



**BANDIRMA
ONYEDİ EYLÜL
ÜNİVERSİTESİ**


**BMBAD
BJESR**

Mühendislik Bilimleri ve Araştırmaları Dergisi
Journal of Engineering Sciences and Researches

Cilt/Volume : 4

Sayı/Issue : 2

Yıl/Year : 2022





BMBAD
BJESR

Mühendislik Bilimleri ve Araştırmaları Dergisi
Journal of Engineering Sciences and Researches



Müh.Bil.ve Araş.Dergisi

Cilt/Vol. 4

Sayı/Issue 2

2022

ISSN: 2687-4415

Sahibi/Owner

Prof.Dr. Süleyman ÖZDEMİR *Bandırma Onyedi Eylül Üniversitesi Rektörü*

Baş Editor /Editor in Chief

Doç.Dr. Muhammet Nuri SEYMAN *Bandırma Onyedi Eylül Üniversitesi*

Yardımcı Editörler/Associate Editors

Doç.Dr. Serhat DUMAN *Bandırma Onyedi Eylül Üniversitesi*

Dr.Öğr. Üyesi Onursal ÇETİN *Bandırma Onyedi Eylül Üniversitesi*

Alan Editörleri/Field Editors

Prof. Dr. Recep ÇALIN (Kırıkkale Üniversitesi) (Malzeme)

Doç. Dr. Serhat DUMAN (Bandırma Onyedi Eylül Üniversitesi) (Elektrik-Elektronik)

Doç. Dr. Bülent BÜYÜK (Bandırma Onyedi Eylül Üniversite) (Mühendislik Temel Bilimleri)

Doç. Dr. Onur ÜLKER (Eskişehir Teknik Üniversitesi) (Orman)

Dr. Öğr. Üyesi Aykut DİKER (Bandırma Onyedi Eylül Üniversitesi) (Bilgisayar)

Dr. Öğr. Üyesi Uğur Erdem DOKUZ (Niğde Ömer Halisdemir Üniversitesi) (Yer Bilimleri)

Mizanpaj

Arş. Gör. F. Kebire BARDAK (Bandırma Onyedi Eylül Üniversitesi)

Dil Editörü

Arş. Gör. Muhammed Şamil BALCI (Bandırma Onyedi Eylül Üniversitesi)

Editörler Kurulu/Editorial Board

Prof. Dr. Feyzullah TEMURTAŞ, ftemurtas@bandirma.edu.tr, Bandırma Onyedli Eylül Üniversitesi

Prof. Dr. Mehmet KURBAN, mehmet.kurban@bilecik.edu.tr, Bilecik Şeyh Edibali Üniversitesi

Prof. Dr. Fırat KAÇAR, gkacar@istanbul.edu.tr, İstanbul Cerrahpaşa Üniversitesi

Prof. Dr. Cihan KARAKUZU, cihan.karakuzu@bilecik.edu.tr, Bilecik Şeyh Edibali Üniversitesi

Doç. Dr. Muhammet Nuri SEYMAN, mseyman@bandirma.edu.tr, Bandırma Onyedli Eylül Üniversitesi

Doç. Dr. Gökçen NUR YILMAZ, gokceyilmaz@tedu.edu.tr, TED Üniversitesi

Doç. Dr. Abdullah YEŞİL, ayesil@bandirma.edu.tr, Bandırma Onyedli Eylül Üniversitesi

Doç. Dr. Muharrem PUL, mpul@kku.edu.tr, Kırıkkale Üniversitesi

Doç. Dr. Ali DURMUŞ, adurmus@kayseri.edu.tr, Kayseri Üniversitesi

Dr. Öğr. Üye. Onursal ÇETİN, ocetin@bandirma.edu.tr, Bandırma Onyedli Eylül Üniversitesi

Dr. Öğr. Üye. Hayri YAMAN, hyaman@kku.edu.tr, Kırıkkale Üniversitesi

Dr. Öğr. Üye. Rahim DEHKHARGHANI, rdehkharghani@bonabu.ac.ir, Computer Eng., Natural Language Processing, and Sentiment Analysis

Behnaz HASSANSHAHİ, behnaz.hassanshahi@oracle.com, Oracle Lab Australia, Computer Eng. Dynamic Analysis and Fuzzing Techniques

Danışma Kurulu/Advisory Board

Prof. Dr. Hasan BAYINDIR, hasanbayindir@dicle.edu.tr, Dicle Üniversitesi

Prof. Dr. Hasan ERBAY, erbay@kku.edu.tr, Kırıkkale Üniversitesi

Prof. Dr. Mustafa GÜNAY, mgunay@karabuk.edu.tr, Karabük Üniversitesi

Prof. Dr. Fırat KAÇAR, gkacar@istanbul.edu.tr, İstanbul Cerrahpaşa Üniversitesi

Prof. Dr. Cihan KARAKUZU, cihan.karakuzu@bilecik.edu.tr, Bilecik Şeyh Edibali Üniversitesi

Prof. Dr. Uğur TEMİZ, ugur.temiz@bozok.edu.tr, Yozgat Bozok Üniversitesi

Prof. Dr. Mehmet KURBAN, mehmet.kurban@bilecik.edu.tr, Bilecik Şeyh Edibali Üniversitesi

Prof. Dr. Osman YILDIZ, osmanyildiz@kku.edu.tr, Kırıkkale Üniversitesi

Prof. Dr. Nejat YUMUŞAK, nyumusak@sakarya.edu.tr, Sakarya Üniversitesi

Prof. Dr. İbrahim DEVELİ, ideveli@erciyes.edu.tr, Erciyes Üniversitesi

Doç. Dr. Adem DALCALI, adalcali@bandirma.edu.tr, Bandırma Onyedli Eylül Üniversitesi

Doç. Dr. Sertaç BAYHAN, sbayhan@hbku.edu.qa, Hamad Bin Khalifa University

Doç. Dr. Selim ÖNCÜ, soncu@karabuk.edu.tr, Karabük Üniversitesi

Doç. Dr. İlker TÜRKER, iturker@karabuk.edu.tr, Karabük Üniversitesi

Doç. Dr. Hasan YAMIK, hasan.yamik@bilecik.edu.tr, Bilecik Şeyh Edebalı Üniversitesi

Doç. Dr. Muharrem PUL, mpul@kku.edu.tr, Kırıkkale Üniversitesi

Dr. Öğr. Üye. Ali DURMUŞ, adurmus@kayseri.edu.tr, Kayseri Üniversitesi

Dr. Öğr. Üye. Serhat Berat EFE, Sefe@bandirma.edu.tr, Bandırma Onyediy Eylül Üniversitesi

Dr. Öğr. Üye. Kenan HATİPOĞLU, kenan.hatipoglu@mail.vwu.edu, West Virginia Area University

Dr. Öğr. Üye. Hayri YAMAN, hyaman@kku.edu.tr, Kırıkkale Üniversitesi

Dr. Öğr. Üye. Rahim DEHKHARGHANI, rdekharghani@bonabu.ac.ir, Computer Eng., Natural Language Processing, and Sentiment Analysis

Behnaz HASSANSHAHİ, behnaz.hassanshahi@oracle.com, Oracle Lab Australia, Computer Eng. Dynamic Analysis and Fuzzing Techniques

Yazışma Adresi/ Correspondence Address

Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, 10200 Bandırma/ Balıkesir, Türkiye

<https://dergipark.org.tr/tr/pub/bjesr>

bjesr@bandirma.edu.tr

Tel: 0266 717 0117 (3512)

İÇİNDEKİLER/CONTENTS

(Araştırma Makalesi/Research Article)

Döşeme Donatısının Betonarme Tablalı Kirişlerin Eğilme Momentine Katkısı

Contribution of Slab Reinforcement to the Bending Moment of Beams with Reinforced Concrete Slabs 99-111

Yunus GENÇ, Orhan DOĞAN

(Araştırma Makalesi/Research Article)

Ağırlıklı Oy Tabanlı Topluluk Sınıflandırma Algoritması ile Göğüs Kanseri Teşhisi

Breast Cancer Diagnosis with Weighted Vote Based Ensemble Classification Algorithm 112-120

Sinem BOZKURT KESER, Kemal KESKİN

(Araştırma Makalesi/Research Article)

Model ve Veri Odaklı Yaklaşımlar ile Nesne Tespit Başarısının Arttırılmasına Yönelik ESA ve Veri Seti Optimizasyonları

CNN and Dataset Optimizations to Improve Object Detection Performance with Model and Data-Centric Approaches 121-128

Önder ALPARSLAN, Ahmet ÖZCAN, Ömer ÇETİN

(Araştırma Makalesi/Research Article)

Kızıl Tilki Optimizasyon Algoritması ile DA-DA Alçaltıcı Tip Dönüştürücü Kontrolör Katsayılarının Optimizasyonu

Optimization of Buck Converter Controller Coefficients with Red Fox Optimization Algorithm 129-140

Ersagun Kürşat YAYLACI, Ahmet Erdem YILMAZ, Hatice Nur ÖZDEŞ

(Araştırma Makalesi/Research Article)

Derin Öğrenme Metodu ve Ayırık Dalgacık Dönüşümü Kullanarak BT Görüntülerinden Akciğer Kanseri Teşhisi

Discrete Wavelet Transform and Deep Learning Model for Diagnosis of Lung Cancer from CT Images

141-154

Mehmet Akif ÇİFÇİ

Remote Access Greenhouse Automation Application Based on LabVIEW

Uzaktan Erişimli LabVIEW Tabanlı Sera Otomasyonu Uygulaması

155-163

Behçet KOCAMAN, Mehmet Fatih GÜLER

Synthesis of Linear Antenna Arrays with Physics Based AOA, CryStAl and LA Algorithms

Lineer Anten Dizilerinin Fizik Tabanlı AOA, CryStAl ve LA Algoritmaları ile Sentezi

164-172

Ali DURMUS, Zafer YILDIRIM

Farklı Cüruf Türlerinden Geopolimer Harç Üretimi

Production of Geopolymer Mortar from Different Slag Types

173-178

Şinasi BİNGÖL

Helisel Kanatçıklara Sahip Bir Boruda Nanoakışkan Kullanımının ve Helisel Kanatçık Sayısının Değişiminin Isı Transferi Üzerindeki Etkilerinin İncelenmesi

Investigation of the Effects of Nanofluid Usage and Variation of Helical Fin Number on Heat Transfer in a Pipe With Helical Fins

179-188

Mustafa DOĞAN, Tolga DEMİRCAN

Human Face Recognition Using Deep Neural Networks

Derin Sinir Ağlarını Kullanarak İnsan Yüzü Tanıma

189-198

Kaplan KAPLAN, Fatma KUNCAN

Seasonality Determination of Stream Flows For Planning Hydraulic Structures in Kızılırmak Basin

Kızılırmak Havzasında Hidrolik Yapıların Planlanmasında Nehir Akımlarının Mevsimselliğinin Belirlenmesi

199-211

Naci BÜYÜKKARACIĞAN

Automatic Classification of Healthy and Sick Broilers in Terms of Avian Influenza by Using Neural Networks

Sağlıklı ve Hasta Etlik Piliçlerin Kuş Gribi Açısından Sinir Ağları Kullanarak Otomatik Sınıflandırılması

212-226

Yalçın IŞIK, Ahmet KAYABAŞI

Katı Hal Güç Kuvvetlendiricisinin LC-GFDM İletim Sinyali Üzerindeki Etkisinin İncelenmesi

Investigation of the Effect of Solid-State Power Amplifier on LC-GFDM Transmission Signal

227-235

Şakir ŞİMŞİR, Necmi TAŞPINAR

Transfer Öğrenme ve Komşuluk Bileşen Analizine Dayalı Balgam Yayma Mikroskop Görüntüleri Üzerinden Otomatik Tüberküloz Teşhisi

Automated Tuberculosis Diagnosis on Sputum Smear Microscope Images Based on Transfer Learning and Neighborhood Component Analysis

236-246

Ömer Faruk NASİP, Kenan ZENGİN

Auto-detection of Intermetallic and Eutectic Phases in Microstructure of the AZ91 Mg-alloys by Image Processing Techniques

AZ91 Mg Alaşımlarının Mikroyapısındaki İntermetalik ve Ötektik Fazların Görüntü İşleme Teknikleriyle Otomatik Tespiti

247-258

Abdullah ELEN, Levent ELEN

COVID-19'un Yayılmasını Önlemek için CNN ile Yüz Maskesi Tespiti

Face Mask Detection using CNN for Preventing the Spread of COVID-19

259-265

Alihan DEĞİRMENCİLER, Berat CENGİZ, Kadir İLERİ

Kenevirden İmal Edilen Geotekstilin Sıkıştırılmış Zeminlerin Dayanımı Üzerindeki Etkisi

The Effect of Geotextile Made of Hemp on the Strength of Compacted Soils

266-277

Erdem DEMİR, Ersin KOLAY, Yekta KARADUMAN

Investigation of the Sample Disturbance Effects on Consolidation Parameters Obtained from Conventional Oedometer Tests

Numune Örselenmesinin Geleneksel Ödometre Deneyleri ile Belirlenen Konsolidasyon Parametrelerine Olan Etkilerinin İncelenmesi

278-286

Muharrem DUMANLILAR, Mustafa FENER, Mehmet Can BALCI

Ceyhan Bölgesi Bazaltlarının Bazı Fiziksel ve Mekanik Özelliklerinin P Dalga Hızı ile Tahmini

Prediction of Some Physical and Mechanic Properties of Basalts in Ceyhan Region Using P Wave Velocity

287-295

Esmâ KAHRAMAN

Yüksek Boyutlu Nümerik Optimizasyon Problemlerinin Çözümünde Kelebek Optimizasyon Algoritmasının Performansının Değerlendirilmesi

Evaluation of The Performance of Butterfly Optimization Algorithm in Solving High-Dimensional Numerical Optimization Problems

296-303

Ceren BAŞTEMUR KAYA, Ebubekir KAYA

Twitter Platformundan Elde Edilen Türkçe Saldırgan Dil Derlemi

A Corpus of Turkish Offensive Language on Twitter Platform

304-316

Şeyma ŞAHİNER YILMAZ, İlyas ÖZER, Hadi GÖKÇEN

Evaluation of Machine Learning Performance in Wildfire Susceptibility Mapping Under Limited Training Data Condition

Sınırlı Eğitim Verileri Durumunda Orman Yangını Duyarlılık Haritalamasında Makine Öğrenimi Performansının Değerlendirilmesi

317-327



Mahyat SHAFAPOURTEHRANY

LED Aydınlatma Sistemlerinde Derin Öğrenme Tabanlı Harmonik Tahminleme

Deep Learning Based Harmonic Estimation in LED Illumination Systems

328-334

İlyas ÖZER, Harun ÖZBAY, Serhat Berat EFE



Döşeme Donatısının Betonarme Tablalı Kirişlerin Eğilme Momentine Katkısı

Contribution of Slab Reinforcement to the Bending Moment of Beams with Reinforced Concrete Slabs

¹Yunus GENÇ , ²Orhan DOĞAN 

^{1,2}Kırıkkale Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Kırıkkale, Türkiye

¹yunusgenc71@yandex.com.tr, ²odogan@kku.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 22 February 2022

Accepted : 9 May 2022

Keywords:

T-Beams, Negative Bending Moment, Slab Reinforcement, System and Floor Mechanization, Strong Column-Weak Beam

ABSTRACT

It is known that in the beam strength calculation of a reinforced concrete building, the slab concrete contributes to the beam in the span, but the slab reinforcement parallel to the beam is neglected at the supports. While many countries' codes suggest that these neglected reinforcement should be taken into account, there is no such statement in our national codes. It is of great importance that parallel slab reinforcements are partially/fully taken into account, as this neglect will put at risk the condition of strong column-weak beam, that is, system mechanization, which precedes hinging in beams. In this study, the contribution of slab reinforcements parallel to the beam, located within the effective table width in the beam support region, to the load carrying capacity of the beam was investigated. In this study, a total of 3 reinforced concrete beams, a fully scaled beam with a slab thickness of 10 cm and a width of 125 cm, with a beam size of 25x45 cm and two beams without slabs of the same dimensions, were produced and subjected to static three-point bending tests. As a result of this study, it is determined that almost all of the slab reinforcements within the effective table width determined in accordance with Turkish Standards-500 (2000) contribute to the moment carrying capacity as a beam reinforcement.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 22 Şubat 2022

Kabul : 9 Mayıs 2022

Anahtar Kelimeler:

Tablalı Kirişler, Negatif Eğilme Momenti, Döşeme Donatısı, Sistem ve Kat Mekanizması, Güçlü Kolon-Zayıf Kiriş

ÖZET

Bir betonarme binanın kiriş dayanımı hesabında, açıklıkta kirişe döşeme betonunun katkı verdiği ancak, mesnetlerde kirişe paralel döşeme donatısının ihmal edildiği bilinmektedir. Birçok ülke yönetmeliklerinde, ihmal edilen bu donatıların dikkate alınması hususunda önerilerde bulunulurken, ulusal yönetmeliklerimizde böyle bir ifade bulunmamaktadır. Bu ihmalin kirişlerde mafsallaşmayı önceleyen güçlü kolon-zayıf kiriş yani sistem mekanizması koşulu riskte atacağından paralel döşeme donatılarının kısmen/tamamen hesaba katılması büyük önem arz etmektedir. Bu çalışma ile kiriş mesnet bölgesinde etkili tabla genişliği içerisinde yer alan kirişe paralel döşeme donatılarının kirişin yük taşıma kapasitesine katkısı araştırılmıştır. Bu kapsamda, tabla kalınlığı 10 cm, genişliği 125 cm olan 25x45 cm boyutunda 1/1 ölçekli bir tablalı ve aynı ebatlarda iki tablasız olmak üzere toplam 3 adet betonarme kiriş üretilerek, statik üç noktalı eğilme deneyine tabi tutulmuştur. Yapılan bu çalışma sonucunda, TS 500 (2000)'e uygunluğu belirlenen etkili tabla genişliği içerisindeki döşeme donatılarının neredeyse tamamının kiriş donatısı gibi moment taşıma kapasitesine katkı verdiği tespit edilmiştir.


© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Taşıyıcı sistemi betonarme çerçeve olan bir yapıda, kiriş-kolon birleşim bölgelerinde yatay deprem yükleri ile mesnet gerilmeleri daha da artmaktadır. Taşıyıcı sistemin kolon-kiriş birleşim bölgelerinde, kat mekanizmalamaşmalarının ve gevrek göçmelerin önlenmesi için enine ve boyuna donatı hesaplarının iyi yapılması gerekmektedir. Ayrıca, bu birleşim bölgelerinin, birleşen yapı elemanlarından daha güçlü olması gerekmektedir. Betonarme çerçeve bir yapıda kat mekanizmalamaşması ile bir kolonda oluşan göçme, kirişte oluşan göçmeye kıyasla tüm yapıyı etkilemektedir. Türkiye Bina Deprem Yönetmeliği (TBDY-2018)'e göre, betonarme tasarımda güçlü kolon-zayıf kiriş prensibi ile sistemin sünek davranış göstermesi sağlanarak, yapının göçmesi önlenmektedir [1]. Bu koşulun sağlanabilmesi için, kolonun alt ve üst taşıma gücü momentinin toplamının, kolona birleşen kirişlerin kolon yüzündeki taşıma gücü momentlerinin toplamından en az %20 güçlü olması gerekmektedir.


Deprem yönetmeliğinde tanımlanan ve kiriş mesnetinin plastik mafsallarda oluşabilecek en büyük eğilme momenti kapasitesi (M_p), betondaki sargı nedeni ile artan dayanım ve donatı çeliğindeki pekleşme dikkate alınarak hesaplanmaktadır [2]. Bu çalışmada, taşıma gücü momenti (M_r), TS 500 (2000)'de yer alan beton ve çeliğin karakteristik dayanımları (f_{ck} ve f_{yk}) baz alınarak hesaplanmıştır [3].

Betonarme tablalı kirişlerin döşeme ve kiriş betonları birlikte dökülür ve betonun dayanımını kazandıktan sonra monolitik bir davranış gösterirler. Her iki kenarında sürekli döşemesi bulunan orta kirişler "T", bir kenarında döşeme bulunan kirişler ise "L" kesitli tablalı kirişler olarak tanımlanır.



Şekil 1. Çerçeve kirişte şekil değişimi ve en kesitlerdeki donatı detayı.

Bir çerçeve kirişin, döşeme tablası pozitif moment bölgesinde basınç, negatif moment bölgesinde ise çekme etkisinde kalmaktadır (Şekil 1). ACI-318 (2019), CSA-A23.3 (2004) ve NZS 3101.1 (2006)'da güçlü kolon-zayıf kiriş koşulunun sağlanması için, kiriş nominal taşıma gücü momentinin hesaplanmasında kirişle tek parça olarak dökülen döşemelerin etkili tabla genişliği içerisinde yer alan kirişe paralel döşeme donatılarının dikkate alınmasının doğru olacağı belirtilirken, EN 1992-1-1 (2004) ve EN 1998-1 (2004)'de, sürekli kirişlerin mesnet bölgelerinde, çekme donatılarının Şekil 2(a)'da görüldüğü üzere öncelikle kiriş gövdesi içerisine yerleştirilmesi, bir kısmının da etkili tabla genişliği (b_{eff}) içerisinde gövdeye yakın dağıtılabileceği belirtilmiştir [4-8]. Ayrıca, NZS 3101.1 (2006)'da döşemenin kirişe paralel donatıları, dik dağıtma donatıları ile etkin bir şekilde bağlandığında, eğilme dayanımının katkısının, kirişin toplam dayanımının %15'ini aşmaması gerektiği belirtilmiştir [6].



Şekil 2. (a) Tablalı kesite sahip kirişin çekme donatısının yerleşimi [7-8], (b) Negatif moment etkisindeki tablalı kirişte beklenen donatı kuvvet dağılımı.

TS 500 (2000)'de negatif moment etkisinde kalan mesnet kesitlerinde, tabla betonu içerisinde bulunan kirişle paralel döşeme donatılarının katkısına yer verilmemektedir [3]. TBDY (2018)'de, mevcut bina ve sistemlerin değerlendirilmesi ve güçlendirilmesi tasarımında, betonarme tablalı kirişlerin negatif plastik momentlerinin

hesabında tabla betonu ve içinde yer alan donatının hesaba katılabileceği ifade edilmiş fakat güçlü kolon-zayıf kiriş koşulunun ve elemanların kapasite tasarımının belirlenmesinde tabla betonun içerisinde yer alan dökme donatısının kısmen/tamamen hesaba katılması ile ilgili ifadeye yer verilmemiştir [1].

Betonarme çerçeve sistemlerin iç ve dış aks kolon-kiriş birleşim bölgelerinde, tabla betonu içerisinde yer alan dökme donatılarının davranış etkilerini araştırmak için 1/2 ve 3/4 ölçekli yapılan deneysel çalışmalarda, dökme donatısının negatif eğilme etkisindeki kirişlerin taşıma gücünü artırdığı, şiddetli yanal yüklemeye maruz kalan çerçevelerde, aşırı kolon mafsallaşmasını önlemek için gerekli kolon dayanımlarının belirlenmesinde dökme donatısı katkısının dikkate alınması gerektiği belirlenmiştir [9-14].


Durani ve Zerbe (1987) tarafından yapılan dökmenin dış aks kolon-kiriş birleşimi davranışına etkisinin incelendiği deneysel çalışmada, 6 adet 3/4 ölçekli tablalı kirişe simüle edilmiş deprem yükleri etki ettirilerek, dökme donatısının kirişlerin negatif eğilme momenti kapasitesini %70'e varan oranda artırdığı, dökme donatısı katkısının göz ardı edilmesinin kolonlarda mafsallaşmaya neden olabileceği belirtilmiştir [15]. Aydemir (2013), yaptığı analitik çalışmada, negatif eğilme etkisindeki tablalı kirişler için yapılan deneyler sonucunda bulunan deneysel moment kapasitesinin, dikdörtgen kesit kabulüyle tabla donatılarının ihmal edildiği varsayılarak belirlenen taşıma gücü moment kapasitesine oranının 1.62-3.78 aralığında arttığı sonucuna varmıştır [16]. Ahmed ve Gunasekaran (2014) deneysel çalışmada, yanal yükler altında biri tablalı biri tablasız olmak üzere toplam 2 adet 1/2 ölçekli iç aks kolon-kiriş birleşimlerinde, dökme donatısının dikkate alınması ile kirişin negatif eğilme momentinde %67.10 oranında önemli bir artış gösterdiği, kirişin moment kapasitesinin büyük olmasının kolonun daha büyük moment kapasitesine ihtiyaç duyacağı, dökme donatısının katkısının ihmal edilmesi halinde kat mekanizmasına sebep olabileceği belirtilmiştir [17].

Mevcut şartnamelere ve yapılan çalışmalara bakıldığında, kirişin açıklık kesiti hesabında etkili tabla genişliğinde yer alan dökme betonu basınç bölgesinde dikkate alınırken, mesnetlerde de tabla donatılarının dikkate alınması bilimsel gerçeklere daha uygun olacaktır. Şekil 2(b)'de görüldüğü üzere, negatif eğilme momenti etkisindeki tablalı kirişin, kirişe paralel dökme donatılarının, kiriş yüzeyinden uzaklaştıkça azalarak kirişe katkı vereceği düşünülmektedir. Dökemelerden gelen donatıların dikkate alınması durumunda, kirişin taşıma gücü gerçeğinden daha fazla çıkacak ve bu da istenmeyen kuvvetli kiriş-zayıf kolon davranışına sebep olacaktır.

Bu çalışmada 1/1 ölçekli, biri tablalı, ikisi tablasız olmak üzere toplam 3 adet betonarme kirişte eğilme deneyleri yapılarak, kiriş mesnet bölgesinde etkili tabla genişliği içerisinde yer alan kirişe paralel dökme donatılarının kirişin yük taşıma kapasitesine katkısı araştırılmıştır. Bu katkının dikkate alınması ile sık donatılı kiriş-kolon birleşim bölgelerinde donatıyı kalınlaştırmak veya çift sıra donatı yapmak yerine, etkili tabla genişliği içerisindeki donatının kısmen veya tamamen kiriş donatısından düşülmesiyle, kolonlardaki ve birleşim bölgelerindeki betonun iyi yerleşimi, vibratör kullanımı (vibratörün donatı aralığından geçememesi) ve beton işçiliği kolaylaşacağından, donatı miktarı ve beton-donatı işçilik maliyeti azalacak ve ülke ekonomisine katkı sağlanacaktır.

Bu kazanımlara ek olarak gevrek göçme riski, kuvvetli kolon-zayıf kiriş şartına yönelik tehdit ve olası kat mekanizması gibi tasarım olumsuzluklarının da ortadan kaldırılması amaçlanmıştır. Betonarme yapılar monolitik (yekpare) kabul edilmektedir. Kolon-kiriş birleşim bölgelerinde donatıların aşırı sıklaşması nedeniyle vibratör kullanılamaması ve betona bilinçsizce su katılması sonucunda oluşan segregasyonlar, bu kabulü yer yer boşa çıkarmaktadır (Şekil 3(a), 3(b)). "Bir zincirin gücü, en zayıf halkasının gücü kadardır." prensibi gereği, özellikle moment ve kesmenin maksimum değerlere ulaştığı kolon-kiriş birleşim bölgelerinde oluşan segregasyonlardan kaynaklı düşük beton dayanımı gevrek göçme riskini ortaya çıkarmaktadır. Ayrıca, çekme bölgesinde bulunan kirişe paralel dökme donatılarının katkısı ile kirişlerdeki çekme ve basınç donatı oranları farkının ($\rho - \rho'$), dengeli donatı oranının %85'inden ($\rho_{max} > 0.85\rho_b$) büyük olmasına ve gevrek göçme riskine sebep olacaktır.

Deprem etkisi altında yer alan betonarme çerçeve bir yapıda, kuvvetli kolon-zayıf kiriş koşulu sağlandığı durumda kiriş uçlarında plastik mafsallar oluşacaktır [2]. Kiriş uç bölgelerinde betonun ezilmesi durumunda, alt donatılar kuvvet çifti oluşturarak, ortaya çıkan plastik momentler sayesinde sistem mekanizmasının oluşması sağlanacak ve sistemdeki ani göçmeler önlenmiş olacaktır. Betonarme hesaplamalarda ihmal edilen kirişe paralel etkili dökme donatılarının kirişin moment taşıma kapasitesinde %20'den fazla artışa sebep olması durumunda, kuvvetli kolon-zayıf kiriş kuralı ihlal edileceğinden Şekil 3(c)'de görülen kat mekanizması tehlikesi ortaya çıkacak ve sistemde ani göçmeler olacaktır.



Şekil 3. (a) Kolon-kiriş birleşim bölgesinde oluşan donatı sıklaşması [18], (b) Kolon-kiriş birleşim bölgesinde oluşan segregasyon [19], (c) Kuvvetli kiriş-zayıf kolon riski [20].


2. MATERYAL VE YÖNTEM

2.1. Deney Numuneleri ve Kullanılan Malzemeler

Bu çalışmada tabla kalınlığı 10 cm, genişliği 125 cm olan 25x45 cm boyutunda bir tablalı ve aynı ebatlarda iki tablasız olmak üzere toplam 3 adet 1/1 ölçekte K1, K2 ve K3 isimli betonarme kiriş numuneleri hazırlanmıştır (Şekil 4). Tablalı kirişler için yapılan kesit hesaplarında dikkate alınan etkili tabla genişliği (b), Denklem 1’de verilen bağıntıdan hesaplanmış olup b_w kiriş gövde genişliğini, l_p ise kirişin iki moment sıfır noktası arasında kalan uzaklığını ifade etmektedir. Daha kesin hesap yapılmayan durumlar için l_p , sürekli kiriş iç açıklığında 0.61 alınabilmektedir [3]. Burada bahsedilen l ise, kirişin hesap açıklığı olup kirişlerde mesnet ekseninden mesnet eksenine olan uzaklıktır.


$$b = b_w + 0.2 l_p \quad (1)$$

Etkili tabla genişliği (b), kiriş hesap açıklığı (l) 600 cm olduğu varsayılarak, TS 500 (2000)’de sürekli kirişler için belirtilen T-kesiti gibi simetrik kesitler için Denklem 1 ile hesaplanmış ve 125 cm olarak belirlenmiştir [3]. Eğik çekme kırılmasının gerçekleşmesi ve kemerlenme oluşmaması için kiriş numunesinin toplam uzunluğu, kesme açıklığının faydalı yüksekliğe oranı ($a/d=123.75/42.00$) yaklaşık 3 olacak şekilde, 300 cm olarak belirlenmiştir [21]. Ayrıca, erken kesme göçmesinin önlenmesi için sarılma bölgesinde sıklaştırma yapılarak $\emptyset 10/10$ etriye yerleştirilmiştir.



Şekil 4. Deneyde kullanılacak kirişlerin en kesitleri (ölçüler cm).

Etkili tablalı kesiti içerisinde yer alan döşeme donatılarının katkılarının araştırılması amacıyla kiriş üst yan yüzünden başlamak üzere sırayla her iki yöne 10 cm arayla $\emptyset 8$ çapında toplam 10 adet döşeme donatısı ilave edilerek K1 isimli numune oluşturulmuştur. K2 isimli numunede ise, çekme ve basınç bölgesinde $3\emptyset 12$ donatı bulunan dikdörtgen kesitli kirişin çekme bölgesine etkili tabla içerisinde yer alan $10\emptyset 8$ donatı ilave edilmiştir. K3 isimli referans numunede ise, negatif eğilme etkisinde dikdörtgen kesit kabulü yapılarak, çekme bölgesinde hesaplanan minimum donatı ($3\emptyset 12$) basınç bölgesinde de kullanılmıştır. Negatif eğilme momenti etkisindeki tablalı kirişin boyuna donatı yerleşimi Şekil 5’te verilmiştir.



Şekil 5. Negatif eğilme momenti etkisindeki tablalı kirişin boyuna donatı yerleşimi (ölçüler cm).

Tablalı ve tablasız deney numunelerinin kalıpları için plywood kalıp kullanılmıştır (Şekil 6). 8, 10 ve 12 mm çaplı donatılar ölçülerine uygun olarak kesilip, kalıp içerisine paspayı bırakılarak yerleştirilmiştir.



Şekil 6. K1, K2 ve K3 kirişlerinin kalıp ve donatılarının hazırlanması.

TS 802 (2016) şartnamesine uygun olarak deneyin yapılacağı laboratuvar ortamında hazırlanan toplam 1.30 m³ beton karışımı, betonda ezilmenin olmaması için C20/25 beton sınıfı hedeflenerek 3 grup halinde dökülmüştür [22]. Betonda kullanılan agrega, TS 706 EN 12620+A1 (2009) şartnamesine uygun olarak doğal kayadan işlenmiş kırma taştan oluşmaktadır [23]. Donatının sık olduğu yerlerdeki betonun yerleşimini sağlayabilmek için maksimum 10 mm'lik agrega boyutu ve S3 sınıfı içerisinde yer alan 120 mm çökme (slump) değeri kullanılmıştır. Beton dökümü sırasında dalıcı vibratör kullanılarak daha az boşuklu beton elde edilmeye çalışılmıştır (Şekil 7).



Şekil 7. Betonun hazırlanması.

Deney numuneleri üzerinde test işlemine başlamadan önce, betonarmeyi oluşturan beton ve çeliğin mekanik özellikleri belirlenmiştir. Bu amaçla, beton dökümü sırasında her deney numunesinden 6 adet olmak üzere toplamda 18 adet 150x150x150 mm beton küp numunesi TS EN 12390-2 (2019)'a uygun olarak hazırlanmıştır

[24]. Bunlardan 3'er adedi beton sertleştikten sonra 28 gün boyunca kür havuzunda küre tabii tutulmuş, diğer küp numuneler ise test gününe kadar deney numunelerinin yanında aynı koşullarda bekletilmiştir. 28 günlük beton dayanımları sonucu, hedeflenen C20/25 beton sağlanmadığı için, kalan küp numunelerinin ve deney numunelerin üzerine jüt kumaş serilerek ve ıslatılarak kürlenme yapılmıştır. Ayrıca, kirişte gevrek göçmenin olmaması için N-Schmidt beton test çekici ile deney numunelerin basınç dayanımları C20/25 beton sınıfına ulaşıncaya kadar kürlenme yapılmaya devam edilmiştir. Küp numunelerinin basınç dayanım testleri, TS EN 12390-3 (2019) yönergeleri izlenerek gerçekleştirilmiştir [25]. Betonun 28 günlük ve test günündeki küp numunelerin dayanımları baz alınarak hesaplanan karakteristik silindir basınç dayanımları (f_{ck}) ile elastisite modülü Tablo 1'de verilmiştir. Küp numuneleri basınç dayanımının silindir dayanımına dönüştürülmesinde TS EN 206+A2 (2021) standardından faydalanılmış, C20/25 ve daha düşük dayanımlı betonlarda kullanılan 0.80 katsayısı ile karakteristik silindir dayanımları hesaplanmıştır [26]. Elastisite modülü (E_c), betonun karakteristik silindir dayanımına bağlı olarak Denklem 2'ye göre belirlenmiştir [3].

$$E_c = 3250 \sqrt{f_{ck}} + 14000 \quad (\text{MPa}) \quad (2)$$

Tablo 1. Beton basınç dayanımları ve elastisite modülleri.

Deney Numunesi	Basınç Dayanımı, f_{ck} (MPa)		Elastisite Modülü, E_c (MPa)
	28 günlük	Deney günü	
K1	14.43	19.10 (153. gün)	28203
K2	15.76	21.43 (165. gün)	29045
K3	19.46	26.50 (172. gün)	30730

Donatı olarak 8, 10 ve 12 mm çaplarına sahip 9 adet nervürlü B500C çelik çubuk, TS EN ISO 6892-1 (2020)'ye uygun olarak çekme testlerine tabi tutulmuş [27] ve ortalama akma dayanımı (f_{yk}), ortalama nihai çekme dayanımı (f_u) ve ortalama kopma uzaması (%) belirlenmiştir. Çeliğin elastisite modülü (E_s) 200000 MPa alınmış olup, deney numunelerinde kullanılan 8, 10 ve 12 mm çapındaki donatılara ait mekanik özellikler Tablo 2'de verilmiştir.


Tablo 2. Donatı özellikleri.

Çap, \varnothing (mm)	Donatı Alanı, A_s (mm ²)	Ortalama Akma Dayanımı, f_{yk} (MPa)	Ortalama Çekme Dayanımı, f_u (MPa)	Ort. Çekme Dayanımı/ Ort. Akma Dayanımı	Ortalama Kopma Uzaması (%)
Ø8	50.24	522.17	641.92	1.23	20.00
Ø10	78.50	518.11	645.24	1.24	20.20
Ø12	113.04	504.42	655.52	1.30	20.56

TS 708 (2016)'ya göre, sünek davranışın sağlanabilmesi için B500C donatılarda, minimum kopma uzamasının %12'den az olamayacağı, deneysel akma dayanımının karakteristik akma dayanımına oranının 1.30'dan büyük olamayacağı, deneysel çekme dayanımının deneysel akma dayanımına oranının 1.15'den küçük veya 1.35'den büyük olamayacağı belirtilmiştir. Yapılan çekme testlerine göre, kopma uzaması %17.50-%22.50, deneysel akma dayanımının karakteristik akma dayanımına oranı 1.16-1.27, deneysel çekme dayanımının deneysel akma dayanımına oranı 1.18-1.32 hesaplanmış ve TS 708 (2016)'ya uygun olduğu tespit edilmiştir [28].

2.2. Deney Düzenliğinin Kurulumu


Araştırma konusu kapsamında, laboratuvarında mevcut olan ekip ve ekipmanlar ile deney düzenliğinin çerçeve sistemi kullanılarak, eksik olan mekanik teçhizatlar ve sarf malzemeler ise temin edilerek Şekil 8'de şematik gösterimi verilen deney düzenliği hazırlanmıştır. Tablalı giriş ve benzer şekilde diğerlerinin deney düzenliğine yerleştirilmesi, desteklenmesi ve deneydeki kolaylıklar göz önünde bulundurulmuş ve Şekil 4'te verilen donatı yerleşimi alt-üst şeklinde yapılarak hazırlanmış ve deney yüklemeleri de ters uygulanmıştır.



Şekil 8. Deneysel düzeneğin şematik gösterimi (ölçüler cm).

Hidrolik pompa, hidrolik kriko, deplasman ölçer (mekanik komparatör saati) vb. donanımlar ile sabit ve kayıcı mesnetler deneysel düzeneğine yerleştirilmiştir. Üç noktalı eğilme deneyinde, 400 kN kapasiteli el kontrollü hidrolik kriko yardımıyla betonarme kirişin ortasına eğilme yükü tek noktadan uygulanmıştır. Genel olarak, maksimum göçme yüküne kadar, her 10 kN yük artışı sonrasında 100 mm kapasiteye sahip mekanik komparatör saati yardımı ile kirişin ortasında oluşan sehimler okunmuştur (Şekil 9). Mesnetlerde kullanılan çelik kutu profillerin oldukça rijit ve giriş ile mesnet kutu profili ara yüzeyinde kullanılan lastik contaların kalınlığının 2 mm olmasından dolayı, 277.50 cm açıklıklı kirişin ortasındaki sehime kıyasla mesnetlerdeki yer değiştirmeler oldukça küçük olacağından mesnet yer değiştirmeleri ihmal edilmiştir.

Deneysel numuneleri, gerektiği gibi kesme donatısı ile donatlandırılmış olup, sünek eğilme davranışı sergilemesi beklenen kirişlerdir. Deneysel numunelerinin, artan yükleme etkisi altında açıklık ortasında yaptığı büyük düşey deplasman sonucu, ana çekme donatısının akma dayanımına ulaşması ve betonun basınç bölgesinde ezilmeden sünek bir eğilme davranışı sergileyerek göçmesi beklenmiştir.



Şekil 9. Deneysel düzeneğin hazırlanması.

3. ARAŞTIRMA BULGULARI VE DEĞERLENDİRME

3.1. Betonarme Hesaplar

Negatif moment etkisi altında kalan kiriş kesitinin taşıma gücü hesabı, basit donatılı dikdörtgen kesite ve basınç donatısının da katkısını alan çift donatılı dikdörtgen kesite göre denge ve uygunluk denklemleri kullanılarak ayrı ayrı yapılmıştır. Beton ve donatı arasında tam aderansın olduğu varsayılarak betonun çekme dayanımı ihmal edilmiştir. Donatı çeliğinin ise gerilme-birim deformasyon ilişkisi elasto-plastik olarak alınmıştır.

Deney numunelerinin tasarımında, TS 500 (2000) ve TBDY (2018)'de çekme donatısı için konulan üst sınırları ($\rho_{\max}=0.02$ veya $\rho_{\max}=0.85\rho_b$) aşmaması ve sünek davranış göstermesi ($\epsilon_c < \epsilon_{cu}$ için $\epsilon_s \geq \epsilon_{sy}$) gibi kurallara dikkat edilmiştir. Taşıma gücü ile ilgili yapılan hesaplamalara uygun olarak normal dayanımlı betonlar için en dış basınç lifindeki birim kısalma (ϵ_{cu}) 0.003, betonun basınç bloğu katsayısı (k_1) 0.85 alınmış ve basınç bölgesinde TS 500 (2000)'de tanımlanan eşdeğer dikdörtgen gerilme dağılımı kullanılmıştır. Taşıma gücü momenti (M_r), TS 500 (2000)'de yer alan beton ve çeliğin karakteristik dayanımları (f_{ck} ve f_{yk}) baz alınarak hesaplanmıştır [1,3].

Tablo 3. Deney numunelerinin betonarme hesap sonuçları.

Deney Numunesi	Basit Donatılı Hesap			Çift Donatılı Hesap			Beton Kesme Kap. V_c (kN)	Etriye Kesme Kap. V_w (kN)
	Maks. Yük, P (kN)	Taş. Gücü Momenti M_r (kN.m)	Kiriş Kesme Kuvveti $V_{kiriş}$ (kN)	Maks. Yük, P (kN)	Taş. Gücü Momenti M_r (kN.m)	Kiriş Kesme Kuvveti, $V_{kiriş}$ (kN)		
K1	256.90	158.96	128.45	269.92	167.01	134.96	83.52	339.78
K2	260.97	161.48	130.49	271.47	167.97	135.73	88.47	339.78
K3	111.97	69.28	55.98	111.94	69.26	55.97	98.37	332.78

Tablo 3'te verilen etriye kesme kapasitesi (V_w) Denklem 3 ile beton kesme kapasitesi (V_c) ise betonun kritik kesme kuvveti kapasitesine (V_{cr}) bağlı olarak Denklem 4 ve Denklem 5 ile karakteristik dayanımlar baz alınarak hesaplanmış olup, denklemlerde yer alan n etriye düşey kol sayısını, A_{sw} etriye düşey kollarının toplam kesit alanını, f_{yw} etriye donatısının karakteristik akma dayanımını, d kirişin faydalı yüksekliğini, s_k etriye aralığını, f_{ctk} betonun karakteristik eksenel çekme dayanımını, b_w ise kiriş gövde genişliğini ifade etmektedir [29].

$$V_w = (n A_{sw} f_{yw} d) / s_k \quad (3)$$

$$V_c = 0.8 V_{cr} \quad (4)$$

$$V_{cr} = 0.65 f_{ctk} b_w d \quad (5)$$

Deney numunelerinin geleneksel teorik betonarme hesap sonuçları Tablo 3'te verilmiştir. Deney esnasında K1, K2 ve K3 kirişlerinde beklenen kesme kapasitesi sırasıyla 134.96, 135.73 ve 55.97 kN, betonun kesme kapasitesi 83.52, 88.47 ve 98.37 kN, etriyelerin kesme kapasitesi ise 339.78, 339.78 ve 332.78 kN olarak hesaplanmıştır. Kirişlerde ilk çatlağın, kiriş ortasından alttan yukarı doğru eğilme çatlağı, yükün artmasına bağlı olarak, kesmenin artması ile mesnetlere doğru sıralı ikincil eğik kesmeli çekme çatlakları beklenmiştir. Ayrıca, etriyelerin kesme kapasitesi yüksek tasarlanarak gevrek kesme göçmesi engellenmiştir. Maksimum eğilme yükü yaklaşık 271 kN olduğundan, deney düzeneğinde 400 kN kapasiteli el kontrollü hidrolik kriko tercih edilmiştir.


3.2. Gözlemsel Sonuçlar

Çalışma kapsamında, 1/1 ölçekli, biri tablalı, ikisi tablasız olmak üzere toplam 3 adet betonarme kirişte yapılan eğilme deneyleri sürecinde, kirişin sol kenarındaki sabit mesnetin, sağ kenarındaki ve maksimum yük altındaki kayıcı mesnetlerin beklenen düzeyde performans gösterdiği ve üç nokta yüklemeli, tek açıklıklı basit kiriş davranışı sergilediği görülmüştür.

Eğilme deneyleri sonucunda, tablalı K1 kirişinin göçme şekli Şekil 10'da, döşeme donatılı tablasız K2 kirişinin göçme şekli Şekil 11'de, referans numune K3 kirişinin göçme şekli ise Şekil 12'de verilmiştir. Kirişlerin denge altı sünek davranışını gözlemek amacıyla, TS 500 (2000)'de bölme duvarlı çatı ve normal kat elemanları için belirtilen, kiriş serbest açıklığının 240'a bölünmesiyle elde edilen kiriş ortasındaki kullanılabilirlik sehim limitinin ($277.50/240=1.16$ cm) üzerine çıkılarak, sehim 10 cm oluncaya kadar deneye devam edilmiştir. Deney numunelerinin göçme şekillerine ve çatlaklara bakıldığında, basınç bölgesinde betonda ezilme olmaması ile betonun basınç mukavemetinin yeterli olduğu, kesme göçmesinin olmaması ile etriyelerin güçlü tasarlandığı anlaşılabilirlikte, beklenildiği üzere kemerlenme etkisi oluşmamıştır.



Şekil 10. K1 kirişi ve göçme şekli.



Şekil 11. K2 kirişi (10Ø8 döşeme donatılı) ve göçme şekli.




Şekil 12. K3 kirişi (döşeme donatısız) ve göçme şekli.

Kirişlerde ilk çatlak, kiriş ortasından alttan yukarı doğru düşey eğilme çatlakları şeklinde başlamış, yükün artmasına bağlı olarak, daha sonra mesnetlere doğru sıralı ikincil eğik kesmeli çekme çatlakları şeklinde devam etmiştir. Deneyin ilerleyen sürecinde, oluşan bu çatlakların boyu ve genişliği artmış ve maksimum yüke ulaşıldığında kiriş ortasındaki çatlak genişliği 11.00 mm'ye ulaşmıştır. Kiriş ortasındaki sehim 10 cm'ye ulaşmaya kadar yükleme yapılmış, yük tamamen kaldırıldığında da K1 ve K2 kirişinde 8.50 cm, K3 kirişinde ise 6.70 cm kalıcı sehim görülmüştür.

3.3. Deneysel Sonuçlar

Yapılan tasarıma uygun olarak sünek eğilme davranışı gösteren kiriş numunelerin, üç noktalı yükleme deneyi sonucu ölçülen yük-sehim grafiği Şekil 13'te verilmiştir. Çift donatılı dikdörtgen kesit dikkate alınarak yapılan geleneksel teorik betonarme hesap sonuçlarına göre, tablalı K1 kirişinin maksimum taşıma gücü momenti 167.01 kN.m, maksimum yük 269.92 kN, tablasız döşeme donatılı K2 kirişinin maksimum taşıma gücü momenti 167.97 kN.m, maksimum yük 271.47 kN, tablasız döşeme donatısız K3 referans numunesinin ise maksimum taşıma gücü momenti 69.26 kN.m, maksimum yük 111.94 kN olacak şekilde tasarımları yapılmıştır (Tablo 3).



Şekil 13. Yük-sehim grafiği.

Tablalı K1 kirişinin, betonarme hesaplara uygun olarak 269.92 kN'da akmaya başladığı, kiriş ortasındaki sehim 10 cm'ye ulaştığında ise taşıdığı maksimum yükün 300.00 kN olduğu görülmüştür. Tablasız döşeme donatılı K2 kirişi, betonarme hesaba göre 271.47 kN'da akmaya başlaması gerekirken yaklaşık 207.00 kN'da akmaya başladığı, kiriş ortasındaki sehim 10 cm'ye ulaştığında ise taşıdığı maksimum yükün 283.00 kN olduğu görülmüştür. Referans numunesi olan tablasız döşeme donatısız K3 kirişi, betonarme hesaba göre 111.94 kN'da akmaya başlaması gerekirken, daha erken yaklaşık 80.00 kN'da akmanın başladığı, kiriş ortasındaki sehim 10 cm'ye ulaştığında ise taşıdığı maksimum yükün 115.00 kN olduğu görülmüştür.

Tablalı K1 ve tablasız döşeme donatılı K2 kirişlerinin kiriş ortasındaki sehim 10 cm'ye ulaştığında taşıma kapasitelerinin birbirine oldukça yakın olduğu görülmüştür. Ancak, tablalı K1 kirişinde döşeme donatısının etriyenin dışında kalması nedeniyle daha düşük bir akma ve taşıma kapasitesi beklenirken, 25.00 cm genişliğindeki tablasız K2 kirişindeki donatı aralıklarının (3Ø12+10Ø8) TS 500 (2000)'e göre (donatı çapından, 4/3 D_{max} ve 20 mm den az olamaz) çok düşük olmasından kaynaklı aderans tam sağlanamadığından yaklaşık %30 oranında akma dayanımı kaybına neden olmuştur. Kirişin hızlı aderans kaybına bağlı oluşan yaklaşık 50 mm'lik sehiminden sonra, kiriş ortasından başlayan aderans kaybının kenarlara doğru devam ettiği ancak, çekme donatısının uçlarından gönyeli olarak ankrajlanmış olması nedeniyle, donatıların germe halatı gibi davranarak, K1 kirişinin taşıma kapasitesine yakın bir kapasiteye yükselttiği görülmüştür. Minimum donatı oranına yakın donatılandırılmış K3 referans kirişinin akma dayanımı, beklenildiği üzere diğer kirişlere kıyasla yaklaşık 1/3 oranında gerçekleşmiştir. Donatının sık olması nedeniyle erken aderans kaybına bağlı olarak, 225.00 kN yük altında K1 kirişindeki sehim yaklaşık 10 mm olurken, K2 kirişinde bu sehim yaklaşık 5 katı (50 mm) olarak gerçekleşmiştir. Erken aderans kaybı neticesinde, K1 kirişine kıyasla K2 kirişinde sehimin hızlı bir şekilde arttığı ve çatlakların daha erken ve daha büyük oluşmasına neden olduğu ancak, kiriş ortasındaki sehim 10 cm'ye ulaştığında taşıma kapasitesine olan negatif etkisinin ise beklenenden az olduğu görülmüştür.

Kiriş ortasındaki sehim $L/240$ limitine (1.16 cm) ulaştığında, tablalı K1 kirişine kıyasla tablasız döşeme donatılı K2 kirişinin sık donatılı olmasından kaynaklı aderans kaybindan dolayı taşıma kapasitesi kaybı yaklaşık %17'lik bir oranla 43.00 kN (250.00-207.00 kN) olduğu görülmüştür. Kiriş ortasındaki sehim 10 cm'ye ulaştığında, tablalı K1 kirişine kıyasla tablasız döşeme donatılı K2 kirişinin sık donatılı olmasından kaynaklı aderans kaybindan dolayı taşıma kapasitesi kaybı yaklaşık %6'lık bir oranla 17.00 kN (300.00-283.00 kN) olduğu görülmüştür (Şekil 13). Kiriş ortasındaki sehim $L/240$ limitine ulaştığında, donatı oranı 0.0032 olan 3Ø12 donatılı kiriş 87.20 kN yük taşıırken, 0.0080 donatı oranına sahip 10Ø8+3Ø12 donatılı kirişin 207.00 kN yük taşıdığı, 10Ø8 donatının kirişe katkısının yaklaşık 119.80 kN (207.00-87.20 kN) olduğu görülmüştür. Aderans kaybı dikkate alınmaksızın, etkili tabla genişliği içerisine yerleştirilecek 10Ø8 donatının kirişe %57.87 oranında katkı vererek, kirişin 326.80 kN yüke ulaşacağı hesaplanmıştır (Tablo 4).

Tablo 4. Kiriş ortasındaki $L/240$ limit sehim için donatı oranlarına bağlı tablalı kiriş yükü.

Donatı Oranı	Tablasız Kiriş Yükü (kN)	Tablalı Kiriş Yükü (kN)	Tablanın Katkısı (%)
ρ_{min} 0.0024	87.00	206.80	137.70
ρ (3Ø12) 0.0032	87.20*	207.00	137.39
ρ (3Ø12+10Ø8) 0.0080	207.00*	326.80	57.87
$\rho_{max}=0.85\rho_b$ 0.0123	433.50	553.30	27.64

*Deneyde elde edilen kiriş yüküdür.

Kiriş ortasındaki sehim L/240 limitine ulaşıldığında, donatı oranlarına bağlı olarak yapılan ekstrapolasyon hesapları sonucunda, aderans kaybı dikkate alınmaksızın, ρ_{min} 'e sahip tablasız kirişin 87.00 kN yük taşıyacağı, 1008 donatılı tablanın eklenmesi ile yaklaşık 1.5 katı olan (%137.70 oranı ile) 206.80 kN bir yükü taşıyabileceği görülmektedir. Benzer şekilde, donatı oranlarına bağlı olarak yapılan ekstrapolasyon hesapları sonucunda, aderans kaybı dikkate alınmaksızın, ρ_{max} 'a sahip tablasız kirişin 433.50 kN yük taşıyacağı, 1008 donatılı tablanın eklenmesi ile yaklaşık %27.64 oranında bir artışla 553.30 kN bir yükü taşıyabileceği görülmektedir.

Kiriş ortasındaki sehim L/240 limitine ulaşıldığında, zayıf donatılı bir kirişin taşıma kapasitesine dökme donatısının katkısı %137'lerde olurken, en güçlü donatılı kirişte bile bu katkının %27.64 olabileceği yapılan ekstrapolasyon ile görülmüştür. Betonarme çerçeve sistemlerin analizinde kiriş-kolon birleşim yerlerinde kirişlerin mafsallaşmasının öncelendiği sistem mekanizmalanması temel prensibini sağlayabilmek için, kuvvetli kolon-zayıf kiriş yaklaşımında kolonların kirişlerden %20 daha güçlü olması beklenirken, dökme donatısının en az katkı vereceği, en güçlü donatılı kirişlerde dahi aderans kaybı da dikkate alındığında dökme donatısı katkı oranının (%27.64-20) %7'nin üzerinde olabileceği görülmüştür. Sonuç olarak, bu bulgular dikkate alındığında, analizlerde etkili tabla genişliği içerisindeki dökme donatısının ihmal ediliyor olması, uygulamada kuvvetli kolon-zayıf kiriş şartının ihlal edildiğini göstermektedir.

4. SONUÇLAR VE ÖNERİLER

Bu çalışmada 1/1 ölçekli, biri tablalı, ikisi tablasız olmak üzere toplam 3 adet betonarme kirişte üç noktalı yükleme eğilme deneyleri yapılarak, kiriş mesnet bölgesinde etkili tabla genişliği içerisinde yeralan kirişe paralel dökme donatılarının kirişin yük taşıma kapasitesine katkısı araştırılmıştır.

TS 500 (2000)'e uygun belirlenen etkili tabla genişliği içerisinde yeralan dökme donatılarının neredeyse tamamının kiriş etriyesi içerisine yerleştirilen donatı gibi taşıma kapasitesine katkı verdiği tespit edilmiştir. Yapılan deneyler neticesinde, betonarme kolon-kiriş çerçeve sistemlerin tasarım ve hesabında mesnetlerde yeralan etkili tabla genişliği içerisindeki dökme donatılarının dikkate alınması ile elde edilebilecek kazanımlar ve önenebilecek riskler aşağıda maddeler halinde özetlenmiştir.

- Dökme donatılarının dikkate alınması ile mesnetlerde kiriş üst donatılarının azaltılması düşük oranda da olsa bir ekonomi sağlayacaktır.
- Sık donatılı kiriş-kolon birleşim bölgelerinde donatı aralığını artırmak adına donatıyı kalınlaştırmak veya çift sıra donatı yapmak bir çözüm olsa da uygulamada donatı işçiliğini artırmakta ve zorlaştırmaktadır. Kiriş donatılarında yapılacak bu azalma neticesinde, kolon-kiriş birleşim bölgelerindeki betonun yerleşimi, beton işçiliği ve vibratör kullanımı (vibratörün donatı aralığından geçmesi) kolaylaşacaktır.
- Kirişlerde donatının denge üstü kullanılmasına dayalı gevrek göçmenin önlenmesi adına, maksimum donatı oranını (ρ_{max}) hesabında, kirişin etkili tabla genişliği içerisinde yeralan dökme donatılarını da dikkate alan Denklem 6'nın kullanılması daha sağlıklı olacaktır. Denklem 6'da yer alan, ρ_b dengeli donatı oranını, $A_{s,dökme}$ etkili tabla içerisindeki kirişe paralel dökme donatılarının alanını, b_w kiriş gövde genişliğini, d ise kirişin faydalı yüksekliğini ifade etmektedir.

$$\rho_{max} = 0.85 \rho_b - (A_{s,dökme} / (b_w d)) \quad (6)$$

- Mesnet üst donatılarındaki azaltmaya bağlı olarak, sık donatılı kirişlerde brüt beton ve akışkanlaştırıcı kullanımı yerine, normal betonlarda vibratörün etkili kullanılmamasından veya betona bilinçsizce ekstra su katılmasından kaynaklı ortaya çıkabilecek segregasyon nedeniyle beton dayanımındaki düşüşe bağlı olarak olası gevrek göçmenin de önüne geçilecektir.
- Kiriş ortasındaki sehim L/240 limitine (1.16 cm) ulaşıldığında, tablalı K1 kirişine kıyasla tablasız dökme donatılı K2 kirişinin sık donatılı olmasından dolayı aderans kaybından kaynaklı, yük taşıma kapasitesinde yaklaşık %17'lik bir oranda kayba neden olduğu, donatının ρ_{max} 'a yakın kullanılması halinde bu oranın daha da artacağı görülmüştür.
- Kirişlerde donatının sık olması, erken aderans kaybı nedeniyle kirişlerde sehimin hızlı bir şekilde artmasına, çatlakların daha erken ve daha büyük olmasına dolayısıyla, kirişlerin kullanılabilirlik limitinin erken aşılmasına neden olduğu görülmüştür. Ancak, kiriş ortasındaki sehim 10 cm'ye ulaşıldığında donatının sık olmasının, kirişin taşıma kapasitesine negatif etkisinin ihmal edilecek düzeyde olduğu tespit edilmiştir.
- Kiriş ortasındaki sehim L/240 limitine ulaşıldığında, zayıf donatılı bir kirişin taşıma kapasitesine dökme donatısının katkısı %137'lerde olurken, en güçlü donatılı kirişte bile bu katkının %27.64 olabileceği yapılan ekstrapolasyon ile görülmüştür.
- Büyük depremler sonrasında yerinde yapılan incelemelerde sıklıkla rastlanan kolonlardaki mafsallaşmadan kaynaklı göçmelerin en büyük nedenlerinden biri kuvvetli kolon-zayıf kiriş şartının ihlal edilmesidir. Bu çalışmalar, etkili tabla genişliği içerisindeki dökme donatılarının da kiriş kesit analizlerinde dikkate alınması gerektiğini, aksi halde kolonların göçmesini önceleyen kat mekanizmalanmasına neden olabileceğini göstermiştir.

Bu çalışmada, TS 500 (2000)'e uygun seçilen tabla genişliği içerisindeki donatılarının neredeyse tamamının kiriş donatısı gibi katkı vermesinden dolayı, kirişlerin mesnetlerdeki gerçek etkili tabla genişliği ve kirişten uzaklaştıkça

donatılardaki yük dağılımındaki değişkenliği belirlenerek, bu çalışmanın ek deneylerle genişletilmesi düşünülmektedir.

Yazar Katkıları

Yunus GENÇ: Deneyleri ve hesapları yapmış ve makaleyi yazmıştır. (%50)

Orhan DOĞAN: Fikrin ortaya çıkmasını sağlamış, deney ve hesapların yapılmasında ve makale yazımında yardımcı olmuştur. (%50)

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

KAYNAKÇA

- [1] TBDY, “Türkiye Bina Deprem Yönetmeliği”, Afet ve Acil Durum Yönetimi Başkanlığı, Ankara, 2018.
- [2] U. Ersoy, “Betonarme giriş ve kolonların moment kapasitelerinin saptanması”, Teknik Dergi, vol. 9, no. 4, pp. 1781-1797, 1998.
- [3] TS 500, “Betonarme Yapıların Tasarım ve Yapım Kuralları”, Türk Standardları Enstitüsü, Ankara, 2000.
- [4] ACI-318, “Building Code Requirements for Structural Concrete”, American Concrete Institute, Farmington Hills, 2019.
- [5] CSA-A23.3, “Design of concrete structures”, Canadian Standards Association, Canada, 2004.
- [6] NZS 3101.1, “Concrete structures standard - Part 1: The Design of Concrete Structures”, New Zealand Standard, New Zealand, 2006.
- [7] EN 1992-1-1, “Eurocode 2: Design of concrete structures - Part 1-1: General rules and rules for buildings”, European Committee for Standardization, Brussels, 2004.
- [8] EN 1998-1, “Eurocode 8: Design of structures for earthquake resistance - Part 1: General rules, seismic actions and rules for buildings”, European Committee for Standardization, Brussels, 2004.
- [9] S. Y. M. Ma, V. V. Bertero, and E. P. Popov, “Experimental and analytical studies on the hysteretic behavior of reinforced concrete rectangular and T-beams”, Report EERC, vol. 76, no. 2, 1976.
- [10] S. Nakata, “Tests of Reinforced Concrete Beam-Column Assemblages”, Building Research Institute Research U.S.-Japan Cooperative Research Program, no.99, 1983.
- [11] C. W. French, and A. Boroojerdi, “Contribution of R/C floor slabs in resisting lateral loads”, Journal of Structural Engineering, vol. 115, no. 1, pp. 1-18, 1989.
- [12] P. C. Cheung, T. Paulay, and R. Park, “interior and exterior reinforced concrete beam-column joints of a prototype two-way with floor slab designed for earthquake resistance”, Report University of Canterbury, Christchurch, vol. 89, no. 2, 1989.
- [13] C. W. French, and J. P. Moehle, “Effect of Floor Slab on Behavior of Slab-Beam-Column Connections”, Design of Beam-Column Joints for Seismic Resistance, American Concrete Institute Special Publication 123, Farmington Hills, 1991.
- [14] S. M. Ahmed, U. Gunasekaran, and G. A. MacRae, “Effect of slab and transverse beam on R.C. beam column joint” International Conference on Earthquake Analysis and Design of Structures (EQADS 2011), India, 2011.
- [15] A. J. Durrani, and H. E. Zerbe, “Seismic resistance of R/C exterior connections with floor slab”, Journal of Structural Engineering, vol. 113, no. 8, pp. 1850-1864, 1987.
- [16] C. Aydemir, “Döşeme donatılarının iç aks girişlerinin negatif moment kapasitesi üzerine etkisi”, Teknik Dergi, vol. 24, no. 1, pp. 6279-6306, 2013.
- [17] S. M. Ahmed, and U. Gunasekaran, “Testing and evaluation of reinforced concrete beam-column-slab joint”, Gadevinar, vol. 66, no. 1, pp. 21-36, 2014.
- [18] URL-1, <https://yapisor.com/16585/kolon-kiris-birlesim-bolgesi>, (Erişim Tarihi: 05.03.2021).
- [19] URL-2, <https://yapisor.com/11700/vibrator-kullanmamanin-yol-actigi-soruna-cozum>, (Erişim Tarihi: 05.03.2021).
- [20] A. Doğangün, A. Ural, H. Sezen, Y. Güney, and F. K. Fırat, “The 2011 Earthquake in Simav, Turkey and Seismic Damage to Reinforced Concrete Buildings”, Buildings, vol. 3, no. 1, pp. 173-190, 2013.
- [21] U. Ersoy, G. Özcebe, and E. Canbay, “Betonarme Cilt 1 – Davranış ve Hesap İlkeleri”, Evrim Yayınevi (9. Basım), 2019.
- [22] TS 802, “Beton Karışım Tasarımı Hesap Esasları” Türk Standardları Enstitüsü, Ankara, 2016.
- [23] TS 706 EN 12620+A1, “Beton Agregaları”, Türk Standardları Enstitüsü, Ankara, 2009.
- [24] TS EN 12390-2, “Beton-Sertleşmiş Beton Deneyleri-Bölüm 2: Dayanım Deneylerinde Kullanılacak Deney Numunelerinin Hazırlanması ve Kürlenmesi”, Türk Standardları Enstitüsü, Ankara, 2019.
- [25] TS EN 12390-3, “Beton-Sertleşmiş Beton Deneyleri-Bölüm 3: Dayanım Deneylerinde Basınç Dayanımının Tayini”, Türk Standardları Enstitüsü, Ankara, 2019.
- [26] TS EN 206+A2, “Beton-Özellik, performans, imalat ve uygunluk”, Türk Standardları Enstitüsü, Ankara, 2021.
- [27] TS EN ISO 6892-1, “Metalik malzemeler - Çekme deneyi - Bölüm 1: Ortam sıcaklığında deney yöntemi”, Türk Standardları Enstitüsü, Ankara, 2020.

- [28] TS 708, “Çelik-Betonarme için-Donatı çeliği”, Türk Standardları Enstitüsü, Ankara, 2016.
- [29] A. Doğangün, “Betonarme Yapıların Hesap ve Tasarımı”, Birsen Yayınevi, (17. Basım), 2020.



Ağırlıklı Oy Tabanlı Topluluk Sınıflandırma Algoritması ile Göğüs Kanseri Teşhisi Breast Cancer Diagnosis with Weighted Vote Based Ensemble Classification Algorithm

¹Sinem BOZKURT KESER , ²Kemal KESKİN 

¹Eskişehir Osmangazi Üniversitesi, Bilgisayar Mühendisliği Bölümü, Eskişehir, Türkiye

²Eskişehir Osmangazi Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Eskişehir, Türkiye

¹sbozkurt@ogu.edu.tr, ²kkeskin@ogu.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 24 March 2022

Accepted : 14 June 2022

Keywords:

Breast Cancer Diagnosis, Machine Learning, Classification, Ensemble Methods, Voting Mechanism.

ABSTRACT

Breast cancer is a disease that is among the second causes of death among women, but its fatal risk is reduced with early diagnosis and the right treatment method. Currently, a large number of classification algorithms in data mining fields are adapted to breast cancer diagnosis based on patients' past medical records. In this study, a weighted vote-based ensemble classification algorithm is proposed for the diagnosis of breast cancer. The proposed algorithm is based on the working principle of more than one classification algorithm. By combining the classification algorithms with the weighted voting method, the result obtained from each algorithm alone is improved. The proposed weighted vote-based community classification algorithm consists of four stages. The first stage is the data preprocessing stage, followed by the classification stage. In the third stage, the reclassification process is carried out by using the weighted vote-based community classification algorithm with the performance values obtained from the classification process. With the proposed algorithm, an accuracy value of %98.77 was obtained, and a better value was obtained than the individual performance of each classification algorithm used in the classification phase.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 24 Mart 2022

Kabul : 14 Haziran 2022

Anahtar Kelimeler:

Meme Kanseri Teşhisi, Makine Öğrenmesi, Sınıflandırma, Topluluk Yöntemleri, Oylama Mekanizması.


