for future pandemics collaboration between diversified stakeholders to minimize enterprise's risks. Within the scope of social distancing precautions, enterprises should establish the right balance of traditional and remote models while updating their business models in terms of working remotely, increasing worldwide (Nagel, 2020).

The digital transformation processes considered within the scope of the COVID-19 pandemic in the literature cover business activities outside the production area. This study aims to contribute to the literature by addressing the digital transformation processes in production areas during the pandemic. The novelty of this study is that it is the first system designed to ensure that people working close to each other in production facilities maintain the social distance, to detect situations where social distance is violated, and to identify other employees who contacted an infected employee. Because researches show that many production activities have come to a halt due to the spread of COVID-19 (Araya, 2021; Olanrewaju et al, 2021). The motivation of this study is that enterprises that have to produce in a closed area within the scope of COVID-19 precautions have to maintain the social distance during their production activities. The researches and precautions are taken to prevent the spread of COVID-19 at workplaces in various areas around the business world draw attention (Kang, 2020; Kim 2020; Arrahmah and Ramadhan, 2021; Rajesh et al, 2021; Kulkarni and Alfatmi, 2022). Rácz-Szabó et al. (2020) stated in their studies that real-time location system (RTLS) based systems could be useful within the scope of the COVID-19 pandemic. Similarly to this study, Ho et al. (2020) investigated the interaction between the patients hospitalized in the COVID-19 service and the medical staff by integrating an RTLS into their electronic medical record system.

As a result of the researches, it has been determined that a mechanism is needed to ensure that the staff

complies with the social distance rule while working. Based on this, a cost-efficient system has been designed to maintain social distance and be useful in the field of occupational health and safety (OHS) and can be implemented in the personnel tracking system of almost every enterprise. The proposed system is based on a kind of RTLS and enables collecting and managing all information regarding the production area's activities. Various studies in the literature before the COVID-19 pandemic proposed kinds of RTLSs for OHS in manufacturing, especially in the construction industry. For example, Dong et al. (2018) proposed an RTLS to determine and track the misused or non-used personal protective equipment. Li et al. (2016) and Soltanmohammadlou et al. (2019) conducted extensive research on RTLSs developed specifically for OHS in the construction industry. However, none of these similar studies include the OHS precautions that come into our lives with COVID-19. Therefore, the RTLS proposed in this study will contribute to the literature, especially in the manufacturing industry.

The remaining sections of this paper are organized as follows. Section 2 presents the background of this study in terms of working under COVID-19 precautions in a production facility. Section 3 explains RTLS and other technologies used with RTLSs and details the proposed RTLS. Section 4 describes the results obtained when the system works correctly and effectively. Finally, the usefulness, advantages, and limitations of the system are discussed in section 5.

## 2. Background

The enterprises update their working policies in production facilities parallel to COVID-19 pandemic precautions. Policies for presence in public areas, personnel vehicle usage rules, number of employees per shift, etc., are rearranged according to the determined maintaining social distance precaution. In particular, precautions are taken to reduce the number of people per unit area to ensure social distance. The number of people that can be taken to indoor spaces simultaneously is determined according to the available spaces. The number of personnel vehicles and the number of people in the vehicles is arranged, maintaining social distance. The number of personnel per shift is regulated according to maintaining social distance, and if necessary, increases can be made in the number of shifts. Physical arrangements can be made in the dining hall and common areas that will not allow people to sit side-by-side and ensure that they sit at a distance.

Especially for individuals who live in a society with strong social relations, despite all these precautions, it can be challenging to prevent people from coming together and maintain social distance. Besides, in the case of COVID-19 incidence in the production facilities, the other workmates with whom the infected employee are in contact cannot be determined precisely. There is a risk that the infected employee may not remember



exactly who they were in connection with or that they would not share their names because they do not want their workmates to be quarantined. In other words, even 100% contact tracing (filiation) is not enough to solve this problem. In case of an incident, enterprises can quarantine all employees who may contact the infected employee, interrupt production at the production facility where the incident occurs, disinfect the facility, and restart production. This situation can cause severe production losses.

Considering the pre-pandemic literature, there are different system recommendations based on RTLS that provide automatic personnel tracking in the field of OHS (Longkang et al., 2011; Barro-Torres et al., 2012; Lee et al., 2012; Ulku, 2017). However, these systems need to be updated by the COVID-19 pandemic rules. It is difficult to predict whether this situation is possible and its cost. The solution that enterprises need a system that they can integrate into existing personnel tracking systems at a low cost. Commonly, there is a card tracking system that controls the entry and exit of the enterprises' personnel. The RTLS-based system proposed in this study is a system that can be integrated into a simple personnel tracking system and has a low additional investment cost.

The solution sought is to block the contact instantly, without leaving it to the preference of individuals. As a result of research on this, it is suggested to implement an RTLS that can be integrated into almost every enterprise's personnel tracking system.

### 3. Materials and Methods

An RTLS has been proposed to ensure OHS in production facilities, especially to maintain social distance while working within the scope of COVID-19 precautions. In the literature, RTLSs appear with different technologies. In this study, an ultra-wideband (UWB) and radio-frequency identification (RFID)-based RTLS is proposed. The characteristics, components, system architecture, and operating mechanism of the proposed system are detailed in this section.

#### 3.1. RTLSs and Other Technologies Used Together

RTLS is a wireless technology solution that can be applied in various fields and is widely used worldwide to increase business efficiency and quality. Many technologies are used, such as wireless fidelity (Wi-Fi) (Urrea and Ariza, 2017), RFID (Kirch et al., 2017), infrared (Jeong et al., 2017), UWB (Ruppert and Abonyi, 2018), ZigBee (Huiracán et al., 2010), BLE (bluetooth low energy) (Astafiev et al., 2019) to determine the real-time location. Besides, studies using these technologies together are also available in the literature. For example, UWB RFID-based (Huang et al., 2017), RFID Wi-Fi-based (Ding et al., 2008),

ZigBee and RFID-based (Barro-Torres, 2012), etc., systems were presented to literature before.

In the industry, RFID technology is frequently used for tracking purposes. The RTLS technologies classification evaluated for the problem's solution in this study is given in Figure 1 (Rácz-Szabó et al., 2020; Simões et al., 2020). Among these technologies, a UWB RFID-based system has been designed in this paper because it is cost-effective, efficient, and easier to integrate into the system.




Figure 1. Classification of RTLSs adopted by Rácz-Szabó et al., 2020; Simões et al., 2020

RFID and RTLS are different from each other. RFID is to identify an object or person tagged over a wireless communication network. It can be used for defining, managing, and positioning a tagged object (Chon et al., 2004). RTLS can detect and track the real-time location of an object or person carrying an RFID tag over wireless networks. Real-time systems can report an object's absolute position based on a small number of variables such as expected current and/or following location, previous locations, and available technology. In many cases, using RFID, RTLS and barcoding together can be an ideal solution (Dash, 2009).

RFID is a wireless communication technology used to identify objects using radio waves. RFID systems consist of an object carrying a tag equipped with a microprocessor, an antenna, a reader, a host/server, and software. Each tag has its unique number. For any object to be identified, the reader sends radio frequencies, and then the recognition process takes place according to the particular unique number coming from the tag. The information and energy transfer between tag and reader is achieved without contact. This communication can be bidirectional. Tags are separated as active or passive depending on whether the power source is connected or not. In this paper, active UWB frequency tags were preferred for the proposed RTLS. These tags operate in the 3.1-10.6 GHz frequency range. Rather than sending a very strong signal from a particular frequency, a low power signal can be sent over a wide band with UWB. Besides, the transmission of the signal is healthier. It can be read up to 200 meters. In precise readings, it is not

affected by metal, liquid environments, and environmental conditions. Thus, choosing UWB frequency RFID tags will be the most appropriate option, especially for personnel cards.

The RFID systems, which are widely used in RTLS today, can communicate wirelessly between readers and carriers without directly seeing each other, making it easier to use the system in the building. In this respect, RTLSs are defined as location tracking systems that determine the exact location of objects or personnel within the facility using wireless technologies. Enterprises using RTLS suffer from the lack of awareness of their employees, despite restructuring all business processes and simplifying high-level integrations in server applications. Due to the easy integration with server applications, uniform barcode and passive RFID tags still adhere.

In terms of RTLS market technology-based segregation, wireless network-based RTLSs bring undisputed advantages compared to proprietary technologies such as UWB and ZigBee due to the existing wireless network Wi-Fi infrastructure. Wireless networking and active RFID-based solutions are promising for the market. Also, emerging technologies such as UWB and ZigBee, due to the high accuracy and precision they offer, are expected to surpass wireless networks and other traditional technologies, creating very fast-growing and developing markets.

### 3.2. The Proposed UWB and RFID-Based RTLS

In this section, what kind of real-time monitoring system the industry needs to ensure social distance and OHS in production areas is discussed. The real-time tracking system components, which are proposed considering the industry's needs, and its working mechanism and architecture, are presented.

#### 3.2.1. The Proposed RTLS Components

The elements of the proposed RTLS are personnel ID cards, local and global remote readers in the production facility and social area, RFID-enabled device, database, remote and closed-loop monitoring systems. The specifications of the system components are given following.

**Personnel ID Cards:** Each staff holds their Personnel ID Cards located on each staff creates an area around him/her with UWB-based RFID technology. The active UWB frequency tags were preferred due to the advantages detailed in section 3.1. Each staff member creates their social distance with their Personnel ID Card

by the created area. The cards also have a vibration feature to alert when the social distance is violated and when a dangerous situation occurs in terms of occupational health and safety. When a social distance violation and a dangerous situation occurs, the date, time, location, and ID information are stored on the card.

**Local Remote Reader (LRR):** The information on the personnel ID cards entering the influence area is wirelessly transferred to the software through these readers. For the system to work effectively and efficiently, the LRRs must be placed in the production area in the optimum number and manner.

**Global Remote Reader:** The global remote reader is the manager of the LRRs, who classifies the information received from the local zone readers and transmits them to the closed-loop monitoring system and software.

**UWB RFID Enabled Device:** These devices work as personnel ID cards but are on forklifts.

**Database:** The system can use the existing database; it does not need a private or external database.

**Remote Monitoring Systems:** Since all data are kept in the database, they can be monitored remotely if desired. Although new technology remote monitoring systems performance is adequate, closed circuit monitoring of the production area is also recommended.

**Closed-Loop Monitoring System:** Since the data coming from the production area must be followed instantly, it is essential for detecting emergencies and instant intervention.

The data flow between all system components occurs at five levels in total. Figure 2 shows these levels.

#### 3.2.2. System Architecture and Working Mechanism

Generally, enterprises have existing personnel tracking systems. The proposed RTLS will require several devices that can be easily implemented into these personnel tracking systems. By these devices, UWB RFID-enabled personnel cards warn employees by vibration when they come to a distance where they can perceive each other (when the social distance is violated). Simultaneously, the information about this closeness (ID information of the other card, time, and locations) is recorded in the cards. When the employee enters the influence area of LRR, this information is transmitted through the LRR to the global remote reader and then to the closed-loop monitoring environment. If necessary, instant intervention to the event is possible from the closed-loop monitoring environment. The data flow of this sub-system is shown in Figure 3.

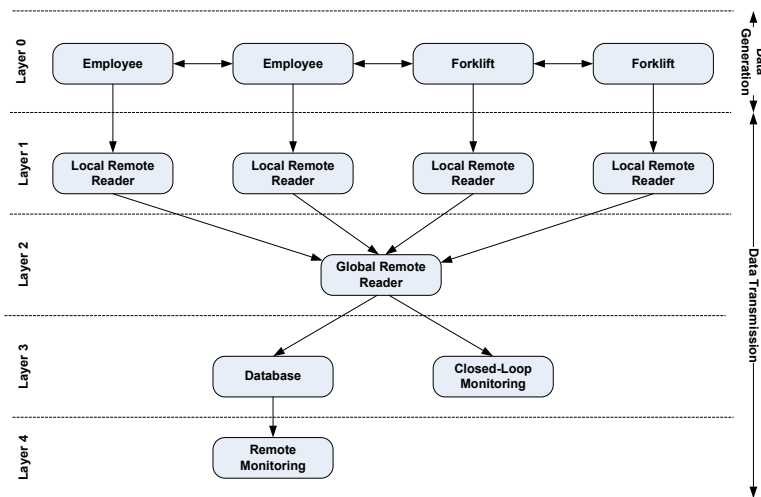


Figure 2. Data flow levels in the system

In another situation, the same system is activated in case a forklift has a UWB RFID-enabled device, or an employee comes dangerously close to another identical forklift. The device on the forklift sends the information of dangerous closeness to the nearest LRR. The LRR sends this information to the global remote reader, from where it will be transferred to the closed-loop monitoring environment. From the closed-loop

monitoring environment, the forklift can be automatically stopped remotely. The data flow of this sub-system is shown in Figure 4. Figure 4a shows the data flow from the forklift, and Figure 4b shows the data flow from the personnel ID card.


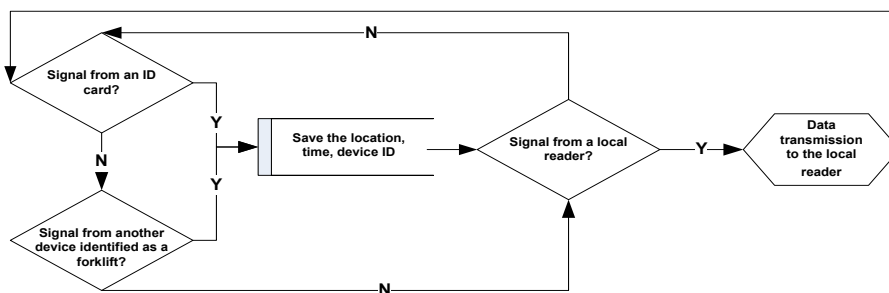



Figure 3. Data flow of the maintaining social distance



4a.



4b.

Figure 4. Data flow of the employee and forklift accident prevention system

The most important thing here is that the forklift is located under the influence area of an LRR. Otherwise, the system cannot send instant alerts. Therefore, it is essential for the system efficiency to accurately determine the number and locations of LRRs in the production and social areas.

In case of an occupational accident, if the employee stays still for a while, the data is transferred to the closed-loop monitoring environment with the same system as a warning. The system facilitates the follow-up of the employees at the emergency assembly point in a disaster or extraordinary situation. Namely, the presence of the employees at the meeting point can be monitored instantly by the ID cards, and the absent employee can be detected, and instant intervention can be provided. The system architecture of the proposed RTLS is as shown in Figure 5.

The RTLS architecture in Figure 5, provides social distance control in the COVID-19 pandemic conditions. Additionally, apart from pandemic conditions, prevention of employee and forklift accidents and remote organization processes in emergencies are

entirely digitalized. In this way, all data obtained from the system can be stored, if desired, the enterprise can be processed for use in different processes and can be monitored instantly from outside the production area.

### 3.2.3. Determining the Number of Local Remote Reader

The number and location of LRR are essential for the efficiency of the system. If situations that require instant intervention occur outside the influence area of the LRR, the emergency action will not be able to take place, as instant information will not reach the relevant location. However, the installation cost of the system, which LRR placement to cover the whole area will be high. Huang et al. (2017) presented an LRR placement model in a way that the influence areas overlap and cover the whole area. In this study, two different LRR placement policies have been proposed. One of them is to place LRRs in a way that leaves no blind zone, likewise Huang et al. (2017). The other policy is to place the LRRs so that their influence areas do not overlap.

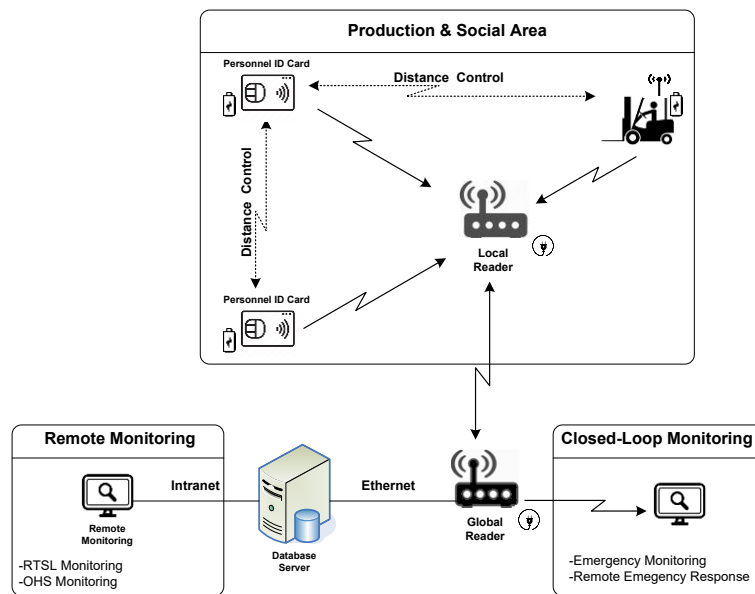


Figure 5. The system architecture of the proposed RTLS

Policy # 1: Starting from one corner of the area where the system will be installed, they are placed in such a way that no area remains outside the influence area of the LRRs. The influence areas of the LRRs intersect; there are no gaps or blind zone in between. Figure 6 shows the image of this placement policy.

Policy # 2: Starting from the one corner of the area where the system will be installed, the influence areas of LRRs are placed tangentially around each other. The influence areas of the LRRs do not intersect; there are gaps or blind zone in between. There is a little blind zone as possible in areas close to walls, too. Figure 7 shows the image of this placement policy.

According to both policies, the approximate number of LRRs to be used in the placement are calculated as in Table 1, which is under the conditions  $xy > \pi r^2$  and  $x \geq y$  must be met. Also, depending on the number of required LRR, the approximate blind zone that can occur in such a situation can be calculated as in Table 1 with  $\epsilon$  denotes a small number (margin of error) considering the blind zone formula by Bayrakdar (2019).

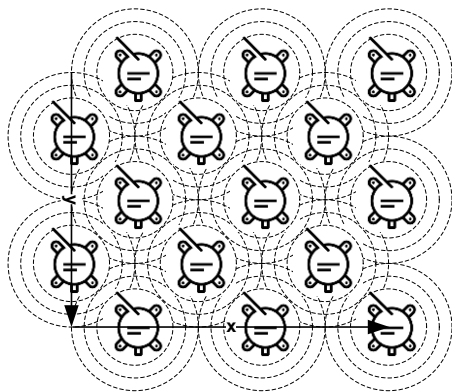


Figure 6. Placement of LRRs according to policy #1

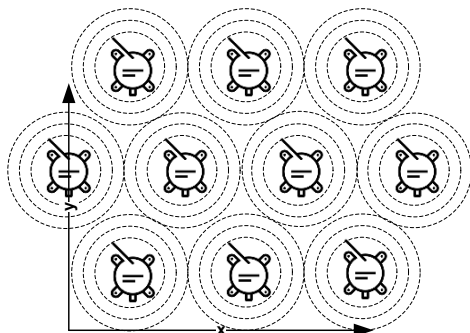


Figure 7. Placement of LRRs according to policy #2

Table 1. Determining the approximate number of required LRR and blind zone according different policies

Policy #	# of Required LRR	Blind Zone
1	$\left\lceil \frac{x}{2r} \right\rceil \left( \left\lceil \frac{y}{2r} \right\rceil + 1 \right)$	No blind zone
2	$\left\lceil \frac{x}{2r} \right\rceil \left\lceil \frac{y}{2r} \right\rceil$	$\left\lceil \frac{x}{2r} \right\rceil \left\lceil \frac{y}{2r} \right\rceil \left( \frac{r^2(2\sqrt{3}-\pi)}{2} \right) - \epsilon$

Considering the current layout of the production facility, only one or both of these policies can be used in the same area. Policy # 1 is suggested in an area where mobility is high, and policy # 2 is suggested in an area where mobility is low.

#### 4. Results

The proposed RTLS warns the personnel who violate the social distance precaution by the vibrating personnel ID card they carry. Personnel who get dangerously close to a forklift will also be warned in the same way, by the closed-loop monitoring system, the forklift will be able to stop remotely when necessary. Likewise, when two forklifts get dangerously close to each other, they can be stopped remotely. In emergencies, staff who are absent at the emergency meeting point can be identified and found easily, taking into account the information of the last location. For the proposed system to provide the mentioned service most accurately with the lowest installation cost, the number

of LRRs and their locations should be determined appropriately.

#### 4.1. Implications for Occupational Health Practice

To set up the proposed RTLS in a representative production facility in Figure 8, the equations given in Table 1 calculating the LRR number are considered.

According to a representative production facility layout given in Figure 8, the approximate LRR requirements and the approximate blind zone that may occur accordingly were calculated as in Table 2 considering Equations 1-7 where the influence area ( $2r$ ) of an LRR is 6000cm. Since thick walls affect the signal strength, it is recommended to consider each area surrounded by thick walls separately.

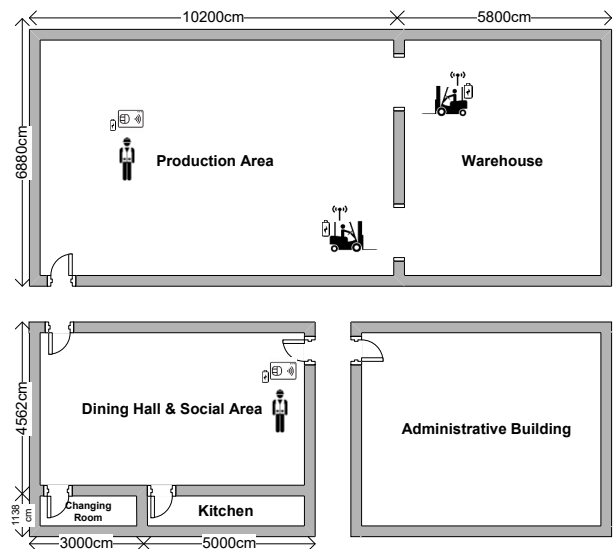


Figure 8. A representative production facility layout

The values given in Table 2 have been calculated to give an idea before the installation of the proposed RTLS, and it is possible to obtain different values in different LRR placement policies. For example, policy #1 can be chosen for the production area because of the high mobility and 6 LRRs are placed. Conversely, policy #2 can be chosen for the warehouse because of the low mobility and 2 LRRs are placed. Namely, if the blind zone is technically risky, policy #1 should be preferred. In large areas, both policies can be preferred. Large enclosed areas can be handled by dividing them into areas with high and low mobility. Policy #1 may be preferred where the area has high mobility, and policy #2 where it has less mobility. In this way the number of LRRs can be reduced intuitively, but it should be noted that policy #2 increases the risk.

Also, system installation in the administrative building is not recommended because the staff working here can work at home office during the COVID-19 pandemic.



**Table 2.** Approximate LRR requirement and blind areas that may occur according to a representative production facility layout

Location	x (cm)	y (cm)	Policy #1		Policy #2	
			# of LRR	Blind Zone (cm <sup>2</sup> )	# of LRR	Blind Zone (cm <sup>2</sup> )
Production Area	10200	6880	6	-	4	5,790,648.42
Warehouse	6880	5800	4	-	2	2,888,067.76
Dining Hall & Social Area	8000	4562	4	-	2	2,888,067.76
Changing Room	3000	1138	2	-	1	1,436,777.43
Kitchen	5000	1138	2	-	1	1,436,777.43

## 5. Conclusion

After determining that the Sars-CoV-2 virus was spread through droplets, profound changes had to be made in the social rules of all life. It has become necessary to wear a mask without exception in social situations, and the whole world has met a new concept called social distance. Social distance means a physical distance between human relations in all areas of life, although its size varies from country to country. People who moved away from each other physically with the increase of physical distance had to connect with digital technologies. This situation has led to the acceleration of digital transformation in many life areas, especially in business and education.

Remote working has become widespread in industries, and enterprises face advantages and disadvantages. The spread of the virus has been tried to be kept under control with new rules in production areas that cannot be worked remotely. The most important of these rules is maintaining social distance. New regulations were made in the physical conditions of production areas to maintain social distance, the staff was trained, new working procedures were developed, and the staff was monitored continuously according to the symptoms of people infected with the virus. Despite all the precautions taken at manufacturing facilities, it has not been possible to prevent the spread of COVID-19. Consequently, some enterprises had to stop production for days, and in some countries even had to pay fines to the state. Because it is challenging to predict whether people in production areas comply with these rules without an automated system.

In this paper, an RTLS is proposed to make all the precautions taken to prevent the spread of COVID-19 in production facilities more meaningful. Maintaining social distance should not be left to the initiative of individuals, it should be tracked automatically. The novelty of this study is that it performs this tracking in real-time and works by integrating it with the personnel ID card. Besides, with the proposed RTLS, it is possible to detect other dangerous approaches and prevent some work accidents too.

The limitation of the proposed system is that the RTLS is designed to work in closed spaces. Integrating different technologies into this system makes it possible to ensure both social distance and OHS in open areas.

## References

- Araya, F., 2021. Modeling the spread of COVID-19 on construction workers: An agent-based approach. *Safety Science*, 133, 105022.
- Arrahmah, A. I., & Ramadhan, S. 2021. Development of Wearable System to Help Preventing the Spread of Covid-19 in Public Indoor Area. *International Journal of Advanced Computer Science and Applications*, 12(11).
- Astafiev, A., Zhiznyakov, A. & Privezentsev, D., 2019. Development of Indoor Positioning Algorithm Based on Bluetooth Low Energy beacons for Building RTLS-Systems. In Proceedings of the International Russian Automation Conference (RusAutoCon), Sochi, Russia.
- Barro-Torres, S., Fernández-Caramés, T. M., Pérez-Iglesias, H. J. & Escudero, C. J., 2012. Real-time personal protective equipment monitoring system. *Computer Communications*, 36, 42–50.
- Bartsch, S., Weber, E., Büttgen, M. & Huber, A., 2020. Leadership matters in crisis-induced digital transformation: how to lead service employees effectively during the COVID-19 pandemic. *Journal of Service Management*, 32(1), 71-85.
- Bayrakdar, M. E., 2019. Cost Efficient Sensor Node Placement Approach for Using Minimum Number of Node in Wireless Sensor Networks. *Bilecik Şeyh Edebali University Journal of Science*, 6, 59-73. (In Turkish)
- Chon, H. D., Jun, S., Jung, H. & An, S. W., 2004. Using RFID for accurate positioning. *Journal of Global Positioning Systems*, 3(1-2), 32-39.
- Dash, A., 2009. Lost+ found: making the right choice in equipment location systems. *Health Facilities Management*, 22(11), 19-21.
- Ding, B., Chen, L., Chen, D. & Yuan, H., 2008. Application of RTLS in warehouse management based on RFID and Wi-Fi. 4th International Conference on Wireless Communications, Networking and Mobile Computing, Dalian, China.
- Dong, S., Li, H. & Yin, Q., 2018. Building information modeling in combination with real time location systems and sensors for safety performance enhancement. *Safety Science*, 102, 226-237.
- Dwivedi, Y. K., Hughes, D. L., Coombs, C., Constantiou, I., Duan, Y., Edwards, J.S., Gupta, B., Lal, B., Misra, S., Prashant, P., Ramam, R., Rana, N.P., Sharma, S.K. & Upadhyay, N., 2020. Impact of COVID-19 pandemic on information management research and practice: Transforming education, work and life. *International Journal Information Management*, 55, 102211.
- Ho, H. J., Zhang, Z. X., Huang, Z., Aung, A.H., Lim, W.Y. & Chow, A., 2020. Use of a real-time locating system for contact tracing of health care workers during the COVID-19 pandemic at an infectious disease center in Singapore: validation study. *Journal of Medical Internet Research*, 22, e19437.

- Huang, S., Guo, Y., Zha, S., Wang, F. & Fang, W., 2017. A real-time location system based on RFID and UWB for digital production workshop. *Procedia Cirp*, 63, 132-137.
- Huircán, J. I., Muñoz, C., Young, H., Von Dossow, L., Bustos, J., Vivallo, G. & Toneatti, M., 2010. ZigBee-based wireless sensor network localization for cattle monitoring in grazing fields. *Computers and Electronics in Agriculture*, 74(2), 258-264.
- Jeong, I. C., Bychkov, D., Hiser, S., Kreif, J. D., Klein, L. M., Hoyer, E. H. & Searson, P. C., 2017. Using a real-time location system for assessment of patient ambulation in a hospital setting. *Archives of Physical Medicine and Rehabilitation*, 98(7), 1366-1373.
- Kang, S. K., 2020. COVID-19 and Middle East respiratory syndrome infections in health-care workers in Korea. *Safety and Health at Work*, 11(2), 125-126.
- Kim, E. A., 2020. Social distancing and public health guidelines at workplaces in Korea: responses to coronavirus disease-19. *Safety and Health at Work*, 11(3), 275-283.
- Kirch, M., Poenicke, O. & Richter, K., 2017. RFID in logistics and production—applications, research and visions for smart logistics zones. *Procedia Eng*, 178, 526-533.
- Kudyba, S., 2020. COVID-19 and the acceleration of digital transformation and the future of work. *Information Systems Management*, 37(4), 284-287.
- Kulkarni, M. D., & Alfatmi, K., 2022. Wi-Fi-Based Proximity Social Distancing Alert to Fight Against COVID-19. In *Pandemic Detection and Analysis Through Smart Computing Technologies*, pp. 225-253, Apple Academic Press.
- Lee, H. S., Lee, K. P., Park, M., Baek, Y. & Lee, S., 2012. RFID-based real-time locating system for construction safety management. *Journal of Computing in Civil Engineering*, 26, 366–377.
- Li, H., Chan, G., Wong, J. K. W. & Skitmore, M., 2016. Real-time locating systems applications in construction. *Automation in Construction*, 63, 37-47.
- Longkang, W., Baisheng, N., Ruming, Z., Shengrui, Z. & Hailong, L., 2011. ZigBee-based positioning system for coal miners. *Procedia Engineering*, 26, 2406–2414.
- Nagel, L., 2020. The influence of the COVID-19 pandemic on the digital transformation of work. *International Journal of Sociology and Social Policy*, 40(9/10), 861-875.
- Olanrewaju, A., AbdulAziz, A., Preece, C. N., & Shobowale, K., 2021. Evaluation of measures to prevent the spread of COVID-19 on the construction sites. *Cleaner engineering and technology*, 5, 100277.
- Papadopoulos, T., Baltas, K. N. & Balta, M. E., 2020. The use of digital technologies by small and medium enterprises during COVID-19: implications for theory and practice. *International Journal Information Management*, 55,102192.
- Papagiannidis, S., Harris, J., Morton, D., 2020. WHO led the digital transformation of your company? a reflection of IT related challenges during the pandemic. *International Journal Information Management*, 55, 102166.
- Rácz-Szabó, A., Ruppert, T., Bántay, L., Löcklin, A., Jakab, L. & Abonyi, J., 2020. Real-time locating system in production management. *Sensor*, 20(23), 6766.
- Rajesh, S., Paul, V., Basheer, A. A., & Lukose, J., 2021. Real-Time Proximity Sensing Module for Social Distancing and Disease Spread Tracking. In *Smart Computing Techniques and Applications*, pp. 415-424.
- Ruppert, T. & Abonyi, J., 2018. Software sensor for activity-time monitoring and fault detection in production lines. *Sensors*, 18(7), 2346.
- Simões, W. C., Machado, G. S., Sales, A., de Lucena, M.M., Jazdi, N. & de Lucena, V. F., 2020. A Review of Technologies and Techniques for Indoor Navigation Systems for the Visually Impaired. *Sensors*, 20(14), 3935.
- Soltanmohammadlou, N., Sadeghi, S., Hon, C. K. & Mokhtarpour-Khanghah, F., 2019. Real-time locating systems and safety in construction sites: A literature review. *Safety Science*, 117, 229-242.
- Soto-Acosta, P., 2020. COVID-19 pandemic: shifting digital transformation to a high-speed gear. *Information Systems Management*, 37(4), 260-266.
- Ulku, A., 2017. The next generation in personnel/people tracking: Active RFID technology has allowed for enhanced security and safety. *IEEE Consumer Electronics Magazine*, 6, 122–124.
- Urrea, W. A. & Ariza, H. M., 2017. Real time location system (RTLS) focused on the optimization of efficiency for hospital center assistance. *International Journal of Applied Engineering Research*, 12(15), 5248-5253.



# Makine Öğrenmesi Yöntemleri Kullanılarak Öğrencilerin Kazanım Bilgileri ile Sınavlardaki Başarı Durumunun Tahmini

Muhammed Fatih Adak<sup>1\*</sup>, Ömer Duralioğlu<sup>2</sup>

<sup>1</sup> Sakarya Üniversitesi, Bilgisayar Mühendisliği Bölümü, Sakarya, Türkiye

<sup>2</sup> Sakarya Üniversitesi, Bilgisayar Mühendisliği Bölümü, Sakarya, Türkiye

fatihadak@sakarya.edu.tr, oduralioglu@hotmail.com

## Öz

Yapılan bu çalışmada öğrencilerin girdiği sınav verilerine göre sonraki sınavlardaki performansları tahmin edilmek istenmiştir. Veri kümesi olarak, 2021-2022 eğitim öğretim yılı 1. döneminde, İstanbul ili Ataşehir ilçesinde bulunan Dr. Nureddin Erk-Perihan Erk Mesleki ve Teknik Anadolu Lisesi, Bilişim Teknolojileri alanındaki 10 ve 11'inci sınıfta okuyan 87 öğrencinin Nesne Tabanlı ve Programlama dersinde uygulanan 3 sınavdaki puan dağılımları kullanılmıştır. Sınavlardaki sorular ders bilgi formundaki kazanım başlıklarıyla eşleştirilmiş, her öğrencinin kazanım başlıklarına göre performans oranları tablo haline getirilmiştir. Verilerin kısıtlı olmasından dolayı toplanan gerçek veriler kullanılarak sentetik veriler üretilmiştir. Sentetik verinin gerçeğe yakınlık derecesi detaylı sonuç raporu ile teyit edilmiştir. Birden çok sayıda performans değeri tahmin edileceğinden, çok çıkışlı regresyonu destekleyen doğrusal regresyon, k-en yakın komşu ve karar ağacı algoritmaları kullanılmıştır. Algoritmaların başarı değerlendirmesi için k katmanlı çapraz doğrulama uygulanmıştır. Performans ölçümleri için MAE, MSE, R2 ve standart sapma hesaplanmıştır. Aşırı uyum çözümü için KNN ve karar ağacı algoritmalarında en iyi parametre değerleri bulunarak performans iyileştirilmiştir. Sonuçlara göre en iyi performans değerleri KNN ile elde edilmiştir. Bu çalışmanın devamı olarak tüm derslerin sınav verilerinin girileceği bir sistem tasarlanarak dersler arasındaki performans bağlantıları analiz edilebilir. Böylece performans tahminlerine göre öğrencilerin gelecekteki başarısızlıkları bugünden önlenebilir ve eğitim kalitesi artırılabilir.

**Anahtar kelimeler:** Eğitsel veri madenciliği, öğrenci performans tahmini, çok çıkışlı regresyon, sentetik veri, makine öğrenmesi

## Estimation of Students' Achievement Information and Success in Exams Using Machine Learning Methods

### Abstract

In this study, it was aimed to predict the performance of the students in the next exams according to the exam data they entered. As the data set, in the 1st semester of the 2021-2022 academic year, Dr. The score distributions of 87 students studying in the 10th and 11th grades of Nureddin Erk-Perihan Erk Vocational and Technical Anatolian High School in the field of Information Technologies in the 3 exams applied in the Object-Oriented and Programming course were used. The questions in the exams were matched with the achievement titles in the course information form, and the performance rates of each student were tabulated according to the achievement titles. Synthetic data were produced using real data collected due to limited data. The degree of closeness of the synthetic data to reality was confirmed by the detailed result report. Since more than one performance value will be estimated, linear regression, k-nearest neighbor and decision tree algorithms supporting multi-output regression are used. K-layer cross validation was applied to evaluate the success of the algorithms. MAE, MSE, R2 and standard deviation were calculated for performance measurements. For overfitting solution, the performance is improved by finding the best parameter values in KNN and decision tree algorithms. According to the results, the best performance values were obtained with KNN. As a continuation of this study, a system in which exam data of all courses will be entered can be designed and the performance connections between courses can be analyzed. Thus, future failures of students can be prevented and the quality of education can be increased according to performance predictions.

**Keywords:** Educational data mining, student performance prediction, multi-output regression, synthetic data, machine learning

\* Sorumlu yazar.  
E-posta adresi: fatihadak@sakarya.edu.tr

Alındı : 2 Ekim 2022  
Revizyon : 24 Ekim 2022  
Kabul : 31 Ekim 2022

## 1. Giriş (Introduction)

Gelişen teknoloji ile saklanan ve kullanılan veri boyutları her geçen gün artmaktadır. Verilerin hangi şekilde kullanılarak daha anlamlı hale getirilebileceği araştırıldıkça veri madenciliği ve makine öğrenmesi yöntemleri önem kazanmıştır. Veri madenciliği, geliştirilen yöntemler ile çok büyük miktardaki veri içerisinden işe yarayacak olanları kullanılabilir hale getirmektedir. Makine öğrenmesi ise sisteme girilen veriler ve kullanılan algoritmalar ile bilgisayarın öğrenmesini ve gelecek hakkında tahminler üretmesini sağlayan tekniktir. Veri madenciliği ve makine öğrenmesi yöntemleri ile birçok alanda olduğu gibi eğitim alanında da yapılan çalışmalar artarak önem kazanmaya devam etmektedir.

Bu çalışmanın amacı öğrencilerin girdiği sınav verilerini kullanarak gelecekte gireceği sınav performanslarını tahmin etmektir. Benzer çalışmalar için yapılan literatür taramasında; İçeli çalışmasında Cumhuriyet Üniversitesi Divriği Nuri Demirağ MYO (Meslek Yüksek Okulu)'da Temel Bilgisayar Bilimleri dersini alan öğrencilere uygulanan anket ile elde edilen veriler kullanılarak Weka programı ile karar ağacı uygulayarak bir derse ait başarı analizi uygulanmış ve anlamlı bilgiler elde edilmiştir. (İçeli, 2012). Güvenç vd. öğrencilerin başarı tahmini ve eksikliklerini gidermek için bir dersi almadan önce öğrencilerin bilgi düzeylerini ölçmüş ve dönem sonu başarı puanlarında alarak öğrencileri başarılarına göre dört kategoriye ayırmıştır. Veriler yetersiz olduğu için SMOTE (The Synthetic Minority Over-sampling TEchnique) yöntemi ile sentetik veri üretilmiştir. Uygulanan altı makine öğrenmesi yönteminde en iyi sonucu SVM (destek vektör makinesi) algoritması vermiştir (Güvenç vd., 2022). Şengür, Fırat Üniversitesi BÖTE (Bilgisayar ve Öğretim Teknolojileri Eğitimi Bölümü) bölümünden mezun öğrencilerin ders ve mezuniyet notu verilerini kullanarak yeni öğrenciler hakkında tahminde bulunmuştur. Yapay sinir ağı ve karar ağacı kullanmış, yapay sinir ağının daha iyi sonuçlar verdiği görülmüştür (Şengür, 2013). Aghalarova çalışmasında Kalboard 360 E-öğrenme sisteminden elde edilen verileri kullanarak otomatik makine öğrenmesi (AutoML) ile en iyi modelin seçimini araştırılmıştır. En iyi algoritma dağıtılmış rastgele orman algoritması olarak elde edilmiştir (Aghalarova, 2022). Gök çalışmasında öğrencilere uygulanan anket sonuçlarına göre dönem sonu genel başarı notları 6 makine öğrenmesi algoritması ile tahmin etmiştir. Puan tahmininde rastgele orman, not tahmininde ise öznelik seçme yöntemi ile birlikte lojistik sınıflandırma algoritması en iyi sonucu vermiştir (Gök, 2017). Abbasoğlu çalışmasında dört farklı resmi ortaokuldaki öğrencilerin verilerini kullanarak uyguladığı 8 sınıflandırıcı algoritma analizi sonucunda lojistik regresyon en iyi sonucu vermiştir (Abbasoğlu, 2020). Aydemir vd. üniversitede Türk Dili dersini alan öğrenci verilerini kullanarak bu derste başarıları beş farklı ağaç algoritması ile tahmin

edilmiştir. En iyi sonuçlar random forest algoritması ile elde edilmiştir (Aydemir vd., 2019). Can vd. üniversite öğrencilerine uygulanan anket ile iki adet ders başarı değişkeni tanımlamıştır. Bu değişkenleri etkileyen soru cevaplarıyla ders başarıları arasındaki ilişki lojistik regresyon ile tahmin edilmek istenmiş, analizler sonucunda %91,6 oranında tahmin başarıları sağlanmıştır (Can vd., 2018). Güner vd. Pamukkale Üniversitesi Mühendislik Fakültesi öğrencilerinin verilerini kullanarak destek vektör makinesi yöntemiyle öğrencilerin matematik-1 dersindeki alacakları puanları tahmin etmiştir. Yapılan analizler sonucunda %86,36 doğruluk oranı ile tahmin sonuçları elde edilmiştir (Güner vd., 2011). Akgün vd. eğitsel veri madenciliğiyle ilgili yapılan 102 çalışmayı incelemiş ve çalışmalarda en çok kullanılan yazılımın WEKA olduğunu, en çok kullanılan tekniklerin ise karar ağaçları ve yapay sinir ağları olduğunu belirtmiştir (Akgün vd., 2020). Üniversite düzeyinde teknik ders öneri sistemi geliştirilmiş bulanık modelin başarıları yüksek olmuştur (Adak vd., 2016).

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

Öğrencilerin girdiği sınavlardaki kazanımlarda gösterdiği performans verileri kullanılarak sonraki gireceği sınavlardaki performans değerleri sayısal olarak tahmin edileceğinden dolayı çok çıktılı regresyon kullanılmıştır.

### 2.1. Veri Kümesi (Data Set)

Veri kümesi olarak 2021-2022 eğitim öğretim yılı 1.döneminde, İstanbul ili Ataşehir ilçesinde bulunan Dr. Nureddin Erk-Perihan Erk Mesleki ve Teknik Anadolu Lisesi, Bilişim Teknolojileri alanındaki 10 ve 11'inci sınıfta okuyan 87 öğrencinin Nesne Tabanlı ve Programlama dersinde uygulanan 3 sınavın not dağılımları kullanılmıştır. Dersin kazanımları, MEB (Milli Eğitim Bakanlığı) tarafından hazırlanan ders bilgi formlarına bakılarak elde edilmiştir (MEB, 2022). Tablo 1'de Nesne Tabanlı Programlama dersinin kazanım başlıkları numaralandırılmış şekilde görülmektedir.

Sınav soruları kazanım başlıklarına göre gruplanmıştır. Gruplama sonucunda 1. sınavda 1, 3, 4, 5 numaralı kazanımlar, 2. sınavda 1, 3, 4, 5 numaralı kazanımlar, 3. sınavda 1, 3, 5, 7 numaralı kazanımlarla ilgili sorular olduğu görülmüştür. Excel programı kullanılarak her sorudan alınan puanlar tablo haline getirilmiştir. Daha sonra sorular kazanım başlıkları eşleştirilerek öğrencinin her kazanımdan toplamda kaç puan aldığını gösteren yeni bir tablo oluşturulmuştur. Sınavdaki sorulara bağlı olarak her kazanımın toplam puanı farklı olduğu için kazanımlardan alınan puanlar yüzölçümüne göre yeniden düzenlenmiştir.

**Tablo 1.** Kazanım başlıkları (Educational attainment titles)

Kazanım Numarası	Kazanım Başlıkları
Kazanım 1	Yazım hatalarını dikkate alarak nesne tabanlı programlama çalışma ortamını kullanır.
Kazanım 2	Yazım hatalarını dikkate alarak isim uzaylarını kullanır.
Kazanım 3	Tanımlama kurallarını dikkate alarak değişkenleri ve temel veri türlerini kullanır.
Kazanım 4	İşlem önceliğine göre aritmetiksel operatörleri kullanır.
Kazanım 5	Yazım kurallarına dikkat ederek şart ifadelerini kullanır.
Kazanım 6	Mantıksal operatörleri öncelik sırasına uygun kullanır.
Kazanım 7	Yazım formatına dikkat ederek döngü yapılarını kullanır.
Kazanım 8	Programda hata ayıklaması yapar.

Yani öğrencinin sınavda her kazanımdan yüzde kaç başarı gösterdiği yeni bir tabloda hesaplanmıştır. Böylece çalışmadaki modellerde kullanılacak veri kümesi elde edilmiştir.

Toplanan verilerin kısıtlı olmasından dolayı Gretel sistemi ile farklı epochs ve batch size değerleri verilerek denemeler sonucunda epochs=10000 ve batch size=5000 değerleri kullanılarak 86 sentetik veri kalite puanı ile 5000 sentetik veri üretilmiştir. Gretel sisteminde 80 ve üzeri puanlama mükemmel olarak değerlendirilmektedir. Şekil 1’de görüldüğü gibi, alan korelasyon kararlılığı, derin yapı stabilitesi ve alan dağılım kararlılığı değerlerinin 80 ve üzerinde puanlandığından dolayı üretilen verilerin makine öğrenmesi çalışmalarında kullanılabilir olduğu görülmüştür.

**Şekil 1.** Veri özet istatistikleri (Data Summary Statistics)

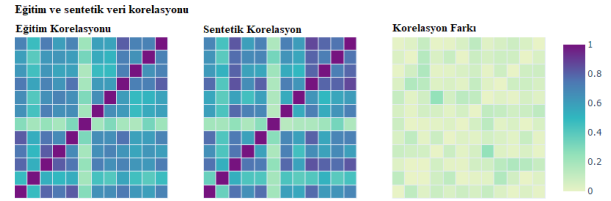
Şekil 2’de üretilen sentetik verilerin başlıklarına göre bilgiler yer almaktadır. Veri kümesi başlığındaki birinci sayı sınav numarasını, ikinci sayı ise o sınavdaki kazanım numarasını temsil etmektedir. Numaralarına göre kazanım başlıkları Tablo 1’de görülmektedir.

**Eğitim Kalitesi**

Alan	Tekil	Eksik Veri	Ort. Uzunluk	Tür	Dağılımın Kalitesi
K_2_3	2	0	1.94	İkili Veri	Mükteşem
K_3_4	12	0	5.06	Sayısal	Orta
K_1_3	14	0	10.31	Sayısal	İyi
K_2_5	15	0	7.09	Sayısal	İyi
K_3_1	29	0	9.48	Sayısal	İyi
K_3_5	22	0	5.51	Sayısal	İyi
K_1_5	20	0	6.15	Sayısal	Mükteşem
K_2_1	52	0	10.90	Sayısal	Mükteşem
K_1_4	29	0	8.99	Sayısal	Mükteşem
K_1_1	67	0	10.64	Sayısal	Mükteşem
K_2_4	18	0	7.22	Sayısal	Mükteşem
K_3_7	24	0	5.37	Sayısal	Mükteşem

**Şekil 2.** Eğitim alanına genel bakış (Training field overview)

Şekil 3’teki Gretel rapor ekranında gerçek ve sentetik verilerin ayrı ayrı olmak üzere kendi içindeki alanları arasındaki korelasyon verilmiştir. Sağda ise gerçek verilerin ve sentetik verilerin alanları arasındaki fark verilmiştir. Her iki veri grubu ayrı ayrı değerlendirildiğinde korelasyon oranlarının birbirine benzediği, ikisi arasındaki korelasyon farkının ise az olduğu görülmüştür.

**Şekil 3.** Eğitim ve sentetik veri korelasyonu (Training and Synthetic Data Correlation)

## 2.2. Kullanılan Regresyon Yöntemleri (Regression Methods Used)

Çok çıktılı regresyonu desteklediğinden dolayı doğrusal regresyon, k-en yakın komşu ve karar ağacı algoritmaları kullanılmıştır.

### 2.2.1. Doğrusal Regresyon (Linear Regression)

Doğrusal regresyon, bağımsız bir değişken ile bağımlı bir değişken arasındaki ilişkiyi tahmin etmek amacıyla kullanılan doğrusal bir yaklaşımdır. (Kumari vd., 2022)

Doğrusala yakın ilişki gözlemlendiğinde, basit doğrusal regresyon modelleri denklem (1)’deki gibi ifade edilir (Mardikyan, 2005):

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad (1)$$

Çoklu doğrusal regresyon modelleri için ise denklem (2)’deki gibi ifade edilir:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_{p-1} X_{i,p-1} + \varepsilon_i \quad (2)$$

### 2.2.2. K-En Yakın Komşu (K-Nearest Neighbors)

KNN algoritması, veriler arasında bir korelasyon olduğunu varsayarak, yeni gelen veriyi mevcut verilerle daha benzer olan kategoriye dahil eder. Burada k değeri, etraftaki kaç komşuya dikkat edileceğini temsil eder. Gözlemler arasındaki mesafe ölçümü için genellikle öklid mesafesi kullanılır (Altunkaynak vd., 2020).

$$\text{Öklid mesafesi} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (3)$$

### 2.2.3. Karar Ağacı (Decision Tree)

Karar ağacı algoritması, bir ağaç yapısı gibi kök düğüm, dallar ve yapraklardan oluşur. Veri kümesinin alt kümelerine bölünmesiyle oluşur. En uçtaki yapraklar, regresyonda sayısal bir değeri temsil eder. Veri kümesi karmaşıkça ağaç dallanarak büyümektedir (Özlür Başer vd., 2021).

### 2.3. K Katmanlı Çapraz Doğrulama (K-Fold Cross Validation)

Çapraz doğrulama, kullanılan verilere göre makine öğrenimi yöntemini değerlendirmek için kullanılır. K değeri verilerin kaç gruba bölüneceğini temsil eder. Gruplardan biri test için, k-1 tanesi ise eğitim için kullanılır. Tüm denemelerin sonucunda ortalama hata hesaplanır (Özlen, 2022).

### 2.4. Kullanılan Performans Ölçümleri (Performance Measurements Used)

Kullanılan regresyon modellerindeki performansı ölçmek amacıyla MAE, MSE, R<sup>2</sup> ölçümleri kullanılmıştır.

#### 2.4.1. Ortalama Mutlak Hata (Mean Absolute Error-MAE)

Hatanın hedef çıktıya bölümüyle elde edilen değer toplamının veri kümesi sayısına bölünmesi sonucu elde edilir. Denklem 4'te, T değeri gerçek çıktı, O değeri ağda hesaplanan çıktı, n değeri ise veri kümesi sayısıdır (Adak, 2016).

$$MAE = \frac{1}{n} \sum_{i=1}^n \frac{|T-O|}{T} \quad (4)$$

MAE değerinin sıfıra yakın olması, modelin tahmin ettiği değerler ile gerçek değerlerin birbirine yakın olduğunu gösterir.

#### 2.4.2. Ortalama Kare Hatası (Mean Squared Error-MSE)

Hata kareleri toplamının eğitimde kullanılan veri kümesi sayısına bölümü ile elde edilir. Denklem 5'te, T değeri gerçek çıktı, O değeri ağda hesaplanan çıktı, n değeri veri kümesi sayısıdır (Adak, 2016).

$$MSE = \frac{1}{n} \sum_{i=1}^n (T - O)^2 \quad (5)$$

MSE değerinin sıfıra yakın olması, modelin performansının iyi olduğunu gösterir.

#### 2.4.3. Açıklayıcılık Katsayısı (Explanatory Coefficient-R<sup>2</sup>)

Bağımsız değişken ile gerçek çıktıların ortalaması hesaplanarak kullanılır. Denklem 6'da, T değeri gerçek çıktı, T<sub>ort</sub> değeri gerçek çıktıların ortalaması, O değeri ağda hesaplanan çıktı, n değeri veri kümesi sayısı, k değeri bağımsız değişken sayısıdır (Adak, 2016).

$$R^2 = 1 - \left[ 1 - \frac{\sum(T-O)^2}{\sum(T-T_{ort})^2} \right] \frac{n-1}{n-k-1} \quad (6)$$

R<sup>2</sup> değeri 0 ile 1 arasında bulunur. Hesaplanan sonucun bire yakın olması, modelinin performansının iyi olduğunu, sıfıra yakın olması ise modelin performansının kötü olduğunu gösterir.

### 2.5. Uygulama (Application)

Regresyon yöntemlerini uygulamak için Python, kodların çalıştırılması için Google Colab ve sentetik veri üretimi için Gretel kullanılmıştır. Veri işleme konusunda zengin kütüphaneleri sayesinde kullanıcılarına kolaylık sağlamaktadır. Analiz sonuçlarını kolaylıkla görme ve görselleştirme sayesinde genellikle tercih edilmektedir. Gretel, her türlü metin veya yapılandırılmış veriden yeni sentetik örnekler oluşturmak için Uzun Kısa Süreli Bellek (LSTM) yapay sinir ağını kullanmaktadır. Sentetik veri üretimi sonrasında üretilen verilerin kalitesiyle ilgili detaylı rapor sunmaktadır.

## 3. Uygulama ve Bulgular (Application and Findings)

Verilerin %80'i sistemin eğitimi için, %20'si test verisi olarak kullanılmıştır.

Öncelikle kullanılan algoritmalarda parametre olmadan performansları gözlenmiştir. İlk aşamada mevcut gerçek verilerle analiz yapılmıştır.

Tablo 2, Tablo 3 ve Tablo 4'te gerçek verilerle algoritmalarından elde edilen sonuçlar görülmektedir.

**Tablo 2.** Gerçek veriler ile doğrusal regresyon sonuçları (Linear regression results with real data)

	MAE	MS E	R <sup>2</sup>	Standart Sapma
1.sınavdan				
2.sınav tahmini	26,47 7	951	0.47 1	7,609
1.sınavdan				
3.sınav tahmini	21,25 6	535	0.62 2	6,324
2.sınavdan				
3.sınav tahmini	21,98 1	653	0.52 6	8,922



**Tablo 3.** Gerçek veriler ile KNN sonuçları (KNN results with real data)

	MAE	MS E	R <sup>2</sup>	Standart Sapma
1.sınavdan 2.sınav tahmini	23,57 8	113 9	0.38 9	4,899
1.sınavdan 3.sınav tahmini	19,52 3	721	0.49 7	7,626
2.sınavdan 3.sınav tahmini	25,33 1	749	0.45	9,742

**Tablo 4.** Gerçek veriler ile karar ağacı sonuçları (Decision tree results with real data)

	MAE	MS E	R <sup>2</sup>	Standart Sapma
1.sınavdan 2.sınav tahmini	29,65 9	162 3	0.073	11.529
1.sınavdan 3.sınav tahmini	19,71 1	943	0.242	8.118
2.sınavdan 3.sınav tahmini	20,90 6	135 4	- 0.094	10.048

Gerçek verilerle elde edilen sonuçlara bakıldığında en iyi performansı doğrusal regresyon algoritması olduğu görülmektedir. MAE, MSE değerlerinin düşük olması hata oranının diğerlerine göre daha düşük olduğunu göstermektedir. R<sup>2</sup> değerinin 1'e yakın olması üretilen tahminlerin doğruluğunun diğerlerine göre daha iyi olduğunu göstermektedir.

Tablo 5, Tablo 6 ve Tablo 7'de sentetik verilerle yapılan analiz sonucunda algoritmalarından elde edilen sonuçlar görülmektedir.

**Tablo 5.** Sentetik veriler ile doğrusal regresyon sonuçları (Linear regression results with synthetic data)

	MAE	MS E	R <sup>2</sup>	Standart Sapma
1.sınavdan 2.sınav tahmini	20,42 3	768	0.44 8	0.578
1.sınavdan 3.sınav tahmini	14,98 0	451	0.56 7	1,034
2.sınavdan 3.sınav tahmini	16,32 0	500	0.52 5	0.991

**Tablo 6.** Sentetik veriler ile KNN sonuçları (KNN results with synthetic data)

	MAE	MS E	R <sup>2</sup>	Standart Sapma
1.sınavdan 2.sınav tahmini	19,49 3	859	0.39	0.766
1.sınavdan 3.sınav tahmini	14,92 7	483	0.53 9	1,155
2.sınavdan 3.sınav tahmini	15,88 9	554	0.47 8	1,179

**Tablo 7.** Sentetik veriler ile karar ağacı sonuçları (Decision tree results with synthetic data)

	MAE	MS E	R <sup>2</sup>	Standart Sapma
1.sınavdan 2.sınav tahmini	22.80 2	148 3	- 0.034	1.536
1.sınavdan 3.sınav tahmini	18.00 3	759	0.27	1.417
2.sınavdan 3.sınav tahmini	19.35 4	904	0.145	1.621


Gerçek verilerle elde edilen sonuçlarda olduğu gibi sentetik verilerle elde edilen sonuçlara bakıldığında en iyi performansı doğrusal regresyon algoritması göstermiştir. Ayrıca sentetik verilerle elde edilen değerlerin, gerçek verilerle elde edilen değerlere göre daha iyi olduğu görülmüştür.

Ancak KNN ve karar ağacı algoritmalarında parametre kullanılmadığından dolayı eğitim aşamasında uygulanan k katmanlı çapraz doğrulama ile elde edilen analiz sonuçlarıyla, test verilerinin kullanılmasıyla elde edilen analiz sonuçları arasındaki farkın çok yüksek olduğu görülmüştür. Sistemin daha önce görmediği test verileri kullanıldığında tahmin performansında önemli düşmeler gözlenmiştir.


Şekil 4, Şekil 5, Şekil 6 ve Şekil 7'de KNN algoritmasındaki k değerine 1'den 20'ye kadar değerler verildiğinde performans ölçümlerindeki değişimler görülmektedir.

Şekil 8, Şekil 9, Şekil 10 ve Şekil 11'de ise karar ağacı algoritmasındaki derinlik değerine 1'den 20'ye kadar değerler verildiğinde performans ölçümlerindeki değişimler görülmektedir.


Şekillerde sistemin eğitim aşamasında k katmanlı çapraz doğrulama ile elde edilen analiz sonuçları mavi ile, test verilerinin uygulanması sonucu elde edilen sonuçlar ise kırmızı ile gösterilmiştir.




Şekil 4. KNN algoritmasındaki k değeri ile MAE ilişkisi (Relationship between k value and MAE in KNN algorithm)




Şekil 5. KNN algoritmasında k değeri ile MSE ilişkisi (Relationship between k value in KNN algorithm and MSE)




Şekil 6. KNN algoritmasında k değeri ile  $R^2$  ilişkisi (Relationship between k value and  $R^2$  in KNN algorithm)




Şekil 7. KNN algoritmasında k değeri ile standart sapma ilişkisi (Relationship between k value and standard deviation in KNN algorithm)




Şekil 8. Karar ağacı algoritmasında derinlik ile MAE ilişkisi (Relationship between depth and MAE in the decision tree algorithm)



Şekil 9. Karar ağacı algoritmasında derinlik ile MSE ilişkisi (Relationship between depth and MSE in the decision tree algorithm)



Şekil 10. Karar ağacı algoritmasında derinlik ile R<sup>2</sup> ilişkisi (Relationship between depth and R<sup>2</sup> in decision tree algorithm)



Şekil 11. Karar ağacı algoritmasında derinlik ile standart sapma ilişkisi (Relationship between depth and standard deviation in decision tree algorithm)

KNN algoritmasındaki k parametresinin en iyi değerini bulabilmek için Python'da GridSearchCV yöntemi kullanılmıştır ve k=35 olarak bulunmuştur. Elde edilen değerlerin parametresiz elde edilen sonuçlara göre daha iyi olduğu görülmüştür. Tablo 8'de, k=35 uygulanarak elde edilen sonuçlar görülmektedir.

**Tablo 8.** KNN algoritmasında k=35 uygulanarak bulunan sonuçlar (The results found by applying k=35 in the KNN algorithm)

	MAE	MS E	R <sup>2</sup>	Standart Sapma
1.sınavdan 2.sınav tahmini	19.82 8	746	0.47	0.603
1.sınavdan 3.sınav tahmini	14.45 2	427	0.58 9	1.027
2.sınavdan 3.sınav tahmini	15.58 7	470	0.55 7	1.016


Karar ağacı algoritmasından daha iyi performansı alabilmek ve aşırı uyum sorununu önlemek amacıyla derinlik (max\_depth) ve düğümün bölünmeden önce gerekli örnek sayısı (min\_samples\_split)

parametrelerinin en iyi değerlerini bulabilmek amacıyla Python'da GridSearchCV yöntemi kullanılmıştır. En iyi derinlik değeri 5 ve örnek sayısı değeri 18 olarak bulunmuştur. Elde edilen değerlerin parametresiz elde edilen sonuçlardan daha iyi olduğu görülmüştür. Tablo 9'da max\_depth=35 ve min\_samples\_split=18 uygulanarak elde edilen sonuçlar görülmektedir.


**Tablo 9.** Karar ağacı algoritmasında Max\_depth=35 ve Min\_samples\_split=18 uygulanarak bulunan sonuçlar (The results found by applying Max\_depth=35 and Min\_samples\_split=18 in the decision tree algorithm)

	MAE	MS E	R <sup>2</sup>	Standart Sapma
1.sınavdan 2.sınav tahmini	20.22 7	762	0.45 6	0.81
1.sınavdan 3.sınav tahmini	14.71 3	446	0.57	1.138
2.sınavdan 3.sınav tahmini	15.81 3	492	0.53 2	1.171


En iyi sonuçların elde edildiği KNN algoritmasında test verileriyle elde edilen grafikler Şekil 12, Şekil 13, Şekil 14’te görülmektedir.



**Şekil 12.** KNN ile 1. sınav verileri ile 2. sınav performansını tahmin grafiği (Prediction graph of 2nd exam performance with 1st exam data with KNN)



**Şekil 13.** KNN ile 1. sınav verileri ile 3. sınav performansını tahmin grafiği (Prediction graph of 3rd exam performance with 1st exam data with KNN)



**Şekil 14.** KNN ile 2. sınav verileri ile 3. sınav performansını tahmin grafiği (Prediction graph of 3rd exam performance with 2nd exam data with KNN)

#### 4. Sonuçlar (Conclusions)

Bu çalışma ile öğrencilerin gelecekte başarılı yada başarısız olma durumlarını tahmin etmek yerine sayısal olarak gelecekte girecekleri sınav tahminleri yapılmak

istenmiştir. Yapılan literatür taramasında genellikle öğrencilerin ileride başarılı olup olmama durumları tahmin edilmek istendiği görülmüştür.

Yapılan analiz sonuçlarına göre, çok az farklar olsada KNN algoritmasının diğerlerine göre daha iyi performans gösterdiği görülmüştür. Algoritmada en iyi parametre değerlerinin bulunarak eklenmesi performansı etkilemiştir. Özellikle karar ağacı algoritmasında sistemin eğitiminden sonra uygulanan çapraz doğrulamada  $R^2$  değeri 1’e yakın çıkıyorken sistemin daha önce görmediği test veri kullanıldığında  $R^2$  değeri çok düşmüştür. Yani tahmin başarı oranı düşmüştür. Aşırı uyum sorunu parametrelerin girilmesiyle giderilmiştir.

Sentetik verilerin kullanımı ile daha iyi sonuçlar elde edilmiştir. Gerçek verilerin yetersiz olduğu durumlarda sentetik verilerin performansı arttırdığı görülmüştür.

Bu çalışmada bir dersteki mevcut sınav verileriyle gelecekte girecekleri sınav kazanım performansını tahmin edilmiştir. Milli Eğitim Bakanlığı tarafından kullanılan e-okul (öğrenci veli bilgi sistemi), MEBBİS (MEB Bilişim Sistemleri), EBA (Eğitim Bilişim Ağı) gibi sistemlerde çok fazla veri işlenmeyi beklemektedir. Bu veriler ile öğrencinin tüm derslerinde aldığı puan dağılımlarına göre dersler arasındaki performans bağlantıları analiz edilebilir. Bir dersteki performans durumunun diğer derslere etkisi tahmin edilebilir. Gelecek hakkındaki bu tahminlere göre öğrenciye rehberlik edilebilir ve öğrenciye göre ders içerikleri planlanabilir. Böylece öğrencilerin gelecekteki başarısızlıkları bugünden önlenebilir ve eğitim kalitesi artırılabilir.


#### Kaynaklar (References)

- Abbasoğlu, B. (2020). Ortaokul Öğrencilerinin Akademik Başarılarının Eğitsel Veri Madenciliği Yöntemleri İle Tahmini . *Veri Bilimi* , 3 (1) , 1-10.
- Adak, M. F., Yumusak, N., & Taskin, H. (2016). An elective course suggestion system developed in computer engineering department using fuzzy logic. In 2016 International Conference on Industrial Informatics and Computer Systems (CIICS) (pp. 1-5). IEEE.
- Aghalarova, S. & Bozkurt Keser, S. (2022). Öğrencilerin Akademik Performanslarının Tahmin Edilmesi İçin Automl Tekniğinin Uygulanması . *El-Cezeri* , 9 (2) , 394-412 . Doi: 10.31202/Ecjse.946505.
- Akgün, K. & Bulut Özek, M. (2020). Eğitsel Veri Madenciliği Yöntemi İle İlgili Yapılmış Çalışmaların İncelenmesi: İçerik Analizi . *Uluslararası Eğitim Bilim Ve Teknoloji Dergisi* , 6 (3) , 197-213 . Doi: 10.47714/Uebt.753526.
- Altunkaynak, A., Başakın, E. E. & Kartal, E. (2020). Dalgacık K-En Yakın Komşuluk Yöntemi İle Hava Kirliliği Tahmini . *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi* , 25 (3) , 1547-1556 . Doi: 10.17482/Uumfd.809938
- Aydemir, E. , Kaysi, F. & Gülseçen, S. (2019). Üniversite Öğrencilerinin Türk Dili Dersi Sınav Sonuçlarının Sınav Hazırlık Düzeylerine Göre Tahminlenmesi . *Alphanumeric Journal* , 7 (2) , 351-356 . Doi: 10.17093/Alphanumeric.583502

- Can, Ş. , Özdil, T. & Yılmaz, C. (2018). Üniversite Öğrencilerinin Ders Başarisini Etkileyen Faktörlerin Lojistik Regresyon Analizi İle Tahminlenmesi . International Review Of Economics And Management , 6 (1) , 28-49 . Doi: 10.18825/Iremjournal.349984.
- Gök, M. (2017). Makine Öğrenmesi Yöntemleri İle Akademik Başarının Tahmin Edilmesi . Gazi University Journal Of Science Part C: Design And Technology , 5 (3) , 139-148.
- Güner, N. & Çomak, E. (2011). Mühendislik Öğrencilerinin Matematik I Derslerindeki Başarisının Destek Vektör Makineleri Kullanılarak Tahmin Edilmesi . Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi , 17 (2) , 87-96.
- Güvenç, E. , Sakal, M. , Çetin, G. & Özkaraca, O. (2022). Öğrencilerin Dersteki Niteliklerinin Makine Öğrenmesi Teknikleri Kullanılarak Sınıflandırılması . Düzce Üniversitesi Bilim Ve Teknoloji Dergisi , 10 (3) , 1359-1371 . Doi: 10.29130/Dubited.1017202.
- İçeli, N. (2012). Veri Madenciliği Yöntemi İle Divriği Nuri Demirağ Meslek Yüksekokulu Öğrencilerinin Temel Bilgisayar Dersine Ait Başari Analizi Uygulaması . Mesleki Bilimler Dergisi (Mbd) , "2012 Yılı Cilt:1 Sayı:1 (Syf 18-37)" , 18-37.
- Kumari, S., Siwach, V., Singh, Y., Barak, D., & Jain, R. (2022). A Machine Learning Centered Approach For Uncovering Excavators' Last Known Location Using Bluetooth And Underground Wsn. Wireless Communications And Mobile Computing, 2022.
- Mardikyan, S. (2005). İlişki Analizinde Varsayımlardan Sapmaların Belirlenmesi Ve Çözümlemesine Yönelik Bir Bilgisayar Programı Geliştirilmesi, Doktora Tezi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Meb, (2022). [Http://Meslek.Eba.Gov.Tr/?P=Ders-Bilgi-Formu&Tur=Mtal](http://Meslek.Eba.Gov.Tr/?P=Ders-Bilgi-Formu&Tur=Mtal), 20.02.2022
- Özlen T. (2022). Servikal Kanserlerin Teşhisinde Kullanılan Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Analizi, Yüksek Lisans Tezi, İstanbul Aydın Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul
- Özlüer Başer, B. , Yangın, M. & Sarıdaş, E. S. (2021). Makine Öğrenmesi Teknikleriyle Diyabet Hastalığının Sınıflandırılması . Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi , 25 (1) , 112-120 . Doi: 10.19113/Sdufenbed.842460
- Şengür, D. & Tekin, A. (2014). Öğrencilerin Mezuniyet Notlarının Veri Madenciliği Metotları İle Tahmini . Bilişim Teknolojileri Dergisi , 6 (3) , 7-16.



# Tek Görüntü Süper Çözünürlük Uygulamaları İçin Görsel Kaliteyi İyileştirmeye Yönelik Yeni Bir Yaklaşım

Fatih Mehmet Şenalp<sup>1\*</sup> 

<sup>1</sup> Konya Teknik Üniversitesi, Elektrik Elektronik Mühendisliği, Konya, Türkiye

fatih.senalp@gmail.com

## Öz

Tek görüntü süper çözünürlük problemi, literatürde çeşitli derin öğrenme tabanlı teknikler kullanılarak kapsamlı çalışmalar yapılmıştır. Derin evrişimli ağlar tabanlı süper çözünürlük, çok sayıda pratik uygulama ile beraber hızla büyüyen bir ilgi alanı haline gelmiştir. Bununla birlikte derin öğrenme tabanlı ilk çalışmalar evrişimli sinir ağları tabanlı olup, tepe sinyal gürültü oranı odaklı çalışmalardır. Son yıllardaki çekişmeli üretici ağlar tabanlı geliştirilen modeller sayesinde görsel kaliteyi artırmak esas amaç olarak belirlenmiştir; fakat bu durum görüntü kalite metrikleri incelendiğinde görülmektedir. Bu çalışmada ise eğitim sırasında kullanılan ağ kaybı için hem ortalama kare hata hem de algısal kayıp değerlerinden faydalanılmıştır. Ayrıca, üç farklı eğitim veri setinin birleşimi yeni bir eğitim veri seti olarak kullanılmıştır. Bu etmenlerin sonucunda hem görsel kalite artırılmış hem de görüntü kalite metrik değerlerinde ciddi bir artış yakalanmıştır. Ek olarak, yığın normalleştirme katmanları ağ mimarisine dahil edilmemiş ve bağlantı atlama tekniği kullanılarak derin ağ mimarisinin eğitim hızı artırılmıştır. Önerilen modelin başarı performansı literatürde yer alan önemli modeller ile karşılaştırılmıştır. Burada, tepe sinyal gürültü oranı ve yapısal benzerlik indeksi değerleri literatürde yaygın kullanılan üç farklı test veri seti için ayrı ayrı hesaplanmış ve değerlendirilmiştir. Elde edilen sonuçlar değerlendirildiğinde önerilen modelin diğer modellere göre daha başarılı olduğu ve daha kaliteli görüntüler oluşturduğu görülmektedir. Tüm bulgular değerlendirildiğinde önerilen modelin diğer modellere kıyasla hem başarı hem de eğitim hızı bakımından daha verimli bir model olduğu görülmektedir.