ÖZET

Meme kanseri, kadınlar arasında ikinci ölüm nedenleri arasında gösterilen fakat erken teşhis ve ardından uygulanan doğru tedavi yöntemi ile ölümcül riski azaltılan bir hastalıktır. Günümüzde, veri madenciliği alanlarındaki çok sayıda sınıflandırma algoritması, hastaların geçmiş tıbbi kayıtlarına dayalı olarak meme kanseri teşhisine uyarlanmaktadır. Bu çalışmada, meme kanseri tanısı için ağırlıklı oy tabanlı topluluk sınıflandırma algoritması önerilmektedir. Önerilen algoritma, birden fazla sınıflandırma algoritmasının bir arada çalışma prensibine dayanmaktadır. Sınıflandırma algoritmaları ağırlıklı oylama yöntemi ile bir araya getirilerek her bir algoritmadan tek başına elde edilen sonucun iyileştirilmesi sağlanmaktadır. Önerilen ağırlıklı oy tabanlı topluluk sınıflandırma algoritması dört aşamadan oluşmaktadır. İlk aşama veri önleme aşaması olup bu aşamayı sınıflandırma aşaması izlemektedir. Üçüncü aşamada, sınıflandırma işleminden elde edilen performans değerleri ile ağırlıklı oy tabanlı topluluk sınıflandırma algoritması kullanılarak yeniden sınıflandırma işlemi gerçekleştirilmektedir. Önerilen algoritma ile %98.77 doğruluk değeri elde edilerek sınıflandırma aşamasında kullanılan her bir sınıflandırma algoritmasının bireysel performansından daha iyi bir değer elde edilmiştir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayımlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Bir organdaki hücrelerin kontrol dışı gelişimine bağlı olarak oluşan doku kütesine tümör denir. İyi huylu ve kötü huylu olmak üzere iki tür tümör vardır (Şekil 1). İyi huylu veya kanserli olmayan tümörler yayılmamaktadır ve yaşamı korkutmamaktadır. Diğer yandan, kötü huylu veya kanserli tümörler komşu organ ve dokulara yayılarak yaşamı ciddi şekilde tehdit ederler [1]. Kötü huylu meme kanseri, bu kötü huylu tümörlerin meme dokusunda olması durumunda tanımlanır. Meme kanseri hücreleri genellikle röntgende görülebilen veya yumru olarak hissedilebilen bir tümör oluşturur. Meme kanseri, kadımlar arasında akciğer kanserinden sonra ikinci genel ölüm nedenidir ve 40-55 yaşları arasında ise ilk ölüm nedenleri arasında gösterilir [2].



Şekil 1. Farklı büyütme oranlarında iyi huylu (sol) ve kötü huylu (sağ) meme örnekleri [3].

Küresel olarak, artan meme kanseri insidansı ve ölüm oranı, gelişmekte olan dünya için önemli ve büyüyen bir tehdit oluşturmaktadır. 2011 yılında, 1980'den 2010'a kadar yaklaşık 187 ülkenin meme kanseri ölüm ve insidans oranlarını kapsayan bir anket, küresel meme kanseri vakalarının yıllık ortalama %3.1'lik artış oranı ile 1980'deki 641.000 vakadan, 2010 yılında 1.643.000 vakaya yükseldiğini göstermiştir. Türkiye'de %2.4'lük artış oranı ile 1993 yılında 24/100.000 olan meme kanseri insidansının 2010 yılında neredeyse 50/100.000 olduğu görülmektedir. 2018 yılı Dünya Sağlık Örgütü verilerine göre ise yaklaşık olarak 627 bin kadın meme kanserinden hayatını yitirmiştir. Önemli ölçüde artan kanser oranının üstesinden gelmek için erken teşhis yaklaşımları birçok hastalığı önleme çalışmasında geniş çapta tartışılmaktadır. Doğru meme kanseri teşhisi ve ardından uygun kanser tedavisi, meme kanserinden kaynaklı ölüm riskini azaltabilir. Bu nedenle, sınıflandırma özelliklerine göre iyi huylu ve kötü huylu tespit çok önemli hale gelmektedir [4]. Erken teşhiste dikkatli teşhisin meme kanseri nedeniyle ölüm oranını azalttığı yapılan çalışmalar ile kanıtlanmıştır [5].

Günümüzde meme kanseri teşhisinde yapay zekâ teknolojilerinden oldukça yararlanılmaktadır. Sınıflandırma algoritmalarının, meme kanseri teşhisi de dâhil olmak üzere tıbbi teşhiste kullanımı hızla artmaktadır. Uzman tıbbi teşhisten değerlendirme ve karar verme süreci, burada anahtar faktördür. Bununla birlikte, akıllı sınıflandırma algoritması özellikle deneyimsiz pratisyenlerin hatalarını en aza indirmede doktora yardımcı olabilir. Imperial College London üniversitesinde görevli bilim insanları geliştirdikleri yapay zekâ sistemi ile 29 bin kadına ait mamografi görüntülerini incelemiştir. Sistemin hastanın geçmişi hakkında bilgisi olmamasına rağmen iki doktorun birlikte teşhis koymasına eşdeğer sonuçlara vardığı görülmüştür. Bu çalışmada, meme kanseri tanısı için ağırlıklı oy tabanlı topluluk sınıflandırma algoritması önerilmektedir. Önerilen algoritma, birden fazla sınıflandırma algoritmasının bir arada çalışma prensibine dayanmaktadır. Sınıflandırma algoritmaları ağırlıklı oylama yöntemi ile bir araya getirilerek her bir algoritmadan tek başına elde edilen sonucun iyileştirilmesi sağlanmaktadır.

Makalede giriş bölümünün ardından, ikinci bölümde meme kanseri teşhisinde literatürde makine öğrenmesi kullanılarak yapılan çalışmalar, Wisconsin meme kanseri veri seti ve önerilen ağırlıklı oy tabanlı topluluk sınıflandırma algoritması hakkında bilgi verilmiştir. Üçüncü bölümde, performans testlerinin nasıl yapıldığı açıklanarak performans testleri gerçekleştirilmiştir. Son bölümde çalışma ile ilgili sonuç ve değerlendirmelere yer verilmiştir.

1.1. Makine Öğrenmesi Algoritmaları ile Meme Kanseri Teşhisi

Son yıllarda biyomedikal teknolojilerin ve bilgi teknolojilerinin gelişmesiyle birlikte, meme kanseriyle ilgili çeşitli prognostik faktörler kaydedilmiş, bu da birçok araştırmacının farklı veriye dayalı tahmin metodolojileri kullanarak daha sofistike erken teşhis modelleri geliştirmesini sağlamıştır. Bu bağlamda literatürde, meme kanseri teşhisi için anlamlı modeli tahmin etmek ve tanımak için çeşitli teknikler uygulanmıştır. Aruna vd. Wisconsin meme kanseri veri setini sınıflandırmak için naif bayes, destek vektör makinesi ve karar ağacı algoritmalarını kullanmıştır ve en iyi doğruluk değerini %96.99 ile destek vektör makinesi ile elde etmiştir [6]. Chaurasia vd. Wisconsin meme kanseri veri seti üzerinde naif bayes, destek vektör makinesi, sinir ağları, karar ağacı yöntemlerini kullanarak denetimli öğrenme sınıflandırıcılarının performansını karşılaştırmıştır. Çalışma sonuçlarına göre destek vektör

makinesi ile %96.84 doğruluk değerine ulaşmıştır [7]. Asri vd. aynı veri seti üzerinde naif bayes, destek vektör makinesi ve karar ağacı arasında bir performans karşılaştırması yapmıştır. Kullanılan her algoritmanın doğruluğu, kesinliği, duyarlılığı ve özgüllüğünü karşılaştırarak verileri verimlilik ve etkinlik açısından sınıflandırmayı amaçlamıştır. Deney sonuçlarında, destek vektör makinesinin %97.13 ile en iyi doğruluk değerini aldığı görülmüştür [8]. Wang vd. lojistik regresyon algoritması ile %96.4 doğruluk değerini elde etmiştir [9]. Keles vd. rastgele orman algoritmasını kullanarak %92.2'lik bir doğruluk değeri elde etmişlerdir [10]. Kavitha vd. yapay sinir ağlarını topluluk yöntemlerini birlikte kullanarak %96.3 doğruluk değerini elde etmiştir [11]. Ahmad vd. karar ağacı, yapay sinir ağları ve destek vektör makineleri algoritmalarını meme kanseri teşhisinde kullanarak sırasıyla %93.6, %94.7 ve %95.7 doğruluk değerlerini elde etmişlerdir [12]. Alhabri ve Tchier bulanık tabanlı sistemler ve evrimsel genetik algoritma tabanlı hibrid bir algoritma ile %97.0 doğruluk değerini elde etmiştir [13]. Karar ağacı tabanlı bir öğrenme algoritması kullanılarak gerçekleştirilen bir diğer çalışmada, meme kanseri türlerinin sınıflandırılması yapılmıştır. Rastgele orman ve ekstra ağaç yöntemlerinin teşhis ve sınıflandırmadaki etkinliği ortaya koyulmuştur [14]. Wisconsin meme kanseri veri seti kullanılarak lojistik regresyon, karar ağacı, rastgele orman, karar destek makinesi yöntemleri ile meme kanseri teşhisi yapılmaya çalışılmıştır. En küçük mutlak küçülme ve seçim operatörü yardımıyla seçilen öznelikler algoritmaların verimini artırmıştır [15].

2. MATERYAL VE YÖNTEM

2.1. Veri Seti

Bu çalışmada, Madison'da bulunan Wisconsin Üniversite Hastanesi'nde Dr. William H. Wolberg'den tarafından elde edilen veri seti kullanılmaktadır. Wisconsin Üniversitesi ve Madison Klinik Bilim Merkezi işbirliğiyle yürütülen göğüs kanseri teşhisinde iğne ucu kadar biyopsi ile edinilen bir kitlenin görüntülenmesi ve bu görüntülerin dijitalleştirilmesiyle 1995 yılında bu veri seti elde edilmiştir. Veri seti B (iyi huylu tümörler) ve M (kötü huylu tümörler) olmak üzere 2 sınıfa ait 597 örnekten oluşturulmuştur. B sınıfına ait 357 adet örnek, M sınıfına ait 212 örnek bulunmaktadır. Her bir örnek için 30 öznelik tanımlanmıştır. Tümör özellikleri yarıçap, doku, çevre, alan, pürüzsüzlük, kompaktlık, içbükeylik, içbükey noktalar, simetri ve fraktal boyut olmak üzere 10 açıdan toplanmıştır. Bu özellikler Tablo 1'de verilmektedir.

Tablo 1. Wisconsin meme kanseri veri seti özellikleri ve değer aralıkları.

Özellik Adı	Ortalama	Standart Hata	En Yüksek
Yarıçap	6.98 - 28.11	0.11 - 2.87	7.93 - 36.04
Doku	9.71 - 39.28	0.36 - 4.89	12.02 - 49.54
Çevre	43.79 - 188.50	0.76 - 21.98	50.41 - 251.20
Alan	143.50 - 2501.00	6.80 - 542.20	185.20 - 4254.00
Pürüzsüzlük	0.05 - 0.16	0.00 - 0.03	0.07 - 0.22
Kompaktlık	0.02 - 0.35	0.00 - 0.14	0.03 - 1.06
İçbükeylik	0.00 - 0.43	0.00 - 0.40	0.00 - 1.25
İçbükey Noktalar	0.00 - 0.20	0.00 - 0.05	0.00 - 0.29
Simetri	0.11 - 0.30	0.01 - 0.08	0.16 - 0.66
Fraktal Boyut	0.05 - 0.10	0.00 - 0.03	0.06 - 0.21

Tablo 1 ile verilen özellikler, bir göğüs kitlesinin ince iğne aspiratının (fine needle aspirate, FNA) dijitalleştirilmiş bir görüntüsünden toplanmıştır. Her görüntü için ortalama, standart hata ve bu özelliklerin "en kötü" veya "en yüksek" hesaplanarak toplam 30 öznelik elde edilmiştir. Bu özneliklerin yeniden isimlendirilmesi Tablo 2'de verilmiştir.

Tablo 2. Wisconsin meme kanseri veri seti özellikleri ve değer aralıkları.

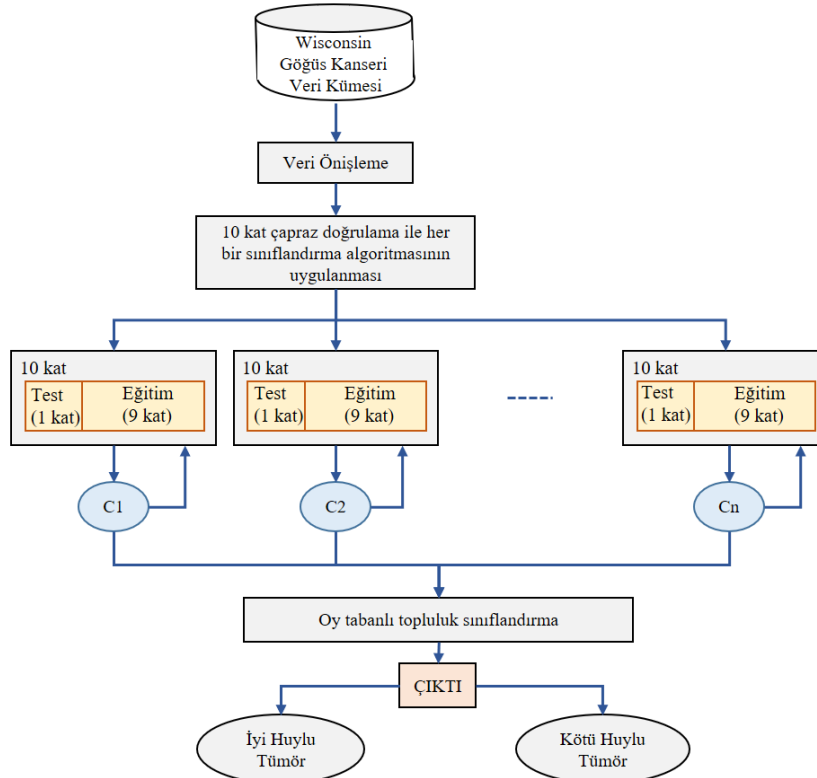
	Ortalama	Standart Hata	En Kötü
Yarıçap	RM	RS	RW
Doku	TM	TS	TW
Çevre	PM	PS	PW
Alan	ARM	ARS	ARW
Pürüzsüzlük	SM	SS	SW
Kompaktlık	CM	CS	CW
İçbükeylik	CNM	CNS	CNW
İçbükey Noktalar	CPM	CPS	CPW
Simetri	SYM	SYS	SYW
Fraktal Boyut	FM	FS	FW

Tablo 2’de her bir hücre içerisinde verilen değer ilgili satır ve sütuna karşılık gelen öznelik isminin yeni değerini göstermektedir. Örneğin, yarıçap_ortalama isimli özneliğin makale içerisindeki değeri RM olarak kısaltılmıştır.

2.2. Önerilen Yöntem

Meme kanseri her yıl milyonlarca kadında görülen ve erken teşhisin bu hastalıkla kaynaklanan ölüm oranını önemli ölçüde azalttığı bir hastalıktır. Meme kanserinin teşhisinde bugüne kadar çok önemli çalışmalar yapılmıştır. Bu çalışmada, meme kanseri tanısı için ağırlıklı oy tabanlı topluluk sınıflandırma algoritması önerilmektedir. Önerilen algoritma, birden fazla sınıflandırma algoritmasının bir arada çalışma prensibine dayanmaktadır. Sınıflandırma algoritmaları ağırlıklı oylama yöntemi ile bir araya getirilerek her bir algoritmadan tek başına elde edilen sonucun iyileştirilmesi sağlanmaktadır.

Önerilen ağırlıklı oy tabanlı topluluk sınıflandırma algoritması dört aşamadan oluşmaktadır. İlk aşamada, çalışmada kullanılan Wisconsin meme kanseri veri seti ön işlemden geçirilmektedir. İkinci aşamada, 10-kat çapraz doğrulama işlemi ile n sayıda sınıflandırıcı ile sınıflandırma işlemi yapılmaktadır. Üçüncü aşamada, sınıflandırma işleminden elde edilen performans değerleri ile ağırlıklı oy tabanlı topluluk sınıflandırma algoritması ile yeniden sınıflandırma işlemi gerçekleştirilmektedir. Son aşamada ise ağırlıklı oy tabanlı topluluk sınıflandırma algoritmasından elde edilen tahmin sonuçlarından karmaşıklık matrisi (confusion matrix) elde edilmektedir. Önerilen algoritmaya ait akış diyagramı Şekil 2’de verilmektedir.



Şekil 2. Önerilen ağırlıklı oy tabanlı topluluk sınıflandırma algoritması.

Şekil 2 ile verilen algorithmada, ilk aşamayı veri önışleme aşamasını oluşturmaktadır. Bu aşamada, her bir öznelik için örneklem bazında veriler kontrol edilerek kayıp veriler ilgili öznelikte tüm verilerin ortalaması ile değıştirilmektedir. Ayrıca bu aşamada veri seti içerisinde tüm veriler [-1, 1] aralığında normalize edilmektedir. İkinci aşama, sınıflandırma aşaması olup bu aşamada seçilen n adet sınıflandırma algoritmasının 10-kat çapraz doğrulama ile performans değerleri tespit edilmektedir. Üçüncü aşamada ağırlıklı oy tabanlı topluluk sınıflandırma algoritması uygulanmaktadır. Sınıflandırma aşamasında, her bir sınıflandırıcı ile veri seti içerisindeki her bir örneklem için iyi huylu tümör olarak tahmin edilme olasılığı ve kötü huylu tahmin edilme olasılıkları hesaplanmıştır. Bu değerlerden iyi huylu tümör olarak tahmin edilme olasılığı yüksek ise örneklem iyi huylu örneklem, diğer durumda ise kötü huylu örneklem olarak tahmin edilmektedir. Oy tabanlı topluluk sınıflandırma algoritmasına bu değerler algoritmaların ağırlıkları olarak verilmektedir. Bunun yanında, oy tabanlı topluluk sınıflandırma algoritmasında bir önceki aşamada kullanılan sınıflandırıcıların hangilerinin yeniden sınıflandırma işlemine dâhil edileceği kombinasyona dayalı bir yaklaşımla belirlenmektedir. Öncelikle ikili kombinasyonlar ile sınıflandırma algoritmaları ağırlıklı oylama yöntemi ile bir araya getirilmektedir. Daha sonra sınıflandırıcıların üçlü kombinasyonları benzer şekilde oluşturulmaktadır. Bu işleme kullanıcının belirlediği bir k sayısına ulaşınca kadar ya da sınıflandırma aşamasında kullanılan sınıflandırıcı sayısına (n) ulaşınca kadar devam edilir. Burada amaç, en az sayıda sınıflandırıcı ile en iyi doğruluk değerinin elde edilmesini sağlayan sınıflandırma kombinasyonunu elde etmektir.

2.3. Performans Değerlendirme

Makine öğrenmesinde karmaşıklık matrisi gerçek sınıf etiketleri ile tahmin edilen sınıf etiketleri arasındaki ilişkiyi göstermek için kullanılmaktadır. Hata matrisi olarak da isimlendirilirler. Sınıflandırma işlemi sonucu elde edilen doğruluk değerleri göstermek için kullanılan bir görselleştirme aracıdır [16]. Aslında, doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP), yanlış negatif (YN) değerlerini temsil etmek için kullanılır (Tablo 3).

Tablo 3. Karmaşıklık matrisi gösterimi.

		Tahmin Edilen Sınıf Etiketi	
		M	B
Gerçek Sınıf Etiketi	M	DP	YN
	B	YP	DN

- Doğru Pozitif (DP): Hastanın meme kanseri olduğunu ifade eder.
- Doğru Negatif (DN): Hastanın kanser olmadığını ifade eder.
- Yanlış Pozitif (YP): Meme kanseri olmayan bir kişiye yanlış bir şekilde kanser teşhisi konulduğunu ifade eder.
- Yanlış Negatif (YN): Meme kanseri olan bir kişiye yanlış bir şekilde kanser olmadığı şeklinde teşhis konulduğunu ifade eder.

Tablo 3 ile verilen karmaşıklık matrisindeki bu değerler kullanılarak sınıflandırma algoritmanın başarımını tespit etmek için kullanılan aşağıda verilen metrikler hesaplanmaktadır [17].

Doğruluk: Doğru olarak sınıflandırılan örneklem sayısının toplam örneklem sayısına oranını ifade eder.

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

Hassasiyet: Sınıflandırma algoritmasının doğru tahmin ettiği pozitif örneklem sayısının pozitif olarak tahmin ettiği toplam örneklem sayısına oranıdır.

$$\text{Hassasiyet} = \frac{DP}{DP+YP} \quad (2)$$

Hatırlama: Sınıflandırma algoritmasının pozitif örneklemeleri doğru tahmin etme gücünü ifade eder. Yani, hastalıklı olan bireylerin hastalıklı olduğunu doğru tahmin etme olasılığıdır.

$$\text{Hatırlama} = \frac{DP}{DP+YN} \quad (3)$$

Özgüllük: Hastalıklı olmayan bireylerin hastalıklı olmadığını doğru tahmin etme olasılığını ifade eder.


$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (4)$$

F-ölçütü: Hassasiyet ve hatırlama ölçütlerinin geometrik ortalaması olup her iki ölçüt değerinin beraber ele alınmasını sağlar.

$$F - \text{ölçütü} = \frac{2 * \text{Hassasiyet} * \text{Hatırlama}}{\text{Hassasiyet} + \text{Hatırlama}} \quad (5)$$

Tıbbi teşhis araştırmalarında, kesinlik ve hatırlama performansı raporlamak için kullanılan ana ölçütlerdir. F-ölçüsü, tıbbi teşhislerde performansın raporlanmasında da önemlidir, çünkü kesinlik ve hatırlamayı karşılaştırmalar için kullanımı daha basit olan bir yöntem olan tek bir metrik altında birleştirir. Tıp camiasında, yanlış bir negatif normalde yanlış pozitiften daha yıkıcıdır, bu nedenle hatırlama daha önemli bir ölçüm olarak kabul edilir. YP (kesinlik), YN (hatırlama) kadar önemli olmayabilir çünkü YP'ler hekimler tarafından dikkate alınmayabilir, ancak gözden kaçan bir durum bir hasta için çok ciddi sonuçlara neden olabilir. Bu nedenle, hassasiyetten çok hatırlama ağırlığına sahip değiştirilmiş bir F-ölçütü daha iyi bir ölçüttür [18].

Alıcı İşletim Eğrisi (ROC, Receiver Operating Characteristics) ve Eğri Altında Kalan Alan (AUC, Area Under Curve): Performans değerlendirmede kullanılan bir diğer analiz ROC analizidir. Özellikle, bir hastalığın teşhisinde sıklıkla kullanılan bir yöntemdir. Bir algoritmanın duyarlılık ve özgüllük açısından birlikte değerlendirilebilmesine olanak sağlar. Bu eğrinin oluşturduğu koordinat sisteminin x ekseninde "1-özgüllük", y ekseninde ise "duyarlılık" yer alır (Şekil 3).



Şekil 3. ROC eğrisi.

ROC eğrisi, her kesim noktasındaki DP ve YP'ye karşılık gelen noktaların birleştirilmesiyle oluşturulur. (0,0), (0,1) ve (1,1) noktalarını birleştiren ROC eğrisi ideal bir sınıflandırma algoritmasına karşılık gelirken (0,0)'dan (1,1) noktasına kadar 450 açı yaparak uzanan köşegen şeklindeki ROC eğrisi ise kötü performanslı bir algoritmanın varlığına işaret eder. ROC eğrisi, bu iki durum arasında değişkenlik göstererek $y=x$ fonksiyonuna yaklaştıkça kötü performanslı bir algoritma ortaya çıkar [19].

ROC eğrisinin altında kalan alan ile hasta ve hasta olmayan bireylerin ayrılmasına yardımcı olan doğruluk değeri belirlenir. AUC değerinin 0,5 olması sınıflandırıcının düzgün bir sınıflandırma yapmadığını, AUC değerinin 1 olması ise mükemmel bir sınıflandırma performansını gösterir. İdeal performanslı bir sınıflandırma algoritması ile elde edilen AUC değerinin bu iki değer arasında ve 1 değerine yakın bir değerde olması beklenir [20].

3. DENEY SONUÇLARI

Bu çalışmada, meme kanseri teşhisinde Python programlama dili ile geliştirilmiş scikit-learn kütüphanesinden yararlanılmıştır. scikit-learn, makine öğrenmesi ve veri madenciliği alanında geliştirilmiş algoritmalara ait fonksiyonları içeren ve son zamanlarda artan bir şekilde kullanılan bir kütüphanedir. Deneyler Windows 10 işletim sisteminde, Python'un 3.6.3 sürümü, scikit-learn kütüphanesinin 0.23.2 sürümü kullanılarak gerçekleştirilmiştir. Tüm deneyler, 8 GB RAM'e sahip (Intel (R) Core(TM) i7-4510U CPU @ 2.00GHz 2.60 GHz) bir bilgisayarda gerçekleştirilmiştir.

Çalışmada sınıflandırma aşamasında naif bayes (NB, naive bayes) [21], k en yakın komşu (kNN, k nearest neighbour) [22], karar ağacı (DT, decision tree) [23], rasgele orman (RF, random forest) [24], yapay sinir ağları (ANN, Artificial neural network) [25] ve destek vektör makineleri (SVM, support vector machine) [26] algoritmaları kullanılmıştır. Bu algoritmalar, literatürde meme kanseri teşhisi için yapılan çalışmalarda başarılı sonuçlar verdiği için tercih edilmiştir. Yapılan deney sonuçlarında algoritmaların her biri ile elde edilen karmaşıklık matrisleri Tablo 4'de verilmektedir.

Tablo 4. Sınıflandırma algoritmalarının karmaşıklık matris sonuçları.

		Tahmin edilen sınıf etiketi											
		SVM		ANN		kNN		NB		DT		RF	
		B	M	B	M	B	M	B	M	B	M	B	M
Gerçek sınıf etiketi	B	352	5	352	5	352	5	337	20	341	16	349	8
	M	8	204	10	202	14	198	16	196	26	186	15	197

Tablo 4’de verilen karmaşıklık matrisinden her bir sınıflandırıcıdan elde edilen DP ve DN değerleri ile önerilen ağırlıklı oy tabanlı topluluk sınıflandırma algoritması işletilmektedir. Bu algoritmaya göre en iyi sınıflandırma kombinasyonunun [SVM, ANN, kNN, NB] ile elde edildiği sonucuna varılmıştır. Bu dört sınıflandırma algoritmasının DP ve DN ağırlıkları ile bir araya getirilmesi ile elde edilen yeniden sınıflandırma sonucuna ait karmaşıklık matrisi Tablo 5’de verilmektedir.

Tablo 5. Önerilen algoritmanın karmaşıklık matrisi.

		Tahmin Edilen Sınıf Etiketleri	
		M	B
Gerçek Sınıf Etiketleri	M	355	2
	B	5	207

Tablo 4 ve Tablo 5’den elde edilen karmaşıklık matrisleri kullanılarak tüm algoritmalarının doğruluk, hassasiyet, hatırlama, f-ölçütü ve AUC performans ölçütleri açısından karşılaştırılmasını sağlayan Tablo 6 elde edilmiştir.

Tablo 6. Algoritmaların genel performans karşılaştırması.

	Doğruluk	Hassasiyet	Hatırlama	F-ölçütü	AUC
Önerilen Algoritma	98.77	99.40	98.60	99.10	99.80
SVM	97.60	97.80	98.60	98.20	99.60
ANN	97.40	97.50	98.30	97.90	99.50
RF	94.70	95.90	97.50	96.70	98.50
NB	93.70	95.50	94.40	93.70	98.40
kNN	93.50	93.50	96.40	94.90	96.50
DT	92.60	92.90	95.50	94.20	89.80

Tablo 6’da görüldüğü üzere önerilen algoritma ile her bir sınıflandırıcıdan bireysel olarak elde edilen başarıya göre daha yüksek değerlerde bir başarı elde edilmiştir. Tıbbi teşhis araştırmalarında, kesinlik ve hatırlama performansı raporlamak için kullanılan ana ölçütlerdir. F-ölçüsü, tıbbi teşhislerde performansın raporlanmasında da önemlidir, çünkü kesinlik ve hatırlamayı karşılaştırmalar için kullanımı daha basit olan bir yöntem olan tek bir metrik altında birleştirir. Tablo 6’da elde edilen F-ölçütü değerleri incelendiğinde ise yine en iyi sonuçlara önerilen algoritma ile erişildiğini söyleyebiliriz.

4. SONUÇLAR

Tıbbi alandaki teşhis süreci çok pahalı ve zaman alıcıdır. Bu çalışmada, meme kanseri tanısı için ağırlıklı oy tabanlı topluluk sınıflandırma algoritması önerilmektedir. Önerilen algoritma, birden fazla sınıflandırma algoritmasının bir arada çalışma prensibine dayanmaktadır. Sınıflandırma algoritmaları ağırlıklı oylama yöntemi ile bir araya getirilerek her bir algoritmadan tek başına elde edilen sonucun iyileştirilmesi sağlanmaktadır. Önerilen ağırlıklı oy tabanlı topluluk sınıflandırma algoritması dört aşamadan oluşmaktadır. İlk aşamada, veri ön işleme aşaması olup bu aşamayı sınıflandırma aşaması izlemektedir. Üçüncü aşamada, sınıflandırma işleminden elde edilen performans değerleri ile ağırlıklı oy tabanlı topluluk sınıflandırma algoritması kullanılarak yeniden sınıflandırma işlemini gerçekleştirmektedir. Önerilen oy tabanlı topluluk sınıflandırma algoritması ile %98.77 doğruluk değeri elde edilerek

sınıflandırma aşamasında kullanılan her bir sınıflandırma algoritmasının bireysel performansından daha iyi bir değer elde edilmiştir. Bu çalışmada önerilen algoritma, makine öğrenimi tekniğinin meme kanseri teşhisinde klinik asistan olarak kullanılabilmesini ve yanlış teşhis durumunda yeni doktorlar veya hekimler için çok faydalı olacağını öne sürmektedir. Bu çalışmada önerilen algoritmanın, meme kanseri teşhisinde yüksek doğrulukla otomatik olarak tespit edebildiği sonucuna varabiliriz.

Gelecek çalışmalar ve araştırmaların, algoritmaların çeşitlendirilmesi, teknolojinin ilerlemesi vb. birçok durum ile hastalıkların teşhisinde bilgisayar sistemlerinin önemi artacaktır. İnsan tarafından yapılabilecek hatalar, hastalık teşhislerinin gecikmesi vb. durumlar makine öğrenmesi, yapay zeka gibi bilimlerle azaltılarak hata payı daha da düşürülecektir.

Yazar Katkıları

Sinem Bozkurt Keser – Makale yazımı, literatür araştırması, yöntem, veri işleme, deneysel çalışmalar.
Kemal Keskin – Makale yazımı, özet, literatür araştırması, düzeltmeler.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

KAYNAKÇA

- [1] The American Cancer Society, “What is Breast Cancer”. url: <https://www.cancer.org/cancer/breast-cancer/about/what-is-breast-cancer.html>. (Erişim Tarihi: 22/03/2022).
- [2] T. S. Subashini, V. Ramalingam, and S. Palanivel, “Breast mass classification based on cytological patterns using RBFNN and SVM,” *Expert Syst. Appl.*, vol. 36, no. 3, pp. 5284–5290, 2009.
- [3] R. M. Levenson, E. A. Krupinski, V. M. Navarro, and E. A. Wasserman, “Pigeons (*Columba livia*) as trainable observers of pathology and radiology breast cancer images.” *PLoS One*, vol. 10, no. 11, p. e0141357, 2015.
- [4] M. F. Akay, “Support vector machines combined with feature selection for breast cancer diagnosis,” *Expert Syst. Appl.*, vol. 36, no. 2, pp. 3240–3247, 2009.
- [5] D. West, P. Mangiameli, R. Rampal, and V. West, “Ensemble strategies for a medical diagnostic decision support system: A breast cancer diagnosis application,” *Eur. J. Oper. Res.*, vol. 162, no. 2, pp. 532–551, 2005.
- [6] S. Aruna, S. Rajagopalan, Nandakishore, “L. Knowledge based analysis of various statistical tools in detecting breast cancer” *Comput. Sci. Inf. Technol.*, vol. 2, pp. 37–45, 2011.
- [7] V. Chaurasia, S. Pal, “Data mining techniques: To predict and resolve breast cancer survivability” *Int. J. Comput. Sci. Mob. Comput.*, vol. 3, pp. 10–22, 2011.
- [8] H. Asri, H. Mousannif, H. Al Moatassime, T. Noel, “Using machine learning algorithms for breast cancer risk prediction and diagnosis.” *Procedia Comput. Sci.*, vol. 83, pp. 1064–1069, 2016.
- [9] D. Wang, D. Zhang, and Y. H. Huang “Breast Cancer Prediction Using Machine Learning”, vol. 66, no.7, 2018
- [10] M. K. Keles, M. Kaya, "Breast Cancer Prediction and Detection Using Data Mining Classification Algorithms: A Comparative Study", *Tehnicki Vjesnik - Technical Gazette*, vol. 26, no. 1, p. 149, 2019.
- [11] R. K. Kavitha¹, D. D. Rangasamy, “Breast Cancer Survivability Using Adaptive Voting Ensemble Machine Learning Algorithm Adaboost and CART Algorithm”, vol. 3, no. 1, 2014.
- [12] L. G. Ahmad, A. Eshlaghy, A. Poorebrahimi, M. Ebrahimi, A. Razavi, and others, “Using three machine learning techniques for predicting breast cancer recurrence”, *J Health Med Inform*, vol.4, no. 3, 2013.
- [13] A. Alharbi, F. Tchier, “Using a genetic-fuzzy algorithm as a computer aided diagnosis tool on Saudi Arabian breast cancer database”, *Mathematical Biosciences*, vol. 286, pp. 39–48, 2017.
- [14] M. M Ghiasi, S. Zendejboudi, “Application of decision tree-based ensemble learning in the classification of breast cancer”, *Computers in Biology and Medicine*, vol. 128, p. 104089, 2021.
- [15] P. Ghosh, A. Karim, S. T. Atik, S. Afrin, M. Saifuzzaman, “Expert cancer model using supervised algorithms with a LASSO selection approach”, *International Journal of Electrical and Computer Engineering*, vol. 11, no. 3, pp. 2631–2639, 2021.
- [16] J. Han and M. Kamber, “Data Mining Concepts and Techniques”, Morgan Kaufman Publishers, 2000.
- [17] P. Cabena, P. Hadjinian, R. Stadler, J. Verhees, and A. Zanasi, “Discovering Data Mining: From Concept to Implementation”, Upper Saddle River, N. J., Prentice Hall, 1998.
- [18] A. S. Assiri, S. Nazir, and S. A. Velastin, “Breast Tumor Classification Using an Ensemble Machine Learning Method”, *Journal of Imaging*, vol. 6, no. 6, p. 39, 2020.
- [19] T. Mitchell, “Machine Learning”, New York, USA, McGraw Hill, 1997.
- [20] P. Harrington, “Machine Learning in Action”, New York, USA, Manning Publications, 2012.
- [21] S. Aruna, S. Rajagopalan, L. Nandakishore, “Knowledge based analysis of various statistical tools in detecting breast cancer”, *Comput. Sci. Inf. Technol.*, vol. 2, pp. 37–45, 2011.

- [22] H. Asri, H. Mousannif, H. Al Moatassime, T. Noel, "Using machine learning algorithms for breast cancer risk prediction and diagnosis", *Procedia Comput. Sci.*, vol. 83, pp. 1064–1069, 2016.
- [23] D. Delen, G. Walker, A. Kadam, "Predicting breast cancer survivability: A comparison of three data mining methods", *Artif. Intell. Med.*, vol. 34, pp. 113–127, 2005.
- [24] T. Al-Quraishi, J. H. Abawajy, M. U. Chowdhury, S. Rajasegarar, A. S. Abdalrada, "Breast cancer recurrence prediction using random forest model", In *Adv. In- tell. Syst. Comput.*, pp. 318–329, 2018.
- [25] N. Shukla, M. Hagenbuchner, K. T. Win, J. Yang, "Breast cancer data analysis for survivability studies and prediction", *Comput. Methods Programs Biomed*, vol. 155, pp. 199–208, 2018.
- [26] K. Kourou, T. P. Exarchos, K. P. Exarchos, M. V. Karamouzis, D. I. Fotiadis, "Machine learning applications in cancer prognosis and prediction", *Comput. Struct. Biotechnol. J.*, vol. 13, pp. 8–17, 2015.



Model ve Veri Odaklı Yaklaşımlar ile Nesne Tespit Başarısının Arttırılmasına Yönelik ESA ve Veri Seti Optimizasyonları

CNN and Dataset Optimizations to Improve Object Detection Performance with Model and Data-Centric Approaches

¹Önder ALPARSLAN , ²Ahmet ÖZCAN , ³Ömer ÇETİN 

^{1,2,3}Milli Savunma Üniversitesi, Hezârfen Havaçılık ve Uzay Teknolojileri Enstitüsü, Yeşilyurt/İstanbul, Türkiye

¹oalparslan@hho.msu.edu.tr, ²iletisim@ahmetozcan.com,

³omer_cetin@outlook.com.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 20 April 2022

Accepted : 29 June 2022

Keywords:

Object Detection and Classification,
Model-Centric Approaches,
Data-Centric Approaches

ABSTRACT

To improve the accuracy of object detection and classification methods, model and data-centric approaches have been frequently studied by researchers in recent years. Most researchers propose methods based on their problem or present new methods by changing the existing models. On the other hand, the number of studies on the data used in the training process is quite small. In this study, the effects of model and data-centric approaches on an existing object detection problem are compared. The accuracy and performance effect obtained with YOLOv4 network, which has widespread usage, and reprocessing of the dataset are compared and evaluated. While the accuracy of object detection increased by about 4% with the change in the network structure, an average of 8% decrease occurred in the computational speed. On the other hand, reprocessing the data and running the object detection algorithm provided 6% gain, but did not cause a change in the calculation cost. Although it is not considered enough today, it is observed that the preparations of the data have a significant effect on the classification accuracy.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 20 Nisan 2022

Kabul : 29 Haziran 2022

Anahtar Kelimeler:

Nesne Tanıma ve Sınıflandırma
Model Odaklı Yaklaşımlar,
Veri Odaklı Yaklaşımlar.

ÖZET

Nesne tespit ve sınıflandırma yöntemlerinin başarısının artırılması amacıyla model odaklı ve veri odaklı yaklaşımlar araştırmacılar tarafından son yıllarda sıklıkla çalışılmaktadır. Araştırmacıların birçoğu problemlere özgü model önerilerinde bulunmakta ve mevcut modeller üzerinde değişimler önermektedir. Öte yandan, eğitim sürecinde kullanılmakta olan veri üzerinde yapılan çalışmaların sayısı oldukça azdır. Bu çalışmada, mevcut bir tanıma ve sınıflandırma problemi üzerinde, model ve veri odaklı yaklaşımların etkileri kıyaslanmıştır. Yaygın kullanıma sahip olan YOLOv4 ağı üzerinde yapılan ağ yapısı değişikliğinin başarı ve performansa etkisiyle, veri setinde kullanılan verilerin yeniden hazırlanmasıyla elde edilen başarı karşılaştırılarak yorumlanmıştır. Ağ yapısının değişimi ile nesne tanıma başarıları yaklaşık %4 oranında artarken, hesaplama hızında ortalama %8'lik düşüş meydana gelmiştir. Öte yandan verilerin yeniden hazırlanarak nesne tanıma algoritmasının çalıştırılması %6 oranında kazanç sağlarken, hesaplama maliyetinde değişime neden olmamıştır. Günümüzde yeteri kadar dikkate alınmasa da veri üzerindeki hazırlıkların sınıflandırma doğruluğuna önemli derecede etki yaptığı gözlemlenmiştir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

ORCID ID: ¹0000-0001-8803-1597

²0000-0002-1098-7078

³0000-0001-5176-6338

1. GİRİŞ

Günümüzde robotik, güvenlik, sağlık ve doğa bilimleri gibi birçok alanda etkinlikle kullanılmakta olan nesne tespit ve sınıflandırma yöntemlerinin başarı ve hız performanslarını artırmaya yönelik yoğun çalışmalar sürdürülmektedir. Bu çalışmalara ait yaklaşımları iki kategoride inceleyebiliriz. Birinci kısımda eğitim ve sınıflandırma modelinin güncellenmesi yer alırken, diğer kısımda verilerin güncellenmesi yer almaktadır. Yapay zekâ araştırmacıları, matematiksel model ve optimizasyon yöntemlerindeki gelişmeler sayesinde model odaklı yaklaşımlardan daha sık faydalanmaktadır [1-3]. Öte yandan, veri odaklı yaklaşımların ele alınması da gündeme gelmeye başlanmıştır [4].

Nesne sınıflandırma yöntemlerinde sıklıkla evrimsel sinir ağları tercih edilmektedir [5]. Son yıllarda, mobil cihazlarda ve araçlarda nesne sınıflandırmasının kullanımı ile hızlı ve etkin sonuçlar üretebilen düşük maliyetli yöntemler daha popüler hale gelmiştir. Faster R-CNN, YOLO, SSD, DSSD, RetinaNet ve SPP-Net [6-11] gibi algoritmalar, giriş verisini evrimsel bir sinir ağı modeli içerisinde sınıflandırmaktadırlar. Görüntü üzerinde nesne sınıflandırma için kullanılan bu yöntemler, birden çok işleme katmanından oluşan hesaplama modellerinin, birden çok soyutlama düzeyi sayesinde verilerin temsillerinin öğrenmesini sağlar [12]. Krizhevsky'nin çalışmasıyla [13] oldukça popüler hale gelen derin öğrenme teknikleri, özellikle mobil robotlarda ve cihazlarda yüksek performans elde edilebilmek için tek bir tespit ağı kullanımını ve ağı küçültülmesini içeren yöntemlere evrilmektedir. Ancak işlem yükünü azaltan bu yöntemler, tespit başarısının düşmesine sebep olduğundan araştırmacılar hesaplama maliyetini artırmadan tespit doğruluğunu artıracak geliştirmeleri araştırmaktadırlar.

Nesne tespit modelinin başarısının artırılabilmesi için giriş verisi üzerinde ön işlemler gerçekleştirilebilir veya ağ yapısında değişikliklere gidilebilmektedir. Giriş verisi üzerinde yapılacak özellik çıkarımları (SIFT, HOG) resim üzerinde aranan nesnelere ağ için daha belirgin hale getirebilmektedir [14, 15]. Bunun yanında, ağ hiperparametrelerinin ve ağ modelinin değişimleri de pozitif getiriler sağlayabilmektedir [16].

Veri setinin hazırlanmasında homojen ortamlar ve kategoriler kullanılamaması, kullanılan ekipmanların veri setini kullanacak kişilerden çok farklı olması, çevresel koşulların ve engelleyici durumların yeterince işlenmemesi ve kullanıcının sınıflandırma yapacağı ekipmanların ya da mekânın sıra dışı olması sebebiyle, sınıflandırma başarısı memnun edici seviyede olmayabilmektedir. Bu nedenlerle ihtiyaca özgü veri seti oluşturulması ya da mevcut veriler üzerinde çalışma yapılması da sınıflandırma başarısına katkı sağlayabilmektedir.

Bu çalışma ile nesne tespit ve sınıflandırma başarısının artırılabilmesi için kullanılacak model odaklı ve veri odaklı yaklaşımlar irdelenerek, mevcut bir model ve veri seti üzerinde yapılan değişikliklerle başarı sınaması yapılması ve sonuçların kıyaslanması amaçlanmıştır. Model odaklı çözümler ve veri odaklı yaklaşımlara duyulan ihtiyaç ikinci bölümde, mevcut bir sistem üzerinde yapılan değişiklikler üçüncü bölümde, yapılan değişikliklerin başarıya olan etkileri ve değerlendirmeleri ise dördüncü bölümde yer almaktadır.

2. MODEL ODAKLI VE VERİ ODAKLI YAKLAŞIMLAR

Derin öğrenme yöntemlerinin günümüzdeki karmaşık yapısı ve yüksek hesaplama maliyetlerine rağmen zorlu koşullarda başarısı güvenilir seviyelerin altındadır. Mevcut model mimarisini, kullanılan fonksiyonların ya da veri işleme tekniklerinin güncellenmesi ile daha yüksek başarı elde edilmeye çalışılmaktadır [1-3]. En sık kullanılan modellerden birisi olan YOLO için farklı geliştiriciler tarafından YOLOv4 [17] ve YOLOv5 [18] önerilmiştir. Bu modeller ve yapılan geliştirmelerle yöntemlerin başarısı artırılmakla birlikte, ağ daha yavaş çalışabilmekte ya da farklı örnekler için başarı oranı düşmektedir [1]. Kendi problemlerini ve modelin çalışma yöntemini iyi anlayabilen araştırmacılar, mevcut model üzerinde girdiler yaparak ihtiyaca özgü bir model oluşturup daha iyi sonuçlar elde edebilmektedir.

Literatürde yapılan çalışmaların çok büyük bir bölümünün model odaklı yaklaşımlar üzerine olduğu görülmektedir [19]. Ancak, yapay zekâ çalışmalarında kullanılan veri setlerinin birçoğu yetersiz, kirli hatta kimi zaman yanlış bilgilerle doludur [20]. Nesne tespit ve sınıflandırması için kullanılan veri setleri araştırmacılar tarafından özgün ya da açık kaynak verilerin toplanmasıyla oluşturulmakta ve Kaggle, Github gibi ortamlarda paylaşılmaktadır. Yaygın kullanılan hazır veri setlerinden alınan veriler; yanlış, eksik ya da uzmanlar tarafından bile ne olduğu konusunda uzlaşamayan etiketlere sahiptir. Şekil 1'de CIFAR-100'da verilen istakoz örneği gerçekte yengeç, Caltech-256'da verilen yunus örneği gerçekte kano, ImageNet'de verilen beyaz leylek örneği gerçekte siyah leylektir. CIFAR-100'da yer alan hamster, Caltech-256'da laptop ve ImageNet'de peygamber devesi örnekleri doğru örnekler olsa da görüntülerde yer alan kupa, insan ve fens teli nesnelere işaretlenmemiştir. Öte yandan şekilde en altta yer alan örneklerin ne olduğu konusunda ise uzlaşamamaktadır.

Northcutt ve arkadaşlarına [4] göre geniş kullanım alanına sahip veri setlerinin %3,4'ü yanlış etiketlenmiş durumdadır ve daha büyük veri setleri de bu hatalardan etkilenmektedir. Yukarıda verilen örneklerden görüleceği üzere kullanımda olan hazır veri setleri eğitimi olumsuz etkileyebilecek olan örneklere ve etiketlere sahiptir. Bu sebeple de veri hazırlama sürecine önem verilerek veriler ayıklanmalı ve etiketlemeleri hassas bir şekilde gerçekleştirilmelidir.


CIFAR-100 Caltech-256 ImageNet



Şekil 1. Hazır veri setlerine ait olumsuz etiketleme örnekleri [4].

3. YÖNTEM

Model ve veri odaklı yaklaşımların nesne tespiti başarısına olan etkilerini ölçmek için, kapalı ortamlarda yer alan kapı, pencere ve merdivenlerin tespit ve sınıflandırılması problemi ele alınmıştır. Bu nesnelere, robotik sistemlerin kapalı ortam otonom yol planlamasında robotun diğer alanlara ya da bina dışına gitmesi için geçiş noktaları olarak kullanılabilir. Bu nesnelere teşhisi için mobil robotlarda kullanılacak performans ve tespit başarısı gösterebileceği değerlendirilen yöntemler incelenmiştir. Mobil robotlar için güncel tespit ve yöntemlerinin karşılaştırıldığı çalışmalar [21, 22] da incelenerek en optimal çözüm olacağı değerlendirilen YOLOv4 yöntemi tercih edilmiştir. Nesne tespit yöntemine ait modelin daha hassas sonuçları üretmesi amacıyla ağ yapısı değiştirilmiştir ve veri seti düzenlenmiştir.



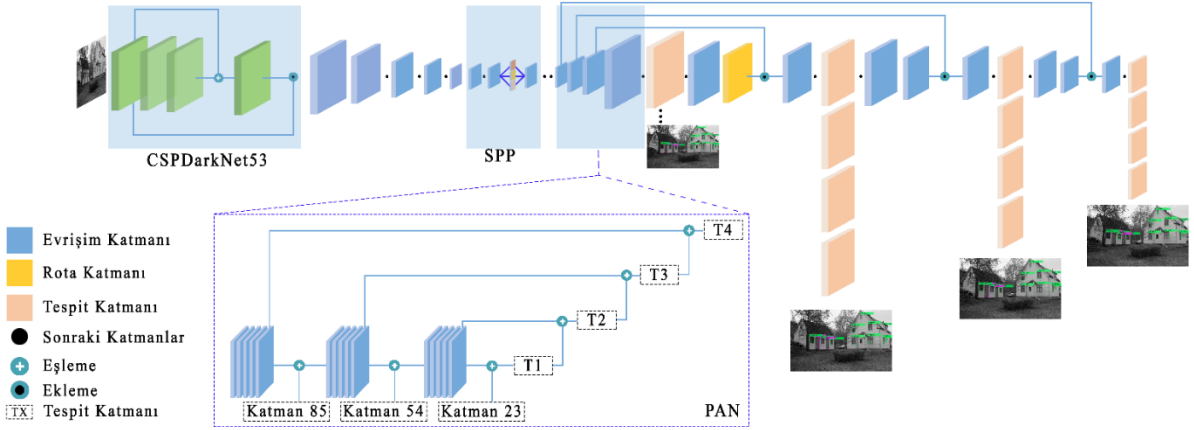
Şekil 2. YOLOv4 mimarisi [17].

3.1. Ağ Yapısının Değişimi

Günümüzün popüler nesne tespit yöntemlerinden YOLOv4'ü inceleyecek olursak, Şekil 2'de görülen bir ağ yapısıyla karşılaşılmaktadır. Ağdaki omurga (backbone) ve boyun (neck) kısımlarında CSPDarknet53 ağı, Spatial Pyramid Pooling (SPP) ve Path Aggregation Network (PAN) yöntemlerinden faydalanılmaktadır. CSPDarknet53 ağı, darknet53 üzerine kurulmuş ve böl/birleştir stratejisiyle daha fazla gradyan akışına izin vermektedir. SPP [11] ve PAN kavrama alanını artırmak ve yanıl bağlantılarla özellik haritaları arasında özellik piramidi inşa etmek için kullanılmaktadır. PAN, ilk olarak eleman bazında maksimum işlemi kullanarak tüm katmanlardan gelen bilgileri birleştirir. Daha sonra, kısa yoldan tanıma katmanlarına ulaşarak daha hassas yerleştirilmiş bilgileri üst katmanlar için kullanılabilir hale getirir. Bu çok özellikli ağ yapısına rağmen, YOLOv4, farklı ölçeklerdeki (çok küçük ya da çok büyük) nesnelere sınıflandırmakta güçlük çekmektedir. Bu zorluğu aşmak adına ağ modeline bir eklenti yapılması tasarlanmıştır.

Görüntü üzerinde yer alan küçük boyutlu nesnelere tespit başarısını artırabilmek adına, PAN ve tanıma katmanları üzerinde güncellemelere gidilmiştir. Evrimsel sinir ağı (ESA), düşük seviyeli özellik haritasında zengin anlamsal

bilgiye ve yüksek seviyeli özellik haritasında zengin konum bilgisine sahiptir. Düşük seviyedeki anlam bilgisini artırmak ve nesnelerin görüntü üzerindeki yer bilgisini daha iyi çıkarabilmek amacıyla, giriş katmanındaki özellik çıkarımlarından daha fazla faydalanmayı sağlayacak bir füzyon katmanı PAN'a eklenmiştir. Şekil 3'de görüleceği üzere PAN içerisindeki görüntü verisi, omurgada yer alan 23, 54 ve 85'inci katmanlardaki görüntülerle eşlenerek tanıma katmanlarına sunulmaktadır. Ayrıca, PAN'dan sonra klasik YOLOv4'ten farklı olarak dört farklı ölçekte tespit işlemi gerçekleştirilmektedir. YOLOv4'te en büyük 64x64 (Giriş verisinin 512x512 olması durumunda) olan tespit ölçeğinin çok küçük ve çok büyük nesneleri tanımda yetersiz olabileceği düşünüldükten dolayı iki katı büyüklüğünde, küçük ve büyük nesneleri daha etkinlikle tespit edebilecek ilave bir tanıma katmanı oluşturulmuştur. Böylece daha büyük boyutlu sayısal görüntüler üzerinde de tespit ve sınıflandırma yapılarak standart ağ modeliyle eksik ya da yanlış yerde tespit edilen nesnelerin daha doğru bir şekilde tespit edilmesi amaçlanmıştır.



Şekil 3. Özelleştirilen ağ modeli.


3.2. Veri Setinin Düzenlenmesi

Tespit ağının eğitiminde kullanılan verilerin kalitesi tespit modelinin başarısına doğrudan katkı sağlamaktadır. Veriler, gerçek hayattaki olası tüm varyasyonları içermeli, verilerin aynı korelasyonda olmasına izin verilmemelidir. Örneğin araba sınıflandırması yapan bir modeldeki verilerin birçoğunun otobandan alınan görüntü olması, yapay sinir ağının asfalt arka planla araba arasında bir bağıntı kurmasına sebep olabilir. Bunun yanında, farklı ışık ve netlik koşullarından veri elde edilmesi de değişen hava koşullarında tespit başarısının sağlanmasını kolaylaştırır. Elde edilen verilerin hatalı olup olmadığının bulunması ve bu verilerin temizlenmesiyle de eğitim sürecine katkıda bulunmaktadır.

Çalışma kapsamında kullanılan veri seti, üç farklı veri setine [23-25] ait görüntüleri ve internet kaynaklarından elde edilen görüntüleri içermektedir. Oluşturulan veri setine internet bağlantı adresinden (www.kaggle.com/dataset/7f4acf71b4f8c8c970c6d8f4a5bc8f4c97ab9bc22f00b38cf5985d7847b772a4) erişilebilmektedir. Bu veri setinin düzenlenebilmesi amacıyla, öncelikle veri seti tek tek gözden geçirilmiştir. Veri seti içinde yer alan hatalı veriler, eksik işaretlemeler, işaretlemede standart dışılık ve bazı ortamlara ait veri miktarının çok kısıtlı olması gibi nedenlerle eğitimin olumsuz etkileyeceği değerlendirilmiştir.

Verilerdeki en büyük zorluklardan birisi, farklı ölçeklerdeki kapı ve pencerelerdir. Örneğin, veri setinin orijinal yapısında Şekil 4 (a)'da görülen çok sayıda küçük pencerenin bir kısmı işaretli iken, bir kısmının işaretli olmadığı görülmüştür. Şekil 4 (b)'de yer alan örneklerde, pencereleri çevreleyen kutuların bazı pencereler için geniş bazı pencereler içinse dar çizildiği anlaşılmaktadır. Bu tip standarttan uzak işaretlemeler IoU (Intersection over Union-birleşim kesişimi) hatalarına sebep olabilmekte ve tespit başarısını azaltmaktadır. Farklı kültür mimarilerine ait kapı ve pencere şekilleri, büyük bir çeşitlilikle veri setine aktarılarak gerçek dünya varyasyonları için iyi bir hazırlık yapıyor olsa da Şekil 4 (c)'de yer alan araba kapısı çok ender rastlanan bir kapı şeklidir ve veri seti genelinde de başka örneği çok azdır. Bu yüzden veri setinin eğitimini olumsuz etkileyeceği değerlendirilmiştir.

Şekil 4 (ç)'de yer alan bir pencereye ait çerçeveyici kutu ise nesneden oldukça büyüktür. Veri seti incelendiğinde bu tip örneklerin çok sayıda olduğu ve görüntü üzerine konum bilgisini oluşturan verilerin dönüşüm hatasından kaynaklandığı anlaşılmıştır. Bu sebeplerle nesne sınıflandırmasına olumlu katkı sağlamayacağı ya da mevcut başarının da düşmesine sebep olacağı düşünülen veriler üzerinde eksiltme, artırma ve yeniden işaretleme yöntemleriyle güncellemeye gidilmiştir.



Şekil 4. Veri setinde görülen eksiklik ve hatalar.

4. BULGULAR

Mevcut tanıma ve sınıflandırma probleminin mobil robotlarda kullanılacak olması nedeniyle, test çalışmaları bir mobil geliştirme birimi olan NVIDIA Jetson AGX Xavier üzerinde gerçekleştirilmiş ve yöntem kısmında belirtildiği üzere kapı, pencere ve merdiven görüntülerini içeren bir veri seti üzerinde değerlendirilmiştir. Veri setinde yer alan görüntülerdeki nesnelerin sınıf dağılımları Tablo 1’de verilmiştir.

Tablo 1. Görüntüler üzerindeki örneklerin sınıf dağılımları.

	Kapı	Merdiven	Pencere	Toplam
Örnek Sayısı	3140	1584	9312	14036
Toplam Görüntü	5012			

Mevcut veri setinin orijinal ağ modeli ile ve modelin değişimi sonrasında eğitimi gerçekleştirilmiştir. Veri setinde yer alan 5012 adet görüntünün %10’luk kısmı rassal olarak ayrılarak modellerin başarısının ölçümü için kullanılmıştır. Modellerin eğitim başarısı ve kayıp değeri her 5000 iterasyonda sınanarak, en iyi başarımların ulaşılan 55000 iterasyona kadar gerçekleştirilmiştir. Tablo 2’de görülen karşılaştırma verisi, her bir sınıf için farklı birleşim kesişimi değerlerinde (0.25, 0.50 ve 0.75) ortalama hassasiyet değerlerini (Average Precision-AP), ortalama doğruluk değerlerini (accuracy) genel ortalama hassasiyet değerlerini (Mean Average Precision-MAP), ortalama birleşim kesişimi değerlerini (average Intersection over Union- avg IoU), ve iki farklı yöntemde saniyede işlenebilen çerçeve sayısını (FPS) içermektedir. Daha iyi bir ölçüm işlemi için 5-katlı çapraz doğrulama gerçekleştirilerek sonuçların ortalaması, en düşük ve en yüksek değerleri tabloya yansıtılmıştır. Modeldeki değişiklik tespit başarısını hemen hemen her karşılaştırmada artırarak hassasiyet değerlerinde ortalama %4’lük bir iyileştirme sağlamış, çerçeveleyici kutular yaklaşık %12 oranında daha isabetli bulunmuştur. Bununla birlikte, ağa eklenen katmanların getirdiği hesaplama maliyeti, saniyede işlenebilen çerçeve sayısının (FPS) yaklaşık %8 oranında düşmesine neden olmuştur.

Tablo 2. Ağ yapısı özelleştirmesine ait test sonuçları.

	Klasik YOLOv4			Özelleştirilmiş YOLOv4		
	AP@0,25	AP@0,50	AP@0,75	AP@0,25	AP@0,50	AP@0,75
Kap_{min}	%52,86	%45,54	%28,65	%59,17	%48,03	%33,18
Kap_{ort}	%58,56	%50,838	%35,04	%64,864	%55,58	%38,93
Kap_{maks}	%61,45	%56,15	%44,32	%68,92	%60,54	%46,77
Merdiven_{min}	%76,23	%75,69	%45,23	%94,31	%88,08	%39,15
Merdiven_{ort}	%82,64	%77,97	%49,58	%95,10	%91,45	%56,40
Merdiven_{maks}	%88,45	%81,12	%53,02	%95,55	%94,78	%86,66
Pencere_{min}	%45,44	%42,16	%17,60	%39,02	%32,53	%18,37
Pencere_{ort}	%56,83	%47,90	%19,15	%50,44	%40,74	%22,37
Pencere_{maks}	%66,24	%51,42	%21,45	%64,75	%49,01	%24,9
mAP	%66,01	%58,90	%39,51	%70,13	%62,59	%39,24
F1 Score	0,55	0,49	0,28	0,61	0,55	0,35
avg iou	%42,99	%43,96	%35,84	%53,95	%56,82	%58,05
FPS	17,6			16,2		

Veri setinde yapılan düzenlemeler sonucunda veri setinde mevcut 5012 görüntüde hatalı verilerin çıkarılması ve yanlış etiketlemelerin düzenlenmesi sonucunda Tablo 3'teki sınıf dağılımları elde edilmiştir.

Tablo 3. Düzenlenen görüntüler üzerindeki örneklerin sınıf dağılımı.

	Kapı	Merdiven	Pencere	Toplam
Örnek Sayısı	3484	1975	13170	18629
Toplam Görüntü	4767			

Düzenlenen veri setindeki görüntülerin %10'luk kısmı sınama için ayrılarak kalan görüntülerle ağız eğitimi gerçekleştirilmiştir. Eğitim sırasında oluşan kayıp değeri ve her 5000 iterasyonda yapılan başarımlarını dikkate alınarak 55000 iterasyona kadar eğitime devam edilmiştir. Daha iyi bir ölçüm işlemi için 5-katlı çapraz doğrulama gerçekleştirilerek eğitim ve test işlemi beş kez tekrar edilmiştir. Eğitim sonunda her sınıf için ortalama hassasiyet, doğruluk ve ortalama birleşim kesişimi değerleri kıyaslanarak, sonuçlar Tablo 4'te gösterilmiştir. Veri setindeki değişimlerin ortalama hassasiyeti yaklaşık %6 artırdığı, nesne konumunun ise yaklaşık %4 oranında daha iyi tespit ettiği anlaşılmıştır.

Tablo 4. Düzenlenen veri setine ait test sonuçları.

	Klasik YOLOv4			Düzenlenen Veri Seti		
	AP@0,25	AP@0,50	AP@0,75	AP@0,25	AP@0,50	AP@0,75
Kap_{min}	%52,86	%45,54	%28,65	%61,32	%46,99	%29,09
Kap_{ort}	%58,56	%50,838	%35,04	%63,63	%53,42	%34,22
Kap_{maks}	%61,45	%56,15	%44,32	%66,89	%58,08	%38,91
Merdiven_{min}	%76,23	%75,69	%45,23	%86,43	%82,06	%48,66
Merdiven_{ort}	%82,64	%77,97	%49,58	%90,02	%87,29	%64,98
Merdiven_{maks}	%88,45	%81,12	%53,02	%92,53	%91,38	%81,40
Pencere_{min}	%45,44	%42,16	%17,60	%55,14	%45,69	%17,30
Pencere_{ort}	%56,83	%47,90	%19,15	%63,64	%54,20	%21,44
Pencere_{maks}	%66,24	%51,42	%21,45	%72,70	%62,39	%26,14
mAP	%66,01	%58,90	%39,51	%72,43	%64,97	%40,21
F1 Score	0,55	0,49	0,28	0,54	0,51	0,36
avg iou	%42,99	%43,96	%35,84	%45,31	%48,26	%39,55

5. DEĞERLENDİRME VE SONUÇ

Bu çalışmada, nesne sınıflandırma yöntemlerinin başarısına artırmaya yönelik literatürdeki çalışmalar incelenerek model ve veri odaklı yaklaşımların tespit başarısına olan etkileri değerlendirilmiştir. Son yıllarda çok sayıda çalışmada sınıflandırma modelinin üzerinde değişiklikler yapılıyor olsa da araştırmacılar veri üzerindeki hazırlıkların da önemine vurgu yapmaktadır. Veri ön işleme süreci ve doğru verilerle eğitim yapılmasının da sınıflandırma başarısı üzerinde büyük etkisi vardır. Model odaklı ve veri odaklı yaklaşımların etkilerini incelemek üzere halihazırda kapı, pencere ve merdiven nesnelerini tespit etmekte kullanılan veri seti ve YOLOv4 ağı üzerinde düzenlemelere gidilmiştir. İki yaklaşımla da tespit başarısının artırılabilirdiği gözlemlenirken, model odaklı yaklaşımda ağı büyütülmesi nedeniyle gerçek zamanlı çalışmada hesaplama performansında yaklaşık %8'lik bir yavaşlamaya neden olduğu görülmüştür. Öte yandan veri setinde yer alan 5012 adet görüntüden gereksiz olduğu değerlendirilen 245 adedinin silinmesi, 2348 görüntü üzerindeki örneklere ait işaretlemelerin değişimi (ekleme, silme ve yeniden işaretleme) ile ağa ek yük getirmeden tespit başarısının yaklaşık %6 oranında artırılması sağlanmıştır. Elde edilen sonuçlar, sıklıkla ihmal edilen ya da bu alanda yeterince profesyonel olmayan üçüncü kişilere yaptırılan veri hazırlama sürecinin sınıflandırma başarısına önemli derecede etkisini olduğunu net olarak göstermektedir. Gelecek çalışmalar ile, çok sayıda içerik barındıran ve geniş kullanım alanına sahip olan COCO veri seti üzerinde düzenleme çalışmaları yapılması planlanmaktadır.

Yazar Katkıları

Yazarlar çalışmaya eşit oranlı katkı sunmuşlardır.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler

KAYNAKÇA

- [1] A. Kumar, Z. J. Zhang, and H. Lyu, "Object detection in real time based on improved single shot multi-box detector algorithm." EURASIP Journal on Wireless Communications and Networking, vol.1, pp. 1-18, 2020.
- [2] Y. Cai, T. Luan, H. Gao, H. Wang, L. Chen, Y. Li, M.Á. Sotelo, and Z. Li, "YOLOv4-5D: An Effective and Efficient Object Detector for Autonomous Driving." IEEE Transactions on Instrumentation and Measurement, vol. 70, pp. 1-13, 2021.
- [3] S. Zhai, D. Shang, S. Wang, and S. Dong, "DF-SSD: An improved SSD object detection algorithm based on DenseNet and feature fusion", IEEE Access, vol. 8, pp. 24344-24357, 2020.
- [4] C. G. Northcutt, A. Athalye, and J. Mueller, "Pervasive label errors in test sets destabilize machine learning benchmarks", arXiv preprint arXiv:2103.14749, 2021.
- [5] K. Li, W. Ma, U. Sajid, Y. Wu, and G. Wang, "Object detection with convolutional neural networks", In Deep Learning in Computer Vision, pp. 41-62, 2020.
- [6] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks", IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 39, no. 6, pp. 1137-1149, 2017.
- [7] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified Real-Time Object Detection", 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 779-788, 2016.
- [8] W. Liu, D. Anguelov, D. Erhan et al., "SSD: Single Shot MultiBox Detector", Lecture Notes in Computer Science, vol. 9905, pp. 21-37, 2016.
- [9] C. Y. Fu, W. Liu, A. Ranga, et al., "DSSD: Deconvolutional Single Shot Detector", arXiv, Computer Vision and Pattern Recognition, 2017.
- [10] T. Y. Lin, P. Goyal, R. Girshick, et al., "Focal Loss for Dense Object Detection", IEEE Transactions on Pattern Analysis and Machine Intelligence, no. 99, pp. 2999-3007, 2017.
- [11] P. Purkait, C. Zhao and C. Zach, "SPP-Net: Deep absolute pose regression with synthetic views", arXiv preprint arXiv:1712.03452, 2017.
- [12] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning. Nature", vol. 521 no. 7553, pp. 436-444, 2015.
- [13] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks", Advances in neural information processing systems, vol. 25, pp. 1097-1105, 2012.
- [14] S. S. Shanta, S. T. Anwar, and M. R. Kabir, "Bangla sign language detection using sift and CNN", In 2018 9th international conference on computing, communication and networking technologies (ICCCNT), pp. 1-6, 2018.
- [15] B. T. Hung, "Face recognition using hybrid HOG-CNN approach", In Research in Intelligent and Computing in Engineering, pp. 715-723, 2021.
- [16] Y. Tian, G. Yang, Z. Wang, H. Wang, E. Li, and Z. Liang, "Apple detection during different growth stages in orchards using the improved YOLO-V3 model", Computers and electronics in agriculture, vol. 157, pp. 417-426, 2019.
- [17] A. Bochkovskiy, W. Chien-Yao, and H. Y. M. Liao, "YOLOv4: Optimal Speed and Accuracy of Object Detection," arXiv preprint arXiv:2004.10934, 2020.