**Anahtar kelimeler:** Süper çözünürlük, Derin öğrenme, Görüntü kalite metrikleri, Yeni eğitim veri seti

## A New Approach to Improve Visual Quality for Single Image Super Resolution Applications

### Abstract

The single image super resolution problem has been extensively studied in the literature using various deep learning-based techniques. Super resolution based on deep convolutional networks has become a rapidly growing area of interest with many practical applications. However, the first studies based on deep learning were based on convolutional neural networks and peak signal-to-noise ratio (PSNR) oriented. Thanks to the models developed based on generative adversarial networks (GAN) in recent years, it has been determined as the main objective to increase the visual quality; however, this is not seen when the image quality metrics are examined. In this study, both mean square error and perceptual loss values were used for the network loss used during the training of the network. Also, the combination of three different training datasets was used as a new training dataset. As a result of these factors, both the visual quality has been increased and a significant increase has been achieved in the image quality metric values. In addition, batch normalization layers are not included in the network architecture and the training speed of the deep network architecture is increased by using the skip connection technique. The success performance of the proposed model was compared with the state-of-the-art models in the literature. Here, the peak signal to noise ratio (PSNR) and structural similarity index measure (SSIM) values were calculated and evaluated separately for three different test data sets commonly used in the literature. When the obtained results are evaluated, it is seen that the proposed model is more successful than other models and generates higher quality images. When all the findings are evaluated, it is seen that the proposed model is a more efficient model in terms of both success and training speed compared to state-of-the-art models.

**Keywords:** Super resolution, Deep learning, Image quality metrics, New training dataset

\* Sorumlu yazar.  
E-posta adresi: fatih.senalp@gmail.com

Alındı : 3 Ekim 2022  
Revizyon : 13 Ocak 2023  
Kabul : 16 Ocak 2023



## 1. Giriş (Introduction)

Süper Çözünürlüğün (SC) temel amacı, daha düşük çözünürlüklü görüntülerden daha yüksek çözünürlüklü bir görüntü oluşturmaktır. Yüksek çözünürlüklü görüntü, yüksek piksel yoğunluğu ve dolayısıyla orijinal sahne hakkında daha fazla ayrıntılar sunmaktadır (Toyran, 2008). Görüntülerin örüntü tanıma ve analizinde daha iyi performans için bilgisayarlı görü uygulamalarında yüksek çözünürlük ihtiyacı yaygındır. Medikal görüntüleme için yüksek çözünürlük önemlidir (Gu vd., 2020). Ayrıca, gözetim, adli ve uydü görüntüleme uygulamaları gibi birçok uygulama, yüksek çözünürlüğün gerekli olduğu görüntüde belirli bir ilgi alanının yakınlaştırılmasını gerektirmektedir. Ancak, yüksek çözünürlüklü görüntüleri elde etmek her zaman mümkün olmamaktadır. Bunun nedeni, yüksek çözünürlüklü görüntüleme sistemlerinin kurulumunun pahalı olması ve ayrıca sensörün, optik üretim teknolojisinin doğal sınırlamalarıdır (Zhang vd., 2018). Bu problemler, nispeten ucuz olan ve süper çözünürlük kavramına yol açan görüntü işleme algoritmalarının kullanılmasıyla aşılabilir. Daha az maliyetli olabileceği ve mevcut düşük çözünürlüklü görüntüleme sistemlerinden yararlanılabildiği için avantaj sağlamaktadır (Anwar vd., 2020).

Süper çözünürlük, bir sahnenin düşük çözünürlüklü (gürültülü) görüntü dizisinin bir kombinasyonunun, yüksek çözünürlüklü bir görüntü veya görüntü dizisi oluşturmak için kullanılabileceği fikrine dayanmaktadır. Yani, daha düşük çözünürlükte gözlenen bir dizi görüntü verildiğinde, orijinal sahne görüntüsü yüksek çözünürlükle yeniden oluşturulmaya çalışılmaktadır. Süper çözünürlük uygulamalarındaki genel yaklaşım, düşük çözünürlüklü görüntülerin yüksek çözünürlüklü bir görüntünün yeniden örneklenmesinden elde edildiği şeklindedir (Chudasama vd, 2020). Daha sonra, girdi görüntülerine ve görüntüleme modeline dayalı olarak daha yüksek çözünürlüğe sahip süper çözünürlüklü görüntüler yeniden oluşturulmaktadır. Bu nedenle, görüntüleme modelinin doğruluğu, süper çözünürlük için hayati önem taşımakta ve yanlış bir modelleme görüntüyü daha da bozabilmektedir. Süper çözünürlük uygulamalarında, gözlenen görüntüler bir veya birden fazla kameradan alınabildiği gibi bir video dizisinin kareleri şeklinde de olabilmektedir. Bu görüntülerin ortak bir referans çerçevesine eşlenmesi gerekmektedir. Bu işlem kayıt olarak ifade edilmektedir. Ayrıca süper çözünürlük prosedürü istenildiği takdirde hizalanmış bileşik görüntüdeki ilgili bir bölgeye de uygulanabilmektedir (Glasner vd., 2009).

Görüntü işleme alanında önemli bir yere sahip olan süper çözünürlük tekniği; tıbbi görüntüleme, uydü görüntüleme, gözetleme ve güvenlik, astronomik görüntüleme, askeri görüntüleme vb. uygulama alanlarında kullanılabilmektedir (Yue vd., 2018). Ayrıca, son yıllarda termal görüntüleme üzerinde de

süper çözünürlük uygulamaları yaygınlaşmıştır (Yan vd., 2021).

Süper çözünürlük kavramı üzerine gerçekleştirilen ilk çalışmalarda faydalanılan basit yöntemler en yakın komşu (nearest neighbor), çift doğrusal (bilinear), bikübik interpolasyon metotlarıdır. Bu teknikler görüntüdeki piksellerin komşuluk ilişkisine dayanmaktadır. Bikübik interpolasyon yöntemi diğer iki yöntemle kıyasla daha yüksek kalitede görüntüler elde edilmesini sağlamaktadır. Buna rağmen kenar detay bilgilerinin elde edilmesi gibi etmenler için yetersiz kalmaktadır. Son yıllardaki donanım teknolojilerindeki ve derin öğrenme alanındaki gelişmeler süper çözünürlük uygulamalarına olan ilgiyi artırmıştır. Burada, derin ağ mimarilerinin geleneksel yöntemlere göre daha başarılı sonuçlar elde ettiği görülmüştür (Dong vd., 2016).

Derin öğrenme tabanlı süper çözünürlük çalışmaları için ilk olarak evrişimli sinir ağları (CNN) tabanlı modeller kullanılmıştır. Dong vd. SRCNN modelini sunmuşlar ve düşük çözünürlüklü - yüksek çözünürlüklü görüntüler arasında uçtan uca haritalama (end to end mapping) tekniğini uygulamışlardır (Dong vd., 2015). Daha sonra Kim vd. SRCNN modelinden esinlenerek tasarladıkları VDRS modelinde kalımtı öğrenme (residual learning) yönteminden yararlanmışlardır. Ayrıca evrişim katmanlarının sayısını 3 yerine 20 olarak düzenlemişler ve daha başarılı sonuçlara ulaşmışlardır. Burada, PSNR değeri 0,5-1 dB ve SSIM değerleri ise %1-3 aralığında artış gerçekleşmiştir (Kim vd., 2016).

CNN tabanlı gerçekleştirilen uygulamalarda, daha çok ortalama kare hatayı (MSE) olabildiğince minimize etmek amaçlanmıştır. Son yıllarda ise görsellik açısından daha kaliteli görüntüler elde edebilmek amacıyla çekişmeli üretici ağlar (GAN) tabanlı modeller önerilmiştir (Goodfellow vd., 2014). Ledig vd. SRGAN modelini geliştirmişler ve bu modelin üretici ağında bağlantı atlama tekniği uygulamışlardır. SRGAN modeli, görsellik açısından CNN tabanlı modellere göre daha başarılı sonuçlara ulaşılmasını sağlamıştır (Ledig vd., 2017). Bu durum GAN tabanlı süper çözünürlük uygulamalarına olan ilgiyi artırmıştır. Wang vd. SRGAN modelini geliştirerek yoğun blok (dense block) kullandıkları ESRGAN modelini önermişlerdir. Burada, SRGAN modeli ile karşılaştırıldığında 0.1-0.4 dB aralığında artışlar elde ettiği gözlenmiştir (Wang vd., 2020). Yakın zamanda gerçekleştirilen diğer bir çalışmada ise Senalp ve Ceylan geliştirdikleri TSRGAN ile süper çözünürlük uygulamaları gerçekleştirilmiş ve oldukça başarılı sonuçlar elde etmişlerdir. Burada, SRGAN modeline göre PSNR değerinde 0.6 dB, SSIM değerinde ise %2 daha başarılı sonuçlar elde edilmiştir (Senalp ve Ceylan, 2021).

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

Bu bölümde, gerçekleştirilen süper çözünürlük uygulamalarında kullanılan veri setleri, geliştirilen derin ağ mimarisi ve başarı performansı değerlendirme ölçütleri ile ilgili detaylı bilgiler paylaşılmaktadır.

### 2.1. Veri setleri (Datasets)

Bu çalışmada, derin ağ mimarisinin eğitim sürecini gerçekleştirmek amacıyla BSD300, T91 ve General100 veri setlerinin (Dong vd., 2016) birleştirilmesiyle yeni bir veri seti oluşturulmuştur. Böylece farklı görüntü boyutu ve pozlama özelliklerinden faydalanılmıştır. Eğitim veri seti 391 adet görüntüden meydana gelmektedir. Bu veri setine ait örnek görüntüler Şekil 1'de paylaşılmıştır. Derin ağ test sürecinde ise Set5, Set14 ve BSD100 veri setleri (Ledig vd., 2017) ayrı ayrı olacak şekilde kullanılmıştır. Böylece eğitilen derin ağ 119 görüntü üzerinde test edilmiştir.

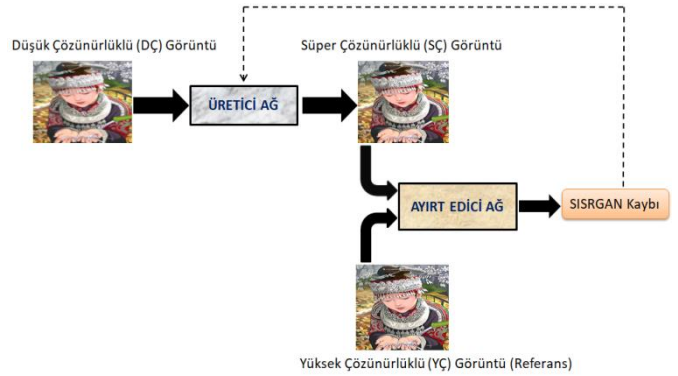


Şekil 1. Eğitim veri setinden örnek görüntüler (Sample images from the training dataset)

### 2.2. Derin ağ mimarisi (Deep network architecture)

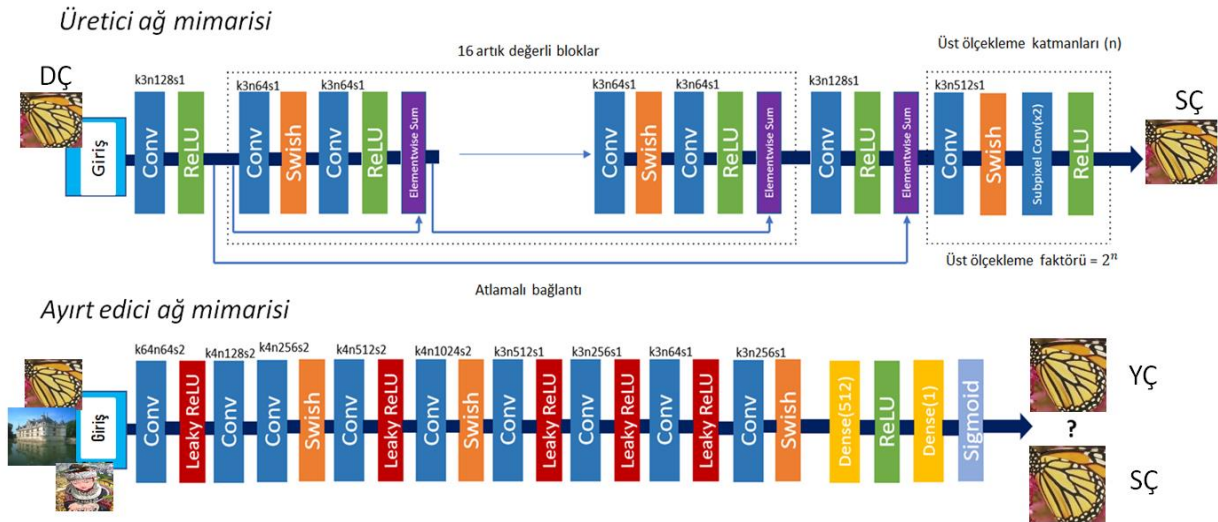
Bu bölüm, süper çözünürlük çalışmalarının başarısını artırmak ve daha hızlı bir eğitim süreci

yerine getirebilmek amacıyla geliştirilen SISRGAN (Single Image Super Resolution Generative Adversarial Networks) modeli ile ilgili detaylı bilgiler vermektedir. Önerilen bu model çekişmeli üretici ağlar (GAN) tabanlı bir model olup, üretici (generator) ve ayırt edici (discriminator) ağ kısımlarından meydana gelmektedir (Radford vd., 2015). Üretici ağ, x4 üst ölçekleme yaparak süper çözünürlüklü görüntüyü (SÇ) meydana getirmektedir. Modelin çalışma prensibine göre ağ kaybindan yararlanarak geri yayılım (backpropagation) tekniği uygulanmaktadır (Senalp ve Ceylan, 2020). SISRGAN mimarisinin genel gösterimi Şekil 2' de verilmiştir.



Şekil 2. SISRGAN mimarisi (SISRGAN architecture)

Önerilen SISRGAN modelinde yığın normalleştirme (batch normalization) katmanları kullanılmayarak eğitim hızı artırılmıştır. Ayrıca kullanılan swish aktivasyon fonksiyonu sayesinde negatif kısımda da öğrenme sağlanmıştır. Ek olarak, üretici ağ kısmında bağlantı atlama (skip connection) tekniği uygulanarak hem modelin başarısı artırılmış olup hem de eğitim süreci kolaylaştırılmıştır. Üretici ve ayırt edici ağların mimarileri Şekil 3'te gösterilmektedir.



Şekil 3. Üretici ve ayırt edici ağ mimarileri (Generator and discriminator networks)

Matematiksel İfade:

$$\delta_G = \min \frac{1}{N} \sum_{n=1}^N L_{SISRGAN}(G_{\delta_G}(I_n^{DC}), I_n^{YC}) \quad (1)$$

Denklem 1’de verilen formülde  $\delta_G$ , derin ağ modelinin ağırlık ve sapma değerlerini ifade ederken  $G$  ise SÇ görüntüyü temsil etmektedir. Ayrıca,  $I_n^{DC}$  ve  $I_n^{YC}$  ise sırasıyla eğitim veri setine ait DC ve YÇ örnek görüntüleri temsil etmektedir. Algısal kayıp (perceptual loss) değerini temsil eden  $L_{SISRGAN}$ , aynı zamanda geri yayılım yönteminde kullanılan derin ağın kaybıdır ve metrik değerlerindeki iyileşmenin yanı sıra görsel kaliteyi de artırabilmek amacıyla kullanılmaktadır. Bu algısal kayıp değeri Denklem 2’de verilen formülle hesaplanmaktadır (Johnson vd., 2016).

$$L_{\text{toplam}(SISRGAN)} = L_{mse} + \underbrace{L_{vgg}}_{L_{\text{icerik}}} + L_{\text{cekişmeli}} \quad (2)$$

*Ortalama Kare Hata (MSE)*, derin ağ modellerinin başarısını gösteren pozitif değerli bir ölçüttür. MSE değerinin azalması modelin başarısının arttığını göstermektedir. MSE, Denklem 3’te verilen formülle hesaplanmaktadır ve  $n$  veri setinin boyutunu,  $e_j$  ise tahmin ile esas değer arasındaki hata değerini temsil etmektedir.

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

*VGG kayıp* değeri hesaplanırken önceden eğitilmiş VGG19 modelinden yararlanılmış olup, hesaplama formülü Denklem 4’te verilmiştir.  $G_{\phi}(I^{DC})$ , SÇ görüntüyü,  $I^{YC}$  ise YÇ görüntüyü temsil etmektedir. Ayrıca  $\psi_{i,j}$ ,  $i$ . maksimum havuzlama (maxpooling) katmanından önce  $j$ . konvolüsyon katmanındaki özellik haritalarını gösterirken,  $W_{i,j}$  ve  $H_{i,j}$  özellik haritalarının boyutlarını göstermektedir (Gu vd., 2020).

$$L_{VGG_{i,j}}^{S\check{C}} = \frac{1}{W_{i,j} H_{i,j}} \sum_{m=1}^{W_{i,j}} \sum_{n=1}^{H_{i,j}} (\psi_{i,j}(I^{YC})_{m,n} - \psi_{i,j}(G_{\phi}(I^{DC}))_{m,n})^2 \quad (4)$$

*Çekişmeli kayıp (adversarial loss)*, daha kaliteli görüntüler oluşturabilmek amacıyla yapısal olarak benzerliği artırma esasına dayanarak hesaplanan bir kayıp değeridir. Bu kayıp değerinin formülü Denklem 5’te verilmiştir. Ayırt edici ağın tüm eğitim veri seti üzerindeki olasılıklarına bağlı olarak hesaplanmaktadır.  $D_{\alpha}(G_{\beta}(I^{DC}))$ , SÇ görüntünün YÇ (referans) görüntüye ne ölçüde benzediğini göstermektedir.

$$L_{\text{Çekişmeli}}^{S\check{C}} = \sum_{n=1}^N -\log D_{\alpha}(G_{\beta}(I^{DC})) \quad (5)$$

### 2.3. Görüntü kalite metrikleri (Image quality metrics)

Tepe sinyal gürültü oranı (PSNR), iki sinyal arasındaki kalitesini etkileyen bozulma gürültüsünün etkisine bağlı bir oran hesaplama amacıyla kullanılmaktadır. İki görüntü için hesaplanan bu oran desibel formunda hesaplanmaktadır. PSNR değeri, sinyaller geniş dinamik aralıklara sahip olduğu için desibel ölçeğinin logaritma terimi olarak hesaplanmaktadır. Tepe sinyal gürültü oranı, düşük kalitedeki görüntülerin yeniden oluşturulması sonucu süper çözünürlüklü görüntülerin kalitelerini değerlendirmek için kullanılan en yaygın ve önemli kalite değerlendirme metriklerindedir. Orjinal sinyal referans veri olarak kabul edilirken, gürültü ise sıkıştırma veya bozulmadan kaynaklanan hata olarak tanımlanmaktadır. PSNR, yeniden yapılandırma kalitesine ilişkin insan algısının yaklaşık tahmini olarak ifade edilebilmektedir. PSNR değerinin hesaplama formülü Denklem 6’da verilmiştir. Bu denklemde,  $I_0$  referans görüntüyü,  $I$  ise oluşturulan süper çözünürlüklü görüntüyü temsil etmektedir (Javaid vd., 2013).

$$PSNR = 20 \times \log_{10} \left( 255 \sqrt{MSE(I, I_0)} \right) \quad (6)$$

Yapısal benzerlik indeksi (SSIM), algıya dayalı bir metriktir. Bu yöntemde görüntü bozulması, yapısal bilgilerdeki algısal değişiklik olarak kabul edilmektedir. Yapısal bilgi terimi, birbirine güçlü şekilde bağlı pikseller veya uzamsal olarak kapalı pikseller hakkında vurgu yapmaktadır. Bu güçlü bir şekilde birbirine bağımlı pikseller, görüntü alanındaki



görsel nesnelere hakkında daha önemli bazı bilgileri belirtmektedir. SSIM, görüntü ve videoların algılanan görsel kalitesini tahmin etmektedir. Yani, orijinal ve yeniden oluşturulmuş iki görüntü arasındaki benzerliği ölçmektedir. SSIM değerinin hesaplama formülü Denklem 7'de verilmiş olup,  $\mu_{I_R}(n)$  ve  $\mu_{I_D}(n)$  sembolleri, referans ( $I_R$ ) ve bozuk ( $I_D$ ) görüntü dizisinin n. çerçevesinin ortalamasını temsil etmektedir. Ayrıca,  $\sigma_{I_R}(n)$  ve  $\sigma_{I_D}(n)$ , referans ( $I_R$ ) ve bozuk ( $I_D$ ) görüntü dizisinin n. çerçevesinin standart sapmasını temsil etmektedir. C1, C2 ise kararsızlıktan kaçınmak için kullanılan sabitlerdir (Dosovitskiy ve Brox, 2016).

$$SSIM = \frac{[2\mu_{I_R}(n)\mu_{I_D}(n)+C1][2\sigma_{I_R}I_D(n)+C2]}{[\mu_{I_R}^2(n)+\mu_{I_D}^2(n)+C1][\sigma_{I_R}^2(n)+\sigma_{I_D}^2(n)+C2]} \quad (7)$$

### 3. Süper Çözünürlük Uygulamalarının Sonuçları (The Results of Super Resolution Implementations)


Bu bölümde, gerçekleştirilen uygulamaların eğitim süreçleri ve uygulamalar sonucunda elde edilen sonuçlar hakkında detaylı bilgiler yer almaktadır.

#### 3.1. Eğitim sürecinin detayları (Training details)

Bu çalışmada, derin öğrenme tabanlı süper çözünürlük modellerinin eğitim süreçleri için CPU E5-2680 işlemci ve 32 gb GeForce GTX 1080 Ti ekran kartına sahip bir iş istasyonu kullanılmıştır. Derin ağların eğitimi 10.000 iterasyon (epoch) sonunda tamamlanmıştır. Burada, önerilen SISRGAN modelinin diğer modellere göre eğitim hızının daha yüksek olduğu gözlemlenmiş olup, ağın eğitimi 14 saat sürmüştür. Ek olarak, TSRGAN ağının eğitimi 18 saat sürerken, SRGAN ağının eğitimi ise 19 saatte tamamlanmıştır. Ayrıca, önerilen modelde optimizasyon algoritması olarak Adam algoritması kullanılmış ve öğrenme oranı 0.001 tercih edilmiştir.

#### 3.2. Elde edilen sonuçlar (The results obtained)

Bu bölümde eğitilmiş derin ağ modellerinin Set5, Set14 ve BSD100 test veri setleri üzerinde elde edilen sonuçlar hem görsel olarak hem de metrik değerleri olarak sunulmaktadır. Üç test verisine ait sonuçlar ayrı ayrı paylaşılmıştır. Burada, önerilen SISRGAN derin ağ modelinin sonuçları literatürde yer alan yeni ve gelişmiş modellerle (SRCNN, SRGAN, TSRGAN) karşılaştırılmıştır. Modellerin test işlemleri sonucu elde edilen süper çözünürlüklü sonuç görüntülerinden örnekler Şekil 4'te görülmektedir. Bu görüntülerin yanı sıra düşük çözünürlüklü ve yüksek çözünürlüklü (referans) görüntülere ait örnekler de paylaşılmıştır.



Şekil 4. Elde edilen görüntülerden örnekler (Examples of the obtained images)

Daha sonra, farklı test veri setlerindeki görüntülerden oluşturulmuş süper çözünürlüklü görüntülerin başarı performansları PSNR ve SSIM görüntü kalite metrikleri dikkate alınarak değerlendirilmiştir. Elde edilen görüntülerden hesaplanan metrik değerlerinin sonuçları Tablo 1’de verilmiştir. Elde edilen en iyi sonuçlar kalın biçimde, ikinci en iyi değerler ise altı çizili olarak gösterilmiştir. PSNR ve SSIM sonuçları incelendiğinde önerilen modelin SRCNN, SRGAN ve TSRGAN modellerine göre daha üstün bir başarı elde ettiği görülmektedir. PSNR değerleri dikkate alındığında, önerilen SISRGAN modeli TSRGAN modeline göre 0.5 dB, SRGAN modeline göre 0.8-1.3 dB aralığında ve SRCNN modeline göre ise 0.2-0.6 dB aralığında daha

başarılı sonuçlara ulaştığı gözlemlenmiştir. Ayrıca SSIM değerleri incelendiğinde, SISRGAN modelinin TSRGAN ve SRGAN modelleri ile karşılaştırıldığında 2-6% aralığında daha başarılı olduğu görülmüştür. Bunun yanı sıra evrişimli sinir ağıları tabanlı SRCNN modeli ile karşılaştırıldığında ise yine daha başarılı olmasına rağmen daha yakın değerler elde edilmiştir. BSD100 veri seti üzerinde yürütülen test çalışmaları sonucunda SRCNN modeli en iyi SSIM değerini elde ederken ikinci en iyi değeri önerilen SISRGAN modeli elde etmiştir. Bunun dışında tüm test çalışmalarının neticesinde önerilen SISRGAN modeli en iyi sonuçlara ulaşmayı başarmıştır. TSRGAN modeli ise genel sonuçlarda en iyi ikinci değerlere ulaştığı gözlenmiştir.

**Tablo 1.** PSNR ve SSIM sonuçları (PSNR and SSIM results)

	DÇ	Biküçük İnterpolasyon	SRCNN	SRGAN	TSRGAN	SISRGAN	YÇ (Referans)
<b>Set 5</b>							
PSNR	25.256	27.372	28.549	28.328	<u>28.785</u>	<b>29.216</b>	∞
SSIM	0,7742	0,8211	0,8522	0,8492	<u>0,8754</u>	<b>0,9065</b>	1
<b>Set 14</b>							
PSNR	22.981	25.140	27.289	26.654	27.213	<b>27.487</b>	∞
SSIM	0,6685	0,7366	<u>0,7914</u>	0,7841	0,7879	<b>0,8092</b>	1
<b>BSD100</b>							
PSNR	24.162	25.583	26.251	25.578	<u>26.492</u>	<b>26.817</b>	∞
SSIM	0,6514	0,7052	<b>0,7486</b>	0,6993	0,737	<u>0,7461</u>	1

#### 4. Sonuçlar (Conclusions)

Bu makalede görünür görüntüler için derin öğrenme tabanlı yeni bir süper çözünürlük modeli önerilmiştir. Bu model literatürde önemli yere sahip modellerle karşılaştırılmış ve hem görsel algı kalitesi hem de görüntü kalite metrikleri açısından daha başarılı sonuçlar elde ettiği görülmüştür. Bu çalışmalar sırasında üç farklı eğitim veri seti birleştirilerek yeni bir eğitim veri seti oluşturulmuştur. Önerilen SISRGAN modeli ve literatürdeki güncel başarıya sahip modeller için gerçekleştirilen test aşamaları sırasında literatürde yaygın bir şekilde kullanılan üç farklı test veri setinden faydalanılmıştır. Böylece farklı görüntüler üzerinde modelin başarısı ispatlanmıştır. Önerilen modelin başarısındaki en önemli etmenlerden birisi de ağı eğitimini sırasında farklı görüntülerden yararlanılmasıdır.

Ayrıca, önerilen modelde yığın normalleştirme katmanları çıkarılıp, konvolüsyon katmanlarının

artırılması sonucu modelin başarısı daha net bir şekilde ortaya konulmuştur. Burada, bağlantı atlama tekniğinin kullanılmasıyla beraber ağı eğitim hızı bakımından da daha verimli bir model elde edilmiştir. Ek olarak, önerilen model çekişmeli üretici ağılar tabanlı bir model olmasına rağmen tepe sinyal gürültü oranı (PSNR) ve yapısal benzerlik indeksi (SSIM) metrikleri açısından da evrişimli sinir ağıları tabanlı SRCNN modeline göre üstün bir başarı göstermiştir. Bunun önemli olmasının sebebi ise evrişimli sinir ağıları tabanlı modellerin literatürde daha çok PSNR-odaklı modeller olarak ifade edilmesidir. Buradaki amaç görsel kaliteden ziyade metrik değerlerinde başarı elde etmektir. Buna karşın bu makalede gerçekleştirilen çalışmalarda amaç görsel olarak daha kaliteli süper çözünürlüklü görüntüler oluşturmak ve bunu metrik değerleri ile desteklemektir. Gerçekleştirilen süper çözünürlük uygulamaları neticesinde, kenar detay bilgilerinin

(yüksek frekans bilgileri) başarılı şekilde elde edildiği ve bulanıklığın giderilerek daha net süper çözünürlüklü görüntülerin üretildiği görülmüştür. Bu durum hesaplanan görüntü kalite metriklerinin değerleri de incelendiğinde açık bir şekilde ortaya konmuştur.

## Kaynaklar (References)

- Anwar, S., Khan, S., Barnes, N., 2020. A deep journey into super-resolution: A Survey. *ACM Computing Surveys* 53:1-34. <http://dx.doi.org/10.1145/3390462>
- Chudasama, V., Patel, H., Prajapati, K., Upla, K., Ramachandra, R., Raja, K., Busch, C., 2020. TherISuRNet- A computationally efficient thermal image super-resolution network. *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. pp 388-397. <http://dx.doi.org/10.1109/CVPRW50498.2020.00051>
- Dong, C., Loy, C.C., He, K., Tan, X., 2015. Image super-resolution using deep convolutional networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 38:295-307. <http://dx.doi.org/10.1109/TPAMI.2015.2439281>
- Dong, C., Loy, C.C., Tang, X., 2016. Accelerating the Super-Resolution Convolutional Neural Network. *Computer Vision ECCV 2016 Lecture Notes in Computer Science Springer* 9906. [https://doi.org/10.1007/978-3-319-46475-6\\_25](https://doi.org/10.1007/978-3-319-46475-6_25)
- Dosovitskiy, A., Brox, T., 2016. Generating images with perceptual similarity metrics based on deep networks. In *Advances in Neural Information Processing Systems (NIPS)*. pp 658-666. <https://doi.org/10.48550/arXiv.1602.02644>
- Glasner, D., Bagon, S., Irani, M., 2009. Super-resolution from a single image. *IEEE 12th International Conference on Computer Vision*. pp 349-356. <http://dx.doi.org/10.1109/ICCV.2009.5459271>
- Goodfellow, I., vd., 2014. Generative adversarial networks. In *Advances in Neural Information Processing Systems (NIPS)*. pp 2672-2680. <http://dx.doi.org/10.1145/3422622>
- Gu, Y., vd., 2020. MedSRGAN: medical images super-resolution using generative adversarial networks. *Multimedia Tools and Applications* 79:21815-21840. <http://dx.doi.org/10.1007/s11042-020-08980-w>
- Javaid, H., Babar, T.K., Rasool, A., Saghir, R.U., 2013. Video colour variation detection and motion magnification to observe subtle changes. M.Sc. Thesis, Blekinge Institute of Technology, Faisalabad, Pakistan.
- Johnson, J., Alahi, A., Li, F., 2016. Perceptual losses for real-time style transfer and super resolution. In *European Conference on Computer Vision (ECCV) Springer*. pp 694-711. [http://dx.doi.org/10.1007/978-3-319-46475-6\\_43](http://dx.doi.org/10.1007/978-3-319-46475-6_43)
- Kim, J., Lee, J.K., Lee, K.M., 2016. Accurate image super-resolution using very deep convolutional networks. *IEEE CVPR*. pp 1646-1654. <http://dx.doi.org/10.1109/CVPR.2016.182>
- Ledig, C., vd., 2017. Photo-realistic single image super-resolution using a generative adversarial network. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Honolulu*. pp 105-114. <http://dx.doi.org/10.1109/CVPR.2017.19>
- Radford, A., Metz, L., Chintala, S., 2015. Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.
- Senalp, F.M., Ceylan, M., 2020. Enhancement of low resolution thermal face image resolution using deep learning. *European Journal of Science & Tech*. pp 131-135. <https://doi.org/10.31590/ejosat.802174>
- Senalp, F.M., Ceylan, M., 2021. Deep learning based super resolution and classification applications for neonatal thermal images. *Traitement du Signal* 38(5):1361-1368. <https://doi.org/10.18280/ts.380511>
- Toyran, M., 2008. Reconstructing super resolution images from low resolution images. M.Sc. Thesis, Institute of science, Istanbul.
- Wang, M., Chen, Z., Wu, Q.M.J., Jian, M., 2020. Improved face super-resolution generative adversarial networks. *Machine Vision and Applications* 31:22. <https://doi.org/10.1007/s00138-020-01073-6>
- Yan, R., Yang, K., Wang, K., 2021. NLFNet: Non-Local Fusion Towards Generalized Multimodal Semantic Segmentation across RGB-Depth, Polarization, and Thermal Images. 2021 *IEEE International Conference on Robotics and Biomimetics (ROBIO)*, pp 1129-1135. <http://dx.doi.org/10.1109/ROBIO54168.2021.9739390>
- Yue, L., Shen, H., Li, J., Yuan, Q., Zhang, H., Zhang, L., 2018. Image super-resolution: the techniques, applications, and future. *Signal Processing* 128:389-408. <http://dx.doi.org/10.1016/j.sigpro.2016.05.002>
- Zhang, Y., Li, K., Li, K., Wang, L., Zhong, B., Fu, Y., 2018. Image super-resolution using very deep residual channel attention networks. *Proceedings of the European Conference on Computer Vision*. pp 286-301. [http://dx.doi.org/10.1007/978-3-030-01234-2\\_18](http://dx.doi.org/10.1007/978-3-030-01234-2_18)





# Robot-Nesne Etkileşiminde Çok Kipli Hata Sezme

Arda İnceoğlu<sup>1</sup> , Gökhan İnce<sup>2</sup> , Yusuf Yaslan<sup>3</sup> , Sanem Sariel<sup>4\*</sup> 

<sup>1,2,3,4</sup> İstanbul Teknik Üniversitesi, Yapay Zeka ve Robotik Laboratuvarı, Bilgisayar ve Bilişim Fakültesi, İstanbul, Türkiye

sariel@itu.edu.tr, gokhan.ince@itu.edu.tr, yyaslan@itu.edu.tr, sariel@itu.edu.tr

## Öz

Hizmet robotları için gündelik etkileşimlerinde yürütme, sensör veya ortamsal faktörlerden dolayı emniyetsiz durumlar oluşabilir. Bu tür durumlarda emniyetin sağlanması kritik öneme sahiptir. Bu durumların sezilebilmesi için sürekli eylem gözetimi ve hata sezme bileşenlerine ihtiyaç duyulmaktadır. Bu amaçla, bu çalışmada nesne etkileşim hatalarının sezilmesi için çok kipli bir eylem gözetimi ve hata sezme sistemi sunulmuştur. Tek bir sensör kipine bağımlı kalmak yerine, farklı tipte sensörlerden alınan gözlemler tümleştirilerek farklı hata senaryoları için hata sezme başarımı artırılmıştır. Önerilen sistemde iç algı, işitsel algı ve görsel algı kipleri birbirlerinden bağımsız olarak işlenerek semantik yüklemeler elde edilmiş ve bu yüklemeler hata sezme için birleştirilmiştir. İnsansı robotumuz ile masa üstünde yapılan deney sonuçlarına göre sensör verilerinin hata sezme katkılarının tamamlayıcı olduğu gözlenmiştir. Çok kipli sensör füzyonuyla hata sezme, tutma eylemi için %86, bırakma ve itme eylemleri için %95 oranında hata sezme başarımı ile tek kipli hata sezmeden daha başarılı sonuçlar üretmiştir.

**Anahtar kelimeler:** Bilişsel robotlar, hata sezme, çok kipli algılama.

## Multimodal Failure Detection in Robot-Object Interaction

### Abstract

Unsafe situations might arise for service robots in everyday manipulation settings due to operational, sensory or environmental factors. Ensuring safety is crucial for these settings. In order to detect these situations, onboard continuous execution monitoring and failure detection procedures are needed. To address these issues, we present a multimodal failure monitoring and detection system to detect manipulation failures. Rather than relying only on a single sensor modality, we consider integration of different modalities to get better detection performance in different failure cases. In our system, high level proprioceptive, auditory and visual predicates are extracted by processing each modality separately. Then, the extracted predicates are fused altogether. Experiments on our humanoid robot for tabletop manipulation scenarios indicate that the contributions of modalities are complementary of each other. Multimodal fusion-based failure detection outperforms the unimodal detection with 86% success rate for pick and 95% success rates for place and push actions.

**Keywords:** Cognitive robots, failure detection, multi-modal perception.


## 1. Giriş (Introduction)

Robotların kendilerine verilen görevleri insanlara, çevrelere ve kendilerine zarar vermeden tamamlamaları gerekmektedir. Fakat robotlar ev ve ofis gibi kendileri için tasarlanmayan düzensiz (unstructured) ortamlarda çalışırken algılamadaki ve ortamdaki belirsizlikler sebebiyle beklenmedik durumlar meydana gelebilir. Nesne etkileşiminde dengesiz tutuş sebebiyle nesnenin düşürülmesi, nesnenin taşınması sırasında ortamdaki diğer nesneler ile çarpışması, sensör motor arayüzündeki farklar sonucu oluşan hatalar beklenmedik durumlara örnek

olarak verilebilir. Örnek bir senaryo Şekil 1' de görülmektedir. Bu senaryoda robot masa üzerindeki makarna kutusunu dengesiz bir noktadan itmeye çalışması sebebiyle kutu devrilmektedir. Robotun eylemi yürütmesi sırasında oluşan beklenmedik durumların tespiti için hem robotun ve hem de ortamın durumu sürekli olarak gözetilmelidir. Bunun için gözlemlenen durumdan hataları ve beklenmedik durumları tespit eden bir eylem gözetim sistemine ihtiyaç vardır. Endüstriyel ortamlarda çalışan robotların güvenliği için belli başlı standartlar (ISO 10218-2:2011, ISO 10218:2011) bulunmasına karşın mutfak gibi

\* Sorumlu yazar.  
E-posta adresi: sariel@itu.edu.tr

düzensiz ortamlarda çalışan otonom robotlar için bu durum henüz çözüme ulaşmamıştır.



Şekil 1. Hizmet robotunun kutuyu devirmesi (The service robot knocked over the object)

Bu çalışmada, çok kipli bir hata sezme sistemi önerilmiştir. Görsel, işitsel ve iç algı kipleri zamansal olarak birleştirilerek Saklı Markov Model yöntemi ile robotun yürüttüğü eylemler *başarılı* ve *hatalı* olarak sınıflandırılmıştır. Bu çalışma, daha önce ICRA-MRP18 çalıştayında (Inceoglu vd., 2018-1) ve IROS 2018 konferansında (Inceoglu vd., 2018-2) sunulan çalışmalardan derlenmiş ve TORK 2019 konferansında sunulmuştur. Çalışma, TÜBİTAK tarafından 115E368 no'lu proje kapsamında desteklenmiştir.

## 2. Literatür Özeti (Related Work)

Literatürde, eylem yürütme hatalarını sezme için modele dayalı ve modelden bağımsız yöntemler sunulmuştur. En yaygın olarak kullanılan modele dayalı yöntemde, eylemlerin yürütülmesi sonucunda ortamda oluşması beklenen etkilerin, eylemlerin gerçek sonuçları ile karşılaştırılması sağlanır (Pettersson, 2005). Modelden bağımsız yöntemlerde ise sensör bilgisi herhangi bir modelden bağımsız olarak işlenir (Pettersson vd., 2007). Hata sezme üzerine sunulan kapsamlı bir çalışmada (Fritz, 2005), hata sezme üç kategori altında incelenmiştir: dış gözlemlene, beklentiye dayalı gözlemlene ve modele dayalı gözlemlene.

Modele dayalı çalışmalar arasında (Mendoza vd., 2012) normal çalışma durumlarını modelleme yoluyla eyleyici (actuator) hatalarının tespiti (Fourlas vd., 2014) ve sensörlerden gelen bilginin odometri modeliyle karşılaştırılması yoluyla hata tespitinin yapılması sağlanmıştır (Stavrou vd., 2015). Başka bir çalışmada hata durumları, varlık bileşen sistemi (Entity-Component-System) ile saptanmıştır (Orendt vd., 2015). RoboCup yarışması için eylemlerin oluşturması beklenen çıktılar ile sensör bilgileri karşılaştırılmıştır (Mendoza vd., 2015). Başka bir çalışmada Focused Anomalous Region Optimization (FARO) algoritması (Mendoza vd., 2014) kullanılarak çapraz-entropi yöntemi (Rubinstein, 1999) ile belirgin bir şekilde sapmaların olduğu durumlar listelenmiştir. Ayrıca

bölütleme algoritmaları (Schleyer ve Russell, 2011) ve planlama algoritmaları (Micalizio, 2013) kullanılarak da hata tespiti ve tanısı yapılmaktadır. Self Organizing Maps (SOPs) (Häussermann vd., 2015) ve Probabilistic Graphical Models (PGMs) gibi olasılıksal yöntemler de hataların uzam-zamansal olarak sezilmesi için analiz edilmiştir. Bir çalışmada (Hovland vd., 1998), hatalar Saklı Markov Modelleri (SMM) (Hidden Markov Models, HMMs) kullanılarak tork ve güç sinyalleri göz önüne alınarak sezilmektedir. Bir başka çalışmada (Bouguerra vd., 2007), robot ortamlarındaki belirsizlik durumları karşısında robotun beklediği çıktılar için bir olasılık dağılımı kullanılarak ortamda oluşan hatalar sezilmiştir. Yapay Sinir Ağları (Artificial Neural Networks, ANN) da eylem gözetimi için kullanılmaktadır. Yapay Sinir Ağları ve Kalman Filtreleri kullanılarak gezgin bir robot sisteminde sensör ve mekanik hataların sezilmesi konusunda bir çalışma da yapılmıştır (Goel vd., 2000). Hata sezme ve tanıma için Dinamik Bayes Ağları (DBA, Dynamic Bayesian Networks) da kullanılmaktadır (Kirchner ve Geighs, 2014). Başka bir çalışmada ise çok katmanlı Bayes Ağları (Multi-layered Bayesian Networks) kullanılarak hata sezme ve tanıma yapılmıştır (Sassi vd., 2016). Anormal durumlar kontrol kuralları kullanılarak da sezilebilir. Bir çalışmada (Adam vd., 2014), kontrol kuralları uygulama alanına özgü bir dilde temsil edilip donanım hataları sezilmiştir. Başka bir çalışmada (Kapotoglu vd., 2014), Metric Temporal Logic (MTL) (Kvarnström vd., 2008) kullanılarak eylem kontrol formleri temsil edilmiştir. El ile kodlanmış bu formler hata sezme için ileri yayılım (progression) algoritması ile eylem yürütülmesi süresince kontrol edilmiştir. İnsansız hava araçları için de hata sezme yöntemleri önerilmiştir (Doherty vd., 2009).

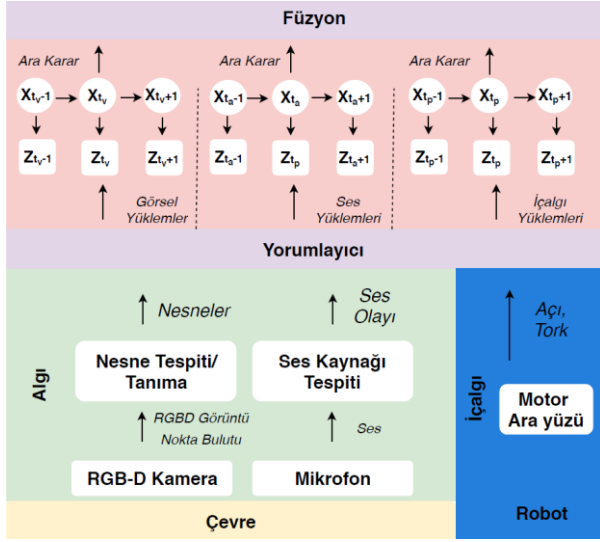
Hataların tümleşik olarak sezilmesi için bir hata sezme, tanıma ve hata kotarma mimarisi sunulmuştur (Saied vd., 2015). Bu çalışmada, lineer olmayan bir gözlemlene birimi kullanılarak kalıntı (residual) üretimi yapılmıştır. Daha sonra ise, koşul-sonuç kuralları kullanılarak hata hakkında bir çıkarım yapılmıştır.

Önceki çalışmalar incelendiğinde, robotlarda hata sezme için görsel, işitsel ve içalgı sensör bilgilerini birarada değerlendiren bir çalışma bulunmamaktadır. Bu makale, bu konudaki öncü çalışmayı sunmaktadır.

## 3. Önerilen Yöntem (Proposed Method)

Bu çalışmada ara seviye (intermediate-level) sensör füzyonu tabanlı bir hata sezme sistemi (Şekil 2) önerilmiştir. Bu sistem sensörlerden (RGB-D kamera ve mikrofon) alınan gözlemlerin işlendiği algılama iş hattı, motor arayüzü, semantik yüklemelerin oluşturulduğu yorumlayıcı katmanı ve bu yüklemelerin zamansal olarak işlendiği füzyon katmanından oluşmaktadır. Sensörlerden elde edilen gözlemler hata sezme için sembolik yüklemelere (görsel, işitsel ve içalgı) dönüştürülmektedir. Bu yüklemeler hata sezme ile ilgili anlamsal bilgiler içermektedir. Oluşturulan yüklemeler

füzyon katmanında birleştirilerek, yürütülen eylem için *başarılı* veya *hatalı* kararı olasılıksal olarak oluşturulur.



Şekil 2. Hata sezme mimarisi (Failure Detection Architecture)

### 3.1. İçalgı (Proprioception)

İçalgı (Proprioception), robotun motor arayüzünden elde edilen ölçümlerin değerlendirilmesi ile elde edilir. Motor arayüzü, motorların konumlarına, hareketlerine ve motorlara uygulanan yük miktarına ilişkin ölçümleri içerir. Hata sezme için robot koluna bağlı iki parmaklı paralel tutucunun anlık durumunu ifade eden yüklemeler oluşturulmaktadır. Tutucu parmakları arasında bulunan kodlayıcılar (encoder) ile ölçülen konum bilgisine göre oluşturulan parmaklar *açık*, *kapalı* ve *hareket* halinde yüklemelerinin yanı sıra parmaklarda ölçülen yük miktarına göre tutucu dolu yüklemi oluşturulmaktadır.

**Paralel Tutucu İçalgı Yüklemeleri:** Robotun paralel tutucusundaki parmakları arasındaki uzaklık ( $D$ ) ve parmaklarda ölçülen kuvvet  $F$  değeri aşağıdaki yüklemelere dönüştürülmektedir ( $\tau_D$  ve  $\tau_F$  uzaklık ve kuvvet eşik değerlerini temsil etmektedir):

- *Açık:* Tutucunun parmakları açık konumdadır:  $D > \tau_D$ .
- *Kapalı:* Tutucunun parmakları kapalı konumdadır:  $D < \tau_D \wedge F < \tau_F$ .
- *Hareketli:* Tutucunun parmakları hareket halindedir; açılmakta ya da kapanmaktadır.
- *Dolu:* Tutucuda ölçülen kuvvet değeri eşik değerinden üzerindedir,  $F > \tau_F$ .

### 3.2. İşitsel İş Hattı (Audio Pipeline)

Yürütme esnasında robota ses bilgisinin sağlanabilmesi için robot üzerine bir mikrofon yerleştirilmiştir. İşitsel iş hattı 3 bileşenden oluşmaktadır: ön işleme, öznelik çıkarma ve

sınıflandırma. Ses sinyalleri 4 kanallı bir mikrofon aracılığıyla 16 KHz örnekleme yapılarak elde edilir. Ön işleme sırasında, elde edilen ses sinyali 32 milisaniyelik çerçevelere bölünür ve çerçevelere Hızlı Fourier Dönüşümü (FFT) (Brigham vd., 1998) uygulanarak zaman alanından frekans alanına geçirilir. O andaki çerçevenin güç spektrumu hesaplanarak daha önceden belirlenmiş başlangıç eşik değeri (onset) ile karşılaştırılır. Eşik değerinin altında kalan çerçeveler gürültü olarak değerlendirilir. Başlangıç eşik değerini aşan ses sinyali, bitiş eşik değerinin (offset) altına düşene kadar dinlenmeye devam edilir.

Öznelik çıkarma adımı, eşik değerinin üzerindeki çerçeveler üzerinde Mel-Frekans kepsral katsayıları (MFCC) (Logan 2000) hesaplanarak 12 boyutlu bir öznelik vektörü oluşturulur ve ilk 10 çerçevenin ortalaması alınır. Ayrıca, ses olayının süresi hesaplanarak öznelik vektörüne eklenir. Sınıflandırma adımı ise, elde edilen öznelik vektörleri Lineer Destek Vektör Makinesi (SVM) aracılığıyla düşme, çarpma ya da robot gürültüsü olarak sınıflandırılır.

**İşitsel Algi Yüklemeleri:** İşitsel algi iş hattının çıktıları aşağıdaki ses olaylarına ( $E = e_j$ ) dönüştürülür:

- *Ses yok:* Herhangi bir ses olayının olmaması durumu. İşlenmekte olan ses sinyali çerçevesinin toplam enerjisi önceden belirlenmiş başlangıç eşik (onset) değerinin altında kalması durumunda ses olayı yok olarak kabul edilmektedir.
- *Düşürme:* Robotun bir nesneyi düşürmesi ile oluşan ses olayı.
- *Çarpma:* Robotun ortamdaki bir nesneye çarpması ile oluşan ses olayı. Bu ses olayı yalnızca *tutma* eyleminin yürütülmesi sırasında gözlemlenmektedir. Bu nedenle *birakma* ve *itme* eylemlerinin modellerinde dahil edilmemiştir.
- *Robot gürültüsü:* Robot motorlarının hareketi sırasında meydana gelen gürültü.

### 3.3. Görsel İş Hattı (Visual Pipeline)

Görsel iş hattı, bir RGB-D kameradan elde edilen veriler üzerinde paralel olarak çalıştırılan nesne tanıma algoritmalarından ve bu algoritmaların sonuçlarının filtrelenerek tutarlı bir dünya modeli oluşturmak için birleştirilmesinden oluşmaktadır.

Ortamda bulunan nesnelere tanımlanması için şablon tabanlı 3 boyutlu bir nesne tanıma algoritması, LINEMOD (Hinterstoisser vd., 2012), kullanılmaktadır. Robotun çalışırken karşılaşacağı nesnelere şablonları eğitim aşamasında kaydedilir. Çalışma sırasında robot, karşılaştığı nesnelere kayıtlı şablonlar ile eşleştirilerek tanımlanır. Nesne tanımlanmaya ek olarak, ortamdaki nesnelere ait nokta bulutları, 3B Bölütleme (Aldoma

vd., 2012) algoritması kullanılarak masa düzleminden ayrıştırılır.

Nesne tanıma algoritmalarının çıktılarını sahne yorumlama birimine iletilir. Tanınan nesnelere kategori, konum, boyut, renk gibi fiziksel özellikleri ile beraber bir bilgi tabanına kaydedilir. Bu özelliklere ek olarak, nesnenin sahnedeki varlığı ile ilgili bir güven değeri hesaplanır. Bu değer, nesne ile ilgili gözlemler alındıkça olasılıksal olarak artırılır veya belirli bir süre gözlem alınmazsa azaltılır. Güven değeri belirli bir değerin altına düştüğünde nesne bilgisi bilgi tabanından kaldırılır (Inceoglu vd., 2018-3).

**Görsel Algı Yüklemeleri:** Robotun eyleme başlamadan önceki ve eylemi bitirdikten sonraki sahneler Violet sisteminin çıktısı kullanılarak temsil edilir. Bu temsil üzerinden daha sonra aşağıdaki yüklemeler oluşturulur:

- $\Delta A$ : Sahnenin nokta bulutu (point cloud) temsili üzerinde hesaplanan yüzey alanı (A) değişimini ifade etmektedir.
- $\Delta L$ : Robotun etkileşime geçtiği nesnenin etkileşim öncesi ve sonrası 3B konumu arasındaki farkı ifade etmektedir. Her bir eksen için ayrı ayrı hesaplanmaktadır. ( $o$  robotun etkileşim halinde olduğu nesneyi temsil etmektedir.)

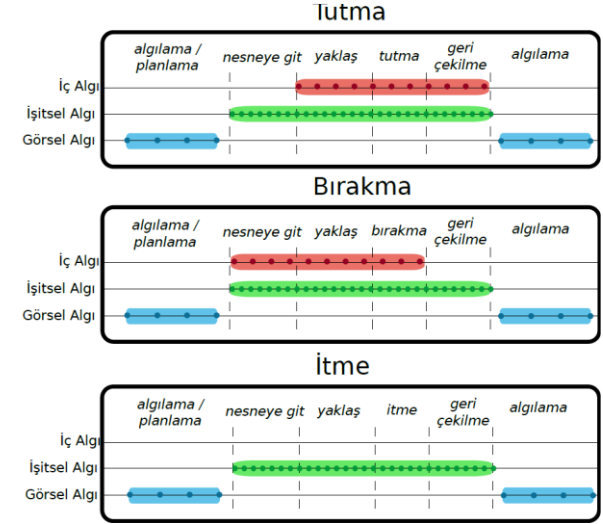
## 4. Bulgular (Results)

Deneylerde Baxter insansı robotu, 2 parmaklı tutucu, robotun baş kısmına yerleştirilmiş Asus Xtion Pro RGBD kamera ve gövde kısmına yerleştirilmiş PSEye mikrofon yerleştirilmiştir. Sistemin yazılım bileşenleri ROS (2022) platformu üzerinde gerçekleştirilmiş, işitsel algı için HARK (2022) kütüphanesi kullanılmıştır. İnsansı robotun karar mekanizması için Intel İ7 İşlemci ve 8 GB belleğe sahip bir dizüstü bilgisayar kullanılmıştır.

### 4.1. Algı Kiplerinin Niteliksel Değerlendirmesi (Qualitative Evaluation of Modalities)

Şekil 3'te tutma, bırakma ve itme eylemleri için içalgı, işitsel ve görsel algı kiplerinin, eylemlerin adımları esnasında (algılama/planlama, nesneye gitme, yaklaşma, tutma, geri çekilme ve algılama) gözlemlenebilirliğine ilişkin grafik sunulmuştur. Şekillerdeki noktalar gözlemlere ve gözlemler arası uzaklıklar gözlem frekanslarına karşılık gelmektedir. Mavi renkle işaretlenen gözlemler görsel algı kipine, yeşil renkle işaretlenen gözlemler işitsel algı kipine, kırmızı renkle işaretlenen gözlemler iç algı kipine aittir. Tutma eylemi için nesneye-git (move-to) adımında ve bırakma eylemi için geri çekilme (retreat) adımında herhangi bir içalgı gözlemi içermemektedir. Benzer şekilde, itme eylemi sırasında içalgı gözlemleri sabit kalmaktadır. Diğer yandan işitsel algı kullanılarak

eylemin herhangi bir adımında oluşan hatalar tespit edilebilmektedir. Diğer yandan, robotun eylemi yürütmesi esnasında robot kolunun görüntüyü engellemesi sebebiyle görsel algı ile sahnenin tamamı gözlenememektedir. Bu yüzden görsel algı ile yalnızca eylemin öncesinde ve sonrasında sahne gözlemlenerek durum tespiti yapılmaktadır.



**Şekil 3.** Tutma, bırakma ve itme eylemleri için algı kiplerinin gözlemlenebilirliği (Visualization of observable action phases for pick, place and push actions)

### 4.2. Hata Sezme Deneyleri (Failure Detection Experiments)

Bu bölümde güvenli görev yürütme mimarisinde hata sezme yöntemlerinin başarımlarını analiz edilmektedir. *Tutma*, *bırakma* ve *itme* veri kümeleri kendi içlerinde rastgele olarak %50 eğitim ve %50 test kümelerine bölünmüştür. Bu işlem sırasında hata ve başarı durumlarının dağılımları korunmuştur. İşlem 10 kez tekrarlanarak elde edilen sonuçların ortalaması alınmıştır.

Hata sezme için çerçeve ve seri olmak üzere iki değerlendirme ölçütü tanımlanmıştır. Çerçeve bazlı değerlendirmede her  $t$  anındaki gözlem ile bir tahmin yapılarak gerçek-değer ile karşılaştırılmaktadır. Seri bazlı değerlendirmede ise gözlem serisinde bulunan tüm gözlemler kullanılarak tek bir karar üretilir ve gerçek değer ile karşılaştırılır.

#### 4.2.1. Hata Sezme için Önerilen Yöntemler (Proposed Methods for Failure Detection)

Hata sezme için ele alınan yöntemler aşağıda sıralanmaktadır:

- *İçalgı-SM*: Hata ve başarı durumları için birer adet tek kipli SMM modeli eğitilir.
- *İşitsel-SMM*: İşitsel yüklemeler ile tek kipli SMM eğitilir.

- *İşitsel-SMM (MFCC)*: MFCC öznitelikleri kullanılarak SMM modeli eğitilir.
- *Görsel ( $\Delta A$ )*: Görsel algı ile hesaplanan alan değişimi  $\Delta A$  özneliği kullanılarak hata tahmini yapılır. Alan değişiminin artması hata göstergesi olarak kabul edilmiştir (örn., kübik bloklardan oluşan yapının devrilerek etrafa saçılması).
- *Görsel ( $\Delta L$ )*: Nesnenin konumu baz alınarak hata tahmini yapılır. 3 boyutta her eksen için beklenen ve gözlemlenen konum arasındaki fark hesaplanarak ikili bir yüklem oluşturulur. Sonrasında Karar Ağacı algoritması (Decision Tree (DT)) kullanılarak hata tahmini yapılır.
- *Görsel-SMM (HOG)*: Robotun kamerasından elde edilen 2B resimler üzerinde Yönlü Gradyan Histogramı (Histogram of Oriented Gradients (HOG) (Freeman vd., 1994) hesaplanarak hata tahmini yapılır. Resimler 3 saniyelik aralıklarla örneklenmiş ve her bir resim üzerinde ilgili alan kırılmıştır. Hesaplanan HOG öznitelikleri Temel Bileşen Analizi (Principal Component Analysis (PCA) (Pearson, 1901) kullanılarak 100 boyuta indirgenmiştir. Bu öznitelikler kullanılarak hata ve başarı durumları için ikişer saklı durum içeren SMM modelleri eğitilmiştir.
- *Görsel-SVM (HOG)*: Her bir eylem için gözlem sekansındaki son görselden elde edilen

HOG öznitelikleri kullanılarak bir Destek Vektör Makinesi (Support Vector Machine (SVM)) eğitilmiştir.

- *Füzyon-SMM*: Farklı kiplerinden alınan gözlemler, zaman bilgisi kullanılarak senkronize edilir ve tek bir vektör haline getirilir. Elde edilen yeni öznitelik ile SMM modelleri eğitilir.
- *Füzyon-DT*: Görsel ve işitsel gözlemler tek bir öznitelik vektörü haline getirilir ve Karar Ağacı (DT) eğitilerek hata sezme gerçekleştirilir.

#### 4.2.2. Çerçeve Bazlı Hata Sezme (Frame level Failure Detection)

İçalgıdan elde edilen ardışık gözlemler birbirinden bağımsız olmasına karşın, bir ses olayı birden fazla çerçeveye etki etmektedir. Ses sinyallerinin işlenmesi sırasında oluşturulan çerçeveler birbirinden bağımsız veya bütün olarak değerlendirilebilir. Bu bölümde sunulan sonuçlar elde edilirken, ses sinyallerine ait çerçeveler birbirinden bağımsız olarak değerlendirilmiştir. Hata sezme modellerinin eğitimi için, gözlem serileri her  $t$  anı için etiketlenmiştir.

Tablo 1 ve Tablo 3'te tutma ve bırakma eylemleri için çerçeve bazlı hata sezme sonuçları sunulmuştur. Tablo 2 ve Tablo 4'te ise son kararlar gerçek değerle karşılaştırılarak ölçülmüştür.

**Tablo 1.** Çerçeve bazlı tek kipli tutma hatası sezme sonuçları (Experimental results for frame level unimodal pick action failure detection)

Yöntem	<i>F1 Ölçüsü</i>	<i>Precision</i>	<i>Hatırlama (Recall)</i>
İçalgı-SMM	0.65 ± 0.09	0.81 ± 0.03	0.71 ± 0.11
İşitsel-SMM	0.55 ± 0.16	0.63 ± 0.06	0.56 ± 0.13
İşitsel-SMM (MFCC)	0.73 ± 0.07	0.76 ± 0.05	0.72 ± 0.08

**Tablo 2.** Çerçeve bazlı tek kipli tutma hatası sezme sonuçları (son çerçeve değerlendirme) (Experimental results for frame level unimodal pick action failure detection, considering the last frame)

Yöntem	<i>F1 Ölçüsü</i>	<i>Precision</i>	<i>Hatırlama (Recall)</i>
İçalgı-SMM	1.00 ± 0.00	1.0 ± 0.00	1.0 ± 0.00
İşitsel-SMM	0.62 ± 0.20	0.66 ± 0.25	0.64 ± 0.15
İşitsel-SMM (MFCC)	0.85 ± 0.09	0.89 ± 0.06	0.85 ± 0.09
Görsel-SMM (HoG)	0.51 ± 0.10	0.63 ± 0.20	0.60 ± 0.05
Görsel-SVM (HoG)	0.55 ± 0.12	0.58 ± 0.12	0.54 ± 0.13

**Tablo 3.** Çerçeve bazlı tek kipli bırakma hatası sezme sonuçları (Experimental results for frame level unimodal place action failure detection)

Yöntem	<i>F1 Ölçüsü</i>	<i>Precision</i>	<i>Hatırlama (Recall)</i>
İçalgı-SMM	0.39 ± 0.03	0.51 ± 0.03	0.50 ± 0.01
İşitsel-SMM	0.70 ± 0.20	0.83 ± 0.06	0.73 ± 0.17
İşitsel-SMM (MFCC)	0.62 ± 0.11	0.81 ± 0.02	0.64 ± 0.09

**Tablo 4.** Çerçeve bazlı tek kipli bırakma hatası sezme sonuçları (son çerçeve değerlendirme) (Experimental results for frame level unimodal place action failure detection, considering the last frame)

Yöntem	<i>F1 Ölçüsü</i>	<i>Precision</i>	<i>Hatırlama (Recall)</i>
İçalgı-SMM	0.48 ± 0.15	0.52 ± 0.29	0.58 ± 0.09
İşitsel-SMM	0.75 ± 0.20	0.81 ± 0.21	0.78 ± 0.16
İşitsel-SMM (MFCC)	0.98 ± 0.05	0.99 ± 0.04	0.98 ± 0.05
Görsel-SMM (HoG)	0.54 ± 0.05	0.48 ± 0.06	0.63 ± 0.07
Görsel-SVM (HoG)	0.79 ± 0.14	0.84 ± 0.13	0.80 ± 0.13



#### 4.2.3. Sekans Bazında Hata Sezme (Temporal Failure Detection)

Bu bölümde sunulan sonuçlar elde edilirken bir ses olayına ait çerçeveler toplu olarak değerlendirilip tek bir sınıflandırma sonucu üretilmiştir. Eylemlere ait gözlemler her sekansa bir etiket karşılık gelecek şekilde etiketlenmiştir. Tablo 5, Tablo 6 ve Tablo 7'de sırasıyla *tutma*, *birakma* ve *itme* eylemlerine ait hata sezme sonuçları verilmiştir. Şekil 3'te yapılan analize göre çok kipli hata sezme yöntemleri incelenmiştir.


Tablo 5'te sunulan sonuçlardan görülebileceği üzere, *tutma* eylemi hatası sezme için ana bilgi kaynağı içalgıdır.

*Bırakma* eylemi için ise (Tablo 6), içalgı tutucunun parmakları açıldıktan sonra eylemin sonucuna ait herhangi bir ek bilgi sunamamaktadır. Görsel algı incelendiğinde, toplam alan değişimi özneliğinin sahnedeki önemli değişiklikleri tespit edebildiği gözlemlenmiştir.

*İtme* eyleminin yürütülmesi sırasında (Tablo 7), içalgıdan elde edilen gözlemler değişmemektedir. Hedef nesnenin konumuna bağlı olarak eylem öncesi ve eylem sonrası sahne karşılaştırılması yapıldığında ( $\Delta L$ ), *itme* eylemi için daha yüksek başarımlar elde edilmiştir.

Şekil 4'te örnek bir nesne tutma hatası için içalgı ve işitsel algıdan elde edilen gözlemler (içalgı ölçümü ve ses güç spektrumu), bu gözlemlerden elde edilen yüklem (iç algı için *açık*, *kapalı*, *hareketli*, *dolu* ve işitsel algı için *gürültü*, *çarpma* ve *düşürme* yüklemelerinin oluşma durumu) ve SMM tabanlı tek kipli hata sezme

sonuçları başarı ve hata sınıfları için olasılıksal olarak sunulmaktadır.



**Şekil 4.** İç algı ve işitsel algı gözlemlerinin ve sistemin hata sezme çıktısı kararının görselleştirilmesi (Visualization of proprioceptive and auditory observations and failure detection)

Hata sezme sonuçlarına bakıldığında, içalgının *tutma* hatalarını sezme için önemi ortaya çıkmaktadır. Bazı durumlarda işitsel algı kullanılarak hata sezme başarımları artırılabilir. *Bırakma* ve *itme* eylemleri için ise *içalgı* hata sezimi için bir bilgi sunamamaktadır. Bu nedenle görsel ve işitsel algı gibi destekleyici bilgilere ihtiyaç duyulmaktadır. Görsel ve işitsel algı karşılaştırıldığında, görsel algı ile daha yüksek başarımlar ile hatalar sezilebilmektedir. Fakat sahnenin tam olarak gözlemlenebilmesi için robotun eylemi yürütmeyi bitirmesi gerekmektedir. Diğer yandan, işitsel algı ile düşme gibi olaylar anlık olarak tespit edilebilmektedir.

**Tablo 5.** Tutma hatası sezme sonuçları (Experimental results for pick action)

Yöntem	F1 Ölçüsü	Precision	Hatırlama (Recall)
İçalgı	0.85 ± 0.00	0.80 ± 0.00	0.80 ± 0.00
İşitsel	0.76 ± 0.05	0.76 ± 0.05	0.76 ± 0.05
Görsel ( $\Delta A$ )	N/A	N/A	N/A
Görsel ( $\Delta L$ )	N/A	N/A	N/A
Füzyon-SMM (İçalgı & İşitsel)	0.86 ± 0.02	0.82 ± 0.03	0.80 ± 0.04

**Tablo 6.** Bırakma hatası sezme sonuçları (Experimental results for place action)

Yöntem	F1 Ölçüsü	Precision	Hatırlama (Recall)
İçalgı	0.26 ± 0.13	0.44 ± 0.33	0.39 ± 0.10
İşitsel	0.87 ± 0.04	0.90 ± 0.02	0.87 ± 0.04
Görsel ( $\Delta A$ )	0.93 ± 0.05	0.95 ± 0.03	0.93 ± 0.05
Görsel ( $\Delta L$ )	N/A	N/A	N/A
Füzyon-DT (Görsel - $\Delta A$ & İşitsel)	0.95 ± 0.06	0.96 ± 0.04	0.95 ± 0.06

**Tablo 7.** İtme hatası sezme sonuçları (Experimental results for push action)

Yöntem	F1 Ölçüsü	Precision	Hatırlama (Recall)
İçalgı	0.48 ± 0.00	0.39 ± 0.00	0.62 ± 0.00
İşitsel	0.64 ± 0.07	0.70 ± 0.10	0.64 ± 0.07
Görsel ( $\Delta A$ )	0.74 ± 0.09	0.74 ± 0.09	0.74 ± 0.09
Görsel ( $\Delta L$ )	0.95 ± 0.03	0.96 ± 0.02	0.95 ± 0.03
Görsel-SMM (HoG)	0.60 ± 0.13	0.66 ± 0.21	0.68 ± 0.10
Görsel-SVM (HoG)	0.69 ± 0.08	0.71 ± 0.09	0.71 ± 0.07
Füzyon-DT (Görsel - $\Delta A$ & İşitsel)	0.70 ± 0.12	0.73 ± 0.13	0.71 ± 0.10
Füzyon-DT (Görsel - $\Delta L$ & İşitsel)	0.95 ± 0.03	0.96 ± 0.02	0.95 ± 0.03



## 5. Sonuçlar (Conclusion)

Bu makalede içalgı, görsel ve işitsel algı tabanlı çok kipli bir eylem gözetimi ve hata sezme sistemi sunulmuştur. *Tutma, bırakma* ve *itme* eylemleri için algılama kiplerinin hata sezme için katkısı analiz edilmiştir. Bu analize göre, çok kipli eylem gözetiminin hataları sezmede tekil sensör sistemlerine göre daha başarılı sonuçlar ürettiği ve sensör kiplerinin birbirlerini tamamlayıcı olduğu gözlenmiştir. İleriki çalışmalarda iç algının dokunma sensörleri ile zenginleştirilmesi planlanmaktadır. Ayrıca nesne ve eylem kümesi çeşitliliği artırılarak daha uzun nesne etkileşimi gerektiren senaryolar üzerinde çalışılması planlanmıştır.

## Teşekkür (Acknowledgment)

Bu çalışma, TÜBİTAK tarafından 115E368 no'lu proje kapsamında desteklenmiştir.