- [18] Ultralytics, "YOLOv5". Available: <https://github.com/ultralytics/yolov5>. (Erişim Tarihi: 02.01.2022)
- [19] S. E. Whang, Y. Roh, H. Song, and J. G. Lee, "Data Collection and Quality Challenges in Deep Learning: A Data-Centric AI Perspective", arXiv preprint arXiv:2112.06409, 2021.
- [20] Y. Lin, Y. Guan, A. Asudeh, H. V. Jagadish, "Identifying insufficient data coverage in databases with multiple relations. Proceedings of the VLDB Endowment", vol. 13, no. 11, 2020.
- [21] Ö. Alparslan, Ö. Çetin, "Comparison of Object Detection and Classification Methods For Mobile Robots", Sakarya University Journal of Science, vol. 25, no. 3, pp. 764-778, 2021.
- [22] S. Manzoor, S. H. Joo, and T. Y. Kuc, "Comparison of object recognition approaches using traditional machine vision and modern deep learning techniques for mobile robot", 19th International Conference on Control, Automation and Systems (ICCAS), pp. 1316-1321, 2019.
- [23] A. Kuznetsova, H. Rom, N. Alldrin, J. Uijlings, I. Krasin, J. PontTuset, et al. "The open images dataset v4: Unified image classification, object detection, and visual relationship detection at scale", International Journal of Computer Vision, vol. 128, pp. 1956-1981, 2020.
- [24] M. Arduengo, T. Carme and L. Sentis, "Robust and adaptive door operation with a mobile manipulator robot", arXiv preprint arXiv:1902.09051, 2019.
- [25] U. Patil et al., "Deep Learning Based Stair Detection and Statistical Image Filtering for Autonomous Stair Climbing", 2019 Third IEEE International Conference on Robotic Computing (IRC), pp. 159-166, 2019.



Kızıl Tilki Optimizasyon Algoritması ile DA-DA Alçaltıcı Tip Dönüştürücü Kontrolör Katsayılarının Optimizasyonu

Optimization of Buck Converter Controller Coefficients with Red Fox Optimization Algorithm

¹Ersagun Kürşat YAYLACI , ²Ahmet Erdem YILMAZ , ³Hatice Nur ÖZDEŞ 

^{1,2,3}Karabük Üniversitesi, Mühendislik Fakültesi, Karabük, Türkiye

¹ekyaylaci@karabuk.edu.tr, ²aeilmz07@gmail.com,

³haticenur9878@gmail.com

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 30 April 2022

Accepted : 12 July 2022

Keywords:

Red Fox Optimization, PI Controller, Buck Converter, Particle Swarm Optimization

ABSTRACT

In this study, closed-loop output voltage control of Buck converter, which is widely used in devices that need dc voltage, has been made. It is seen that meta-heuristic methods have been used quite a lot recently for the determination of controller coefficients. By using red fox optimization algorithm, steady-state error, which is one of the control performance criteria of the system, is tried to be improved with PI controller. The objective function used for the desired improvement process; is calculated by taking the average of the sum of the absolute values of the error, the sum of the squares of the error, and the sum of the time-weighted squares of the error. This study is carried out in MATLAB/Simulink environment and the obtained results are analyzed comparatively by the particle swarm optimization method. According to the analysis results obtained, the objective function fitness values for the red fox and particle swarm optimization methods were obtained as 1.1181 and 1.1045, respectively, and they showed close performances. When the working times are compared, the particle swarm optimization algorithm can find the optimum two times faster than the red fox optimization algorithm.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 30 Nisan 2022

Kabul : 12 Temmuz 2022

Anahtar Kelimeler:

Kızıl Tilki Optimizasyonu, PI Kontrolör, Alçaltıcı Tip DA-DA Dönüştürücü, Parçacık Sürü Optimizasyonu

ÖZET

Bu çalışmada, da gerilime ihtiyaç duyulan cihazlarda yaygın olarak kullanılan alçaltıcı tip DA-DA dönüştürücünün kapalı çevrim çıkış gerilim kontrolü yapılmıştır. Kontrolör katsayılarının belirlenmesi için meta-sezgisel yöntemlerin son zamanlarda oldukça fazla kullanıldığı görülmektedir. PI kontrolörü ile kızıl tilki optimizasyon yöntemi kullanılarak sistemin kontrol performans kriterlerinden sürekli hal hatası iyileştirilmeye çalışılmıştır. Yapılmak istenen iyileştirme işlemi için kullanılan amaç fonksiyonu; zamanla ağırlıklandırılmış hata karelerinin toplamı, hata mutlak değerlerinin toplamı ve hata karelerinin toplamı değerlerinin ortalaması alınarak hesaplanmıştır. Bu çalışma MATLAB/Simulink ortamında gerçekleştirilmiş olup elde edilen sonuçlar parçacık sürü optimizasyonu yöntemi ile karşılaştırmalı olarak analiz edilmiştir. Elde edilen analiz sonuçlarına göre kızıl tilki ve parçacık sürüsü optimizasyon yöntemleri için amaç fonksiyonu uygunluk değerleri sırasıyla 1,1181 ve 1,1045 olarak elde edilmiş olup birbirine yakın performans sergilemişlerdir. Çalışma süreleri kıyaslandığında ise parçacık sürü optimizasyon algoritması, kızıl tilki optimizasyon algoritmasından yaklaşık iki kat daha hızlı optimum bulabilmektedir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayımlanmaktadır. Tüm Hakları Saklıdır.

ORCID ID: ¹0000-0003-0358-5617

²0000-0002-8408-5536

³0000-0002-3198-3412


1. GİRİŞ

Doğadaki canlıların yaşayış biçimleri meta-sezgisel optimizasyon yöntemlerine ilham kaynağı olmaktadır. Doğada sürü halinde yaşayan canlıların sergiledikleri sezgisel hareketler, avlanma şekilleri ve yaşayış tarzları matematiksel olarak modellenerek çeşitli problemlerin çözümü için farklı optimizasyon algoritmaları geliştirilmiştir [1, 2]. Parçacık Sürü Optimizasyonu (PSO), Gri Kurt Optimizasyonu (GKO), Kızıl Tilki Optimizasyonu (KTO) algoritmaları bu tür algoritmalara örnek olarak verilebilir [3–5]. PSO algoritması 1995 yılında Kennedy ve Eberhart tarafından geliştirilmiş olup doğrusal olmayan problemlerin çözümünde de sıkça tercih edilmektedir [6]. Kızıl tilki optimizasyonu algoritması 2021 yılında Dawid Połap ve Marcin Woźniak tarafından kızıl tilkilerin doğadaki yaşayış ve avlanma biçimlerinden esinlenilerek geliştirilmiş bir optimizasyon algoritmasıdır. KTO algoritması PSO'ya benzer bir şekilde sürü zekasına dayanmakta ve amaç fonksiyonuna en uygun olan tilkinin konumu kullanılarak sürü içerisindeki tilkilerin yeniden konumlandırılması yapılmaktadır. Buna ek olarak avını çevreleyen bir avlanma modeli ile avlanma tamamlanmaktadır [5]. KTO yöntemi şimdiye dek çeşitli problemlerin çözümünde kullanılmıştır [7–13]. Örneğin 2022 yılında yapılan bir çalışmada, deri kanserinin teşhisinde KTO tabanlı geliştirilmiş algoritma kullanılmıştır [7]. Bir başka çalışmada uçak yakıt hücresi, süper kapasitör ve pil enerji depolama biriminden oluşan hibrit sistem için sistemin verimliliğini arttırmak amacı ile Kaos Kızıl Tilki Optimizasyonu algoritması adı verilen KTO tabanlı geliştirilmiş bir meta-sezgisel algoritma kullanılmıştır [8]. Bir diğer çalışmada ise KTO algoritmasında geliştirmeler yapılarak elde edilen algoritma ile Olağanüstü Öğrenme Makineleri (Extreme Learning Machines, ELM) yöntemi hibrit kullanılmıştır [9]. Neng Zhu ve arkadaşları yaptıkları çalışmada sıfır enerjili binalarda yer alan yenilenebilir enerji yapıları için maliyet ve model tasarımında, geliştirilmiş KTO yöntemi ile çok kriterli optimizasyon ve optimum model için Gri Çok Düzeyli Tam Değerlendirme yaklaşımının entegrasyonunu sağlamışlardır [10]. 2022 yılında yapılan bir çalışmada PV hücre/modellerinde kullanılacak olan tek ve çift diyot model parametrelerinin güvenilir seçilmesi amacıyla Runge Kutta yöntemi ile KTO ve yeni çıkan diğer dört optimizasyon yöntemi karşılaştırılmıştır [11]. Katı oksit yakıt hücresindeki bilinmeyen değişkenlerin optimum şekilde tanımlanması amaçlanan bir çalışmada ise KTO yöntemi tercih edilerek optimizasyon sağlanmıştır [12]. Bir başka çalışmada ise yapay zeka uygulamalarında kullanılan birleşik öğrenme yönteminin doğruluğunu arttırmak için KTO yöntemi kullanılmıştır [13].

Endüstride sıklıkla kullanılan doğru akım dönüştürücülerinden biri olan alçaltıcı tip DA-DA dönüştürücü (Buck Converter, BC), girişine uygulanan gerilimi çıkışına düşürerek aktaran anahtarlamalı bir dönüştürücü devresidir. BC devresinin çıkış gerilim kontrolü, çıkışına bağlanacak cihazların problemsiz çalışması için önem arz etmektedir. Bu çalışma kapsamında BC çıkış gerilim kontrolü için PI (Oransal-İntegral) kontrolör kullanılmıştır. PI kontrolöre ilişkin katsayıların belirlenmesi bir optimizasyon problemi olarak kabul edilebilir [6]. Günümüze dek en uygun katsayılar için optimizasyon yöntemlerinin kullanıldığı bir çok farklı çalışma yapılmıştır [14–16]. Bu çalışmalardan birinde DA-DA yükseltici dönüştürücü için PI kontrolörü kullanılmış ve Guguk kuşu optimizasyonu yöntemi ile PI kontrolörünün katsayıları belirlenmiştir [14]. Bir diğer çalışmada ise alçaltıcı-yükseltici DA-DA dönüştürücünün çıkış gerilim kontrolü için PI kontrolörü uygulanmış ve PI katsayıları PSO yöntemi ile belirlenmiştir [15]. BC devresi için PI kontrolörü kullanılan başka bir çalışmada ise optimum katsayıları Karışık Kurbağa Sıçrayan Algoritması (Shuffled Frog Leaping Algorithm, SFLA) ile bulunmuştur [16]. Literatürde henüz KTO yöntemi ile kontrolör katsayısı optimizasyonuna ilişkin bir çalışmaya rastlanmamıştır. Bu çalışmada, KTO ile BC devresinin çıkış gerilim kontrolü için kullanılan PI kontrolörün katsayıları optimize edilmiştir. Yöntem için sürekli hal hatası referans alınarak amaç fonksiyonu uygunluk değerinin minimizasyonu amaçlanmıştır. Önerilen yöntem ile daha önce literatürde oldukça fazla kullanılan PSO algoritması; uygunluk değeri, iterasyon sayısı ve simülasyon süreleri bakımından karşılaştırılmıştır. Çalışmanın geri kalanında 2. bölüm alçaltıcı tip DA-DA dönüştürücüye ayrılmıştır. 3. ve 4. bölümde sırasıyla PSO ve KTO yöntemleri anlatılmış, 5. ve 6. bölümde ise sırasıyla bulgular ve sonuç kısımlarına yer verilmiştir.

2. ALÇALTICI TİP DA-DA DÖNÜŞTÜRÜCÜ

BC devresi, elektronik cihazların birçoğunda, güç kaynakları ve motor hız denetimi uygulamalarında sıklıkla kullanılmaktadır [17]. Girişine uygulanan gerilimi anahtarlama elemanı ile çıkışına düşürerek ileten BC devresi, anahtarlama elemanının iletim ve kesim durumuna göre iki farklı çalışma konfigürasyonuna sahiptir. Ayrıca BC sürekli ve süreksiz akım modu olarak iki farklı dinamik yapıya sahip olabilir. Bu çalışma kapsamında sürekli akım modunda çalışması sağlanmaktadır [6]. BC elektriksel eşdeğer devresi Şekil 1'de gösterilmiştir.



Şekil 1. Alçaltıcı tip DA-DA dönüştürücü.

Anahtar açık durumda iken BC eşdeğer devresi Şekil 2.a'da gösterildiği gibi olup çıkışında elde edilen akım ve gerilim Denklem 1 ve 2 ile hesaplanabilmektedir:


$$\frac{di_L}{dt} = -\frac{v_o}{L} \quad (1)$$

$$\frac{dv_o}{dt} = \frac{1}{C} \left(i_L - \frac{v_o}{R} \right) \quad (2)$$

Anahtar kapalı durumda iken ise BC eşdeğer devresi Şekil 2.b'de gösterildiği gibi olup akım ve çıkış gerilimi Denklem 3 ve 4'te ifade edilen denklemler ile hesaplanabilmektedir:

$$\frac{di_L}{dt} = \frac{1}{L} (V_i - v_o) \quad (3)$$

$$\frac{dv_o}{dt} = \frac{1}{C} \left(i_L - \frac{v_o}{R} \right) \quad (4)$$



Şekil 2. BC elektriksel eşdeğer devresi a) Anahtar açık iken, b) Anahtar kapalı iken.

Çalışmada kullanılan BC devresi parametreleri Tablo 1'de gösterilmiştir.

Tablo 1. Parametre değerleri.

Tanım	Sembol	Parametre
Giriş Gerilimi	V_i	9 V
Çıkış Gerilimi	V_o	5 V
İndüktör	L	555 μ H
Kapasitör	C	25 μ F
Yük Direnci	R	10 Ω
Anahtarlama Frekansı	f_s	20 kHz

3. PARÇACIK SÜRÜ OPTİMİZASYONU

PSO algoritması, doğadaki yaşamlarını sürüler halinde sürdüren canlıların yaşayış biçimlerinden esinlenerek geliştirilmiştir. Sürü içinde bilgi paylaşımını ve sürü dayanışmasını esas almaktadır. Sürülerin beslenmek ve güvenli bir barınak bulmak için sergiledikleri rastgele veya sezgisel davranışların, sürüyü amacına kolay ve hızlı bir şekilde ulaştırdığı görülmüştür. Parçacıklar, daha önceki tecrübelerinden ve sürünün en iyi bireyinden faydalanarak kendilerini sürü içerisindeki en iyi konuma ayarlamaya çalışırlar [6].

Algoritma esas olarak aşağıdaki adımlardan meydana gelir [3];

1. Başlangıçta rastgele atanan başlangıç konumları ve hızları ile sürü oluşturulur.
2. Sürüde bulunan tüm parçacıklar için amaç fonksiyonundan uygunluk değerleri hesaplanır.
3. Her bir parçacığın, bulunduğu iterasyon için lokal en iyi değeri belirlenir.
4. Bulunulan iterasyon için parçacıkların lokal en iyi değerlerinin arasından global en iyi değeri ifade eden "gbest" değeri seçilir.
5. Konum ve hız değerleri gbest değerine göre her iterasyonda güncellenir.

Hız ve konum değerleri sırasıyla Denklem 5 ve 6'da ifade edildiği gibi hesaplanmaktadır [18].

$$v_{iD}^{(t+1)} = w \cdot v_{iD}^t + c_1 r_1 (p_{iD}^t - x_{iD}^t) + c_2 r_2 (g_i^t - x_{iD}^t) \quad i = 1, 2, 3, \dots, m \quad (5)$$

$$x_{iD}^{t+1} = x_{iD}^t + v_{iD}^{t+1} \quad (6)$$

Burada c_1 ve c_2 ölçeklendirme katsayıları, p_{iD}^t lokal en iyi konum, g_i^t ise global en iyi konumdur. Parçacık sayısı i ile ifade edilirken, t iterasyon sayısını belirtmektedir. r_1 ve r_2 çarpanları her iterasyonda güncellenen, [0,1] aralığında rastgele atanan çarpanlardır [18]. Atalet ağırlığı w ile ifade edilip yapılmak istenen yavaşlatma işleminin oranını belirlemektedir. Bu değer için algoritmanın başında bir maksimum ve minimum noktası belirlenir ve iterasyon boyunca w değeri w_{max} 'dan w_{min} 'e doğru doğrusal bir azalma gösterir. Bu azalma işlemi ile sistemin

başlangıcında w global arama performansında artış sağlarken, sistemin sonlanmasına doğru lokal arama performansında artış sağlanmaktadır. Atalet ağırlığı Denklem 7’de gösterildiği gibi hesaplanmaktadır [6].

$$w = w_{\max} - i \left(\frac{w_{\max} - w_{\min}}{i_{\max}} \right) \quad (7)$$

w_{\max} ve w_{\min} değerleri çalışmaların genelinde sırasıyla 0,9 ve 0,4 kullanılmaktadır [19].

Algoritmanın arama işlemi sırasında, parçacıkların arama uzayının dışına çıkmasını önlemek için sistemin başında arama uzayı için bir alt ve üst sınır belirlenir. Sınır değerleri, sistemin optimuma daha hızlı ulaşmasını sağlamak için önemli bir etmendir. Parçacıkların v_{\max} ve v_{\min} sınırları Denklem 8 ve 9’da belirtildiği gibi belirlenmektedir [20].

$$v^{\max} = k \cdot x^{\max} \quad 0,1 \leq k \leq 0,5 \quad (8)$$

$$v^{\min} = -v^{\max} \quad (9)$$

Konum ve hız değerleri, belirlenen sınırlar dışında bir değer gelmesi halinde Denklem 10’a göre güncellenir [21].

$$\text{Eğer } v^{t+1} > v^{\max} \text{ ise } v^{t+1} = v^{\max}$$

$$\text{Eğer } v^{t+1} < v^{\min} \text{ ise } v^{t+1} = v^{\min}$$

$$\text{Eğer } x^{t+1} > x^{\max} \text{ ise } x^{t+1} = x^{\max} \quad (10)$$

$$\text{Eğer } x^{t+1} < x^{\min} \text{ ise } x^{t+1} = x^{\min}$$

4. KIZIL TILKI OPTİMİZASYONU

Dawid Połap ve Marcin Woźniak tarafından 2021 yılında geliştirilen KTO, kızıl tilkilerin doğadaki yaşam tarzlarından ve avlanmalarından esinlenilerek geliştirilmiştir. Her bir tilki sürüsü kendi alfa çiftinin egemenliği altında tek bir bölgeyi paylaşmaktadır. Sürüdeki genç üyeler büyüdüklerinde eğer başka bir bölgeyi kontrol etme şansı yakalarlarsa sürüden ayrılarak kendi sürülerini kurabilmektedirler. Bölgede yemek için arama yapan bir tilki, avlayabileceği bir av fark ettiğinde ona en etkili saldırıyı yapabilecek yakınlığa gelene kadar ava fark ettirmeden yaklaşır. Kızıl tilkinin avlanması iki safhada gerçekleşmektedir; birinci safhada bölge üzerinde av araması yapılır ve bu safha global arama olarak isimlendirilir. İkinci safhada bölge üzerinde fark edilen ava; saldırmadan önce olabildiğince yaklaşılır ve bu safha ise lokal arama olarak isimlendirilmektedir [5].

Tüm iterasyonlar boyunca tilki sayısı sabit kalmaktadır. Tilkilerin her birinin n koordinattaki bir noktası $\bar{x} = (x_0, x_1, \dots, x_{n-1})$ şeklinde gösterilmektedir. Her bir tilki $(\bar{x}_j^t)^t$ gösterimi ile ifade edilmektedir. Burada j boyut indisine karşılık gelmektedir. Amaç fonksiyonundan optimum değerleri bulmak için tilkilerin çözüm uzayı sınırları içerisinde dolaştıkları kabul edilmektedir [5].

4.1. Yemek Arama (Global Arama)

Sürü içerisindeki tüm tilkiler, diğer üyelerin hayatta kalması için önem arz etmektedir. Farklı bölgelerin keşfi ve lokal habitatta yemek olmaması gibi durumlar sonucunda tilkiler uzak noktalara giderek av arayışlarını sürdürürler. Bu keşif eylemi sırasında edindikleri bilgi, tecrübe gibi kazanımları sürünün hayatta kalması ve gelişmesi için diğer tilkilerle paylaşırlar. Bölgenin keşfi, bütün bireylerin uygunluk değerine göre modellenir. Sürüdeki en iyi tilkinin, amaç fonksiyonuna göre arazi üzerindeki en uygun noktayı keşfettiği varsayılır ve en iyi tilki bu noktayı ailenin diğer üyeleri ile paylaşır. Bu sebepten dolayı, ilk olarak bireyler amaç fonksiyonuna göre sıralanır ve sürü içerisindeki en iyi tilki $(\bar{x}^{\text{en iyi}})^t$ olarak atanır. Daha sonra her bir tilkinin $(\bar{x}^{\text{en iyi}})^t$ ile olan öklid uzaklığı hesaplanır. Bu hesaplama işlemi Denklem 11 ile gösterildiği gibi yapılır ve Denklem 12’ye bağlı olarak tüm tilkiler yeniden konumlandırılırlar [5].

$$d((\bar{x}^i)^t, (\bar{x}^{\text{en iyi}})^t) = \sqrt{\|(\bar{x}^i)^t - (\bar{x}^{\text{en iyi}})^t\|} \quad (11)$$

$$(\bar{x}^i)^t = (\bar{x}^i)^t + \alpha \cdot \text{sign}((\bar{x}^{\text{en iyi}})^t - (\bar{x}^i)^t) \quad (12)$$

Burada $\alpha \in (0, d((\bar{x}^i)^t, (\bar{x}^{\text{en iyi}})^t))$ aralığında sürüdeki tüm tilkiler için rastgele atanan ölçeklendirme parametresidir. Denklem 12 ile hesaplanan yeni konum değerleri, bir önceki konum değerinin uygunluğu ile kıyaslanır. Elde edilen yeni konum değerinin uygunluğu, önceki konumuna göre daha iyi ise yeni konum korunur. Aksi halde tilki eski konumuna geri döner [5].

4.2. Lokal Habitattan Geçiş (Lokal Arama)

Kızıl tilki arama yaptığı bölgede bir av bulduğunda, kendisini ava fark ettirmeden yaklaşabildiği kadar yaklaşır ve avını dairesel olarak çevreler. Ava yeterince yaklaştığında ise ava saldırır. Bu yaklaşım sırasında tilkinin hareketini modellemek için μ parametresi, her iterasyonda tüm bireyler için 0 ile 1 arasında rastgele atanır [5].

$$\begin{cases} \text{Ava yaklaş} & \mu > 0,75 \\ \text{Konumunu koru ve saklan} & \mu \leq 0,75 \end{cases} \quad (13)$$


Denklem 13 ile belirtilen ilk koşula göre, μ katsayısının 0,75'ten büyük olması halinde tilkiler harekete geçmektedirler. Hareket sırasında tilkilerin gözlem yarıçapı iki parametre ile temsil edilmektedir; $a \in (0, 0,2)$ aralığında ölçeklendirme parametresidir ve tüm tilkiler için her iterasyonda rastgele atanarak güncellenmektedir. ϕ_0 ise $(0, 2\pi)$ aralığında, tilkilerin gözlem açısını belirlemek amacıyla algoritmanın başlangıcında bütün tilkiler için rastgele atanmaktadır. Burada tilkilerin hareketinin modellenmesinde değiştirilmiş Cochleoid denklemi kullanılmaktadır. Bu sayede dairesel bir harekete olanak sağlanmaktadır. Tilkinin görüş yarıçapı Denklem 14 ile belirtildiği gibi tanımlanır [5].

$$r = \begin{cases} a \frac{\sin(\phi_0)}{\phi_0} & \text{eğer } \phi_0 \neq 0 \\ \theta & \text{eğer } \phi_0 = 0 \end{cases} \quad (14)$$

Burada belirtilen θ değeri, sis, yağmur, kar gibi olumsuz hava koşullarını temsil etmektedir. Bu değer iterasyonun başında bir kere 0 ile 1 aralığında rastgele atanmaktadır. Tilkilerin arazi üzerindeki hareketleri Denklem 15 ile ifade edildiği gibi hesaplanmaktadır [5].

$$\begin{cases} x_0^{yeni} = ar \cdot \cos(\phi_1) + x_0^{gerçek} \\ x_1^{yeni} = ar \cdot \sin(\phi_1) + ar \cdot \cos(\phi_2) + x_1^{gerçek} \\ x_2^{yeni} = ar \cdot \sin(\phi_1) + ar \cdot \sin(\phi_2) + ar \cdot \cos(\phi_3) + x_2^{gerçek} \\ \dots \\ x_{n-2}^{yeni} = ar \cdot \sum_{k=1}^{n-2} \sin(\phi_k) + ar \cdot \cos(\phi_{n-1}) + x_{n-2}^{gerçek} \\ x_{n-1}^{yeni} = ar \cdot \sin(\phi_1) + ar \cdot \sin(\phi_2) + \dots + ar \cdot \sin(\phi_{n-1}) + x_{n-1}^{gerçek} \end{cases} \quad (15)$$

Burada $\phi_1, \phi_2, \dots, \phi_{n-1}$ değerleri $(0, 2\pi)$ aralığında her tilki için rastgele seçilir. Belirtilen bu hareket ile tilki, avını saptadıktan sonra yaklaşılabildiği kadar yakınına yaklaşır. Tilki, avını kendini fark etmesi durumunda başka bir av seçerek aynı şekilde yaklaşılmaya çalışır. Bu hareket tilkinin lokal arama safhası için modellenmiştir. Belirtilen yaklaşma hareketi Şekil 3 ile gösterilmiştir [5].



Şekil 3. (a) KTO global arama: Kızıl tilkinin avın etrafını çevrelemek ve avlanmaya başlamak için olası konumları. Habitat içerisinde geçiş sırasında, her tilki olası bir av arar ve ona doğru hareket eder. (b) KTO lokal arama: Kızıl tilkinin avlanma sırasında avını aldatmak için gerçekleştirdiği dönme hareketinin görseli. Tilki avına olabildiğince yaklaşmaya çalışır, ancak fark edilirse başka bir ava benzeri şekilde saldırı gerçekleştirir [5].

4.3. Sürüden Ayrılma ve Sürüye Katılma

Kızıl tilkiler doğada birçok tehlike ile karşı karşıya kalmaktadırlar. Lokal yaşama alanlarında yiyecek sıkıntısı çekmeleri sonucunda, yaşam alanlarını terk ederek farklı yeni alanlarda arama yapmak zorunda kalabilirler. Bu

durum tilkiler açısından tehlike arz etmektedir. Bir diğer tehlike ise insanların tilkileri avlamasıdır. Fakat doğada bu olaylar neticesinde zeki olan tilkiler bu olumsuz koşullardan etkilenmez ve arazi üzerinde yiyecek bulabilir, avcılardan kaçabilir veya kendilerine yeni bir sürü oluşturmak için zemin hazırlayabilirler [5].

Her iterasyon sonunda amaç fonksiyonundan aldığımız değerlere göre popülasyondaki en kötü bireylerin %5'i belirlenir. Belirlenen bu tilkilerin avcılar tarafından avlandığı veya sürüyü terk ettiği varsayılır. Popülasyondaki tilki sayısını sabit tutmak için alfa çifti tarafından oluşturulmuş yaşam alanı modeli kullanılarak sürüye yeni tilkiler eklenir. Bu işlem için her iterasyonda $(\bar{x}^{(1)})^t$ ve $(\bar{x}^{(2)})^t$ ile ifade edilen sürünün en iyi iki tilkisi olan alfa çifti seçilir. Seçilen alfa çifti kullanılarak Denklem 16 ile habitat merkezi hesaplanır [5].

$$(\text{habitat}^{\text{(merkez)}})^t = \frac{(\bar{x}^{(1)})^t + (\bar{x}^{(2)})^t}{2} \quad (16)$$

Daha sonra alfa çifti arasındaki öklid uzaklığının kare kökü hesaplanarak habitatın çapı Denklem 17 ile gösterildiği gibi hesaplanır [5].

$$(\text{habitat}^{\text{(cap)}})^t = \sqrt{\|(\bar{x}^{(1)})^t - (\bar{x}^{(2)})^t\|} \quad (17)$$


İterasyonların her birinde $(0,1)$ arasında rastgele atanan κ parametresine göre sürüye yeni katılacak olan tilkilerin katılım şekli belirlenir. Bu seçim Denklem 18 ile belirtildiği gibi yapılmaktadır [5].

$$\begin{cases} \text{Yeni göçebe tilkiler} & \text{eğer } \kappa \geq 0,45 \\ \text{Alfa çiftinin üremesi} & \text{eğer } \kappa < 0,45 \end{cases} \quad (18)$$

İlk durumda habitata seçilecek yeni tilkiler habitatın dışı ile arama uzayının sınırları arasında rastgele seçilir. İkinci durumda ise sürüye yeni katılacak olan tilkilerin alfa çiftinden meydana geldiği varsayılmaktadır. Bu koşul ile sürüye yeni eklenen tilkilerin konumu Denklem 19 ile ifade edildiği gibi hesaplanmaktadır [5].

$$(\bar{x}^{\text{(alfa çiftinden üreyen)}})^t = \kappa \frac{(\bar{x}^{(1)})^t + (\bar{x}^{(2)})^t}{2} \quad (19)$$

Kızıl tilki algoritmasına ait akış diyagramı Şekil 4 ile ifade edildiği gibidir.



Şekil 4. KTO algoritma akış şeması.

5. BULGULAR

Belirtilen yöntemler farklı iterasyon ve parçacık sayıları ile eşit koşullarda çalıştırılarak karşılaştırılmıştır. Yapılan karşılaştırma işleminde amaç fonksiyonu uygunluk değeri, sistemin çalışma süresi, yükselme zamanı ve yerleşme zamanı göz önünde bulundurulmuştur. Amaç fonksiyonu sırasıyla Denklem 20, 21 ve 22'de belirtilen hataların mutlak değerlerinin toplamı (HMT), hataların kareleri toplamı (HKT) ve zamanla ağırlıklandırılmış hataların kareleri toplamı (ZHKT) ifadelerinin ortalaması alınarak Denklem 23 ile ifade edildiği gibi kullanılmıştır.

$$HMT = \sum_{k=1}^q |e(k)| \quad (20)$$

$$HKT = \sum_{k=1}^q e^2(k) \quad (21)$$


$$ZHKT = \sum_{k=1}^q t. e^2(k) \quad (22)$$

$$\text{Amaç fonksiyonu} = \frac{HMT+HKT+ZHKT}{3} \quad (23)$$

Bu karşılaştırma kıstaslarından amaç fonksiyonu uygunluk değeri, yerleşme zamanı ve yükselme zamanı değerleri her iki algortmada da yakın değerler gelmekteyken, PSO algoritmasının çalışma süresinin KTO algoritmasına kıyasla daha kısa sürdüğü gözlemlenmiştir. Amaç fonksiyonu uygunluk değeri; tilki/parçacık sayısı ve iterasyon sayısına göre sırasıyla KTO ve PSO için Şekil 5 ile verilmiştir. Şekil 5'te görüldüğü gibi KTO algoritması için optimum değerler 50 tilki 10 iterasyon ile elde edilirken, PSO algoritmasında 10 parçacık 50 iterasyon ile elde edilmiştir. Sistemde yapılacak olan testler bu değerler ile gerçekleştirilmiştir. Optimum değerlere ilişkin K_p ve K_i değerleri Tablo 2 ile gösterilmiştir.


Tablo 2. Optimum K_p ve K_i değerleri.

	KTO	PSO
K_p	367,206	336,237
K_i	52,290	0,658




Şekil 5. Amaç fonksiyonu uygunluk değerlerinin karşılaştırılması.

Tüm koşullar her iki algoritmada da test edilerek optimum katsayılar bulunmuştur. Seçilen optimum değerlerin sistemdeki toleransını gözlemleyebilmek için bu değerler ile sistem farklı koşullarda test edilmiştir. Yapılan ilk çalışmada giriş gerilim değerine $\pm\%20$ değişim uygulanarak sonuçlar gözlemlenmiştir. Her üç karşılaştırmada da kayda değer bir fark gözlemlenmemiştir. Burada kullanılan yerleşme zamanı $\%2$ kriterine göre seçilmiştir. Giriş gerilimi 9, 10,8 ve 7,2 V değerlerinde iken elde edilen grafiksel sonuçlar sırasıyla Şekil 6, 7 ve 8 ile sunulmuştur. Ayrıca sonuçları daha detaylı sunabilmek için performans kriterleri tablolaştırılarak Tablo 3 ile sunulmuştur.




Şekil 6. Normal koşullar altında kontrolör performansları.



Şekil 7. Giriş gerilimi 10,8 V iken kontrolör performansları.


Bir diğer çalışmada çıkış gerilim referansı için $\pm\%20$ değişim uygulanarak kontrolör performansları test edilmiştir. Çıkış gerilim referansı 4 ve 6 V iken sonuçlar Şekil 9 ve 10 ile verilmiştir. Yine daha detaylı sonuçlar Tablo 4 ile sunulmuştur. Yapılan test için de elde edilen sonuçlar oldukça yakındır.




Şekil 8. Giriş gerilimi 7,2 V iken kontrolör performansları.

Tablo 3. Giriş gerilim değerinin $\pm\%20$ değişimi.

Giriş gerilimi	KTO			PSO		
	Uygunluk değeri	t_s (ms)	t_r (μ s)	Uygunluk değeri	t_s (ms)	t_r (μ s)
9 V	1,1181	1,054	94,729	1,1045	1,054	94,727
10,8 V	1,1924	0,859	84,990	1,6789	0,868	84,989
7,2 V	1,9416	1,059	109,907	1,9280	1,059	109,905



Şekil 9. Çıkış gerilimi referansı 4 V iken kontrolör performansları.




Şekil 10. Çıkış gerilimi referansı 6 V iken kontrolör performansları.


Tablo 4. Çıkış gerilim değerinin $\pm\%20$ değişimi.

Çıkış gerilimi	KTO			PSO		
	Uygunluk değeri	t_s (ms)	t_r (μ s)	Uygunluk değeri	t_s (ms)	t_r (μ s)
5 V	1,1181	1,054	94,729	1,1045	1,054	94,727
6 V	2,9770	1,219	106,699	2,5080	1,219	107,296
4 V	0,7181	0,941	82,915	0,7949	0,940	82,913

Yapılan son çalışmada ise giriş gerilimi ve çıkış gerilimi referansı sabit iken yük direncinin $\pm\%20$ değişimi için kontrolör performansı incelenmiştir. Sonuçlar Şekil 11, 12 ve Tablo 5 ile sunulmuştur.



Şekil 11. Yük direnci 8 Ω iken kontrolör performansları.

Şekil 12. Yük direnci 12 Ω iken kontrolör performansları.Tablo 5. Yük direnci değerinin $\pm\%20$ değişimi.

Yük direnci	KTO			PSO		
	Uygunluk değeri	t_s (ms)	t_r (μ s)	Uygunluk değeri	t_s (ms)	t_r (μ s)
10 Ω	1,1181	1,054	94,729	1,1045	1,054	94,727
12 Ω	0,8411	0,857	92,945	0,8297	0,945	92,944
8 Ω	1,9633	0,979	97,858	1,7231	0,979	97,856

6. SONUÇ

DA-DA alçaltıcı tip dönüştürücü birçok elektronik cihazda bulunmakta olup kararlı bir çıkış gerilimi, bulunduğu sistemin düzgün ve kararlı çalışması için oldukça önemlidir. Bu amaçla kontrolörün önemi artmaktadır. Bu çalışma kapsamında BC için optimum kontrolör katsayılarının elde edilmesi amacıyla literatüre yeni kazandırılan KTO yöntemi kullanılmıştır. Bu amaçla daha önce hiç kullanılmamış olan KTO yönteminin literatüre kazandırılabilmesi ve yeni çalışmalara ışık tutacağı düşünülmektedir. Önerilen yöntem ile kontrolör performansı; giriş geriliminde, yük direncinde ve çıkış gerilim referansında meydana gelebilecek değişikliklere karşı test edilmiştir. Ayrıca elde edilen sonuçlar literatürde en yaygın kullanılan meta-sezgisel yöntemlerden birisi olan PSO yöntemi ile karşılaştırılmıştır. Yapılmak istenen minimizasyon işleminin sonucunda PSO ve KTO algoritmalarının birbirine yakın performans sergilediği gözlemlenmiştir. MATLAB/Simulink ortamında gerçekleştirilen simülasyon işlemlerinin sonucunda PSO algoritması çalışma süresi bakımından KTO algoritmasına göre yaklaşık iki kat daha iyi bir performans sergilemiş ve uygunluk değerini 1,1045 bularak sistemin daha kararlı bir çıkış geriliminin olmasını sağlamıştır.

Yazar Katkıları

Bütün yazarlar eşit oranda katkı sağlamıştır.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması yoktur.

KAYNAKÇA

- [1] Y. Atalan Ayaz, "Ambulance Service for Hospital Selection: Optimization with Discrete-Event Simulation Application for Yozgat Province Of Turkey", Mühendislik Bilim. ve Araştırmaları Derg., vol. 3, no. 1, pp. 112–122, 2021.
- [2] G. Mühürücü, A. Mühürücü, E. Köse, and A. Kuyumcu, "Parameter Optimization of PI Controller by PSO for Optimal Controlling of A Buck Converter's Output", in 2017 International Artificial Intelligence and Data Processing Symposium (IDAP), pp. 1–6, 2017.

- [3] M. Y. Özsağlam ve M. Çunkaş, "Optimizasyon Problemlerinin Çözümü için Parçacık Sürü Optimizasyonu Algoritması", J. Polytech., vol. 11, no. 4, pp. 299–305, 2008.
- [4] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey Wolf Optimizer", Adv. Eng. Softw., vol. 69, pp. 46–61, 2014.
- [5] D. Połap and M. Woźniak, "Red fox optimization algorithm", Expert Syst. Appl., vol. 166, no. 114107, 2021.
- [6] E. K. Yaylacı, A. E. Yılmaz, ve H. N. Özdeş, "Geliştirilmiş Parçacık Sürü Optimizasyon Algoritması ile Da-Da Alçaltıcı Tip Dönüştürücünün PI Katsayılarının Optimizasyonu," in 2nd International Conference on Applied Engineering and Natural Sciences, pp. 257–261, 2022.
- [7] Z. Fu, J. An, Q. Yang, H. Yuan, Y. Sun, and H. Ebrahimian, "Skin cancer detection using Kernel Fuzzy C-means and Developed Red Fox Optimization algorithm," Biomed. Signal Process. Control, vol. 71, no. 103160, 2022.
- [8] Z. Huo, S. J. Liu, and H. Ebrahimian, "Aircraft Energy Management System Using Chaos Red Fox Optimization Algorithm," J. Electr. Eng. Technol., vol. 17, no. 1, pp. 179–195, 2022.
- [9] M. Zhang, Z. Xu, X. Lu, Y. Liu, Q. Xiao, and B. Taheri, "An Optimal Model Identification for Solid Oxide Fuel Cell Based on Extreme Learning Machines Optimized by Improved Red Fox Optimization Algorithm," Int. J. Hydrogen Energy, vol. 46, no. 55, pp. 28270–28281, 2021.
- [10] N. Zhu, X. Liu, Q. Dong, and D. Rodriguez, "Optimization of zero-energy building by multi-criteria optimization method: A case study," J. Build. Eng., vol. 44, no. 102969, pp. 1–13, 2021.
- [11] D. Yousri et al., "Modified Interactive Algorithm Based on Runge Kutta Optimizer for Photovoltaic Modeling: Justification Under Partial Shading and Varied Temperature Conditions," IEEE Access, vol. 10, pp. 20793–20815, 2022.
- [12] R. Luo and M. Shafiee, "The Application of Metaheuristics in Optimal Parameter Identification of Solid Oxide Fuel Cell," Energy Reports, vol. 7, pp. 2563–2573, 2021.
- [13] D. Połap and M. Woźniak, "Meta-Heuristic as Manager in Federated Learning Approaches for Image Processing Purposes," Appl. Soft Comput., vol. 113, no. 107872, 2021.
- [14] A. Mamizadeh, N. Genc, and R. Rajabioun, "Optimal Tuning of PI Controller for Boost DC-DC Converters Based on Cuckoo Optimization Algorithm," in 2018 7th International Conference on Renewable Energy Research and Applications (ICRERA), pp. 677–680, 2018.
- [15] S. Vadi, F. Batincan Gurbuz, R. Bayindir, and S. Sagiroglu, "Optimization of PI Based Buck-Boost Converter by Particle Swarm Optimization Algorithm," in 2021 9th International Conference on Smart Grid (icSmartGrid), pp. 295–301, 2021.
- [16] E. Köse, G. Mühürçü, A. Mühürçü, and B. Sevim, "SFLA Based PI Parameter Optimization for Optimal Controlling of A Buck Converter's Voltage," in 2017 International Artificial Intelligence and Data Processing Symposium (IDAP), pp. 1–5, 2017.
- [17] O. Kapukaya, "Adaptif Parçacık Sürü Optimizasyonu ve Karınca Kolonisi Algoritması Kullanarak Öz Ayarlamalı PID Denetleyici Tasarımı," Fen Bilimleri Enstitüsü, Kahramanmaraş, 2019.
- [18] H. Gözde, M. C. Taplamacıoğlu, İlhan Kocaarslan, ve M. A. Şenol, "İki Bölge Ara-Isıtmalı Termal Güç Sisteminin Yük-Frekans Kontrolü için Parçacık Sürüsü Optimizasyonu Tabanlı PI-Kontrolör," Isı Bilim. ve Tek. Derg., vol. 30, no. 1, pp. 13–21, 2010.
- [19] O. T. Altınöz and H. Erdem, "Evaluation Function Comparison of Particle Swarm Optimization for Buck Converter," in International Symposium on Power Electronics, Electrical Drives, Automation and Motion, pp. 798–802, 2010.
- [20] H. Aygun and H. Demirel, "Comparison of PSO-PID, FLC and PID in A Circulating Fluidized Bed Boiler," in 7th International Conference on Electrical and Electronics Engineering, pp. 355–359, 2011.
- [21] H. Aygün, "Akışkan Yataklı Buhar Kazanının Yatak Sıcaklığının Parçacık Sürüsü Optimizasyonu Tabanlı PID Kontrolör (PSO-PID) le Kontrolü," Fen Bilimleri Enstitüsü, Karabük, 2011.



Derin Öğrenme Metodu ve Ayrık Dalgacık Dönüşümü Kullanarak BT Görüntülerinden Akciğer Kanseri Teşhisi

Discrete Wavelet Transform and Deep Learning Model for Diagnosis of Lung Cancer from CT Images

¹Mehmet Akif ÇİFÇİ 

¹Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bandırma/Balıkesir, Türkiye

mcifci@bandirma.edu.tr

[Araştırma Makalesi/Research Article](#)

ARTICLE INFO

Article history

Received : 9 May 2022

Accepted : 6 July 2022

Keywords:

Computed Tomography, Deep Learning, VGG, CNN, Lung Cancer

ABSTRACT

Recently, researchers have placed the greatest emphasis on using Deep Learning (DL) approaches for early cancer detection. In this study, A Computed Tomography (CT) scan was used to find the position of the tumor and identify the level of cancer in the body. The 6053 lung tomography dataset was processed using the Discrete Wavelet Transform (DWT) technique in conjunction with the DL approach (data source, age group, geographical region, and sensitive data were excluded). The diagnosis and prognosis of a cancer type at an early stage have become necessary in cancer research since they simplify the following clinical care of patients. Targeted was the significance of categorizing cancer patients as benign or malignant. Using computed tomography (CT) images and image preparation procedures, DWT is used to extract features. The gathered data served as input data for processing by the created architectures. Utilizing DWT, ResNet152V2, MobileNet, VGG-16, and Inception v4 have been optimized for early lung cancer detection. Comparative findings revealed that the ResNet152V2 model presented by DWT had 91.89 percent sensitivity, 94.16 percent specificity, and 97.5 percent accuracy.

© 2022 Bandırma Onyediy Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 9 Mayıs 2022

Kabul : 6 Temmuz 2022

Anahtar Kelimeler:

Bilgisayarlı Tomografi, Derin Öğrenme, VGG, CNN, Akciğer Kanseri


ÖZET

Derin Öğrenmenin (DÖ) teknikleriyle erken kanser tanısı son dönemlerde araştırmacılar arasında en çok üzerinde durulan konu olmuştur. Bu çalışmada Ayrık Dalgacık Dönüşümü (ADD) yaklaşımı ile DÖ tekniği birleştirilerek, 6053 akciğer tomografi veri seti (veri kaynağı, yaş grubu, coğrafi bölge vb. kısa bilgi) üzerinde işlem yapılmıştır. Hastanın kanser olup olmadığı, kanser olduğu takdirde ise bunun iyi huylu (benign) ya da kötü huylu (malign) olduğuna karar verilmesine çalışılmaktadır. Bilgisayarlı Tomografi (BT), görüntülerde öncelikle görüntü işleme aşamalarının yanı sıra ADD ile öznelik çıkarımı yapıp elde edilen veriler DÖ 'ya girdi verisi olarak kullanılır. ResNet152V2, MobileNet, VGG-16 ve Inception v4, BT görüntülerine uygulandıktan sonra akciğer kanseri erken tanısı için ADD kullanılarak optimize edilmiştir. Karşılaştırmalı sonuçlar, ADD ile önerilen ResNet152V2 modelinin %91,89 duyarlılık, %94,16 özgüllük ve %97,52 doğrulukta sonuç verdiği belirlenmiştir.

© 2022 Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Akciğer kanseri, dünya çapında en ölümcül kanser türü olarak kabul edilmektedir. Bu nedenle birçok ülke akciğer kanserinin erken teşhisi için stratejiler geliştirmektedir. Düşük doz Bilgisayarlı Tomografi (BT) kullanan yüksek riskli deneklerin üç yıllık tarama sonucunda, ölüm oranlarının önemli ölçüde azaldığı görülmektedir [1]. Birçok tıbbi görüntüleme tekniği; anjiyografi, ultrasonografi, nükleer görüntüleme ve manyetik rezonans görüntüleme (MRI) gibi tıbbi tanı yöntemleriyle elde edilen görüntüleri iyileştiren kontrast maddeleri içermektedir [2]. Elde edilen bu BT görüntüleri uzman radyologlarca işaretlenmiş ve teyit edilmiştir. Nodülleri tespit etmek uzmanlar için bile çok zor olduğundan, analiz edilecek BT taramalarının sayısı ile radyologların üzerindeki yük büyük ölçüde artmaktadır [3,4]. Önleyici/erken tespit tedbirlerinin sayısında beklenen artışla birlikte bilim insanları; doktorların işini hafifletmeye, öznellik faktörünü azaltarak teşhisin kesinliğini artırmaya, analizi hızlandırmaya ve tıbbi maliyetleri düşürmeye yardımcı olan bilgisayarlı çözümler üzerinde çalışmaktadırlar [5, 6]. BT taraması ile erken tanı, akciğer kanseri ölümlerini azaltabilir ancak bu taramaların maliyeti yüksektir. Bunun yanı sıra, düşük ve orta gelirli ülkeler için durum daha risklidir ve hekimlerin fikir ayrılıklarından dolayı vakalar yanlış teşhisle sonuçlanabilmektedir [6]. MRI sonuçları, morfoloji ve güçlendirme kinetiğinin bir kombinasyonu kullanılarak BIRADS sınıflandırmasına benzer bir modelde puanlanmaktadır [7]. Başka bir çalışma ise kurumsal inceleme kurulu onayının ardından Akdeniz Üniversitesi Radyoloji Anabilim Dalı'nda gerçekleştirilmiştir. Toplamda, 15 lezyonu olan 12 hasta, radyolojik sonuçlara göre çalışmaya dâhil edilmiştir [1, 7]. Genel olarak, yeniden oluşturulmuş görüntülerdeki gürültüyü azaltmak için üç boyutlu filtreleme yöntemleri önerilmektedir. Filtreleme; görüntü yumuşatma, keskinleştirme, kenar algılama, iyileştirme gerçekleştiren bir görüntü işleme prosedürüdür [8]. Malignite nodülleri saptamak için belirli özelliklerin tanınması ve ölçülmesi gerekmektedir. Tespit edilen özelliklere ve bunların kombinasyonuna dayanarak kanser olasılığı değerlendirilebilmektedir [9]. Bununla birlikte, nodül varlığı ile pozitif kanser teşhisi kolayca ilişkilendirilemediğinden, bu teşhis deneyimli bir tıp doktoru için bile kolay değildir. Yaygın bilgisayar destekli tanı yaklaşımları; diğerleri arasında hacim, şekil, incelik, sağlamlık, spekülasyon ve küresellik gibi kanser şüphesiyle ilgili daha önce çalışılmış özellikleri kullanmaktadır [10]. Nodülü iyi huylu veya kötü huylu olarak sınıflandırmak için bu özellikleri ve “Destek Vektör Makinesi” gibi Makine Öğrenimi (MÖ) tekniklerini kullanılmaktadır. Birçok çalışmada MÖ ile tahmin edilen akciğer kanserinin, çoğu araştırmada yanlış pozitif oranı yüksek çıkmıştır. Bunun asıl nedeni ilgi alanlarının el ile bulunmasıdır. Son teknolojik sonuçlar, bu yaklaşımları farklı BT taramaları ve farklı tarama parametreleri arasındaki değişkenliğe karşı savunmasız hâle getirir. Bilgisayar Destekli Tanı (BDT) sistemlerinde derin öğrenme kullanmanın avantajı, algoritmanın/ağın eğitim sırasında en göze çarpan özellikleri öğrenerek uçtan uca algılama gerçekleştirebilmesidir. Bu, değişen parametrelerle çeşitli BT taramalarında nodüllerin özelliklerini yakaladığı için ağın varyasyonlara karşı dayanıklı olmasını sağlar. Değişkenlik açısından zengin bir eğitim setine sahip olarak sistem, doğası gereği malignite nodüllerden değişmez özellikleri öğrenebilir ve daha iyi performanslar sağlar. Hiçbir özellik tasarlanmadığı için ağ, sağlanan temel gerçeği kullanarak özellikleri ve kanser arasındaki ilişkiyi kendi kendine öğrenebilir. Ağ eğitildikten sonra, sistem tarafından daha önce hiç görülmemiş yeni vakalarda öğrenmesini genelleştirebilmesi ve malignite nodülleri tespit/teşhis etmesi beklenmektedir. Bu çalışmada, akciğer kanseri tespiti için yeni derin öğrenme tekniklerinin bir incelemesi sunulmaktadır. Önerilen çalışmaların çoğu, derin Evrişimli Sinir Ağlarına (ESA) dayanmaktadır. ESA, eğitim sırasında bir dizi mevcut veriden evrişim parametrelerini öğrenmek için tasarlanmış bir sinir ağı sınıfıdır. Genel olarak evrişim katmanları; filtreler havuzlama katmanları gibi farklı katmanlardan oluşur. Şekil 1’de a. akciğer kanseri nodülü görüntüsü, b. gri tonlamalı yapı, c. ise gri tonlamalı nodül görüntüsü gösterilmektedir.



Şekil 1. a) akciğer kanseri nodülü görüntüsü, b) gri tonlamalı yapı, c) ise gri tonlamalı nodül görüntüsü.

Akciğer kanserinin nedenleri ve belirlenmesi: Akciğer kanserinin tespiti genel olarak zordur çünkü uzmanlar enfekte olmuş bölgeyi ilerleyen aşamaya geçinceye kadar bulamazlar. Kanser saptandıktan sonra hastanın hayatta kalma şansı akciğer kanseri için %54 civarındadır [13]. Çalışmanın katkısı iki yönlüdür. İlk olarak, DÖ yöntemlerinin akciğer kanseri sınıflandırması için küçük veri kümeleri üzerinde mevcut çalışmalardan daha iyi

performans gösterebileceği ilk kez ortaya konmuştur. İkinci olarak, akciğer kanseri sınıflandırması için diğer yöntemlerden daha iyi performans gösteren ve ayrıca performans iyileştirmesinin istatistiksel olarak anlamlı olduğunu gösteren ADD ile ResNet152V2 ağı mimarisi önerilmektedir.

Bu makalenin ikinci bölümünde, benzer araştırmalardan örnekler verilerek bu yayın ile bulguların karşılaştırılmasına yer verilecektir. Bölüm 3'te akciğer kanserinin tespit edilmesinde göz önünde bulundurulmuş yöntemler değerlendirilecektir. Bölüm 4'te, önerilen modelle ilgili uygulama üzerinde durulacaktır. Bu bölümü tartışma ve deneysel bulgular izleyecektir. Bölüm 5'te spesifik sonuçlar ortaya konacaktır. Şekil 1'de akciğer kanseri nodülü görüntüsü gösterilmektedir.

2. LİTERATÜR TARAMASI

Literatürde yer alan pek çok araştırma ve metodolojiler çerçevesinde değerlendirildiğinde, kanser hastalığına ilişkin araştırmalarda yaygın olarak karşılaşılan "yanlış sonuçlar" dikkat çekmektedir. Bu nedenle, teknolojik imkânlar sayesinde daha hızlı ve daha doğru sonuçlara ulaşmayı kolaylaştıran ve insan kaynaklı hataların en aza indirgenmesine katkı sağlayan teknolojik yöntemlerin geliştirilmesi oldukça önemlidir. Çalışmanın bu bölümünde, söz konusu önemden hareketle akciğer kanserini tanımlama yöntem ve prosedürleri, DÖ algoritmaları ile ilişkili çeşitli görüşler ve BT görüntülerinin işleme evreleri ele alınmaktadır.

Akciğer nodüllerinin tespit edilebilmesi amacıyla otomatik veya yarı otomatik sistemlerin geliştirilmesine yönelik olarak literatüre katkı sağlayan çok sayıda araştırma yapılmış olmakla birlikte hâlen de yapılmaya devam etmektedir. Bunun yanı sıra, yapılan çalışmalar sayesinde akciğer kanserinin tespit edilmesine yönelik olarak pek çok farklı algoritma geliştirilmiştir. Söz konusu algoritmalarından bazılarına aşağıda değinilmiştir:

DÖ tekniği kullanılarak akciğer nodülünün sınıflandırılabilmesi için BT görüntü verilerini şekil ve doku açısından ele alan bir algoritmayı öneren bazı çalışmalar bulunmaktadır [14]. Önerilen bu algoritmada, nodüllerin heterojenliğini betimlemek için bir "Fourier-Şekil Tanımlayıcı" ile bir "Gri Seviye Eş Oluşum Matrisleri" tabanlı yüzey tanımlayıcıdan ve düğümlerin özelliklerini eğitmek için Evrişimli Sinir Ağlarından (ESA) yararlanılmıştır. Diğer bir çalışma ise geleneksel BDT teknikleri üzerine odaklanmış olan ve manuel olarak tasarlanan sistem, akciğer kanseri erken teşhisi için ideal görünmemektedir [15]. Bazı bilim insanları tarafından akciğer kanserinin tanısı için sınıflandırıcı olarak Destek Vektör Makinelerinden (DVM) yararlanılarak çalışmalarda epidemiyoloji materyal, klinik semptomlar ve miRNA (mikroRNA) biyobelirteçlerin esas alınmasıyla bir DVM modeli geliştirilmiştir [16].

Son yıllarda, örüntü tanıma ve görüntü işleme tekniklerinde hızlı ilerleme kaydedilmiştir. Akciğer kanseri tespit sınıflandırması hakkında yapılan çalışmalar her geçen gün artmaktadır. İnce kesitli BT görüntülerinin doku analizi temelinde çeşitli obstrüktif akciğer hastalıklarını ayırt etmek için literatürde bazı yöntemler bulunmaktadır [12]. Chen vd., [16] BT ile saptanan ve değerlendirilen Soliter Pulmoner Nodüllerin doku özelliklerini sunmuşlardır. Çalışmada toplamda 67 öznitelik çıkarılmış ve 300 genetik nesilden sonra yaklaşık 25 öznitelik seçilmiştir. Bera vd., [17] sınıflandırıcı olarak Destek Vektör Makinelerinden (DVM) yararlanmışlardır. Çalışmalarında mikroRNA biyobelirteçleri, klinik semptomlar ve epidemiyoloji materyali temel alınarak akciğer kanseri tanısı için bir DVM modeli oluşturmuşlardır. Önerilen model ile %90,1'lik bir doğruluk oranına ulaşmış oldukları anlaşılmaktadır. Sharma vd., [18] lineer bir yöntem üzerine odaklanmışlardır. Düzenleme parametresinin geleneksel çapraz doğrulama algoritmasının hesaplandığı "doğrusal ayırıcı analiz" tekniğinden yararlanmışlardır. Hastalığın gereksinim tahmini için tıbbi verileri araştırmaya uygun özellik kümesine ihtiyaç duyulmuştur. Optimum özellik seçimini elde etmek için birçok evrimsel algoritma uygulanmıştır. Kuruvilla vd. [19] tarafından BT görüntüleri için Yapay Sinir Ağları (YSA) temelli bir kanser sınıflandırması geliştirilmiştir. Sınıflandırma modeli için kullanılan istatistik kısmi olarak başarı sağlamıştır. Aleesa vd., [20] akciğer kanserini teşhisi için Taksonomik Farklılık İndeksleri ve DVM tekniğinden yararlanmaktadırlar. Elde ettikleri başarı oranı %98,11 olarak açıklanmıştır. Aggarwal, Furquan ve Kalra [21] normal akciğer anatomi yapısını sınıflandıran bir model önermişlerdir. BT görüntü özelliklerini geometrik, istatistiksel ve gri seviye karakteristikleri kullanarak çıkarmışlardır. Sonuç olarak doğruluk başarı oranı %84 ve duyarlılık ise %97,14 olarak ölçülmüştür. Song vd. [22], DNN'nin dalgacık dönüşümü ve temel bileşen analizi ile birleştirildiği beyin tümörü sınıflandırması için DNN sınıflandırıcısı ile çalışmıştır. Buna göre benzer pikseller küme olarak oluşturulmakta ve etkilenen bölgede oluşan kümeden yararlanılmaktadır.

Sonuç olarak %84,6 doğruluk, %82,5 duyarlılık ve %86,7 özgüllük bildirmişlerdir. Hosny, vd., [33] derin öğrenme tekniği olan Otomatik Kodlayıcı kullanarak %75,01 doğruluk oranına sahip bir yöntem sunmuştur. Dey vd., [34] ise derin inanç ağını kullanarak %73,40 hassasiyet oranına ve %82,20'lik özel orana ulaşmıştır. Li vd., [35] LIDC veri tabanında akciğer kanserini çok ölçekli, iki katmanlı ESA üzerine çalışmıştır. Elde edilen doğruluk oranı %86,84 olarak kaydedilmiştir.

Çalışmanın bu bölümünde değinilen araştırmalar, öne çıkan bir model, genomik ve klinik gibi karışık bilgi kombinasyonlarını içermektedir. Değinilen bu araştırmalarda görülen tipik bir eksiklik olarak modellerin önceden oluşturulmasına yönelik bir dış onay mekanizması ya da testin olmayışı söylenebilir. Dolayısıyla, söz konusu eksiklikten hareketle ve DÖ stratejilerinin kullanılmasıyla hastalığın zayıflaması, tekrarlaması ve hastanın hayatta kalması hususlarında yapılan tahminlerin kesinlik yüzdelerinin artırılabilmesi mümkündür. Aynı şekilde, son zamanlarda DÖ stratejileri esas alınarak gerçekleştirilen tümör araştırmalarında %15-20 oranları arasında bir artış görülmüştür. Son zamanlarda akciğer kanseri teşhisinde BDT yerini daha gelişmiş DÖ tekniklerine bırakmıştır

3. VERİ VE YÖNTEM

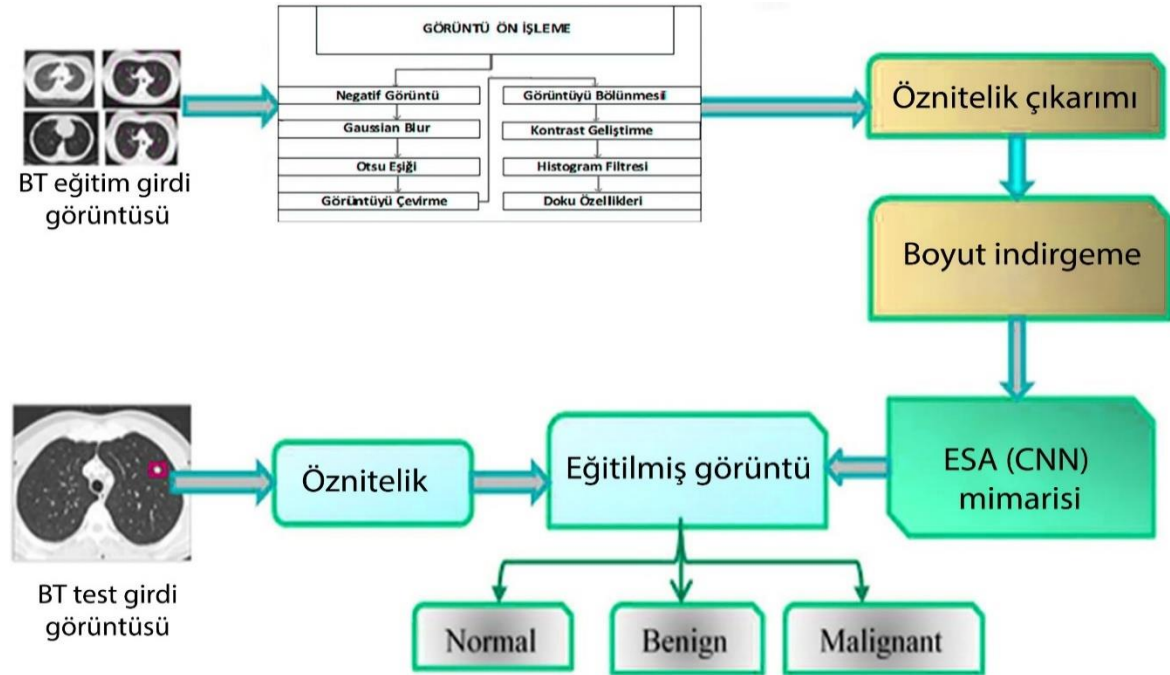
3.1. Yöntem ve Teknikler

İnsan vücudunda akciğer kanseri gibi insanın akciğer sistemine saldırabilecek birçok hastalık vardır. Bu hastalıkları teşhis etmek amacıyla, kritik ve önemli bir rol oynadıkları için BT veya X-ray gibi görüntüleme cihazlarına ihtiyaç duyulmaktadır [36]. Bilgisayar teknolojileri, DÖ tabanlı sistemler gibi hastalık tanılarına yardımcı olacak araçlar sunmaktadır. Bu çalışmada, akciğer kanseri erken tanısı için çok sınıflı bir derin öğrenme modeli geliştirilmiştir [37]. Çalışmadaki amaç, dört farklı model kullanarak göğüs hastalıkları sınıflandırması için bir derin öğrenme modeli önermektir [38]. Bu çalışma, akciğer kanseri hastalıklarının tespiti için tek bir DÖ modelini tanıtmaya yönelik ilk yaklaşım olarak kabul edilebilir. Geliştirilen mimari, Şekil 2'de gösterilmektedir. Şekilden açıkça görüldüğü gibi, model üç ana aşamadan oluşmaktadır: veri ön işleme, özellik çıkarımı için DÖ modelleri ve sınıflandırma. Önerilen model, girdi olarak BT'den alınan göğüs görüntülerini kullanmaktadır. Nihai çıktı, girdi görüntüsünün 3 sınıftan birine sınıflandırılmasıdır: normal, pnömoni ve akciğer kanseri.

Mimaride ilk aşama, yeniden boyutlandırma, görüntü büyütme ve veri gibi görüntü ön işlemeyi gerçekleştirmek ve rastgele iki gruba ayırmaktır: Veri setinin yaklaşık %70'i eğitim için, geri kalan %30 doğrulama için kullanılmıştır. Veri seti görüntüleri, görüntülerin çeşitliliğini sağlamak için rastgele iki bölüme (eğitim ve doğrulama) ayrılmaktadır. Görüntünün piksel değerini [0,1] aralığına yeniden ölçeklendirmek için görüntüyü bir dizi piksele dönüştürdükten sonra veri normalleştirme de kullanılmaktadır. İkinci ve üçüncü aşamalar ise farklı türde DÖ yaklaşımları kullanılarak sırasıyla özellik çıkarma ve görüntü sınıflandırma olarak sıralanabilir. Önerilen model için giriş görüntüleri $224 \times 224 \times 3$ olarak yeniden boyutlandırılmıştır. Sistem için verimli ve güvenilir doğruluk üretmek amacıyla eğitim görüntülerinin sayısını artırmak için görüntü büyütme yöntemleri kullanılmaktadır.

Bu mimari, ReLU etkinleştirme işlevselliğini kullanan bir evrişim katmanı içermektedir. Evrişimden sonra maksimum havuzlama gerçekleştirilmektedir. Softmax katmanı, bu mimaride tamamen bağlı birkaç sinir ağı katmanıyla sınıflandırılmak için kullanılmaktadır.

Boyut indirgemenin amacı sınıflandırma yönteminde hesaplama süresini ve maliyetini düşürmektir. Boyut indirgeme için Doğrusal Ayırım Analizinden faydalanılmaktadır [39]. Sınıflandırma için kullanılan maksimum özellikler, hesaplama süresini ve depolama belleğini artırmaktadır. Sınıflandırma aşamasında BT akciğer görüntüleri, özelliklere göre normal, iyi huylu ve kötü huylu olarak sınıflandırılmaktadır. Genel olarak, sınıflandırma sorununun eğitim ve test olmak üzere iki aşaması bulunmaktadır; sınıflandırıcı, eğitim verilerinin seçilen özellikleri ile eğitilmektedir. Diğer yandan test aşamasında, sınıflandırma prosedürünün sonuçları, görüntülerin akciğer kanseri bölgelerini mi yoksa kanser dışı bölgeleri mi içerdiğini göstermektedir. Mevcut çalışma mimarisi Şekil 2'de görülmektedir.




Şekil 2. Derin öğrenme mimarisi.

DÖ mimarisi içerisinde dalgacık katsayıları ESA'ya girdi olarak kullanılmıştır [40]. Görüntülerde şüphelenilen lezyonlar için İlgi Alanı (region of interest) sağlanmamıştır. Yani önerilen ağ için girdiler, tüm görüntünün dalgacık katsayılarıdır. Tekrar eğitimden sonra BT görüntüleri; önerilen ağ kullanılarak normal, iyi, kötü diye üç kategoriye ayrılmıştır.

Görüntü Veri Seti

Bu çalışmada kullanılan veri kümeleri, herhangi bir MÖ veya derin öğrenme yaklaşımının önemli bir parçasıdır. Uzmanlarca onaylanmış veriler; algoritmaların geliştirilmesine, eğitilmesine ve iyileştirilmesine yardımcı olur. Tıbbi görüntüleme uygulamalarında, mevcut veriler, herhangi bir geliştirmede faydalı olması için uzmanlar tarafından doğrulanmalı ve etiketlenmelidir. Bu bölüm, akciğer kanseri tespiti için Derin Öğrenme ile ilgili son çalışmalarda kullanılan veri kümelerini sunmaktadır.


Akciğer Görüntü Veri Tabanı Konsorsiyumu (LIDC-IDRI): Veri seti yedi akademik merkez ve sekiz tıbbi görüntüleme merkezinin iş birliğiyle toplanan 1018 vakadan oluşmaktadır. Her vaka, BT taramasının açıklamalarını içeren bir XML dosyası içerir. Bu açıklamalar dört deneyimli uzman tarafından 2 aşamalı bir süreçte gerçekleştirilir. İlk aşamada, her radyolog bulguları bağımsız olarak üç kategoriye ayırır. Daha sonra ikinci aşamada her radyolog kendi sınıflandırmasını ve diğer radyologlar tarafından anonim olarak yapılan sınıflandırmaları gözden geçirir. Böylece her nodül, dört radyolog tarafından bağımsız olarak gözden geçirilir. Veri seti, toplam 244.527 görüntü ile 1010 hastadan alınan 1018 BT taramasından oluşmaktadır. Bu veri seti ile tanı iki düzeyde yapılabilir. Hasta düzeyinde tanı ve nodül düzeyinde tanı. BT tarama DICOM görüntüleri, genişliğin 65 ile 764 dilim arasında değiştiği 512 x 512 x 3 genişlik çözünürlüğüne sahiptir. Bu veri seti için ortalama dilim genişliği sayısı 240'tır.



Şekil 3. Farklı lezyon örnekleri. a) üst sıra kötü huylu, b) alt sıra iyi huylu lezyonlar.


BT görüntülerindeki zayıflıkları, kör bölgeleri düzeltmek için Gauss filtreleri kullanılmaktadır. Yani BT görüntülerinin tüm gürültüsünü azaltmak amacıyla her BT görüntüsünde Gauss bulanıklığı uygulanır (bkz. Şekil 5). Bu işlemi yaptıktan sonra, BT görüntüleri aynı özelliğe sahip olmaktadır. Şekil 5'te BT görüntülerine Gauss bulanıklığı uygulaması gösterilmektedir.

Negatif görüntü: BT görüntüleri gri skala değerindeki görüntülerdir. 3 boyutlu görüntüler makine gücü düşük olduğundan gri tonlamalı görüntüye çevrilmektedir. Böylece her pikselin 8 bit (0- 255) aralığına inmektedir. Herhangi bir zamanda gri görüntülerde görüntülenebilecek maksimum renk sayısı 256 aralığındadır. Akciğer BT görüntüleri karakteristik olarak net değildir. Bu nedenle görüntü işlemede daha iyi performans elde etmek için gri tonlamalı görüntüyü negatif görüntüye çevirmek gerekir. Şekil 4'te BT görüntüsünün negatifi gösterilmektedir.



Şekil 4. BT görüntüsünün negatifi.


Bulanıklaştırma (Blurring) filtresi; BT görüntülerini etkilediğinde, görüntüdeki küçük bileşenlerin görselleştirilmesini ve görünürliğini azaltmaktadır. Bu nedenle, görüntünün bozulmamış şeklini bozuk sürümünden geri kazanmak ve görüntüye daha keskin bir görünüm vermek için Gauss bulanıklığı analizi uygulamak gerekmektedir [42].



Şekil 5. BT görüntülerine Gauss bulanıklığı uygulaması.

$$a_{\omega}^2(t) = q_1(t)a_1^2(t) + q_2(t)a_2^2(t) \quad (1)$$

Denklemden (1) görüldüğü üzere $P(i)$, her piksel değerinin olasılığıdır. Eşik, görüntüleri bir görüntünün daha basit bir formuna ve akciğer nodülünün algılanmasına dönüştürür. Şekil 6'da BT görüntüsüne uygulanan Otsu eşiği gösterilmektedir.




Şekil 6. a) akciğer BT görüntüsü, b) Otsu eşiği uygulanmış BT görüntüsü.

Görüntünün Bölünmesi: İnsan akciğeri simetrik bir yapıya sahiptir. Başlangıç noktasının merkezi seçilir ve bu nokta yardımıyla sağ ve sol akciğer görüntüsü bölünür. Görüntü o noktada kırılır ve sol ve sağ görüntüyü iki belirli görüntüye dönüştürür. Daha iyi sonuç elde etmek için akciğer BT görüntüleri ikiye bölünmüştür. Şekil 7'de BT görüntüsünün bölünmesi gösterilmektedir.




Şekil 7. Akciğer BT Görüntüsünün bölünmesi.

Görüntünün Çevrilmesi: BT görüntüleri bölündükten sonra görüntü daha iyi anlamak adına sağ ve sol olarak çevrilmektedir. Burada x sütun sayısını ve y satır sayısını temsil eder. Şekil 8’de BT görüntüsünün çevrilmesi gösterilmektedir.



Şekil 8. Görüntünün çevrilmesi.

Histogram Özellikleri: Histogram özelliklerinde görüntü, piksel cinsinden gösterilmektedir. Histogram, görüntüdeki her güç değerindeki piksel sayısını göstermektedir. Görüntü histogramının güç değerlerine dönüştürülmesi yaklaşık olarak önceden belirlenmiş bir histogramla eşleştirilerek yapılmaktadır. Şekil 9’da Histogram ve önışlem uygulanmış görüntü verilmektedir.



Şekil 9. Histogram ve önışlem uygulanmış görüntüler.

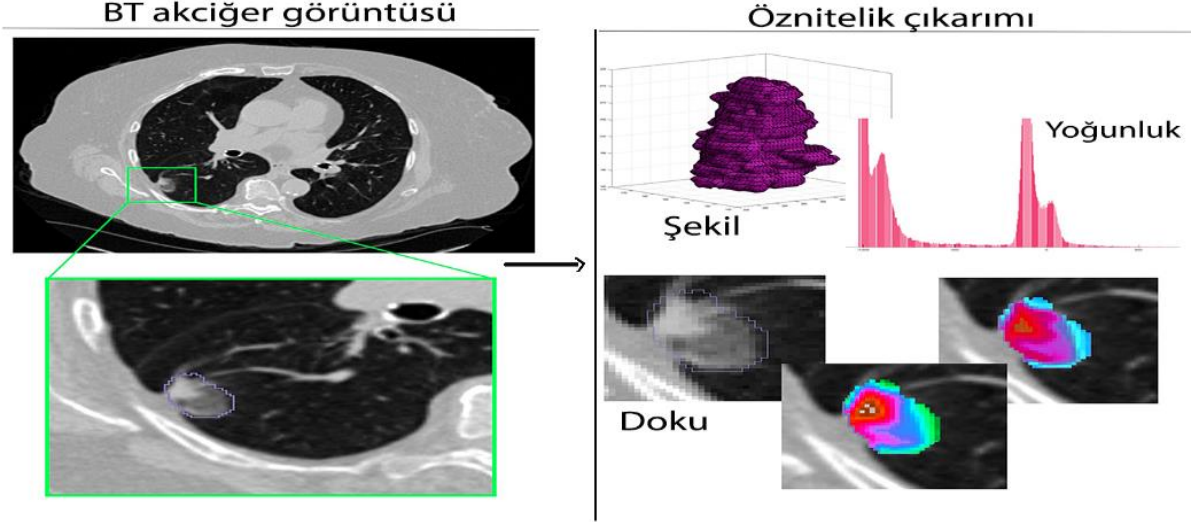
Giriş görüntüsünden, toplam gri seviye aralığı histogram yöntemiyle değerlendirilmektedir. Burada, 0 ile 255 arasında değişen 256 gri seviye bulunmaktadır.

3.2. Dalgacık Dönüşümü ile Öznitelik Çıkarma

BT görüntülerine sadece Dalgacık Dönüşümü (DD) uygulandığı zaman, genelde boyut düşürme (down sampling) gerçekleşir. Sonuç olarak çözünürlük seviyesi 1 artmakta ve dört bileşenin her birinin örnek boyutu 1/4 olmaktadır. Bu sorunla başa çıkmak için bu çalışmada Ayrık Dalgacık Dönüşümü (ADD) kullanılmaktadır. DD’nin aksine ADD, boyut düşürme işlemlerini içermez ve dolayısıyla düşük frekans katsayıları ve yüksek frekans katsayıları her seviyede başlangıç sinyali ile aynı uzunluğa sahip olmaktadır. Geleneksel bir ADD’nin temel algoritması; görüntünün her noktasında dönüşüm uygulamaması, detaylı katsayıları saklaması ve yaklaşım katsayılarını bir sonraki seviye için kullanması şeklinde açıklanabilir. Katsayıların dizin boyutları seviyeden seviyeye azalmaz. Bu dönüşümün amacı, durağan olmayan sinyali küçük, durağan zaman dilimlerine bölmek ve bu zaman dilimlerindeki frekansları belirlemek için bahsedilen aralıkların ADD analizini yapmaktır. ADD dönüşümü, zaman-frekans eksenlerine bölünerek kullanılmıştır. Daha sonra güç spektral yoğunluğu alınır ve bu yöntem ses verilerinin enerjisinin frekansa göre nasıl dağıldığını açıklar. Son olarak dalgacık dönüşümü uygulanmaktadır. Bu teknik, görüntülerin merkezini bulmak için kullanılır. Burada normalize edilmiş çapraz korelasyon uygulanır. Denklemi şöyledir:

$$e = \frac{1}{p \cdot q} \sum_{i=1}^p \sum_{j=1}^q |x(i, j)| \quad (2)$$

Burada kaynak görüntü 'i' iken şablon görüntü 'j'dir. Denklem (2) burada 'p', 'q', şablon görüntüsünün sayısını/satırını ve sütun sayısını temsil eder. Şablon eşleşmesinin en iyi eşleşmesi seçilir ve bu eşleme en iyi eşleştiği noktayı verir. Bu seçilen nokta ilgi kaynağıdır. Her görüntü bu noktayı alır ve piksel değeri yüksek olan kenarlık bu pikselin düşük değerine çevrilmektedir. Şekil 10'da öznelik çıkarımı uygulanmış görüntü gösterilmektedir.



Şekil 10. Öznelik çıkarımı.

Öznelik çıkarma tekniğinde asıl amaç, görüntüyü kompakt ve benzersiz tek değer veya matris vektörü biçimine sokmaktır. Öznelik çıkarma, görüntü işlemede, sınıflandırma için hangi görüntünün kullanılabileceğine bağlı olarak boyutsal küçülmeyi hesaplar. Giriş verilerinin, temsili özelliklerinin azaltılmasını içerir. Öznelik çıkarma işlemi ADD yöntemi ile gerçekleştirilmektedir.

4. ÖNERİLEN DERİN ÖĞRENME MİMARİSİ

4.1. Performans parametreleri

Performans farklı parametreler ile ölçülmektedir. Her derin sinir ağı için doğruluk, özgüllük ve hassaslık hesaplanır. Bu bir ikili sınıflandırma görevidir. Böylelikle sonuç dört şekilde oluşturulabilir. Bunlar:

Doğru Pozitif (DP): BT görüntüsünde akciğer nodülü bulunur ve nodül ile BT görüntüsü olarak sınıflandırılır [43]

Yanlış Pozitif (YP): BT görüntüsünde akciğer nodülü yoktur ve nodül ile BT görüntüsü olarak sınıflandırılır [44].

Doğru Negatif (DN): BT görüntüsünde akciğer nodülü yoktur ve nodül olmadan BT görüntüsü olarak sınıflandırılır [45].

Yanlış Negatif (YN): BT görüntüsünde akciğer nodülü bulunur ve nodülsüz BT görüntüsü olarak sınıflandırılır [46].

4.2. Uygulanan Modeller

ESA, BT görüntülerine bir dizi öğrenilebilir filtre uygular. ESA'da evrişim katmanı, filtre boyutu, uygulanan filtre sayısı ve iş parçacıkları ile tanımlanabilir. Evrişimli bir katmanın giriş ve çıkışı, BT görüntülerinden başlayarak üç boyutlu bir yapıya (genişlik, yükseklik, kanal sayısı) sahiptir. Evrişim katmanlarını derlerken, çıktının genişliği ve yüksekliği en yüksek havuzlama işlemi kullanılarak ve derinlik ise az veya çok filtreler kullanılarak elde edilebilir.


Bilgisayar konfigürasyonu düşük olduğundan MobileNet V3'ten yararlanılmıştır. MacOS 10.15.3; işlemci, 2.2 GHz, Intel Core i7; ekran kartı, Intel HD Graphics 4000 ile programlama olarak Python dilinden yararlanılmıştır.

4.3. MobileNet V3

MobileNet etkili bir ESA ağıdır. Düşük konfigürasyonlu cihazlar için çok uygun olan MobileNet V3, platforma duyarlı ağ mimarisi araması ve NetAdapt algoritması [19] aracılığıyla tasarlanmıştır. Bölütme ve sınıflandırma görevleri için en gelişmiş sonuçları elde etmektedir. Bu modelin, farklı kaynak platformlarını karşılamak için MobileNet V3 geliştirilmiştir. MobileNet V3, ImageNet veri setinde %20 daha az gecikme ile MobileNet V2'den %3,2 daha başarılı sonuçlar sağlamaktadır [20].

MobileNet V3, MobileNet V2'den ters çevrilmiş darboğaz (bottleneck) Squeeze and Excitation bloklarının bir kombinasyonunu kullanmaktadır [21]. Bu darboğazlar 1×1 genişleme evrişim katmanı, 3×3 derinlemesine evrişim katmanı ve ardından 1×1 projeksiyon katmanından oluşmaktadır.

H-swish doğrusal olmama işlevi, gömülü ortamlarda hesaplama açısından maliyetli olan swish'in sert bir karşılığı olarak kullanılmaktadır. Buna ek olarak, MobileNet V2'de bulunan önceki ters çevrilmiş kalıntı yapısındaki maliyetli katmanlar bu sürümde kullanılmak üzere yeniden tasarlanmıştır. Son aşamadan 1×1 genişleme katmanı, havuzlama katmanının ötesine kaydırılmıştır. Bu, 1×1 katmanının gecikme ve hesaplama süresini 7×7 azaltmak yerine 1×1 özellik haritası üzerinde çalışmasına izin vermektedir. Varsayılan olarak 32 filtre olan diğer MobileNet modellerine kıyasla, ilk aşamadaki filtre sayısı 3×3 evrişim için 16'ya düşürülmüştür.




Şekil 11. MobileNet v3 uygulama şeması.

MobileNet V3, NetAdapt algoritması ile tamamlanan ve daha sonra yeni mimari avantajlar ile geliştirilen donanıma duyarlı ağ mimarisi araması kombinasyonu içermektedir

Mobil cihazlar için çok uygun olan hafif bir model olan MobileNet V3, platform farkında ağ mimarisi araması ve NetAdapt algoritması aracılığıyla tasarlanmıştır. Segmentasyon ve sınıflandırma görevleri için çok iyi sonuçlar elde etmektedir. MobileNet v3, ImageNet veri setinde %20 daha az gecikme ile MobileNet modelinin diğer versiyonlarından daha iyi sonuçlar vermektedir. MobileNet V3, eğitilmiş 16 ImageNet sınıflandırma modeli kontrol noktası oluşturulur. Giriş BT görüntüsü 6053 boyutlu bir vektör olarak alınır. Her görüntü, darboğaz (bottleneck) değeri için hesaplanır. Bu darboğazlar; 1×1 genişleme evrişim katmanı, 3×3 derinlemesine evrişim katmanı ve ardından 1×1 projeksiyon katmanından oluşmaktadır. MobileNet V3'ün tam yapısı Şekil 11'de gösterilmektedir. Şekilde görüldüğü üzere son aşamadan 1×1 genişleme katmanı, havuz katmanının ötesine kaydırılmıştır.

$$y_i^{(k)} = \alpha^{(k)} x_i^{(k)} + \beta^{(k)} \quad (3)$$

Denklemden (3) görüldüğü üzere hesaplama maliyetini azaltmak için, her k kanalı için α , ağırlıkları paylaşılacak ve tekli evrişim işlemlerine yardımcı olacaktır. Ağırlık niceleme için kullanılan ölçek bütünsel olarak ağırlık dağılımının aralığına bağlıdır. TensorFlow uygulamasında, ölçek hesaplamak için minimum ve maksimum ağırlık değerleri tüm kanallardan aynı oranlarda alınmaktadır. Şekil 12'de MobileNet V3 modelinin doğruluk ve kesinlik seviyeleri gösterilmektedir.



Şekil 12. Model eğitiminde doğruluk seviyesi.


4.3.1. Inception-v4

Bilgisayar görüşünde, Inception etkili bir derin sinir ağı mimarisidir [7]. Başlangıç algoritması, yerleşik veya mobil bilgi işlem aygıtları için çok daha iyi performans göstermektedir. Derin ESA'da doğruluğu artırmanın yolu, her bir düzeydeki ortalama boyutlarda çalışma düzeyi ve birim sayısını artırmaktır. Başlangıçta 1×1 , 3×3 , 5×5 evrişim filtresi ve 3×3 maksimum ortaklama filtresi kullanılır. Evrişim katmanında maksimum ortaklama işlemi çok etkilidir. Başlangıç, optimum seyrek mimari ve diğer mimariden $3 \sim 10 \times$ daha hızlıdır.

4.3.2. VGG-16

Bu modelde ise veri eğitimi için VGG-16 kullanılmıştır. VGG Net 16 mimarisini kullanan eğitilmiş model Şekil 13'te gösterilmektedir. Evrişim 1 giriş katmanı, 224×224 kırmızı yeşil mavi (RGB) standart bir görüntü boyutudur. Filtrelerin 3×3 boyutunda tam bir küçük alım alanıyla uygulandığı en doğru sonuçları bulmak için giriş 16 katmanın tümüne verilir [27]. Bazı düzenlerde, giriş istasyonlarının düz modifikasyonu olarak görülen 1×1 evrişim filtreleri de kullanılır. Evrişim çizgisi 1 piksel olarak değiştirilmiştir. Evrişim katmanı girişinin uzamsal dolgusu, uzamsal çözünürlüğün evrişimden sonra depolanacağı şekildedir. Doldurma (padding), 3×3 evrişim katmanları için 1 pikseldir. Koleksiyon, evrişim katmanlarından birini takip eden maksimum havuzlama lensleriyle gerçekleştirilmektedir. Maksimum havuzlama, 2×2 piksel evrişim katmanıyla yapılır.

Tam bağlı 3 katmanın tümü, çeşitli yapılarla farklı derinliklere sahip evrişim katmanı ile devam edecektir. İlk iki katman 4096 kanala sahiptir ve üçüncü katman, kategori başına bir kanal oluşturarak 1000 kanalda ILSVRC sınıflandırmasına bağlanır. Softmax katmanı, tutma katmanıdır ve tamamen entegre katmanların konfigürasyonu, tüm ağırlarda benzerdir. Tüm gizli katmanlar, RELU (doğrultulmuş lineer birim/rectified linear unit) tarafından temsil edilen doğrusal olmayan erişime uyarlanır.



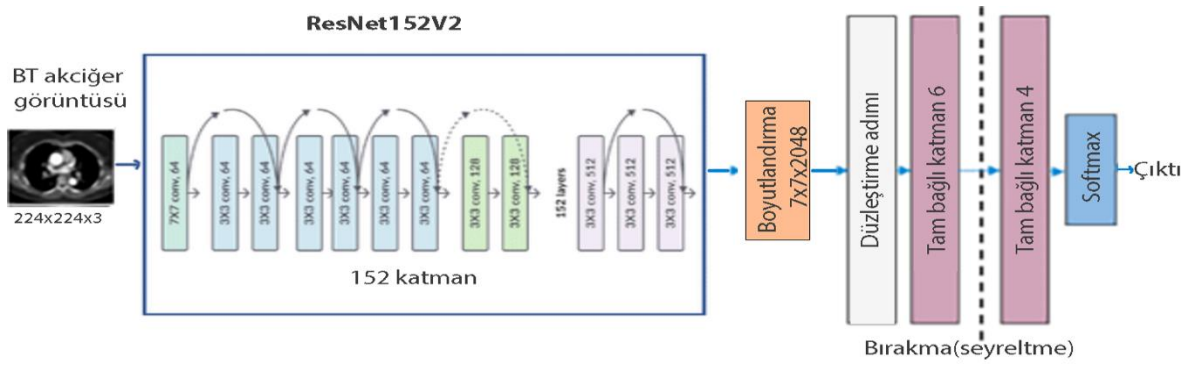
Şekil 13. Uygulanan VGG-16 Mimarisi [36].

Şekil 13'te görüldüğü gibi VGG-16 basit bir ağ modelidir, önceki modellerden en önemli farkı ikili veya üçlü evrişim katmanlarını birleştirme katmanlarının takip etmesidir. Girdiler tam bağlı katmanda $7 \times 7 \times 512 = 4096$ nöronlu bir öznitelik vektörüne dönüştürülür. 1000 sınıfı esnek softmax performansı, tüm bağlantı katmanı çıkışında hesaplanır. Bu modelde yaklaşık 138 milyon parametrenin hesabı yapılmaktadır.

4.3.3. ResNet152V2 Mimarisi

ResNet152V2, Şekil 6'da gösterildiği gibi özellik çıkarma modeli olarak kullanılmaktadır. Model, geleneksel bir ESA'dan daha hızlı kabul edilebilir doğruluk elde etmeye yardımcı olabilecek, önceden eğitilmiş bir model olduğu için başlangıç ağırlıklarına sahiptir. Model mimarisi, ResNet152V2 modelini takip eden bir yeniden şekillendirme katmanı, düzleştirilmiş bir katman, 128 nöronlu yoğun bir katman, bir bırakma katmanı ve son olarak, görüntüyü karşılık gelen katmana ince ayar uygulamak için Softmax etkinleştirme işlevine sahip yoğun bir katmandan oluşmaktadır. Mimari Şekil 14'te detaylandırılmıştır. ResNet152V2'nin tüm parametreleri, iki tür parametreden oluşan 71.177.348'dir: Sırasıyla 71.033.604 ve 143.744 olan eğitilebilir parametreler ile eğitilemez parametreler olarak kabul edilmektedir.

Şekil 14'te görüldüğü gibi ilk adımda ResNet152V2, önce eğitilmiş ağın birinci kısmı dışa aktarılmıştır. İkinci adımda elde edilen öznitelik kısmı yeni tasarlanmış bir ikinci yarı kısmına (eğitilmemiş FC katmanları) bağlanır; önerilen ağın temel mimarisi bu şekilde oluşmaktadır [11]. Öğrenme ünitelerinin rastgele deaktif hâle gelmesi için tam bağlantılı katmanlarda %50 çıkarma uygulanmıştır. Böylece Softmax ile her eğitim yinelemesinin ardından ağırlıklar değişmektedir, bu da genelleme performansının artmasıyla sonuçlanır. Buna ek olarak, aşırı uymaya engel olmak ve genelleme performansını iyileştirmek için L2-norm düzenlemesi benimsenmiştir. Üçüncü adımda, 3 bileşen görüntüsünün dalgacık katsayıları yeni inşa edilmiş ağın üç girdi kanalına verilir; bunun ardından yeniden eğitim için geri yayılım gerçekleşir [48].



Şekil 14. ResNet152V2 önerilen model mimarisi [40].

4.3.4. Tartışma ve Elde Edilen Sonuçlar

Bu çalışmada 4 klasik ESA modeli ve ADD yöntemi kullanılarak akciğer kanserinin erken teşhisi yapılmıştır. Önerilen bu metodoloji, büyük bir BT akciğer görüntüsü veri setinde uygulanmaktadır ve sistemlerin performansı, evrensel metriklerle karşılaştırma için alt bölümde sunulmaktadır. Tablo 1, önerilen yöntem için akciğer kanseri görüntü sınıflandırma oranlarının doğruluk düzeyini göstermektedir. Bu testte, ADD tabanlı ResNet152V2 modeli, BT görüntüsü için mevcut sınıflandırıcılar ile karşılaştırılmış ve önerilen algoritmanın daha iyi sınıflandırma sonucu sağladığı tespit edilmiştir. Tablo 1'de gösterildiği gibi, pozitif prediktif (öngörü) değer, testin pozitif değerinin o toplumda gerçekten hasta olma olasılığıdır. Tabloda Gerçek Pozitifliğin pozitif test toplamına oranıdır. Negatif prediktif değer, tarama testi negatif olan deneklerin aslında hastalığa sahip olmama olasılığı diğer modellere göre daha iyi sonuçlar göstermektedir. Bu, önerilen çalışmanın ADD ve ESA sınıflandırmasının yeterliliğini artırmak ve BT akciğer kanseri veri kümelerini gruplamak için doku ve renk özelliklerini dikkate almanın sonucudur. Dalgacık katsayıları, normal vakalar da dâhil olmak üzere akciğer BT görüntülerinden kanseri sınıflandırmak için girdi olarak kullanılmış ve elde edilen sonuçlar, önerilen yöntemin etkinliğini ve verimliliğini doğrulamak için birinci adımla karşılaştırılmıştır. Toplam doğruluk, diğer iki yöntemle elde edilenden daha yüksektir. Bu, önerilen yöntemin üstünlüğünü kanıtlamaktadır. Tablo 1, gerçekleştirilen deneylerin sonuçlarını göstermektedir.

Tablo 1. Yapılan deneyler sonucunda elde edilen model performansı.

BT veriseti	Nodül Tespiti	Model	Doğruluk	Hassaslık	Özgüllük	Pozitif tahmin değerler	Negatif tahmin değerler
		ResNet152V2 modeli	97,52	91,89	94,16	96,45	95,34
		MobileNet V3 modeli	96,45	93,85	90,40	89,50	60,20
		VGG-16 modeli	97,52	88,45	84,56	89,65	56,45
		Inception v4 modeli	94,11	90,45	72,22	73,12	83,34

4.3.5. Mevcut çalışmalar ile karşılaştırma

Akciğer kanserinin erken teşhisine yönelik literatürde elde edilen çalışmanın sonuçları Tablo 2'de karşılaştırmalı olarak verilmiştir. Tablo 2'de görüldüğü gibi önerilen modelde, ADD yardımıyla elde edilen özelliklerin sınıflandırılması sonucunda daha iyi bir duyarlılık, özgüllük ve doğruluğa ulaşılmıştır.

Tablo 2. Önerilen modelin mevcut çalışmalar ile karşılaştırılması.

Mevcut çalışmalar	Doğruluk	Hassaslık	Özgüllük
Suren vd., [49]	92,24	93,65	91,23
Taruna vd., [50]	97,12	97,14	96,33
Hiram Madero vd., [51]	89,52	90,90	88,15
Hiram Madero vd., [52]	95,66	96,15	97,32
Hong Shao vd., [53]	90,35	89,47	90,52
Silva vd., [54]	94,78	94,66	95,14
Costa vd., [55]	91,81	93,42	91,21
Önerilen model	97.52	91.89	94.16

5. GENEL SONUÇ VE ÖNERİLER

Akciğer kanserinin otonom olarak tanımlanması ve tedavi edilmesi için son yıllarda birkaç Derin Öğrenme temelli araştırma yapılmıştır. Bu çalışmalar, yüksek doğruluk oranlarına sahip otomatik tanımlama ve yönetim sistemleri kullanarak halk sağlığı kurumları ve hastaneler üzerindeki yükü hafifletmektedir. Önceki sınıflandırma algoritmalarıyla karşılaştırıldığında, bu çalışmada oluşturulan ayrık dalgacık dönüşümüne sahip ResNet152V2 modeli, akciğer BT görüntüleri örneğinde daha iyi performans göstermiştir. Otomatik akciğer kanseri sınıflandırma yöntemi, manuel etiketleme süresini kısaltabilir ve insan hatalarını ortadan kaldırabilir. Önerilen teknik, deneysel verilere göre akciğer resimlerini %97,52 doğruluk, %91,89 duyarlılık ve %94,16 özgüllük ile kategorize etmede etkilidir. Teknik, akciğer kanseri için otomatik teşhis hedefini %97'nin üzerinde doğrulukla gerçekleştirmiştir.

Sonraki araştırmalarda sınıflandırma doğruluğunu artırmak için alternatif dalgacık tabanlı fonksiyonların sınıflandırma üzerindeki etkisinin araştırılması ve yeni bir mimari oluşturulması amaçlanmaktadır. Önerilen yaklaşımın, çeşitli hastalık sınıflandırmalarında ve görüntüleme yöntemlerinde kullanımı için yeterince güvenilir olması beklenmektedir.

Yazar Katkıları

Yazar 1 kavram ve fikri ortaya atmıştır. Ayrıca denetleme ve danışmanlık görevi de Yazar 1 tarafından yürütmüştür. Yazar 1 literatür taraması ve formatı düzenlemiştir. Yazar 1 analiz ve metotları geliştirmiştir. Bütün süreçler Yazar 1 tarafından gerçekleştirilmiştir.

Çıkar Çatışması

Yazarlar arasında çıkar çatışması bulunmamaktadır.

KAYNAKÇA

- [1] M. Atasever, "Sağlık İşletmelerinde Tıbbi Laboratuvar Hizmet Alımları Yönetimi", 2017.
- [2] Y. A. Üncü, "Segmentation of Major Vessel in X-Ray Angiographic Images with Image Processing Technique", Eskişehir Technical University Journal of Science and Technology A-Applied Sciences and Engineering, vol. 22, no. 2, pp. 209-214, 2021.
- [3] H. Balsak, "Yoğun bakım hemşirelerine verilen radyasyon güvenliği programının değerlendirilmesi", 2019.
- [4] D. Moitra, and R. K. Mandal, "Automated AJCC staging of non-small cell lung cancer (NSCLC) using deep convolutional neural network (CNN) and recurrent neural network (RNN)", Health information science and systems, vol. 7, no. 1, pp. 1-12, 2019.
- [5] K. Munir et al., "Cancer diagnosis using deep learning: a bibliographic review", Cancers, vol. 11, no. 9, pp. 1235, 2019.
- [6] G. Sevim et al., "Image reconstruction for diffuse optical tomography using bi-conjugate gradient and transpose-free quasi minimal residual algorithms and comparison of them", International Journal of Imaging Systems and Technology, vol. 31, no. 4, pp. 1894-1905, 2021.
- [7] Y. A. Üncü et al., "Differentiation of tumoral and non-tumoral breast lesions using back reflection diffuse optical tomography: A pilot clinical study", International Journal of Imaging Systems and Technology, vol. 31, no. 4, pp. 2023-2031, 2021.
- [8] Y. A. Üncü, G. Sevim, and M. Canpolat, "Approaches to preclinical studies with heterogeneous breast phantom using reconstruction and three-dimensional image processing algorithms for diffuse optical imaging", International Journal of Imaging Systems and Technology, vol. 32, no. 1, pp. 343-353, 2022.
- [9] E. Warner et al., "Comparison of breast magnetic resonance imaging, mammography, and ultrasound for surveillance of women at high risk for hereditary breast cancer", Journal of Clinical Oncology, vol. 19, no. 15, pp. 3524-3531, 2001.
- [10] H. Park, and C. Monahan, "Genetic deep learning for lung cancer screening", arXiv preprint arXiv:1907.11849, 2019.
- [11] L. Ebner et al., "Lung nodule detection by microdose CT versus chest radiography (standard and dual-energy subtracted)", American Journal of Roentgenology, vol. 204, no. 4 pp. 727-735, 2015.

- [12] D. Ardila, A. P. Kiraly, S. Bharadwaj, B. Choi, J. J. Reicher, L. Peng, and S. Shetty, "End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography", *Nature medicine*, vol. 25, no. 6, pp. 954-961, 2019.
- [13] S. S. Singh et al., "Genotype driven therapy for non-small cell lung cancer: Resistance, pan inhibitors and immunotherapy", *Current Medicinal Chemistry*, vol. 27 no. 32, pp. 5274-5316, 2020.
- [14] F. Silva et al., "Pre-training autoencoder for lung nodule malignancy assessment using ct images", *Applied Sciences*, vol. 10, no. 21, p. 7837, 2020.
- [15] S. Lakshmananprabu et al., "Optimal deep learning model for classification of lung cancer on CT images", *Future Generation Computer Systems*, vol. 92, pp. 374-382, 2019.
- [16] S. Chen et al., "Texture analysis of baseline multiphase hepatic computed tomography images for the prognosis of single hepatocellular carcinoma after hepatectomy: a retrospective pilot study", *European journal of radiology*, vol. 90, pp. 198-204, 2017.
- [17] H. Bera et al., "Carboxymethyl fenureek galactomannan-g-poly (N-isopropylacrylamide-co-N, N'-methylene-bis-acrylamide)-clay based pH/temperature-responsive nanocomposites as drug-carriers", *Materials Science and Engineering: C*, vol. 110, p. 110628, 2020.
- [18] A. Sharma, and R. Rani, "An optimized framework for cancer classification using deep learning and genetic algorithm", *Journal of medical imaging and health informatics*, vol. 7, no. 8, pp. 1851-1856, 2017.
- [19] J. Kuruvilla, and K. Gunavathi, "Lung cancer classification using neural networks for CT images", *Computer methods and programs in biomedicine*, vol. 113, no. 1, pp. 202-209, 2014.
- [20] A. Aleesa et al., "Review of intrusion detection systems based on deep learning techniques: coherent taxonomy, challenges, motivations, recommendations, substantial analysis and future directions", *Neural Computing and Applications*, vol. 32, no. 14, pp. 9827-9858, 2020.
- [21] T. Aggarwal, A. Furqan, and K. Kalra, "Feature extraction and LDA based classification of lung nodules in chest CT scan images", In 2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI), IEEE, 2015.
- [22] Q, Song, et al., "Using deep learning for classification of lung nodules on computed tomography images", *Journal of healthcare engineering*, 2017.
- [23] P. M. Shakeel, M. A. Burhanuddin, and M. I. Desa, "Lung cancer detection from CT image using improved profuse clustering and deep learning instantaneously trained neural networks", *Measurement*, vol. 145, pp. 702-712, 2019.
- [24] R. Roslidar et al., "A review on recent progress in thermal imaging and deep learning approaches for breast cancer detection", *IEEE Access*, vol. 8, pp. 116176-116194, 2020.
- [25] Y. Zhong et al., "Deep learning for prediction of N2 metastasis and survival for clinical stage I non-small cell lung cancer", *Radiology*, vol. 302, no. 1), pp. 200-211, 2022
- [26] D. Riquelme, and M. A. Akhloufi, "Deep learning for lung cancer nodules detection and classification in CT scans", *AI*, vol. 1, no. 1, pp. 28-67, 2020.
- [27] S. Bhatia, Y. Sinha, and L. Goel, "Lung cancer detection: a deep learning approach", In *Soft Computing for Problem Solving*, Springer, pp. 699-705, 2019.
- [28] T. Pandiangan, I. Bali, and A. Silalahi, "Early lung cancer detection using artificial neural network", *Atom Indonesia*, vol. 45, no. 1, pp. 9-15, 2019.
- [29] F. Ciompi, F., "Towards automatic pulmonary nodule management in lung cancer screening with deep learning", *Scientific reports*, vol. 7, no. 1, pp. 1-11, 2017.
- [30] A. Halder, D. Dey, and A. K. Sadhu, "Lung nodule detection from feature engineering to deep learning in thoracic CT images: a comprehensive review", *Journal of Digital Imaging*, vol. 33, no. 3, pp. 655-677, 2020.
- [31] Z. Li et al., "Deep learning methods for lung cancer segmentation in whole-slide histopathology images—the acdc@ lunghp challenge 2019", *IEEE Journal of Biomedical and Health Informatics*, vol. 25, no. 2, pp. 429-440, 2020.
- [32] Q, Wang et al., "Prediction of gene mutation in lung cancer based on deep learning and histomorphology analysis", *Sheng wu yi xue gong cheng xue za zhi= Journal of biomedical engineering= Shengwu yixue gongchengxue zazhi*, vol. 37, no. 1, pp. 10-18, 2020.
- [33] A. Hosny et al., "Deep learning for lung cancer prognostication: a retrospective multi-cohort radiomics study", *PLoS medicine*, vol. 15, no. 11, p. e1002711, 2018.
- [34] R. Dey, Z. Lu, and Y. Hong, "Diagnostic classification of lung nodules using 3D neural networks", In 2018 IEEE 15th international symposium on biomedical imaging (ISBI), 2018.
- [35] K. Li et al., "Towards cross-modality medical image segmentation with online mutual knowledge distillation", In *Proceedings of the AAAI conference on artificial intelligence*, 2020.
- [36] S. Li, et al., "Predicting lung nodule malignancies by combining deep convolutional neural network and handcrafted features", *Physics in Medicine and Biology*, vol. 64, no. 17, p. 175012, 2019.
- [37] H. Polat, and H. Danaei Mehr, "Classification of pulmonary CT images by using hybrid 3D-deep convolutional neural network architecture", *Applied Sciences*, vol. 9, no. 5, p. 940, 2019.
- [38] N. Coudray, P. S. Ocampo, T. Sakellaropoulos, N. Narula, M. Snuderl, D. Fenyö, and A. Tsirigos, "Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning", *Nature medicine*, vol. 24, no. 10, pp. 1559-1567, 2018.

- [39] A. M. Mesleh, "Lung Cancer Detection Using Multi-Layer Neural Networks with Independent Component Analysis: A Comparative Study of Training Algorithms", *Jordan Journal of Biological Sciences*, vol. 10, no. 4, 2017.
- [40] A. Asuntha, and A. Srinivasan, "Deep learning for lung Cancer detection and classification", *Multimedia Tools and Applications*, vol. 79, no. 11, pp. 7731-7762, 2020.
- [41] D. Aberle et al., "National Lung Screening Trial Research T. Reduced lung-cancer mortality with low-dose computed tomographic screening" *N Engl J Med*, vol. 365, no. 5, pp. 395-409, 2011.
- [42] A. M. Santos et al., "Automatic detection of small lung nodules in 3D CT data using Gaussian mixture models", *Tsallis entropy and SVM. Engineering applications of artificial intelligence*, vol. 36, pp. 27-39, 2014.
- [43] F. Sahito, P. Zhiwen, J. Ahmed, and R. A. Memon, "Wavelet-integrated deep networks for single image super-resolution", *Electron.*, vol. 8, no. 5, pp. 1-16, 2019.
- [44] K. H. B. T. Sarode, and S. Natu, "Performance Comparison Of Hybrid Wavelet Transforms Formed Using Dct, Walsh, Haar and DKT in Watermarking", *Int. J. Comput. Sci. Inf. Technol.*, vol. 7, no. 1, pp. 41-58, 2015.
- [45] R. V. M. Da Nóbrega, S. A. Peixoto, S. P. P. Da Silva, and P. P. R. Filho, "Lung Nodule Classification via Deep Transfer Learning in CT Lung Images", In *Proceedings - IEEE Symposium on Computer-Based Medical Systems*, 2018.
- [46] J. W. Lee, H. W. Lee, J. H. Lee, I. T. Kang, and G. K. Lee, "A study on lung nodule detection using neural networks", In *IEEE Region 10 Annual International Conference, Proceedings/TENCON*, vol. 2, pp. 1150-1153, 1999.
- [47] S. Srinivas and R. V. Babu, "Learning the Architecture of Deep Neural Networks", *arXiv Prepr.*, no. Section 2, pp. 1-13, 2015.
- [48] J. Günther, P. M. Pilarski, G. Helfrich, H. Shen, and K. Diepold, "Intelligent laser welding through representation, prediction, and control learning: An architecture with deep neural networks and reinforcement learning", *Mechatronics*, vol. 34, pp. 1-11, 2016.
- [49] S. Makaju, A. A. Prasad, S. Elchouemi, "Lung Cancer detection using CTscan images", *Elsevier, Procedia Computer Science*, vol. 125, pp. 107-114, 2018.
- [50] T. Aggarwal, A. Furqan, K. Kalra, "Feature extraction and LDA based classification of lung nodules in chest CT scan images", *IEEE, International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pp. 1189-1193, 2015.
- [51] H. M. Orozco, O. O. V. Villegas, V. G. C. Sánchez, H. de Jesús Ochoa Domínguez, M. de Jesús Nandayapa Alfaro, "Automated system for lung nodules classification based on wavelet feature descriptor and support vector machine", *Biomed Eng* vol. 14, no. 9, pp. 1-20, 2015.
- [52] H. M. Orozco, O. O. V. Villegas, L. O. Maynez, V. G. C. Sanchez, H. de Jesus Ochoa Dominguez, "Lung Nodule CLASSIFICATION in Frequency Domain Using Support Vector Machine", *IEEE, In international conference on information science, signal processing and their application*, 2012.
- [53] H. Shao, L. Cao, Y. Liu, "A detection approach for solitary pulmonary nodules based on CT images", *IEEE, 2nd international conference on computer science and network technology*, 2012.
- [54] G. L. F. Da Silva, O. P. da Silva Neto, A. C. Silva, A. C. de Paiva Marcelo Gattass, "Lung nodules diagnosis based on evolutionary convolutional neural network", *Springer, Multimed Tools Appl*, vol. 76, no. 18, pp. 19039-19055, 2017.
- [55] R. W. de Sousa Costa, G. L. F. da Silva, A. O. de Carvalho Filho, A. C. Silva, A. C. de Paiva Marcelo Gattass, "Classification of malignant and benign lung nodules using taxonomic diversity index and phylogenetic distance", *Springer, Med Biol Eng Comput*, vol. 56, no. 11, pp. 2125-2136, 2018.



Remote Access Greenhouse Automation Application Based on LabVIEW

Uzaktan Erişimli LabVIEW Tabanlı Sera Otomasyonu Uygulaması

¹Behçet KOCAMAN , ²Mehmet Fatih GÜLER 

¹Bitlis Eren Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bitlis, Türkiye

²T.C. Milli Savunma Bakanlığı, Ankara, Türkiye

¹bkocaman@beu.edu.tr, ²guler.mfatih@gmail.com

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 20 May 2022

Accepted : 7 July 2022

Keywords:

Greenhouse, Lighting,
LabVIEW, Remote Monitoring
and Control

ABSTRACT

Various automatic control systems have been established in order to increase the yield of the products to be obtained from the plants grown in the greenhouses. These control systems come into prominence in ensuring the automatic solution of the determined problems by being activated quickly, controlling the temperature and moisture values in the greenhouse and in the stable operation of the system. In this study, remote access greenhouse automation application with NI MyRIO control card was carried out on the prototype. System datas were monitored and controlled in real time with the LabVIEW (Laboratory Virtual Instrument Engineering Workbench) graphical program. The values of the plants to be grown in the greenhouse such as water, temperature, moisture and appropriate photosynthesis light ratio are measured and determined by the sensors used in the system and shown to the user with the LabVIEW interface program with the NI MyRIO control card.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 20 Mayıs 2022

Kabul : 7 Temmuz 2022

Anahtar Kelimeler:

Sera, Aydınlatma, LabVIEW,
Uzaktan İzleme ve Kontrol

ÖZET

Seralarda yetiştirilen bitkilerden elde edilecek ürünlerin verimini artırmak için çeşitli otomatik kontrol sistemleri kurulmuştur. Bu kontrol sistemleri, hızlı devreye girerek belirlenen problemlerin otomatik çözümünün sağlanmasında, sera içindeki sıcaklık ve nem değerlerinin kontrol edilmesinde ve sistemin stabil çalışmasında ön plana çıkmaktadır. Bu çalışmada, NI MyRIO kontrol kartı ile uzaktan erişimli sera otomasyonu uygulaması, prototip üzerinde gerçekleştirilmiştir. Sistem verileri, LabVIEW (Laboratory Virtual Instrument Engineering Workbench) grafik programı ile gerçek zamanlı olarak izlenip kontrol edilmiştir. Serada yetiştirilecek bitkilerin su, sıcaklık, nem ve uygun fotosentez ışık oranı gibi değerleri sistemde kullanılan sensörler tarafından ölçülerek belirlenir ve NI MyRIO kontrol kartı ile LabVIEW arayüz programı ile kullanıcıya gösterilmektedir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. INTRODUCTION

Nowadays, the need for agricultural products has increased with the increase of the world population and it has become very difficult to meet the desired product at the desired time. In order to prevent this situation, greenhouses where fruit and vegetables are grown have been established. It is important in terms of applying developing technologies to the agricultural sector in developing countries and bringing the market share of the agricultural economy to the desired level. In this respect, to integrate technology into agriculture; together with the agricultural industry, it enables it to connect with many sectors and to development many sectors. One of the applications of technology in agriculture is greenhouse automation. Thanks to this automation, the control of the temperature, moisture, light and irrigation amount needed by the plant during the production phase is provided.

It is not possible to grow plants in all seasons of the year in traditional farming systems. In addition, plant productivity is not optimum in these systems. There should be suitable conditions for growing plants in all seasons of the year. These environments can be provided with a greenhouse. Because greenhouses protect plants from too much heat or cold and dust storms. In this study, a greenhouse automation system has been designed to provide a suitable environment for plants, providing temperature, ventilation, light and irrigation.

Greenhouse technology and controlled environment agriculture (CEA) some of the latest developments in CEA have been highlighted. For this, various aspects of a high-tech CEA system, such as the framework and coating materials, environmental perception and data sharing, and advanced microclimate control and energy optimization models, are discussed. It also described urban agriculture and its derivatives, including vertical farming, rooftop greenhouses and plant factories [1]. It has been proposed to develop a cost-effective automated system for greenhouse environmental control. It has been analyzed in terms of architectural and functional features. The proposed embedded platform provides remote monitoring and control of the greenhouse environment. It is also implemented as a distributed detection and control network integrating wired and wireless nodes [2]. The development of a greenhouse area network system and intelligent wireless sensor and field performance to monitor, control and access sera microenvironments has been proposed [3, 4]. It has been proposed to the design and implementation of the electrical and mechanical requirements of a smart greenhouse system. Measurement and control systems have been developed to autonomously manage the greenhouse and the interconnection between hardware components such as sensors, actuators and controllers. The system is based on a wirelessly connected microcontroller [5]. The software application created for smartphones with Android operating system provides remote user access to the database over the Internet for remote control and analysis of climate indicators in the greenhouse. The lighting control system suggested in the greenhouse improves the greenhouse lighting control system and increases efficiency. Thus, it contributes to the development of agriculture [6]. An automatic pest count and environmental status monitoring system using integrated camera modules and an embedded system as sensor nodes in the wireless sensor network has been built. Information on pest concentrations has been further analyzed temporally and spatially, together with environmental factors [7]. It is aimed to examine the progress of microcomputers in smart remote monitoring and control applications for the control and management of different systems using wireless / wired techniques [8]. A general scheme of an intelligent greenhouse control system based on the Internet of Things (IoT) and Zig Bee wireless sensor network technology is designed. Greenhouse control strategy has been investigated using IoT technology and fuzzy adaptive PID control algorithm [9,10]. The design system applied using LabVIEW, allowing the user to monitor the data obtained from the greenhouse, a real-time remote light intensity, temperature and humidity monitoring system was designed and applied for the greenhouse based on Raspberry Pi3 platforms [11]. Current strategies for energy efficient control operation and state of the art energy simulation for greenhouses are explained [12]. The environmental factors affecting all indoor temperatures for the greenhouse were collected as data on outdoor air temperature, wind speed and external solar radiation. In this research, 13 different training algorithms were used for Artificial Neural Networks models. Based on K-fold cross validation and Randomized Complete Block methodology, the best model was chosen [13]. A new phenotyping greenhouse facility has been designed. It is built with an automatic, highly efficient imaging system and a belt-based plant conveyor. Plants were transported to the greenhouse during the experiment with the conveyor system controlled by computer algorithm [14]. It is aimed to increase the quality and efficiency of greenhouses by saving time, energy, light and water consumption by measuring and controlling the climate parameters that are effective in the formation of climate factors in greenhouses. For this, it has been controlled with the fuzzy logic-based control strategy proposed as an intelligent and remotely accessible Android based interface [15]. A decentralized smart irrigation approach has been proposed for strawberry greenhouses. It performed significantly better than the traditional approach in terms of both soil moisture change and soil moisture [16, 17]. A wireless sensor network prototype of MicaZ nodes used to measure the temperature, light, pressure and humidity of greenhouses is presented. With this system, farmers can control their greenhouses from the moisture on their mobile phones or computers with internet connection [18]. A greenhouse sensor smart management system based on the Internet of Things has been designed. The performance of the system has been tested in the laboratory. The results showed that the system is reasonable, the structure is compact, the network layer is reliable, and the performance is stable [19]. Based on the current state of development of greenhouse remote monitoring systems, a greenhouse remote monitoring system based on WinCE has been designed and developed. The remote control of the greenhouse is realized by monitoring. Computer and mobile

phone tests have shown that the system is reliable and easy to use, and that the expected goals are achieved in every respect [20]. Using a combination of Arduino, different digital sensors, bluetooth module and mobile device, a system of monitoring natural ambient light in a greenhouse with a sensitivity similar to other electronic devices has been made. It is stated that the system can provide assistance to small entrepreneurs in the vegetable and horticultural sector [21]. Enclose-Loop wireless power supply technology has been proposed to take into account the distribution of the sensors in smart greenhouses and for the energy consumption of the sensor nodes. The proposed wireless transmission technology has been stated that the sensor node can effectively resolve the energy consumption and charging [22].

In this study, differently from the studies, remote access greenhouse automation was designed using the MyRIO control card and LabVIEW interface program. The rest of the paper has structured as follows. In Section III, material and method have explained. In other words, hardware and software features of the device prototype have described. Results and discussion have investigated in Section IV. Conclusion has been evaluated in Section V.

2. MATERIAL AND METHOD

In this study, a greenhouse prototype was created in order to create the necessary climatic conditions for the plants to be grown in greenhouses and to allow the plants to act as if they were outdoors. A control system has been designed for this. In the control system, the fans for cooling, heating, ventilation, lighting and irrigation rate are automatically managed by a specific program with the MyRIO control card and the LabVIEW interface program. The proposed system consists of experimental and software. Experimental mainly includes analog/digital input and digital output circuits, MyRIO control card, test cables, LM35 temperature sensor, infrared heater and relay, rain sensor, Light Dependent Resistors (LDR), Light Emitting Diode (LED) lighting and relay, soil moisture sensor, water pump, relay, servo motor, fan and computer. LED luminaries were preferred for lighting. Because it is one of the best solutions in the field of sustainable lighting for light quality and energy efficiency and is small in size compared to traditional luminaries [23-27]. The block scheme of the experimental setup is shown in Figure 1.

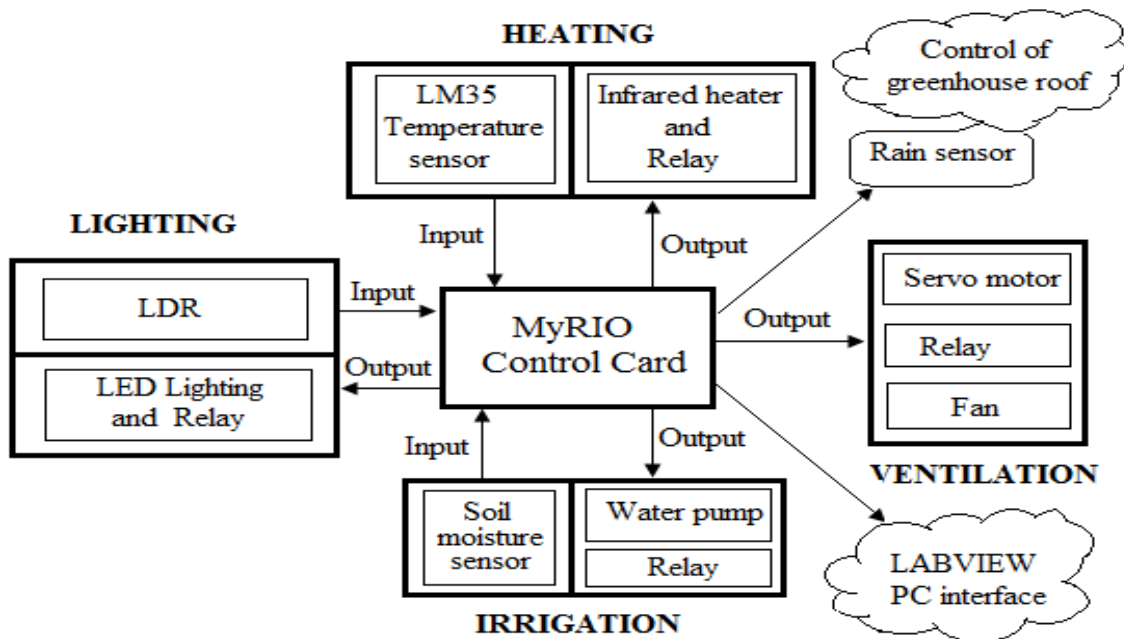


Figure 1. Block scheme of the experimental setup.

In the designed system, the control of the greenhouse is done in terms of ventilation, heating, irrigation and lighting systems. These systems are managed by the program prepared automatically with the MyRIO control card. First of all, parameters such as moisture, temperature, light are recorded for automatic or manual monitoring and control of the greenhouse. The recorded data is presented to the user with the designed LabVIEW interface program. Flowchart of the proposed system is given in Figure 2.

As can be seen in the flowchart in Figure 2, the primary MyRIO control card is introduced to the system and all operations are performed in connection with the MyRIO control card. It compares the values obtained from the MyRIO card, LM35 temperature sensor, Light Dependent Resistors (LDR) lighting sensor, rain sensor and soil-moisture sensor with the values determined by the user in the LabVIEW graphical program. Later, the values read by the MyRIO control card are decided in the decision cycle and the system runs continuously. The photograph of the experimental setup of the designed system is given in Figure 3.




Figure 2. Flowchart of the proposed system.




Figure 3. Photograph of the experimental setup.

In this study, block diagrams in accordance with the working logic of the sensors in the LabVIEW visual program for the automatic control of the greenhouse in the designed greenhouse prototype and front panels for the user to see the values taken from the sensors were created. For these, greenhouse roof control software, soil-moisture control software for irrigation, lighting control software, temperature control software for heating, ventilation control software, reporting software of moisture and temperature values in the air conditioning system, data communication software was made in LabVIEW program. Graphical programming block diagram is given in Figure 4.




Figure 4. Graphical programming block diagram.

3. RESULTS AND DISCUSSION

On the designed greenhouse automation prototype; the greenhouse roof control software, soil-moisture control software for irrigation, lighting control software, temperature control software for heating, ventilation control software, software for reporting moisture and temperature values in the air conditioning system, and the program have been tested on LabVIEW user interfaces. The LabVIEW interface of the designed system is given in Figure 5.

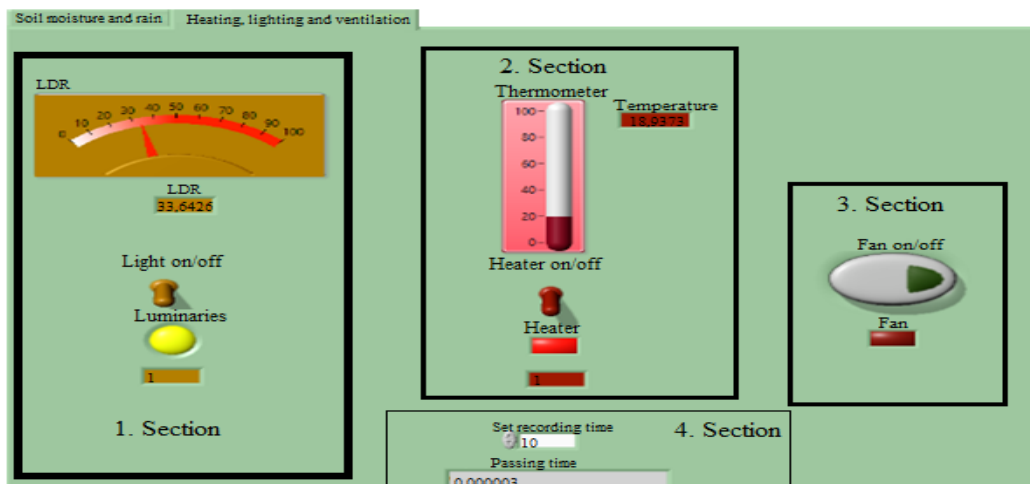


Figure 5. LabVIEW interface of the designed system.

In the LabVIEW user interface, it was tested whether the irrigation system was activated or not and the prototype greenhouse roof was opened and closed in rainy weather. During this process, it was observed that the servo motor rotates in the positive direction at an 90 degrees in the positive direction and leaves the roof open by detecting that it is not raining according to the value obtained from the rain sensor connected to the MyRIO control card. When it rained, it was observed that the servo motor turned 90 degrees in a negative direction and closed the greenhouse roof. Soil-moisture control and roof control experiment LabVIEW interface is given in Figure 6.




Figure 6. Soil-moisture control and roof control experiment LabVIEW interface.

It has been tested whether the water pump used for irrigation sends water from the water tank to the irrigation pipes. During this test, as can be seen in the figure above, the soil-moisture value was measured to be 77,6856 and it was observed that the greenhouse irrigation was performed (the moisture percentage limit value determined by the user in LabVIEW is 80). The values obtained by measuring the humidity values per hour for 12 hours from the soil-moisture sensor are given graphically in Figure 7.




Figure 7. Values taken from the soil-moisture sensor every hour for 12 hours.

It was observed that the water motor stopped the irrigation process with the order received from the MyRIO control card when the soil moisture percentage value within the scope of the 12-hour greenhouse soil moisture percentage values read from the soil-moisture sensor of the MyRIO card was 80.9863.

In the test of the lighting software part, the information received from the LDR sensor is received by MyRIO control card and the information received by it is evaluated according to the value specified in the LabVIEW and it is decided whether or not to illuminate. In the test for application control, the LDR sensor measured the illumination value as 33.6426. It has been observed that the measured value of the MyRIO control card is below the value determined by the user in LabVIEW and the greenhouse lighting is performed by commanding the white strip LEDs used in the study to perform the lighting operation (the value where the light measured from the LDR sensor is closest to the dark is 80). LED luminary have been used in lighting due to their savings, long life, lighting efficiency and low maintenance costs. For example, if 10 number incandescent luminaries were used instead of 10 number LED luminaries to be used, energy consumption would be higher. Incandescent and LED lamp comparison is given in Table 1.

When Table 1 is examined, in the case of using an incandescent lamp for the same number of luminaries with close luminous fluxes, 1000 W will be consumed, while in the case of LED luminaries 150 W will be consumed. In terms of energy efficiency, the use of LED luminary is very important in this respect. In addition, it has been observed that the inside of the greenhouse is illuminated from 23:00 to 06:00 according to the values read by the LDR sensor of the MyRIO control card at different times during the day. It was observed that the value (85,2789) detected by the MyRIO card through the LDR lighting sensor at 07:00, exceeded the value determined by the user in the LabVIEW program and exceeded the value of 80 where the darkness ended and the light

Table 1. Characteristics of the Luminaires.

Luminaire type	Power (W)	Luminous flux (lm)	Number of luminaire used (pc.)	Colour rendering index (CRI)	Total power (W)
Incandescent	100	1380	10	100	1000
LED	15	1521	10	80	150

started, so the lighting system was automatically deactivated with the command received from the MyRIO control card. Graph of values taken from the LDR sensor per hour is given in Figure 8.




Figure 8. Graph of values taken from the LDR sensor per hour.

A temperature test in the greenhouse has been carried out in the designed system. Here, MyRIO card has determined that the temperature inside the greenhouse from the LM35 temperature sensor is 18.9373 ° C and this value is between the lower-upper (15-30 ° C) limit value determined by the user in LabVIEW. For this reason, it has been observed that the heater is not activated. However, it was determined that when the temperature value was 13.6598 ° C, it was automatically activated with the command it received from the MyRIO control card. Temperature value and moisture percentage values are given in Figure 9.




Figure 9. Temperature value and moisture percentage values.

The ventilation process on the greenhouse prototype was tested in the program in the user interface. During this process, it was observed that the temperature value was at its normal value (18.9373 ° C) and therefore it was determined that the DC Fan was not activated.

4. CONCLUSIONS

The main objective of this study is to design and implement a remote access control and monitor system for greenhouse. Greenhouse system consists of many systems such as lighting, heating, irrigation control systems that controlled by LabVIEW software. This system was supported by remote control and connected to the internet to monitor and control the greenhouse equipment's from anywhere in the world using LabVIEW. In addition, it is aimed to bring the greenhouse automation application to the agricultural sector. For this purpose, the feasibility and usability of the study was tested on the designed greenhouse prototype. Various sensors were

placed in the greenhouse model to adjust the amount of moisture, temperature and light required for the plants to be grown in the greenhouse prototype, allowing it to be remotely controlled remotely via a computer tablet or mobile phone with the MyRIO control card and LabVIEW interface program. In terms of energy efficiency, the use of LED luminary is very important in this respect.

Remote access greenhouse automation application with MyRIO control card has several advantages. These are;

- The system designed with the MyRIO control card; it can be controlled remotely in real time with computers, tablets and smart mobile phones.
- Since the system is remotely accessible, it can be intervened when necessary.
- Since the infrared heater used in the heating system directly heats the plants in the greenhouse, the amount of heat needed by the plants can be obtained by consuming less energy, thus providing energy savings.
- Although the operations of the codes written using microprocessors/ microcontrollers and various electronic control cards are difficult to display by creating an interface to the user, the data is presented to the user easily on the front panel graphically thanks to the LabVIEW program we use in our study.
- The codes that are written in pages of computer programming languages can be easily written in the LabVIEW program we use in our work.
- Thanks to the LabVIEW graphical program used, the data obtained from the climate conditions in the greenhouse during the day can be reported in Excel, allowing the user to check the data again.

By using renewable energy sources (such as sun, biogas, geothermal resources, etc.) instead of traditional heating systems (such as stoves, radiators, etc.) in greenhouse heating, the damage to the environment can be reduced to even lower levels and the rate of global warming can be reduced since carbon-based fuel is not used.

In greenhouses, electrical energy is generally used in every part of the air conditioning system. Hence, the cost spent for energy increases. In order to prevent this, if the greenhouses to be established are established close to geothermal resources, the cost spent for energy in greenhouse heating can be reduced.

Author Contributions

The first author wrote and edited the article. The second author took part in the preparation and implementation of the prototype of the system. This study was produced from the second author's Master's Thesis conducted under the supervision of the first author.


Conflict of Interest

The authors of the article declare that there is no conflict of interest between them.

REFERENCES



- [1] R. R. Shamshiri, F. Kalantari, K. C. Ting, K. R. Thorp, I. A. Hameed, C. Weltzien, and et al. "Advances in greenhouse automation and controlled environment agriculture: A transition to plant factories and urban agriculture", *Int J Agric & Biol Eng*, vol. 11, no. 1, pp. 1-22, 2018.
- [2] R. L. Sumalan, N. Stroia, D. Moga, V. Muresan, A. Lodin, T. Vintila, and C. A. Popescu, "A Cost-Effective Embedded Platform for Greenhouse Environment Control and Remote Monitoring", *Agronomy*, vol. 10, no. 7, pp. 2-36, 2020.
- [3] P. Roop, K. V. Harish, U. Moin, "An Intelligent Wireless Sensor and Actuator Network System for Greenhouse Microenvironment Control and Assessment", *Journal of Biosystems Engineering*, vol. 42, no. 1, pp. 23-43, 2017.
- [4] Ö. Alpay and E. Erdem, "Climate Control of an Smart Greenhouse based on Android", 2018 International Conference on Artificial Intelligence and Data Processing (IDAP), pp. 1-5, 2018.
- [5] J. Oscar, A. Gustav, "Smart Greenhouse, A microcontroller based architecture for autonomous and remote control", A thesis submitted for the degree of B.Sc. Mechatronic Engineering, Halmstad University School of Information Technology, Halmstad, Sweden, 2020.
- [6] I. Lapyga, "Application of Light Sensors Amplifier and Wireless Networking Sensor for Ambient Light Data to the Android Platform", *International Journal of Recent Technology and Engineering (IJRTE)*, vol. 8, no. 3, pp. 930-935, 2019.
- [7] D. J. A. Rustia, L. C. Erh, J. Chung, Y. Zhuang, Y.-J., J.-C. Hsu, and T.-T. Lin, "Application of an Image and Environmental Sensor Network for Automated Greenhouse Insect Pest Monitoring", *Journal of Asia-Pacific Entomology*. vol. 23, no.1, pp. 17-28, 2019.
- [8] A. S. Wael, and A. Z Basem, "Evolution of microcontroller-based remote monitoring system applications", *International Journal of Electrical and Computer Engineering (IJECE)*. vol. 9, no. 4, pp. 2354-2364, 2019.
- [9] W. Cai, X. Wen, and Q. Tu, "Designing an intelligent greenhouse monitoring system based on the internet of things", *Applied Ecology And Environmental Research*, vol. 17, no. 4, pp. 8449-8464, 2019.
- [10] H. G. Eugen, and D. A. Gheorghe, "Greenhouse Environment Monitoring and Control: State of The Art And Current Trends", *Environmental Engineering and Management Journal*, vol. 17, no. 2, pp. 399-416, 2018.

- [11] I. E. H. Arfeen, and A. E. Suliman, “Real-Time Monitoring for Data Greenhouse Based on Raspberry Pi Technology”, *Open Access Library Journal*, vol. 6, no. 3, pp. 1-8, 2019.
- [12] E. Iddio, L. Wang, Y. Thomas, G. McMorro, and A. Denzer, “Energy efficient operation and modeling for greenhouses: A literature review”, *Renewable and Sustainable Energy Reviews*, vol. 117, 109480, pp. 1-15, 2020.
- [13] M. Taki., M. S. Abdanan, A. Rohani, M. Rahnama, and M. Rahmati-Joneidabad, “Applied machine learning in greenhouse simulation; New application and analysis”, *Information Processing In Agriculture* vol. 5, pp. 253–268, 2018.
- [14] D. Ma, N. Carpenter, S. Amatya, H. Maki, L. Wang, L. Zhang, and J. Jin, “Removal of greenhouse microclimate heterogeneity with conveyor system for indoor phenotyping”, *Computers and Electronics in Agriculture*, vol. 166, pp. 1-9, 2019.
- [15] Ö. Alpay, and E. Erdem, “The Control of Greenhouses Based on Fuzzy Logic Using Wireless Sensor Networks”, *International Journal of Computational Intelligence Systems*, vol. 12, no. 1, pp. 190-203, 2019.
- [16] C. M. Angelopoulos, G. Filios, S. Nikolettseas, and T. P. Raptis, “Keeping Data at the Edge of Smart Irrigation Networks: A Case Study in Strawberry Greenhouses”, *Computer Networks*, 107039, pp.1-10, 2019.
- [17] Š. Koprda, M. Magdin, and M. Munk, “Implementation of microcontroller arduino in irrigation system,” in *Lecture Notes in Computer Science*, vol. 9771, pp. 133–144, 2016.
- [18] M. A. Akkaş, and R. Sokullu, “An IoT-based greenhouse monitoring system with Micaz motes”, *Procedia Computer Science*, vol. 113, pp. 603–608, 2017.
- [19] J. Li, “Design and Realization of Greenhouse Sensor Intelligent Management System Based on Internet of Things”, *International Journal of Online Engineering (iJOE)*, vol. 13, no. 5, pp. 80-96, 2017.
- [20] C. Cai, H. Liu, and W. Yang, “Design and Development of a Greenhouse Remote Monitoring System Based on WinCE”. *Meteorological and Environmental Research*, vol. 9, no. 4, pp. 106-111, 2018.
- [21] I. George, V. Gheorghe, I. Filip, B. Marian, V. Marian, and M. Eugen, “Natural Ambient Light Monitoring In Greenhouses With Polyethylene Film Roof”, *Engineering Hunedoara – International Journal of Engineering Tome XV*, vol. 3 pp. 197-203, 2017.
- [22] J. Xu, F. Dai, Y. Xu, C. Yao, and C. Li, “Wireless power supply technology for uniform magnetic field of intelligent greenhouse sensors”. *Computers and Electronics in Agriculture*, vol. 156, pp. 203–208, 2019.
- [23] B. Kocaman, and S. Rüstemli, “Comparison of LED and HPS luminaires in Terms of Energy Savings at Tunnel Lighting”, *Light and Engineering*, vol. 27, no. 3, pp. 67–74, 2019.
- [24] B. Kocaman, “Energy Efficiency in Lighting for Historical Buildings: Case Study of The El Aman Caravanserai in Province of Bitlis”, *Turkey, Light and Engineering*, vol. 28, no. 4, pp. 68–76, 2020.
- [25] S. Rustemli, and Y. Demir, “Сравнительный анализ ламп в осветительных установках дорожного освещения. Журнал” *«Светотехника»* no. 4, pp.56-62, 2021.
- [26] S. B. Efe, and D. Varhan, “Interior Lighting of A Historical Building By Using Led Luminaires: A Case Study of Fatih Paşa Mosque”, *Light and Engineering*, vol. 28, no. 4, pp. 77–83, 2020.
- [27] S. Rustemli, and Y. Demir, “Comparative Analysis of Lighting Installations Used In Road Illumination”, *Light & Engineering*, vol. 29, no. 6, pp. 86–94, 2021.