## Kaynaklar (References)

- Adam S., Larsen M., Jensen K., and Schultz U. P., 2014. Towards Rule-based Dynamic Safety Monitoring for Mobile Robots. Simulation, Modeling, and Programming for Autonomous Robots. Springer, 207–218.
- Aldoma A., Marton Z.C., Tombari F., Wohlkinger W., Potthast C., Zeisl B., Rusu R. B., Gedikli S., and Vincze M., 2012. Point cloud library. IEEE Robotics & Automation Magazine, 1070(12).
- Bouguerra A., Karlsson L., and Saffiotti A., 2007. Handling uncertainty in semantic-knowledge based execution monitoring. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 437–443.
- Brigham E. O., Pastor J. R., Apostol T. M., Rodríguez M., Martínez M. R., Edwards C. H., Edwards D. E. H., 1998. The fast Fourier transform and its applications, Prentice Hall.
- Doherty P., Kvarnström J., and Heintz F., 2009. A temporal logic-based planning and execution monitoring framework for unmanned aircraft systems. Autonomous Agents and Multi-Agent Systems, 19(3), 332–377.
- Freeman W. T. and Roth M., 1994. Orientation histograms for hand gesture recognition. Mitsubishi Electric Research Laboratories Teknik Raporu.
- Fritz C., 2005. Execution monitoring – a survey. University of Toronto Teknik Raporu.
- Fourlas G. K., Karkanis S., Karras G. C., and Kyriakopoulos K. J., 2014. Model based actuator fault diagnosis for a mobile robot. IEEE International Conference on Industrial Technology (ICIT), 79–84.
- Goel P., Dedeoglu G., Roumeliotis S. I., and Sukhatme G. S., 2000. Fault detection and identification in a mobile robot using multiple model estimation and neural network. IEEE International Conference on Robotics and Automation (ICRA), 2302–2309.
- HARK: <http://www.hark.jp/>, 12.09.2022.
- Hüsserle K., Zweigle O., and Levi P., 2015. A novel framework for anomaly detection of robot behaviors. Journal of Intelligent & Robotic Systems, 77(2), 361–375.
- Hinterstoisser S., Cagniard C., Ilic S., Sturm P., Navab N., Fua P., and Lepetit V., 2012. Gradient response maps for real-time detection of textureless objects. IEEE Transactions on Pattern Analysis and Machine Intelligence, 34(5), 876–888.
- Hovland G. E., and McCarragher, B. J., 1998. Hidden markov models as a process monitor in robotic assembly. The International Journal of Robotics Research, 17(2), 153–168.
- Inceoglu A., Ince G., Yaslan Y., Sariel S., 2018-1. Comparative Assessment of Sensing Modalities on Manipulation Failure Detection. IEEE International Conference on Robotics and Automation (ICRA) Workshop on Multimodal Robot Perception.
- Inceoglu A., Ince G., Yaslan Y., Sariel S., 2018-2. Failure Detection Using Proprioceptive, Auditory and Visual Modalities. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS).
- Inceoglu A., Koc C., Kanat B. O., Ersen M., and Sariel S., 2018-3. Continuous visual world modeling for autonomous robot manipulation. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 49(1), 192 – 205.
- ISO 10218-2:2011, 2011. Robots and Robotic Devices – Safety Requirements for Industrial Robots – Part 2: Robot Systems and Integration. ISO, Geneva, Switzerland.
- ISO 10218:2011, 2011. Robots and Robotic Devices – Safety Requirements for Industrial Robots – Part 1: Robots. ISO, Geneva, Switzerland.
- Kapotoglu M., Koc C., Sariel S., and Ince G., 2014. Action monitoring in cognitive robots. The 22nd Signal Processing and Communications Applications Conference (SIU), 2154–2157.
- Kirchner D., and Geigs K., 2014. Qualitative bayesian failure diagnosis for robot systems. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS).
- Kvarnström J., Heintz F., and Doherty P., 2008. A temporal logic-based planning and execution monitoring system. ICAPS, 198–205.
- Logan B., 2000. Mel frequency cepstral coefficients for music modeling. International Symposium on Music Information Retrieval (ISMIR).
- Mendoza J. P., Veloso M., and Simmons R., 2012. Mobile robot fault detection based on redundant information statistics. IEEE/RSJ International Conference on Intelligent Robots and Systems.
- Mendoza J. P., Veloso M., and Simmons R., 2015. Plan execution monitoring through detection of unmet expectations about action outcomes. IEEE International Conference on Robotics and Automation (ICRA), 3247–3252.
- Mendoza J. P., Veloso M., Simmons R., 2014. Focused optimization for online detection of anomalous regions. IEEE International Conference on Robotics and Automation (ICRA), 3358–3363.
- Micalizio R., 2013. Action failure recovery via model-based diagnosis and conformant planning. Computational Intelligence, 29(2), 233–280.
- Orendt E. M. and Henrich D., 2015. Design of robust robot programs: Deviation detection and classification using

- entity-based resources. IEEE International Conference on Robotics and Biomimetics (ROBIO), 1704–1710.
- Pearson K., 1901. On lines and planes of closest fit to systems of points in space. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 2(11), 559–572.
- Pettersson O., 2005. Execution monitoring in robotics: A survey. *Robotics and Autonomous Systems*, 53(2), 73–88.
- Pettersson O., Karlsson L., and Saffiotti A., 2007. Model-free execution monitoring in behavior-based robotics. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 37(4), 890–901.
- ROS, 2022: <http://www.ros.org/>, 12.09.2022.
- Rubinstein R., 1999. The cross-entropy method for combinatorial and continuous optimization. *Methodology and Computing in Applied Probability*, 1(2), 127–190.
- Saied M., Lussier B., Fantoni I., Francis C., Shraim H., and Sanahuja G., 2015. Fault diagnosis and fault-tolerant control strategy for rotor failure in an octorotor. *IEEE International Conference on Robotics and Automation (ICRA)*.
- Sassi I., Gouin A., and Thiriet J., 2016. A Bayesian Network for Diagnosis of Networked Mobile Robots. *Risk, Reliability and Safety: Innovating Theory and Practice (ESREL)*.
- Schleyer G. and Russell R. A., 2011. Disturbance and failure classification in walking robots. *Australasian Conference on Robotics and Automation*, 1–8.
- Stavrou D., Eliades D. G., Panayiotou C. G., and Polycarpou M., 2015. Fault detection for service mobile robots using model-based method. *Autonomous Robots* 40(1), 383–394.



# Yapay Öğrenme ile Farklı Akıllı Ulaşım Senaryoları Altında Araçtan Her Şeye Haberleşme Standardı Seçimi

Hakan Alp Eren<sup>1\*</sup>, Nihat Adar<sup>2</sup>, Ahmet Yazar<sup>3</sup>

<sup>1,3</sup> Eskişehir Osmangazi Üniversitesi, Yazılım Mühendisliği Bölümü, Eskişehir, Türkiye

<sup>2</sup> Eskişehir Osmangazi Üniversitesi, Bilgisayar Mühendisliği Bölümü, Eskişehir, Türkiye

erenhalp@gmail.com, nadar@ogu.edu.tr, ahmet.yazar@ogu.edu.tr

## Öz

Akıllı ulaşım sistemlerine yönelik çalışmaların son yıllarda artmasıyla birlikte araçtan her şeye (V2X) haberleşme konsepti için farklı standartların geliştirilmesi önem kazanmıştır. Bu doğrultuda 5. Nesil (5G) haberleşmesine yön veren 3GPP ve Wi-Fi haberleşmesine yön veren IEEE gibi organizasyonlar farklı V2X standartları geliştirmişlerdir. Farklı senaryolarda bu iki kritik standardın birbirlerine karşı üstünlükleri olabileceğini gösteren çeşitli çalışmalar bulunmaktadır. Önerilen yöntem ile birlikte farklı şartlar altında 3GPP ve IEEE standartlarından hangisinin kullanılmasının daha avantajlı olacağı yapay öğrenme teknikleri ile belirlenmekte ve uygun V2X standardı otomatik olarak seçilmektedir. Bu kapsamda araçta ve çevre sistemlerinde her iki standartla ilişkili donanımların bulunduğu varsayılmaktadır. Bu amaca yönelik yeni bir yapay veri seti oluşturulmuş ve K-en yakın komşu, karar ağacı, yapay sinir ağı ile TabNet sınıflandırıcıları kullanılarak çeşitli yapay öğrenme modelleri eğitilmiştir. Ayrıca çapraz doğrulama ile hiperparametre optimizasyonu gerçekleştirilmiştir. TabNet sınıflandırıcısı ile doğruluk değeri ve ağırlıklı F1 skoru 0.88 olarak elde edilmiştir. Tüm bu çalışmalar beraber ele alındığında, V2X haberleşmesine yönelik özgün bir çalışma yapılarak literatüre önemli bir katkı sağlandığı görülmüştür. Geliştirilen yapay öğrenme tabanlı V2X standardı seçirme yönteminin akıllı ulaşım sistemleri altındaki araçlara entegre edilebileceği düşünülmektedir.

**Anahtar kelimeler:** 5G, Akıllı Ulaşım, Araçtan Her Şeye Haberleşme, TabNet, Yapay Öğrenme.

## Vehicle-to-Everything Communications Standard Selection Under Different Intelligent Transportation Scenarios with Artificial Learning

### Abstract

It has become important to develop different standards for vehicle-to-everything (V2X) communications concept with the increase in studies on intelligent transportation systems in recent years. In this direction, organizations such as 3GPP, which leads 5th Generation (5G) communications, and IEEE, which leads Wi-Fi communications, have developed different V2X standards. There are various studies showing that these two critical standards may have advantages over each other in different scenarios. With the proposed method, which of 3GPP and IEEE standards will be more advantageous under different conditions is determined by artificial learning techniques and appropriate V2X standard is selected automatically. In this context, it is assumed that there is related equipment for each of the two standards in the vehicle and its environmental systems. For this purpose, a new artificial dataset was created, and various artificial learning models were trained using K-nearest neighbor, decision tree, artificial neural network and TabNet classifiers. In addition, hyperparameter optimization was performed with cross validation. With the TabNet classifier, the accuracy value and the weighted F1 score were obtained as 0.88. When all these studies are considered together, it has been seen that a significant contribution to the literature has been made by conducting a novel study on V2X communications. It is thought that the developed artificial learning based V2X standard selection method can be integrated into vehicles under intelligent transportation systems.

**Keywords:** 5G, Intelligent Transportation, Vehicle-to-Everything Communications, TabNet, Artificial Learning.

\* Sorumlu yazar.  
E-posta adresi: erenhalp@gmail.com

Alındı : 21 Ekim 2022  
Revizyon : 5 Şubat 2023  
Kabul : 23 Şubat 2023

## 1. Giriş (Introduction)

Nesnelerin interneti (IoT) ve akıllı sistemler gibi kavramların 5. Nesil (5G) hücreli haberleşme sistemleri ile birlikte uygulamada daha çok yaygınlaşacak olmasıyla, akıllı ulaşım ve araçtan her şeye (V2X) haberleşme sistemleri de giderek daha fazla önem kazanmaya başlamıştır. 2010'lu yılların başında standartlaştırma çalışmaları hız kazanan V2X sistemleri günümüzde kritik bir haberleşme altyapısına dönüşmüştür (Filippi vd., 2017). 2030'lu yıllarda kullanılmaya başlanacağı öngörülen 6. Nesil (6G) kablosuz haberleşme sistemlerinde ise V2X konseptinin rolünün çok daha büyük olacağı düşünülmektedir (Yazar vd., 2020; Yazar, 2021). Tüm bu gelişmelere bakıldığında, V2X haberleşme standartlarına yönelik yapılan çalışmaların kritik öneme sahip olduğu değerlendirilmektedir.

Yaygın olarak kullanılmaya başlanan V2X standartları incelendiğinde, 5G haberleşmesine yön veren 3GPP ve Wi-Fi haberleşmesine yön veren IEEE organizasyonları tarafından iki farklı standardın geliştirildiği görülmektedir (MacHardy vd., 2018). Sırasıyla C-V2X ve IEEE 802.11p standartları çerçevesinde sürekli olarak yeni iyileştirmeler yapılmaktadır. Bu çerçevede iki ana standardın birbirlerine karşı farklı üstünlükleri oluşabilmektedir (Naik vd., 2019). Mevcut literatüre bakıldığında bu üstünlüklerin incelendiği çalışmalara rastlanmaktadır (Zhao vd., 2018; Ullah vd., 2019; Naik vd., 2019; Shrestha vd., 2020). Bununla birlikte, hangi standardın hangi şartlar altında kullanılmasının daha çok fayda sağlayacağını otomatik belirlenmesine yönelik yöntem geliştirme çalışmalarının bulunmadığı görülmektedir. Örneğin, bir akıllı araçta ve haberleşeceği çevre sistemlerinde her iki standartla ilişkili donanımların bulunduğu varsayımda, anlık olarak hangi standart ile haberleşilmesi gerektiğinin kararına ihtiyaç duyulacaktır.

Yukarıda bahsedilen V2X haberleşme standartlarının farklı özellikler açısından güçlü ve zayıf yönleri bulunduğundan dolayı, bu standartlar arasından kullanılacak en uygun olanın tespiti için haberleşme gereksinimlerinin ve sistem özelliklerinin analiz edilmesi gerekmektedir. Sonrasında bu analiz temel alınarak hangi senaryolar altında hangi standardın kullanılmasının daha avantajlı olacağını kararı verdirilebilecektir. Bu çalışmada önerilen yöntem ile birlikte bu karar verme sürecine yapay öğrenme modellerinin dahil edilmesi sağlanarak uygun V2X haberleşme standardının bulunmasının zaman ve insan gücü bakımından verimli hale getirilmesi sağlanmıştır. Bu yöntemeye dayalı olarak geliştirilen uygulamanın akıllı araç üreticilerine, son kullanıcılara ve akıllı ulaşım alanında çalışan araştırmacılara faydalı olacağı düşünülmektedir. Geliştirilen uygulama akıllı araç üreticileri tarafından daha verimli çalışan bir V2X haberleşme sistemi oluşturulması noktasında fayda

getirirken, araç sahiplerinin ise bu kapsamda daha iyi bir hizmet alabilmesi sağlanacaktır. Ayrıca araç üreticileri kendi çözümlerini bu çalışmada geliştirilen yöntem üzerine kurgulayabileceklerdir.

Makalenin 2. bölümünde V2X haberleşme sistemleri ile ilgili olarak yapılan kaynak araştırmasına yer verilmiştir. 3. bölüm kapsamında veri seti ve kullanılan yapay öğrenme modelleri tanıtılmıştır. Modellerden elde edilen sonuçlara ait performans metrikleri 4. bölümde sunulmuştur. Son olarak 5. bölümde sonuç ve tartışmalar yer almaktadır.

## 2. Kaynak Araştırması (Literature Survey)

Literatürdeki benzer çalışmalar incelendiğinde hizmet kalitesi tahmini, araç haberleşme ağlarında hatalı davranış tespiti, V2X ağlarında performans tahmini, 5G hücreli ağ analizi, gecikme tahmini, zaman-frekans analizi ile V2X teknolojisinin tespit edilmesi gibi konuların ele alındığı görülmektedir. Fakat bu çalışmaların hiçbirinde farklı V2X haberleşme standartları arasında seçim yaptırılmasına yönelik bir yöntemin geliştirilmediği görülmektedir.

Moreira vd. (2020) bir V2X haberleşme senaryosu üzerinde makine öğrenmesi ile bir paketin teslim edilmesindeki hizmet kalitesini tahmin etmeye çalışmışlardır. İşlemin istenen gecikme süresi içerisinde gerçekleştirilip gerçekleştirilemeyeceğini gösterecek şekilde ikili sınıflandırma yapılmaktadır. Simülasyon aracılığıyla elde edilen sonuçlar incelendiğinde hizmet kalitesi seviyesinin iki saniye önceden %85 güvenilirlikle tahmin edilebildiği sonucuna ulaşılmaktadır. Ancak çalışmada ele alınan senaryonun hücreli haberleşme üzerine olması nedeniyle sadece 3GPP standardına odaklanılmaktadır.

Abdellah vd. (2021) V2X trafiğinin performansını tahmin amacıyla 3GPP standardı altındaki 5G ağları için derin öğrenme modeli oluşturmuşlardır. Modelin aykırı değerlerden daha az etkilenmesi ve eğitimin iyileştirilmesi için M-tahmin ediciler kullanılarak yeni kayıp fonksiyonları önerilmektedir. Ortalama kare hatası (MSE) fonksiyonu ile karşılaştırıldığında önerilen fonksiyonlar ile sağlaştıran modelin daha başarılı sonuçlar sağladığı gözlemlenmektedir.

Gyawali ve Qian (2019), araç iletişim ağlarındaki hataların tespit edilmesini sağlayan bir sistem önermişlerdir. Veri seti oluşturmak için araç ağı ortamı kapsamlı olarak simüle edilmiştir. Farklı makine öğrenmesi modelleri ile yapılan testlerde yüksek kesinlik, duyarlılık ve F1 skoru değerlerine ulaşılmıştır.

Sevgican vd. (2020) 5G hücreli ağları analiz etmeyi sağlayan yeni bir sistem sunmuşlardır. Oluşturulan modeller ağ yükünü tahmin etme ve anomalileri tespit etme üzere iki farklı problemi çözmek için kullanılmaktadır. Ağ yükünü tahmin etmek için zaman serisi analizi ile doğrusal regresyon, uzun kısa süreli bellek (LSTM) ve özyinelemeli sinir ağı (RNN) modelleri eğitilmiş ve MSE azaltılmaya çalışılmıştır. İkinci problem olan anomali tespitinde ise doğrusal

regresyon ve ekstrem gradyan artırma (XGBoost) ile alıcı işlem karakteristiği (ROC) eğrisinin altında kalan alanın artırılması hedeflenmiştir. Model eğitimi için sentetik 5G hücresele ağ veri seti üretilmiştir. Deneyler sonucunda her iki problem için de diğer modellerin doğrusal regresyondan daha fazla başarı gösterdiği tespit edilmiştir.

Zhang vd. (2020) gecikmeye duyarlı V2X uygulamaları için gecikmenin tahmin edilmesini sağlayan bir çatı geliştirmişlerdir. Bu çalışmada kullanılan veriler, LTE tabanlı bir ağda çeşitli hareket senaryolarını içeren sürüşlerden gecikme değerlerinin ölçülmesi ile elde edilmiştir. Veriler işlenerek zaman içindeki gecikme eğilimini gösteren ve rastgele gürültü gibi davranan olmak üzere iki bileşene ayrılmıştır. Bu bileşenler için LSTM ve K-medoids algoritmalarına ek olarak Epanechnikov çekirdeği ve hareketli ortalama fonksiyonlarının birleşiminden oluşan bir yöntem önerilmiştir. Sonuçlar incelendiğinde önerilen yöntemin tahminlerdeki hatayı azaltmada etkili olduğu görülmüştür.

Zhang vd. (2019) araçtan altyapıya (V2I) kullanıcıları için haberleşme kapasitesini maksimize etmek amacıyla V2X hücresele haberleşmede uygun iletim modunu seçme ve kaynak tahsisini gerçekleştirme üzerine çalışmışlardır. Problem bir Markov karar süreci (MDP) modeli ile ifade edilmiş ve çözüm için derin pekiştirmeli öğrenme (DRL) kullanılmıştır. Simülasyon sonuçları, önerilen yöntemin gecikme ve güvenilirlik gereksinimleri doğrultusunda problemin optimizasyonu için etkili olduğunu doğrulamıştır.

Skiribou ve Elbahhar (2021), makine öğrenmesi ile V2X haberleşme sinyallerinin tanınması için anlık frekans (IF) öznelik vektörünü kullanmışlardır. Zaman-frekans analizinden elde edilen bu vektörün boyutu, tekil değer ayrıştırması (SVD) ile küçültülmüştür. Rastgele orman modeli ile ITS-G5 sinyalleri için %100 doğruluk elde edilmiştir. LTE-V2X ve NR-V2X sinyalleri için kesinlik, duyarlılık ve F1 skoru değerleri 0.99 olarak gözlemlenmiştir.

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

#### 3.1. Veri seti (Dataset)

V2X haberleşmesi için 3GPP ve IEEE standartlarının haberleşme gereksinimleri açısından karşılaştırıldığı çalışmalar (Zhao vd., 2018; Ullah vd., 2019; Naik vd., 2019; Shrestha vd., 2020) incelendiğinde hem şebeke mimarisi hem de fiziksel katman özelliklerinden dolayı IEEE standardının iletim gecikmeleri noktasında daha başarılı olduğu görülmektedir. Buna karşılık, 3GPP standardının haberleşme kapasitesi ve kapsama alanı ölçütleri açısından daha ön plana çıktığı tespit edilmiştir. Yapılan çalışma kapsamında farklı performans ölçütleri ile akıllı ulaşım senaryoları arasında Tablo 1 üzerindeki ilk sütunda verilen çeşitli senaryo bilgileri üzerinden bağ kurulmuştur. Arka planda, farklı akıllı ulaşım

senaryolarındaki kablosuz haberleşme kanalının genel olarak değişimi incelenmiştir. Dolayısıyla kablosuz haberleşme kanalına doğrudan bakmadan, ona etki edebilecek karakteristik senaryo bilgileri temel alınarak çalışmaya dahil edilmiştir.

Literatür taraması sonucunda V2X haberleşmesinde uygun standardın belirlenmesine yönelik bir veri setinin mevcut olmadığı görülmektedir. Bu problemi çözmek için veri üretme amacıyla farklı yöntemler karşımıza çıkmaktadır. Benzer konularda çalışma yapmış araştırmacılar, amaçlarına yönelik verileri yapay olarak üretmişlerdir.

Yapay veri setinin oluşturulması amacıyla MATLAB platformu üzerinde bir komut dizisi hazırlanmıştır. Bu komut dizisi, Tablo 1 üzerinde verilen öznelikleri birbirleriyle ilişkili olabilecek şekilde rastgele olarak 1-10 değerleri arasında ve ölçüt sütununda verilen iki genel tanım arasında değişiklik gösterecek şekilde üretmektedir. Veri etiketleme için ayrı bir mekanizma oluşturulmuş, otomatik ve elle olacak şekilde hibrit bir etiketleme süreci sürdürülmüştür. Bu hibrit mekanizmanın otomatik çalışan kısmının ilk aşamasında öznelikler oluşturulmadan önce sınıf etiketleri üretilmektedir. Öznelikler ise bu sınıf etiketleri ile uyumlu ve rastgele olacak şekilde yukarıda bahsedilen komut dizisi aracılığıyla oluşturulmaktadır. Hibrit veri etiketleme mekanizmasının otomatik çalışan kısmının ikinci aşaması öznelikler oluşturulduktan sonra devreye girmektedir. Bu aşamadaki amaç, sınıf etiketleri ile ilişkili olarak rastgele üretilen özneliklere bakarak, bazı özel tanımlı kurallar dikkate alınarak gerçekleşmesi mümkün olmayan durumlara karşılık gelen örneklemelerin veri setinden çıkarılmasıdır. Otomatik çalışan kısmın devamında ise eğer belirsiz olabilecek durumlar tespit edilmişse, bu durumların elle düzeltilmesine imkân tanımak için uyarı oluşturulmaktadır. Nihai veri setine bakıldığında sınıf etiketi, verilen öznelik değerlerine göre, hangi haberleşme standardının daha iyi bir çözüm sunacağı noktasında ulaşılan kararı göstermektedir. 5957 adet 3GPP ve 4043 adet IEEE sınıfına ait örnek içeren veri setinde toplamda 10000 örnek bulunmaktadır.


**Tablo 1.** Veri setindeki öznelikler ve sınıf etiketi (Features and class label in the dataset)

Öznelikler ve Sınıf Etiketleri	Ölçüt	Değer
Coğrafya özellikleri	Zorlu – Basit	1 – 10
Yerleşim özellikleri	Kentsel – Kırsal	1 – 10
Araç yoğunluğu	Yoğun – Seyrek	1 – 10
Yaya yoğunluğu	Yoğun – Seyrek	1 – 10
Veri hızı gereksinimi	Kritik – Normal	1 – 10
Güvenilirlik gereksinimi	Kritik – Normal	1 – 10
Gecikme gereksinimi	Kritik – Normal	1 – 10
Kapsama gereksinimi	Kritik – Normal	1 – 10
Standart	3GPP, IEEE	0, 1

### 3.2. Deney tasarımı (Experiment design)

Deney başlangıcında veri seti karıştırılarak 8000 adet eğitim ve 2000 adet test verisi olacak şekilde alt setlere ayrılmıştır. Ayırma işlemi tabakalı olarak gerçekleştirilerek orijinal veri setindeki sınıf etiketi dağılım oranının alt setlerde de korunması hedeflenmiştir. Sınıf etiketlerine ait örnek sayıları 3GPP için 5957 ve IEEE için 4043 olduğundan dolayı alt setlerde de yaklaşık olarak 6/4 oranı bulunmaktadır. Eğitim veri seti, çapraz doğrulamada kullanılmak üzere kendi içinde beş parçaya bölünmüştür. Bu aşamada da karıştırma ve tabakalı ayırma yapılarak dengesiz dağılımların önüne geçilmiştir. Çapraz doğrulama sonuçları karşılaştırılarak en başarılı sonuca sahip

hiperparametre değerleri tespit edilmiştir. Son aşamada modeller optimize edilmiş hiperparametre değerleri ve eğitim seti ile eğitilerek, test seti üzerinde sınanmıştır. Bu işlemler, Şekil 1'de verilen diyagramda özetlenmiştir. Veri setinin parçalara bölünmesi, sınıflandırma metriklerinin hesaplanması ve makine öğrenmesi modellerinin oluşturulmasında Scikit-Learn (Pedregosa vd., 2011) modülünden faydalanılmıştır. Ayrıca dizi ve veri çerçevesi yapıları üzerinde gerçekleştirilecek işlemler için NumPy (Harris vd., 2020) ve Pandas (McKinney, 2010) kütüphaneleri kullanılmıştır. Proje kapsamında kullanılan veri seti, deney kodları ve model dosyalarına <https://github.com/haeren/vehxcom> adresinden erişilebilmektedir.



Şekil 1. Deney tasarımı (Experiment design)

### 3.3. Sınıflandırmada kullanılan modeller (Models used for classification)

Deneylerde makine öğrenmesi ve derin öğrenme algoritmalarını kullanan dört adet sınıflandırma modeli yer almaktadır. İlk olarak en basit makine öğrenmesi algoritmalarından biri olan K-en yakın komşu kullanılmıştır. Ardından tablo halindeki verilerde başarılı olmasıyla bilinen karar ağacı modeli oluşturulmuştur. Son olarak yapay sinir ağı sınıflandırıcısı ve tablo şeklindeki veriler ile birlikte kullanılmak üzere tasarlanan bir derin öğrenme yöntemi olan TabNet modeline yer verilmiştir.

K-en yakın komşu algoritması, test edilen örnek ve eğitim kümesindeki veriler arasındaki uzaklıkları hesaplayarak sınıflandırma işlemini gerçekleştirmektedir.  $\mathbb{R}^q$ 'da uzaklık hesaplamak için Eşitlik (1)'de verilen Minkowski metriği tercih edilmektedir (Kramer, 2013). Eşitlikteki p değeri değiştirilerek sınıflandırma sırasında farklı türdeki uzunluklar kullanılabilir. Örneğin p = 1 için Manhattan ve p = 2 için Öklid uzaklıkları elde edilmektedir. Bu çalışmada oluşturulan modellerde Öklid uzunluğu ile sınıflandırma yapılmaktadır. Test edilen örneğin x olarak kabul edilmesi durumunda y, eğitim kümesindeki bir örneği temsil etmektedir. Bu iki

veri arasındaki uzaklık, q adet özneliğin mutlak farklarının toplanması ile hesaplanmaktadır.

$$\|x - y\|^p = \left( \sum_{i=1}^q |x_i - y_i|^p \right)^{1/p} \quad (1)$$

K-en yakın komşu algoritmasındaki en önemli hiperparametrelerden biri olan komşu sayısı, k ile ifade edilmektedir. Uzunluklar hesaplandıktan sonra test edilen örneğe en yakın k adet komşu belirlenmektedir. Belirlenen komşular içerisinde çoğunluğu oluşturan sınıf etiketi, tahmin sonucunu vermektedir. Dolayısıyla oylamada beraberliği önlemek için genellikle tek sayıda komşu seçilmesi önerilmektedir. Gerçekleştirilen deneylerde çapraz doğrulama ile modelin farklı sayıdaki komşular için başarısı gözlemlenmiştir.

Karar ağacı algoritması ile sınıflandırma, eğitim verilerinin alt kümelerine ayrılacak şekilde bölünmesi sonucunda oluşturulan ağaç yapısı üzerinden ilerleyerek gerçekleştirilmektedir. Bu yapı, veri setindeki herhangi bir özneliğin belirli bir koşulu sağlayıp sağlamadığına bağlı olarak dallanan düğümlerden oluşmaktadır. Bölünme sırasında hedef, sınıf etiketlerinin karışmasını minimize eden özneliği ve koşulu belirleyerek olabildiğince saf alt kümeler elde etmektir (Tangirala, 2020). Bu amaç doğrultusunda bölünmenin kalitesini




değerlendirebilmek için yaygın olarak kullanılan kriterler olan entropi ve Gini Eşitlik (2) ve (3)'te gösterilmektedir.

$$\text{Entropi} = -\sum_{i=1}^c p_i \log_2 p_i \quad (2)$$

$$\text{Gini} = 1 - \sum_{i=1}^c p_i^2 \quad (3)$$

Herhangi bir değişkenle ilişkili belirsizliğin ölçülmesinde entropi kullanılmaktadır. Belirsizlikle orantılı bir şekilde artan veya azalan entropinin minimum değeri 0 iken maksimum değeri sınıf sayısına bağlı olarak değişmektedir. Üretilen veri setine benzer bir şekilde iki sınıf bulunması durumunda entropinin değer aralığı [0, 1] olmaktadır. Eşitlik (2)'de  $p_i$ , veri setinden rastgele seçilen bir elemanın  $i$  sınıfına ait olma olasılığını ifade etmektedir (Rahmati vd., 2020). Gini indeksi ise safsızlığı ölçen bir öznitelik ölçüsüdür. Minimum Gini indeksine sahip öznitelik, bölme işleminde kullanılmaktadır (Gupta vd., 2017). Her iki kriter için de çapraz doğrulama yapılmış ve sonuçlar karşılaştırılmıştır.

Yapay sinir ağı, nöronlardan oluşan katmanların birbirlerine bağlanması ile elde edilen bir model mimarisidir. Eğitim boyunca nöronlardaki ağırlıkların güncellenerek modelin daha başarılı tahminler yapması hedeflenmektedir. Basit bir sinir ağı yapısında birer adet girdi ve çıktı katmanı ile bu katmanlar arasındaki gizli katmanlar yer almaktadır. Oluşturulan sinir ağına 8 nörona sahip girdi katmanı ve 1 nörona sahip çıktı katmanı bulunmaktadır. Ek olarak 64 nörona sahip gizli katmanlar kullanılmıştır. Gizli katmanlara ReLU ve çıktı katmanına sigmoid aktivasyon fonksiyonu eklenmiştir. Sinir ağının mimarisi Şekil 2'de gösterilmektedir. Model, Keras API (Chollet, 2018) kullanılarak oluşturulmuştur.



Şekil 2. Yapay sinir ağı mimarisi (Artificial neural network architecture)

Ele alınan problemin ikili sınıflandırma içermesinden dolayı modelde kayıp fonksiyonu olarak ikili çapraz entropi kullanılmıştır. Eniyileştirici (optimizer) için Adam ve değerlendirme ölçütü için doğruluk tercih edilmiştir. Eğitimde maksimum evre sayısı (epoch) 100 seçilmiş ve erken durdurma mekanizması ile aşırı öğrenmenin engellenmesi hedeflenmiştir. Bu sayede doğruluk değerinin 15 evre boyunca iyileşmemesi sonucunda eğitim


durdurulmaktadır. Farklı yığın boyutları (batch size) için çapraz doğrulama yapılarak daha başarılı sonuçlar veren boyutun bulunması hedeflenmiştir.

TabNet (Arık ve Pfister, 2021), tablo şeklindeki veriler için önerilmiş bir derin öğrenme mimarisidir. Ardışık dikkat (sequential attention) mekanizması ile karar adımlarının her birinde kullanılacak öznitelikleri belirlemektedir. Öznitelik seçiminin örnek tabanlı olarak gerçekleştirilmesi, öğrenme kapasitesinin en dikkat çekici öznitelikler için kullanılmasını sağlamaktadır. Bu sayede yorumlanabilirlik ve daha başarılı bir öğrenme elde edilmektedir. Farklı veri setleri ile yapılan testlerde TabNet modellerinin, XGBoost (Chen vd., 2015) ve LightGBM (Ke vd., 2017) yöntemlerini geride bıraktığı görülmektedir (Arık ve Pfister, 2021).

Deneylerde kullanılan TabNet modeline ait parametrelerin değerleri, yapay sinir ağındaki değerlere benzer şekilde seçilmiştir. Kayıp fonksiyonu olarak çapraz entropi ve eniyileştirici olarak Adam kullanılan modelde değerlendirme ölçütü için doğruluk tercih edilmiştir. Maksimum evre sayısı 100 ve tahammül (patience) değeri 15 olarak belirlenerek farklı yığın boyutları için çapraz doğrulama gerçekleştirilmiştir.

### 3.4. Kullanıcı arayüzü tasarımı (User interface design)

Geliştirilen sistemin araçlara entegre edilmesi durumunda kullanıcıların da bilgilendirilmesi için minimum sayıda bileşen kullanılarak sade bir kullanıcı arayüzü tasarlanmıştır. Gerçekleştirilen eğitimler sonucunda elde edilen en başarılı model arka planda kullanılarak çeşitli V2X haberleşme senaryoları için en uygun haberleşme standardının bulunabilmesi hedeflenmektedir. Tasarlanan arayüz ile örnek bir senaryonun sınıflandırılması Şekil 3'te gösterilmektedir.



Şekil 3. Kullanıcı arayüzü ile sınıflandırma (Classification with user interface)

#### 4. Deneysel Sonuçlar (Experimental Results)

Modellerin farklı hiperparametre değerleri için çapraz doğrulama sonuçları incelenerek en yüksek başarıyı sağlayan değerler tespit edilmiştir. Test aşamasında doğruluğa ek olarak karışıklık matrisinden türeyen diğer metrikler olan kesinlik, duyarlılık ve F1 skoru değerleri gösterilmektedir. Modellerin performansları hem sınıf bazında hem de makro ortalama ve ağırlıklı ortalama olarak analiz edilmiştir.

K-en yakın komşu sınıflandırıcısı ile yapılan çapraz doğrulamada en başarılı sonuç  $K = 17$  komşu için elde edilmiştir. Tablo 2'deki sonuçlar ardışık olarak artan komşu sayılarına göre incelendiğinde tek sayıdaki komşular için daha başarılı olduğu gözlemlenmektedir. Buna ek olarak komşu sayısı artırıldığında 17 komşuya kadar olan tek ve çift sayıdaki komşuların kendi içlerinde doğruluk değerlerinin yükseldiği görülmektedir.

Tablo 6'da görülebileceği üzere K-en yakın komşu modeli, test setinde 1031 gerçek pozitif ve 575 gerçek negatif olmak üzere toplamda 1606 adet örneği doğru olarak sınıflandırarak 0.803 doğruluk değerine ulaşmıştır. Tablo 7'deki diğer metrikler sınıf bazında incelendiğinde 3GPP sınıfının daha yüksek değerlere sahip olduğu görülmektedir. 3GPP sınıfı için duyarlılık daha fazla iken IEEE sınıfı için ise kesinlik değerinin daha yüksek olması dikkat çekmektedir. IEEE sınıfını tespit edebilmenin önemli olduğu durumlarda bu modelin kullanılması tavsiye edilmemektedir.

**Tablo 2.** Farklı komşu sayıları için doğrulama sonuçları (Validation results for different numbers of neighbors)

Komşu	Doğruluk	Komşu	Doğruluk
1	0.753625	11	0.811125
2	0.751000	12	0.808250
3	0.784125	13	0.812375
4	0.778500	14	0.810625
5	0.797750	15	0.815750
6	0.797000	16	0.811750
7	0.802875	17	0.816250
8	0.799250	18	0.811375
9	0.804625	19	0.813125
10	0.804625	20	0.812375

Farklı kriterlerin kullanıldığı karar ağacı sınıflandırıcılarında birbirine oldukça yakın sonuçlar elde edilmiştir. Tablo 3'te verilen doğrulama sonuçlarına bakıldığında entropi kriteri ile bir miktar daha yüksek doğruluğa ulaşıldığı gözlemlenmektedir.

Karar ağacı modelinin test verisi üzerindeki sonuçlarına ait karışıklık matrisi Tablo 6'da gösterilmektedir. Test seti üzerinde 0.8325 doğruluk değerine sahip modelin kesinlik, duyarlılık ve F1 skoru değerleri Tablo 7'de detaylı olarak verilmektedir. Modelin 3GPP sınıfı için daha başarılı sonuçlar verdiği görülmektedir. K-en yakın komşu sınıflandırıcısından farklı olarak sınıf içinde birbirine benzer kesinlik ve duyarlılık değerleri elde edilmiştir.