Synthesis of Linear Antenna Arrays with Physics Based AOA, CryStAl and LA Algorithms

Lineer Anten Dizilerinin Fizik Tabanlı AOA, CryStAl ve LA Algoritmaları ile Sentezi

¹Ali DURMUS , ²Zafer YILDIRIM 

¹Department of Electricity and Energy, Vocational School of Technical Sciences, Kayseri University, Kayseri, Türkiye

²Faculty of Engineering Architecture and Design, Electrical Electronics Engineering, Kayseri University, Kayseri Türkiye

¹alidurmus@kayseri.edu.tr, ²zyldrm038@gmail.com

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 23 May 2022

Accepted : 30 July 2022

Keywords:

Linear Antenna Array Synthesis, Archimedes Optimization Algorithm, Crystal Structure Algorithm, Lichtenberg Algorithm

ABSTRACT

In this article, 10, 16, and 24-Element of Linear Antenna Arrays (LAAs) synthesis are carried out with 3 different novel physics-based metaheuristic methods. These methods are called Archimedes Optimization Algorithm (AOA), Crystal Structure Algorithm (CryStAl), and Lichtenberg Algorithm (LA). While performing the LAA synthesis, Half Power Beam Width (HPBW), which is related to the directivity of the antenna, is also taken into account. The methods proposed in this study are run independently 30 times to obtain the statistical values of LAA synthesis. The minimum, maximum, median, and standard deviation values of the SLL and HPBW of the radiation patterns obtained as a result of these runs are tabulated. The performances of these three proposed novel physics-based optimization methods are given comparatively. In all simulation studies, the CryStAl method generally showed the best performance.

© 2022 Bandırma Onyediy Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 23 Mayıs 2022

Kabul : 30 Temmuz 2022

Anahtar Kelimeler:

Lineer Anten Dizi Sentezi, Arşimet Optimizasyon Algoritması, Kristal Yapı Algoritması, Lichtenberg Algoritması

ÖZET

Bu makalede 10, 16, ve 24 elemanlı Doğrusal Anten Dizi (Linear Antenna Array-LAA) sentezi literatüre yeni kazandırılmış 3 farklı fizik tabanlı metasezgisel yöntemle gerçekleştirilmiştir. Bu yöntemler Arşimet Optimizasyon Algoritması (AOA), Kristal Yapı Algoritması (CryStAl) ve Lichtenberg Algoritması (LA) olarak isimlendirilirler. LAA sentezi gerçekleştirilirken aynı zamanda antenin yönelticiliği ile ilgili olan Yarı Demet Güç Genişliği (HPBW)'de göz önüne alınmıştır. Bu çalışmada önerilen metotlar, LAA sentezinin istatistiksel değerlerini alabilmek için 30 defa bağımsız olarak koşurulmuştur. Bu koşurmalar neticesinde elde edilen ışınma diyagramlarına ait SLL ve HPBW değerlerinin minimum, maksimum, ortalama ve standart sapma değerleri tablanmıştır. Önerilen 3 yeni fizik tabanlı optimizasyon metotlarının performansları karşılaştırmalı olarak verilmiştir. Yapılan tüm simülasyon çalışmalarında genellikle CryStAl metodu en iyi performansı göstermiştir.

© 2022 Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Dergi Park tarafından yayımlanmaktadır. Tüm Hakları Saklıdır.

1. INTRODUCTION

Different problems occur in nature constantly and at the same time, nature, which is the biggest problem solver, constantly produces solutions to these problems in order to preserve its existence. There are many physical laws in nature to solve problems and keep the ecosystem functioning. Many technologies have been developed using the existing laws of physics and continue to be developed. Realizing the ability to find the solution found in the laws of physics, some researchers developed new artificial intelligence methods inspired by some physics laws to solve extremely complex problems.

Basically, algorithms inspired by the laws of physics are simply called [1-4]. We can classify algorithms inspired by the laws of physics as follows. There are many different optimization methods that have emerged with different theorems of physics. These are Charged System Search inspired by Coulomb's and Newton's laws [5]; Gravitational Search Algorithm explaining the theory of gravity [6]; Henry Gas Solubility Optimization based on Henry's law [7]; Sine-Cosine Algorithm using trigonometric functions and fractals [8]; Thermal Exchange Optimization inspired by Newton's Cooling laws [9]; Lightning Search Algorithm developed based on step leader propagation mechanism using the lightning phenomenon found in nature [10]; Magnetic Optimization algorithm created by formulating magnetic force laws [11]; Electromagnetic Field Optimization based on the mathematical formula of electromagnetic physics law known as Biot-Savart [12]; They are Ion Motion Optimization methods of ions formed based on the repulsion and attraction law of electromagnets [13]. As mentioned, physics-based algorithms are quite diverse and there are many studies in the literature using physics-based algorithms [1-13]. Considering these studies, physics-based algorithms have the ability to cope with difficult problems. In order to achieve high efficiency in antennas, they must be optimized with optimization methods that overcome difficult problems. In addition, in order to increase the efficiency of the antennas, it is necessary to form antenna arrays by combining more than one antenna [14]. Antenna array synthesis is a very challenging problem in the field of computational electromagnetics. The names of the antenna arrays change according to the geometric structures of the antennas [15]. Antenna arrays in which the elements are arranged on a linear structure are called Linear Antenna Arrays (LAAs). LAAs have ease of application thanks to their flat structure. Due to this convenience, there are many studies with LAAs in the literature. Contrary to the ease of implementation, since many parameters such as position, amplitude, and phase need to be optimized, the solution of the problem is quite difficult and algorithms with the ability to cope with difficult problems are preferred for optimizing LAA [16].

In this study, LAAs with 10, 16, and 24-Element are optimized. Three novel physics-based algorithms, which are called Archimedes Optimization Algorithm (AOA), Crystal Structure Algorithm (CryStAl), and Lichtenberg Algorithm (LA) are used to determine amplitudes values of LAAs in the optimization process. To the best of our knowledge, these physics-based methods have been applied to LAA for the first time. After 30 independent runs, median, max, min, and standard deviation values of SLL, and HPBW are obtained. The results obtained using these data are presented in a comparative way.

In the rest of the study, detailed information about the problem formulation is given in Section 2. The physics-based algorithms used are explained in Section 3. A comparative presentation of the obtained results is given in Section 4. Finally, inferences made from the conclusions are given in Section 5.

2. PROBLEM FORMULATION

The geometry of the LAA is given in Figure 1. LAA elements arranged in a linear x-axis plane are positioned equidistant from each other on both arms of the axis. LAA elements are arranged on both sides of the starting point as M pieces, a total of $2M$ pieces [15].




Figure 1. The geometry of LAA.

Array factor of LAA is given in the following equations:

$$AF(\varphi) = 2 \sum_{m=1}^M I_m \cos [kd_m \cos(\varphi) + \varphi_m] \quad (1)$$

where, the excitation amplitude, phase, and position weight of the m th element in the array are represented by I_m , φ_m , and d_m respectively. The wavenumber is represented by the scanning angle k , which is written as $k = \frac{2\pi}{\lambda}$.

The LAA has a total of $2M$ elements, however, because these LAA are symmetrical, the parameter to be optimized is half of the total number of antennas, M . Cost function (CF) is also needed to integrate the antenna array's formula into metaheuristic algorithms. CF is shown below:

$$CF = WF_{SLL} \cdot F_{SLL} + WF_{HPBW} \cdot F_{HPBW} \quad (2)$$

where WF_{SLL} and WF_{HPBW} are the CF 's weight factors. The functions F_{SLL} and F_{HPBW} are utilized to narrow HPBW and suppress SLL values, respectively.

3. ALGORITHMS

3.1. Archimedes Optimization Algorithm

AOA is discovered by Hashim et al, inspired by the buoyancy of fluids [2]. In this algorithm, firstly, an imaginary object is dropped into the water. The dropped object may be floating or submerged in water. AOA tries to find the optimum value by trying to keep the object in balance above the water. This algorithm basically has two items. The first is a fluid substance and the second is a solid body. When the solid body is released into the fluid, it is floating if it weighs no more than the weight of the fluid. In the opposite situation, it will travel into the fluid until it reaches the equilibrium state. In other words, the object has a force in the water. It is necessary to reduce this force to zero and to keep it in balance by keeping this force constant at 0. There are some necessary parameters to ensure this. AOA uses three parameters to optimize this object. These are volume, density, and acceleration. here v is the volume, p is the density, a is acceleration, and the subscripts b and o , respectively, stand for fluid and submerged object. This equation may be written as follows:

$$a_0 = \frac{p_b v_b a_b}{p_o v_o} \quad (3)$$

The search strategy of AOA algorithm is explained in Figure 2.




Figure 2. The search strategy of AOA.

3.2. Crystal Structure Algorithm

The CryStAl algorithm is created, inspired by the method of adding basis to the lattice points, which is the principle underlying the formation of crystals such as pure quartz [17]. A "lattice," which displays a periodic array of points in predetermined areas but is incapable of describing the precise placements of atoms in the material, is the underlying component of a crystal. It is created by transforming the physics into an algorithm under the formation of the quartz crystal. CryStAl is created by S. Talathari et al. There are many crystal models. Here, the researchers are inspired by the model called Bravais model. The Bravais model is used to construct crystal configurations in this article since a mathematical representation of these characteristics is needed for numerical research. A periodic crystal structure is constructed in the Bravais model by considering an infinite lattice shape in which every lattice point is specified by the position of their lattice point as a vector. It is formulated as:

$$r = \sum n_i a_i \quad (4)$$

where n_i is the number of crystal corners, a_i is the shortest vector along with the primary crystallographic directions, and i is the number of crystal corners. The search strategy of the CryStAl algorithm is showed in Figure 3.

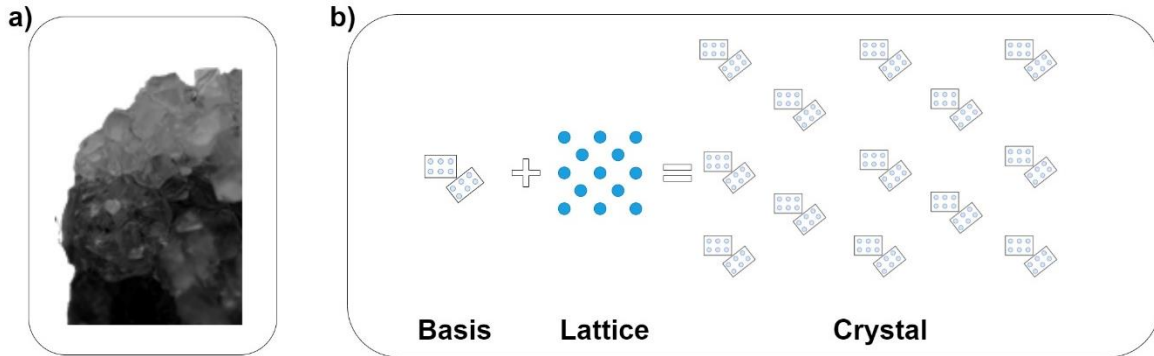


Figure 3. The search strategy of CryStAl.

3.3. Lichtenberg Algorithm

The Diffusion Limited Aggregation (DLA) theory served as the numerical foundation for the algorithm's creation. The Lichtenberg Figure (LF) is based on the model published by Witten and Sander. The LA algorithm authors are inspired by the DLA [18]. DLA has a Matrix of 0s and 1s that is formed like a map, with a particle, identified by the number one, positioned in the middle. The cluster is made up of one-valued matrix values, and vacant spaces having 0 values. Each matrix element with the value one represents a cluster particle, and the number of them in the cluster (N_c) is specified at the start of the program. The creation radius (R_c) defines the space in which the figure is built, and it is used to build a matrix with line and column numbers equal to twice R_c (diameter). Its mathematical form is as in the following equation:

$$D = \frac{\ln(N_{cluster})}{\ln(R_{cluster})} \quad (5)$$

The search strategy of the LA algorithm is illustrated in Figure 4.




Figure 4. The search strategy of LA.

4. NUMERICAL RESULTS

In this work, three distinct novel physic-based metaheuristic optimization approaches are utilized to construct symmetric LAAs with 10, 16, and 24-Element. The main aim of this synthesis is to maintain HPBW values stable or as narrow as possible while suppressing SLL values. AOA, CryStAl, and LA optimization techniques are utilized to identify the optimum amplitudes of the antenna array elements, and 30 independent runs are performed to assess their performance. Simulations are performed utilizing MATLAB software on a personal computer with 16 GB RAM and an i7 CPU. SLL values are given in “dB” and HPBW values are given in “°”.

4.1. Case 1. LAA with 10-Element

The amplitudes for the symmetric LAA with 10-Element are found in the first example by performing the optimal array design utilizing AOA, CryStAl, and LA. Table 1 shows a statistical comparison of AOA, CryStAl, and LA methods in terms of SLL and HPBW.

Table 1. Comparative result of 10-Element LAA.

10-Element	SLL _{min}	SLL _{med.}	SLL _{max}	SLL _{std}	HPBW _{min}	HPBW _{med.}	HPBW _{max}	HPBW _{std}
	AOA	-26.9772	-26.9768	-26.9677	0.0019	12.5000	12.5000	12.5000
CryStAl	-26.9772	-26.9772	-26.9772	0.0000	12.5000	12.5000	12.5000	0.00000087
LA	-26.9755	-26.9610	-26.9171	0.0146	12.4983	12.4998	12.5000	0.0004

CryStAl achieved the best SLL based on the values given in Table 1. When HPBW values are examined, there is no noticeable difference between algorithms. When the CPU time values are examined according to the standard deviation, the most stable algorithm is LA with 0.778 seconds. The amplitude values of the best SLL value results are given in Table 2.

Table 2. Amplitude values of LAA with 10-Element.

10-Element	AOA	0.2169	0.1932	0.1518	0.1028	0.0719
	CryStAl	0.6342	0.5649	0.4440	0.3007	0.2102
	LA	0.8340	0.7430	0.5840	0.3955	0.2765

Each algorithm spent CPU time while obtaining the median value. The algorithm that consumes the least CPU time is AOA with 13.073 seconds. The radiation patterns created by these values using the amplitude values given in Table 2 are shown in Figure 5.

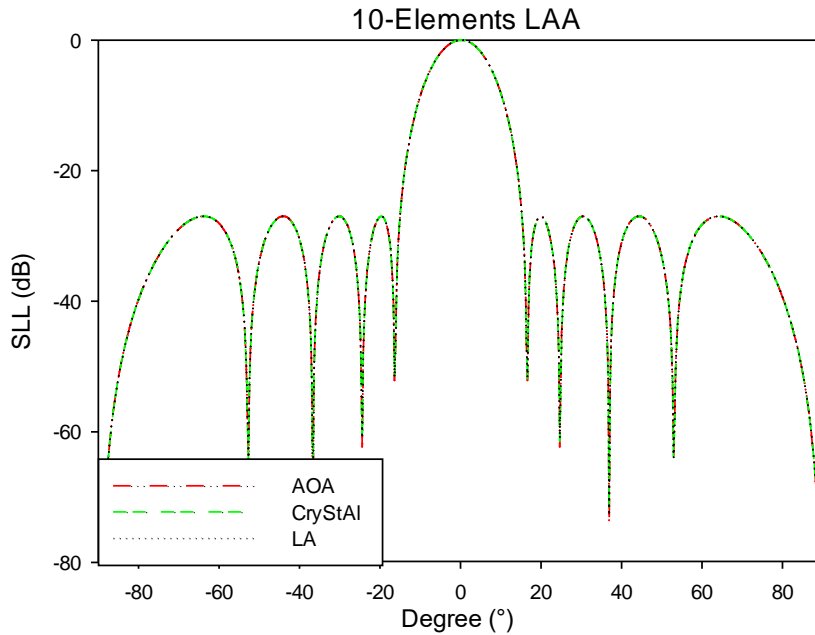


Figure 5. The radiation pattern for LAA with 10-Element.

There is no difference in the radiation pattern of the sequence of 10-Element LAA in Figure 5 since all algorithms reach almost the same SLL value.

The algorithm with the fastest approach curve has been the LA algorithm. It is clearly seen in Figure 6 that AOA does not have a good convergence curve of 10-Element LAA.

4.2. Case 2. LAA with 16-Element

Comparative results of 16-Element LAAs are tabulated in Table 3. The values given in Table 3 are presented with various data such as standard deviation, minimum and maximum values of SLL an HPBW.




Figure 6. Convergence curve of LAA with 10-Element.

Table 3. Comparative result of LAA with 16-Element.

	SLL _{min}	SLL _{med.}	SLL _{max}	SLL _{std}	HPBW _{min}	HPBW _{med.}	HPBW _{max}	HPBW _{std}
16-Element AOA	-40.2374	-36.7346	-28.1659	3.1819	8.7221	8.9562	9.0000	0.0852
CryStAl	-40.2423	-40.2209	-40.2027	0.0094	8.9985	8.9994	8.9999	0.0004
LA	-40.2083	-39.2288	-37.5938	0.7255	8.9962	8.9989	8.9999	0.0011

When the values shown in Table 3 are compared, the algorithm with the best SLL value is the CryStAl algorithm. According to the standard deviation, the least scattering algorithm is the CryStAl algorithm. HPBW values are very close to each other. The most stable algorithm in terms of CPU time has been the LA with 0.121 seconds. Table 4 showed the amplitude value of the best SLL achieved.

Table 4. Amplitude values of LAA with 16-Element.

16-Element	AOA	0.2223	0.2078	0.1812	0.1466	0.1090	0.0732	0.0432	0.0248
	CryStAl	0.6527	0.6102	0.5321	0.4305	0.3200	0.2151	0.1267	0.0727
	LA	0.5826	0.5446	0.4751	0.3843	0.2856	0.1921	0.1132	0.0649

For the median of the 16-Element LAA, the fastest algorithm to arrive at the result is AOA with 16.796 seconds. Table 4 shows the amplitude values of LAA with 16-Element obtained by algorithms. The 2-Dimension radiation pattern obtained using these amplitudes is shown in Figure 7.




Figure 7. The radiation pattern for LAA with 16-Element.

The convergence curve of the algorithms when obtaining the 16-Element LAA is given in Figure 8.




Figure 8. The convergence curve of LAA with 16-Element.

Examining the convergence curve of 16-Element LAA, AOA has a very bad convergence curve. The algorithm with the best convergence curve of 16-Element LAA is CryStAl.

4.3. Case 3. LAA with 24-Element

Compared to the results obtained, there is no noticeable difference in the 16-Element LAA, which is an easier problem than the 24-Element LAA. Comparative results for LAA with 24-Element are tabulated in Table 5.

Table 5. Comparative result of 24-Element LAA.

	SLL _{min}	SLL _{med.}	SLL _{max}	SLL _{std}	HPBW _{min}	HPBW _{med.}	HPBW _{max}	HPBW _{std}
24-Element AOA	-38.9896	-33.2765	-25.7744	3.2153	5.5013	5.8552	5.9999	0.1779
24-Element CryStAl	-40.8412	-40.0569	-36.6468	1.0083	5.9719	5.9956	6.0000	0.0070
24-Element LA	-40.2575	-38.9898	-37.2272	0.8543	5.9857	5.9973	6.0000	0.0038

According to Table 5, the algorithm that reaches the best values is CryStAl. In addition, the best algorithm in terms of the standard deviation of SLL is the LA algorithm. The HPBW values for all algorithms had almost the same values. When the CPU time values are examined, the algorithm with the best standard deviation value is the AOA with 0.110 seconds. The Amplitude values obtained by the algorithms while reaching the best values are given in Table 6.

Table 6. Amplitude values of 24-Element LAA.

24-Element	AOA	0.0815	0.0787	0.0741	0.0678	0.0593	0.0499	0.0417	0.0325	0.0229	0.0181	0.0117	0.0092
	CryStAl	0.7921	0.7728	0.7214	0.6651	0.5793	0.5014	0.4060	0.3203	0.2411	0.1652	0.1145	0.0839
	LA	0.7990	0.7731	0.7401	0.6649	0.5888	0.5023	0.4049	0.3358	0.2385	0.1698	0.1138	0.0829

By processing these values, a radiation pattern is obtained for the 24-Element LAA. When the median values are compared according to the CPU time, the AOA with 24.120 seconds has the best value. The radiation pattern of the algorithms obtained LAA with 24-Element is shown in Figure 9.

As can be clearly seen from Figure 9, the algorithm that obtained the best radiation pattern is the CryStAl algorithm. The convergence curves of the algorithms are plotted in Figure 10.

When the convergence curve of 24-Element LAA is examined, the fastest converging algorithm is LA. The algorithm that achieves the best results is CryStAl. The algorithm with the worst convergence curve of 24-Element LAA and the worst result is AOA.




Figure 9. The radiation pattern for LAA with 24-Element.




Figure 10. Convergence curve of LAA with 24-Element.

5. CONCLUSIONS

In this study, the AOA, CryStAl, and LA are applied to optimize amplitude values of the 10, 16, and 24-Element LAAs. The main purpose of this study is to test the performance of novel physics-based algorithms in synthesizing LAA. These three proposed new physics-based metaheuristic optimization methods have been applied to LAA synthesis for the first time according to the literature study we have done. In all simulations, HPBW is kept constant, and SLL is tried to be reduced to the minimum value. HPBW values during this process are determined as 12.5°, 9°, and 6° for 10, 16, and 24-Element LAA, respectively. The algorithm that achieves the best SLL median value in all LAA simulations is CryStAl. When examined in terms of the standard deviation of SLL, the method that reached the best value for the 10 and 16-Element LAA is CryStAl. In the 24-Element LAA synthesis, the LA method reached its value with the least scattering. When all cases are examined in terms of CPU time, even if the algorithm that reaches the fastest result is AOA, it is insufficient in terms of obtaining a good result. Novel physics-based optimization methods can be used in future work to solve different antenna arrays and other computational electromagnetic problems.

Author Contributions

Each author contributed an equal amount to the study.

Conflict of Interest

There is no conflict of interest between the article authors.

Acknowledgements

This work was supported by the Kayseri University Scientific Research Projects Coordination Unit (Project No: FLY-2021-1050)


REFERENCES

- [1] A. Kaveh, H. Akbari, and S. M. J. E. C. Hosseini, "Plasma generation optimization: a new physically-based metaheuristic algorithm for solving constrained optimization problems", *Engineering Computations*, vol. 38, no. 4, pp. 1554-1606, 2020.
- [2] F. A. Hashim, K. Hussain, E. H. Houssein, M. S. Mabrouk, and W. J. A. I. Al-Atabany, "Archimedes optimization algorithm: a new metaheuristic algorithm for solving optimization problems", *Applied Intelligence*, vol. 51, no. 3, pp. 1531-1551, 2021.
- [3] M. H. Qais, H. M. Hasanien, and S. J. A. I. Alghuwainem, "Transient search optimization: A new meta-heuristic optimization algorithm", *Applied Intelligence*, vol. 50, no. 11, pp. 3926-3941, 2020.
- [4] H. Shayanfar and F. S. J. A. S. C. Gharehchopogh, "Farmland fertility: A new metaheuristic algorithm for solving continuous optimization problems", *Applied Soft Computing*, vol. 71, pp. 728-746, 2018.
- [5] A. Kaveh and S. J. A. M. Talatahari, "A novel heuristic optimization method: charged system search", *Acta Mechanica*, vol. 213, no. 3, pp. 267-289, 2010.
- [6] E. Rashedi, H. Nezamabadi-Pour, and S. J. I. S. Saryazdi, "GSA: a gravitational search algorithm", *Information Sciences*, vol. 179, no. 13, pp. 2232-2248, 2009.
- [7] F. A. Hashim, E. H. Houssein, M. S. Mabrouk, W. Al-Atabany, and S. J. F. G. C. S. Mirjalili, "Henry gas solubility optimization: A novel physics-based algorithm", *Future Generation Computer Systems*, vol. 101, pp. 646-667, 2019.
- [8] S. J. K.-B. S. Mirjalili, "SCA: a sine cosine algorithm for solving optimization problems", *Knowledge-Based Systems*, vol. 96, pp. 120-133, 2016.
- [9] A. Kaveh and A. J. A. I. E. S. Dadras, "A novel meta-heuristic optimization algorithm: thermal exchange optimization", *Advances in Engineering Software*, vol. 110, pp. 69-84, 2017.
- [10] H. Shareef, A. A. Ibrahim, and A. H. J. A. S. C. Mutlag, "Lightning search algorithm", *Applied Soft Computing*, vol. 36, pp. 315-333, 2015.
- [11] M.-H. Tayarani-N and M. Akbarzadeh-T, "Magnetic optimization algorithms a new synthesis," in 2008 IEEE Congress on Evolutionary Computation (IEEE World Congress on Computational Intelligence). pp. 2659-2664, IEEE, 2008.
- [12] H. Abedinpourshotorban, S. M. Shamsuddin, Z. Beheshti, D. N. J. S. Jawawi, and E. Computation, "Electromagnetic field optimization: a physics-inspired metaheuristic optimization algorithm", *Swarm and Evolutionary Computation*, vol. 26, pp. 8-22, 2016.
- [13] M.-J. Wang, J.-S. Pan, T.-k. Dao, and T.-G. Ngo, "A load economic dispatch based on ion motion optimization algorithm", *Advances in Intelligent Information Hiding and Multimedia Signal Processing*, pp. 115-125, Springer, 2020.
- [14] A. Durmus, R. Kurban, and E. J. J. O. C. E. Karakose, "A comparison of swarm-based optimization algorithms in linear antenna array synthesis", *Journal of Computational Electronics*, vol. 20, no. 4, pp. 1520-1531, 2021.
- [15] C. A. J. A. T. Balanis, "Fundamental parameters of antennas", *Analysis and Design*, pp. 28-102, 1997.
- [16] A. Durmus, R. J. I. J. O. M. Kurban, and W. Technologies, "Optimum design of linear and circular antenna arrays using equilibrium optimization algorithm", *International Journal of Microwave and Wireless Technologies*, vol. 13, no. 9, pp. 986-997, 2021.
- [17] S. Talatahari, M. Azizi, M. Tolouei, B. Talatahari, and P. J. I. A. Sareh, "Crystal structure algorithm (CryStAl): a metaheuristic optimization method", *IEEE Access*, vol. 9, pp. 71244-71261, 2021.
- [18] J. L. J. Pereira, M. B. Francisco, C. A. Diniz, G. A. Oliver, S. S. Cunha Jr, and G. F. J. E. S. W. A. Gomes, "Lichtenberg algorithm: A novel hybrid physics-based meta-heuristic for global optimization", *Expert Systems with Applications*, vol. 170, pp. 114522, 2021.



BMBAD
BJESR

Mühendislik Bilimleri ve Araştırmaları Dergisi
Journal of Engineering Sciences and Researches



Farklı Cüruf Türlerinden Geopolimer Harç Üretimi

Production of Geopolymer Mortar from Different Slag Types

¹Şinasi BİNGÖL 

¹Tokat Gaziosmanpaşa Üniversitesi, Mühendislik ve Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, Tokat, Türkiye

sinasi.bingol@gop.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 26 May 2022

Accepted : 4 July 2022

Keywords:

Blast Furnace Slag, Steel Slag, Geopolymer Mortar, Compressive Strength

ABSTRACT

In this study, it is tried to obtain a more environmentally friendly binder instead of cement by using two waste materials, Blast furnace slag (BFS) and Steel mill slag (SMS). For this purpose, geopolymer mortars were produced by using different ratios of BFS and SMS. The slags were used as 80% BFS+ 20% SMS and 60% BFS+ 40% SMS as a substitute for cement. For the activation of slag mortars, sodium silicate (Na_2SiO_3) was used, containing 3%, 5%, 7.5% and 9% sodium of the binder amount. In addition, control mortars were produced with Portland cement (CEM I 42.5 R). The produced samples were cured in water at 21 ± 2 °C for 7 and 28 days and their ultrasonic pulse velocities, flexural and compressive strengths were determined. The test results of geopolymer mortars and control mortars were compared. With BFS and SMS, it is aimed to produce a more economical and environmentally friendly binder material compared to Normal Portland cement.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 26 Mayıs 2022

Kabul : 4 Temmuz 2022

Anahtar Kelimeler:

Yüksek Fırın Cürufu, Çelikhane Cürufu, Geopolimer Harç, Basınç Dayanımı

ÖZET

Bu çalışmada, iki atık malzeme olan Yüksek fırın cürufu (YFC) ve Çelikhane cürufu (ÇC) kullanılarak çimento yerine daha çevre dostu bir bağlayıcı elde edilmeye çalışılmaktadır. Bu amaçla, YFC ve ÇC farklı oranlarda kullanılarak geopolimer harçlar üretilmiştir. Cürufular, %80 YFC+ %20 ÇC ve %60 YFC+ %40 ÇC olacak şekilde çimento yerine ikame edilerek kullanılmıştır. Cürufulu harçların aktivasyonu için, bağlayıcı miktarının %3, %5, %7.5 ve %9'u oranında sodyum içerecek şekilde sodyum silikat (Na_2SiO_3) kullanılmıştır. Ayrıca Portland çimentosuyla (CEM I 42.5 R) kontrol harçları üretilmiştir. Üretilen numuneler, 7 ve 28 gün 21 ± 2 °C suda kür edilerek, ultrases geçiş hızları, eğilme ve basınç dayanımları belirlenmiştir. Geopolimer harçların ve kontrol harçlarının deney sonuçları karşılaştırılmıştır. YFC ve ÇC ile Normal Portland çimentosuna göre daha ekonomik ve çevre dostu bir bağlayıcı malzeme üretilmesi amaçlanmaktadır.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Beton yıllık 20 milyon tondan fazla üretimi ile dünya üzerinde sudan sonra en çok kullanılan malzemedir [1]. Portland çimentosu betonun bağlayıcı yapısını oluşturan matristir. Çimentonun üretimi sırasında, dünya genelindeki enerji tüketiminin yaklaşık %3'ü harcanmaktadır [2]. Ayrıca üretim esnasında çok yüksek oranda CO₂ salınımı gerçekleşmektedir. Dünya genelindeki CO₂'nin %5-7'si çimento üretiminden kaynaklanmaktadır [3]. Yüksek emisyonlar ve enerji tüketimi nedeniyle, Portland çimento endüstrisi iklim değişikliğinin ana nedenlerinden biri olarak kabul edilmektedir ve genel küresel ısınmanın yaklaşık %65'ine katkıda bulunmaktadır [4].

Çimentonun çevreye verdiği zarar ve maliyetinin çok yüksek olması yeni bağlayıcı malzeme arayışlarını zorunlu hale getirmektedir. Geopolimerler, çimento yerine üretilen ve araştırılan yeni nesil bağlayıcı malzemelerdir. Alümina silikat temelli yüksek fırın cürufu, uçucu kül, metakaolin ve silis dumanı gibi atık malzemeler alkali aktivatörlerle aktive edilerek bağlayıcı özellik kazandırılmaktadır. Atık malzemelerin kullanımıyla, biriken malzeme azaltılmakta ve ekonomiye kazandırılmaktadır. Ayrıca atmosfere salınan CO₂ %26-45 oranında azalmaktadır [5,6,7]. Ekonomiye ve çevreye sağladığı olumlu etkiler göz önüne alındığında, geopolimer harçlar ve betonlarla ilgili çalışmalar giderek yaygınlaşmaktadır. Farklı türden puzolanlar farklı aktivatörlerle denemekte ve çimento yerine kullanılacak malzemeler elde edilmektedir.

Açıkkapı vd., %4, %6, %8, %10 ve %12 oranlarında Na₂SiO₃ kullanarak çelikhane cürufuyla geopolimer harçlar üretmiştir. Üretilen harçları farklı kür koşullarında bekleterek dayanım gelişimlerini izlemişlerdir. %6 sodyum içeriğine sahip harçlarda 22 MPa basınç dayanımı elde etmişlerdir. Çelikhane cürufunun literatürde genel olarak agrega ve zemin stabilizasyon malzemesi olmasının yanında, geopolimer harçlarda bağlayıcı özellik de gösterebileceğini ifade etmektedirler [8]. Guo vd., çelikhane cürufunu ince agrega olarak %0, %10, %20, %30 ve %40 oranlarında betonda kullanmış, statik ve dinamik basınç dayanımına etkilerini araştırmışlardır. %20 oranında çelikhane cürufu katkısının optimum sonuçları verdiğini belirlemişlerdir [9].

Yüksek fırın cürufuyla yapılan çalışmalarda elde edilen sonuçlara göre, cürufu geopolimer harçların çimentolu harçlara nazaran daha yüksek dayanım ve dayanıklılık gösterdiği belirlenmiştir. El-Didamony vd., Bilim vd. çalışmalarında çimento yerine yüksek fırın cürufu kullanarak geopolimer harçlar üretmişlerdir. Geopolimer harçların çimentolu ve çimento-cüruf karışımı harçlara kıyasla daha iyi dayanım gösterdiğini belirlemişlerdir [10,11].

Bu çalışma kapsamında, YFC ve ÇÇ farklı oranlarda çimento yerine ikame edilerek geopolimer harçlar üretilmiştir. Üretilen harçların 7 ve 28 günlük basınç dayanımları belirlenerek Portland çimentosunun 7 ve 28 günlük dayanımlarıyla mukayese edilmiştir. Ayrıca geopolimer harçlara ve Portland çimentolu harçlara ultrases geçiş hızı deneyi uygulanmıştır. Geçiş hızları m/s cinsinden belirlenerek dayanım değerleriyle ilişkisi incelenmiştir.

YFC geopolimer harç teknolojisinde uzun yıllardır kullanılmaktadır. Ancak ÇÇ geopolimer harçlar için henüz yeni bir malzemedir. Bu nedenle iki malzemenin birlikte kullanılarak yeni bir bağlayıcı ürün ortaya çıkarılması amaçlanmaktadır. ÇÇ'nun da atık malzeme olarak değerlendirilerek ekonomiye kazandırılması ve çevresel zararların azaltılması yönünde katkı sağlaması hedeflenmektedir. Yapılan deneysel çalışmalar bu amaçlarla yapılmış ve daha çevre dostu bir bağlayıcı malzeme ortaya çıkarılmaya çalışılmıştır.

2. MATERYAL VE METOT

2.1. Materyal

2.1.1. Çimento

Bu çalışmada kullanılan çimento, EN 197-1'e [12] uygun normal Portland çimentosu (CEM I 42.5 R) olup, Tokat Adoçim Çimento Beton San. ve Tic. A.Ş tarafından üretilmiştir. Çimentoya ait kimyasal özellikler Tablo 1'de ve kullanılan çimento Şekil 1'de verilmiştir.

Tablo 1. Portland çimentosunun kimyasal içeriği.

Oksit (%)	CEM I 42.5 R
SiO ₂	18.87
Al ₂ O ₃	5.62
Fe ₂ O ₃	2.54
CaO	62.78
MgO	2.63
SO ₃	2.82
Na ₂ O	0.4
K ₂ O	0.9
Özgül yüzöl alanı	3900 cm ² /g
Yoğunluk	3.16 g/cm ³



Şekil 1. Portland çimentosu.

2.1.2. Yüksek Fırın Cürufu

Yüksek fırın cürufu, İskenderun Demir Çelik fabrikasının atığıdır. Cürufa ait özellikler ve içeriği Tablo 2’de, görseli Şekil 2’de verilmiştir.

Tablo 2. Yüksek fırın cürufunun kimyasal içeriği.

Kimyasal İçerik	Analiz sonucu (%)
SiO ₂	38.89
CaO	28.94
Al ₂ O ₃	13.48
MgO	5.53
SO ₃	1.51
Fe ₂ O ₃	1.36
MnO	1.16
K ₂ O	0.78
TiO ₂	0.53
BaO	0.45
P ₂ O ₅	0.41
Na ₂ O	0.36
SrO	0.10
Kızdırma Kaybı	6.50
Özgül yüzölçümü	5990 cm ² /g
Yoğunluk	2,88 g/cm ³



Şekil 2. Yüksek fırın cürufu.

2.1.3. Çelikhane Cürufu

Çalışmada kullanılan çelikhane cürufu, Kardemir demir-çelik fabrikasından temin edilmiştir. Cürufa ait kimyasal içerik Tablo 3’te ve görsel Şekil 3’te verilmektedir.

Tablo 3. Çelikhane cürufunun kimyasal içeriği.

Kimyasal İçerik	Analiz sonucu (%)
SiO ₂	13.53
CaO	52.83
Al ₂ O ₃	3.16
MgO	5.49
SO ₃	0.99
Fe ₂ O ₃	12.74
MnO	1.73
K ₂ O	0.16
TiO ₂	0.58
BaO	-
P ₂ O ₅	0.50
Na ₂ O	0.02
SrO	0.03
V ₂ O ₅	0.77
Kızdırma Kaybı	7.24
Özgül yüzölçümü	6800 cm ² /g
Yoğunluk	3.18 g/cm ³



Şekil 3. Çelikhane cürufu.

2.1.4. Aktivatör

Çalışmada Tekkim Kimya Sanayi ve Tic. Ltd. Şti.’den temin edilen Na₂SiO₃ (Şekil 4) kullanılmıştır.



Şekil 4. Sodyum silikat.

2.1.5. Kum

Çalışmada öğütülmüş dere kumu kullanılmıştır. Maksimum tane çapı yaklaşık 3 mm, özgül ağırlığı 2.2 g/cm³' tür.

2.1.6. Su

Harç karışımları için kullanılan su, EN 1008'e [13] uygun olarak içilebilir temiz şebeke suyudur.

2.2. Metot

Harç karışımları EN 197-7'ye [14] uygun olarak üretilerek 40*40*160 mm'lik prizma kalıplara dökülmüştür. Harç karışım oranları Tablo 4'te verilmektedir.

Tablo 4. Harç karışım oranları.

	YFC	ÇÇ	Çimento	Kum	Su	Aktivatör (%3, 5, 7.5, 9)
%80 YFC+%20 ÇÇ	360 g	90 g	0 g	1200 g	225 g	36 g, 60 g, 90 g, 108 g
%60 YFC+%40 ÇÇ	270 g	180 g	0 g	1200 g	225 g	36 g, 60 g, 90 g, 108 g
%100 Portland çimentosu	0 g	0 g	450 g	1200 g	225 g	0 g

YFC ve ÇÇ iki farklı oranda seçilerek 4 farklı aktivatör oranında harçlar hazırlanmıştır. Hazırlanan geopolimer harçlar ve Portland çimentolu kontrol harçları 24 saat laboratuvar ortamında bekletilmiştir. 24 saat sonunda prizini tamamlayan harçlar kür havuzuna 21±2 °C'de 7 ve 28 gün bekletilmiştir. Kür sürelerinin sonunda EN 196-1 'e [15] uygun olarak eğilme ve basınç dayanımları belirlenmiştir. Ayrıca bütün numunelere ultrases geçiş hızı deneyi uygulanmıştır [16]. Deney düzenekleri Şekil 5'te verilmiştir. Ultrases geçiş hızı testi, beton içine gönderilen ses üstü dalgaların bir uçtan diğer uca geçme süresini ölçerek belirlenmektedir. Hızın yüksek olması beton içindeki boşluk miktarının az olduğunu, hızın düşük olması ise boşluk miktarının fazla olduğunu ifade etmektedir. Tahribatsız bir yöntem olan bu yöntem beton ve harçların dayanımlarının tahmini olarak belirlenmesinde kullanılmaktadır. Harçların ultrases geçiş hızları m/s cinsinden belirlenerek dayanım değerleri ile ilişkisi incelenmiştir.



Şekil 5. Eğilme-basınç dayanımı ve Ultrases geçiş hızı deneyi.

3. SONUÇLAR VE TARTIŞMA

3.1. Eğilme ve Basınç Dayanımı Sonuçları

Geopolimer harçların ve Portland çimentolu kontrol harçlarının 7 ve 28 günlük eğilme, basınç dayanımı ve ultrases geçiş hızı sonuçları Tablo 5'te verilmektedir. Ayrıca sonuçlar Şekil 6'da grafik olarak verilmektedir.

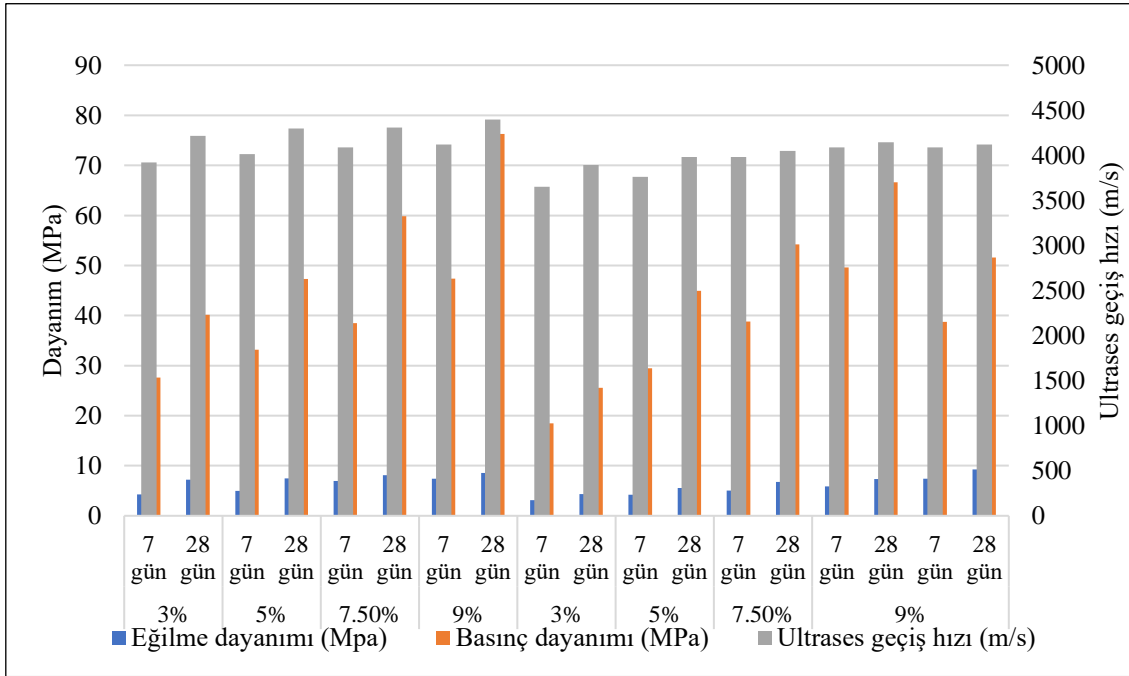
Portland çimentolu harçların 7 ve 28 günlük basınç dayanımı değerleri, 38.74 ve 51.58 MPa olarak ölçülmüştür. Ultrases geçiş hızı ise 4120 m/s olarak belirlenmiştir. Portland çimentolu harçların (CEM I 42.5) 28 günlük basınç dayanımlarının en az 42.5 MPa olması gerekmektedir. Benzer çalışmalarda da kontrol harcı olarak üretilen Portland çimentolu harçların 28 günde 49.87 MPa basınç dayanımına eriştiği gözlenmektedir [17].

%80 YFC+ %20 ÇÇ içeren harçların eğilme, basınç dayanımı ve ultrases geçiş hızı sonuçlarına bakıldığında, Na₂SiO₃ oranı arttıkça dayanım değerlerinin ve geçiş hızı değerlerinin arttığı görülmektedir. 7 günlük eğilme dayanımları; 4.28, 4.97, 6.98 ve 7.38 MPa, basınç dayanımları; 27.42, 33.18, 38.46 ve 47.39 MPa'dır. 28 günlük eğilme dayanımları; 7.24, 7.45, 8.12 ve 8.56 MPa, basınç dayanımları; 40.14, 47.28, 59.87 ve 76.25 MPa'dır.

Özellikle %7.5 ve %9 sodyum oranlarında 28 günlük basınç dayanımları, 59.87 ve 76.25 MPa olarak belirlenmiştir. Bu da Portland çimentosuna (51.58 MPa) kıyasla %16 ve %47 oranında daha fazla dayanım anlamına gelmektedir. Geçiş hızı değerleri de genel itibariyle 4200- 4400 m/s aralığında yer almaktadır. Sodyum oranı arttıkça harçların daha yüksek sıkışma ve kompasiteye sahip olduğu, buna bağlı olarak da dayanım gelişiminin yüksek olduğu söylenebilir.

Tablo 5. Cürüflu harçlara ait deney sonuçları.

	Silikat oranı (%)	Kür süresi	Eğilme dayanımı (Mpa)	Basınç dayanımı (MPa)	Ultras ses geçiş hızı (m/s)
%80 YFC+ %20 ÇÇ	3%	7 gün	4.28	27.62	3920
		28 gün	7.24	40.14	4217
	5%	7 gün	4.97	33.18	4014
		28 gün	7.45	47.28	4298
	7.50%	7 gün	6.98	38.46	4090
		28 gün	8.12	59.87	4307
	9%	7 gün	7.38	47.39	4121
		28 gün	8.56	76.25	4397
%60 YFC+ %40 ÇÇ	3%	7 gün	3.14	18.47	3652
		28 gün	4.32	25.57	3893
	5%	7 gün	4.21	29.48	3762
		28 gün	5.58	44.92	3980
	7.50%	7 gün	5.02	38.78	3980
		28 gün	6.79	54.23	4051
	9%	7 gün	5.87	49.63	4089
		28 gün	7.32	66.65	4145
	Portland çimentosu	7 gün	7.41	38.74	4087
		28 gün	9.27	51.58	4120

**Şekil 6.** Harç numunelere ait deney sonuçları.

%60 YFC+ %40 ÇÇ içeren harçların eğilme, basınç dayanımı ve ultras ses geçiş hızı sonuçlarına bakıldığında, Na_2SiO_3 oranı arttıkça dayanım değerlerinin ve geçiş hızı değerlerinin arttığı görülmektedir. 7 günlük eğilme dayanımı değerleri sırasıyla; 3.14, 4.21, 5.02 ve 5.87 MPa, basınç dayanımları; 18.47, 29.48, 38.78 ve 49.63 MPa'dır. 28 günlük eğilme dayanımları sırasıyla; 4.32, 5.58, 6.79 ve 7.32 MPa, basınç dayanımları; 25.57, 44.92, 54.23 ve 66.65 MPa'dır.

%7.5 ve %9 sodyum oranlarında 28 günlük basınç dayanımları, 54.23 ve 66.65 MPa olarak belirlenmiştir. Portland çimentosu harçlara nazaran %5 ve %29 oranında daha yüksek basınç dayanımı elde edilmiştir. Ultras ses geçiş hızları da 3900-4150 m/s aralığında yer almaktadır. Portland çimentosu harçlara kıyasla iyi sonuçlar alınmaktadır. Ancak YFC oranının %80'den %60'a düştüğü göz önüne alındığında, dayanım ve geçiş hızı değerleri genel olarak azalmaktadır. Bu da YFC oranının yüksek olması halinde eğilme ve basınç dayanımlarının daha yüksek sonuçlar verdiğini göstermektedir.

4. SONUÇ

Çalışma kapsamında, Portland çimentosuna kıyasla daha ekonomik, çevre dostu ve yüksek basınç dayanımına sahip geopolimer harçlar üretilmeye çalışılmıştır. Bu amaçla, YFC ve ÇÇ iki farklı oranda kullanılarak, harçlar üretilmiş ve ultras ses geçiş hızı, eğilme ve basınç dayanımları belirlenmiştir. Ayrıca Normal Portland çimentosuyla kontrol harçları üretilerek sonuçlar kıyaslanmıştır. Elde edilen sonuçlara göre;

Portland çimentosu kontrol harçlarının 28 günlük basınç dayanımları 51.58 MPa olarak belirlenmiştir.

%80 YFC+ %20 ÇÇ kullanılarak üretilen geopolimer harçların, 28 günlük basınç dayanımları, %7.5 ve %9 sodyum oranlarında, Portland çimentosuna göre %16 ve %47 daha yüksek çıkmıştır. Bu sodyum oranlarında basınç dayanımları 59.87 ve 76.25 MPa olarak belirlenmiştir.

%60 YFC+%40 ÇÇ kullanılarak üretilen geopolimer harçların, 28 günlük basınç dayanımları. %7.5 ve %9 sodyum oranlarında kontrol harçlarına kıyasla %5 ve %29 oranında daha yüksek çıkmıştır. Bu sodyum oranlarında basınç dayanımları 54.23 ve 66.65 MPa olarak belirlenmiştir.

Bu çalışma kapsamında üretilen geopolimer harçların %7.5 ve %9 Na oranlarında, Normal Portland çimentosunun 28 günlük basınç dayanımına kıyasla yüksek değerlere eriştiği belirlenmiştir. Ayrıca benzer çalışmalarda üretilen Portland çimentosu harçların 28 günlük basınç dayanımlarına kıyasla da yüksek değerler elde edildiği gözlenmektedir [17].

Geopolimer harç teknolojisinde yüksek fırın cürufu, uçucu kül gibi atık malzemelerin kullanımı yaygın hale geldiği göz önüne alınacak olursa, bu çalışma kapsamında çelikhane cürufu da ayrıca ekonomiye kazandırılmaya çalışılmıştır. Çelikhane cürufu çalışmalarda daha çok zemin stabilizasyon malzemesi veya beton agregası olarak kullanılmıştır [9]. YFC ile geopolimer harç üretimi güncel çalışmalarda yapılmakta, ancak ÇÇ geopolimer harçlarda bağlayıcı olarak yer almamaktadır. Bu çalışmada iki malzeme birlikte kullanılmış ve Portland çimentosuna göre dayanım özellikleri kıyaslanmıştır. Elde edilen sonuçlar, YFC ve ÇÇ'nun birlikte kullanılması halinde Portland çimentosuna göre basınç dayanımı anlamında oldukça iyi sonuçlar verdiğini göstermektedir. Böylece iki atık malzeme değerlendirilerek ekonomiye kazandırılmakta ve çevreye verilen zarar nispeten azaltılmaktadır. Portland çimentosunun üretimi esnasında açığa çıkan gazların ve harcanan enerjinin bir miktar da olsa azaltılmasına katkı sağlanması hedeflenmektedir.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler


KAYNAKÇA

- [1] M. Kaya, F. Koksall, O. Gencel, M. J. Munir, S. M. S. Kazmi, "Influence of micro Fe₂O₃ and MgO on the physical and mechanical properties of the zeolite and kaolin based geopolymer mortar", *J Build Eng.*, vol. 52, p. 104443, 2022
- [2] J. S. Damtoft, J. Lukasik, D. Herfort, D. Sorrentino, E. M. Gartner, "Sustainable development and climate change initiatives", *Cem Concr Res.*, vol. 38, no. 2, pp. 115-127, 2008.
- [3] M. C. G. Juenger, F. Winnefeld, J. L. Provis, J. H. Ideker, "Advances in alternative cementitious binders", *Cem Concr Res.*, vol. 41, no. 12, pp. 1232-1243, 2011.
- [4] W. Zhou, C. Yan, P. Duan, et al., "A comparative study of high- and low-Al₂O₃ fly ash based-geopolymers: The role of mix proportion factors and curing temperature", *Mater Des.*, vol. 95, pp. 63-74, 2016.
- [5] G. Habert, J. B. D'Espinose De Lacaillerie, N. Roussel, "An environmental evaluation of geopolymer based concrete production: Reviewing current research trends", *J Clean Prod.*, vol. 19, no. 11, pp. 1229-1238, 2011.
- [6] W. Lokuge, A. Wilson, C. Gunasekara, D. W. Law, S. Setunge, "Design of fly ash geopolymer concrete mix proportions using Multivariate Adaptive Regression Spline model", *Constr Build Mater*, vol. 166, pp. 472-481, 2018.
- [7] M. Kaya, "The effect of micro-SiO₂ and micro-Al₂O₃ additive on the strength properties of ceramic powder-based geopolymer pastes", *J Mater Cycles Waste Manag*, vol. 24, no. 1, pp. 333-350, 2022.
- [8] Y. H. Açikkapi, S. T. Yildirim, Ş. Bingöl, "Alkalilerle Aktive Edilen Çelikhane Cürufu Harçların Mekanik Özellikleri", *2nd Int Symp Sci Res Innov Stud.*, pp. 644-654, 2022.
- [9] Y. Guo, J. Xie, W. Zheng, J. Li, "Effects of steel slag as fine aggregate on static and impact behaviours of concrete", *Constr Build Mater*, vol. 192, pp. 194-201, 2018.
- [10] C. Bilim, C. D. Ati, "Alkali activation of mortars containing different replacement levels of ground granulated blast furnace slag", *Constr Build Mater*, vol. 28, no. 1, pp. 708-712, 2012.
- [11] H. El-Didamony, A. A. Amer, H. Abd Ela-Ziz, "Properties and durability of alkali-activated slag pastes immersed in sea water", *Ceram Int.*, vol. 38, no. 5, pp. 3773-3780, 2012.
- [12] TS EN 197-1, "Çimento - Bölüm 1: Genel çimentolar - Bileşim, özellikler ve uygunluk kriterleri", TSE, Published online 2012.
- [13] TS EN 1008, "Mixing Water for Concrete - Specifications for Sampling, Testing and Assessing the Suitability of Water, Including Water Recovered from Processes in the Concrete Industry, as Mixing Water for Concrete", Turkish Standardization Institute, 2003.
- [14] TS EN 196-7, "Çimento Deney Yöntemleri - Bölüm 7: Çimentodan Numune Alma ve Numune Hazırlama Yöntemleri", TSE, 2010.
- [15] TS EN 196-1, "Methods of Testing Cement - Part 1: Determination of Strength", Turkish Standardization Institute, 2016.
- [16] ASTM C597-16, "Standard Test Method for Pulse Velocity Through Concrete", Published online 2016.
- [17] N. Degirmenci, A. Yılmaz, "Use of diatomite as partial replacement for Portland cement in cement mortars", *Constr Build Mater*, vol. 23, no. 1, pp. 284-288, 2009.





BMBAD
BJESR

Mühendislik Bilimleri ve Araştırmaları Dergisi
Journal of Engineering Sciences and Researches



Helisel Kanatçıklara Sahip Bir Boruda Nanoakışkan Kullanımının ve Helisel Kanatçık Sayısının Değişiminin Isı Transferi Üzerindeki Etkilerinin İncelenmesi

Investigation of the Effects of Nanofluid Usage and Variation of Helical Fin Number on Heat Transfer in a Pipe With Helical Fins

¹Mustafa DOĞAN , ²*Tolga DEMİRCAN 

^{1,2}*Kırıkkale Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Makine Mühendisliği Bölümü, 71450 Yahşihan, Kırıkkale

¹mustafa.dogan7144@gmail.com, ²*tolgademircan@kku.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 23 June 2022

Accepted : 10 September 2022

Keywords:

Nanofluids, HBN, Heat Transfer, CFD

ABSTRACT

In this study, the effects of nanofluid usage on heat transfer in a pipe with helical fins on its inner surface were investigated. In this context, four model geometries were determined as finless, single helical fin, double helical fin and triple helical fin tube. It is assumed that hBN-water (hexagonal boron nitride-water) nanofluid with constant inlet temperature passes through the pipe, and a constant heat flux is applied to the pipe surfaces. Water was used as the base fluid. 0%, 0.5%, 1%, 1.5%, 2% and 2.5% hBN nanoparticles were added to the water. Numerical analyses were carried out with the help of Computational Fluid Dynamics. As a result of the study, it was observed that the average fluid temperature, heat transfer coefficient and Nusselt number increased with increasing the number of fins and the mixing ratio of the nanofluid. The lowest Nusselt number was determined as 25.93 in the case of water flowing from the finless pipe, and the highest Nusselt number was determined as 97,036 in the case of three helical fins and 2.5% volumetric mixture. Therefore, it was observed that adding helical fins to a pipe and using hBN-water nanofluid had a positive effect on heat transfer.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 23 Haziran 2022

Kabul : 10 Eylül 2022

Anahtar Kelimeler:

Nanoakışkan, HBN, Isı Transferi, HAD

ÖZET

Bu çalışmada iç yüzeyinde helisel kanatçıklara sahip bir boruda nanoakışkan kullanımının ısı transferi üzerindeki etkileri incelenmiştir. Bu kapsamda kanatçiksiz, tek helisel kanatçıklı, çift helisel kanatçıklı ve üç helisel kanatçıklı boru olmak üzere dört model geometrisi belirlenmiştir. Borunun içerisinden sabit giriş sıcaklığına sahip hBN-su (hekzagonal bor nitrür-su) nanoakışkanı geçtiği, boru yüzeylerinde sabit ısı akışı uygulandığı varsayılmıştır. Baz akışkan olarak kullanılan suyun içerisine hacimsel olarak %0, %0,5, %1, %1,5, %2 ve %2,5 oranında hBN nano partikülü katıldığı düşünülmüştür. Hesaplamalı Akışkanlar Dinamiği yardımıyla sayısal analizler gerçekleştirilmiştir. Çalışmanın sonucunda kanatçık sayısının ve nanoakışkanın karışım oranının artırılmasıyla ortalama akışkan sıcaklığının, ısı taşınım katsayısının ve Nusselt sayısının arttığı görülmüştür. En düşük Nusselt sayısı kanatçiksiz borudan su aktığı durumda 25,93 olarak, en yüksek Nusselt sayısı ise üç helisel kanatçık ve %2,5 hacimsel karışım olduğu durumda 97,036 olarak belirlenmiştir. Dolayısıyla bir boru içerisine helisel kanatçık eklemenin ve hBN-su nanoakışkan kullanımının ısı transferi üzerinde olumlu yönde etkisi olduğu gözlemlenmiştir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayımlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Dünyamızda kişi başına düşen ortalama enerji tüketimi hızlı bir şekilde artmaktadır. Bu durum enerji kaynaklarının daha dikkatli ve daha verimli kullanılması gerektiğini göstermektedir. Günümüzde enerji ihtiyacı büyük oranda fosil kaynaklı yakıtlar ile karşılanmaktadır. Ancak fosil yakıtların rezervleri kısıtlıdır ve kullanıldıklarında çevreye zarar vermektedirler. Bundan dolayı yenilenebilir enerji kaynaklarının kullanımının artırılması önemli bir gerekliliktir. Bu nedenle bu çalışmada yenilenebilir enerji kaynaklarından biri olan güneş enerjisinin daha verimli kullanılması üzerine yoğunlaşmıştır. Bu kapsamda parabolik bir güneş kolektörünün toplayıcı borusunun geliştirilerek, güneşten elde edilen enerjinin daha verimli olması amaçlanmıştır. Bu amaçla bir borunun iç kısmına helisel şekilde kanatçık eklentisi yapılarak gerçekleşen ısı transferinin artırılması planlanmıştır. Ayrıca borunun içinden ısı iletkenliği yüksek bir nanoakışkan geçirilerek ısı transferi geliştirilmeye çalışılmıştır.

Nanoakışkan, bir baz akışkan içerisine çok küçük boyutta nano partiküllerin belirli bir hacimsel oranda eklenmesi ile oluşturulan yeni akışkanlardır. Bu oluşturulan yeni akışkan, baz akışkana göre daha yüksek ısı iletkenliğe sahip olmaktadır. Nanoakışkanlarda kullanılan nanopartiküller genel olarak metallere, karbürlerden, oksitlerden veya karbon nanotüplerden oluşmaktadır. Baz sıvı olarak ise genellikle su, yağ ve etilen glikol vb. gibi akışkanlar kullanılmaktadır. Literatür incelendiğinde nanoakışkanların ısı değiştiricileri, ısı boruları, yakıt hücreleri, motor soğutma sistemleri vb. gibi birçok mühendislik uygulamasında ısı transferini geliştirmek amacıyla kullanıldığı görülmüştür. Literatürde bulunan ve nanoakışkanlar üzerine yapılmış bazı çalışmalar aşağıda verilmiştir.

Çiftçi ve ark. [1] bir ısı borusunda nanopartikül olarak TiO_2 (Titanyum dioksit) ilave edilmiş bir nanoakışkanın kullanımının ısı performans üzerindeki etkilerini deneysel olarak incelemiştir. Nanopartikül eklenmesi ile akışkanın buharlaşma sıcaklığının normalden $10^\circ C$ azaldığını belirtmişlerdir. Nano partikül ilavesi ile akışkanın ısı iletkenliğinin arttığını gözlemlemiştir. Nanoakışkan kullanımı ile ısı borusunun ısı veriminin %11,76 arttığını belirtmişlerdir. Elçioğlu ve ark. [2] nanoakışkan viskozitesinin tahmininde kullanılan farklı modelleri karşılaştırmalı olarak incelemiştir. Sonuç olarak, hacimsel karışım oranı arttıkça nanoakışkanın viskozitesinin arttığını gözlemlemiştir. Sıcaklık arttığında ise nanoakışkanın viskozitenin azaldığını belirtmişlerdir. Jalili ve ark. [3] çeşitli kanatçıklara sahip çift borulu bir ısı değiştiricisinde, nanoakışkan kullanımının ısı transfer üzerindeki etkilerini incelemiştir. Nanoakışkanın hacimsel karışım oranını %0,4, %2, %4, %6 olacak şekilde değiştirmişlerdir. Sonuç olarak, su-alüminyum oksit nanoakışkanının, su-titanyum dioksit nanoakışkanına ve saf suya oranla daha yüksek ısı transfer katsayısına sahip olduğunu gözlemlemiştir. Nanoakışkan konsantrasyon oranının %0,4'den %6'ya artırılması ile ısı transfer katsayısının yaklaşık %12 arttığını belirtmişlerdir. Ziyadanoğulları ve Yücel [4] farklı hacimsel oranlara sahip Al_2O_3 -su nanoakışkan kullanımının ısı transfer üzerindeki etkilerini incelemiştir. Çalışmalarının sonucunda partikül hacimsel karışım oranının artışı ile birlikte ısı iletkenlik değerinin arttığını belirtmişlerdir.

Kahveci ve Koca [5] sıcak su hazırlama sisteminde yer alan bir ısı değiştiricisinde grafit-su nanoakışkan kullanımının ısı transferine olan etkilerini incelemiştir. Yaptıkları deneylerin sonucunda plakalı bir ısı değiştiricisinde nanoakışkan kullanımının ısı transferini arttırdığını gözlemlemiştir. Tekir ve ark. [6] yamuk kesite sahip bir kanalın içerisinde Al_2O_3 -Cu/su hibrit nanoakışkan kullanımını termodinamik açıdan incelemiştir. Sonuç olarak, %2,0 hacimsel derişime sahip hibrit nanoakışkan kullanımında, tek parçacıklı nanoakışkanlara oranla ısı taşınım katsayısının yaklaşık %34 arttığını belirlemiştir. En düşük entropi üretiminin hibrit nanoakışkanla gerçekleştiğini belirlemiştir. Tokgoz ve ark. [7] içerisinde dikkörtgen kesitli oyuklar bulunan bir kanalda Al_2O_3 -su nanoakışkan kullanımının ısı transferine etkilerini sayısal olarak incelemiştir. Reynolds sayısını 500-2000 aralığında, nanoparçacık hacimsel karışım oranını 0-0,08 aralığında, faz açılarını ise $180-0$ derece arasında değiştirerek analizler yapmışlardır. Reynolds sayısının ve faz açısının artışı ile türbülans yoğunluğunun arttığını belirtmişlerdir. Nanoakışkanın hacimsel karışım oranının artması ile ısı transferinin arttığını göstermişlerdir. Akçay ve ark. [8] pulsatif akışın ve Al_2O_3 -su nanoakışkanının ısı transferine olan etkilerini sayısal olarak incelemiştir. Pulsatif parametrelerin değişiminin ısı transferini etkilediğini belirtmişlerdir. Akışın genliği ve frekansı arttıkça ısı transferinin arttığı, ancak bu artışın sürtünme faktörünü de arttırdığını gözlemlemiştir.

Yu ve ark. [9] 4,5 mm çapa sahip bir boru içinden su- Al_2O_3 nanoakışkan aktığında gerçekleşen zorlanmış konveksiyonu sayısal olarak incelemiştir. Reynolds sayısını 1050 olacak şekilde sabit tutmuşlar ve nanoakışkanın hacimsel karışım oranını değiştirerek analizlerini tekrarlamışlardır. Sonuç olarak nanoakışkanın Al_2O_3 hacimsel karışım oranı arttıkça Nusselt sayısının ve ısı transferinin arttığını gözlemlemiştir. Rahman ve ark. [10] nanoakışkan ile doldurulmuş üçgen bir boşluk içindeki karışık konveksiyonu sayısal olarak incelemiştir. Prandtl sayısı 6,2 için, nanoakışkan hacimsel karışım oranını %0-%10 aralığında değiştirerek analizler yapmışlardır. Baz akışkana nanopartiküllerin dahil edilmesi ile ısı transfer katsayısında artış gözlemlemiştir. Isı aktarım hızının Richardson sayısına büyük ölçüde bağlı olduğunu belirtmişlerdir. Sheikholeslami ve ark. [11] türbülator kullanılan nanoparçacıkların türbülanslı ısı transferini ve entropi üretimini incelemiştir. Bu amaçla CuO-su nanoakışkanını kullanmışlardır. Çalışmalarının sonucunda, türbülator yüksekliğinin artışı ile Nusselt sayısının arttığını gözlemlemiştir. Bant yüksekliği ve pompalama gücü arttığında sürtünmenin arttığı, termal bileşenin ise azaldığı sonucuna varmışlardır. Hosseini ve ark. [12] mikro kanallı bir ısı alıcısında (MCHS) manyetik alanın nanoakışkan akışı üzerindeki etkisini incelemiştir. Çalışmalarında Al_2O_3 -su nanoakışkanını kullanmışlardır. Isıl iletkenliği ve viskoziteyi hesaplamak için KKL

korelasyonunu, gözenekli ortam için ise Darcy denklemini kullanmışlardır. Çalışmalarının sonucunda, mikro kanallı ısı alıcısına manyetik alan uygulanması ile Nusselt sayısının değerinin etkilendiğini belirtmişlerdir. Karabulut ve ark. [13] bir boru içinde Grafen Oksit partikülü içeren nanoakışkanın ısı transferini sayısal ve deneysel olarak incelemişlerdir. Çalışmalarının sonucunda %0,02'lik hacimsel karışım oranı için ısı taşınım katsayısının %13,9 arttığını gözlemlemişlerdir. Sonuç olarak Grafen Oksit nanoakışkanının ısı transferi uygulamalarında alternatif olarak kullanılabileceğini belirtmişlerdir. Ghasemi ve Ranjbar [14] parabolik oluklu güneş kolektörlerinde nanoakışkan kullanımının ısı performans üzerindeki etkilerini sayısal olarak ele almışlardır. Elde ettikleri sayısal sonuçların deneysel veriler ve ampirik korelasyonlar ile uyumlu olduğunu belirtmişlerdir. Nanoparçacık hacimsel karışım oranının artmasıyla Nusselt sayısının arttığını gözlemlemişlerdir. Isı transfer katsayısının Al_2O_3 -su ve CuO -su nanoakışkanları için sırasıyla %28 ve %35'e kadar arttığını belirtmişlerdir. Demir [15] mini kanallarda nanoakışkan kullanıldığı durumda gerçekleşen ısı geçişi üzerine sayısal ve deneysel çalışmıştır. Al_2O_3 -su ve ZnO -su nanoakışkanlarını kullanmıştır. Al_2O_3 nano akışkanı kullanımında ısı transferinde %14,35, taşınım katsayısında ise %20,90 artış sağlandığını gözlemlemiştir. Benzer olarak ZnO nano akışkanı kullanımında ise ısı transferi ve taşınım katsayısı değerinde sırasıyla %7,42 ve %10,01 artış gerçekleştirdiğini belirtmiştir.

Hasan ve ark. [16] nanoakışkan kullanılan helisel bir ısı eşanjörünün ısı performansını sayısal olarak incelemişlerdir. Bu kapsamda baz akışkan olarak kullanılan suyun içerisine %4 hacimsel karışım oranında Al_2O_3 , CuO ve SiO_2 nano partikülleri ilave etmişlerdir. Çalışmalarının sonucunda helisel sarımın ısı transferini artırdığını belirtmişlerdir. En yüksek ısı transferini Al_2O_3 nanoakışkanında elde etmişlerdir. Ramasubramania ve ark. [17] bakır kaplamalı helisel bir boruya sahip bir ısı değiştiricisinde nanoakışkan kullanımını deneysel olarak incelemişlerdir. Nanoakışkan olarak Al_2O_3 -su karışımını kullanmışlar, farklı hacimsel karışım oranları ve akış hızları için deneyler yapmışlardır. Çalışmalarının sonucunda nanoakışkan kullanımı ile ısı transfer oranında yaklaşık olarak %20 iyileşme gerçekleştiğini belirtmişlerdir. Zheng ve ark. [18] nanoakışkan kullanılan çift borulu bir ısı değiştiricisinin termal verimliliğini incelemişlerdir. Çalışmalarının sonucunda, hacimsel karışım oranı %1,5 olan SiC -su nanoakışkanı kullanıldığında, sadece su kullanımına kıyasla Nusselt sayısında %106,7 artış gözlemlemişlerdir.

Rajput ve ark. [19] ısı eşanjörlerinde nanoakışkan kullanımı ile Nusselt sayısının iyileştirilmesi üzerine bir çalışma yapmışlardır. Bu amaçla, ısı transfer akışkanı olarak Al_2O_3 -su ve TiO_2 -su nanoakışkanlarını kullanmışlardır. Farklı karışım oranları ve farklı akış hızları için incelemeler yapmışlardır. Çalışmalarının sonucunda nanoakışkan kullanımının Nusselt sayısını artırdığını belirtmişlerdir. Bu artışın en fazla Al_2O_3 -su nanoakışkanının kullanıldığı durumda gerçekleştiğini gözlemlemişlerdir. Malika ve ark. [20] gövde borulu bir ısı değiştiricisinde düşük hacimsel karışım oranlara sahip hibrit nanoakışkanının kullanımının ısı performans üzerindeki etkilerini sayısal olarak incelemişlerdir. Çalışmalarında ısı transfer akışkanı olarak CuO - ZnO /su hibrit nanoakışkanını kullanmışlardır. Reynolds sayısı 17448 için hibrit nanoakışkan kullanımı ile Nusselt sayısının %33, basınç düşüşünün ise %13 arttığını belirlemişlerdir. Saleh ve Sundar [21] Ni -su nanoakışkanı kullanılan bir ısı değiştiricisinde ısı transferi, sürtünme faktörü, entropi ve ekserji verim analizleri üzerine deneysel incelemeler yapmışlardır. Çalıştıkları parametre aralığında, nanoakışkan kullanımı ile ısı transfer katsayısında %38,6, Nusselt sayısında %42,68, ekserji veriminde ise %42,27 oranında bir artış gözlemlemişlerdir. Fares ve ark. [22] bir gövde borulu ısı değiştiricisinde nanoakışkan kullanımının ısı transfer analizini yapmışlardır. Bu kapsamda, nanoakışkanların konsantrasyonu, akış hızı ve giriş sıcaklığı gibi farklı parametreleri incelemişler ve bu parametrelerin ısı transfer katsayısı ve termal verimlilik üzerindeki etkilerini irdelemişlerdir. Grafen-su nanoakışkanının kullanılması ile ısı transfer katsayısında yaklaşık %29, ısı veriminde ise %13,7 artış gözlemlemişlerdir.

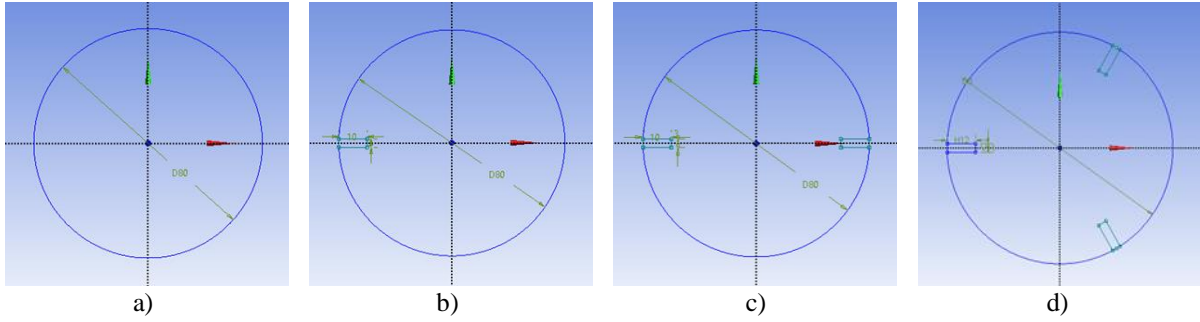
Literatür incelemesinden de görüldüğü üzere, geleneksel olarak kullanılan ısı transfer akışkanlarının içine nanopartikül eklenmesi üzerine yapılmış birçok çalışma bulunmaktadır. Bu çalışmalar da genel olarak Al_2O_3 , CuO , ZnO , TiO_2 vb. gibi sık kullanılan nano partiküller üzerine yoğunlaşmıştır. Literatür incelemesinde nanopartikül olarak hBN nano parçacığının kullanıldığı çalışmalara çok az rastlanılmıştır. Bundan dolayı bu çalışmada, hBN nano parçacığı ile oluşturulan nanoakışkanın ısı performansı üzerine yoğunlaşmıştır. Bu amaçla bu çalışmada helisel olarak sarılmış kanatçıklara sahip bir boruda, helisel kanatçık sayısının değişimi ve hBN-su nanoakışkanının kullanımı ile gerçekleşen ısı transferi ele alınmıştır.

2. MATERYAL VE METOT

2.1. Problemin Tanıtımı ve Matematiksel Yaklaşım

Bu çalışmada içinde boru uzunluğu boyunca helisel olarak sarılmış kanatçıklara sahip bir boruda nanoakışkan kullanımı ile gerçekleşen ısı transferi ele alınmıştır. Bu kapsamda kanatçiksiz, tek helisel kanatçıklı, çift helisel kanatçıklı ve üç helisel kanatçıklı olmak üzere dört farklı model geometrisi oluşturulmuştur. Boru girişinden 298 K sabit sıcaklıkta nanoakışkan girdiği, boru dış yüzeyine ise $1200 W/m^2$ sabit ısı akısı uygulandığı varsayılmıştır. Tüm model geometrileri için farklı hacimsel karışım oranlarında (%0, %0,5, %1, %1,5, %2 ve %2,5) hBN nanoakışkanı kullanılarak Hesaplamalı Akışkanlar Dinamiği yardımıyla sayısal analizler gerçekleştirilmiştir. Bu çalışmada kullanılan model geometrilerin şematik gösterimi Şekil 1'de verilmiştir. Oluşturulan modellerde dikdörtgen helisel kanatçık sayısı 0, 1, 2 ve 3 olarak belirlenmiştir. Her dört modelde de boru çapı 80 mm, uzunluğu

ise 2000 mm olarak sabit tutulmuştur. Kanatçıkların uzun kenarı 10 mm, kısa kenarı ise 3 mm, boru uzunluğu boyunca helisel sarım sayısı ise sabit olacak şekilde ayarlanmıştır.



Şekil 1. Bu çalışmada incelenen geometriler a) Kanatçiksız, b) Tek helisel kanatçıklı, c) Çift helisel kanatçıklı ve d) Üç helisel kanatçıklı.

Yukarıda da belirtildiği üzere, 4 farklı model geometrinin boru uzunlukları ve çapları eşdeğerdir. Bu modelleri birbirinden ayıran en önemli özellik borunun sahip olduğu helisel kanatçık sayısıdır. İlk geometri kanatçiksız düz borudur. İkinci model geometride 1 adet helisel kanatçık, üçüncü model geometride aralarında 180° açı olacak şekilde 2 adet helisel kanatçık ve dördüncü model geometride ise aralarında 120° açı olacak şekilde 3 adet helisel kanatçık bulunmaktadır. Isı transfer akışkanı olarak kullanılan hBN-su nanoakışkanı, baz akışkan olan suyun içerisinde farklı hacimsel karışım oranlarında hBN partikülü ilave edilerek hazırlanmaktadır.

Problemin süreklilik, momentum ve enerjinin korunumu denklemlerinin genel hali aşağıdaki şekilde yazılabilir [13]:

Süreklilik Denklemi

$$\nabla \cdot (\rho_{nf} V_m) = 0 \quad (1)$$

Momentum Denklemi

$$\nabla \cdot (\rho_{nf} V_m V_m) = -\nabla P + \nabla \cdot (\mu_{nf} \nabla V_m) \quad (2)$$

Enerji Denklemi

$$\nabla \cdot (\rho_{nf} c_p V_m T) = \nabla \cdot (k_{nf} \nabla T) \quad (3)$$

Yukarıda verilen diferansiyel denklemlerin çözümlenebilmesi için kullanılan sınır şartları, 4 model geometrinin hepsinde aynı alınmıştır. Borunun dış yüzeyi için “wall” sınır şartı tanımlanmıştır. Bu yüzeye sabit 1200 W/m² değerinde ısı akışı uygulandığı kabul edilmiştir. Boru girişinde “inlet” sınır şartı kullanılmıştır. Reynolds sayısının sabit olması ancak model geometrilerin hidrolik çapının farklı olmasından dolayı akışın giriş hızları geometriye göre farklılık göstermiştir. Bu kapsamda kanatçiksız, tek kanatçıklı, çift kanatçıklı ve üç kanatçıklı borular için sırasıyla 0,0188 m/s, 0,01699 m/s, 0,0151 m/s ve 0,0132 m/s giriş hızı tanımlanmıştır. Akışkan giriş sıcaklığı ise sabit 298 K olarak belirlenmiştir. Borunun çıkış kısmına ise “outlet” sınır şartı tanımlanmıştır ve akışkanın atmosfer şartlarına çıktığı kabul edilmiştir.

Oluşturulan nanoakışkanın temel özellikleri hacimsel karışım oranına göre değişiklik göstermektedir. Bu çalışmada farklı karışım oranlarındaki nanoakışkanın ısı transferi üzerinde ki etkileri üzerinde durulmaktadır. Dolayısıyla farklı karışım oranları için yapılan analizlerde, nanoakışkanın termofiziksel özellikleri değişiklik göstermektedir. Literatürde nanoakışkanın termofiziksel özelliklerini belirlemek için kullanılan ampirik bağıntılar bulunmaktadır. Bu bağıntılardan nanoakışkanın ısı iletim katsayısını [5], viskozitesini [4], yoğunluğunu [5] ve özgül ısıyı [5] belirlemek için kullanılanları aşağıda verilmiştir.

$$k_{nf} = k_{bf} \frac{k_{np} + 2k_{bf} - 2\phi(k_{bf} - k_{np})}{k_{np} + 2k_{bf} + \phi(k_{bf} - k_{np})} \quad (4)$$

$$\mu_{nf} = \mu_{bf}(1 + 2,5\phi) \quad (5)$$

$$\rho_{nf} = \phi \rho_{np} + (1 - \phi) \rho_{bf} \quad (6)$$

$$c_{pnf} = (\phi(\rho c_p)_{np} + (1 - \phi)(\rho c_p)_{bf}) / \rho_{nf} \quad (7)$$

Bu denklemlerde “k” ısı iletim katsayısını, “μ” viskoziteyi, “ρ” yoğunluğu, “c_p” sabit basınçta özgül ısı kapasitesini, “nf” nanoakışkanı, “bf” baz akışkanı, “np” nanopartikülü, ve “Ø” nanoakışkanın hacimsel karışım oranını temsil etmektedir.

Bu çalışmanın sayısal çözümünde çoklu faz yaklaşımı kullanılmıştır. Yapılan analizlerden elde edilen özellik değerleri, yukarıdaki denklemlerden elde edilen sonuçlar ile kıyaslanmış ve sonuçların birbiri ile oldukça uyumlu olduğu görülmüştür. Bundan dolayı, sayısal çözüm aşamasında kullanılan çoklu faz yaklaşımının kullanımının güvenilir bir seviyede olduğu söylenebilir.

İncelenen nanoakışım Reynolds sayısı ise aşağıda verilen Eşitlik 8 [7] aracılığı ile belirlenmektedir.

$$Re = \frac{\rho_f \bar{u} D_h}{\mu_f} \quad (8)$$

Burada “ \bar{u} ” nanoakışkanın ortalama hızını “ D_h ” ise hidrolik çapı temsil etmektedir. Hidrolik çapın değeri boru çapı (D) olarak alınmıştır. Akışım ortalama ısı taşınım katsayısı (h) ise Eşitlik 9 [7] yardımıyla belirlenmektedir. Burada, “ T_w ” duvar sıcaklığı ve “ T_m ” ise bulk sıcaklığıdır. Bulk sıcaklığı ise, akışkanın giriş sıcaklığı ile çıkış sıcaklığının aritmetik ortalamasıdır.


$$h = \frac{q''}{\Delta T} = \frac{q''}{T_w - T_m} \quad (9)$$

Ortalama ısı taşınım katsayısı Eşitlik 10’da yerine yazılarak ortalama Nusselt sayısı [7] belirlenmektedir.


$$Nu = \frac{h D_h}{k} \quad (10)$$

2.2. Sayısal Yöntem

Bu çalışmada incelenen modellerin süreklilik, momentum ve enerji denklemleri hesaplamalı akışkanlar dinamiği (HAD) aracılığı ile sayısal olarak çözülmüştür. Bu amaçla Fluent paket programı kullanılmıştır. Diferansiyel denklemlerin sayısal olarak çözümü için SIMPLE algoritması tercih edilmiştir. Nanoakışım modellenmesinde çoklu faz yaklaşımı kullanılmıştır. Problemin çözümünde kullanılan ağ yapısı, akışın hız ve sıcaklık değerlerinin fazla değişim gösterdiği helisel kanatçığa ve boru yüzeylerine yakın bölgelerde sık, diğer bölgelerde daha gevşek bir yapıda olacak şekilde oluşturulmuştur. Örnek olarak çift kanatçıklı model geometri için oluşturulan ağ yapısı Şekil 2’de verilmiştir. İncelenen dört model geometri için, farklı eleman sayılarına sahip ağ yapılarında analizler tekrarlanarak ağ yapısından bağımsızlaştırma işlemi yapılmıştır. Örnek olarak çift kanatçıklı model geometri için, farklı ağ yapılarında elde edilen sonuçlar Şekil 3’de görülmektedir. Bu geometri için optimum düğüm sayısı 495700 olarak belirlenmiştir.



Şekil 2. Çift kanatçıklı modelin ağ yapısı.




Şekil 3. Çift kanatçıklı model için, ısı taşınım katsayısının ağ yapısındaki eleman sayısı ile değişimi.

Bu çalışmada kullanılan sayısal yöntemin güvenilirliğini kontrol etmek amacıyla literatürde yer alan benzer başka bir çalışmanın sonuçları kullanılmıştır. Bu kapsamda, Demir [15] tarafından yapılan çalışmaya ait geometri ve sınır koşulları, %0,5 hacimsel orandaki Al_2O_3 nanoakışkanı için aynen kullanılarak sayısal analizler yapılmıştır. Analizlerden elde edilen sonuçlar Demir’in [15] sonuçları ile karşılaştırılmıştır. İki çalışmadan elde edilen sonuçların karşılaştırılması Şekil 4’de verilmektedir.

Şekil 4’de ısı taşınım katsayısının Reynolds sayısı ile değişimini gösteren eğriler iki çalışma için birlikte görülmektedir. Şekil incelendiğinde, her iki çalışmada da Reynolds sayısının artışı ile ısı taşınım katsayısının

arttığı görülmektedir. İki çalışmanın sonuçları genel olarak benzer bir yapıdadır ve birbirini ile uyumludur. Bundan dolayı bu çalışmadan elde edilen sonuçların kabul edilebilir bir güvenilirlikte olduğu söylenebilir.

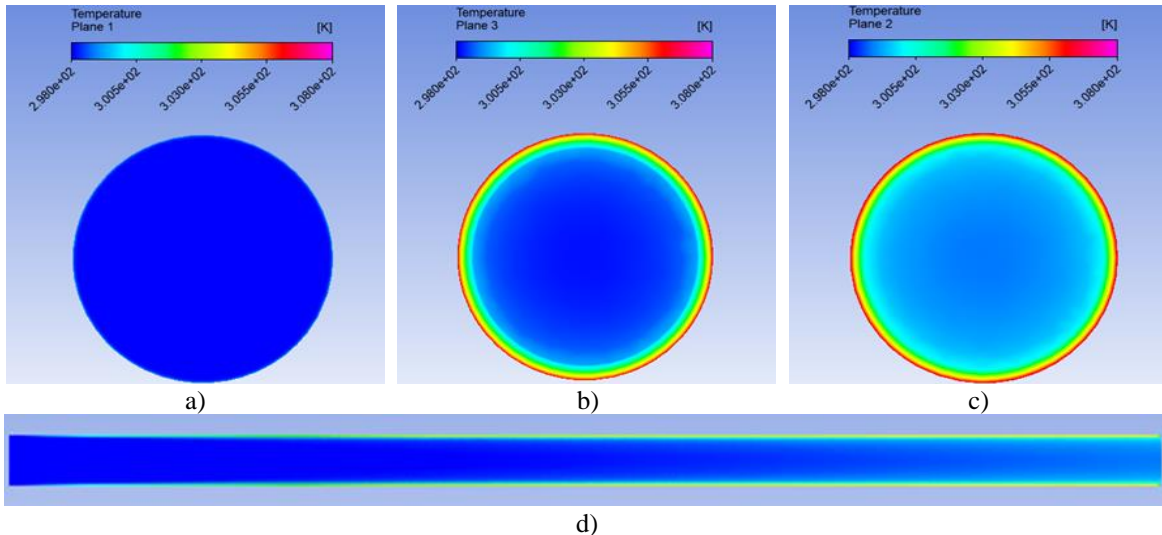


Şekil 4. %0.5 Al₂O₃ için, bu çalışmanın sonuçları ile literatür [15] sonuçlarının karşılaştırılması.

3. BULGULAR

Bu çalışmada iç yüzeyinde helisel yapıda sarmal kanatçık bulunan bir borunun içinden nanoakışkan (hBN-su) akıtılmasının ısı transferi üzerindeki etkileri incelenmiştir. Bu doğrultuda incelenen boru için dört model geometri oluşturulmuştur. Bu modeller için, nanoakışkanın hacimsel karışım oranı %0, %0,5, %1, %1,5, %2 ve %2,5 olacak şekilde analizler yapılmıştır. Analizler sonucunda akışın hız ve sıcaklık dağılımları belirlenmiştir. Ek olarak, akışkanın ortalama çıkış sıcaklığı, ortalama yüzey sıcaklığı, ortalama ısı taşınım katsayısı ve ortalama Nusselt sayısı hesaplanarak grafikler oluşturulmuştur. Bu sayede bu çalışma kapsamında incelenen parametrelerin ısı transferi üzerindeki etkileri irdelenmiştir. Çalışmanın sonuçlarından elde edilen bazı önemli grafikler aşağıda açıklanmıştır.

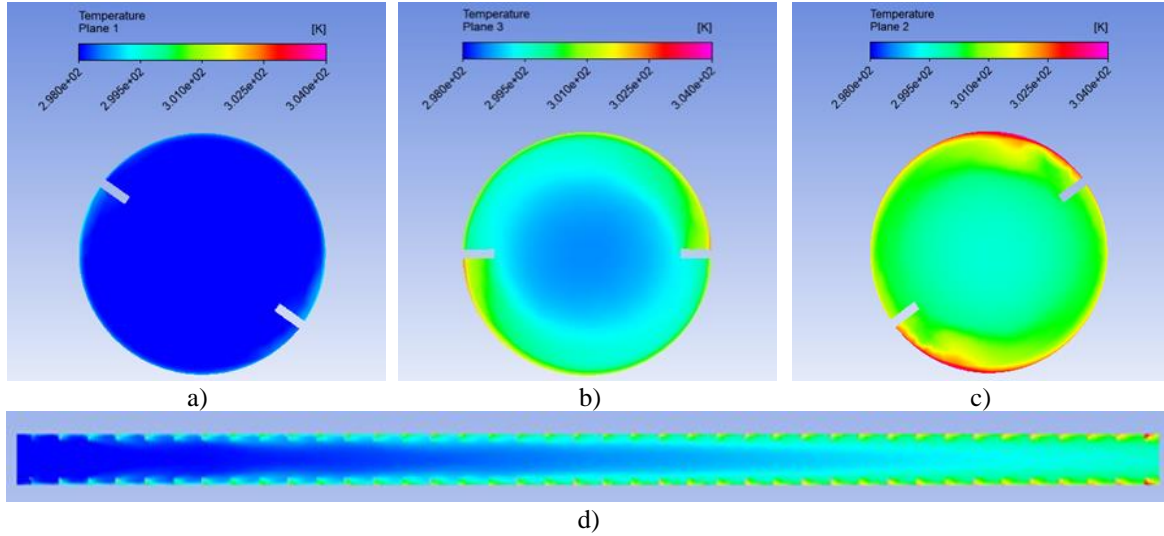
Şekil 5'de kanatçiksız düz boru için hacimsel karışım oranı %0 (sadece su) olduğu durumda farklı kesit alanları için çizilen sıcaklık dağılımları verilmektedir. Bu kapsamda Şekil 5'in a, b ve c şıklarında sırasıyla boru girişinden 0,01 m, 1 m (borunun tam ortası) ve 1,99 m sonra alınan kesitlerdeki sıcaklık dağılımları, Şekil 5'in d şikkında ise boru uzunluğu boyunca alınan bir kesit için sıcaklık dağılımı görülmektedir. Şekiller incelendiğinde boru girişinden düşük sıcaklıkta giren akışkanın, boru yüzeyine uygulanan ısı akışı nedeniyle ortalama sıcaklığının arttığı ısıl sınır tabakanın ise genişlediği görülmektedir. Ayrıca boru yüzeyinden boru merkezine doğru akışkan sıcaklığı azalış göstermektedir. Boru çıkışında ise, akışkanın ortalama sıcaklığı maksimum seviyeye ulaşmaktadır.



Şekil 5. Kanatçiksız boru ve hacimsel oran %0 olduğunda, boru uzunluğu boyunca farklı kesitler için sıcaklık dağılımı a) 0,01 m, b) 1 m, c) 1,99 m ve d) Boru uzunluğu boyunca.

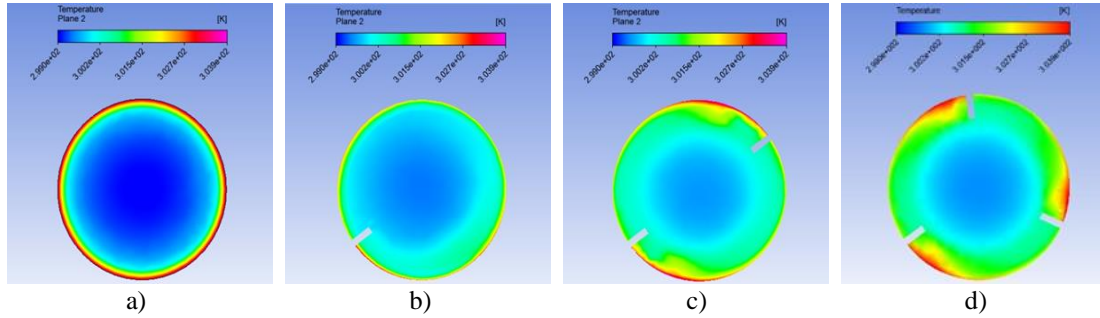
Şekil 6'da ise çift helisel kanatçıklı boru ve hacimsel karışım oranı %2,5 olduğu durum için farklı kesit alanlarında çizilen sıcaklık dağılımları birlikte verilmektedir. Bir önceki şekle benzer olarak, akış boyunca akışkan ortalama sıcaklığı artmakta ve sınır tabaka ise genişlemektedir. Boru yüzeyinden boru merkezine doğru ise akışkan sıcaklığı azalmaktadır. Ancak düz boruda oluşan sıcaklık dağılımından farklı olarak, kanatçık eklentisi ile boru yüzeyine yakın bölgelerdeki sıcaklık dağılımının farklılaştığı görülmektedir. Kanatçığın helisel yapısından kaynaklı olarak

radyan yönde ısı sınır tabaka kalınlığı bozulmaktadır. Bundan dolayı kanatçığın bir tarafında yüksek sıcaklık bölgelerinin diğer tarafında ise düşük sıcaklık bölgelerinin olduğu görülmektedir. Ayrıca su içerisine nanopartikül ilave edilmesi ile ısı transferinin arttığı ve bundan dolayı boru çıkışında ortalama akışkan sıcaklığının bir önceki şekle göre arttığı gözlemlenmiştir.



Şekil 6. Çift helisel kanatçıklı boru ve hacimsel oran %2,5 olduğunda, boru uzunluğu boyunca farklı kesitler için sıcaklık dağılımı a) 0,01 m, b) 1 m, c) 1,99 m ve d) Boru uzunluğu boyunca.


Şekil 7’de hacimsel karışım oranı %2,5 olduğu durumda, 4 model geometrinin boru girişinden 1,99 m sonrasında alınan bir kesit için elde edilen sıcaklık dağılımları verilmektedir. Dört geometride de boru yüzeyinden boru merkezine doğru bir sıcaklık azalışı görülmektedir. Kanatçiksiz borunun yüzey sıcaklığının, diğer modellere göre daha yüksek sıcaklıkta olduğu gözlemlenmiştir. Kanatçık eklentisi ile boru yüzey sıcaklığının azaldığı, akışkan sıcaklığının ise arttığı belirlenmiştir. Kanat sayısı arttıkça akışkanın ısı sınır tabakasının kalınlığının arttığı, ancak kanatçığa yakın bölgelerde ısı sınır tabakanın genel yapısının bozulduğu görülmüştür. Çift kanatçıklı ve üç kanatçıklı borularda, kanatçıkların bir tarafında yüksek yüzey sıcaklıkları diğer tarafında ise düşük yüzey sıcaklıkları gözlemlenmiştir.




Şekil 7. Hacimsel karışım oranı %2,5 iken farklı model geometrileri için sıcaklık dağılımları a) Kanatçiksiz, b) Tek helisel kanatçıklı, c) Çift helisel kanatçıklı ve d) Üç helisel kanatçıklı.

Şekil 8’de çift helisel kanatçığa sahip modelde, farklı hacimsel karışım oranları için boru eksenı boyunca alınan kesitin sıcaklık dağılımları birlikte verilmiştir. Şekiller incelendiğinde, helisel kanatçık kaynaklı olarak boru uzunluğu boyunca ısı sınır tabakanın dalgalı bir yapı oluşturduğu görülmektedir. Tüm şekillerde akışın boru çıkışından önce ısı olarak tam geliştiği görülmektedir. Akışkanın hacimsel karışım arttıkça, akışın ısı giriş uzunluğu azalmakta ve akış ısı olarak tam gelişmiş şartlara daha önce ulaşmaktadır. Nanoakışkanın hacimsel karışım oranının artırılması ile gerçekleşen ısı transfer de artış göstermektedir.

Şekil 9’da farklı model geometrileri için, ortalama yüzey sıcaklığının hacimsel karışım oranı ile değişimini gösteren eğriler birlikte verilmiştir. Tüm karışım oranlarında en yüksek yüzey sıcaklıkları kanatçiksiz boruda görülmüştür. Sabit hacimsel karışım oranı için, kanatçık sayısı arttıkça ortalama yüzey sıcaklığı azalmıştır. Genel olarak tüm modellerde hacimsel karışım oranının artırılması ile ortalama yüzey sıcaklığı azalmıştır. Kanatçiksiz boruda hBN-su nanoakışkanının karışım oranının %2,5’e çıkarılması ile, suya (%) göre ortalama yüzey sıcaklığında yaklaşık 5 °C kadar bir azalış gözlemlenmiştir.




Şekil 8. Çift helisel kanatçıklı boruda farklı hacimsel karışım oranları için sıcaklık dağılımı a) %0, b) %0,5, c) %1, d) %1,5, e) %2 ve f) %2,5.



Şekil 9. Farklı modeller geometrileri için, ortalama duvar sıcaklığının hacimsel karışım oranı ile değişimi.

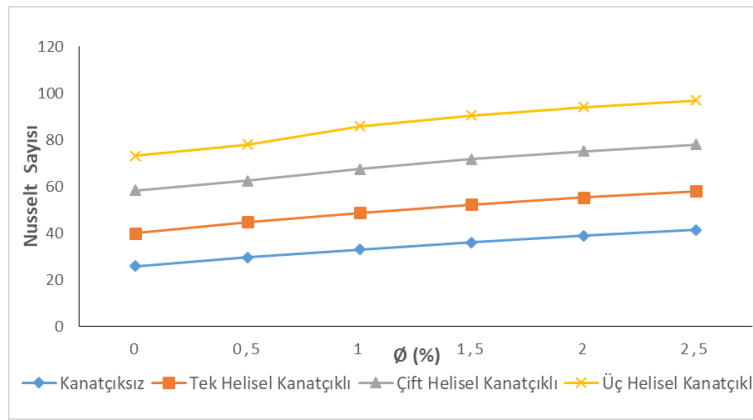
Farklı model geometrileri için, ortalama ısı taşınım katsayısının hacimsel karışım oranı ile değişimi ise Şekil 10'da görülmektedir. Şekil incelendiğinde, tüm karışım oranları için ortalama ısı transfer katsayısının en yüksek değeri üç helisel kanatçıklı boruda, en düşük değeri ise kanatçıksız boruda gerçekleşmektedir. Sabit karışım oranı için, helisel kanatçık sayısı arttıkça ısı transfer katsayısı artış göstermektedir. Hacimsel karışım oranının %2,5 için, ısı taşınım katsayısının değeri tek helisel kanatçıklı, çift helisel kanatçıklı ve üç helisel kanatçıklı borularda kanatçıksız boruya göre sırasıyla %40,03, %67,95 ve %82,51 kadar artış göstermiştir. Ayrıca tüm geometrilerde, hacimsel karışım oranının artırılması ile ısı taşınım katsayısının değeri de artış göstermektedir. Bu artış saf suya (%0) göre, kanatçıksız, tek kanatçıklı, çift kanatçıklı ve üç kanatçıklı geometriler için sırasıyla %78,98, %62,29, %50,15 ve %48,59 kadardır.

Şekil 11'de akışım ortalama Nusselt sayısının nanoakışkanın hacimsel karışım oranıyla değişimi farklı geometrik modeller için birlikte görülmektedir. Şekilden de görüldüğü gibi, tüm geometrik modeller için hacimsel karışım oranı arttıkça Nusselt sayısının değeri de artış göstermektedir. Nanoakışkanın hacimsel karışım oranının %0'dan %2,5'e çıkarılması ile, kanatçıksız, tek helisel kanatçıklı, çift helisel kanatçıklı ve üç helisel kanatçıklı borular için ortalama Nusselt sayısının değeri sırasıyla %59,61, %44,72, %33,89 ve %32,51 kadar artış göstermektedir. Ayrıca kanatçık sayısının artması da Nusselt sayısının değerini artırmaktadır. Hacimsel karışım oranı %2,5 için, tek helisel



Şekil 10. Farklı modeller geometrileri için, ortalama ısı taşınım katsayısının hacimsel karışım oranı ile değişimi.

kanatçıklı, çift helisel kanatçıklı ve üç helisel kanatçıklı boruda ortalama Nusselt sayısının değeri kanatçiksiz boruya oranla sırasıyla %40,03, %88,71 ve %134,41 kadar artış göstermektedir.



Şekil 11. Farklı modeller geometrileri için, ortalama Nusselt sayısının hacimsel karışım oranı ile değişimi.

4. SONUÇ

Bu çalışmada iç yüzeyinde helisel kanatçıga sahip borularda hBN-su nanoakışkanının kullanımının ısı transferi üzerindeki etkileri incelenmiştir. Bu amaçla kanatçiksiz, tek helisel kanatçıklı, çift helisel kanatçıklı ve üç helisel kanatçıklı olmak üzere dört farklı model belirlenmiştir. Boru yüzeyine sabit bir ısı akısı uygulanmıştır. Nanoakışkanın hacimsel karışım oranı %0 ile %2,5 aralığında değiştirilerek analizler yapılmıştır. Analizlerin sonucunda, düz boruya helisel yapıda kanatçık ilave edilmesinin ısı transferini geliştirdiği gözlemlenmiştir. Helisel kanatçık sayısı arttıkça, akışın ısı taşınım katsayısı ve Nusselt sayısı artış göstermiştir. Üç helisel kanatçıklı borunun ısı taşınım katsayısı ve Nusselt sayısında kanatçiksiz boruya oranla sırasıyla yaklaşık %82,51 ve %134,41 kadar artış gözlemlenmiştir. Nanoakışkanın hacimsel karışım oranının artırılması da ısı transferini artırmıştır. Üç helisel kanatçıklı boru için hacimsel karışım oranının %0'dan %2,5 artırılması ile, ısı taşınım katsayısı ve Nusselt sayısının sırasıyla yaklaşık %48,59 ve %32,51 kadar arttığı görülmüştür. Sonuç olarak düz bir boruya helisel kanatçık eklentisinin ve su yerine hBN-su nanoakışkanının kullanımının ısı transferi üzerinde olumlu yönde etkisi olduğu belirlenmiştir.

Yazar Katkıları

Mustafa Doğan: Literatür incelemesine, sayısal doğrulamaya, ağ yapısından bağımsızlığın sağlanmasına, sayısal analizlerin yapılmasına, makalenin taslağının yazımına, şekil ve grafiklerin oluşturulmasına katkı sağlamıştır.

Tolga Demircan: Makalenin konusunun ve kapsamının belirlenmesine, makalenin yazımına, şekil ve grafiklerin irdelenmesine, makale içeriğinin derlenmesine ve metnin son okumasına katkı sağlamıştır.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler

KAYNAKÇA

[1] E. Çiftçi, A. Sözen, E. Karaman, "TiO₂ İçeren Nanoakışkan Kullanımının Isı Borusu Performansına

Etkisinin Deneysel Olarak İncelenmesi", Politeknik Dergisi, vol.19, no. 3, pp. 367-376, 2016.

- [2] E. B. Elçioğlu, A. G. Yazıcıoğlu, S. Kakaç, "Nanoakışkan Viskozitesinin Karşılaştırmalı Değerlendirmesi", *Isı Bilimi ve Tekniği Dergisi*, vol. 34, no.1, pp. 137-151, 2014.
- [3] B. Jalili, N. Aghaee, P. Jalili, D. D. Ganji, "Novel usage of the curved rectangular fin on the heat transfer of a double-pipe heat exchanger with a nanofluid", *Case Studies in Thermal Engineering*, vol. 35, p. 102086, 2022.
- [4] N. B. Ziyadanoğulları, H. L. Yücel, "Al₂O₃-Su Nanoakışkan İle Isı Transferinin İyileştirilmesi", *Batman University Journal of Life Sciences*, vol. 7, no. 2/2, pp. 253-260, 2017.
- [5] M. Kahveci, T. Koca, "Plaka Tip Isı Değiştiricide Grafit/Saf Su Nanoakışkan Kullanımının Isıl Performansa Etkisi", *European Journal of Science and Technology*, no. 25, pp. 400-405, 2021.
- [6] M. Tekir, M. Bayat, K. Arslan, "Energy, Entropy and Exergy Analyses of Hybrid Nanofluid Flow in a Trapezoidal Channel", *Mugla Journal of Science and Technology*, vol. 7, no. 1, pp. 106-116, 2021.
- [7] N. Tokgoz, V. Ozbolat, B. Sahin, "Investigation of Heat Transfer Enhancement by Using Al₂O₃/Water Nanofluid in Rectangular Corrugated Channel", *KSU. Journal of Engineering Sciences*, vol. 19, no. 2, pp. 42-51, 2016.
- [8] S. Akçay, Ü. Akdağ, O. Hacıhafizoğlu, D. Demiral, "Boru demeti üzerinden geçen Al₂O₃-su nanoakışkanın pulsatif akışının ısı transferine etkisi", *DÜMF Mühendislik Dergisi*, vol.10, no. 2, pp. 621-631, 2019.
- [9] K. Yu, C. Park, S. Kim, H. Song, H. Jeong, "CFD Analysis of nanofluid forced convection heat transport in laminar flow through a compact pipe", *Journal of Physics: Conference Series*, pp. 1-7, 2017.
- [10] M. M. Rahman, M. M. Billah, A. T. M. M. Rahman, M. A. Kalam, A. Ahsan, "Numerical investigation of heat transfer enhancement of nanofluids in an inclined lid-driven triangular enclosure", *International Communications in Heat and Mass Transfer*, vol. 38, no. 10, pp. 1360-1367, 2011.
- [11] M. Sheikholeslami, M. Jafaryar, A. Shafee, Z. Li, R. Haq, "Heat transfer of nanoparticles employing innovative turbulator considering entropy generation", *International Journal of Heat and Mass Transfer*, vol. 136, pp. 1233-1240, 2019.
- [12] S. R. Hosseini, M. Sheikholeslami, M. Ghasemian, D. D. Ganji, "Nanofluid heat transfer analysis in a microchannel heat sink (MCHS) under the effect of magnetic field by means of KKL model", *Powder Technology*, vol. 324, pp. 36-47, 2018.
- [13] K. Karabulut, E. Buyruk, F. Kılınç, "Grafen Oksit Nanoparçacıkları İçeren Nanoakışkanın Taşınım Isı Transferi ve Basınç Düşüşü Artışı Üzerindeki Etkisinin Düz Bir Boruda Deneysel Olarak Araştırılması", *Mühendis ve Makine*, vol. 59, no. 690, pp. 45-67, 2018.
- [14] S. E. Ghasemi, A. A. Ranjbar, "Thermal performance analysis of solar parabolic trough collector using nanofluid as working fluid: A CFD modelling study", *Journal of Molecular Liquids*, vol. 222, pp. 159-166, 2016.
- [15] U. Demir, "Mini Kanalda Nanoakışkan Kullanımının Isı Transferine Etkisinin Deneysel ve Sayısal Olarak İncelenmesi", *Yüksek Lisans Tezi, Makine Mühendisliği A.B.D, Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü, Zonguldak*, 2019.
- [16] M. J. Hasan, S. F. Ahmed, A. A. Bhuiyan, "Geometrical and coil revolution effects on the performance enhancement of a helical heat exchanger using nanofluids", *Case Studies in Thermal Engineering*, vol.35, 102106, 2022.
- [17] S. Ramasubramanian, S. Baskar, R. S. Santhosh, "Experimental analysis of copper coated helical coiled tube heat exchanger using nanofluid and water", *Materials Today: Proceedings*, Available online, in Press, 2022.
- [18] D. Zheng, J. Du, W. Wang, J. J. Klemeš, J. Wang, B. Sundén, "Analysis of thermal efficiency of a corrugated double-tube heat exchanger with nanofluids", *Energy*, vol. 256, p. 124522, 2022.
- [19] N. S. Rajput, D. D. Shukla, L. Ishan, K. S. Madhav, "Enhancement of Nusselt number by using Al₂O₃ and TiO₂ Nanofluids in Heat Exchangers", *Materials Today: Proceedings*, vol. 47, no.18, pp. 6515-652, 2021.
- [20] M. Malika, R. Bhad, S. S. Sonawane, "ANSYS simulation study of a low volume fraction CuO-ZnO/water hybrid nanofluid in a shell and tube heat exchanger", *Journal of the Indian Chemical Society*, vol. 98, no. 11, p. 100200, 2021.
- [21] B. Saleh, L. S. Sundar, "Experimental study on heat transfer, friction factor, entropy and exergy efficiency analyses of a corrugated plate heat exchanger using Ni/water nanofluids", *International Journal of Thermal Sciences*, vol. 165, p. 106935, 2021.
- [22] M. Fares, M. AL-Mayyahi, M. AL-Saad, "Heat transfer analysis of a shell and tube heat exchanger operated with graphene nanofluids", *Case Studies in Thermal Engineering*, vol. 18, p. 100584, 2020.



Human Face Recognition Using Deep Neural Networks

Derin Sinir Ağlarını Kullanarak İnsan Yüzü Tanıma

¹Kaplan KAPLAN , ²Fatma KUNCAN 

¹Kocaeli University, Faculty of Engineering, Department of Software Engineering, İzmit/Kocaeli, Turkey

²Siirt University, Faculty of Engineering, Department of Computer Engineering, Merkez/Siirt, Turkey

kaplan.kaplan@kocaeli.edu.tr, fatmakuncan@siirt.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 1 July 2022

Accepted : 5 September 2022

Keywords:

Deep Learning, Convolutional Neural Networks, Face Recognition, Faces96

ABSTRACT

In recent years, many researchers have been using computer-based systems containing artificial intelligence applications for different applications. Human recognition application is one of the studies carried out in this field. Face and object recognition applications, which were originally designed for security measures, are also used in the entertainment and shopping sectors recently. These applications are gaining even more popularity with the mobile application development of various companies. In face recognition applications, deep learning methods can be preferred if the data is large and complex. In this study, a 3-layer Convolutional Neural Network (CNN) has been developed for a face recognition application. The developed model was applied to the Libor Spacek's Facial Images Databases dataset. As a result of the application of the proposed method on the data set, it was determined that the accuracy rate was 99.29%. This means that the application can be adapted for real recognition systems.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 1 Temmuz 2022

Kabul : 5 Eylül 2022

Anahtar Kelimeler:

Derin öğrenme, Evrişimli Sinir Ağları, Yüz Tanıma, Faces96

ÖZET

Son yıllarda birçok araştırmacı farklı uygulamalar için yapay zeka uygulamalarını içeren bilgisayar tabanlı sistemler kullanmaktadır. Kişi tanıma uygulaması da bu alanda yapılan çalışmalardandır. İlk zamanlarda güvenlik önlemleri için tasarlanan yüz ve nesne tanıma uygulamaları, son zamanlarda eğlence ve alışveriş sektörü alanlarında da kullanılmaktadır. Bu uygulamalar, çeşitli firmaların mobil uygulama geliştirmeleriyle daha da popülerlik kazanmaktadır. Yüz tanıma uygulamalarında, verilerin büyük ve karmaşık olması durumunda derin öğrenme yöntemleri tercih edilebilmektedir. Bu çalışmada da bir yüz tanıma uygulaması için 3 katmanlı bir Evrişimli Sinir Ağı (ESA) geliştirilmiştir. Geliştirilen model Libor Spacek's Facial Images Databases veri setine uygulanmıştır. Önerilen yöntemin veri seti üzerine uygulanması sonucunda %99.29 doğruluk oranı olduğu belirlenmiştir. Bu da uygulamanın gerçek bir tanıma sistemine uyarlanabileceği anlamına gelmektedir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. INTRODUCTION

In recent years, thanks to the development of technological innovations, many researchers have started to take an intense interest in human-computer interactive systems. The basic usage approach of human-computer interactive systems is to obtain personal data, process this data and then automatically use them according to the relevant fields. In recent years, as an example of human-computer interaction studies, person recognition-identification studies have become a leading research area. Identification studies are one of the important issues in terms of people's security. In many cases, identification is made using various methods to identify the individual who is authorized to do a job or the individual who is effective in the realization of a negative situation that has occurred. While these methods used in identification are carried out in the form of password verification, in criminal cases, mostly physical structures or behaviors are examined and estimation processes are carried out for identification. In this context, fingerprints, signatures, the structure of the DNA molecule used to distinguish living things have been widely used for many years in identification and matching processes. [1-2].

With the rapid development of technology, new tools are included in our life's day by day. In the last period of the 20th century, mobile phones began to be included in human life to be always accessible. These devices, which were used for communication in the early periods, gained additional functional features with the desire of their manufacturers to stand out from the competition. Especially in the early 2000s, every mobile device has turned into an interactive and multi-functional device with one or more cameras. Today, cameras are easily accessible in all areas of life, and they are widely used with the tendency of individuals to keep memories of their lives alive. Images of many visual elements are photographed every day, and these photos contain a lot of data.

Similar to the development processes of mobile phones, camera security systems have been increasingly used since the last period of the 20th century. These systems instantly record the images obtained from many cameras, and at the same time, they are instantly examined by individuals and interventions are carried out when necessary. Although common methods used in identification have various advantages and disadvantages, one of the limitations can be considered as the access of additional hardware devices. Today, the widespread use of cameras in all areas of life and the non-contact way of obtaining data increase the importance of identification from images. In this study, face recognition was performed with a 3-layer Convolutional Neural Network (CNN) developed with deep learning techniques, which have become widespread recently, instead of traditional face recognition methods. The proposed model was developed for the reference dataset Libor Spacek's Face Images dataset and the codes were developed in MATLAB environment. Then, the results of the developed model were evaluated with performance criteria. Firstly, the network was trained with some of the original data from the face dataset, and then testing of model was performed with the rest of data that had not been introduced to the network before. As a result of the studies carried out, an accuracy rate of 99.29% was determined. It is predicted that the method proposed in the scope of the study can be used successfully in different fields or in real recognition studies.

2. LITERATURE STUDIES

The early stage of face recognition studies and the current stage of studies show differences. While early studies were described as traditional methods, today's studies are generally characterized as modern methods that make use of deep learning methods. Facial recognition studies are still one of the trending topics.

Bledsoe developed the first semi-automatic facial recognition system in 1966. In 1971, another study on face recognition was conducted by Goldstein et al. Bloedsoe (1966) and Goldstein et al. (1971) used the size and position of parts of the face such as ears or eyes to extract features in their studies. Goldstein et al. (1971) predicted that an individual should be distinguished from a population of 255 individuals with 6 characteristics in their study. In the mentioned studies, feature extractions and calculations are performed semi-autonomously [3-4]. Although the first studies on identification with face recognition started in the 1960s, a system that could perform automatic diagnosis was proposed in Kanade's doctoral thesis in 1973. This system, created with similar feature extraction methods, is the first automatic face recognition system. The system included techniques for matching various parts of the percentage and did the calculations automatically [5-6]. Turk and Pentland (1991) shared a study that can detect a human face almost simultaneously from an image in which people are constantly in motion, and also identify who it belongs to. The work includes the concept of eigenface calculation. They state that they have achieved 96% success in different light environments in their studies. At the same time, they reported that they achieved 85% success according to the direction variation and 64% according to the size variation. Gross et al. (1992) stated in their study that both the examination of face-selective neurons in the monkey temporal lobe and facial recognition disorders after brain injury in humans became very active research areas. They stated that it reflects the more general role of the temporal cortex in pattern recognition. They pointed out that there are various facial processing disorders in humans resulting from damage to different areas, reflecting interference in the processing of the face image at different levels. This study is an important study as one of the face recognitions based on pattern recognition [7]. Zhao et al. (2003) stated in their study that one of the most used applications of image processing is face recognition that have gained tremendous interest in recent years. The authors thought that one of these reasons was due to legal and commercial processes. Another reason was that they thought the idea had a long-term construction phase. The authors stated that machine learning systems, which already have a

developed structure, do not carry the success criterion to the desired level due to the disrupting factors in real systems. Exposure changes and lighting levels are examples of these disruptive factors. Briefly, the authors stated that the existing studies cannot be considered sufficient in terms of human perception. The authors presented a critique of their article, which included two different face recognition working groups, a group of still images and a group of videos. The authors stated that they carried out a study, firstly, to perform a comprehensive literature review, and secondly, to gather information on facial recognition systems developed with machine learning algorithms [8]. Tolba et al. (2006) mentioned in their study that the face recognition task has been recently researched. In their article, the authors stated that they present a current review of face recognition research. Firstly, they introduced the concept of facial recognition and its usage field. Then, they gave a literature study of the latest face recognition methods. The authors have clarified some definitions and limitations of databases used to measure the performance of face recognition techniques. They explained a summary of the Face Recognition Vendor Test (FRVT), a detailed evaluation of automatic face recognition challenge and its outcomes [9].

Abdur Rahim et al. suggested that various inferences can be made about the current mood and physical conditions based on the human face and presented a study in which they performed the face recognition process by using the Local Binary Patterns (LBP) method. Within the scope of the study, the authors also mentioned the difficulties of the face recognition process and the diversity of its usage areas and stated that this diversity also affects many applications used in daily life. In addition, the authors stated that face recognition methods consist of feature extraction and classification processes. Face detection, which is the first of these, has the task of determining the sequential detection and recognition algorithms that aim to model the face. They stated that the most characteristic and unique features of the face images were extracted during this stage. They stated that during the classification phase, the facial images were compared with the images in the database. They evaluated face recognition empirically in their study by considering both shape and texture features representing face images based on Local Binary Models for person-independent face recognition. They firstly divided the face area into small regions and they extracted Local Binary Patterns (LBP) and histograms and then they combined them into a single feature vector. They emphasized the extracted feature vector forms an efficient representation of the face and this vector can show similarities between images. The authors stated in their study that their study is a successful application for person recognition from facial images [10].

According to Ghazi et al. (2016) stated in their study that face recognition methods performed with deep learning have high success in cases where there are operations to be performed on a complex data set. However, the authors stated that no evaluation was made on the behavior of the system against changes caused by ambient lighting or exposure angles, which may affect the recognition accuracy. In their study, the authors conducted a detailed study to evaluate the performance of deep learning-based face recognition under a variety of conditions, including varying head exposure angles, upper and lower face occlusion, varying illumination, and misalignment due to faulty facial feature localization. They used VGG-Face and Lightened CNN deep learning models to extract facial representations. The results indicated that although deep learning algorithms provide a powerful model for face recognition applications, they still need to take advantage of preprocessing to gain better performance under specific conditions such as exposure and illumination normalization. Especially if these parameters are not included in the learning algorithm, the importance of preprocessing that needs to be applied to the image increases. In addition, deep learning methods have the potential to tolerate errors that may arise from misalignment and location errors based on facial features to a certain extent, thanks to their structure [11].

Haq et al. (2017) conducted a study on face recognition with Support Vector Machine using LBP Methods. The authors stated that face detection is very important for situations requiring high security. The authors said that by classifying the patterns based on prior knowledge or statistical information of the patterns, they not only offer various solutions to pattern recognition problems, but also help in detecting, recognizing, and authenticating what is desired. The authors stated that a better face recognition can be achieved by factors such as good training of the classifier, making the input images desirable. The authors noted that the illumination of the image effects the face recognition accuracy and does not produce the best-matched results with Single Sample Per Person where only one training sample is available. In their study, the authors stated that they present a working model by generating normalized histograms to train the SVM classifier by taking different sample images and extracting Local Binary patterns, and then classifying the input research images using Binary and Multiclass Support Vector Machines. Although the authors clearly demonstrated in the final part of their study the simplicity and robustness of LBP-based facial representation extraction in terms of facial expression, aging, illumination, and alignment, they noted that some improvements are still need [12].

Qu et al. (2018), in their study, stated that the success of deep learning methods on complex and high-dimensional data is improving day by day and their application areas are increasing. When the results of other common face recognition algorithms are examined, it has been stated by the authors that the success of face recognition processes performed with the help of deep learning has superiority in terms of accuracy. By combining FPGA and CNN [3] methods, the authors proposed a method that significantly affects the recognition accuracy. The authors presented the proposed method in two steps. The first of these consists of obtaining the parameters. With the help of these parameters, the training of the model is carried out. In the second step, the obtained face recognition approach is combined with FPGA. The FPGA accelerates the computing speed of the network thanks to parallel processing to achieve real-time processing of face recognition. The authors claimed that they obtained 400FPS as the recognition

speed of the system, far beyond the current results. Finally, the authors stated that the recommended recognition rate is 99.25% higher than the human eye. They also said that the proposed method give good results under complex light environment [13].

Öziş et al. (2020) developed a face recognition system with Raspberry Pi in their study. The authors stated that image processing applications have been widely used in recent years, especially in terms of safety and health. They stated that some of these studies showed that applications such as license plate recognition, person recognition, face recognition in terms of security gave many useful results from the statistical information. In addition, in terms of health, they mentioned that there are applications in image processing to obtain preliminary diagnosis and preliminary information in terms of health. In their study, the authors proposed a study focusing on the field of face recognition among image processing applications. They said that the usage areas of face recognition systems are increasing in parallel with the development of image processing technologies and machine learning. The authors stated that in their study, it was carried out by making use of the Haar-cascade classification feature applied to find objects on the image. In addition, it was stated that the OpenCV (Open Source Computer Vision Library) library was preferred as an image processing library in the study. In their study, the authors stated that this system, which detects the faces in the image taken with the Raspberry Pi camera module and frames the detected faces, records the images of the faces it finally detected. In the last part of the studies, the authors stated that there may be a potential study that can help many sectors, especially security systems [14].

Başaran E. (2020) has done a thesis on face recognition and person re-recognition for person recognition. The author stated that face recognition and person re-recognition applications are needed in many different areas, especially in individual and social security, forensic cases, and entertainment. The author said that facial images contain rich and highly distinctive features for person identification. He also mentioned that the fact that face images can be obtained without contact and cooperation causes face recognition applications to have a wider application area than applications using other biometric identifiers such as iris and fingerprint. The author emphasized that the scientific part and the original aspect of the thesis were calculated by calculating the distance between the images using the reordering algorithm for his thesis work. Finally, the author stated that as a result of the experiments on the SYSU-MM01 and RegDB datasets he used, the proposed method proved successful [15].

Table 1. Comparison of the proposed approach with the studies in the literature.

Authors (year)	Method	Accuracy (%)
Guo et al. (2000) [16]	ORL Support vector machines (SVM) and nearest center classification (NCC)	94-98
Agarwal et al. (2010) [17]	Artificial Neural Network (ANN)	97
Ramaiah et al. (2015) [18]	Convolutional Neural Network (CNN)	94.1
Khiyari and Wechsler (2016) [19]	Convolutional Neural Network (CNN)	80-90
Kamencay et al. (2017) [20]	Convolutional Neural Network (CNN) Principal Component Analysis (PCA), Local Binary Patterns Histograms (LBPH) and K-Nearest Neighbour (KNN)	98.3
Coşkun et al. (2017) [21]	Convolutional Neural Network (CNN)	98
Hansen et al. (2018) [22]	Convolutional Neural Network (CNN)	96.7
Khan et al. (2019) [23]	Convolutional Neural Network (CNN)	98
Zulfiqar et al. (2019) [24]	Convolutional Neural Network (CNN)	98.76
Abinaya et al. (2020) [25]	Local Binary Pattern (LBP) and Gray Level Co-Occurrence Matrix (GLCM)	96.4
Sharma et al. (2020) [26]	PCA+LDA, PCA+MLP, PCA+NB, PCA+SVM	97-100
This study	CNN, CNN+Adaboost Classifier	99.29 – 97.33

As can be seen from Table 1, the calculated performance values of the proposed models are well-marked compared to the literature. When the literature is examined, it is seen that CNN-based models exhibit high success. The proposed model has proven to be feasible by achieving a high success rate in the literature.

3. DATASET

The dataset used in this study was taken from Libor Spacek's Facial Images Databases, which is an open-source dataset. The data used is kept here in four compressed archives. These four data sets are faces94, faces95, faces96, grimace. These datasets are also sorted according to increasing difficulty. Faces 96 and grimace datasets are the most challenge between these datasets because of different reasons. These difficulties are defined as the background and scale diversity on faces for the faces96 dataset and the extreme diversity of expressions in the

grimace dataset. All images are stored in 24-bit RGB, JPEG format. These datasets were obtained from 395 people. The number of images per person is 20 and the total number of images is 7900. Most individuals are between the ages of 18-20, as the age range in the dataset is mostly first-year undergraduate students, but there are some older individuals as well. The data set consists of images obtained differently to allow different (male, female, people of different races, glasses, beards, S-VHS video camera, 24-bit color JPEG, artificial lighting, fluorescent overhead mixture, and tungsten) scenarios and to increase the degree of difficulty [27]. Within the scope of this study, the images of 125 individuals were used from the faces96 dataset. Images contain both male and female images in 196×196 size. Some images are illustrated as in the Figure 1.



Figure 1. Some sample images of people used in this study.

4. THEORETICAL BACKGROUND

4.1. Convolutional Neural Networks

In recent years, Convolutional Neural Networks (CNN) models have been used especially in image recognition and processing problems. In fact, CNN models were developed from multilayer artificial neural networks (ANN) models. CNN models consist of two steps, as in Figure 2, feature extraction with convolution layers and classification with multilayer ANN layers added afterward.

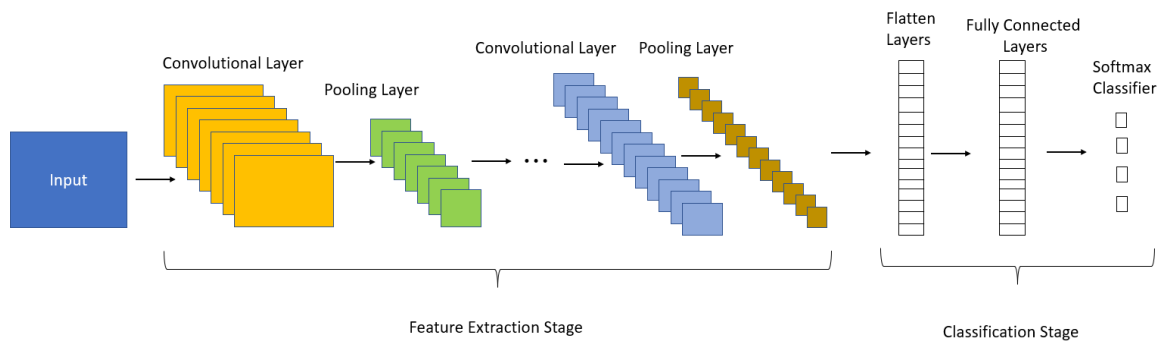


Figure 2. A sample CNN architecture.

A conventional convolutional neural network model consists of six steps: convolutional layers, rectified linear unit (ReLU), pooling layers, a flattening layer, Fully Connected (FC) layers and softmax classification layer. In the first step, a set of convolution filters is applied to the input image to enable certain features from the images. Convolution layers are used to obtain feature information from input images. Following the convolution layer, negative values are usually set to zero and positive values remain unchanged with the ReLU activation function to increase the training speed [28].

One way to reduce the size of the output image is pooling operation. The aim of the pooling layers is to make the output simpler with nonlinear down sampling and thus, the model learns by reducing the number of parameters.

The pooling operation can be performed with the average, maximum calculations. These steps are repeated for many layers, and each layer gains unique properties. In convolutional neural networks, the pooling process is generally used after the convolution layer.

In order to reduce the processing cost by reducing the size of the output image, stride operation can also be performed. While the process can be performed by shifting the filter one pixel in convolution or pooling operations, it can also be done by shifting more than one pixel by increasing the number of steps. Thus, larger and more complex patterns of input can be detected with stride operation.

Feature matrix sizes obtained at layer outputs can be reduced. In addition, taking into account the edge pixels features can make the model more effective. For this reason, it can solve the edges of the input slice by padding the rows and columns with zeros or pixel values on the edge before the convolution operation. The most common use of pixel padding is to produce output with the same dimensions as the input.

In the flattening layer, obtained two-dimensional feature arrays are converted to a flattened linear vector to use for as input to the fully connected layers. FC layers can combine all the local features of each previous layers and are learned by updating the weight and bias values by the feedback method, as in Artificial Neural Networks (ANNs). All these processes are completed by adding the softmax function to the last layer of the model to get the final classification result [29].

4.2. AdaBoost Classifier

In fact, AdaBoost is an ensemble classifier, and it can combine weak classifiers to form a strong classifier. At each iteration, it creates the classifier using a simple learning algorithm called the base learner. Then, the model determines the weight coefficient to this classifier. The final classification decision is made because of the weighted voting of the weak classifiers based on their weight coefficients. The lower the weak classifier error, the higher its weight in the final vote. There is great flexibility in the design of the weak classifier set, as weak classifiers predict slightly better than random guessing.

AdaBoost algorithm uses some parameters for definitions:

$D_n = \{(x_1, y_1), \dots, (x_n, y_n)\}$ and T parameters represent the training set and the algorithm's iteration time, respectively. T parameter can be determined manually and predefined. In each iteration of $t=1, \dots, T$, the coefficient of a weak $h^{(t)}$ classifier $a^{(t)}$ is adjusted from the set H resulting from the classifier.

Algorithm in its simplest form, H represent a finite set of binary classifiers with the form $h: R^d \rightarrow \{-1, +1\}$, and the base learner performs a detailed search on H set at each iteration. The final output of the AdaBoost model is a discriminant function created by weighted voting of weak classifiers [30].

5. EXPERIMENTAL RESULTS

During the model training phase, 70% of the data was used in the training and the rest 30% of the data is used in the testing phase. In other words, 1750 sample images of a total of 2500 images were used in the training phase of the model, and 750 images were used in the testing phase of the model. In the model performance evaluation, the confusion matrix, and the f-score, recall, precision, accuracy values obtained from this matrix were obtained.

All applications were implemented using MATLAB Deep Learning and Statistical machine learning tools [31]. Before the implementation phase, all the images were converted to 224x224 size. Figure 3 shows developed two model for face recognition application. As can be seen, the three layers consist of convolution and pooling layers.




Figure 3. Proposed CNN architecture used for facial recognition.

Table 2. Model parameters.

Layer Name	Function	Weight filter size	Number of filters	Output size
Input				3×196×196
Conv1	Convolution	3×3	8	8×224×224
Batchnorm1	Batch Normalization			8×224×224
ReLU1	Activation function			8×224×224
Pool1	Max. Pooling	2×2		8×112×112
Conv2	Convolution	3×3	16	16×112×112
Batchnorm2	Batch Normalization			16×112×112
ReLU2	Activation function			16×112×112
Pool2	Max. Pooling	2×2		16×56×56
Conv3	Convolution	3×3	32	32×56×56
Batchnorm3	Batch Normalization			32×56×56
ReLU3	Activation function			32×56×56
Flatten Layers	Flatten Layers			1×1×125
fc	Fully connected layer			1×1×125
Softmax	Classification layer			1×1×125

In Table 2, the feature was extracted with combination of 3 convolution and pooling layers, and then the classification process was carried out with two model that are a one-dimensional fully connected layer and a Adaboost classifier, respectively. In Table 3, the training parameters used in the single layer CNN model are given.

Table 3. Parameters used to train the model.

Parameter	Number or type
Hidden size	125
Output layer size	125
Batch size	4
Optimization function	Adam
Learning rate	0.001
Max epoch	5

The model training stage training accuracy is given in Figure 4(a) and the error function graph at the training stage is given in Figure 4(b). If the figures are examined, it can be observed that the accuracy curve stabilizes after ascension. At the same time, the error function decreased and reached its minimum value.




Figure 4. (a) Accuracy rate of model training stage (b) Loss function of training stage.

After the model training was completed, the model was tested with the test data and the confusion matrix was obtained and then, the performance criterions were calculated. The performance criterions are obtained by using 10 cross-validation schemes. The calculated performance measures are given in Table 4. Model weights value of the last epoch were used for testing phase.

For second classification scheme, the flatten layers weight are taken as feature matrix after training of CNN is completed. And feature matrix is given as inputs to Adaboost classifier. The performance criterions of convolutional features with Adaboost classifier are given in Table 4.

Table 4. The calculated performance criterions.

Measure	Accuracy	Recall	Precision	F-Measure
CNN Model	0.9929	0.9950	0.9941	0.9941
Convolutional features + Adaboost Model	0.9733	0.9640	0.9780	0.9737

As can be seen in Table 4, the developed CNN model created achieved better results than Adaboost classifier. while Adaboost classifier achieves %97.33 accuracy rate, the developed CNN model obtained higher success rate than the Adaboost classifier as 99.29% for this face recognition application.




Figure 5. Accuracy rates of some images.

After the best model is determined, some random test samples and their accuracy are given In Figure 5. It is seen that all the selected samples were classified 100% correctly by the developed CNN model.

6. CONCLUSIONS

CNN models are a valuable pattern recognition method both in theory and in real-time image classification or recognition applications. In this study, a CNN model was presented for a face recognition problem. The proposed CNN model was used to classify the data set containing 20 different image samples of each individual taken from different 125 people. Model training was completed with a part of the dataset and tested with the resting part of the dataset. In addition, to see CNN model efficiency, convolutional features of CNN model are taken as feature matrix. And then, they are classified with Adaboost classifier. When the models are compared CNN model achieved more promising results than Adaboost classifier.

As a result of this study, it has been observed that the developed CNN model gives effective face recognition and high accuracy results compared to the literature studies. The proposed method provided a high accuracy for the Faces96 dataset. Also, it was observed that the variety of background and scale on the faces did not affect the accuracy of proposed model. This output is very important for real-time applications with background noise because it is not always possible to obtain images without a background in practice. At the same time, the scale diversity of the faces96 dataset did not affect the performance of the developed model. This means that the model developed for real-time applications can promise high accuracy.

In future studies, it is planned to develop a model with a faster training phase instead of the CNN model. Also, it is thought to increase dataset variety to see developed model performance. For the next studies, it is thought to use this developed CNN model for more complex face recognition problems.

Author Contributions

The authors contributed equally to the study.


Conflict of Interest

The authors of the article declare that there is no conflict of interest between them.