**Tablo 3.** Farklı kriterlere sahip ağaçlar için doğrulama sonuçları (Validation results for trees with different criteria)

Kriter	Doğruluk
Gini	0.846375
Entropi	0.847625

Çapraz doğrulamada 128, 256, 512 ve 1024 olmak üzere farklı yığın boyutları ile eğitilen yapay sinir ağı modellerinin doğruluk değerleri Tablo 4'tedir. En başarılı modelin yığın boyutu için 128 seçildiğinde elde edildiği ve boyut artırıldıkça başarının düştüğü gözlemlenmektedir.

Yapay sinir ağı sınıflandırıcısı ile test veri setindeki örneklerin sınıflandırılması sonucu elde edilen Tablo 6'daki karışıklık matrisi, 0.819 doğruluk değerine ulaşıldığını ifade etmektedir. Tablo 7'deki sınıflandırma metriklerine göre model, 3GPP sınıfını tahmin etmede daha başarılı olmaktadır. K-en yakın komşu sınıflandırıcısındaki benzer şekilde 3GPP sınıfı için duyarlılık ve IEEE sınıfı için kesinlik daha yüksektir.

**Tablo 4.** Yapay sinir ağına farklı yığın boyutları için doğrulama sonuçları (Validation results for different batch sizes in artificial neural network)

Yığın boyutu	Doğruluk
128	0.8177500009536743
256	0.8142499923706055
512	0.8091249942779541
1024	0.8024999856948852

Farklı büyüklükteki yığınlar ile eğitilmiş TabNet modellerine ait çapraz doğrulama sonuçları Tablo 5'te gösterilmektedir. Yapay sinir ağındaki duruma benzer olarak en başarılı modelin 128 boyutundaki yığınlar ile eğitim gerçekleştirildiğinde elde edildiği ve bu sayının artırıldıkça başarının düştüğü görülmektedir.

TabNet sınıflandırıcısı kullanılarak test seti üzerinde 0.8795 doğruluk değeri elde edildiği gösteren ilgili karışıklık matrisi Tablo 6'da verilmektedir. Tablo 7'deki performans metrikleri sınıf bazında incelendiğinde kesinlik, duyarlılık ve F1 skoru değerlerinin, kullanılan dört sınıflandırıcıda da 3GPP sınıfı için daha yüksek olduğu anlaşılmaktadır. TabNet ile karar ağacı sınıflandırıcısına paralel olarak sınıf içinde birbirine yakın kesinlik ve duyarlılık değerlerine ulaşılmıştır. K-en yakın komşu ve yapay sinir ağı sınıflandırıcılarında ise duyarlılığın 3GPP sınıfı için daha yüksek iken kesinliğin IEEE sınıfı için yüksek olması dikkat çekmektedir. Performans metriklerinin makro ortalama ve ağırlıklı ortalama değerlerine bakıldığında TabNet sınıflandırıcısının diğer modelleri geride bıraktığı görülmektedir. TabNet mimarisinin yüksek başarı göstermesinin sebebi kullanılan ardışık dikkat mekanizması ile öznitelik seçiminin örnek bazında gerçekleştirilmesidir. Modelin öğrenme sürecinde her bir örnek için en önemli öznitelikler seçilerek verim artırılmakta ve yorumlanabilirlik sağlanmaktadır (Arık ve Pfister, 2021).

**Tablo 5.** TabNet'te farklı yığın boyutları için doğrulama sonuçları (Validation results for different batch sizes in TabNet)

Yığın boyutu	Doğruluk
128	0.875250
256	0.874250
512	0.866000
1024	0.863625

**Tablo 6.** Karışıklık matrisleri (Confusion matrices)

		Tahmin		
Gerçek	K-en yakın komşu (K = 17)	3GPP	1031	160
		IEEE	234	575
		IEEE	234	575
	Karar ağacı (Kriter = Entropi)	3GPP	1016	175
IEEE		160	649	
Yapay sinir ağı (Yığın boyutu = 128)	3GPP	1050	141	
	IEEE	221	588	
TabNet (Yığın boyutu = 128)	3GPP	1073	118	
	IEEE	123	686	

**Tablo 7.** Sınıflandırma metrikleri (Classification metrics)

Model			Kesinlik	Duyarlılık	F1 skoru	Örnek sayısı
K-en yakın komşu	Sınıf bazında	3GPP	0.82	0.87	0.84	1191
		IEEE	0.78	0.71	0.74	809
	Ağırlıklı ortalama		0.80	0.79	0.79	2000
			0.80	0.80	0.80	2000
Karar ağacı	Sınıf bazında	3GPP	0.86	0.85	0.86	1191
		IEEE	0.79	0.80	0.79	809
	Ağırlıklı ortalama		0.83	0.83	0.83	2000
			0.83	0.83	0.83	2000
Yapay sinir ağı	Sınıf bazında	3GPP	0.83	0.88	0.85	1191
		IEEE	0.81	0.73	0.76	809
	Ağırlıklı ortalama		0.82	0.80	0.81	2000
			0.82	0.82	0.82	2000
TabNet	Sınıf bazında	3GPP	0.90	0.90	0.90	1191
		IEEE	0.85	0.85	0.85	809
	Ağırlıklı ortalama		0.88	0.87	0.87	2000
			0.88	0.88	0.88	2000

## 5. Sonuçlar (Conclusions)

Akıllı ulaşım konseptinin son yıllarda oldukça önem kazanmasıyla birlikte farklı V2X haberleşme standartları geliştirilmiştir. Bu standartların haberleşme gereksinimlerine göre güçlü ve zayıf yanları bulunmaktadır. Dolayısıyla tasarımlarda kullanılacak uygun V2X standardının seçilmesi kritik öneme sahip olacaktır. Bu doğrultuda 3GPP ve IEEE standartları analiz edilerek yapay bir veri seti oluşturulmuştur. Deneysel çeşitli sınıflandırma modelleri kullanılmış ve hiperparametre optimizasyonu gerçekleştirilmiştir. En basit makine öğrenmesi algoritmalarından biri olan K-en yakın komşu sınıflandırıcısı ile 0.80 doğruluk elde edilirken, tablo halindeki veriler üzerinde yüksek performans göstermesiyle bilinen karar ağacı sınıflandırıcısıyla ise 0.83 doğruluk değerine ulaşılmıştır. Bu değer, yapay sinir ağı sınıflandırıcısı kullanıldığında 0.82 olarak gözlemlenmiştir. Son olarak, tablo şeklindeki veriler için geliştirilmiş bir derin öğrenme mimarisi olan TabNet modeli eğitilmiş ve test aşamasında 0.88 doğruluk oranı elde edilmiştir. Sonuçlar karşılaştırıldığında TabNet mimarisinin diğer yapay öğrenme algoritmalarını geride bıraktığı ve sınıf bazında başarının 3GPP standardı için daha yüksek

olduğu görülmektedir. Sınıfların kesinlik ve duyarlılık değerlerinin birbirine yakın olduğu iki sınıflandırıcı olan karar ağacı ve TabNet modelleri, diğer modellere göre daha güvenilir sonuçlar vermektedirler. 3GPP sınıfını tespit etmede bütün modeller 0.84 ve üzeri F1 skorlarına ulaşmışlardır. Fakat K-en yakın komşu ve yapay sinir ağı sınıflandırıcılarının diğer modellere göre daha düşük IEEE sınıfı duyarlılığına sahip olması, bu sınıfı tespit edebilmenin önemli olduğu durumlarda kullanılmamaları gerektiğini ifade etmektedir.

%80'in üzerinde başarıya ulaşıldığını gösteren sonuçlar, önerilen yöntemin akıllı ulaşım sistemleri altındaki araçlara entegre edilmesinin fayda getireceğini göstermektedir. Bu sayede bir akıllı araç üzerinde yer alan her iki haberleşme standardı ile ilgili modülden hangisinin ne zaman daha etkin şekilde kullanılabileceği otomatik olarak belirlenebilecek ve araç sahibi daha yüksek kalitede bir hizmet alabilecektir. Bir başka bakış açısı olarak, araç üreticisi firmalar hangi haberleşme modüllerini nasıl kullanabileceklerine karar verme noktasında bu çalışmadaki yöntemden yararlanabileceklerdir. Diğer bir deyişle araç üreticileri kendi çözümlerini bu çalışmada geliştirilen yöntem üzerine inşa edebileceklerdir. İlerleyen süreçte yapılacak çalışmalarda, mevcut yöntemde sınıf etiketi olarak kullanılan haberleşme standartları için alt sürüm

sayısının artırılması ve farklı yapay öğrenme modellerinin sisteme eklenmesi hedeflenmektedir.

### Teşekkür (Acknowledgment)

Bu çalışma 122E400 no'lu Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) projesi kapsamında desteklenmiştir.

### Kaynaklar (References)

- Abdellah, A. R., Alshahrani, A., Muthanna, A., Koucheryavy, A., 2021. Performance Estimation in V2X Networks Using Deep Learning-Based M-Estimator Loss Functions in the Presence of Outliers. *Symmetry*, 13(11), 2207.
- Arık, S. Ö., Pfister, T., 2021. Tabnet: Attentive interpretable tabular learning. In *Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 35, No. 8, pp. 6679-6687)*.
- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., Chen, K., 2015. Xgboost: extreme gradient boosting. R package version 0.4-2, 1(4), 1-4.
- Chollet, F., 2018. Keras: The python deep learning library. *Astrophysics source code library*, ascl-1806.
- Filippi, A., Moerman, K., Martinez, V., Turley, A., Haran, O., Toledano, R., 2017. IEEE802. 11p ahead of LTE-V2V for safety applications. *Autotalks NXP*, 1, 1-19.
- Gupta, B., Rawat, A., Jain, A., Arora, A., Dhama, N., 2017. Analysis of various decision tree algorithms for classification in data mining. *International Journal of Computer Applications*, 163(8), 15-19.
- Gyawali, S., Qian, Y., 2019. Misbehavior detection using machine learning in vehicular communication networks. In *ICC 2019-2019 IEEE International Conference on Communications (ICC) (pp. 1-6)*. IEEE.
- Harris, C. R., Millman, K. J., Van Der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., ... & Oliphant, T. E., 2020. Array programming with NumPy. *Nature*, 585(7825), 357-362.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., Liu, T. Y., 2017. Lightgbm: A highly efficient gradient boosting decision tree. *Advances in neural information processing systems*, 30.
- Kramer, O., 2013. Dimensionality reduction with unsupervised nearest neighbors (Vol. 51, pp. 13-23). Berlin: Springer.
- MacHardy, Z., Khan, A., Obana, K., Iwashina, S., 2018. V2X access technologies: Regulation, research, and remaining challenges. *IEEE Communications Surveys & Tutorials*, 20(3), 1858-1877.
- McKinney, W., 2010. Data structures for statistical computing in python. In *Proceedings of the 9th Python in Science Conference (Vol. 445, No. 1, pp. 51-56)*.
- Moreira, D. C., Guerreiro, I. M., Sun, W., Cavalcante, C. C., Sousa, D. A., 2020. QoS predictability in V2X communication with machine learning. In *2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring) (pp. 1-5)*. IEEE.
- Naik, G., Choudhury, B., Park, J. M., 2019. IEEE 802.11 bd & 5G NR V2X: Evolution of radio access technologies for V2X communications. *IEEE access*, 7, 70169-70184.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, E., 2011. Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12, 2825-2830.
- Rahmati, O., Avand, M., Yariyan, P., Tiefenbacher, J. P., Azareh, A., Bui, D. T., 2020. Assessment of Gini-, entropy-and ratio-based classification trees for groundwater potential modelling and prediction. *Geocarto International*, 1-20.
- Sevgican, S., Turan, M., Gökarslan, K., Yilmaz, H. B., Tugcu, T., 2020. Intelligent network data analytics function in 5G cellular networks using machine learning. *Journal of Communications and Networks*, 22(3), 269-280.
- Shrestha, R., Nam, S. Y., Bajracharya, R., Kim, S., 2020. Evolution of V2X communication and integration of blockchain for security enhancements. *Electronics*, 9(9), 1338.
- Skiribou, C., Elbahhar, F., 2021. V2X wireless technology identification using time-frequency analysis and random forest classifier. *Sensors*, 21(13), 4286.
- Tangirala, S., 2020. Evaluating the impact of GINI index and information gain on classification using decision tree classifier algorithm. *International Journal of Advanced Computer Science and Applications*, 11(2), 612-619.
- Ullah, H., Nair, N. G., Moore, A., Nugent, C., Muschamp, P., Cuevas, M., 2019. 5G communication: an overview of vehicle-to-everything, drones, and healthcare use-cases. *IEEE Access*, 7, 37251-37268.
- Yazar, A., Dogan-Tusha, S., Arslan, H., 2020. 6G vision: An ultra-flexible perspective. *ITU Journal on Future and Evolving Technologies*, 1(1), 121-140.
- Yazar, A., 2021. Requirement Analysis and Clustering Study for Possible Service Types in 6G Communications. In *IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (pp. 1-4)*. IEEE.
- Zhang, W., Feng, M., Krunz, M., Volos, H., 2020. Latency prediction for delay-sensitive v2x applications in mobile cloud/edge computing systems. In *GLOBECOM 2020-2020 IEEE Global Communications Conference (pp. 1-6)*. IEEE.
- Zhang, X., Peng, M., Yan, S., Sun, Y., 2019. Deep-reinforcement-learning-based mode selection and resource allocation for cellular V2X communications. *IEEE Internet of Things Journal*, 7(7), 6380-6391.
- Zhao, L., Fang, J., Hu, J., Li, Y., Lin, L., Shi, Y., Li, C., 2018. The performance comparison of LTE-V2X and IEEE 802.11p. In *2018 IEEE 87th Vehicular Technology Conference (VTC Spring) (pp. 1-5)*. IEEE.



# Derin Öğrenme Yöntemleri Kullanılarak BT Taramalarında Beyin Kanaması Teşhisinin Karşılaştırmalı Bir Analizi

Tuğrul Hakan Gençtürk<sup>1\*</sup>, Fidan Kaya Gülağız<sup>2</sup>, İsmail Kaya<sup>3</sup>

<sup>1,2,3</sup> Kocaeli Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kocaeli, Türkiye

tuhage@gmail.com, fidan.kaya@kocaeli.edu.tr, hekimikaya@gmail.com

## Öz

Teknolojinin gelişmesiyle birlikte yapay zekâ temelli uygulamalar pek çok alanda destek amaçlı kullanılmaktadır. Sağlık sektörü de bu tür uygulamaların yaygın kullanıldığı alanlardan bir tanesidir. Sağlık sektöründe teknolojik gelişime bağlı olarak meydana gelen bilgi artışı beraberinde radyolojik değerlendirmede uzmanlık gereğini doğurmuştur. Yoğun çalışma saatleri, sağlık kurumlarında her branştan uzmana ulaşamaması ve özellikle acil patolojilerde erken teşhisin önemi göz önünde bulundurulduğunda hekimlere teşhis sürecinde destek olacak uygulamalara olan ihtiyacın önemi anlaşılmaktadır. Çalışma kapsamında Bilgisayarlı Tomografi (BT) görüntüleri kullanılarak beyin kanamalarının tespitini gerçekleştirmek amacıyla güncel derin öğrenme yöntemlerinden GörSEL Geometri Grubu (VGG), Artık Sinir Ağı (ResNet) ve EfficientNet mimarileri yine güncel bir veri kümesi olan PhysioNet'e uygulanmıştır. Modeller doğruluk, kesinlik, hassasiyet ve F1 skor metrikleri kullanılarak hem kendi aralarında hem de literatürdeki çalışmalarla karşılaştırılmıştır. Gerçekleştirilen çalışma ile veri kümesine uygun model seçiminin önemi güncel modeller üzerinden ortaya konulmuştur. EfficientNet-B2 modelinin başarısı hem literatürdeki çalışmalardan hem de makale kapsamında değerlendirilen modellerden yüksek olmuştur. Elde edilen sonuçlar güncel derin öğrenme modellerinin, beyin kanaması teşhisine yardımcı olabilecek potansiyelde olduğunu göstermiştir. Çalışma acil servislerin yükünü çeken pratisyen hekimleri en azından beyin kanamasının varlığı konusunda uyarıp kanama durumunun gözden kaçmamasını sağlaması ve erken teşhisi açısından önem arz etmektedir.

**Anahtar kelimeler:** Beyin kanaması, BT, Derin Öğrenme, EfficientNet, ResNet, VGG

## A Comparative Analysis of Brain Hemorrhage Diagnosis on CT Scans Using Deep Learning Methods

### Abstract

With the development of technology, artificial intelligence-based applications are used for support in many areas. The health sector is one of the areas where such applications are widely used. The increase in knowledge in the health sector due to technological development has led to the need for expertise in radiological evaluation. Considering the intensive working hours, the inaccessibility of specialists from every branch in health institutions and the importance of early diagnosis, especially in emergency pathologies, the importance of the need for applications that will support physicians in the diagnosis process is understood. In the scope of the study, Visual Geometry Group (VGG), Residual Neural Network (ResNet) and EfficientNet architectures, which are among the current deep learning methods, were applied to PhysioNet, a recent dataset, in order to detect brain hemorrhages using Computed Tomography (CT) images. The models were compared among themselves and with existing studies in the literature using accuracy, precision, recall and F1 score metrics. With this study, the importance of choosing the appropriate model for the dataset has been demonstrated through current models. The success of the EfficientNet-B2 model was higher than both the studies in the literature and the models evaluated within the scope of the article. The results show that current deep-learning models have the potential to help in the diagnosis of an intracranial hemorrhage. The study is essential in terms of early diagnosis of intracranial hemorrhage by at least alerting general practitioners, who bear the burden of emergency services, to the presence of intracranial hemorrhage and ensuring that the bleeding condition is not overlooked.

**Keywords:** Brain Hemorrhage, CT, Deep Learning, EfficientNet, ResNet, VGG

\* Sorumlu yazar.  
E-posta adresi: tuhage@gmail.com

Alındı : 5 Aralık 2022  
Revizyon : 13 Şubat 2023  
Kabul : 21 Şubat 2023

## 1. Giriş (Introduction)

Önleyici tıp sağlık halinin korunmasında en önemli ve en etkili yöntemdir (Zeng vd., 2021). Erken teşhis de bu amaçla kullanılan yöntemler arasında önde gelir (Zeng vd., 2021). Kalp ve sinir dokusu rejenerasyonu mümkün olmayan dokulardır. Bu nedenle nöronal hasarın önlenmesi bakımından erken teşhisin morbidite ve mortalite üzerindeki etkisi tartışılmazdır (Rogatsky vd., 1996).

Günümüzde yüksek enerjili kazaların artışı, sağlık ve teknoloji alanındaki gelişmelerle paralellik göstermektedir (TBI Data, 2022). Bu şekilde yüksek enerjili kazaların yaklaşık %80' ine kafa travmaları eşlik eder (Mirzai vd., 2005). Yine bunların yaklaşık %30' unda çeşitli ciddiyet ve boyutta beyin kanamaları eşlik eder (Mirzai vd., 2005). Beyin kanamalarında klinik takipte derin bilinç bozuklukları ardından yapılan teşhislerde tedavi ihtimali zayıftır (Rogatsky vd., 1996). Çünkü 3 dakika içinde beyin beslenmesi bozulduğunda geri dönüşsüz hasarlara neden olmaktadır (Rogatsky vd., 1996).

Travmaların teşhisinde kullanılan en hızlı ve yaygın yöntem BT'dir (Kuno vd., 2017). BT cihazları, günümüzde ikinci basamak ve üzeri hastanelerde bulunmaktadır (T. C. Sağlık Bakanlığı, 2019). Bu yaygınlık ve ek olarak BT görüntülerinin tüm vücut travmalarında kullanılabilir olması acil servislerde çalışan doktorlarımıza ciddi sorumluluklar yüklemektedir (Kuno vd., 2017). Acil servislerin pek çoğunda her bölümden uzmanlar olmadığı gibi acil uzmanları da bulunmamaktadır (Türkiye Ministry of Health Expert Board in Medicine, 2022). Pek çok acil servisin yükünü pratisyen doktorlarımız taşımaktadır (Türkiye Ministry of Health Expert Board in Medicine, 2022). Tüm travmaların BT görüntülerinin pratisyen doktorlar hatta acil uzmanları tarafından yorumlanması mümkün değildir (Türkiye Ministry of Health Expert Board in Medicine, 2022). Günümüzde bu eksiklik tele tıp yöntemleri ile uzaktan radyologlar tarafından giderilmeye çalışılmaktadır (Wallis ve McCoubrie, 2011). Ancak radyologlar çoğu zaman hasta kliniği hakkında bilgi sahibi değildir (Wallis ve McCoubrie, 2011). Bunlara ek olarak radyologların yüksek iş yükü de göz önünde bulundurulursa bu alanda sağlık personellerine destek olacak uygulamalara olan ihtiyaç ortaya çıkmaktadır (Wallis ve McCoubrie, 2011).

Teknolojinin gelişmesiyle birlikte sağlık sektöründe de yapay zekâ temelli uygulamaların kullanımı artış göstermiştir. Bu alanda kullanılabilecek teknikler makine öğrenmesi ve derin öğrenme temelli olmak üzere iki alt kategoride değerlendirilebilir. Makine öğrenmesi teknikleri model oluşturma sürecinde kullanılacak özellikleri yapılandırılmış olarak alırken, derin öğrenme teknikleri ses, görüntü gibi pek çok veriyi kullanarak özellik çıkarma sürecini otomatik olarak gerçekleştirir. BT görüntülerinin işlenmesi söz konusu olduğunda da derin öğrenme tekniklerinin daha yaygın tercih edildiği görülmektedir (Zhang vd., 2022;

Alquzi vd., 202; Morgan vd., 2022; Li vd., 2022; AlOthman vd., 2022).

Makale kapsamında BT görüntüler üzerinde erken teşhis sürecine destek olmak amacıyla derin öğrenme teknikleri kullanılarak beyin kanamalarının varlığının tespiti gerçekleştirilmiştir. Bu amaçla VGG, ResNet ve EfficientNet teknikleri kullanılmıştır. Hem bu teknikler arasında hem de tekniklerin kendi alt modelleri arasında kapsamlı bir karşılaştırma yapılmıştır. Yapılan karşılaştırma ile kullanılacak veri ile model seçimi arasındaki ilişki de ortaya konulmuştur.

Çalışmanın bundan sonraki bölümü şu şekilde organize edilmiştir. İkinci bölümde BT görüntüler üzerinde son yıllarda yapılan çalışmalara yer verilmiştir. Üçüncü bölümde kullanılan teknikler detaylı olarak açıklanmıştır. Elde edilen sonuçlara dördüncü bölümde yer verilmiştir. Sonuç bölümü ile çalışma tamamlanmıştır.

## 2. Literatür Araştırması (Literature Review)

Beyin kanamalarının BT görüntüler kullanılarak sınıflandırılması amacıyla son yıllarda yapılan çalışmalar incelendiğinde bu alanda yaygın olarak derin öğrenme tekniklerinin kullanıldığı tespit edilmiştir. Özellikle verinin kısıtlı olduğu durumlarda makine öğrenmesi tekniklerinden faydalanan çalışmalar da mevcuttur. Bu bölümde beyin kanamaları özelinde gerçekleştirilen sınıflandırma problemleri için hem makine öğrenmesi hem derin öğrenme tekniklerinden hangilerinin daha başarılı olduğu mevcut çalışmalar üzerinden özetlenmiştir.

Beyin kanamalarının türlerinin tespit edilmesi amacıyla Solorio-Ramirez vd. (2021) tarafından gerçekleştirilen çalışmada Açıklanabilir Yapay Zeka yaklaşımı kullanılmıştır. dMeans olarak adlandırılan bir öznelik seçim algoritması ile beyin görüntülerinin sınıflandırılması gerçekleştirilmiştir. Önerilen yöntemin performansı Çok Katmanlı Algılayıcılar (MLP), Naive Bayes, K En Yakın Komşu (KNN), Destek Vektör Makinesi (SVM), Adaboost ve Rastgele Orman gibi geleneksel yöntemler ile karşılaştırılmıştır. Geliştirilen yöntem %86.50 doğruluk ve %91.60 özgüllük oranı ile karşılaştırılan yöntemlerden daha iyi bir sonuç elde etmiştir. Makine öğrenmesi tekniklerinin kullanıldığı başka bir çalışmada Alawad vd. (2020) tarafından gerçekleştirilmiştir. BT görüntülerinden beyin kanamasının tespiti ve sınıflandırılması için yeni bir yaklaşım önerilmiştir. Önerilen yöntem sınıflandırma için radyal tabanlı fonksiyon çekirdeğine sahip SVM tekniğini kullanmaktadır. Çalışmaya özgü olarak oluşturulan veri kümesi üzerinden yöntemin doğruluk değeri %99.5 olarak elde edilmiştir.

Beyin kanamalarının sınıflandırılması amacıyla derin öğrenme tekniklerini kullanan çalışmalar incelendiğinde yaygın olarak Evrimsel Sinir Ağı (CNN) temelli modellerin kullanıldığı görülmüştür. Mushtaq vd. (2021) tarafından BT görüntülerinden beyin kanaması sınıflandırmak için CNN modelleri



kullanılmıştır. Çalışmada iki farklı hibrit model (CNN + Uzun Kısa Süreli Bellek (LSTM) ve CNN + Geçitli Tekrarlayan Birim (GRU)) önerilmiştir. Modellerin doğruluğunun tespiti için beyin kanaması olan ve olmayan hastaların eşit olarak dengelendiği 200 BT görüntüsünden oluşan bir veri kümesi kullanılmıştır. Önerilen modellerden elde edilen en iyi sonuç %95 doğruluk oranına ve %90 özgüllük değerine sahiptir. CNN temelli olarak gerçekleştirilen başka bir çalışmada (Gautam ve Raman, 2021) beyinde kanama kaynaklı inme ve iskemik inme durumlarının sınıflandırılması gerçekleştirilmiştir. Görüntülerin kalitesini arttırmak için çok odaklı bir görüntü füzyonu tekniği kullanılarak ön işleme yapılmıştır. Sınıflandırma işlemi 13 katmanlı bir CNN mimarisi kullanılarak gerçekleştirilmiştir. Önerilen yöntemin doğruluğu Himalaya Tıp Bilimleri Enstitüsü tarafından sağlanan BT görüntülerden elde edilen iki farklı veri kümesi üzerinden gösterilmiştir. İlk veri kümesinde elde edilen en yüksek doğruluk değeri %98.77 iken ikinci veri kümesinden elde edilen en yüksek doğruluk değeri %93.33 olmuştur. RSNA 2019 veri kümesinde yer alan BT görüntüler kullanılarak Burduja vd. (2020) tarafından gerçekleştirilen çalışmada kafa içi kanama tespiti yapılmıştır. Yine LSTM ve CNN tekniklerini hibrit olarak kullanan bir model ile sınıflandırma işlemi gerçekleştirilmiştir. Önerilen yöntem ile sınıflandırma işlemi için ortalama %96.00 doğruluk değeri elde edilmiştir. Beyin kanamalarının BT görüntüler kullanılarak sınıflandırılması problemi çözümü olarak otoenkoderlar ile AlexNet mimarisini birleştiren başka bir çalışmada (Toğaçar vd., 2019) %98.57 doğruluk değeri elde edilmiştir. Yalçın ve Vural (2022) tarafından beyin BT görüntüler üzerinden inmelerinin sınıflandırılması amacıyla gerçekleştirilen çalışmada U-net mimarisi kullanılmıştır. Önerilen U-net temelli yöntem ile inme sınıflandırılması için %98.9 doğruluk, iskemi ve kanama sınıflandırması için ise %98.5 doğruluk değeri elde edilmiştir. Konvolüsyonel sinir ağları ve BT görüntüler kullanılarak beyin kanaması tespiti ve sınıflandırılması amacıyla gerçekleştirilen başka bir çalışmada (Phan vd., 2019) %97.1 doğruluk değeri elde edilmiştir. Çalışmada görüntünün piksel değerlerine ek olarak Houndsfield değeri kullanılarak kanamanın oluşma zamanı ve olduğu bölge de tespit edilmiştir.

Beyin kanamalarının sınıflandırılması problemini özel bir kanama alt türünün sağlıklı beyin kanamalarından ayrılması şeklinde ikili sınıflandırma olarak gerçekleştiren çalışmalar da mevcuttur. Altuve ve Pérez (2022) sağlıklı beyin ve Intracerebral kanama (ICH) içeren beyin görüntülerinin ayrımı için ResNet-18 mimarisini kullanmışlardır. Önerilen yöntem ile sınıf dağılımları eşit 200 BT görüntüsü üzerinden %95.25 doğruluk ve %95.91 F1 skor değeri elde edilmiştir. ICH kanamalarının BT görüntülerinden tanımlanması ve sınıflandırılması üzerine yapılan bir çalışmada (Ko vd., 2020) CNN ve LSTM modelleri hibrit olarak kullanılmıştır. Önerilen modelin

sınıflandırma işlemi için doğruluk değeri %92 olarak elde edilmiştir. Lewick vd. (2020) intrakraniyal kanama tespiti amacıyla ResNet tabanlı bir konvolüsyonel sinir ağı mimarisi kullanmışlardır. Veri kümesi olarak Kuzey Amerika Radyoloji Derneği tarafından dört uluslararası üniversiteden toplanan 752.803 adet görüntü kullanılmıştır. Kanama türlerinin sınıflandırılması amacıyla oluşturulan ResNet-50 tabanlı bir konvolüsyonel ağ ile ortalama doğruluk değeri %93.3 olarak elde edilmiştir. ResNet-50 gibi önceden eğitilmiş ve ağırlıkları belirlenen modeller ile transfer öğrenmesi yapan bir diğer çalışma ise (Rahman vd., 2022) EfficientNet-B6 mimarisi ile %95.99 doğruluk oranına ulaşabilmiştir. Venugopal vd. (2021) çalışmalarında FFEDL-ICH ismini verdikleri bir yöntem geliştirmişlerdir. Geliştirilen yöntem dört aşamadan oluşmaktadır: ön işleme, resim segmentasyonu, özellik çıkarımı ve sınıflandırma. Özellik çıkarımı için ResNet-152 mimarisi kullanılmış ve derin sinir ağları ile sınıflandırma yapılmıştır. Bu şekilde doğruluk değeri %96.56 olarak bulunmuştur. AIMA-ICHDC (Meng vd., 2022) ismiyle geliştirilen bir başka yöntem ise sezgisel optimizasyon ve VGG-19 mimarisini bir arada kullanarak ikili sınıflandırmada %96.51 doğruluk değerine ulaşabilmiştir.

Çalışmamızda literatürde görüntü sınıflandırma için sıklıkla kullanılan ve başarılı oldukları ImageNet (Deng vd., 2009) veri kümesi üzerinden gösterilmiş (He vd., 2016; Tan ve Le, 2019; Simonyan ve Zisserman, 2015) VGG, ResNet ve EfficientNet mimarileri kullanılmıştır. Bu mimariler karmaşıklık olarak birbirlerinden ayrılmaktadır ve sınıflandırma problemlerinde sıklıkla sonuçları karşılaştırılmaktadır (Liu vd., 2020; Ravi vd., 2021; Wang vd., 2021; Rim vd., 2020). Literatürde beyin kanamalarının tespiti için bu mimarilerin karşılaştırıldığı bir çalışmaya rastlanmamıştır.

### 3. Metodoloji (Methodology)


Çalışmamızda beyin kanamalarının sınıflandırılması amacıyla günümüzde farklı sınıflandırma problemlerinde yaygın olarak kullanılan 3 farklı konvolüsyonel ağ mimarisi kullanılmıştır. Makalenin bu bölümünde kullanılan mimarilerinin detaylı açıklamaları verilmiştir.

#### 3.1. VGG (Visual Geometry Group)

VGG (Simonyan ve Zisserman, 2015) büyük ölçekli veri kümelerinde görüntü tanıma yapabilmek amacıyla geliştirilmiş birden fazla katmana sahip standart bir CNN mimarisidir. Yenilikçi nesne tanıma modellerinin temelini oluşturmaktadır. Çalışmamızda VGG'nin özel mimarileri olan VGG-11, VGG-13 ve VGG-16 kullanılmıştır. VGG-11 mimarisi 8 evrişim katmanı ve 3 tam bağlantılı katmandan oluşur. Girdi olarak 224x224x3 boyutlarında RGB görüntüleri alır. Mimari içerisinde ilerledikçe derinleşmektedir ve parametre sayıları artmaktadır. Parametre sayıları

havuzlama katmanları sayesinde azaltılır. VGG-11 içerisinde havuzlama katmanları her aşamada kullanılmak yerine ağ içerisinde dağıtık halde

bulunmaktadır. Son aşamada ise sınıflandırmayı gerçekleştirmek için softmax sınıflandırıcısı kullanılır. VGG-11 mimarisi Şekil 1’de gösterilmiştir.



Şekil 1. VGG-11 Ağ mimarisi (VGG-11 Network architecture)

VGG-13 ve VGG-16 mimarileri VGG-11 mimarisi ile ortak girdi ve çıktı katmanlarına sahiptir. Mimariler evrişimli katmanların bulunduğu ve özellik çıkarımı

yapılan kısımda özelleşmektedir. Mimarilerin katmanları ve farklılaştıkları kısımlar Tablo 1’de gösterilmektedir.

Tablo 1. VGG Ağ mimarisi genel katman tablosu (VGG Network architecture general layer table)

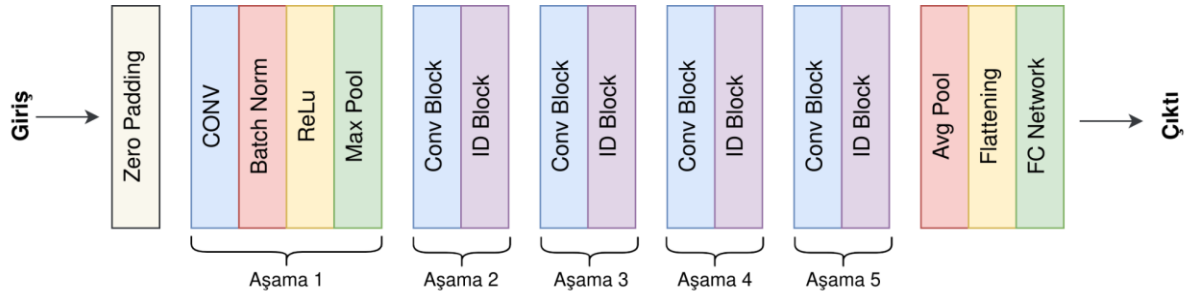
Model	Özellik Çıkarımı				
	1. Blok	2. Blok	3. Blok	4. Blok	5. Blok
VGG-11	Conv3-64	Conv3-128	Conv3-256 Conv3-256	Conv3-512 Conv3-512	Conv3-512 Conv3-512
VGG-13	Conv3-64	Conv3-128	Conv3-256	Conv3-512	Conv3-512
VGG-16	Conv3-64	Conv3-128	Conv3-256	Conv3-512	Conv3-512
	Conv3-64	Conv3-128	Conv3-256	Conv3-512	Conv3-512
			Conv3-256	Conv3-512	Conv3-512

VGG mimarilerinde konvolüsyon katmanları özellik çıkarıcı olarak 5 blok halinde incelenebilir. Her blok içerisinde küçük boyutlu (3x3) filtreler kullanılmaktadır. VGG-11 ve VGG-13 tasarımlarını birbirinden ayıran sadece ilk iki bloktaki seviye sayısıdır. VGG-11 mimarisinden VGG-13 mimarisini oluşturmak için aynı konfigürasyona sahip ilk iki blok eklenir. Buna benzer şekilde, VGG-16 ve VGG-19 tasarımları üçüncü bloktan beşinci bloğa kadar kademeli olarak katmanlar eklenerek oluşturulur. Aynı zamanda özellik uzayını yoğunlaştırmak için her bloğun sonuna bir maksimum havuzlama katmanı eklenir. Maksimum havuzlama katmanında 2 adımlı bir (2x2) filtre kullanılır.