REFERENCES

- [1] A. K. Jain, K. Nandakumar, A. Ross, "50 Years of Biometric Research: Accomplishments, Challenges, and Opportunities", *Pattern Recognition Letters*, vol. no. 79, pp. 80-105, 2016.
- [2] A. K. Jain, A. Ross, S. Prabhakar, "An Introduction to Biometric Recognition", *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 14, no. 1, pp. 4-20, 2004.
- [3] W. W. Bledsoe, "The Model Method In Facial Recognition. Panoramic Research Inc.", Palo Alto, CA, Rep. PR1, vol. 15, no. 47, pp. 2, 1966.
- [4] A. J. Goldstein, L. D. Harmon, A. B. Lesk, "Identification of Human Faces", *Proceedings of the IEEE*, vol. 59, no.5, pp. 748-760, 1971.
- [5] M. Naeem, I. Qureshi, F. Azam, "Face Recognition Techniques And Approaches: A Survey", *Science International*, vol. 27, pp. 1, 2015.
- [6] T. Kanade, "Picture Processing System By Computer Complex and Recognition of Human Faces", Basel: Birkhäuser, vol. 47, p. 63, 1974.
- [7] C. G. Gross, J. Sergent, "Face Recognition", *Current Opinion In Neurobiology*, vol. 2, no. 2, pp. 156-161, 1992.
- [8] W. Zhao, R. Chellappa, P. J. Phillips, A. Rosenfeld, "Face recognition: A literature survey", *ACM Computing Surveys (CSUR)*, vol. 35, no. 4, pp. 399-458, 2003.
- [9] A. S. Tolba, A. H. El-Baz, A. A. El-Harby, "Face recognition: A literature review", *International Journal of Signal Processing*, vol. 2, no. 2, pp. 88-103, 2006.
- [10] M. A. Rahim, M. S. Azam, N. Hossain, M. R. Islam, "Face Recognition Using Local Binary Patterns (LBP)", *Global Journal of Computer Science and Technology*, vol. 13, no. 4, pp. 1-9, 2013.
- [11] M. Mehdipour Ghazi, H. Kemal Ekenel, "A Comprehensive Analysis Of Deep Learning Based Representation for Face Recognition", *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, pp. 34-41, 2016.
- [12] E. U. Haq, X. Huarong, M. I. Khattak, "Notice of Retraction: Face Recognition by SVM Using Local Binary Patterns", *14th Web Information Systems and Applications Conference (WISA)*, pp. 172-175, 2017.
- [13] X. Qu, T. Wei, C. Peng and P. Du, "A Fast Face Recognition System Based on Deep Learning", *11th International Symposium on Computational Intelligence and Design (ISCID)*, pp. 289-292, 2018.
- [14] H. Öziş, İ. Kandilli, M. Kuncan, M. "Face Recognition System With Raspberry Pi", *4th International Zeugma on Scientific Researches*, pp. 178-185, 2020.
- [15] G. Bolukbaş, E. Başaran, M. E. Kamaşak, "BMI Prediction From Face Images". *27th Signal Processing and Communications Applications Conference (SIU)*, pp. 1-4, 2019.
- [16] G. Guo, Z. Z. Li, K. Chan, "Face recognition by support vector machines", *Proceedings Fourth IEEE International Conference on Automatic Face and Gesture Recognition*, pp. 196-201, 2000.
- [17] M. Agarwal, H. Agrawal, N. Jain, M. Kumar, "Face recognition using principle component analysis, eigenface and neural network", *2010 International Conference on Signal Acquisition and Processing*, pp. 310-314, 2010.
- [18] N. P. Ramaiah, E. P. Ijjina, C. K. Mohan, "Illumination invariant face recognition using convolutional neural networks", *International Conference on Signal Processing, Informatics, Communication and Energy Systems (SPICES)*, pp. 1-4, 2015.
- [19] H. El Khiyari, H. Wechsler, H. "Face recognition across time lapse using convolutional neural networks", *Journal of Information Security*, vol. 7, no. 3, pp. 141-151, 2016.
- [20] P. Kamencay, M. Benco, T. Mizdos, R. Radil, "A new method for face recognition using convolutional neural network", *Advances in Electrical and Electronic Engineering*, vol. 15, no. 4, pp. 663-672.
- [21] M. Coşkun, A. Uçar, A., Ö. Yildirim, Y. Demir, "Face recognition based on convolutional neural network", *In 2017 International Conference on Modern Electrical and Energy Systems (MEES)*, pp. 376-379, 2017.
- [22] M. F. Hansen, M. L. Smith, L. N. Smith, M. G. Salter, E. M. Baxter, M. Farish, B. Grieve, "Towards on-farm pig face recognition using convolutional neural networks", *Computers in Industry*, vol. 98, pp. 145-152, 2018.
- [23] S. Khan, M. H. Javed, E. Ahmed, S. A. Shah, S. U. Ali, "Facial recognition using convolutional neural networks and implementation on smart glasses", *2019 International Conference on Information Science and Communication Technology (ICISCT)*, pp. 1-6, 2019.
- [24] M. Zulfikar, F. Syed, M. J. Khan, K. Khurshid, "Deep face recognition for biometric authentication", *In 2019 international conference on electrical, communication, and computer engineering (ICECCE)*, pp. 1-6, 2019.
- [25] R. Abinaya, L. P. Maguluri, S. Narayana, M. Syamala, "A novel biometric approach for facial image recognition using deep learning techniques", *International Journal of Advanced Research in Engineering and Technology*, vol. 11, no. 9, 2020.
- [26] S. Sharma, M. Bhatt, P. Sharma, "Face recognition system using machine learning algorithm", *5th International Conference on Communication and Electronics Systems (ICCES)*, pp. 1162-1168, 2020.

- [27] D. Hond, L. Spacek, "Distinctive Descriptions for Face Processing", The British Machine Vision Conference (BMVC), pp. 1-4, 1997.
- [28] Y. LeCun, Y. Bengio, G. Hinton, "Deep learning" Nature, vol. 521, no. 7553, pp. 436-444., 2015.
- [29] I. Goodfellow, Y. Bengio, A. Courville, "Deep learning", 1st ed., London, UK, MIT press, 2016.
- [30] C. Ying, M. Qi-Guang, L. Jia-Chen, and G. Lin, "Advance and Prospects of AdaBoost Algorithm". Acta Automatica Sinica, vol. 39, no. 6, pp. 745-758, 2013.
- [31] M. Paluszek, S. Thomas, "Practical MATLAB Deep Learning: A Project-Based Approach", 1st ed., New Jersey, USA, Apress, 2022.



Seasonality Determination of Stream Flows For Planning Hydraulic Structures in Kızılırmak Basin

Kızılırmak Havzasında Hidrolik Yapıların Planlanmasında Nehir Akımlarının Mevsimselliğinin Belirlenmesi

¹Naci BÜYÜKKARACIĞAN 

¹Selçuk University, SBMYO, Selçuklu/Konya, Türkiye

nacibk@selcuk.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 4 August 2022

Accepted : 10 October 2022

Keywords:

High Flows, Low Flows, Seasonality, Stream Flow Regimes, Flow Homogeneity

ABSTRACT

The demand for water resources is increasing day by day due to the rapid increase in the world population, drought caused by industrialization, urbanization and global climate change. The efficient use of water resources depends on the correct planning and operation of the water resources systems of the future. The seasonality analysis is to reveal the similarities between the hydrological characteristics of streamflows regionally. In this study; the seasonal similarity of low and high flows throughout the year was determined by using the daily flow data from 5 streamflow gauging stations selected at certain geographical points across the Kızılırmak basin. The similarity of the basins was determined by using the seasonal statistics calculated and the direction of the average occurrence dates for each station. The similarity revealed was also associated with the hydrological similarity between stations and the hydrological characteristics of the basins were found.

© 2022 Bandırma Onyedli Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 4 Ağustos 2022

Kabul : 10 Ekim 2022

Anahtar Kelimeler:

Yüksek Akım, Düşük Akım, Mevsimsellik, Nehir Akış Rejimi, Akım Homojenliği

ÖZET

Dünya nüfusunun hızla artması, sanayileşmenin neden olduğu kuraklık, kentleşme ve küresel iklim değişikliği nedeniyle su kaynaklarına olan talep her geçen gün artmaktadır. Su kaynaklarının verimli kullanılması, geleceğin su kaynakları sistemlerinin doğru planlanması ve işletilmesine bağlıdır. Mevsimsellik analizi, bölgesel olarak akışların hidrolojik özellikleri arasındaki benzerlikleri ortaya çıkarmaktır. Bu çalışmada, Kızılırmak havzası boyunca belirli coğrafi noktalarda seçilen 5 adet akarsu akış ölçüm istasyonundan alınan günlük akım verileri kullanılarak yıl boyunca düşük ve yüksek akımların mevsimsel benzerliği belirlenmiştir. Burada, yüksek akımların göz önüne alınmasının en önemli nedeni, bu akımların özelliklerinin sel gibi su kaynaklarının planlanması ve işletilmesinin temel unsurlarını oluşturmasıdır. Havzaların benzerliği, her istasyon için hesaplanan mevsimsel istatistikler ve ortalama oluşum tarihlerinin yönü kullanılarak belirlenmiştir. Ortaya çıkarılan benzerlik, istasyonlar arasındaki hidrolojik benzerlikle de ilişkilendirilmiş ve havzaların hidrolojik özellikleri bulunmuştur.

© 2022 Bandırma Onyedli Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. INTRODUCTION

Water is an essential substance for human life, as well as an energy source. However, these resources have been under the threat of global warming since the mid-1980s. Heavy downpours, especially in recent years, create significant changes in the flows in the river basins. These, in turn, cause flood disasters in rivers to be more frequent and severe today. The efficient use of our water resources depends on the correct planning and operation of the water resources systems of the future [1]. Due to population growth and changing consumption patterns, it is expected that the demand for water will increase and this will lead to water conflicts [2].

In Turkey, the demand for energy is increasing rapidly with the effect of social, economic and technological developments and increasing population. To meet this demand, high quality, reliable, environmentally friendly and economical energy sources are needed. Due to the scarcity of fossil resources in our country, it is necessary to make more use of renewable energy. Hydroelectric energy is preferred because it is a reliable energy source. The reasons for this are that it has the possibility of storage and use when necessary, has a long economic life, is environmentally friendly, has no fuel costs, has a short payback period and has high efficiency. Time series analysis of river flows can provide answers to questions regarding the feasibility and management of a hydraulic structure investment. For example, the maximum amount of water needed for energy production or irrigation can be defined more efficiently for the future. Such operations are carried out by statistical control methods based on temporal data. Thus, the liability of the investor can be determined in advance. Most water resources development projects are designed to be used efficiently for 50-100 years or more. The project development and design of hydraulic structures are generally carried out using the forecasts of flood and/or drought events that may occur in 50 or 100 years with the existing meteorological and hydrological records. [3]. However, trends in climate parameters such as precipitation and temperature are often not taken into account during the design phase of water structure projects. Therefore, projects prepared without considering climatic trends and seasonality of river flows can cause major problems, especially during the operation of the facilities [4].

In terms of flow duration, flows are classified as perennial, intermittent and short-lived flows. A stream network with continuous flow is governed by groundwater flow. Therefore, it depends on the average annual precipitation modified by the watershed features; transient flows, i.e. intermittent or short-lived, occur once or more each year and are responses to seasonal climate and individual precipitation events [5].

One of the hydrological functions of perennial streams is as a perennial snow and regional seasonal link, which progresses in daily life during short intermittent seasons. It depends on what's going on with the events in the air tonight [6]. The seasonality of stream flow varies regionally, depending on the timing of maximum precipitation, evapotranspiration and contributions from snow and ice, and air temperature. The delays between precipitation peaks and stream flow vary smoothly, from long delays in high latitudes and mountainous regions to short delays in the warmest sectors [7].

In many applications of hydrology and water resources engineering; flood seasonality information is required in seasonal flow estimations, creek bed flood protection, flood management and water resources infrastructure studies [8]. Flood seasonality is information used during the preparation of all construction projects to be planned for water resources control and assessment. Seasonal forecasts of water availability in a basin are useful to managers and planners involved in a variety of activities such as agriculture, water supply, and reservoir management.

Many research has been done on the subject in the world. In the study called "Global characteristics of stream flow seasonality and variability, monthly stream flow series from 1345 sites around the world" were used for characterizing geographic differences in the seasonality and year-to-year variability of stream flow. As a result of study stream flow seasonality varies regionally, depending on the timing of maximum precipitation, evapotranspiration, and contributions from snow and ice [9]. In the UK, the development of seasonal river flow estimation methods has previously been limited to either a few watersheds. Besides, it included the summer season [10]. Eisner et al. selected eleven representative major river basins to study the effects of climate change on the seasonality of stream flow. The basin set includes Rhine and Tagus in Europe, upper Amazon in South America, upper Mississippi in North America, Lena, Ganges, upper Yellow, and upper Yangtze in Asia, Blue Nile and Niger in Africa, and Darling in Australia. As a result of the research, the predicted fluvial flow seasonality differences between the low-emission route and the high-emission route were small in most basins, except for four basins. The old methods are based on empirical relationships between hydrological indicators and climate indices in previous months [11]. In Brazil, low flow seasonality and its effects on water availability along the river network were studied. The study was performed for 16 streamflow gauging stations in Piranga basin. The results show that the annual Q95 is 31% higher than the Q7.10, whereas the monthly values were statistically equal [12]. According to different study, as a result of the assessment of the contribution of groundwater discharges to rivers using monthly flow statistics and flow seasonality in South Africa, it was found that seasonality has a great effect on groundwater potential [13]. Seasonality index (IS), concentration date (PK) half-flow date (TPO), and seasonality coefficient (GMO) were use in study of determining the seasonality of flow in 25 stations on two major rivers in Poland. I was seen that as the catchment area increased, the seasonality of the Vistula flows became considerably higher than of the Oder, and the differences were the most pronounced in the 1960s and 1970s. [14]. In different study, seasonality and variability of daily flows of 40 stations in Mexico City were evaluated based on hydrology, climate, and geography. Variability tests and PCA method

were used. As a result, seasonality and variability of river flows were evaluated in terms of climate-smart environmental flow reference values [15]. Eng et al. identified five distinct seasonality patterns in the zero-flow events in the United States and strong correlation patterns with historical variations in climate [16]. In other study, identification of seasonal streamflow regimes and streamflow drivers for daily and peak flows of 253 streamgages in Alaska was actualized. Basin characteristics and weather station observations were used to support the interpretations of drivers and were explored as explanatory variables of differences in seasonal flow regimes [17]. In the literature, seasonality and similarity analyzes of flows have also been used to analyze the effects of river regimes on animal (like fish) populations. These studies provided a comprehensive understanding of environmental systems [18], [19].

It is important to determine the seasonality of flow data for the future of many water resources engineering projects. The occurrence times of high and low flows determined by seasonality analysis are required for planning such as irrigation, operation, determination of facility capacity, flood and drought analyzes of non-accumulative hydroelectric facilities. While considering the homogeneous basins used in regionalization analyzes, their hydrological similarities are taken into account rather than geographical neighborhood. Flood characteristics and occurrence times are used to determine basin homogeneity [1].

Missing or incomplete data creates problems in field studies. The inadequacy of flow measurements is a major problem in terms of efficient use of water resources. Flow measurements in many river basins in Turkey are not available or insufficient. Flow estimations are made in non-measured basins with regional analysis. In order to solve this problem, there are techniques that allow the attribution of appropriate values instead of missing values. The main purpose of regionalization is to ensure the transfer of flows within the region by dividing the basins into groups with sufficient similarity. In order to complete the missing data, flow assignment (regression, hot / cold deck, multi-disposal) can be made for the missing year among the stations with similar characteristics. It is possible to complete the missing data by using the data of the stations that show homogeneity as a result of similarity and seasonality analysis.

In this study; the seasonality of high and low flows during the year was examined by using the daily flows of 5 streamflow gauging stations located at different points on the Kızılırmak River in the Kızılırmak Basin. The reasons for choosing the Kızılırmak basin in the study are that it is the second largest basin in Turkey, has a precipitation area of approximately 10.49% of the country's surface area, and covers some parts of the Central Anatolia, Black Sea and Eastern Anatolia Regions. Other reasons for the preference of the basin are that various climates are effective in the basin due to its location, there are 15 important dams and many small hydroelectric power plants on the Kızılırmak River, which is the longest river in Turkey, and its tributaries. It is of great importance in terms of the planning and management of water resources in the basin, as there are occurrences of drought and flood events. The effect of the variability of the flow rates for each station on the date of the average was determined with the calculated seasonal statistics. The formation dates and regularity of the flows are indicative of the similarity in the hydrological characteristics of the basins. The regional similarities between the hydrological characteristics of the flows in the Kızılırmak basin were determined with the seasonality analysis, and the manageability of many basins was investigated with a general operating policy. The results were evaluated in the planning and operation of hydraulic structures, flood and drought analyzes as well as estimation of flows at unmeasured points in the basin. The results of the study are important in water resources engineering projects, especially in the operation of hydroelectric power plants.

2. SEASONAL ANALYSIS

The dates and regularities of the flows are indicative of the similarity in the hydrological characteristics of the basins. The seasonal behavior of the flows occurring at the time of their formation also gives the similarity of the physical, geographical and meteorological characteristics of the basins. Basins with this similarity show similar characteristics against flows coming in the same time period [20].

2.1. Seasonal Analysis Using Directive Analysis

If the dates of the flows with certain exceedance probabilities are to be determined, the angular value of these dates in radians can be calculated [21]. If January 1 is the 1st day and December 31 is the 365th day, the angular value of the date of occurrence of the flow;

$$\theta = (JULDATE)_i \cdot \frac{2\pi}{365} \quad (1)$$

Here, θ is the angular value in radians of the date of occurrence of any flow. The flow date can be converted to a vector of unit length and in the θ direction. The x and y coordinates of the unit vector; for N streams are given by Equations (2) and (3).

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N \cos(\theta_i) \quad (2)$$

$$\bar{y} = \frac{1}{N} \sum_{i=1}^N \sin(\theta_i) \quad (3)$$

The average directions of flow dates from these coordinates are calculated as follows;

$$\begin{aligned} \bar{\theta} &= \arctan\left(\frac{\bar{y}}{\bar{x}}\right) && \text{(for the 1st and 4th regions of the Cartesian coordinate plane with } x>0) \\ \bar{\theta} &= \arctan\left(\frac{\bar{y}}{\bar{x}}\right) + \pi && \text{(for the 2nd and 3rd region of the Cartesian coordinate plane with } x>0) \\ md &= \bar{\theta} \frac{365}{2\pi} \end{aligned} \tag{4}$$

Here, *md* is the day showing the average dates of the flows. Basins with similar *md* values also show similar behaviors in terms of other hydrological characteristics. Average days depend on the size of the basin and the geographical region.

Considering that a flow series consists of *n* elements, the variability around the mean value can be calculated by Equation (5).

$$\bar{r} = \sqrt{\bar{x}^2 + \bar{y}^2} \tag{5}$$

Here *r* is a dimensionless measure of the scattering of data around average days. The value of *r* ranges from 0 to 1. If *r* is equal to 1 it is indicated that the flows occur on the same day. For this reason, the flows with *r* values approaching to 1 are formed. For this reason, flows with *r* values approaching 1 show regularity in terms of their occurrence times. On the other hand, if *r* value converges to 0 it is seen an indication of the irregularity between the days of occurrence of flows. Seasonality application is also used to calculate the difference between basins. A numerical value can be obtained to show the measure of the distribution in the seasonal space of the basins. This value can be calculated with the relationship given by Equation (6).

$$d_1^{ij} = \sqrt{(\bar{x}_i^2 + \bar{x}_j^2)^2 + (\bar{y}_i^2 + \bar{y}_j^2)^2} \tag{6}$$

Here, it shows the "Euclidean" distance between the two basins. The smaller this value, the more similar are the two basin streams compared in terms of their behavior.

2.2. Seasonal Analysis Using Relative Frequencies

The basis of the seasonality research of the flows depends on the clustering of the days of occurrence of the flows according to the calendar months. The selected interval should be 1 month. The regularity of flood regimes decreases in shorter periods. If longer intervals were used, a typical separation was not observed [22].

In this study; The hydroelectric power plants. of the flows were grouped into months and the relative frequencies were calculated for each month. In the method, a year in a circle corresponds to 360 days, and every 1 degree corresponds to 1 day. In this case, the sum of the original frequencies (*f_i*) (*s*) will not be equal to the sum of the arranged frequencies (*f_i'*) (*s'*). The relationship given in Equation (7) is used to ensure equality.

$$\sum_{i=1}^{12} f_i' = \sum_{i=1}^{12} f_i \left(\frac{s}{s'}\right) \tag{7}$$

The 12 month dependent frequency value indicating flood or rain formation can be used to determine the seasonal value within the year. Moreover, such regime descriptors do not vary for models to be applied to hydrological events [22]. The similarity of two basins (*i* and *j*) are measured in the dataset with the use of calculated 12 regulated frequencies.

$$d_2^{ij} = \sqrt{\sum_{k=1}^{12} (f_k^i - f_k^j)^2} \tag{8}$$

2.3. Flow Continuity Curve and Specific Flow Continuity Curve

The flow continuity curve shows the probability of occurrence of flow in a river at a given percentage of time. The flow continuity curve shows the relationship between the amount and frequency of daily, weekly, monthly flows at a given station. It shows the percentage of time that the given flow is equal to or exceeded during a given time interval. For cases where the percentage of time is greater than or equal to a certain value, the flow is calculated using the flow continuity curve. The flow continuity line is obtained by moving the flow rates to the vertical axis and the time percentages to the horizontal axis [23].

The flow obtained by dividing the flow by the cross-sectional area is the "specific flow". Considering that the sizes of the basins in the study area are different from each other, working with the flow continuity curve obtained by using specific flow rates provides more efficient results in the comparison of basins.

The flow continuity curve shows the probability of finding the flow in a stream at a given percentage of time. Flows on the stream in less than a year show a statistically time-varying process. For this reason, statistical properties such as mean, standard deviation, skewness coefficient are variable over time. Therefore, the probability of daily flows exceeding a certain value depends on the day in the year [24].

3. DATA

Daily low and high flow values of 5 streamflow gauging stations in the Kızılırmak Basin were used in this study. The stations were selected from different regions (sub-basins) and active ones in order to fully represent the basin. The data length of the flow stations are 45 years covering the years 1970-2015. The Kızılırmak Basin covers an area of 82221 km². The circumference of the basin is 3546 km. The length of the basin is 293 km. Due to the wideness of the basin, there are differences in climate types, as well as evaporation values within the basin. The average temperature of the Kızılırmak Basin was calculated as 10.5 °C. The average temperature in February throughout the basin falls below 0°C. The hottest months are July and August, with average temperatures above 20°C. Due to the wideness of the basin, there are differences in climate types, as well as evaporation values within the basin. The highest evaporation values have been seen in the part of the Kızılırmak Basin bordering the Konya Closed Basin. Evaporation values are at the lowest level in the north of the basin. While evaporation is low in the regions where the Black Sea climate is dominant, evaporation is high in the regions where the continental climate is dominant [25]. The locations of the stations used in the basin are shown in Figure 1.



Figure 1. Kızılırmak Basin and streamflow gauging stations.

The Physical properties and statistical data of the stations are shown in Table 1.

Table 1. Physical characteristics and statistical data of stations.

Station No	Station Name	Precipitation Area (m ²)	Altitude (m)	Min. Flow (m ³ /s)	Max. Flow (m ³ /s)
E15A001	Kızılırmak -Yamula	15581.60	995	0.56	1089.00
E15A017	Karanlık – Şefaatli	8592.40	895	0.41	164.00
E15A035	Kızılırmak – Söğütlühan	6606.50	1243	1.48	589.00
E15A038	Devres – Çeltikçibaşı	1962.00	775	0.12	558.00
D15A164	Kızılırmak – Sofular	33422	548	2.31	277.00

Table 1 shows that E15A001 station has the largest precipitation area and maximum flow. The difference between the minimum and maximum flow is also quite high for the same station. This situation is similar for the other stations. These differences emphasize the importance of seasonality in the design studies of hydraulic structures to be established in these regions.

4. RESULTS

In the study, firstly, a specific flow continuity curve was obtained for each station in order to check that the catchment area has no effect on seasonality (Figure 2a-e). The flow continuity curve was obtained by calculating the percentages of time the flow was greater than or equal to a certain value. In figures, the x-axis represents the percent of time (time percents where the flow was greater than or equal to a certain value), and the y-axis represents the specific flow. Seasonality has been applied over the specific flow continuity curve, on certain percentages of exceedance and the sections above which are important parts for the planning and operation of hydraulic structures.




Figure 2a. The specific flow continuity curve of E15A001 station.




Figure 2b. The specific flow continuity curve of E15A017 station.




Figure 2c. The specific flow continuity curve of E15A035 station.




Figure 2d. The specific flow continuity curve of E15A038 station.




Figure 2e. The specific flow continuity curve of D15A164 station.

Flow values above the 5%, 25%, 50%, 75%, 95% exceedance probabilities and the flow values below the 95% exceedance probability were determined by applying the specific flow continuity curves method. Flow rates above the 5% probability of exceedance are important in the examination of high flows, while the flow rates below the 95% probability of exceedance are important in the examination of low flows. In the seasonality analysis, the analyzes made according to 6 different percentages were beneficial in terms of comparison. Determining the dates of these flow rates is important in terms of observing the distribution of the flows throughout the year. The seasonality indices of the flows corresponding to certain percentages of exceedance from the flow continuity curves are calculated with (1-6) given in the methodology (Table 2).

In Table 2, x and y values show the coordinates of the days of the flows in radians on the cartesian plane. These coordinates are; If the unit placed in the center of the cartesian plane is placed on the circle. The seasonality of the flows is determined by looking at the region where the days of the flows coincide on the circle.

The seasonal area diagram is formed with the unit circle placed on the center of the Cartesian coordinate plane (Fig. 3). In this circle, each degree corresponds to a day. 4 regions of the Cartesian plane are arranged to represent approximately 4 seasons, with the first 3 months of the year being the spring season.

All percentages above the 5%, 25%, 50%, 75%, 95% probability of exceeding the flow rate continuity curve obtained from all stations and below the 95% probability of exceedance on a single plane were shown in Figure 4. The seasonality behavior of flows with certain exceedance probabilities can be examined to a large extent, with this whole demonstration.

Table 2. Seasonality indices of flows at stations.

Station	Probability of exceeding	\bar{x}	\bar{y}	θ	Md	R
E15A001	5%	-0.24004	0.776571	2.283179786	116.748	0.688512
	25%	-0.31321	0.705134	2.348332524	120.056	0.550265
	50%	-0.01997	0.554742	1.90702823	282.333	0.164253
	75%	0.10320	0.445833	1.309931796	666.221	0.099587
	95%	0.03001	0.351723	1.101937195	560.557	0.045423
	>95%	-0.34831	-0.39655	2.256974203	206.389	0.836588
E15A017	5%	-0.42331	-0.70141	4.788072574	243.998	0.647402
	25%	-0.22378	0.761518	2.203288486	112.688	0.582521
	50%	-0.16497	0.701125	2.133846231	109.603	0.487800
	75%	0.108234	0.565483	1.549675091	788.014	0.201104
	95%	0.166174	0.444985	1.057358460	537.910	0.298722
	>95%	-0.45299	-0.26587	3.269874123	199.568	0.898532
E15A035	5%	0.089084	0.350506	1.061047952	539.785	0.083584
	25%	-0.72354	-0.67225	4.722752963	240.685	0.721781
	50%	-0.45687	0.790409	2.130832068	109.007	0.777727
	75%	-0.19267	0.709968	2.093189471	107.094	0.601076
	95%	0.101356	0.556233	1.552260091	789.327	0.281189
	>95%	0.046264	0.045623	0.589230498	056.156	0.025697
E15A038	5%	0.273922	0.436395	0.872900522	505.165	0.192079
	25%	0.053250	0.348047	0.812976537	434.082	0.094819
	50%	-.711120	-0.63027	4.539111912	231.351	0.741213
	75%	-0.48405	0.748673	2.158028980	123.089	0.672737
	95%	-0.51628	0.671497	2.597543974	128.765	0.638705
	>95%	-0.52033	-0.74396	2.102256891	301.444	0.889821
D15A164	5%	-0.09898	0.495627	1.854406425	105.124	0.217913
	25%	0.159840	0.447894	1.366617696	695.018	0.199771
	50%	0.065897	0.351706	1.128038376	573.817	0.064587
	75%	-0.72021	-0.69998	3.913086989	245.269	0.709413
	95%	0.568942	0.757164	2.497497377	122.554	0.787887
	>95%	-0.02018	-0.048458	0.789267791	037.456	0.029874




Figure 3. Seasonal space.

The “ r ” value calculated with the (7) represents the proximity of the dates of the flows to the center or the edge on the seasonality graphs. r ranges from 0 to 1. If the r is equal to 1, it shows that the flows come within the same days. For this reason, flows with r approaching 1 show regularity in terms of their occurrence times. The fact that the flows are close to the center in the seasonality flow plane means that the r is close to 0. This is an indication of the irregularity between the days of occurrence of the flows. r is also a measure of the radii of the seasonality clusters of the dates of the flows distributed on the unit circle drawn on the seasonality space. The dates of flows with a probability of exceeding 95% are closest to the center of the unit circle. The dates of flows with a probability of exceedance of more than 5% are located the farthest from the centre (Figure 4). The probability of exceedance is above 5% and there is regularity of flows in the remaining region of 95%. Flow rates with a probability of exceeding 5% from these values from the flow continuity curve indicate high flows in stations. Flows with a probability of exceeding below 95% indicate low flows. These flows occur in a very small part of the time. For this reason, the regularity and seasonality of these flows within themselves represent the seasonality of the regions within the basin.




Figure 4. Seasonality Graph Calculated for Flows at Stations.

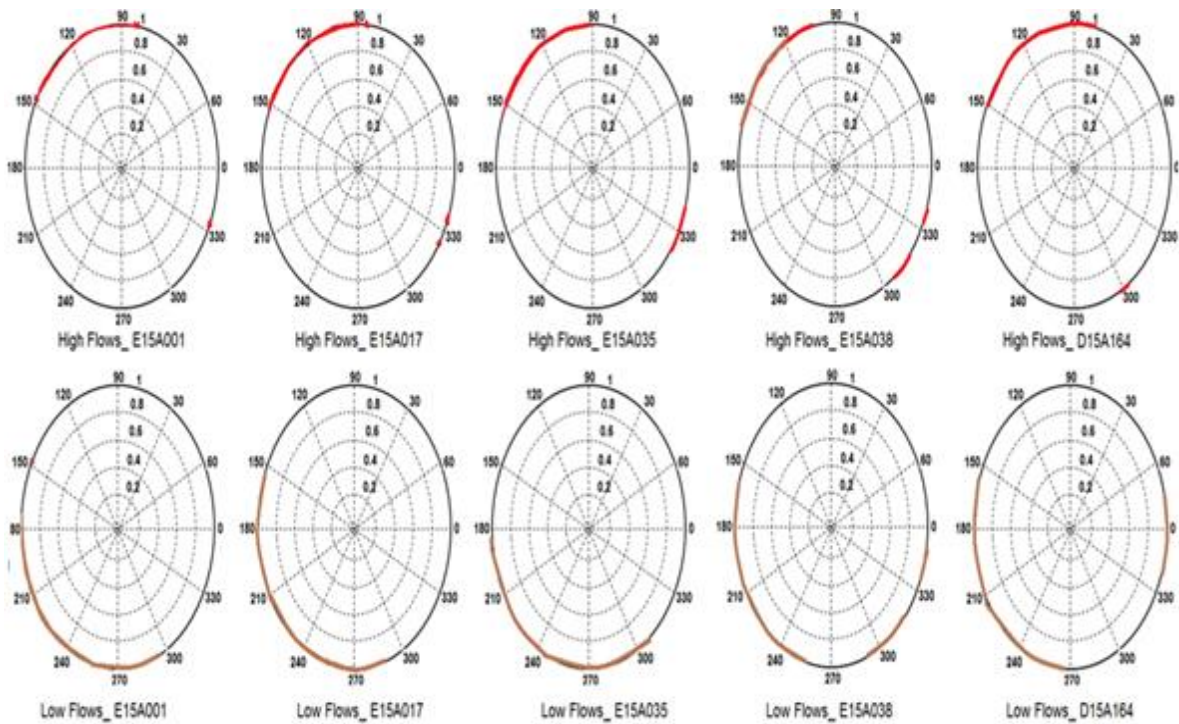


Figure 5. Seasonal days graphs of stations for high and low flows.

According to the results from Figure 5: (a) high flows started in February and continued until the end of April. (b) The small cluster observed around 300-330 degrees is indicative of the autumn rains starting from the end of October. (c) lowest flows are clustered in July-August. This is because there is no precipitation on the river basin and evaporation is at its highest in these months. Figure 5 shows that the river basins show similar seasonality to each other and the seasonality behavior of the flows in the region themselves.

d_1 “Euclidean distance” can also be used for determining the hydrological similarities of the river basins. These values calculated with (8) are given in Table 3.

The Euclidean distance between the basins, symbolized d_1 , in Table 3, is an indicator of basin similarity. There is an inverse correlation between d_1 and basin similarity. As d_1 gets smaller, the similarity of the basins increases. The reason why d_1 values are at least 75% and 95%, the basins of all stations are very similar to each other.

The cross-comparison of the similarity of the basins with each other was shown in Table 4. For river basin similarity, homogeneity was symbolized H and NH was used for inhomogeneity.

Table 4 evaluation; for the 5% probability of exceedance and the flows remaining above, (a) station E15A001 was similar to stations E15A017, E15A037, E15A038 and D15A164, (b) Station E15A017 gave homogeneity characteristics with stations E15A001 and E15A018, (c) E15A035, E15A001 and E15A038 were also similar

Table 3. Euclidean distances (d_i) between stations.

	Euclidean Distance	E15A001	E15A017	E15A035	E15A038	D15A164
E15A001	5%	0				
	25%	0				
	50%	0				
	75%	0				
	95%	0				
E15A017	5%	0.093	0			
	25%	0.150	0			
	50%	0.119	0			
	75%	0.069	0			
	95%	0.006	0			
E15A035	5%	0.123	0.235	0		
	25%	0.179	0.325	0		
	50%	0.137	0.236	0		
	75%	0.075	0.121	0		
	95%	0.010	0.006	0		
E15A038	5%	0.101	0.017	0.222	0	
	25%	0.119	0.043	0.288	0	
	50%	0.069	0.050	0.193	0	
	75%	0.012	0.066	0.088	0	
	95%	0.001	0.006	0.011	0	
D15A164	5%	0.083	0.162	0.072	0.165	0
	25%	0.156	0.299	0.029	0.261	0
	50%	0.145	0.249	0.019	0.204	0
	75%	0.067	0.122	0.018	0.079	0
	95%	0.002	0.003	0.008	0.002	0

Table 4. Basin Homogeneity Between Stations.

	Basin Similarity	E15A001	E15A017	E15A035	E15A038	D15A164
E15A001	5%					
	25%					
	50%					
	75%					
	95%					
	>95%					
E15A017	5%	H				
	25%	NH				
	50%	NH				
	75%	H				
	95%	H				
	>95%	NH				
E15A035	5%	H	NH			
	25%	NH	NH			
	50%	NH	NH			
	75%	H	NH			
	95%	H	H			
	>95%	NH	H			
E15A038	5%	H	H	H		
	25%	NH	H	H		
	50%	H	H	H		
	75%	H	H	H		
	95%	H	H	H		
	>95%	H	H	H		
D15A164	5%	H	NH	H	NH	
	25%	NH	NH	H	NH	
	50%	H	NH	H	NH	
	75%	H	H	H	NH	
	95%	H	H	H	H	
	>95%	H	H	H	H	

each other, (d) E15A038 was similar to E15A001, E15A017 and E15A035, (e) D15A164 was similar to E15A001 and E15A038.

For flows with a 95% probability of exceeding and below (low flows): (a) E15A001 is similar to E15A038 and D15A164, (b) E15A017 is similar to E15A038 and D15A164, (c) E15A035 Station numbered shows homogeneity with E15A017, E15A038 and D15A164, (d) Station E15A038 showed homogeneity with all stations, (e) Finally, D15A164 showed similarity with all stations.

5. CONCLUSION

The operational policies of the hydraulic structures planned to be established in the region can be realized more easily by determining the occurrence times of high and low flows with seasonality analysis. The strong seasonal behavior of high flows is very important for flood analysis and desing of hydraulic construction projects. The strong seasonality of low flows also indicates the dry season in the basin. The seasonality analysis also gives an idea about the similarity between the hydrological characteristics of the basin.

Flood protection can be provided with a common policy for basins with similar seasonality. The project flow rate selected for a hydraulic structure planned to be established in the region can also be selected for similar basins. In addition, precautions can be taken for the expected drought in the region by looking at the similarities between 95% and below. Basin similarity is very important in terms of completing the missing measurements as well as its importance for water resources enterprises. Similar river basins show similar hydrological behavior. In this respect, similar measured basin data can be used to complement flow data in non-measured basins.

In this study, 45 years of daily low and high flow data of 5 river measurement stations in the Kızılırmak Basin were used for seasonality analysis. Seasonal analysis was performed for low and high flows for the probability of exceeding 5%, 25%, 50%, 75%, 95% and 95% from the flow continuity curves obtained separately for the stations. Similarities between stations were determined by two different methods. Flow continuity curve was used for each station (Fig.2a-e). It was accepted that the drainage areas of the basins have no effect on the formation dates of the flows. Therefore, the specific flow continuity curve was used by dimensionless flow continuity curves. According to the results of the analysis, high flows are located in the region between the 50th day (20 February) and the 120th day (April 30) (Fig.4). This situation can be interpreted as the melting of february heavy snowfalls in the spring. Snow melts occurred earlier at stations located at lower elevations. The regions where the stations are located are very close to each other for high flows with a probability of exceeding 5%, showed seasonal characteristics. In addition, observed at some stations autumn precipitation also occurred in October-November in the same period. The low flows, which were below the 95% probability of being exceeded, were concentrated in the summer period, which includes July (182th day) and August (232th day). The time intervals in which high and low flows occur in the basins of our country are not very different from each other. For the purpose of comparison with the Kızılırmak basin, for the neighboring Konya basin, the high flow time interval was found as 15 March-30 May, and the low flow time interval was 30 June-1 September (Fig. 5). Although the flow formation intervals in both basins are the same seasonally, there are day differences in the dates. The mentioned day differences are very important especially in the project calculations and operations of hydroelectric power plants.

Euclidean distance were used for determining the hydrological similarities of the river basins. All stations were very similar to each other (Table 3). According to results of the cross-comparison of the similarity analyses of the basins, for the 5% probability of exceedance, station basins showed similarity. For flows with a 95% probability of exceeding and below (low flows), It was observed that the hydrological behavior of stations during the drought period is compatible with the basin (Table 5).

As a result of seasonal analyzes of 5 river flows, it was concluded that there are regional similarities between the hydrological characteristics of river flows in the Kızılırmak basin. This result shows that Kızılırmak basin can be managed with a general operating policy. At the same time, with the positive results of the similarity and seasonality characteristics on the basis of the basin, it can be also possible to complete the missing data in the streamflow gauging stations in the Kızılırmak basin. The basin streamflow gauging stations with complete data in those years can be used for the completion of missing data on the streamflow gauging stations located within Kızılırmak basin. This situation is also very important in terms of the data used in hydraulic construction projects to be built in places where there is not enough data in the basin. In particular, the determination by seasonality analysis will be of great benefit in the efficient and effective planning and operation of hydraulic structures to be built in the basin. Considering that flow measurements are insufficient in Turkey, this method will yield useful results for effective and smart business policies and management of water resources. The occurrence days of the flows occurring at the stations used in the study occur independently of the precipitation area and elevation. This situation shows that the flow continuity curve to be obtained while determining the water potential of hydraulic structures should be independent from the area and obtained with specific flow rates. These curves can be used in the planning of the structures to be built in the places where the streamflow gauging stations are located and in the selection of the project flow rates. In addition, determining the days when high flows occur with seasonal analysis will be of great benefit in the effective and efficient planning and operation of hydroelectric power plants. As a result of the analyzes, the determination of the days when the maximum flows occur is important for

the operation of hydraulic structures (such as reservoir overflow). In addition, determining the days when the maximum flows occur will be useful in taking precautions against a possible flood and in the design of the structures. The study will contribute greatly to the prevention of floods and the operation of small hydroelectric power plants, which are numerous in the region, in order to support economic and cultural development in the Kızılırmak basin.

Statement of Conflict of Interest:

Author has declared no conflict of interest.

Author's Contributions:

The contribution of the authors is equal.

REFERENCES


- [1] Albostan, "Yüksek ve düşük akımların mevsimselliği murat nehri uygulaması", İstanbul Teknik Üniversitesi, Enerji Enstitüsü, Yüksek Lisans Tezi, pp. 5-58, 2008.
- [2] N. K. Gunasekara, S. Kazama, D. Yamazaki and T. Oki, "Water conflict risk due to water resource availability and unequal distribution", *Water Resour Manag.*, vol. 28, pp. 169–184, 2014.
- [3] M. Bayazıt and B. Oğuz, "Probability and statistics for engineers", Birsen Yayınevi, 1998.
- [4] R. H. McCuen and R. E. Beighley, "Seasonal flow frequency analysis", *Journal of Hydrology*, vol. 279, pp. 43-56, 2003.
- [5] G. Laaha and G. Blöschl, "Seasonality indices for regionalizing low flows", *Hydrological Processes: An International Journal*, vol. 20, no. 18, pp. 3851-3878, 2006.
- [6] J. Yang, X. Lin and D. Wu, "On the dynamics of the seasonal variation in the South China Sea throughflow transport", *Journal of Geophysical Research: Oceans*, vol. 118, no. 12, pp. 6854-6866, 2013.
- [7] M. D. Dettinger and H. F. Diaz, "Global characteristics of stream flow seasonality and variability", *Journal of hydrometeorology*, vol. 1, no. 4, pp. 289-310, 2000.
- [8] J. M. Cunderlik, T. B. Ouarda and B. Bobée, "Determination of flood seasonality from hydrological records", *Hydrological Sciences Journal*, vol. 49, no. 3, 2004.
- [9] M. D. Dettinger, D. R. Cayan, G. M., McCabe and J. A. Marengo, "Multiscale streamflow variability associated with El Niño/Southern Oscillation, in HF Diaz and V. Markgraf, V.(eds.)", *El Niño and the Southern Oscillation--Multiscale Variability and Global and Regional Impacts*, 2000.
- [10] C. Svensson, "Seasonal river flow forecasts for the United Kingdom using persistence and historical analogues", *Hydrological Sciences Journal*, vol. 61, no. 1, pp. 19-35, 2016.
- [11] S. Eisner, M. Flörke, A. Chamorro, P. Daggupati, C. Donnelly, J. Huang, and V. Krysanova, "An ensemble analysis of climate change impacts on streamflow seasonality across 11 large river basins", *Climatic Change*, vol. 141, no. 3, pp. 401-417, 2017.
- [12] L. D. O. Serrano, R. B. Ribeiro, A. C. Borges and F. F. Pruski, "Low-flow seasonality and effects on water availability throughout the river network", *Water Resources Management*, vol. 34, no. 4, pp. 1289-1304, 2020.
- [13] D. C. Le Maitre and C. A. Colvin, "Assessment of the contribution of groundwater discharges to rivers using monthly flow statistics and flow seasonality", *Water SA*, vol. 34, no. 5, pp. 549-564, 2008.
- [14] P. Jokiel and P. Tomalski, "Flow seasonality in two big Polish rivers—the Vistula and the Oder", In *Management of Water Resources in Poland*, pp. 181-204, Springer, 2021.
- [15] S. A. Salinas-Rodríguez, N. C. van de Giesen and M. E. McClain, "Inter-annual and seasonal variability of flows: delivering climate-smart environmental flow reference values", *Water*, vol. 14, p.1489, 2022.
- [16] K. Eng, D. M. Wolock, and M. D. Dettinger, "Sensitivity of intermittent streams to climate variations in the USA", *River Research and Applications*, vol. 32, no. 5, pp. 885– 895, 2016.
- [17] J. H. Curran and F. E. Biles, "Identification of seasonal streamflow regimes and streamflow drivers for daily and peak flows in Alaska", *Water Resources Research*, vol. 57, no. 2, 2021.
- [18] W. R. Berghuijs, M. Sivapalan, R. A. and H. H. Savenije, "Patterns of similarity of seasonal water balances: A window into streamflow variability over a range of time scales", *Water Resources Research*, vol. 50, no. 7, pp. 5638-5661, 2014.
- [19] B. Bergerot, V. Bret and F. Cattaneo, "Similarity in seasonal flow regimes, not regional environmental classifications explain synchrony in brown trout population dynamics in France", *Freshwater Biology*, vol. 64, no. 6, pp. 1226-1238, 2019.
- [20] D. H. Burn, "Catchment similarity for regional flood frequency analysis using seasonality measures", *Journal of Hydrology*, vol. 202, pp. 212-230, 1997.
- [21] B. Önöz and A. Albostan, "Hidroelektrik santral planlama ve işletmesinde yüksek akımların mevsimselliğinin belirlenmesi", *TMMOB Türkiye VI. Enerji Sempozyumu*, pp.196-206, 2007.
- [22] W. R. Berghuijs, M. Sivapalan, R. A. Woods and H. H. Savenije, "Patterns of similarity of seasonal water

- balances: A window into streamflow variability over a range of time scales”, *Water Resources Research*, vol. 50, no. 7, pp. 5638-5661, 2014.
- [23] A. Fathabadi and V. Anamoradi, “Evaluation the efficiency of flow duration curve based and statistical criteria objective functions in calibrating hydrological model”, *Watershed Engineering and Management*, vol. 13, no. 3, pp. 548-562, 2021.
- [24] X. Gong, and M. B. Richman, “On the application of cluster analysis to growing season precipitation data in North America East of the Rockies”, *Journal of Climate*, vol. 8, pp. 897-931, 1994.
- [25] SYGM, “İklim değişikliğinin su kaynaklarına etkisi projesi proje nihai raporu”, T.C. Orman ve Su İşleri Bakanlığı, 2016.



BMBAD
BJESR

Mühendislik Bilimleri ve Araştırmaları Dergisi
Journal of Engineering Sciences and Researches



Automatic Classification of Healthy and Sick Broilers in Terms of Avian Influenza by Using Neural Networks

Sağlıklı ve Hasta Etlik Piliçlerin Kuş Gribi Açısından Sinir Ağları Kullanarak Otomatik Sınıflandırılması

¹Yalçın IŞIK , ²Ahmet KAYABAŞI 

¹Selçuk Üniversitesi, Silifke-Taşucu Meslek Yüksekokulu, Silifke/Mersin, Türkiye

²Karamanoğlu Mehmetbey Üniversitesi, Mühendislik Fakültesi, Karaman, Türkiye

¹isiky@selcuk.edu.tr, ²ahmetkayabasi@kmu.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 5 August 2022

Accepted : 2 September 2022

Keywords:

Avian Influenza, Broiler Chicken, Classification, Neural Networks

ABSTRACT

Poultry meat containing low fat and high protein is an important and economical protein source in providing the animal protein requirement for human nutrition. The frequent emergence of poultry diseases such as avian influenza is the feature of fast-spread in farms seriously threatens both the economy and human health. In this study, neural network (NNs) models are proposed for the classification of broiler chickens as healthy and sick for earlier detection of poultry diseases. The NNs used in the classification are artificial neural network (ANN), adaptive neuro-fuzzy inference system (ANFIS), and support vector machine (SVM). In the literature, the data set which includes seven visual features were acquired through the image processing techniques (IPTs) and was used for training, testing, and validating the process of NN models. The results point out that, the computer vision-based application using NNs successfully classifies the broilers in terms of their health conditions.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 5 Ağustos 2022

Kabul : 2 Eylül 2022

Anahtar Kelimeler:

Kuş Gribi, Etlik Piliç, Sınıflandırma, Yapay Sinir Ağları

ÖZET

Düşük yağ ve yüksek protein içeren kanatlı eti, insan beslenmesi için hayvansal protein ihtiyacının sağlanmasında önemli ve ekonomik bir protein kaynağıdır. Çiftliklerde hızlı yayılma özelliği olan kuş gribi gibi kanatlı hastalıklarının sıklıkla ortaya çıkması hem ekonomiyi hem de insan sağlığını ciddi şekilde tehdit etmektedir. Bu çalışmada, kanatlı hastalıklarının erken tespiti için etlik piliçlerin sağlıklı ve hasta olarak sınıflandırılması için sinir ağı (NN'ler) modelleri önerilmiştir. Sınıflandırmada kullanılan NN'ler yapay sinir ağı (YSA), uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) ve destek vektör makinesidir (SVM). Literatürde, IPT'ler aracılığıyla yedi görsel özellik içeren veri seti elde edilmiş ve NN modellerinin eğitimi, test edilmesi ve doğrulanması için kullanılmıştır. Sonuçlar, NN'leri kullanan bilgisayarlı görü tabanlı uygulamanın, piliçleri sağlık koşulları açısından başarıyla sınıflandırdığını göstermektedir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. INTRODUCTION

Poultry meat is seen as an important and economical protein source in providing the animal protein needs required for human nutrition with its low fat and high protein content. Poultry meat consumption has been increased in recent years due to cheaper and shorter production times than red meat [1]. Therefore, poultry meat production increased to second place after pork in meat production. To meet this need, broiler chickens are grown which are fast-growing, better utilizing than feed and producing high-quality carcass. The most important factor in poultry farming is the health and regular control of poultry. The prevalence of poultry diseases has seriously affected poultry farming in recent years. This situation poses a threat not only for economic reasons but also for human health. Today, the diagnosis of poultry diseases is performed manually with the observation of the veterinarian and using various laboratory tests. However, manual processes are time-consuming, difficult, and yet fail to detect some of the diseases. Therefore, the rapid detection of poultry diseases has become an important issue in broiler breeding. The automatic detection of broiler diseases with the help of image processing techniques (IPTs) has been an important topic in the point of fast diagnosis. For this issue, different neural networks (NNs) such as artificial neural networks (ANNs), [2-3] adaptive neuro-fuzzy inference system (ANFIS) [4-5], and support vector machine (SVM) [6-7] can be combined with IPTs.

Several studies regarding the diagnosis of broiler diseases using NNs combined IPT have been proposed in the literature [8-14] In Zhuang et al. [8], it was comparatively determined by different machine learning algorithms that the broiler chickens were healthy or sick for avian influenza disease and the most successful result was obtained with SVM. The data set used in machine learning algorithms was created by computer vision. The body weights of live broilers were estimated by using IPT analysis by Mollah et al. [9] the estimated weights and manual measurement results were shown to be very close to each other. In Matin et al. [10], different artificial intelligence techniques (AITs) were used to estimate intestinal broiler microflora. The results show that the Enterobacteriaceae population was predicted better than the lactic acid bacteria with the proposed models. A novel algorithm of image analysis was investigated for early detection of lameness for broilers by Aydın [11] and some feature variables of broilers were detected by the proposed algorithm. In Pereira et al. [12], the welfare status in commercial broiler breeders was assessed by the data mining algorithms combined with IPT, and results were obtained successfully. The NNs such as ANN and ANFIS was proposed to predict chick body mass and more successful results were achieved with ANN by Ferraz et al. [13] In Mortensen et al. [14], the weight prediction of broiler chickens five regression model integrated with 3D computer vision was used and the best result was obtained with Bayesian ANN model.

In this study, the most used NNs such as feed-forward backpropagation (FFBP) [15] based ANN (ANNFFBP), learning vector quantization (LVQ) [16] based ANN (ANNLVQ), ANFIS, and SVM are modeled to classify broiler chickens as healthy and sick in terms of avian influenza infection. In the literature, the data set includes 7 main visual feature parameters that indicate the health status of broilers were acquired through the IPTs [17]. These visual parameters are concavity, skeleton attitude angle, skeleton splicing angle, and shape features (area-linear rate, elongation, and circularity). About seven visual features, the 300 data sets were created, 150 of which were healthy and 150 of sick broilers [17]. The accuracy of the models is determined by selected 260 training, 20 testing, and 20 validating broilers data set and their performances of classification are compared to each other. In the training process, the ANNFFBP, ANNLVQ, ANFIS, and SVM models successfully classify the broilers as healthy and sick with the accuracy of 100%, 99.23%, 99.64%, and 99.92%, respectively.

2. MATERIALS AND METHODS

2.1. Data Set

The automatic classification application based on NNs is carried out through a data set reported elsewhere [17] containing 7 main visual feature parameters of broiler chickens. In the literature it is stated that, four to six weeks old broiler chickens were divided into two groups and they were placed in isolator cages [8]. Ten of the twenty R381 group broilers were vaccinated with 0.1 mL volume of 106 EID₅₀ H5N2 avian influenza virus (R381/2008) and the other ten were intranasally injected with 0.1 mL phosphate-buffered saline (PBS). Clinical symptoms of avian influenza were observed in twenty broilers after 14 days [8]. As shown in Figure 1, the images of broilers were captured with a resolution of 640 by 480 pixels by using a Logitech C922 CCD camera, and image processing was performed using an algorithm based on VS2013 and OpenCV 2.4.13.8 To calculate the skeletal structure of the broiler, the algorithm only extracts the image of broiler from the complex background as shown in Figure 2. The eigenvectors are determined according to the features such as concavity, skeleton attitude angle, skeleton splicing angle, and shape features [8]. Briefly, the process for obtaining data on the visual properties of the broiler is shown in Figure 3 as topology.

2.2. Broiler Feature Extraction

In this section, the extraction of the features of broilers will be briefly summarized according to what is described in Zhuang et al. [8] Concavity, skeleton attitude angle, skeleton splicing angle, area-linear ratio, elongation, and

circularity were named K_0 , K_1 , K_2 , K_4 , K_5 , and K_6 respectively. K_3 was obtained by using the methods of skeleton simplification and skeleton splicing.



Figure 1. Image of broilers capture environment [8].



Figure 2. Image of extracted broiler from the background [8].

2.2.1. Concavity

There is a difference in the concavity between a broiler caught in avian influenza and a healthy broiler. The steepness appears in the middle of the sick broiler but this is concave in the healthy broiler. For the polygon to be convex, all inner angles of the polygon must be less than 180 degrees. For this reason, the back of the broilers with a high probability of disease is convex and K_0 is set to -1. The K_0 can be calculated as shown in Equation (1) [8].

$$K_0 = \hat{a}_{i=1}^n \frac{b(s_1, s_2)l(s_1)l(s_2)}{[l(s_1)+l(s_2)]r} \quad (1)$$

2.2.2. Skeleton Attitude Angle

The angle (β) between the skeleton and horizontal plane is relatively large when the broiler is healthy [8]. Therefore, as shown in Equation (2), the skeleton can be used as a feature to separate the healthy broiler from the sick broiler [8].

$$K_1 = \hat{a}_{i=1}^n \frac{l_i}{L} b \quad (2)$$

2.2.3. Skeleton Splicing Angle

As shown in Equation (3), the β angle is less than 90° ($0^\circ < \beta < 90^\circ$). In Equation (3), K_2 is the skeleton splicing angle. After K_2 was obtained, K_3 was obtained by using the methods of skeleton simplification and skeleton splicing [8].

$$K_2 = b = \arctan \frac{\hat{a}_{i=1}^n |y_i^r - y_i^l|}{\hat{a}_{i=1}^n |x_i^r - x_i^l|} \quad (3)$$

2.2.4. Shape Features

In addition to the skeletal features of broilers, the area-linear ratio, elongation, and circularity also reflect the shape features of broilers. The area-linear ratio (K_4), elongation (K_5), and circularity (K_6) can be formulated as follows [8]:

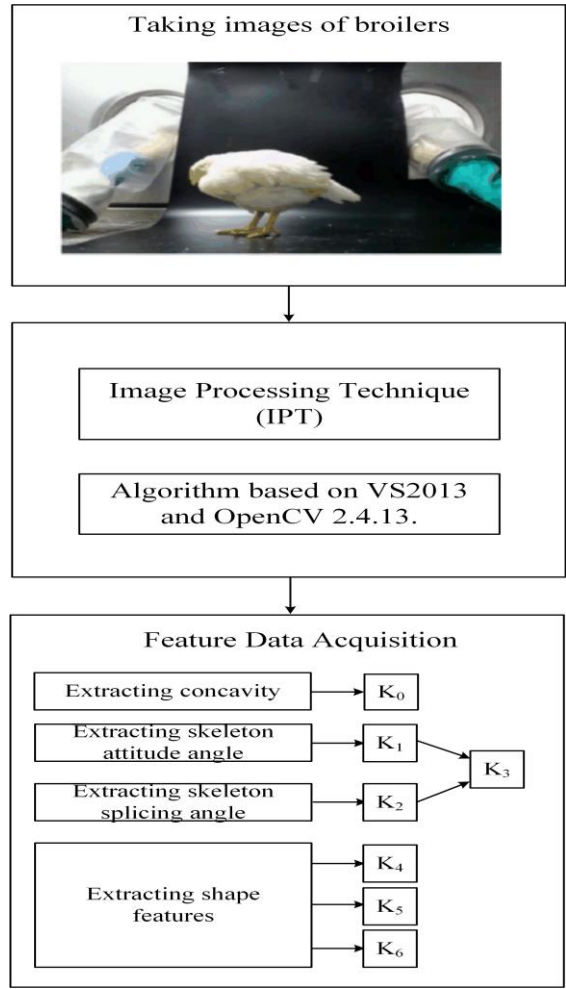


Figure 3. The topology of IPT.

$$K_4 = \frac{S}{C} \tag{4}$$

$$K_5 = \frac{H}{W} \tag{5}$$

$$K_6 = \frac{4pS}{C^2} \tag{6}$$

Where S , C , H , and W are respectively the area of the contour, the circumference of the contour, the height of the circumscribed rectangle, and the width of the circumscribed rectangle [8].

In Figure 4, 2D scattering of the broilers' features is demonstrated to show how healthy and sick broilers discriminate among each other by the feature parameters. In addition, the graphs of all feature parameters (K_0 , K_1 , K_2 , K_3 , K_4 , K_5 , and K_6) are plotted in Figure 5. It is observed that healthy and sick broilers distinctly cluster concerning the visual feature parameters.




Figure 4. 2D scattering of 300 broilers according to feature parameters.

2.3. Neural Networks

The NNs such as ANN, ANFIS, and SVM are beautiful biologically-inspired programming paradigm that enables a computer to learn from observational data [2, 4, 6]. The NNs currently provide the best solutions to many problems in image recognition. The NNs interpret the raw input by labeling or clustering with a kind of machine perception. They help to group unlabeled data according to similarities between sample inputs and classify data when they have a data set labeled for training [9-14]. The modeling and training of the ANN, ANFIS, and SVM for the classification of broilers in terms of avian influenza are described below.

2.3.1. Modelling of Neural Networks

To use easier, the NNs, a graphical user interface (GUI) is prepared as seen in Figure 6 for the classification of broilers.

Before preparing the GUI, NNs are modeled and trained with appropriate set parameters according to the topology illustrated in Figure 7.

According to the results of the training, the models are updated and the training is repeated. Modeling and training processes are carried out one after the other to try to obtain the lowest classification error. The ANNFFBP, ANFIS, and SVM models numerically calculate the outputs according to mean absolute percentage error (MAPE) in given Equation (7).

$$MAPE = \frac{\sum \left| \frac{Target - Output}{Target} \right| \times 100}{Number\ of\ total\ data} \quad (7)$$

where the target is “1” or “2” which respectively correspond to “healthy broilers” and “sick broilers”.

ANN is one of the main tools used in machine learning. The ANN consists of neurons that are organized into different layers. These neurons containing the non-linear type of functions are mutually connected by synaptic weights. These weights increase or decrease to output closer to the target throughout the training process [2]. As shown in Figure 8a and 8b, along with the set parameters given in Table 1, ANNFFBP and ANNLVQ are designed to classify the broilers into “healthy” or “sick” according to the feature parameters.

The ANNFFBP model is constructed with an input layer (7 neurons), two hidden layers (6 and 3 neurons), and an output layer (1 neuron). The “Logarithm sigmoid” function is used for both input and hidden layers while the “purelin” function is utilized for the output layer. Also, the ANNLVQ model is constructed with an input layer having 7 neurons, one hidden layer having 7 neurons and one output layer has 2 neurons.

Table 1. The set parameters of the ANN model.

Model	Parameters	Set type/value
ANN _{FFBP}	Epochs	40
	Minimum gradient descent	10 ⁻¹⁰
	Momentum parameter (μ)	0.0003
	μ increment	0.3
	μ decrement	3
	Seed value	1108444055
ANN _{LVQ}	Epochs	100
	Minimum gradient descent	10 ⁻⁶
	Learning rate	0.01
	Validation checks	6
	Output class percentage	0.5, 05

The ANFIS is a combination of two methods of ANN and fuzzy inference system (FIS) [18]. ANFIS is a fuzzy system whose membership function parameters have been tuned using neuro-adaptive learning methods similar to methods used in training ANN. ANFIS is generally formed of 5 layers that include 1 input, 3 hidden, and 1 output layer. Hidden layers consist of two membership functions (MFs) of input and output layers and one fuzzy logic rule layer [4]. The classification of broilers is constructed on Sugeno type FIS-based ANFIS, as illustrated in Figure 9, and configuration parameters of the ANFIS model, are tabulated in Table 2. The membership functions (MFs) of the ANFIS network are the Gaussian function for the input and linear function for the output [18].

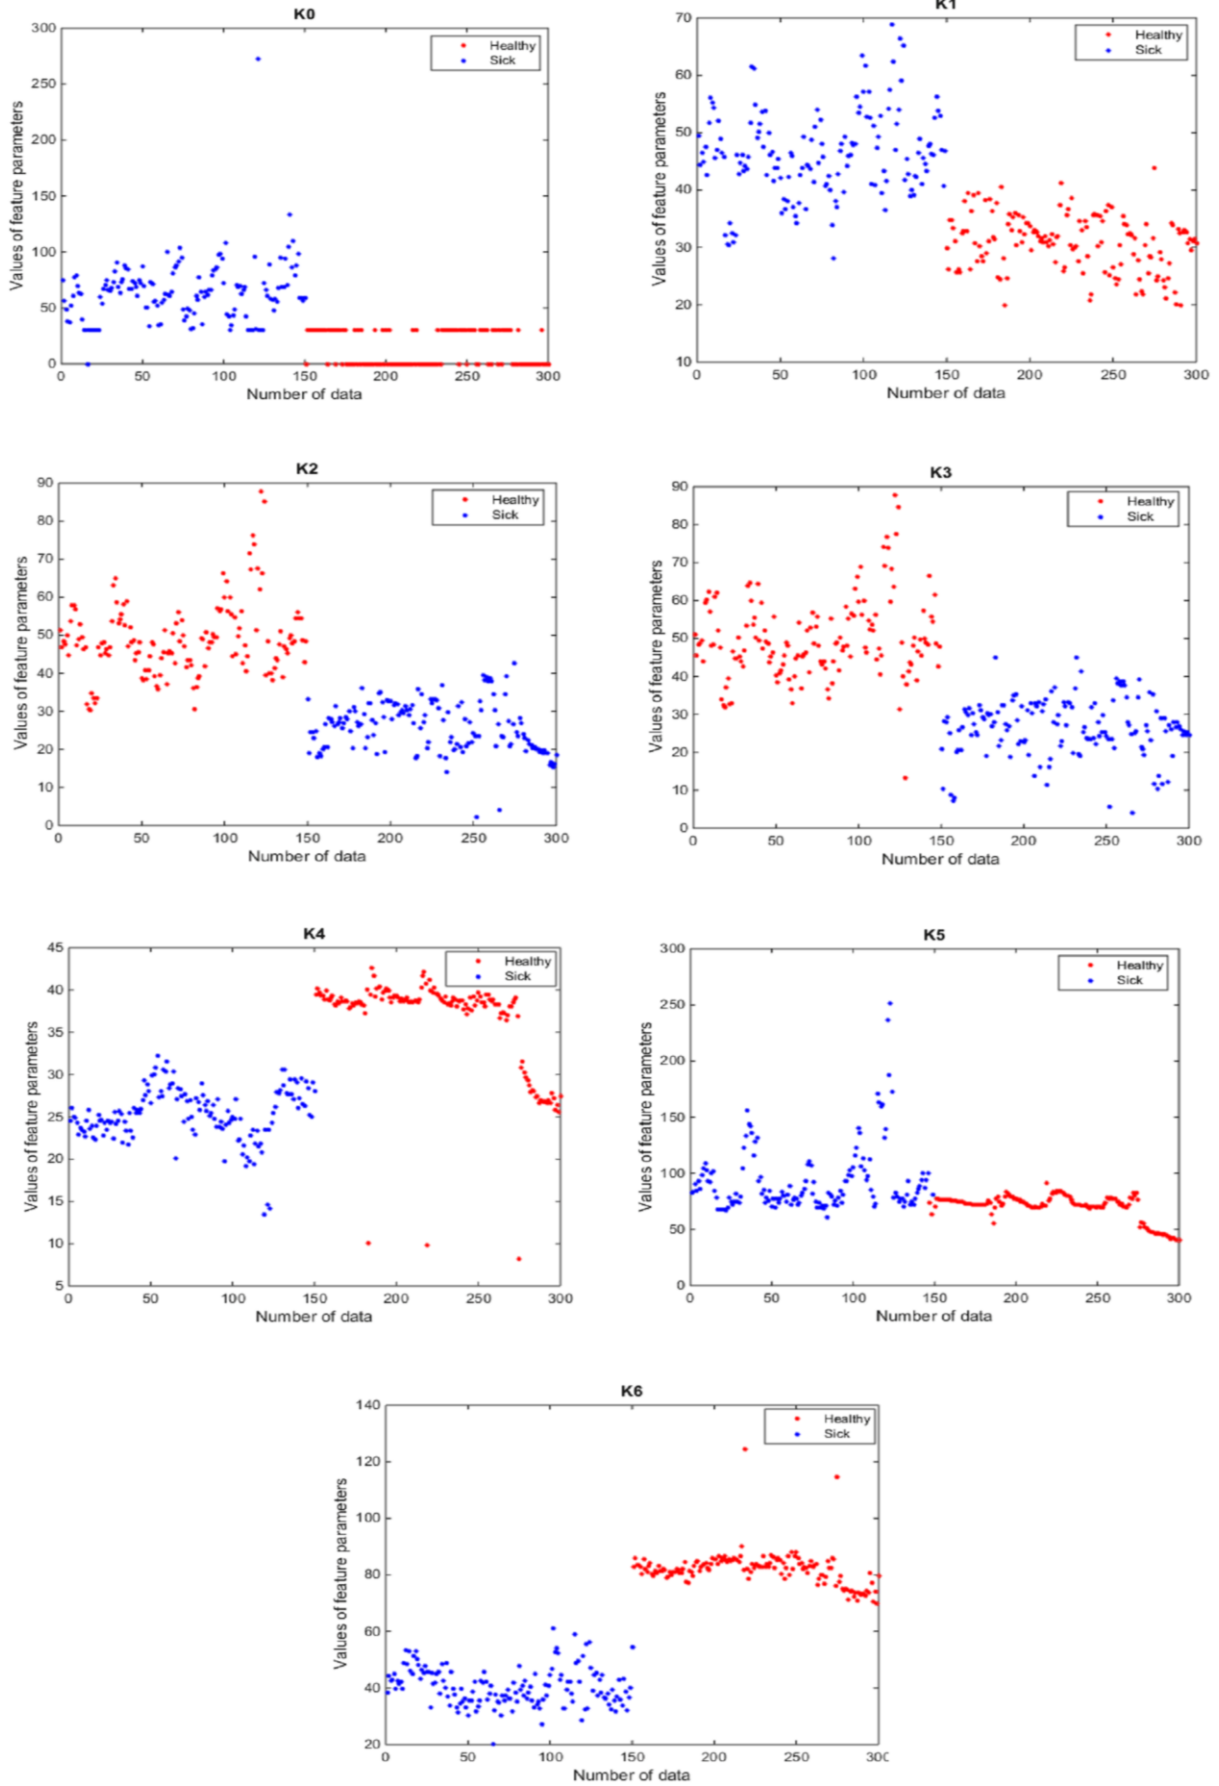


Figure 5. Separately graphs of feature parameters.