### 3.2. ResNet (Residual Neural Network)

ResNet (He vd., 2016) özel bir CNN mimarisidir ve yalnızca konvolüsyon katmanlarından oluşur. Temelde katman bloklarının kısayol bağlantıları kullanılarak atlanması fikrini gerçekleştirmektedir. Her iki katmanda bir artık bağlantılar kullanır. Bir artık

bağlantı, konvolüsyon ağının çıktısını takip eden konvolüsyonel katmanın çıkışına bağlar. Özellik haritalarının çözünürlüğü ve kanal sayısı ağ içerisinde ilerledikçe azalmaktadır. Buna ek olarak evrişim filtrelerinden sonra, bir ortalama havuzlama katmanına, tahmin yapmak için ise mimarinin çıkışında tam bağlantılı katmana sahiptir. Aynı zamanda modelin artık ağlar dışında devam eden çıktılarını ve artık evrişim katmanlarının girdilerini birleştirmek için basit bir toplam uygulanır. Bu şekilde özellik haritasının artıklarını kullanarak gerçekleştirilen bir eğitimin sadece özellik haritasının kullanıldığı bir eğitimden daha verimli olduğu görülmüştür (He vd., 2016). ResNet ağının 18 katman, 34 katman ve 101 katman gibi değişen parametrelerde katman sayısı içeren çeşitli mimarileri bulunmaktadır. ResNet-50’nin genel mimarisi Şekil 2’de gösterilmiştir. Tablo 2’de çalışmada kullanılan iki model olan ResNet-50 ve ResNet-101 mimarilerinin katmanları detaylı olarak gösterilmiştir.



Şekil 2. ResNet-50 Ağ mimarisi (ResNet-50 Network architecture)

Tablo 2. ResNet Ağ mimarisi genel katman tablosu (ResNet Network architecture general layer table)


Model	Özellik Çıkarımı				
	1. Blok	2. Blok	3. Blok	4. Blok	5. Blok
ResNet-50	7x7, 64, Stride 2	3x3, MaxPool, Stride 2	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
ResNet-101		3x3, MaxPool, Stride 2	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$

### 3.3. EfficientNet (EfficientNet)

EfficientNet (Tan ve Le, 2019) daha az parametreye sahip ve sınıflandırma doğruluğunu artıran CNN modelleri tasarlamak amacıyla geliştirilmiştir. Genişliği, derinliği ve çözünürlüğü eşit olarak ölçeklendirmek için bileşik ölçeklendirme tekniğini ve mobil ters darboğaz konvolüsyonunu (MBConv) kullanır. MBConv blokları kanalları genişleten ve ardından sıkıştırılan bir katmandan oluşur. Bu tasarım, geleneksel katmanlara kıyasla hesaplamayı neredeyse  $k^2$  oranında azaltan derin ayrılabilir konvolüsyonlar içerir; burada  $k$ , 2D konvolüsyon penceresinin

genişliğini ve yüksekliğini temsil eden çekirdek boyutudur (Sandler vd., 2018). EfficientNet-B0'dan EfficientNet-B7'ye kadar yedi farklı mimariye sahiptir. EfficientNet-B0 modelinin şematik gösterimi Şekil 3'te verilmiştir.

Şekil incelendiğinde MBConv1, MBConv3 ve MBConv6 bloklarının tekrarlanarak kullanıldığı görülmektedir. Bunlar MBConv bloğunun farklı biçimleridir. Şekilde her bir blok içindeki kanal sayısının daha fazla sayıda filtre kullanılarak artırıldığı veya büyütüldüğü de görülmektedir. EfficientNet mimarisinin sekiz farklı modeline ait özellikler Tablo 3'te verilmiştir.



Şekil 3. EfficientNet-B0 Ağ mimarisi (EfficientNet-B0 Network architecture)

**Tablo 3.** EfficientNet modellerine ait genel özellik tablosu (General attribute table of EfficientNet models)


Model	Katman Sayısı	Giriş Çözünürlüğü	Özellik Vektör Boyutu
EfficientNet-B0	240	224x224	1280
EfficientNet-B1	342	240x240	1280
EfficientNet-B2	342	260x260	1408
EfficientNet-B3	387	300x300	1536
EfficientNet-B4	477	380x380	1792
EfficientNet-B5	579	456x456	2048
EfficientNet-B6	669	528x528	2304
EfficientNet-B7	816	600x600	2560

Tablo 3 incelendiğinde EfficientNet-B0'dan B7'ye kadar, giriş çözünürlükleri gibi katman sayısının da değiştiği görülmektedir. EfficientNet-B7 ise EfficientNet-B0'dan yaklaşık 3.50 kat daha derindir. Çalışmamızda EfficientNet modellerinden ilk dördü (B0-B4) kullanılarak BT görüntülerinden beyin kanamasının sınıflandırılması yapılmıştır. Modellerin karmaşıklığı arttıkça doğruluk değerlerinin düştüğü gözlemlendiği için B4 modelinden sonra gelen modeller çalışmada test edilmemiştir.

## 4. Deneysel Çalışma (Experimental Study)

### 4.1. Veri Kümesi (Data Set)

Makale kapsamında 82 BT taraması içeren PhysioNet (Hssayeni vd., 2020) veri kümesi kullanılmıştır. Veri kümesinde yer alan görüntüler iki radyolog tarafından kanama ve kırık türlerine göre etiketlenmiştir. Aynı zamanda her kesitteki ICH bölgeleri de radyologlar tarafından işaretlenmiştir.

**Tablo 4.** PhysioNet veri kümesinden alınan örnek görüntüler (Sample images from PhysioNet dataset)

Veri kümesinde yer alan taramalar toplamda 2812 kesit (2494 sağlıklı kesit, 318 beyin kanaması içeren kesit) içermektedir. Tablo 4'te hem kanama içeren hem de kanama içermeyen üçer adet tarama görüntüsü verilmiştir.

### 4.2. Hata Metrikleri (Error Metrics)

Çalışmamızda eğitilen modellerin değerlendirilmesi amacıyla doğruluk, kesinlik, hassasiyet ve F1 skor metrikleri kullanılmıştır. Doğruluk, sınıflandırıcı tarafından doğru yapılan tahminlerin tüm tahminlere oranını, kesinlik, doğru tahin ettiğimiz kanamalı görüntülerin, tüm kanamalı tahminlerimize oranını, hassasiyet, doğru tahin ettiğimiz kanamalı görüntülerin tüm kanamalı görüntülere oranını ve F1 skor, kesinlik ve hassasiyet metriklerinin harmonik ortalamasını ifade eder. Metriklere ait formüller sırasıyla Eşitlik (1), (2), (3) ve (4)'te verilmiştir. Eşitliklerde gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif değerler sırasıyla TP, TN, FP ve FN olarak gösterilmektedir. TP değeri kanamalı olarak tahmin edilen ve gerçekte de kanama içeren görüntülerin sayısını, TN değeri kanamasız olarak tahmin edilen ve gerçekte de kanama içermeyen görüntülerin sayısını, FP değeri kanamalı olarak tahmin edilen ancak gerçekte kanama içermeyen görüntülerin sayısını ve FN değeri ise kanamasız olarak tahmin edilen ancak gerçekte kanamalı olan görüntülerin sayısını temsil etmektedir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (2)$$

$$\text{Hassasiyet} = \frac{TP}{TP+FN} \quad (3)$$

$$\text{F1 skor} = 2 * \frac{\text{Kesinlik} * \text{Hassasiyet}}{\text{Kesinlik} + \text{Hassasiyet}} \quad (4)$$


### 4.3. Deneysel Sonuçlar (Experimental Results)

Model eğitimi öncesi veri kümesi %80 eğitim %20 test olacak şekilde bölümlenmiştir. Eğitim için VGG modellerinden VGG-11, VGG-13 ve VGG-16, ResNet modellerinden ResNet-50 ve ResNet-101 ve EfficientNet modellerinden de EfficientNet-B0, EfficientNet-B1, EfficientNet-B2 ve EfficientNet-B3 kullanılmıştır. Eğitim için 24GB RAM GTX1060 6GB

GPU ve i7-4770k işlemciye sahip bir sunucu kullanılmıştır. Modellere ait doğruluk değerleri Şekil


4'te gösterilmiştir.

### Doğruluk



Şekil 4. Modellerden elde edilen doğruluk değerleri (Accuracy values obtained from models)

### F1 Skor



Şekil 5. Modellerden elde edilen F1 skor değerleri (F1 score values obtained from models)

Grafik incelendiğinde en yüksek doğruluk oranının EfficientNet-B2 modeli ile elde edildiği görülmektedir. VGG, ResNet ve EfficientNet modelleri kendi içlerinde incelendiğinde (EfficientNet-B1-EfficientNet-B2 geçişi hariç) modellerin karmaşıklığındaki artışın doğruluk oranını düşürdüğü gözlemlenmiştir. Bu durum problemin karmaşıklığına uygun model seçiminin derin öğrenmedeki önemini göstermektedir. BT görüntüleri üzerinden gerçekleştirilen ikili sınıflandırma problemi (kanama var/yok) için karmaşıklığı düşük modeller daha yüksek doğruluk değeri vermiştir. Elde edilen

sonuçlar modelin probleme özgü olarak seçilmesi gerektiğinin açık bir göstergesidir. Sınıf etiketlerinde var olan dengesiz dağılım sebebiyle doğruluk değerine ek olarak F1 skor değeri de hesaplanmıştır. F1 skor değerine ait sonuçlar Şekil 5'te gösterilmiştir.

Şekilden de anlaşıldığı gibi VGG ve ResNet mimarileri için ağır karmaşıklığı yükseldiğinde model aşırı öğrenme eğilimine girmektedir. EfficientNet modellerinde de benzer durum söz konusudur ancak bu modellerde karmaşıklığın artışı ile F1 skor değerindeki düşüş oranı VGG ve ResNet modelleri kadar yüksek

değildir. Bu da bize EfficientNet modellerinin aşırı öğrenmeye karşı diğerlerinden daha dayanıklı

olduğunu göstermektedir.

**Tablo 5.** Modellerden elde edilen sınıflandırma sonuçları (Classification results obtained from models)

Yöntem	Doğruluk	Kesinlik	Hassasiyet	F1 Skor
VGG-11	95.9147	90.5085	88.8417	89.6511
VGG-13	89.1652	72.9331	62.5595	65.5927
VGG-16	94.3162	85.8968	85.8968	85.8968
ResNet-50	95.5595	89.5892	87.9603	88.7512
ResNet-101	90.9414	82.1807	65.6046	70.1121
EfficientNet-B0	97.1581	94.6005	90.9052	92.6458
EfficientNet-B1	96.6252	93.4523	89.2425	91.2035
<b>EfficientNet-B2</b>	<b>97.3357</b>	<b>95.4043</b>	<b>91.0054</b>	<b>93.0554</b>
EfficientNet-B3	96.0924	94.2456	85.5367	89.2639

Çalışma kapsamında değerlendirilen tüm metriklerin sonuçları detaylı olarak Tablo 5'te verilmiştir. Tablo 5 üzerinden genel bir değerlendirme yapılırsa, EfficientNet-B2 modelinin BT görüntüler kullanılarak beyin kanamalarının sınıflandırılması problemi için değerlendirilen modeller arasında en

uygun model olduğu söylenebilir. Tablo 6'te VGG-11, ResNet-50 ve EfficientNet-B2 modellerinin, PhysioNet veri kümesini kullanarak sınıflandırma yapan literatürdeki benzer çalışmalarla karşılaştırması verilmiştir.

**Tablo 6.** Kullanılan modeller ile PhysioNet veri kümesini kullanan çalışmaların karşılaştırması (Comparison of the used models and studies that using the PhysioNet data set)

Yöntem	Doğruluk	Kesinlik	Hassasiyet	F1 Skor
VGG-11	95.91	90.50	88.84	89.65
ResNet-50	95.55	89.58	87.96	88.75
<b>EfficientNet-B2</b>	<b>97.33</b>	95.40	91.00	93.05
Rahman vd. (2022)	95.99	94.24	85.53	89.26
Venugopal vd. (2021)	96.56	96.43	<b>95.65</b>	<b>96.03</b>
Meng vd. (2022)	96.51	<b>96.50</b>	95.25	95.87
Anupama vd. (2022)	95.73	95.79	94.01	94.89

Tablo 6'da yer alan sonuçlardan EfficientNet-B2 modelinin diğer modellerden daha başarılı olduğu görülmektedir. Elde edilen sonuçlar güncel derin öğrenme modellerinin, beyin kanaması tespiti için uzmanlara yardımcı olabilecek doğrulukta olduğunu göstermiştir.

## 5. Sonuçlar (Conclusions)

Travmatik beyin hasarı (TBH) vakalarında beyin kanamasının varlığını ve derecesini belirlemek için en çok kullanılan tıbbi görüntüleme yöntemi BT'dir. TBH sonrası kanama tanısı hızlı bir şekilde konulmalıdır çünkü birkaç dakikalık bir gecikme bile ölümle sonuçlanabilir. Ancak kanamanın manuel olarak tespit edilmesi zaman alır ve nitelikli radyologların her zaman hazır olması gerektirir (Grewal vd., 2018). Bu nedenle, radyologlarla eşit düzeyde çıkarım ve doğruluk sağlayabilen otomatik kanama tespit teknikleri binlerce hastanın hayatını kurtarma potansiyeline sahiptir.

Bu çalışmada açık bir veri kümesi üzerinden güncel sınıflandırma mimarileri kullanılarak beyin kanaması tespiti yapılmıştır. Güncel yöntemlerin probleme uygunluğu ve modellerin karmaşıklığına göre sonuçların nasıl değiştiği incelenmiştir. Problemin çözümü amacıyla VGG, ResNet ve EfficientNet

mimarileri kullanılarak transfer öğrenmesi yapılmıştır. Kullanılan modellerin değişik varyasyonları ile sonuçlar elde edilmiş ve sınıflandırma için en yüksek doğruluk değeri veren model belirlenmiştir. Elde edilen sonuçlara göre en yüksek doğruluk ve F1 skor sırasıyla %97.33 ve %93.05 ile EfficientNet-B2 mimarisinden elde edilmiştir.

Çalışma kapsamında yalnızca beyin kanamaları özelinde farklı sınıflandırma yöntemleri karşılaştırılmıştır. İlerleyen çalışmalarda beyin kanamalarının tespiti için daha özel bir model oluşturulması amacıyla çalışmalar yapılabilir. Aynı zamanda kanamanın varlığının tespitine ek olarak kanama olan bölgenin spesifik olarak belirlenmesi amacıyla segmentasyon modelleri geliştirilebilir. Özellikle başlangıç aşamasındaki kanamaların tespiti akut kanamalara göre kısmen zor olduğundan bu türlerde kanamalar içeren görüntülerle çalışan hem sınıflandırma hem segmentasyon modellerine erken teşhis aşamasında ihtiyaç vardır.

## Kaynaklar (References)

- Alawad, D. M., Mishra, A., Hoque, M. T., 2020. AIBH: accurate identification of brain hemorrhage using genetic algorithm based feature selection and stacking. Machine Learning and Knowledge Extraction, 2(2), 56-77.  
<https://doi.org/10.3390/make2020005>



- AlOthman, A. F., Sait, A. R. W., Alhussain, T. A., 2022. Detecting coronary artery disease from computed tomography images using a deep learning technique. *Diagnostics*, 12(9), 2073.  
<https://doi.org/10.3390/diagnostics12092073>
- Alquzi, S., Alhichri, H., Bazi, Y., 2021. Detection of COVID-19 using EfficientNet-B3 CNN and chest computed tomography images. *ICICC 2021, International Conference on Innovative Computing and Communications*, February 2021, Delhi, India, pp. 365-373.
- Altuve, M., Pérez, A., 2022. Intracerebral hemorrhage detection on computed tomography images using a residual neural network. *Physica Medica*, 99, 113-119.  
<https://doi.org/10.1016/j.ejomp.2022.05.015>
- Anupama, C. S. S., Sivaram, M., Lydia, E. L., Gupta, D., Shankar, K., 2022. Synergic deep learning model-based automated detection and classification of brain intracranial hemorrhage images in wearable networks. *Personal and Ubiquitous Computing*, 26, 1-10.  
<https://doi.org/10.1007/s00779-020-01492-2>
- Burduja, M., Ionescu, R. T., Verga, N., 2020. Accurate and efficient intracranial hemorrhage detection and subtype classification in 3D CT scans with convolutional and long short-term memory neural networks. *Sensors*, 20(19), 5611.  
<https://doi.org/10.3390/s20195611>
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L., 2009. ImageNet: A large-scale hierarchical image database. *CVPR09, IEEE Conference on Computer Vision and Pattern Recognition*, 20-25 June 2009, Miami, Florida, USA, pp. 248-255.
- Gautam, A., Raman, B., 2021. Towards effective classification of brain hemorrhagic and ischemic stroke using CNN. *Biomedical Signal Processing and Control*, 63, 102178.  
<https://doi.org/10.1016/j.bspc.2020.102178>
- Grewal, M., Srivastava, M. M., Kumar, P., Varadarajan, S., 2018. Radnet: Radiologist level accuracy using deep learning for hemorrhage detection in CT scans. *IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, 4-7 April 2018, Washington, D.C, U.S., pp. 281-284.
- He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep residual learning for image recognition. *CVPR, IEEE Conference on Computer Vision and Pattern Recognition*, 27-30 June 2016, Las Vegas, Nevada, U. S., pp. 770-778.
- Hssayeni, M., Croock, M. S., Salman, A. D., Al-khafaji, H. F., Yahya, Z. A., Ghoraani, B., 2020. Intracranial hemorrhage segmentation using a deep convolutional model. *Data*, 5(1), 14.  
<https://doi.org/10.13026/4nae-zg36>
- Ko, H., Chung, H., Lee, H., Lee, J., 2020. Feasible study on intracranial hemorrhage detection and classification using a cnn-lstm network. *EMBC, 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society*, 20-24 July 2020, Montreal, Canada, pp.1290-1293.
- Kuno, H., Sekiya, K., Chapman, M. N., Sakai, O., 2017. Miscellaneous and emerging applications of dual-energy computed tomography for the evaluation of intracranial pathology. *Neuroimaging Clinics*, 27(3), 411-427.  
<https://doi.org/10.1016/j.nic.2017.03.005>
- Lewick, T., Kumar, M., Hong, R., Wu, W., 2020. Intracranial hemorrhage detection in CT scans using deep learning. *IEEE Sixth International Conference on Big Data Computing Service and Applications*, 3-6 August 2020, Oxford, United Kingdom, pp.169-172.
- Li, R., Xiao, C., Huang, Y., Hassan, H., Huang, B., 2022. Deep learning applications in computed tomography images for pulmonary nodule detection and diagnosis: A review. *Diagnostics*, 12(2), 298.  
<https://doi.org/10.3390/diagnostics12020298>
- Liu, J., Wang, M., Bao, L., Li, X., 2020. EfficientNet based recognition of maize diseases by leaf image classification. *Journal of Physics: Conference Series*, 1693(1), 012148.  
<https://doi.org/10.1088/1742-6596/1693/1/012148>
- Meng, F., Wang, J., Zhang, H., Li, W., 2022. Artificial intelligence-enabled medical analysis for intracranial cerebral hemorrhage detection and classification. *Journal of Healthcare Engineering*, 2022, 1-13.  
<https://doi.org/10.1155/2022/2017223>
- Mirzai, H., Yağlı, N., Tekin, İ., 2005. Celal Bayar Üniversitesi Tıp Fakültesi acil birimine başvuran kafa travmalı olguların epidemiyolojik ve klinik özellikleri. *Ulusal Travma Dergisi*, 2, 146-152.
- Morgan, N., Van Gerven, A., Smolders, A., de Faria Vasconcelos, K., Willems, H., Jacobs, R., 2022. Convolutional neural network for automatic maxillary sinus segmentation on cone-beam computed tomographic images. *Scientific Reports*, 12(1), 1-9.  
<https://doi.org/10.1038/s41598-022-11483-3>
- Mushtaq, M. F., Shahroz, M., Aseere, A. M., Shah, H., Majeed, R., Shehzad, D., Samad, A., 2021. BHCNet: neural network-based brain hemorrhage classification using head CT Scan. *IEEE Access*, 9, 113901-113916.  
<https://doi.org/10.1109/ACCESS.2021.3102740>
- Phan A.-C., Nguyen T.-M.-N., Phan T.-C., 2019. Detection and classification of brain hemorrhage based on hounsfield values and convolution neural network technique. *RIVF, 2019 IEEE-RIVF International Conference on Computing and Communication Technologies*, 20-22 March 2019, Vietnam, pp.1-7.
- Rahman, A. I., Bhuiyan, S., Reza, Z. H., Zaheen, J., Khan, T. A. N., Karim, D. Z., 2022. Intracranial hemorrhage detection on CT scan images using transfer learning approach of convolutional neural network. *ICCA '22, 2nd International Conference on Computing Advancements*, 10-12 March 2022, Dhaka Bangladesh, pp. 171-177.
- Ravi, V., Narasimhan, H., Pham, T. D., 2021. EfficientNet-based convolutional neural networks for tuberculosis classification. In: Pham, T.D., Yan, H., Ashraf, M.W., Sjöberg, F. (eds) *Advances in Artificial Intelligence, Computation, and Data Science. Computational Biology*, 31, 227-244.  
[https://doi.org/10.1007/978-3-030-69951-2\\_9](https://doi.org/10.1007/978-3-030-69951-2_9)
- Rim, B., Kim, J., Hong, M., 2020. Gender classification from fingerprint-images using deep learning approach. *RACS '20, International conference on research in adaptive and*

- convergent systems, 13-16 October 2020, Gwangju Republic of Korea, pp. 7-12.
- Rogatsky, G., Mayevsky, A., Zarchin, N., Doron, A., 1996. Continuous multiparametric monitoring of brain activities following fluid-percussion injury in rats: preliminary results. *Journal of basic and clinical physiology and pharmacology*, 7(1), 23-44.  
<https://doi.org/10.1515/jbcpp.1996.7.1.23>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L.-C., 2018. Mobilenetv2: Inverted residuals and linear bottlenecks. *IEEE conference on computer vision and pattern recognition*, 18-23 June 2018, Salt Lake City, UT, USA, pp. 4510-4520.
- Simonyan, K., Zisserman, A. 2015. Very deep convolutional networks for large-scale image recognition. *ICLR 2015, 3rd International Conference on Learning Representations*, 7-9 May 2015, San Diego, CA, USA.  
<https://doi.org/10.48550/arXiv.1409.1556>
- Solorio-Ramírez, J.-L., Saldana-Perez, M., Lytras, M. D., Moreno-Ibarra, M.-A., Yáñez-Márquez, C., 2021. Brain hemorrhage classification in CT scan images using minimalist machine learning. *Diagnostics*, 11(8), 1449.  
<https://doi.org/10.3390/diagnostics11081449>
- T. C. Sağlık Bakanlığı, 2019. Sağlık İstatistikleri Yıllığı. <https://dosyasb.saglik.gov.tr/Eklenti/40564,saglik-istatistikleri-yilligi-2019pdf.pdf?0>
- Tan, M., Le, Q., 2019. Efficientnet: Rethinking model scaling for convolutional neural networks. *ICML 2019, The 36th International conference on machine learning*, 10-15 June 2019, Long Beach, California, USA ,pp. 6105-6114.
- TBI Data | Concussion | Traumatic Brain Injury | CDC Injury Center. 2022, Mart 21.  
<https://www.cdc.gov/traumaticbraininjury/data/index.html>
- Toğaçar, M., Cömert, Z., Ergen, B., Budak, Ü., 2019. Brain hemorrhage detection based on heat maps, autoencoder and CNN architecture. *UBMYK, 1st International Informatics and Software Engineering Conference*, 6-7 November 2019, Ankara, Turkey, pp. 1-5.
- Türkiye Ministry of Health Expert Board in Medicine. Türkiye emergency medicine specialty training curriculum. 2022, Mart 21.  
<https://tuk.saglik.gov.tr/Eklenti/34065/0/acilipmufredatv24doc.doc>
- Venugopal, D., Jayasankar, T., Sikkandar, M. Y., Waly, M. I., Pustokhina, I. V., Pustokhin, D. A., Shankar, K., 2021. A novel deep neural network for intracranial haemorrhage detection and classification. *Computers, Materials & Continua*, 68(3), 2877-2893.  
<https://doi.org/10.32604/cmc.2021.015480>
- Wallis, A., McCoubrie, P., 2011. The radiology report—are we getting the message across?. *Clinical radiology*, 66(11), 1015-1022.  
<https://doi.org/10.1016/j.crad.2011.05.013>
- Wang, P., Liu, J., Xu, L., Huang, P., Luo, X., Hu, Y., Kang, Z., 2021. Classification of Amanita Species Based on Bilinear Networks with Attention Mechanism. *Agriculture*, 11(5), 393.  
<https://doi.org/10.3390/agriculture11050393>
- Yalçın, S., Vural, H., 2022. Brain stroke classification and segmentation using encoder-decoder based deep convolutional neural networks. *Computers in Biology and Medicine*, 149, 105941.  
<https://doi.org/10.1016/j.combiomed.2022.105941>
- Zeng, W., Li, G., Turbat, V., Hu, G., Ahn, H., Shen, J., 2021. Optimizing preventive medicine to bridge the gap between clinical medicine and public health for disease control in China: a lesson from COVID-19. *Preventive Medicine*, 143, 106324.  
<https://doi.org/10.1016/j.ypmed.2020.106324>
- Zhang, M., Gu, S., Shi, Y., 2022. The use of deep learning methods in low-dose computed tomography image reconstruction: a systematic review. *Complex & Intelligent Systems*, 8, 5545–5561.  
<https://doi.org/10.1007/s40747-022-00724-7>



# Neural Coreference Resolution for Turkish

Şeniz Demir<sup>1</sup> 

<sup>1</sup> MEF University, Department of Computer Engineering, İstanbul, Turkey  
demirse@mef.edu.tr

## Abstract

Coreference resolution deals with resolving mentions of the same underlying entity in a given text. This challenging task is an indispensable aspect of text understanding and has important applications in various language processing systems such as question answering and machine translation. Although a significant amount of studies is devoted to coreference resolution, the research on Turkish is scarce and mostly limited to pronoun resolution. To our best knowledge, this article presents the first neural Turkish coreference resolution study where two learning-based models are explored. Both models follow the mention-ranking approach while forming clusters of mentions. The first model uses a set of hand-crafted features whereas the second coreference model relies on embeddings learned from large-scale pre-trained language models for capturing similarities between a mention and its candidate antecedents. Several language models trained specifically for Turkish are used to obtain mention representations and their effectiveness is compared in conducted experiments using automatic metrics. We argue that the results of this study shed light on the possible contributions of neural architectures to Turkish coreference resolution.

**Keywords:** Turkish, coreference resolution, neural architectures, pre-trained language models.

## Sinir Ağı ile Türkçe Eşgönderge Çözümleme

### Öz

Eşgönderge çözümleme, bir metinde yer alan ve aynı temel varlığa gönderimde bulunan ifadelerin çözümlenmesiyle ilgilidir. Metin anlamının vazgeçilmez bir unsuru olan bu zor iş, soru yanıtlama ve makine çevirisi gibi çeşitli dil işleme sistemlerinde önemli uygulamalara sahiptir. Eşgönderge çözümlemesine yönelik önemli sayıda çalışma olmasına rağmen, Türkçe üzerine yapılan araştırmalar sayıca azdır ve çoğunlukla zamir çözümlemesiyle sınırlı kalmıştır. Bildiğimiz kadarıyla, bu makale öğrenme tabanlı iki farklı modelin araştırıldığı ilk sinir ağı kullanılarak yürütülmüş Türkçe eşgönderge çözümleme çalışmasını sunmaktadır. Her iki model de ifade kümelerini oluştururken ifade sıralaması yaklaşımını takip etmektedir. İlk model, bir dizi önceden belirlenmiş özellikleri kullanırken, ikinci eşgönderge modeli, bir ifade ile onun aday öncül ifadeleri arasındaki benzerlikleri tespit için önceden eğitilmiş büyük ölçekli dil modellerinden öğrenilen kelime temsillerini kullanmaktadır. Türkçe için özel olarak eğitilmiş birçok dil modeli, kelime temsillerini elde etmek için kullanılmış ve bunları etkinlikleri yapılan deneylerde otomatik ölçütler kullanılarak karşılaştırılmıştır. Bu çalışma sonuçlarının, sinir ağı mimarilerinin Türkçe eşgönderge çözümlenmesine olası katkılarına ışık tuttuğu düşünülmektedir.

**Anahtar Kelimeler:** Türkçe, eşgönderge çözümleme, sinir ağı mimarileri, eğitilmiş dil modelleri.

## 1. Introduction

The information about real-world entities might be spread across multiple sentences in a document. It is essential to connect all mentions of the same entities and aggregate information related to these entities in order to fully understand the document. Coreference resolution is the task of identifying text spans that refer to the same entities and grouping these spans into coreference chains (clusters). The task has an impact on the performance of various natural language

applications, including information extraction (Kriman and Heng, 2021), question answering (Bhattacharjee et al., 2020), and text summarization (Li et al., 2021; Steinberger et al., 2007).

Coreference resolution comprises mention detection and mention clustering (coreference resolving) subtasks that are often performed jointly. Given a document, the mention detection subtask is responsible for finding all text spans that refer to an entity and hence constitute a mention. Previous research has demonstrated that incorrect or missing identification of entity mentions negatively affected the accuracy of downstream

\* Corresponding Author  
E-mail: demirse@mef.edu.tr

Received : 27 Dec 2022  
Revision : 26 Feb 2023  
Accepted : 9 Mar 2023

coreference resolution. To address this task, previous research has utilized rule-based, statistical-based, and deep learning-based approaches (Lata et al., 2022). In rule-based solutions, a set of hand-crafted rules and knowledge resources are used where the rules require tremendous effort. The system developed by Sapena et al. (2010) identified noun phrases, named entities, and pronouns as mentions by relying on a set of rules that benefit from part-of-speech (POS), named entity, and syntactic information. In the work of Soraluze et al. (2012), a rule-based approach was developed for the Basque language using finite-state transducers. In statistical-based approaches, the detection task is defined as either a sequence labeling or a classification problem and the models trained on large-scale data are used for predictions. The work of Zitouni et al. (2005) addressed the task as a classification problem and used a maximum entropy Markov model classifier that utilizes various features (e.g., lexical, syntactic, and shallow parsing features) and information obtained from a gazetteer. Another detection solution based on a support vector machine classifier was implemented by Hacioglu et al. (2005). The classification was followed by a post-processing step to capture missing mentions. On the other hand, deep learning-based approaches hinder feature engineering and capture both syntactic and semantic features of candidate mentions via word embeddings. Different neural architectures were explored for mention detection such as the Bi-directional long short-term memory (BiLSTM) with conditional random field (CRF) (Park and Lee, 2015), the pointer network (Park et al., 2017), and the stacked LSTM enhanced with stack pointer (Wang et al., 2018).

An entity introduced by a mention might be referred multiple times later in a document. If the document contains multiple mentions of different entities, the mentions that are coreferent should be differentiated from those that are not and all identified mentions that refer to the same entity should be clustered in a group. Earlier studies have either performed mention detection and clustering subtasks jointly in an end-to-end fashion (Cai and Strube, 2010) or applied clustering to identified mentions (Durrett and Klein, 2013; Clark and Manning, 2015) or gold mentions provided in a dataset. Recent advancements in deep learning and transformer models motivated the development of several end-to-end solutions (Lai et al., 2022). The pioneering end-to-end solution by Lee et al. (2017) formed a contextual representation of each token in a text via a BiLSTM network that is fed by word and character embeddings. These representations were used to assign mention scores to candidate text spans and the top-scoring mentions were used as input in a feed-forward neural network (FFNN) to handle coreference resolution. Several extensions to this work have been developed since then including the use of a biaffine attention model in place of the original FFNN to compute antecedent scores (Zhang et al., 2018) and the incorporation of reinforcement learning where a reward function is used

to measure the correctness of generated clusters (Fei et al., 2019).

Most coreference resolution studies have followed one of three main methods to make coreference decisions. In mention-pair approaches, the task is formulated as determining whether a given pair of mentions is coreferent or not (Soon et al., 2001; Hoste, 2016). Despite its simplicity (Uryupina and Moschitti, 2015), these approaches cannot compare all candidate antecedents for a mention at once in order to choose the most probable antecedent. On the other hand, independent decisions are eliminated and all candidate antecedents for a mention are jointly compared in mention-ranking approaches (Denis and Baldridge, 2008; Wiseman et al., 2015). The performance of these approaches was improved by the introduction of syntactic information to better prune the space of candidate antecedents and the incorporation of parse tree information (e.g., the siblings and degrees of tree nodes and the traversal node sequence) into mention span representations (Fang and Jian, 2019). The entity-mention approaches determine whether an entity represented by a possibly partially formed cluster of mentions is coreferent with a given mention (Luo et al., 2004; Yang et al., 2008). Links are built between a given mention and a discourse entity rather than a prior mention. Given that a mention might not capture adequate information about the entity it refers to, these approaches make linking decisions by utilizing the representations of clusters containing multiple mentions of the same entities. In the work of Wiseman et al. (2016), an RNN network was used to obtain a representation of a cluster (i.e., cluster level features) from the sequence of mentions that belong to it. Although cluster level features better capture entity based information, candidate clusters cannot be considered simultaneously in entity-mention approaches. Additionally, the strengths of different approaches are combined in hybrid solutions such as the cluster-ranking approaches where preceding clusters in the discourse are ranked for a given mention (Rahman and Ng, 2011). These solutions promote the expressiveness strength of entity-mention approaches and the comparison ability of mention-ranking approaches. Alternative coreference solutions have also evolved over time such as the solution where singleton clusters from mentions are initially built and larger clusters are incrementally formed by joining clusters that refer to the same entities (Bunescu, 2012; Clark and Manning, 2015), and the solution where ensemble resolvers are explored (Rahman and Ng, 2011).

There has been substantial coreference research on high resource languages. By contrast, a limited number of studies have been dedicated to low resource languages in the last decade and mainly neural network based approaches have been proposed in these studies. A mention-pair model where mention relations are learned via a convolutional neural network (CNN) was developed for Indonesian (Auliarachman and

Purwarianti, 2019). The model was equipped with a classifier in order to eliminate cases with singleton mentions being included in a cluster. Another mention-pair model that was developed for the Persian language extracted hand-crafted, embedding-based, and rich semantic features of mentions and used them as input to a fully connected neural network for coreference resolution (Sahlani et al., 2020). The adaptation of an English mention-ranking model (Lee et al., 2008) to Arabic was enhanced with performance-related improvements such as the heuristic-based preprocessing of words and the use of a separately trained mention detection approach (Aloraini et al., 2020). A Siamese network architecture and an extended feature set of mentions were used for Polish coreference resolution (Niton et al., 2018).

Coreference resolution on Turkish has received little attention. The proposed studies mostly addressed pronoun resolution such as the decision tree-based approach developed by Yıldırım et al. (2007) and the extension of that work with the use of four other learning-based approaches, namely naive Bayes, support vector machine, k-nearest neighbour, and voted perceptron (Kılıçaslan et al., 2009). In the literature, there is only one Turkish coreference resolution study (Pamay and Eryiğit, 2018). That work followed the mention-pair approach and coreference decisions were made by applying decision tree and support vector machine classifiers to some linguistic mention features.

Deep learning approaches have been shown to perform on par or considerably better than statistical-based approaches in several language processing applications. However, to our best knowledge, no deep learning-based coreference research has taken place for the morphologically-rich language Turkish. This article presents the first Turkish neural coreference resolution work where mention-ranking task is particularly addressed. Two different learning-based models are developed for ranking candidate antecedents of a mention according to a score and selecting the highest scoring antecedent. In the first model, a set of well-studied features by existing literature (Bengtson and Roth, 2008; Durrett and Klein, 2013; Wiseman et al., 2015) are extracted for a mention and its candidate antecedents and then fed to a single-layer feed-forward neural network as input. Our second model closely follows the mention ranking approach of the end-to-end coreference solution proposed by Lee et al. (2007) which was successfully applied to other languages including Arabic (Aloraini et al., 2020) and Slovenian (Klemen and Žitnik, 2022). The contextual representations of a mention and its candidate antecedent mentions are learned from pre-trained language models, and a probability distribution is obtained over all possible pairings of the mention with

candidate antecedents using a two-layer feed-forward network. In order to obtain mention representations, several Turkish pre-trained language models with different architectures are explored including BERTurk and DistilBERTurk. In our work, the mention detection task is assumed to be done in advance and hence gold mentions provided by the publicly available Turkish coreference dataset are used. The model performances are evaluated using 10-fold cross-validation and compared based on automatic metrics MUC, B<sup>3</sup>, and CEAF-e.

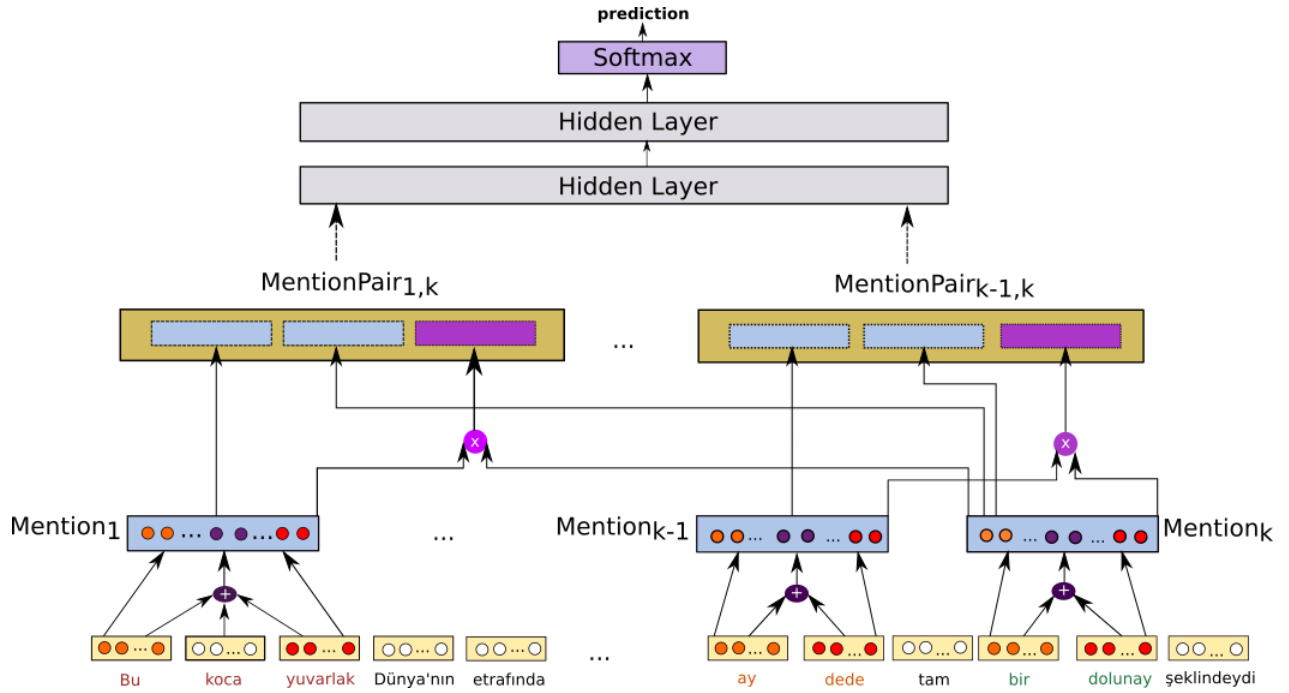
## 2. Methodology

For this study, we develop two neural models that follow the mention-ranking approach and analyze their performances on a Turkish coreference dataset. In both models, we pair an input mention (Mention<sub>k</sub>) with all preceding candidate mentions in the same document (Mention<sub>1</sub>, Mention<sub>2</sub>, ..., Mention<sub>k-1</sub>) and rank these identified mention pairs according to antecedent scores (AS<sub>k,1</sub>, AS<sub>k,2</sub>, ..., AS<sub>k,k-1</sub>). The antecedent score reflects the likelihood of two mentions being coreferent. The candidate mention in the pair with the highest score is selected as the correct antecedent of the input mention.

### First Model:

In this model (Model\_1), we first extract a set of features for each mention pair in order to assess the similarity between the contained mentions. Earlier approaches have utilized several features to capture similarities between mentions such as the features extracted directly from the text or the features learned from external sources (Sahlani et al., 2020). Here, we only utilized seven handcrafted features, with six of them being binary features as follows:

- *Sentence match*: whether the mentions appear in the same sentence or not
- *Number match*: whether the mentions agree in number (i.e., singular or plural) or not
- *String match*: whether mentions share the same lemma or not
- *Prefix match*: whether one mention is the prefix of the other mention or not
- *Suffix match*: whether one mention is the suffix of the other mention or not
- *Initial match*: whether one mention consists of the initials of the words in the other mention or not
- *Similarity*: the Jaro similarity of mentions



**Figure 3.** The architecture of the second model (Model\_2)

In multi-word mentions, the number agreement is applied to the last tokens of mentions whereas the lemmas of all tokens are considered while determining the string match value. The Jaro similarity is a normalized edit distance score between 0 and 1. In our case, a Jaro score of 0 means no match between the surface forms of mentions whereas 1 means the mentions match exactly.

For each mention pair, the corresponding set of features is fed to a single-layer feed-forward neural network as input. The network applies a linear transformation to the input ( $x$ ) and returns an antecedent score for candidate mention in the pair ( $y$ ) by multiplying the input with a weight matrix ( $W$ ) and adding a bias value ( $y=Wx+b$ ). The candidate mentions are ranked according to their normalized scores and the candidate with the highest score is selected as the correct antecedent for the input mention.

#### Second Model:

The second model (Model\_2), addresses the problem by adapting a well-studied end-to-end coreference scoring model (Lee et al., 2017; Klemen and Žitnik, 2022). In this model, we obtain the representation of a mention by concatenating the embedding of the first token, the embedding of the last token, and the weighted combination of the embeddings of all tokens in the mention. The embedding of the first token is included in order to capture the left context of the mention whereas the embedding of the last token brings the right context into computation. The learned weighted combination of all token embeddings encodes the internal structure of a

mention by using an attention mechanism that models its head token.


We form the representation of a mention pair by concatenating the representation of the first mention, the representation of the second mention, and element-wise multiplication of these representations. Mention pair representations are fed to a two-layer feed-forward neural network. The rectified linear activation function (RELU) is used for hidden layers. The softmax function is applied as the final activation function in order to obtain a probability distribution of all preceding candidate mentions. From among all candidates, the most probable mention is selected as the correct antecedent. The overall architecture of our second model is shown in Figure 3.

### 3. Experimental Setup


#### 3.1. Dataset

In this study, we used the publicly available Marmara Turkish Coreference Corpus (Schüller et al., 2007) as our dataset. The corpus contains 33 documents retrieved from the METU-Sabancı Turkish Treebank (Say et al., 2002) where each document consists of 26 to 424 sentences. The sentences are manually annotated with mentions and coreference chains that these mentions form. A textual expression (e.g., noun phrase, pronoun, or a nominalized adjective) that refers to an entity is considered as a mention. Each multi-word mention is annotated with the largest possible token span and no overlapping mentions are tagged. However, the remaining mentions of a document that are not part of any chain are not annotated.






a)



b)



c)

**Figure 1.** The statistics of annotated mentions

For this study, we also include 202 named entities (e.g., expressions that refer to a person, location, and organization) that are mentioned only once in these documents. Our dataset totally contains 5,372 mentions and 944 coreference chains capturing 5,170 mentions. As shown in Figure 1a, the majority of our mentions contain a single token (i.e., 4,133 mentions) whereas the number of tokens in a multi-word mention is between 2 and 24.

In order to answer the question of what forms a mention, we analyzed the part-of-speech (POS) tags of tokens in single-word and multi-word mentions. We used POS tags associated with the tokens in the treebank corpus and considered the POS tags of the first and last tokens for multi-word mentions. Figure 1b shows mention POS tags that appear at least 20 times in our dataset. We found that single-word expressions are often nouns (Noun), pronouns (Pron), and proper nouns (Prop). Our analysis also showed that multi-word

mentions often correspond to textual expressions that start with a noun, determiner (Det), or adjective (Adj) and end with a noun. It is particularly noteworthy that even verbs (Verb) and adverbs (Adv) are annotated as mentions. As shown in Figure 1c, the documents in our dataset contain between 17 and 359 mentions where the majority has more than 120 mentions.


In the dataset, the mentions that refer to the same real-world entity are clustered into coreference chains. Figure 2a shows the number of coreference chains that contain at most 20 mentions. In more than half of the cases, the chains contain 2 or 3 mentions and the entities with more than 20 mentions (up to 66 mentions) are observed to be rare (only 45 out of 944 chains).

We also examined how the mentions of the same entity are distributed in corresponding documents. We computed the distance between two mentions of the same chain by calculating the number of mentions that appear in between these mentions. The distance is taken as 0 if two mentions are not interleaved by other mentions. Figure 2b presents the number of coreferring mention pairs separated by at most 14 mentions. The results demonstrated that slightly more than half of the mentions that appear in the same chain have at most 3 other mentions in between.


The following is a representative chain from our dataset that consists of 8 mentions from 7 sentences. There are both single-word and multi-word mentions in

the chain and the surface forms of these underlined mentions are all different. Moreover, there is more than one mention in the same sentence (i.e., the mentions numbered as fifth and sixth in the fifth sentence) and mention POS tags vary between sentences.

- Cebinde bir düğün fotoğrafı<sup>1</sup> durur  
He holds a wedding photo<sup>1</sup> in his pocket
- Kendi düğününde çekilmiş bir fotoğraf<sup>2</sup> , uzun yıllar önce  
A photo taken at his own wedding<sup>2</sup> , many year ago
- Elini sol cebine sokup bir fotoğraf<sup>3</sup> çıkarttı , uzun\_uzun baktı  
He puts his hand in his left pocket and took out a photo<sup>3</sup> , took a long look
- Omzunun üstünden fotoğrafı<sup>4</sup> görebiliyordum  
I could see the photo<sup>4</sup> over his shoulder
- Bir düğün fotoğrafıydı<sup>5</sup> bu<sup>6</sup>  
It<sup>6</sup> was a wedding photo<sup>5</sup>
- Kerem'in sözünü ettiği fotoğraf<sup>7</sup> olmalıydı  
It should have been the photo that Kerem mentioned<sup>7</sup>
- Lacivert takım elbiseli adam fotoğrafta<sup>8</sup> gençti  
The man in the navy blue suit was young in the photo<sup>8</sup>



a)



b)

Figure 2. The statistics of annotated coreference chains

### 3.2. Model parameters and evaluation metrics

For this study, we performed several experiments using both models with different settings. In Model\_1, the annotations given in our dataset were used to extract the singularity and plurality information of input words and their lemmas. In Model\_2, we explored the use of both context-dependent and context-independent word embeddings (Miaschi and Dell'Orletta, 2020) to assess the impact of contextual information on coreference resolution. The context-independent embedding of a word is the same regardless of the context where the word appears. Here, we used fastText embeddings trained for Turkish on Common Crawl and Wikipedia articles using character n-grams of length 5 (Grave et al., 2018). We experimented with the default embedding dimension of 300 (fastText-300) and also reduced dimensions of 100 (fastText-100) and 200 (fastText-200).

A word might have different context-dependent embeddings based on its context (surrounding words), all of which capture varying uses of the word. Literature has investigated several neural architectures while producing context-dependent embeddings (Van der Heijden et al., 2020; Mars, 2022), each with its own optimization instruments and limitations. In this work, we obtained embeddings of input tokens from Turkish language models based on BERT (Devlin et al., 2019), DistilBERT (Sanh et al., 2019), and ELECTRA (Clark et al., 2020) architectures. In BERT architectures, some random tokens in the input are masked during training and the model learns to predict the original tokens. The Turkish BERT models (BERTurk) used in this work (Schwetter, 2021) were trained on Turkish OSCAR, Wikipedia, and OPUS corpora. We experimented with different models with small (BERTurk-32K) and large (BERTurk-128K) vocabulary sizes for both cased (BERTurk-cased) and uncased (BERTurk-uncased) training data. We also benefited from the DistilBERT architecture which is a distilled version of the BERT architecture that aims to reduce the parameter size (e.g., fewer encoder blocks) and hence increase the speed of the model. The DistilBERTurk model that we used (Schwetter, 2021) was a cased model with 32K vocabulary and trained on a portion of the original data used for training the BERTurk model. Finally, we experimented with the ELECTRA architecture where the input is corrupted by replacing some tokens with plausible incorrect alternatives during training. A generator model and a discriminator model are used to train a language model that is significantly smaller than the BERT model. The Turkish ELECTRA model used in this work (ELECTRA-base-mC4) was trained on a multilingual dataset and the cased model has a vocabulary of 32K (Schwetter, 2021).

For the experimental study, we trained Model\_1 and Model\_2 using 10-fold cross-validation and computed the mean scores across folds. Model\_1 and Model\_2 with a particular setting (i.e., with a specific pre-trained language model) was trained for 5, 10, and 15 epochs

each and their performances were compared. While training Model\_1, the cross entropy loss was used to adjust model weights and the stochastic gradient descent optimization with a learning rate of 0.005 was applied. In Model\_2, the hidden layer size was set to 64, and the Adam optimizer with learning rate of 0.005 and dropout with a rate of 0.4 were used for model training. We reported performance scores using three automatic metrics that are often used in coreference resolution studies, namely the link-based metric MUC (Vilain et al., 1995), the mention-based metric B<sup>3</sup> (Bagga and Baldwin, 1998), and the entity-based metric CEAF-e (Luo, 2005).

## 4. Results and Discussion

Table 1 presents the evaluation scores that we obtained for Model\_1 and Model\_2. The results showed that Model\_1 achieved the highest precision values but suffered from very low recall scores according to MUC and B<sup>3</sup> metrics. On the other hand, the precision of the model dropped significantly in CEAF-e metric despite an increase in its recall value. In terms of F1 scores, the performance of the model was surpassed by most of the Model\_2 settings. Since Model\_1 requires deep feature engineering, its performance substantially depends on the utilized features and their coverage. It is noteworthy to mention that the set of features used in this study can be extended to a larger set which would probably demonstrate a different resolution performance. Nonetheless, our scores indicate that it is yet practical to use Model\_1 as a strong baseline for Turkish neural coreference studies.

In terms of all metrics, Model\_2 settings where DistilBERT and ELECTRA language models are used received the lowest F1 scores among all settings with context-independent and context-dependent embeddings. The use of DistilBERT and ELECTRA embeddings resulted in very high precision values according to B<sup>3</sup>, but as observed in other metrics, the low recall value had a negative impact on the overall performance. The setting with DistilBERT model showed poor performance as compared to the setting with ELECTRA model.

The Model\_2 setting where BERTurk-uncased language model with 128K vocabulary is used obtained the highest F1 scores in MUC and CEAF-e metrics. According to the B<sup>3</sup> metric, its performance was the closest to the best performing model. In addition, the embeddings trained on the uncased dataset were observed to receive higher scores than those learned from the cased dataset for the same vocabulary size. When the dataset used to fine-tune a BERT model is scarce, the literature showed that the model often suffers from degraded performances (Yu et al., 2021; Zhang et al., 2021). However, here we observed that the larger model (BERTurk-128k-uncased) has a better resolution performance than the smaller model (BERTurk-32k-uncased) even though our coreference dataset is scarce.

**Table 1.** Performance evaluations of all models (10 epochs)

Model Name	Embedding Type	MUC			B <sup>3</sup>			CEAF-e		
		<i>P</i>	<i>R</i>	<i>F1</i>	<i>P</i>	<i>R</i>	<i>F1</i>	<i>P</i>	<i>R</i>	<i>F1</i>
Model_1		0.958	0.353	0.501	0.983	0.401	0.554	0.245	0.681	0.347
	<i>fastText-100</i>	0.682	0.426	0.520	0.766	0.445	0.562	0.298	0.658	0.410
	<i>fastText-200</i>	0.699	0.573	0.629	0.656	0.547	0.593	0.415	0.616	0.489
	<i>fastText-300</i>	0.668	0.568	0.612	0.631	0.520	0.567	0.398	0.626	0.482
	<i>BERTurk-32k-cased</i>	0.699	0.631	0.660	0.604	0.553	0.560	0.437	0.549	0.472
Model_2	<i>BERTurk-32k-uncased</i>	0.717	0.651	0.679	0.572	0.590	0.569	0.453	0.558	0.488
	<i>BERTurk-128k-cased</i>	0.711	0.617	0.654	0.638	0.531	0.564	0.427	0.576	0.476
	<i>BERTurk-128k-uncased</i>	0.718	0.681	0.697	0.603	0.570	0.574	0.486	0.556	0.508
	<i>DistilBERT</i>	0.237	0.123	0.134	0.928	0.264	0.392	0.167	0.530	0.243
	<i>ELECTRA</i>	0.490	0.426	0.449	0.867	0.300	0.408	0.202	0.525	0.270

Using context-independent embeddings in Model\_2 achieved the highest F1 score in B<sup>3</sup> metric, lagged behind context-dependent embeddings in MUC metric, and showed a competitive performance in CEAF-e metric. The scores achieved by the setting where 200-dimensional embeddings are used were higher than those obtained by embeddings with other dimensions. These results arguably indicate that context-independent embeddings can be used for Turkish coreference resolution in the lack of a large dataset required to fine-tune a pre-trained language model efficiently.

Figure 4 presents the behavior of all models with different settings where the training was performed for 5, 10, and 15 epochs. Increasing the number of epochs positively impacted the overall F1 performance of Model\_1 (i.e., feature\_based model) and Model\_2 settings that utilize context-independent fastText embeddings. Model\_1 achieved an improvement of 0.002 in MUC, and 0.001 in B<sup>3</sup> and CEAF-e metrics once the number of epochs is increased from 5 to 15. The improvements seen in Model\_2 settings with fastText embeddings were in the range of 0.084-0.114 for MUC, 0.021-0.045 for B<sup>3</sup>, and 0.064-0.118 for CEAF-e metrics, respectively. The performance of Model\_2 with DistilBERT and ELECTRA embeddings were observed to decline once the epoch number is increased from 5 to 15. However, the use of BERT embeddings did not show any emergent pattern with respect to increased training epochs.

## 5. Conclusions

In this article, we present the first Turkish neural coreference resolution study where two different models that follow the mention-ranking approach are developed. The models cluster given mentions by ranking candidate antecedents of each mention and selecting the candidate with the highest score. The first model utilizes a set of hand-crafted features of mentions and uses them as input in a feed-forward neural network. On the other hand, the second model first obtains contextual representations of mentions using pre-trained language models and feeds representation pairs of mentions and candidate antecedents to a feed-forward neural network. We experiment with different context-dependent and context-independent language models and report their overall performances in resolving Turkish coreference mentions. Our results demonstrate that utilizing pre-trained language models (in particular BERT base models) for this task is beneficial and promising results can be obtained despite the lack of large-scale Turkish coreference datasets.

Given these encouraging results, we plan to extend this work in several directions. We first plan to collect a large-scale Turkish coreference dataset in order to fine-tune pre-trained models more efficiently and better learn the coreference relations. We argue that an extensive dataset would help us to obtain more accurate insights about the impact of Turkish language models on this task. Although this study is a significant advance in the

state-of-the-art, there is still room for future improvements. One important future work to investigate is developing a mention detection approach for Turkish and assessing its performance in an end-to-end coreference resolution system. Finally, we plan to explore new ways of achieving higher resolution performances by studying mention-pair and entity-mention approaches for Turkish using neural network architectures.

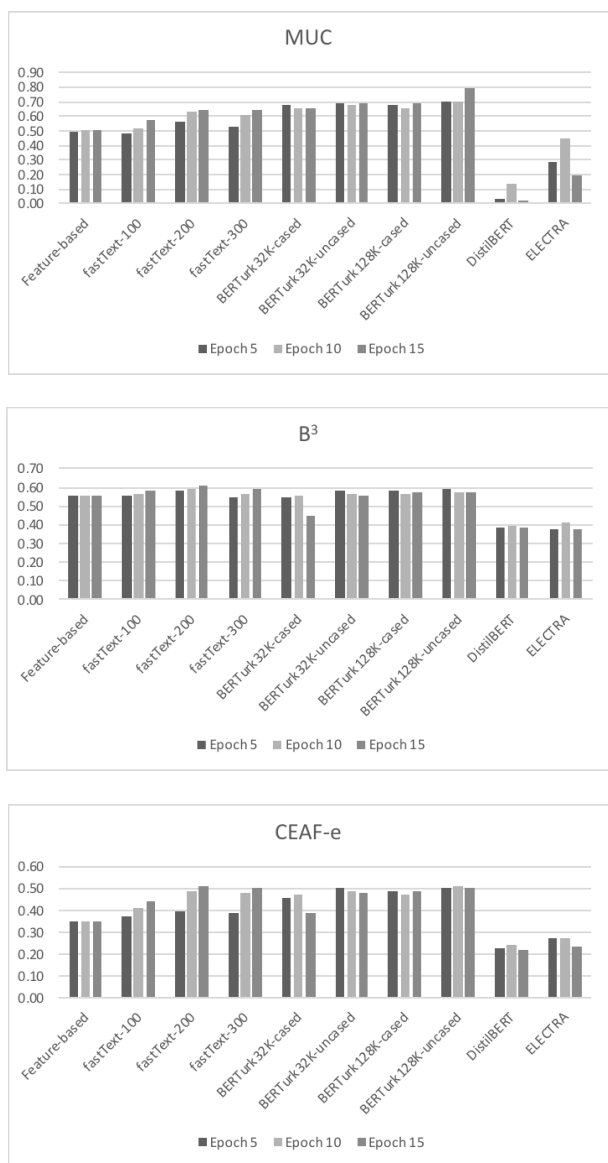


Figure 4. F1 scores of models for different epoch numbers

## References

Aloraini, A., Yu, J., Poesio, M., 2020. Neural Coreference Resolution for Arabic. The Third Workshop on Computational Models of Reference, Anaphora and Coreference, pp. 99-110.

Auliarachman, T., Purwarianti, A., 2019. Coreference Resolution System for Indonesian Text with Mention Pair Method and Singleton Exclusion using Convolutional Neural Network. ICAICTA2019, The International

Conference of Advanced Informatics: Concepts, Theory and Applications, pp. 1-5.

Bagga, A., Baldwin, B., 1998. Algorithms for scoring coreference chains. LREC 1998, The 1st International Conference on Language Resources and Evaluation, pp. 563-566.

Bengtson, E., Roth, D., 2008. Understanding the Value of Features for Coreference Resolution. EMNLP 2008, The Conference on Empirical Methods in Natural Language Processing, pp. 294-303.

Bhattacharjee, S., Haque, R., de Buy Wenniger, G.M., Way, A., 2020. Investigating Query Expansion and Coreference Resolution in Question Answering on BERT. In: E. Métais, F. Mezziane, H. Horacek, P. Cimiano (Eds.), Natural Language Processing and Information Systems, NLDB 2020, Lecture Notes in Computer Science, 12089 pp. 47-59. Springer, Cham. doi:10.1007/978-3-030-51310-8\_5

Bunescu, R., 2012. Adaptive Clustering for Coreference Resolution with Deterministic Rules and Web-Based Language Models. SemL 2012, The First Joint Conference on Lexical and Computational Semantics, pp. 11-19.

Cai, J., Strube, M., 2010. End-to-End Coreference Resolution via Hypergraph Partitioning. Coling 2010, The 23rd International Conference on Computational Linguistics, pp. 143-151.

Clark, K. Manning, C.D., 2015. Entity-Centric Coreference Resolution with Model Stacking. ACL-IJCNLP 2015, The 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing, pp.1405-1415.

Clark, K., Luong, M.T., Le, Q.V., Manning, C.D., 2020. ELECTRA: Pre-training Text Encoders as Discriminators Rather Than Generators. The ACL Workshop on Computational Approaches to Semitic Languages, pp. 63-70.

Denis, P., Baldrige, J., 2008. Specialized Models and Ranking for Coreference Resolution. The 2008 Conference on Empirical Methods in Natural Language Processing, pp. 660-669.

Devlin, J., Chang, M., Lee, K., Toutanova, K., 2019. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. NAACL-HLT 2019, The Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, pp. 4171-4186.

Durrett, G., Klein, D., 2013. Easy Victories and Uphill Battles in Coreference Resolution. EMNLP 2013, the 2013 Conference on Empirical Methods in Natural Language Processing, pp.1971-1982.

Fang, K., Jian, F., 2019. Incorporating Structural Information for Better Coreference Resolution. IJCAI 2019, The Twenty-Eighth International Joint Conference on Artificial Intelligence, pp. 5039-5045.

Fei, H., Li, X., Li, D., Li, P., 2019. End-to-end Deep Reinforcement Learning Based Coreference Resolution. The 57th Annual Meeting of the Association for Computational Linguistics the ACL Workshop on Computational Approaches to Semitic Languages, pp. 660-665.

Grave, E., Bojanowski, P., Gupta, P., Joulin, A., Mikolov, T., 2018. Learning Word Vectors for 157 Languages. LREC 2018, The International Conference on Language Resources and Evaluation.

- Hacıoğlu, K., Douglas, B., Chen, Y., 2005. Detection of entity mentions occurring in English and Chinese text. *Human Language Technology Conference and Conference on Empirical Methods in Natural Language Processing*, pp. 379-386.
- Hoste, V., 2016. The Mention-Pair Model. In: M. Poesio, R. Stuckardt, Y. Versley (Eds.) *Anaphora Resolution. Theory and Applications of Natural Language Processing* pp. 269-282 Springer, Berlin, Heidelberg. doi: 10.1007/978-3-662-47909-4\_9
- Kılıçaslan, Y., Güner, E.S., Yıldırım, S., 2009. Learning-based pronoun resolution for Turkish with a comparative evaluation. *Computer Speech Language*, 23(3), 311-331. doi: 10.1016/j.csl.2008.09.001
- Klemen, M., Žitnik, S., 2022. Neural Coreference Resolution for Slovene Language. *Computer Science and Information Systems*, 19(2), 495-521. doi: 10.2298/CSIS201120060K
- Kriman, S., Heng, J., 2021. Joint Detection and Coreference Resolution of Entities and Events with Document-level Context Aggregation. *ACL-IJCNLP 2021, The 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing: Student Research Workshop*, pp. 174-179.
- Lai, T.M., Bui, T., Kim, D.S., 2022. End-To-End Neural Coreference Resolution Revisited: A Simple Yet Effective Baseline. *ICASSP 2022, The IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 8147-8151.
- Lata, K., Singh, P., Dutta, K., 2022. Mention detection in coreference resolution: survey. *Applied Intelligence*, 52, 9816-9860. doi: 10.1007/s10489-021-02878-2
- Lee, K., He, L., Lewis, M., Zettlemoyer, L., 2017. End-to-End Neural Coreference Resolution. *EMNLP 2017, The 2017 Conference on Empirical Methods in Natural Language Processing*, pp. 188-197.
- Lee, K., He, L., Zettlemoyer, L., 2018. Higher-order coreference resolution with coarse-to-fine inference. *NAACL 2018, The Annual Conference of the North American Chapter of the Association for Computational Linguistics*, pp. 687-692.
- Li, Z., Shi, K., Chen N.F., 2021. Coreference-Aware Dialogue Summarization. *The 22nd Annual Meeting of the Special Interest Group on Discourse and Dialogue*, pp. 509-519.
- Luo, X., Ittycheriah, A., Jing, H., Kambhatla, N., Roukos, S., 2004. A mention-synchronous coreference resolution algorithm based on the Bell tree. *ACL 2004, The 42nd Annual Meeting on Association for Computational Linguistics*, pp. 135-142.
- Luo, X., 2005. On Coreference Resolution Performance Metrics. *Human Language Technology Conference and Conference on Empirical Methods in Natural Language Processing*, pp. 25-32.
- Mars, M., 2022. From Word Embeddings to Pre-Trained Language Models: A State-of-the-Art Walkthrough. *Applied Sciences*. 12(17). doi: 10.3390/app12178805
- Miaschi, A., Dell'Orletta, F., 2020. Contextual and Non-Contextual Word Embeddings: an in-depth Linguistic Investigation. *The 5th Workshop on Representation Learning for NLP*, pp. 110-119.
- Niton, B., Morawiecki, P., Ogrodniczuk, M., 2018. Deep Neural Networks for Coreference Resolution for Polish. *LREC 2018, The International Conference on Language Resources and Evaluation*, pp. 395-400.
- Pamay, T., Eryiğit, G., 2018. Turkish Coreference Resolution. *INISTA 2018, The Innovations in Intelligent Systems and Applications*, pp. 1-7.
- Park, C., Lee, C., 2015. Mention Detection using Bidirectional LSTM-CRF Model. *The Annual Conference on Human and Language Technology*, pp. 224-227.
- Park, C., Lee, C., Lim, S., 2017. Mention detection using pointer networks for coreference resolution. *ETRI Journal*, 39(5), 652-661. doi: 10.4218/etrij.17.0117.0140
- Rahman, A., Ng, V., 2011. Narrowing the Modeling Gap: A Cluster-Ranking Approach to Coreference Resolution. *Journal of Artificial Intelligence Research*, 40, 469-521. doi: 10.1613/jair.3120
- Rahman, A., Ng, V., 2011. Ensemble-based coreference resolution. *IJCAI 2011, The Twenty-Second international joint conference on Artificial Intelligence*, pp. 1884-1889.
- Sahlani, H., Hourali, M., Minaei-Bidgoli, B., 2020. Coreference Resolution Using Semantic Features and Fully Connected Neural Network in the Persian Language. *International Journal of Computational Intelligence Systems*, 13(1), 1002-1013. doi: 10.2991/ijcis.d.200706.002
- Sanh, V., Debut, L., Chaumond, J., Wolf, T., 2019. DistilBERT, a distilled version of BERT: smaller, faster, cheaper and lighter. *arXiv*, doi: 10.48550/ARXIV.1910.01108  
10.48550/arXiv.1706.01863
- Sapena, E., Padró, L., Turmo, J., 2010. Relaxcor: A global relaxation labeling approach to coreference resolution. *The 5th International Workshop on Semantic Evaluation*, pp. 88-91.
- Say, B., Zeyrek, D., Oflazer, K., Özge, U., 2002. Development of a corpus and a treebank for present-day written Turkish. *ICTIL 2002, The 11th International Conference of Turkish Linguistics*, pp. 183-192.
- Schüller, P., Cingilli, K., Tunçer, F., Sürmeli, B. G., Pekel, A., Karatay, A. H., Karakaş, H. E., 2007. Marmara Turkish coreference corpus and coreference resolution baseline. *arXiv*, doi: 10.48550/arXiv.1706.01863
- Schweterr, S., 2021. BERTurk. <https://github.com/stefan-it/turkish-bert>
- Soon, W.M., Ng, H.T., Lim, D.C.Y., 2001. A machine learning approach to coreference resolution of noun phrases. *Computational Linguistics*, 27(4), 521-544. doi: 10.1162/089120101753342653
- Soraluze, A., Arregi, O., Arregi, X., Ceberio, K., De Ilaraza, A.D., 2012. Mention detection: First steps in the development of a Basque coreference resolution system. *KONVENS 2012, The 11th Conference on Natural Language Processing*, pp.128-136.
- Steinberger, J., Poesio, M., Kabadjov, M.A., Ježek, K., 2007. Two uses of anaphora resolution in summarization. *Information Processing Management*, 43(6), 1663-1680. doi: 10.1016/j.ipm.2007.01.010
- Uryupina, O., Moschitti, A., 2015. A State-of-the-Art Mention-Pair Model for Coreference Resolution. *The Fourth Joint Conference on Lexical and Computational Semantics*, pp. 289-298.
- Van der Heijden, N., Abnar, S., Shutova, E., 2020. A Comparison of Architectures and Pretraining Methods for Contextualized Multilingual Word Embedding. pp. 9090-9097.
- Vilain, M., Burger, J., Aberdeen, J., Connolly, D., Hirschman, L., 1995. A model-theoretic coreference scoring scheme. *The 6th Message Understanding Conference (MUC-6)*, pp. 45-52.



- Wang, B., Lu, W., Wang, Y., Jin, H., 2018. A Neural Transition-based Model for Nested Mention Recognition. The 2018 Conference on Empirical Methods in Natural Language Processing, pp. 1011-1017.
- Wiseman, S., Rush, A.M., Shieber, S., Wetson, J., 2015. Learning Anaphoricity and Antecedent Ranking Features for Coreference Resolution. ACL-IJCNLP 2015, The 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing , pp. 1416-1426.
- Wiseman, S., Rush, A. M., Shieber, S. M., 2016. Learning Global Features for Coreference Resolution. The Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, pp. 994-1004.
- Yang, X., Su, J., Lang, J., Tan, C. L., Liu, T., Li, S., 2008. An Entity-Mention Model for Coreference Resolution with Inductive Logic Programming. ACL08-HLT, The 46th Annual Meeting of the Association for Computational Linguistics and the Human Language Technology Conference , pp. 843-851.
- Yıldırım, S., Kılıçaslan, Y., Yıldız, T., 2009. Pronoun Resolution in Turkish Using Decision Tree and Rule-Based Learning Algorithms. In: Z. Vetulani, H. Uszkoreit (Eds.), Human Language Technology, Challenges of the Information Society, LTC 2007, Lecture Notes in Computer Science, 5603, pp. 270-278) Springer. doi: 10.1007/978-3-642-04235-5\_23
- Yu, Y., Zuo, S., Jiang, H., Ren, W., Zhao, T., Zhang, C., 2021. Fine-Tuning Pre-trained Language Model with Weak Supervision: A Contrastive-Regularized Self-Training Approach, The Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, pp. 1063-1077.
- Zhang, R., Nogueira dos Santos, C., Yasunaga, M., Xiang, B., Radev, D., 2018. Neural Coreference Resolution with Deep Biaffine Attention by Joint Mention Detection and Mention Clustering. The 56th Annual Meeting of the Association for Computational Linguistics, pp. 102-107.
- Zhang, T., Wu, F., Katiyar, A., Weinberger, K. Q., Artzi, Y., 2021. Revisiting Few-sample BERT Fine-tuning. The 9th International Conference on Learning Representations.
- Zitouni, I., Sorensen, J., Luo, X., Florian, R., 2005. The impact of morphological stemming on Arabic mention detection and coreference resolution. The ACL Workshop on Computational Approaches to Semitic Languages, pp. 63-70.