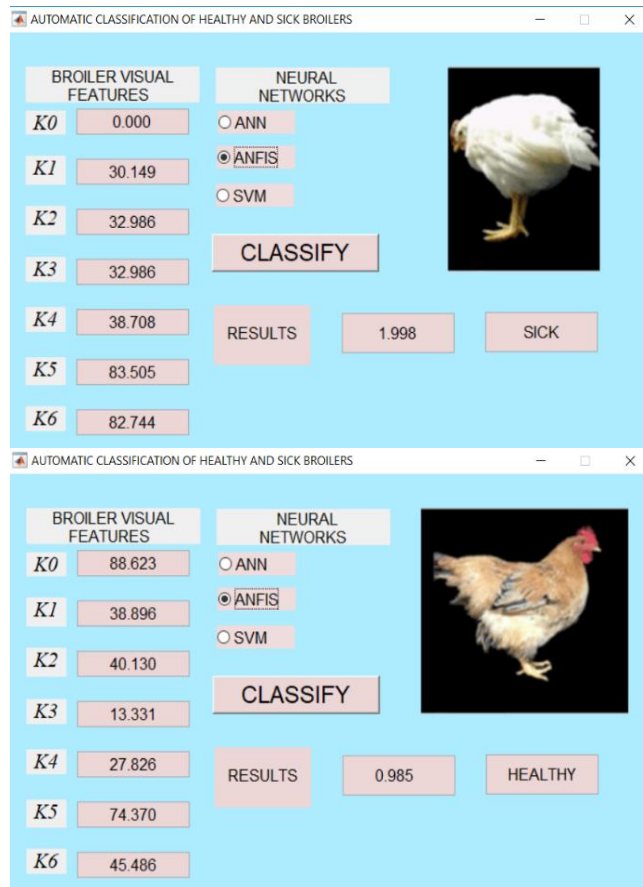


Figure 6. Screenshots of GUI for the NN models.

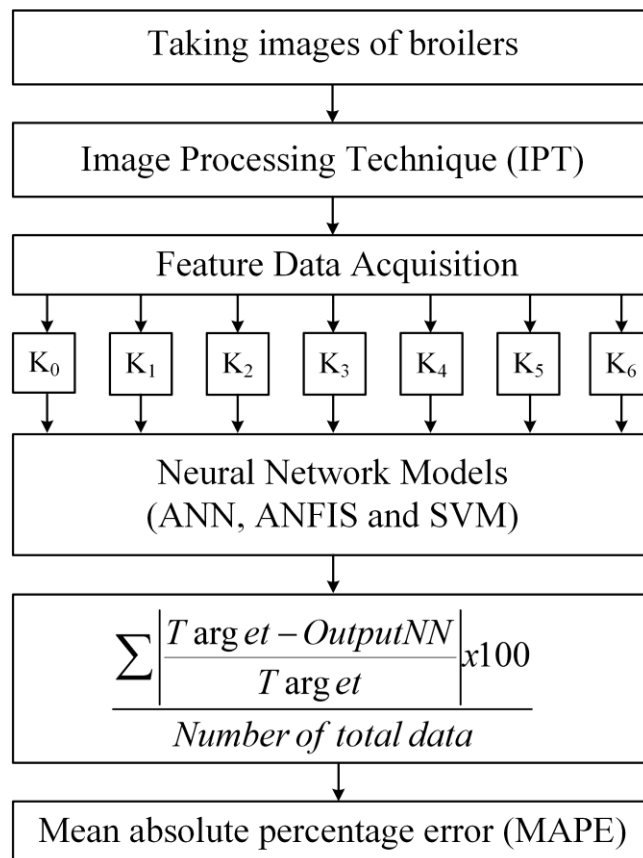


Figure 7. Topology of the NN models.

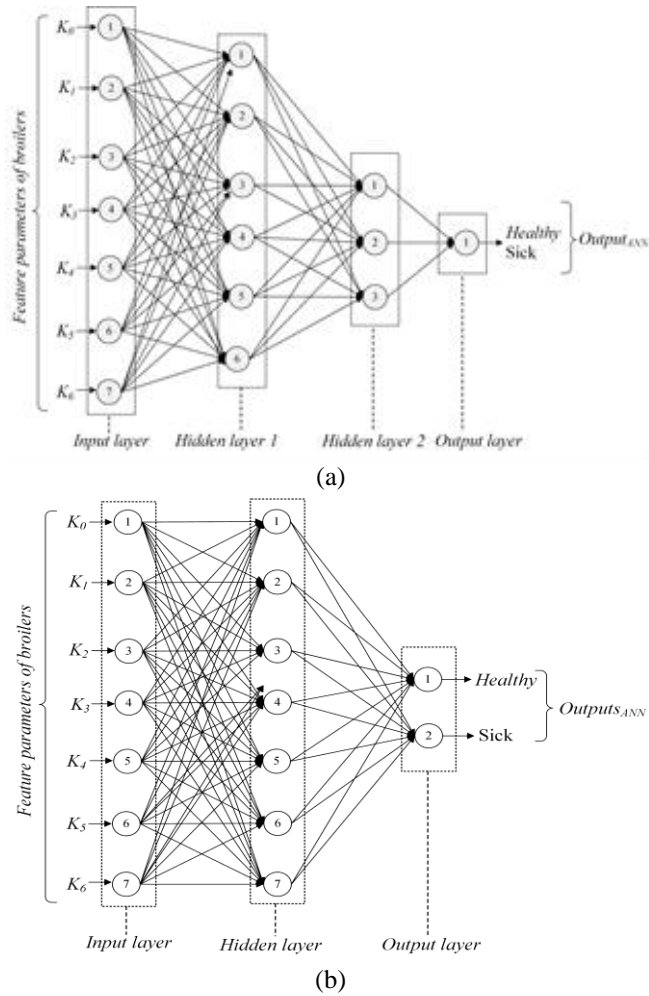


Figure 8. Topology of the NN models(a) ANNFFBP model (b) ANNLVQ model.

Table 2. The set parameters of the ANFIS model.

Model	Parameters	Set type/value
ANFIS	Epochs	150
	Range of influence	0.5
	Squash factor	1.25
	Accept ratio	0.5
	Reject ratio	0.15
	Seed value	1948281958

SVM is a supervised NN algorithm that can be used especially for classification problems. In this algorithm, each data is represented as a dot in n-dimensional space, and then it is performed classification by finding a hyperplane that separates the data very well. The data is mapped to multidimensional space by using kernel functions in multi-nonlinear problems with multi-parameter [19].

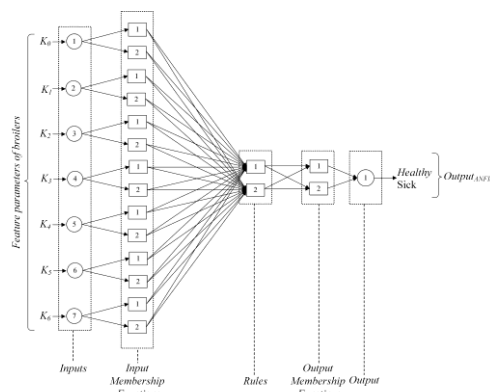


Figure 9. ANFIS model.

SVM network generally has two feed-forward layers similar to ANN. In the SVM model, the visual data of broilers is mapped to higher dimensional space using the Gaussian Kernel function [6]. SVM modeled in this study for broiler classification is illustrated in Figure 10 along with the set parameters given in Table 3.




Figure 10. SVM model.

Table 3. The set parameters of the SVM model.

Model	Parameters	Set type/value
SVM	Kernel function	Gaussian
	Kernel function coefficient (σ)	10
	Penalty weight (C)	1000000

2.3.2. Training of Neural Networks

The flowchart prepared for the training of NNs is seen in Figure 11. 260 visual data of broilers randomly selected from 300 data are used for the training of NNs. To optimize the network output during the training phase, NN models are trained with different algorithms. The models of ANNFFBP, ANNLVQ, ANFIS, and SVM are trained Levenberg-Marquardt algorithm [15], random weight/bias rule [16], hybrid-learning algorithm [4], and quadratic programming algorithm [19], respectively.

As shown in Figure 12, the NNs classify broilers as healthy or sick if numerical results are in the range of 0.9-1.1 and 1.9-2.1, respectively. As a result of the training, MAPE values are calculated as 0.0001% for the ANNFFBP model, 0.356% for the ANFIS model, and 0.073% for the SVM model. Only two of 260 data sets used for the training process are incorrectly classified in the ANNLVQ model. The classification of broilers is carried out as a regression problem in ANNFFBP, ANFIS, and SVM models. But, it is carried out as a classification problem with 2 outputs in the ANNLVQ model.




Figure 12. Numerical training results of the NN models.

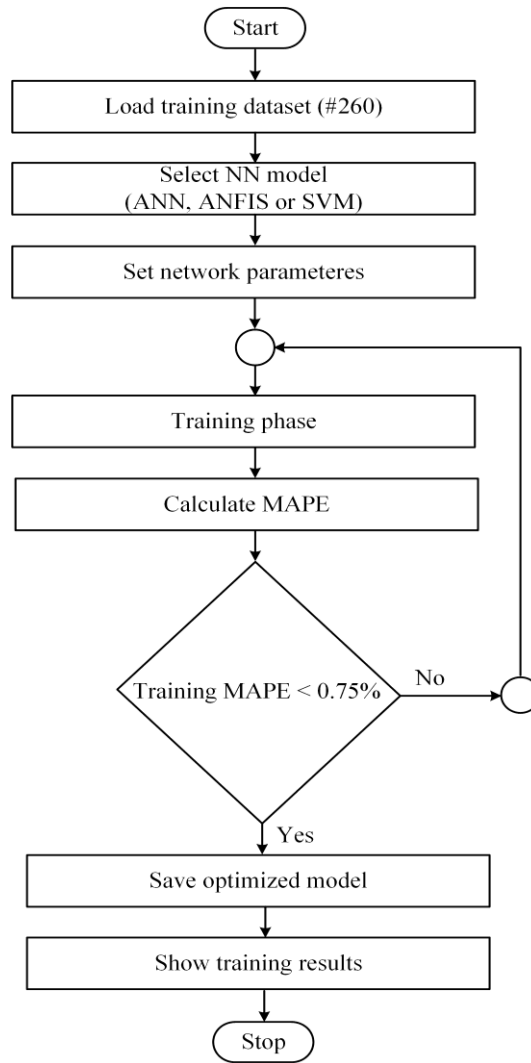


Figure 11. Flowchart of the training process of NNs models.

2.3.3. Testing of Neural Networks

The data of 20 broilers' visual features are used to test the accuracy of the NNs. The tabulated in Table 4, 20 test data are randomly selected among 300 broiler visual features and are not utilized during the training phase. The results of NNs are tabulated in Table 5 for the analysis of the testing process. The ANNFBP, ANFIS, and SVM models numerically classify the broilers in terms of avian influenza with 0.001% (accuracy of 100%), 0.590% (accuracy of 99.41%), and 0.393% (accuracy of 99.61%), respectively. The results of the ANNLVQ model are tabulated in Table 6 for the testing process. As it is seen from the test results given in Table 5, Table 6, and Figure 13, the modeled NNs are successfully implemented to classify the broilers as “healthy” or “sick”. Only one of the 20 data sets used for the testing process is misclassified in the ANNLVQ model.

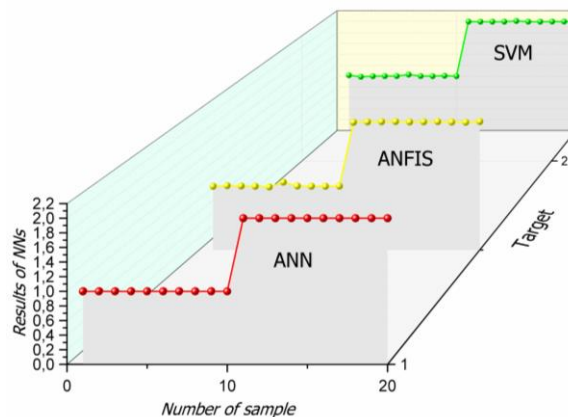


Figure 13. Numerical testing results of the NN model.

2.4. Validate and Comparison of Neural Networks

The proposed NNs are validated with the remaining 20 broiler data given in Table 7. The results of models are compared with in terms of MAPE. The design of ANN is easier and simpler than the ANFIS and SVM for this classification task in terms of the design of NNs. In the training process, the computational time is the longest in the ANFIS model, whereas it is almost the same in all models in the testing process. The data of 20 broilers not utilized during the training phase is used to validate the accuracy of the NNs. To analyze the validating process, the results of NNs are tabulated in Table 8 and Table 9. The ANNFFBP, ANFIS, and SVM models successfully classify the broilers as healthy and sick with the accuracy of 100% (MAPE of 0.001%), 99.62% (MAPE of 0.381%), and 99.31% (MAPE of 0.687%), respectively. All 20 data sets used for the validating process are correctly classified in the ANNLVQ model. As it is seen from the validating results given in Table 8, Table 9, and Figure 14, proposed models can be successfully implemented to such classification of broilers as healthy or sick. It is seen from these results that the proposed NN models based on IPT are successful. These models can be used to automatically detect sick broilers on a farm as shown in Figure 15. In this regard, images taken at certain intervals with cameras on a farm can be analyzed using NNs. After determining the coordinate of the sick broiler, it can be taken to another area by removing the broiler with a 3-dimensional movable mechanism. In this way, early screening can be done by making an instant scan and the spread can be prevented. Also, the presented models can be easily integrated into the farm industry to automatically classify different animals.

Table 4. The used dataset in the testing process.

Sample	Broiler visual feature parameters						
	K ₀	K ₁	K ₂	K ₃	K ₄	K ₅	K ₆
1	63.107	45.511	47.432	48.280	24.506	92.983	49.032
2	77.059	56.150	57.923	60.245	23.494	104.790	41.570
3	94.870	52.251	53.972	53.208	27.032	106.771	39.533
4	48.201	40.805	44.882	52.308	21.656	102.395	44.597
5	88.663	38.896	40.130	13.331	27.826	74.370	45.486
6	30.000	30.537	30.441	32.421	25.180	67.822	53.184
7	42.109	40.774	41.463	43.884	22.894	74.899	31.859
8	57.653	43.820	45.626	45.525	28.944	76.513	38.068
9	56.507	44.460	46.838	45.537	26.090	83.886	44.182
10	71.938	46.576	48.617	48.596	26.984	84.884	34.354
11	0.000	33.062	27.811	27.422	40.251	79.293	84.501
12	0.000	25.632	27.911	27.911	39.089	68.627	86.474
13	30.000	30.170	31.432	31.776	37.738	71.717	80.250
14	0.000	38.272	28.407	32.292	38.397	72.330	80.937
15	30.000	30.656	31.446	31.735	38.659	74.510	81.526
16	0.000	37.426	25.710	27.892	40.695	71.698	81.854
17	0.000	27.892	26.842	11.737	29.655	52.381	74.457
18	0.000	35.241	28.457	28.457	39.116	80.000	82.462
19	0.000	30.149	32.986	32.986	38.708	83.505	82.744
20	0.000	37.808	27.126	29.947	38.190	72.195	80.570




Figure 14. Numerical testing results of the NN models.

Table 5. The results of NNs in the test process.

#	Target	Neural network results								
		Numerical outputs			Absolute Percentage Error			Classification		
		ANN _{FFBP}	ANFIS	SVM	ANN _{FFBP}	ANFIS	SVM	ANN _{FFBP}	ANFIS	SVM
1	1.000	1.000	0.996	1.016	0.000	0.420	1.568	Healthy	Healthy	Healthy
2	1.000	1.000	1.005	0.988	0.000	0.494	1.168	Healthy	Healthy	Healthy
3	1.000	1.000	1.000	0.999	0.000	0.014	0.100	Healthy	Healthy	Healthy
4	1.000	1.000	0.996	1.001	0.000	0.420	0.100	Healthy	Healthy	Healthy
5	1.000	1.000	0.985	1.001	0.000	1.457	0.100	Healthy	Healthy	Healthy
6	1.000	1.000	1.060	1.029	0.000	6.031	2.851	Healthy	Healthy	Healthy
7	1.000	1.000	1.000	1.001	0.000	0.035	0.100	Healthy	Healthy	Healthy
8	1.000	1.000	0.996	1.000	0.000	0.372	0.046	Healthy	Healthy	Healthy
9	1.000	1.000	0.996	1.007	0.000	0.438	0.658	Healthy	Healthy	Healthy
10	1.000	1.000	0.999	0.999	0.000	0.077	0.100	Healthy	Healthy	Healthy
11	2.000	2.000	1.995	2.001	0.000	0.238	0.050	Sick	Sick	Sick
12	2.000	2.000	2.001	1.999	0.000	0.058	0.050	Sick	Sick	Sick
13	2.000	2.000	2.005	1.999	0.000	0.251	0.050	Sick	Sick	Sick
14	2.000	2.000	2.007	1.999	0.000	0.357	0.050	Sick	Sick	Sick
15	2.000	2.000	2.001	2.012	0.000	0.057	0.614	Sick	Sick	Sick
16	2.000	2.000	2.003	1.999	0.000	0.138	0.050	Sick	Sick	Sick
17	2.000	2.000	2.006	1.999	0.000	0.316	0.050	Sick	Sick	Sick
18	2.000	2.000	1.998	2.001	0.000	0.075	0.050	Sick	Sick	Sick
19	2.000	2.000	1.996	2.001	0.000	0.184	0.050	Sick	Sick	Sick
20	2.000	2.000	2.007	2.001	0.000	0.367	0.050	Sick	Sick	Sick
Mean Absolute Percentage Error					0.001%	0.590%	0.393%			
							Accuracy	100%	99.41%	99.61%

Table 6. The used dataset in the testing process.

#	Target		Numerical outputs		Classification
			ANN _{LVQ}	ANN _{LVQ}	ANN _{LVQ}
1	0.000	1.000	0.000	1.000	Healthy
2	0.000	1.000	0.000	1.000	Healthy
3	0.000	1.000	0.000	1.000	Healthy
4	0.000	1.000	0.000	1.000	Healthy
5	0.000	1.000	0.000	1.000	Healthy
6	0.000	1.000	1.000	0.000	Sick
7	0.000	1.000	0.000	1.000	Healthy
8	0.000	1.000	0.000	1.000	Healthy
9	0.000	1.000	0.000	1.000	Healthy
10	0.000	1.000	0.000	1.000	Healthy
11	1.000	0.000	1.000	0.000	Sick
12	1.000	0.000	1.000	0.000	Sick
13	1.000	0.000	1.000	0.000	Sick
14	1.000	0.000	1.000	0.000	Sick
15	1.000	0.000	1.000	0.000	Sick
16	1.000	0.000	1.000	0.000	Sick
17	1.000	0.000	1.000	0.000	Sick
18	1.000	0.000	1.000	0.000	Sick
19	1.000	0.000	1.000	0.000	Sick
20	1.000	0.000	1.000	0.000	Sick

Table 7. The used dataset in the validating process.

Sample	Broiler visual feature parameters						
	K ₀	K ₁	K ₂	K ₃	K ₄	K ₅	K ₆
1	73.249	42.214	44.400	45.639	27.376	77.211	31.599
2	35.776	47.980	49.050	49.021	25.439	79.237	38.477
3	32.124	33.947	36.189	36.621	28.928	71.260	47.783
4	69.812	53.009	56.221	56.280	19.768	112.752	39.254
5	88.663	38.896	40.130	13.331	27.826	74.370	45.486
6	50.140	36.713	38.415	41.469	30.807	77.000	38.730
7	63.107	45.511	47.432	48.280	24.506	92.983	49.032
8	59.294	46.962	48.768	48.673	25.266	73.646	32.114
9	48.201	40.805	44.882	52.308	21.656	102.395	44.597
10	30.000	65.139	85.255	84.659	24.316	172.881	56.283
11	30.000	24.690	23.574	23.574	39.190	70.202	86.018
12	30.000	30.656	31.446	31.735	38.659	74.510	81.526
13	0.000	30.149	32.986	32.986	38.708	83.505	82.744
14	0.000	31.578	30.196	32.819	38.687	71.212	85.141
15	0.000	37.808	27.126	29.947	38.190	72.195	80.570
16	0.000	34.013	38.177	38.177	38.914	77.500	80.801
17	30.000	30.170	31.432	31.776	37.738	71.717	80.250
18	0.000	27.487	17.788	16.077	40.307	70.531	84.474
19	0.000	35.241	28.457	28.457	39.116	80.000	82.462
20	30.000	22.279	23.376	25.104	36.441	70.202	76.827




Figure 15. The system automatically detects sick broilers.

Table 8. The results of NNs in the validating process.

#	Target	Neural network results									
		Numerical outputs			Absolute Percentage Error			Classification			
		ANN _{FFBP}	ANFIS	SVM	ANN _{FFBP}	ANFIS	SVM	ANN _{FFBP}	ANFIS	SVM	
1	1.000	1.000	0.998	1.001	0.000	0.237	0.100	Healthy	Healthy	Healthy	
2	1.000	1.000	1.001	1.001	0.000	0.070	0.100	Healthy	Healthy	Healthy	
3	1.000	1.000	1.020	0.999	0.000	2.014	0.100	Healthy	Healthy	Healthy	
4	1.000	1.000	1.004	1.001	0.000	0.374	0.100	Healthy	Healthy	Healthy	
5	1.000	1.000	0.985	1.001	0.000	1.457	0.100	Healthy	Healthy	Healthy	
6	1.000	1.000	0.995	1.001	0.000	0.508	0.100	Healthy	Healthy	Healthy	
7	1.000	1.000	0.996	1.118	0.000	0.420	11.805	Healthy	Healthy	Sick	
8	1.000	1.000	1.002	1.001	0.000	0.190	0.100	Healthy	Healthy	Healthy	
9	1.000	1.000	0.996	1.001	0.000	0.420	0.100	Healthy	Healthy	Healthy	
10	1.000	1.000	0.999	1.001	0.000	0.136	0.100	Healthy	Healthy	Healthy	
11	2.000	2.000	1.998	2.001	0.000	0.087	0.050	Sick	Sick	Sick	
12	2.000	2.000	2.001	2.012	0.000	0.057	0.614	Sick	Sick	Sick	
13	2.000	2.000	1.996	2.001	0.000	0.184	0.050	Sick	Sick	Sick	
14	2.000	2.000	2.003	2.000	0.000	0.144	0.015	Sick	Sick	Sick	
15	2.000	2.000	2.007	2.001	0.000	0.367	0.050	Sick	Sick	Sick	
16	2.000	2.000	2.002	2.001	0.000	0.097	0.050	Sick	Sick	Sick	
17	2.000	2.000	2.005	1.999	0.000	0.251	0.050	Sick	Sick	Sick	
18	2.000	2.000	1.999	1.999	0.000	0.047	0.050	Sick	Sick	Sick	
19	2.000	2.000	1.998	2.001	0.000	0.075	0.050	Sick	Sick	Sick	
20	2.000	2.000	2.010	1.999	0.000	0.491	0.050	Sick	Sick	Sick	
Mean Absolute Percentage Error					0.001%	0.381%	0.687%				
								Accuracy	100%	99.62%	99.31%

Table 9. The results of the ANNLVQ model in the validating process.

#	Target		Numerical outputs		Classification
			ANN _{LVQ}		ANN _{LVQ}
1	0.000	1.000	0.000	1.000	Healthy
2	0.000	1.000	0.000	1.000	Healthy
3	0.000	1.000	0.000	1.000	Healthy
4	0.000	1.000	0.000	1.000	Healthy
5	0.000	1.000	0.000	1.000	Healthy
6	0.000	1.000	1.000	0.000	Sick
7	0.000	1.000	0.000	1.000	Healthy
8	0.000	1.000	0.000	1.000	Healthy
9	0.000	1.000	0.000	1.000	Healthy
10	0.000	1.000	0.000	1.000	Healthy
11	1.000	0.000	1.000	0.000	Sick
12	1.000	0.000	1.000	0.000	Sick
13	1.000	0.000	1.000	0.000	Sick
14	1.000	0.000	1.000	0.000	Sick
15	1.000	0.000	1.000	0.000	Sick
16	1.000	0.000	1.000	0.000	Sick
17	1.000	0.000	1.000	0.000	Sick
18	1.000	0.000	1.000	0.000	Sick
19	1.000	0.000	1.000	0.000	Sick
20	1.000	0.000	1.000	0.000	Sick

3. CONCLUSION

In this paper, applications of IPT based NNs are successfully carried out for the classification of broilers in terms of avian influenza. The models of ANN, ANFIS, and SVM are conducted through 300 data of which visual features of broilers were acquired using IPT. The training, testing, and validation of the NN models are accomplished by using data of 260, 20, and 20 visual data, respectively. In terms of the design procedure and classification performance the ANNFFBP, ANNLVQ, ANFIS, and SVM models classify the outputs with the accuracy of 100% (MAPE of 0.001%), 100%, 99.62% (MAPE of 0.381%), and 99.31% (MAPE of 0.687%) for validating process,

respectively. In the design and optimization procedure, the modeling of ANN is easier than ANFIS and SVM for classification. The proposed NN models can be integrated into a hardware system to automatically classify sick broilers on a farm. In addition, the automatic classification of broilers in terms of different health problems can be made after NNs are updated.

Acknowledgment

The authors are thankful to RAC-LAB (www.rac-lab.com) for providing the trial version of their commercial software for this study.

Author's Contributions

The contributions of the authors is equal.

Statement of Conflict of Interest

Authors have declared no conflict of interest.



REFERENCES

- [1] A. C. Fanatico et al., "Meat quality of slow-and fast-growing chicken genotypes fed low-nutrient or standard diets and raised indoors or with outdoor access", *Poultry Science*, vol. 86, no. 10, pp. 2245-2255, 2007.
- [2] S. Haykin, "Neural networks: A comprehensive foundation", Macmillan College Publishing Company, New York, USA: hardbound, 1994, pp. 696.
- [3] K. Sabanci, A. Kayabasi, and A. Toktas, "Computer vision-based method for classification of wheat grains using artificial neural network", *J Sci Food Agric*, vol. 97, no. 8, pp. 2588-2593, 2017.
- [4] J. S. Jang, "ANFIS: adaptive-network-based fuzzy inference system", *IEEE Trans SystMan Cybern*, vol. 23, no. 3, pp. 665-685, 1993.
- [5] K. Sabanci, A. Toktas, A. Kayabasi, "Grain classifier with computer vision using adaptive neuro-fuzzy inference system", *J Sci Food Agric*, vol. 97, no. 12, pp. 3994-4000, 2017.
- [6] V. N. Vapnik, "Statistical Learning Theory", Wiley, New York, USA (1998).
- [7] A. Kayabasi, A. Toktas, K. Sabanci, and E. Yigit, "Automatic classification of agricultural grains: Comparison of neural networks", *Neural Netw World*, vol. 28, no. 3, pp. 213-224, 2018.
- [8] X. Zhuang, M. Bi, J. Guo, S. Wu, and T. Zhang, "Development of an early warning algorithm to detect sick broilers", *Comput Electron Agric*, vol. 144, pp. 102-113, 2018.
- [9] M. B..R. Mollah, M. A. Hasan, M. A. Salam, and M. A. Ali, "Digital image analysis to estimate the live weight of broiler", *Comput Electron Agric*, vol. 72, no. 1, pp. 48-52, 2010.
- [10] H. R. H. Matin, A. A. Saki, M. B. Varkeshi, and H. Z. Abyaneh, "Comparison and validation of artificial intelligence techniques to estimate intestinal broiler microflora", *Neural Comput Appl*, vol. 23, no. 1, pp. 61-66, 2013.
- [11] A. Aydin, "Development of an early detection system for the lameness of broilers using computer vision", *Comput Electron Agr*, vol. 136, pp. 140-146, 2017.
- [12] D. F. Pereira, B. C. Miyamoto, G. D. Maia, G. T. Sales, M. M. Magalhães, and R. S. Gates, "Machine vision to identify broiler breeder behaviour", *Comput Electron Agric*, vol. 99, pp. 194-199, 2013.
- [13] P. F. P. Ferraz, T. Yanagi Junior, H. Julio, Y. Fabián, J. D. O. Castro, R. S. Gates and A. T. Campos, "Predicting chick body mass by artificial intelligence-based models", *Pesqui Agropecu Bras*, vol. 49, no. 7, pp. 559-568, 2014.
- [14] A. K. Mortensen, P. Lisouski, and P. Ahrendt, "Weight prediction of broiler chickens using 3D computer vision", *Comput Electron Agric*, vol. 123, pp. 319-326, 2016.
- [15] M. T. Hagan, and M. B. Menhaj, "Training feedforward networks with the Marquardt algorithm", *IEEE Trans Neural Netw*, vol. 5, no. 6, pp. 989-993, 1994.
- [16] T. Temel, "A new classification algorithm: optimally generalized learning vector quantization (OGLVQ)", *Neural Netw World*, vol. 27, no. 6, pp. 569-576, 2017.
- [17] T. Zhang, M. Bi, J. Guo, and X. Zhuang, "Data for: Broiler chickens posture feature extraction and disease early-warning algorithm", *Mendeley Data*, 2017.
- [18] T. Takagi, and M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control", *IEEE Trans SystMan Cybern*, vol. 15, pp. 116-132, 1985.
- [19] N. Cristianini, and J. Shawe-Taylor, "An Introduction to Support Vector Machines and Other Kernel-based Learning Methods", Cambridge University Press, 2000.



Katı Hal Güç Kuvvetlendiricisinin LC-GFDM İletim Sinyali Üzerindeki Etkisinin İncelenmesi

Investigation of the Effect of Solid State Power Amplifier on LC-GFDM Transmission Signal

¹Sakir ŞİMŞİR , ²Necmi TAŞPINAR 

¹Nevşehir Hacı Bektaş Veli Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Nevşehir, Türkiye

²Erciyes Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Kayseri, Türkiye

¹sakirsimsir@nevsehir.edu.tr, ²taspinar@erciyes.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 9 August 2022

Accepted : 13 September 2022

Keywords:

LC-GFDM, Solid State Power Amplifier, 5G, High Power Amplifier, PAPR

ABSTRACT

In this study, solid state power amplifier (SSPA), which is among the most widely used high power amplifiers, was applied to the transmitter of low complex-generalized frequency division multiplexing (LC-GFDM), and it is aimed to reveal the effect of such nonlinear high power amplifiers on the LC-GFDM transmission signal and system performance. To this end, both the spectral characteristic and bit error rate performance of the LC-GFDM waveform was investigated for diversified values of smoothness coefficient (p) and input back off (IBO) parameters determining the degree of linearity and operating point of SSPA, respectively. In the simulation studies, it was observed that the distortions happening in the LC-GFDM signals with high PAPR as a result of amplification with SSPA cause serious enhancements in the amounts of both out-of-band radiation and bit error rate. On the other hand, it was demonstrated that the aforementioned enhancements can be controlled via the IBO and p parameters.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 9 Ağustos 2022

Kabul : 13 Eylül 2022

Anahtar Kelimeler:

LC-GFDM, Katı Hal Güç Kuvvetlendiricisi, 5G, Yüksek Güç Kuvvetlendiricisi, PAPR

ÖZET

Bu çalışmada, en yaygın kullanılan yüksek güç kuvvetlendiricileri arasında yer alan katı hal güç kuvvetlendiricisi (SSPA), düşük karmaşıklık-genelleştirilmiş frekans bölmeli çoğullama (LC-GFDM) vericisine uygulanmış olup, bu tür doğrusal olmayan yüksek güç kuvvetlendiricilerinin, LC-GFDM iletim sinyali ve sistem performansı üzerindeki etkisinin ortaya konması hedeflenmiştir. Bu amaçla, LC-GFDM dalga formunun hem spektral karakteristiği hem de bit hata oranı (BER) performansı, SSPA'nın sırasıyla doğrusallık derecesi ve çalışma noktasını belirleyen düzgünlük katsayısı (p) ve giriş geri çekme (IBO) parametrelerinin çeşitli değerleri için incelenmiştir. Simülasyon çalışmalarında, yüksek PAPR'lı LC-GFDM sinyallerinde SSPA ile gerçekleştirilen kuvvetlendirme sonucu meydana gelen bozulmaların hem bant dışı radyasyon hem de bit hata oranı miktarlarında ciddi artışlara neden olduğu görülmüştür. Diğer taraftan IBO ve p parametreleri ile söz konusu artışların kontrol edilebileceği ortaya konmuştur.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Dördüncü nesil (4G) haberleşme teknolojisinin 2010 yılı civarında hayatımıza girmesiyle birlikte, yüksek veri hızlarında kaliteli iletişim olanaklarından faydalanmak mümkün hale gelmiştir. Ancak, on yıldan daha kısa bir süre içerisinde, özellikle akıllı telefonlar ve mobil internet uyumlu diğer insan odaklı akıllı cihazların kullanımındaki aşırı artış, mobil veri trafiğinin daha önce hiç olmadığı kadar artmasına neden olmuştur. Veri trafiğindeki bu büyük artışla birlikte, sürekli gelişen mobil servisler ve uygulamalar mevcut hücreli sistemlerin limitlerini artık zorlamaya başlamıştır. Bir de, nesnelerin interneti (IoT) ve makine tipi haberleşme (MTC) gibi yakın gelecekte hayatımızın bir parçası olması beklenen yeni teknolojilerin yaygınlaşması ile birlikte, 4G'den 5G ve ötesi haberleşme teknolojilerine geçiş kaçınılmaz hale gelecektir [1-4].

Hali hazırda 4G haberleşme sistemlerinde, dikgen frekans bölme (OFDM) olarak isimlendirilen dalga formu kullanılmaktadır [5-7]. Çok taşıyıcı bir dalga formu olması nedeniyle OFDM, çok yönlü ortamlarda kullanılmaya oldukça uygun olup frekans seçici sönmeye karşı dayanıklı bir yapıya sahiptir. Ancak, bant dışı emisyon problemine sahip olması, kullanıcılar arası girişimi önlemek için alt taşıyıcılar arasında senkronizasyon işlemine ihtiyaç duyması ve frekans kaymalarına olan hassasiyeti, OFDM dalga formunun 5G ve ötesi haberleşme teknolojilerinin ihtiyaçlarını ne derecede karşılayabileceğinin sorgulanmasına yol açmış olup, araştırmacıları yeni nesil haberleşme sistemlerinde kullanılmak üzere OFDM'ye alternatif yeni dalga formları geliştirmeye itmiştir.

Genelleştirilmiş frekans bölme (GFDM) [8], mevcut 4G haberleşme sistemlerinde etkin olarak kullanılmakta olan OFDM dalga formunun sahip olduğu zayıflıklar göz önünde bulundurularak 5G ve ötesi haberleşme teknolojilerinin ihtiyaçlarını karşılamak üzere geliştirilmiş olan yeni bir dalga formudur. Sahip olduğu eşsiz özellikler sayesinde, GFDM dalga formunun ilerde OFDM yerine kullanılma potansiyeline sahip 5G ve ötesi dalga formu adayları arasında yerini alması çok uzun sürmemiştir. GFDM sisteminde alt taşıyıcıların her biri hem zaman hem de frekans domeninde dairesel olarak kaydırılan prototip bir filtre vasıtasıyla filtrelenmektedir. Bu filtreleme işlemi, bant dışı emisyonun bastırılmasını mümkün kılıp, kullanıcılar arasında ciddi bir girişime mahal vermeden dinamik bir spektrum tahsisi gerçekleştirilmesine olanak tanımaktadır. Bunun haricinde, GFDM sisteminin verici kısmında ayarlanabilir filtre kullanımı sayesinde, yüksek frekans lokalizasyon karakteristiklerine sahip iletim sinyalleri elde edilebilmektedir. Ayrıca, GFDM sisteminde hem zaman hem de frekans domeninde çok kullanıcı düzenleme yapmak mümkündür [8-10].

Diğer taraftan, GFDM dalga formunun bilim dünyasına sunulması üzerinden çok fazla süre geçmeden, ilgili dalga formunun LC-GFDM olarak isimlendirilen düşük karmaşıklık (LC) bir versiyonu geliştirilmiştir [11]. Bu yeni GFDM varyantında hem iletim sinyali üretimi hem de alınan sinyalin demodülasyonu, orijinal GFDM sistemine göre daha az hesaplama karmaşıklığı ile gerçekleştirilebilmektedir. LC-GFDM dalga formu ile, OFDM'ye ait birçok zayıflık giderilmiştir. Ancak çok taşıyıcı dalga formlarının kronik bir sorunu olarak bilinen yüksek tepe gücü/ortalama güç oranı (PAPR) problemine, LC-GFDM dalga formunda da rastlanmaktadır. Doğrusal olmayan yüksek güç kuvvetlendiricileri (HPA), iletim sinyallerinin kuvvetlendirilmesinde kullanılan, haberleşme sistemlerinin vazgeçilmez elemanlarından bir tanesidir. Bu tür kuvvetlendiricilerin doğru bir şekilde çalışabilmesi için, girişlerine uygulanan iletim sinyallerinin düşük PAPR değerlerine sahip olması gerekir. Aksi takdirde, yüksek PAPR'lı sinyaller, doğrusal olmayan HPA'ları doyuma ulaştırarak sağlıklı bir kuvvetlendirme işlemi gerçekleştirilmesine engel olmaktadır. Bunun sonucunda da sinyallerde bozulmalar meydana gelmekte ve sistem performansı düşmektedir. Bu çalışmada, oldukça yaygın bir kullanım alanına sahip bir tür doğrusal olmayan HPA modeli olan katı hal güç kuvvetlendiricisi (SSPA) [12], LC-GFDM vericisine entegre edilerek, LC-GFDM dalga formunun güç spektral yoğunluğu (PSD) ve bit hata oranı (BER) performansında meydana gelen değişim, söz konusu kuvvetlendiricinin çalışma noktasını belirleyen giriş geri çekme (IBO) parametresi ile doğrusallık derecesini tayin eden düzgünlük katsayısının (p) farklı değerleri için incelenmiştir.

Doğrusal olmayan HPA'ların OFDM sistem performansı üzerindeki etkisi ile ilgili literatürde çeşitli çalışmalar mevcuttur [13-16]: [13]'te, OFDM sisteminin bit hata oranı performansının SSPA tabanlı sinyal kuvvetlendirme işlemi kaynaklı doğrusal olmayan bozulmalar tarafından nasıl etkilendiği üzerine bir çalışma gerçekleştirilmiştir. Aynı çalışmada, doğrusal olmayan bozulma yoğunluğunu belirleyen parametreleri kontrol etmek için bazı analitik ifadeler geliştirilmiştir. [14]'te, farklı HPA türleri, OFDM sisteminin bit hata oranı ve güç spektral yoğunluğu performansı üzerindeki etkileri bakımından, değişik alt taşıyıcı sayıları, modülasyon teknikleri ve IBO değerleri için analiz edilmiştir. [15]'te, HPA'nın doğrusal olmama durumunu telafi etmek için kullanılan ön-bozucunun varlığında, OFDM sisteminin bit hata oranı performansında meydana gelen değişim, birkaç IBO değeri için incelenmiştir. [16]'da, frekans çoğullamalı OFDM sinyallerinin doğrusal olmayan bir HPA ile kuvvetlendirilmesinin spektral büyüme ve bit hata oranı performansı üzerindeki etkisi simülasyon çalışmaları vasıtasıyla değerlendirilmiştir.

Makalenin geri kalan kısmı şu şekilde organize edilmiştir: Bölüm 2'de, LC-GFDM sisteminde sinyal üretimi açıklanmıştır. Bölüm 3'te, SSPA ve çalışma prosedürü hakkında detaylı bir bilgilendirme yapılmıştır. Bölüm 4'te simülasyon sonuçlarının sunumu gerçekleştirilmiştir ve son olarak Bölüm 5'te verilen sonuç kısmıyla makale sonlandırılmıştır.

2. LC-GFDM SİSTEMİNDE SİNYAL ÜRETİMİ

LC-GFDM iletim sinyalinin üretilmesi için gereken işlemlerin yer aldığı blok diyagram Şekil 1'de gösterilmektedir [11, 17]. Şekil 1'den de açıkça görüleceği üzere, sinyal üretim sürecinde gerçekleştirilmesi gereken ilk işlem, bilgi bitlerinin (b) dördün genlik modülasyonu (QAM) sembollerine dönüştürülmesidir. QAM modülasyon işleminin ardından elde edilmiş olan ve N adet QAM sembolü içeren d veri vektörü, aşağıdaki gibi tanımlanan K -uzunluklu veri dizilerine ayrılır [11, 17]:

$$d_m = [d_{0,m}, d_{1,m}, \dots, d_{K-1,m}] \quad , \quad 1 \leq m \leq M \quad (1)$$

Burada M değişkeni, K -uzunluklu veri dizilerinin sayısını ifade etmektedir. Daha sonra, ilgili veri dizilerinin her birine aşağıdaki gibi ters hızlı Fourier dönüşüm (IFFT) işlemi uygulanır [11, 17]:

$$d_m[n] = \frac{1}{\sqrt{K}} \sum_{k=0}^{K-1} d_{k,m} e^{j\frac{2\pi kn}{K}} \quad , \quad 0 \leq n \leq K-1 \quad , \quad 1 \leq m \leq M \quad (2)$$


IFFT işleminin ardından, her bir $d_m[n]$ dizisinin M adet kopyası alınır. Sonrasında, elde edilen kopyalar, zaman domeninde yan yana sıralanarak her biri $N = MK$ uzunluğuna sahip olan $c_m[n]$ dizileri aşağıdaki gibi elde edilir [11, 17]:

$$c_m[n] = \left[\begin{array}{c} \overbrace{[d_m[0], d_m[1], \dots, d_m[K-1]]}^1, \overbrace{[d_m[0], d_m[1], \dots, d_m[K-1]]}^2 \\ \vdots \\ \overbrace{[d_m[0], d_m[1], \dots, d_m[K-1]]}^M \end{array} \right] \quad , \quad 0 \leq n \leq MK-1 \quad (3)$$

Sonuç olarak, iletim sinyali aşağıdaki gibi elde edilir [11, 17]:

$$s[n] = \sum_{m=1}^M g \left[\langle n - (m-1)K \rangle_N \right] c_m[n] \quad , \quad 0 \leq n \leq MK-1 \quad , \quad 1 \leq m \leq M \quad (4)$$

Yukarıdaki ifadede, prototip filtreye ait $g[n]$ ile belirtilen dürtü cevabı, $\langle \bullet \rangle_N$ modülü operatörü kullanılarak her bir m değeri için dairesel olarak kaydırılmaktadır. LC-GFDM çıkışından elde edilen iletim sinyali daha sonra doğrusal olmayan HPA girişine beslenerek kuvvetlendirme işlemi gerçekleştirilir. Son olarak kuvvetlendirilmiş sinyal, kanala verilerek iletme sokulur.




Şekil 1. LC-GFDM blok diyagramı.

Şekil 2'de, geleneksel OFDM ve LC-GFDM dalga formlarına ait güç spektral yoğunluğu grafikleri karşılaştırılmıştır. Sahip olduğu spektral karakteristik bakımından, LC-GFDM dalga formunun OFDM üzerindeki üstünlüğü Şekil 2'de net bir şekilde görülmektedir. LC-GFDM dalga formunda gerçekleştirilen sinyal üretim prosedürü sayesinde, şekilde görüldüğü gibi çok düşük yan lob seviyeleri elde etmek mümkündür. Söz konusu güç spektral yoğunluğu grafiklerinin elde edilmesi için kullanılan parametre değerleri Tablo 1'de yer almaktadır.

3. SSPA'NIN ÇALIŞMA PRENSİBİ

Doğrusal olmayan HPA'ların popüler bir temsilcisi olarak SSPA, belirli bir seviyenin üzerinde PAPR değerlerine sahip sinyallerde, kuvvetlendirme işlemi sırasında bozulmalar meydana getirmektedir. Bu gibi sinyal bozulmaları, sadece spektral büyüme ile sonuçlanmayıp, bit hata oranı performansını da olumsuz yönde etkilemektedir. SSPA girişine verilen sinyal ve ilgili sinyalin kuvvetlendirilmiş versiyonu sırasıyla aşağıdaki gibi ifade edilmektedir [12]:



Şekil 2. OFDM ve LC-GFDM dalga formları arasında güç spektral yoğunluğu karşılaştırması.

$$x(n) = |x(n)|e^{j\theta(n)} \quad (5)$$

$$r(n) = A_{SSPA}(|x(n)|)e^{j\{\theta(n)+\phi_{SSPA}(|x(n)|)\}} \quad (6)$$

Burada $|x(n)|$, $\theta(n)$, $A_{SSPA}(|x(n)|)$ ve $\phi_{SSPA}(|x(n)|)$ sırasıyla giriş sinyali genliği, giriş sinyali fazı, çıkış sinyali genliği ve çıkış sinyali fazını ifade etmektedir. $A_{SSPA}(|x(n)|)$ ve $\phi_{SSPA}(|x(n)|)$ ifadeleri aşağıdaki gibi tanımlanmaktadır [12]:

$$A_{SSPA}(|x(n)|) = \frac{|x(n)|}{\left[1 + (|x(n)|/A_0)^{2p}\right]^{1/2p}} \quad (7)$$

$$\phi_{SSPA}(|x(n)|) = 0 \quad (8)$$

Burada p ve A_0 , sırasıyla SSPA'nın doğrusallığını belirleyen düzgünlük parametresi ve çıkış doyum genliğini sembolize etmektedir. p parametresi SSPA'nın doğrusallığını kontrol ettiğinden dolayı, p değerindeki artış, kuvvetlendirilen sinyallerde daha az bozulma meydana gelmesini sağlamaktadır.


Diğer taraftan, aşağıdaki gibi ifade edilen IBO parametresi ayarlanarak SSPA'nın çalışma noktasının belirlenmesi mümkün olabilmektedir [12]:

$$IBO = 10 \log_{10} \left(\frac{P_{doy}}{P_{orta}} \right) \quad (9)$$

Burada giriş sinyaline ait ortalama güç değeri ve SSPA'nın doyum gücü, sırasıyla P_{orta} ve P_{doy} ile ifade edilmektedir. Büyük IBO değerleri için, SSPA'nın çalışma noktası doğrusal bölge civarında olacaktır ve buna bağlı olarak sinyaller daha az bozulmayla kuvvetlendirilecektir. Bu durum, daha iyi bit hata oranı performansı ve daha az spektral büyüme ile sonuçlanacaktır. Ancak, IBO değeri ile kuvvetlendirme verimi arasında bir ödünleşim mevcuttur. IBO değeri artırıldıkça, SSPA'nın kuvvetlendirme veriminin kötüye gittiği unutulmamalıdır. Doğrusal olmayan bir HPA'nın kuvvetlendirme karakteristiği Şekil 3'te gösterilmektedir [12].

4. SİMÜLASYON SONUÇLARI

Bu çalışmada ilk olarak, iletim sinyallerinin kuvvetlendirilmesi için SSPA'nın LC-GFDM vericisine entegrasyon işlemi gerçekleştirilmiştir. Daha sonra SSPA'nın, LC-GFDM dalga formunun hem bant dışı radyasyon hem de bit hata oranı performansı üzerindeki etkisi, sırasıyla PSD ve sinyal/gürültü oranı (SNR) – BER grafikleri vasıtasıyla incelenmiştir. Simülasyon parametreleri ise Tablo 1'de verilmiştir.





Şekil 3. Doğrusal olmayan HPA'ya ait kuvvetlendirme karakteristiği eğrisi.

Tablo 1. Simülasyon parametreleri.

FFT boyutu	256
Alt taşıyıcı sayısı	$K = 32$
GFDM sembollerinin sayısı	$M = 15$
Üst örnekleme faktörü	$L = 8$
Yuvarlanma (roll-off) faktörü	$\alpha = 0.5$
Örnekleme frekansı	3.84 MHz
Verici filtresinin türü	Kök yükseltilmiş kosinüs (rrc)
Alıcı filtresinin türü	Sıfır zorlama (ZF)
Kanal modeli	AWGN
Modülasyon türü	4-QAM
HPA modeli	SSPA

Şekil 4'te, LC-GFDM dalga formunun güç spektral yoğunluğu grafiği, 6 dB'den ikişer dB'lik aralıklarla 20 dB'ye kadar artırılan IBO değerleri için elde edilmiştir. Bu simülasyon için düzgünlük katsayısı $p = 2$ olarak belirlenmiştir. Farklı IBO değerleri için elde edilmiş olan söz konusu PSD eğrilerinin yanı sıra, SSPA'nın neden olduğu spektral büyüme miktarını net olarak gözlemleyebilmek için, LC-GFDM sisteminde doğrusal HPA ile bozunumsuz kuvvetlendirme işleminin gerçekleştirilmesi durumunda elde edilen PSD eğrisi de Şekil 4'e eklenmiştir. Şekilden de açıkça görüleceği üzere, IBO değeri artırdıkça, bant dışı emisyon miktarı da bastırılmakta olup, LC-GFDM dalga formunun güç spektral yoğunluğu eğrisi, sadece doğrusal HPA kullanılarak elde edilebilen orijinal formuna yaklaşmaktadır. Bu beklenen bir sonuçtur, çünkü IBO değeri artırıldığında, SSPA'nın çalışma noktası doyum bölgesinden doğrusal bölgeye doğru kayar. SSPA doyum bölgesinden ne kadar uzakta çalıştırılırsa, sinyaller de kuvvetlendirme işlemi boyunca o kadar az bozulmaya uğrar. Bunun sonucunda da, sinyal bozulmasından kaynaklanan bant dışı emisyon miktarı düşer ve LC-GFDM dalga formuna ait PSD eğrisi ideal formuna yaklaşır.


Şekil 4. Farklı IBO değerleri için LC-GFDM dalga formuna ait güç spektral yoğunluğu eğrileri ($p = 2$).



Şekil 5. Çeşitli IBO değerleri için LC-GFDM dalga formunun bit hata oranı performansı ($p = 2$).


Şekil 5'te, LC-GFDM dalga formunun bit hata oranı performansı, farklı IBO değerleri için incelenmiştir. BER eğrileri sırasıyla 1 dB, 3 dB, 5 dB, 7 dB, 9 dB ve 11 dB IBO değerleri için elde edilmiş olup, LC-GFDM sinyalinin doğrusal HPA ile bozunumsuz olarak kuvvetlendirilmesi durumunda elde edilen BER eğrisi de Şekil 5'e eklenmiştir. Bir önceki PSD analizinde olduğu gibi SSPA'ya ait düzgünlük parametresi $p = 2$ olarak tayin edilmiştir. Şekilden de kolayca anlaşılacağı üzere, IBO değerindeki artışla birlikte, LC-GFDM dalga formunun bit hata oranı her bir SNR değeri için düşmektedir. Örneğin, 16 dB SNR değerinde, IBO = 1 dB, 3 dB, 5 dB, 7 dB, 9 dB ve 11 dB için ulaşılan bit hata oranı seviyeleri sırasıyla 1.40×10^{-2} , 6.64×10^{-3} , 2.03×10^{-3} , 3.51×10^{-4} , 4.04×10^{-5} ve 5.21×10^{-6} olmaktadır. Bu da beklenen bir sonuçtur, çünkü Şekil 4'te de bahsedildiği üzere, IBO değerindeki artış, sinyallerin SSPA tarafından daha az bozulmayla kuvvetlendirilmesine neden olmaktadır. Alıcıya gelen sinyal ne kadar az bozulmaya maruz kalmışsa, söz konusu sinyalden bilgi biti dizisini elde etmek o kadar kolaylaşacak olup, bit hata oranı da o kadar azalacaktır.

Şekil 6'da LC-GFDM vericisinde kullanılan rrc filtresinin $\alpha = 0.5$, $\alpha = 0.7$ ve $\alpha = 0.9$ yuvarlanma faktörü değerleri için sırasıyla 12 dB, 14 dB ve 16 dB IBO değerlerinde elde edilmiş olan PSD eğrileri görülmektedir. Şekilden de görüldüğü gibi, en yüksek yan lob seviyeleri IBO = 12 dB için elde edilirken, en düşük yan lob seviyeleri en yüksek IBO değeri olan 16 dB için elde edilmiştir. Diğer taraftan, yuvarlanma faktörü değerindeki artışla birlikte, yan lob seviyelerinde her bir IBO değeri için oldukça belirgin yükselmeler gözlemlenmiştir. Örneğin IBO = 14 dB için, yuvarlanma faktörü değerinin $\alpha = 0.5$ 'ten $\alpha = 0.9$ 'a artırılması, yan lob seviyesinde 25.33 dB'lik bir yükselişe neden olmuştur. Bu durum, yuvarlanma faktörü değerindeki artışın LC-GFDM iletim sinyalinin PAPR değerinde yol açtığı yükselmeden kaynaklanmaktadır. Söz konusu PAPR yükselmesinin arkasında yatan ana neden, iletim sinyalindeki dikgenlik kaybı sonucu meydana gelen semboller arası girişimdir. Dikgenlik kaybı, yuvarlanma faktörü değerindeki artıştan kaynaklandığı için, α değerindeki her bir artış PAPR büyümesine ve buna bağlı olarak da bant dışı radyasyon miktarının yükselmesine neden olmaktadır.




Şekil 6. Kök yükseltilmiş kosinüs (rrc) filtresinin üç farklı yuvarlanma faktörü değeri için farklı IBO değerlerinde elde edilen PSD eğrileri ($p = 2$).

Şekil 7’de, $\alpha = 0.5$, $\alpha = 0.6$, $\alpha = 0.7$ ve $\alpha = 0.8$ yuvarlanma faktörü değerleri için LC-GFDM dalga formunun 7 dB ve 11 dB IBO değerlerinde elde edilmiş olan bit hata oranı eğrileri görülmektedir. Şekil 6’dan da bilgi sahibi olduğu gibi, yuvarlanma faktörü değerindeki artış, LC-GFDM iletim sinyalinin PAPR değerinde de artışa neden olmaktadır. PAPR değerindeki söz konusu artış, aynı zamanda SSPA tabanlı sinyal bozulmalarının da artmasına neden olmakta ve buna bağlı olarak da bit hata oranı performansının kötüleşmesine yol açmaktadır. α değerindeki artışın LC-GFDM dalga formunun bit hata oranı performansında neden olduğu kötüleşme, Şekil 7’de net olarak görülmektedir. Örneğin SNR = 14 dB yatay eksende referans noktası olarak alınacak olursa, ilgili SNR değerinde SSPA’ya ait IBO parametresinin 11 dB olarak ayarlanması durumunda, $\alpha = 0.5$, $\alpha = 0.6$, $\alpha = 0.7$ ve $\alpha = 0.8$ yuvarlanma faktörü değerleri için sırasıyla 1.16×10^{-4} , 2.34×10^{-4} , 4.14×10^{-4} ve 7.25×10^{-4} bit hata oranları elde edilmektedir.



Şekil 7. İki farklı IBO değerinde rrc filtresinin artan yuvarlanma faktörü değerleri için elde edilen BER eğrileri ($p = 2$).

Şekil 4-7’de düzgünlük parametresi $p = 2$ olarak alınmıştır. p parametresi, SSPA’nın doğrusallığını belirleyen bir parametre olduğundan dolayı, söz konusu parametrenin daha büyük değerleri, LC-GFDM sisteminin güç spektral yoğunluğu ve bit hata oranı performansında iyileşmeye yol açacaktır. Daha düşük p değerlerinde ise, performans kötüleşmesi meydana gelecektir.



Şekil 8. Çeşitli p değerleri için LC-GFDM dalga formunun bit hata oranı performansı (IBO = 4 dB).

Şekil 8’de, LC-GFDM dalga formunun bit hata oranı eğrisi bu kez farklı düzgünlük katsayısı değerleri için elde edilmiştir. Bu simülasyonda, IBO değeri 4 dB olarak belirlenirken, düzgünlük katsayısı $p = 0.5$ değerinden 0.5’lik aralıklarla $p = 4$ değerine kadar artırılmıştır. Şekilden de kolayca anlaşılacağı üzere, p değerindeki artışla birlikte SSPA’nın doğrusallığı da artmış olup, iletim sinyali daha az bozulmayla kuvvetlendirilmiştir ve buna bağlı olarak da bit hata oranı performansında önemli iyileşmeler kaydedilmiştir. Örneğin düzgünlük katsayısının $p = 0.5$

değerinden $p = 4$ değerine kadar artırılması, 18 dB SNR değerindeki bit hata oranının 4.39×10^{-2} 'den 3.90×10^{-5} 'e düşmesine neden olmuştur.

Yapılan simülasyon çalışmalarından da görüldüğü üzere, SSPA ile kuvvetlendirme yapıldığı takdirde, IBO değerindeki artış, sonuçları olumlu yönde etkilerken, α değerindeki artış olumsuz yönde etkilemektedir. Daha düşük yan lob seviyeleri ve bit hata oranları elde edebilmek için, SSPA ile kuvvetlendirme yapılan LC-GFDM sisteminde mantıken IBO değerinin büyük, α değerinin küçük seçilmesi gerekmektedir. Ancak, yüksek IBO değerinin kuvvetlendirme verimini düşürdüğü bilinmektedir. Bu yüzden enerji veriminin geri plana atılarak spektral verimliliğe ve hatasız iletme daha fazla önem verilen sistemlerde IBO değeri yüksek seçilebilir. Enerji verimliliğinin ön plana alınarak makul bir spektral verimlilikte ve kabul edilebilir bir bit hata oranı seviyesinde haberleşme yapılması amaçlanan sistemlerde ise IBO değeri küçük seçilerek SSPA doyum bölgesine yakın çalıştırılmalıdır. Dolayısıyla, IBO değeri ve enerji verimliliği arasındaki ödünleşim de göz önünde bulundurularak, sistem gereksinimlerine göre optimum parametre değerleri belirlenmelidir.

Hem kuvvetlendirme verimini yüksek tutmak hem de daha düşük yan lob seviyesi ve BER değeri elde edebilmek için, kuvvetlendirici girişine uygulanan iletim sinyalinin PAPR değeri mümkün olduğunca düşürülerek, IBO değerinin minimum seviyede tutulması gerekmektedir. Böylelikle, SSPA doyum bölgesine yakın çalıştırılabilir, kuvvetlendirilen sinyallerin düşük PAPR değerleri, ilgili kuvvetlendiricinin doyuma ulaşma sıklığını düşürecek ve bunun sonucunda da sinyaller daha az bozulmaya uğradığı için hem spektral verimlilikte hem de BER performansında artış meydana gelecektir.

5. SONUÇ

Bu çalışmada, LC-GFDM dalga formunun doğrusal olmayan yüksek güç kuvvetlendiricisi altındaki performansını inceleyebilmek için, ilgili dalga formunun vericisine literatürde en çok kullanılan yüksek güç kuvvetlendiricileri arasında yer alan SSPA entegre edilmiştir. Daha sonra, LC-GFDM dalga formunun güç spektral yoğunluğu ve bit hata oranı performansı, çeşitli IBO ve p değerleri için analiz edilmiştir. Simülasyonlarda, doğrusal olmayan yüksek güç kuvvetlendiricileri belirli bir güç aralığı dışında doğrusal kuvvetlendirme işlemi gerçekleştiremedikleri için, bir tür doğrusal olmayan yüksek güç kuvvetlendiricisi olarak SSPA, yüksek PAPR değerlerine sahip LC-GFDM iletim sinyallerinde kuvvetlendirme işlemi boyunca bozulmalar meydana getirmiştir. Söz konusu sinyal bozulmalarına yol açan SSPA-tabanlı sinyal kuvvetlendirme işlemi, LC-GFDM dalga formunun güç spektral yoğunluğu ve bit hata oranı performansını da olumsuz yönde etkilemiştir. Diğer yandan, IBO ve p değerlerinin artırılarak SSPA'nın sinyal bozucu etkisinin düşürülebileceği, yapılan simülasyon çalışmalarıyla ortaya konmuştur.

Teşekkür

Bu çalışma, Erciyes Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir. Proje No: FDK-2018-8463

Yazar Katkıları

Şakir Şimşir: Teorik Analiz, Metodoloji, Kodlama, Yazma, Gözden Geçirme ve Düzenleme.

Necmi Taşpınar: Kontrol ve Denetleme, Doğrulama, Finansman Edinimi, Proje Yönetimi.

Çıkar Çatışması

Makale yazarları, aralarında herhangi bir çıkar çatışması olmadığını beyan ederler

KAYNAKÇA

- [1] M. Agiwal, A. Roy, and N. Saxena, "Next generation 5G wireless networks: a comprehensive survey," IEEE Communications Surveys & Tutorials, vol. 18, no. 3, pp. 1617-1655, 2016.
- [2] S.-Y. Lien, S.-L. Shieh, Y. Huang, B. Su, Y.-L. Hsu, and H.-Y. Wei, "5G new radio: waveform, frame structure, multiple access, and initial access," IEEE Communications Magazine, vol. 55, no. 6, pp. 64-71, 2017.
- [3] N. Panwar, S. Sharma, and A. K. Singh, "A survey on 5G: the next generation of mobile communication," Physical Communication, vol. 18, no. 2, pp. 64-84, 2016.
- [4] A. Fuente, R. P. Leal, and A. G. Armada, "New technologies and trends for next generation mobile broadcasting services," IEEE Communications Magazine, vol. 54, no. 11, pp. 217-223, 2016.
- [5] L. J. Cimini, "Analysis and simulation of a digital mobile channel using orthogonal frequency division multiplexing," IEEE Transactions on Communications, vol. 33, no. 7, pp. 665-675, 1985.
- [6] T. Hwang, C. Yang, G. Wu, S. Li, and G. Y. Li, "OFDM and its wireless applications: a survey. IEEE Transactions on Vehicular Technology," vol. 58, no. 4, pp. 1673-1694, 2009.
- [7] R. Prasad, "OFDM for Wireless Communications Systems," Artech House, 2004.
- [8] G. Fettweis, M. Krondorf, and S. Bittner, "GFDM - generalized frequency division multiplexing," IEEE

- 69th Vehicular Technology Conference, pp. 1-4, Barcelona, 2009.
- [9] N. Michailow, S. Krone, M. Lentmaier, and G. Fettweis, "Bit error rate performance of generalized frequency division multiplexing," IEEE Vehicular Technology Conference (VTC Fall), pp. 1-5, Quebec City, 2012.
- [10] N. Michailow, M. Matthé, I. S. Gaspar, A. N. Caldevilla, L. L. Mendes, A. Festag, and G. Fettweis, "Generalized frequency division multiplexing for 5th generation cellular networks," IEEE Transactions on Communications, vol. 62, no. 9, pp. 3045-3061, 2014.
- [11] M. Matthé, L. Mendes, I. Gaspar, N. Michailow, D. Zhang, and G. Fettweis, "Precoded GFDM transceiver with low complexity time domain processing," EURASIP Journal on Wireless Communications and Networking, vol. 2016, no. 138, pp. 1-9, 2016.
- [12] D. Di Zenobio, G. Santella, and F. Mazzenga, "Adaptive linearization of power amplifier in orthogonal multicarrier schemes," IEEE Wireless Communication System Symposium, pp. 225-230, Long Island, 1995.
- [13] T. Helaly, R. Dansereau, and M. El-Tanany, "BER performance of OFDM signals in presence of nonlinear distortion due to SSPA," Wireless Personal Communications, vol. 64, no. 4, pp. 749-760, 2012.
- [14] M. C. P. Paredes, F. Grijalva, J. C. Rodrigez, and F. Sarzosa, "Performance analysis of the effects caused by HPA models on an OFDM signal with high PAPR," IEEE Second Ecuador Technical Chapters Meeting (ETCM), pp. 1-5, Salinas, 2017.
- [15] H. G. Ryu, J. S. Park, and J. S. Park, "Threshold IBO of HPA in the predistorted OFDM communication system," IEEE Transactions on Broadcasting, vol. 50, no. 4, pp. 425-428, 2004.
- [16] P. Banelli, G. Baruffa, and S. Cacapardi, "Effects of HPA nonlinearity on frequency multiplexed OFDM signals," IEEE Transactions on Broadcasting, vol. 47, no. 2, pp. 123-136, 2001.
- [17] Ş. Şimşir, and N. Taşpınar, "Cumulative symbol optimization-based partial transmit sequence technique for PAPR reduction in low complexity GFDM system," Transactions on Emerging Telecommunications Technologies, vol. 31, no. 6, pp. 1-19, 2020.



Transfer Öğrenme ve Komşuluk Bileşen Analizine Dayalı Balgam Yayma Mikroskop Görüntüleri Üzerinden Otomatik Tüberküloz Teşhisi

Automated Tuberculosis Diagnosis on Sputum Smear Microscope Images Based on Transfer Learning and Neighborhood Component Analysis

¹Ömer Faruk NASİP , ²Kenan ZENGİN 

¹Tokat Gaziosmanpaşa Üniversitesi, Tıp Fakültesi, 60100, Tokat, Türkiye

²Tokat Gaziosmanpaşa Üniversitesi, Mühendislik ve Mimarlık Fakültesi, 60100, Tokat, Türkiye

¹omerfaruk.nasip@gop.edu.tr, ²kenan.zengin@gop.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 10 August 2022

Accepted : 14 September 2022

Keywords:

Tuberculosis, Transfer Learning, Neighborhood Component Analysis, Support Vector Machine

ABSTRACT

Tuberculosis is an infectious disease caused by the Mycobacterium tuberculosis bacterium, which is effective worldwide and can result in death. Examination of the sputum sample taken from the person under the microscope is one of the most common diagnostic methods of the disease. However, this manual process is error-prone and time-consuming. In this study, a model for automatic tuberculosis diagnosis using sputum smear microscope images is proposed. In the model, the features of the data set were obtained with the transfer learning approach using Vgg19, ResNet50 and DenseNet201. After the features are combined, they are weighted with Neighborhood Component Analysis (NCA) and the best ones are selected. The selected features were trained with the Support Vector Machine (SVM), and the performance of the model was calculated using five-fold cross validation. Experimental results yielded 99.03% accuracy, 99.24% precision, 98.81% sensitivity, 99.25% specificity, and 99.02% f1-score.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 10 Ağustos 2022

Kabul : 14 Eylül 2022

Anahtar Kelimeler:

Tüberküloz, Transfer Öğrenme, Komşuluk Bileşen Analizi, Destek Vektör Makinesi

ÖZET

Tüberküloz, Mycobacterium tuberculosis bakterisinin neden olduğu, dünya çapında etkili olan ve ölümlü sonuçlanabilen bulaşıcı bir hastalıktır. Kişiden alınan balgam örneğinin mikroskop altında incelenmesi hastalığın en yaygın tanı yöntemlerindedir. Ancak bu manuel işlem hataya açık ve zaman alıcıdır. Bu çalışmada, balgam yayma mikroskop görüntüleri kullanılarak otomatik tüberküloz teşhisi için bir model önerilmiştir. Modelde veri setine ait öznelikler transfer öğrenme yaklaşımı ile Vgg19, ResNet50 ve DenseNet201 kullanılarak elde edilmiştir. Öznelikler birleştirildikten sonra Komşuluk Bileşen Analizi (KBA) ile ağırlıklandırılıp en iyi olanları seçilmiştir. Seçilen öznelikler Destek Vektör Makinesi (DVM) ile eğitilmiş, modelin performansı beş kat çapraz doğrulama kullanılarak hesaplanmıştır. Deneysel sonuçlarda %99.03 doğruluk, %99.24 kesinlik, %98.81 duyarlılık, %99.25 özgüllük ve %99.02 f1-skoru elde edilmiştir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Tüberküloz, çoğunlukla akciğerleri etkileyen ciddi bulaşıcı bir hastalıktır. Hastalığa Mycobacterium tuberculosis adı verilen bir bakteri türü neden olur. Hastalık havada yayılır ve bir kişinin enfekte olması için sadece birkaç mikrobu soluması yeterlidir. Dünyada her yıl yaklaşık 10 milyon kişiye tüberküloz teşhisi konulmaktadır. Önlenemez ve tedavi edilebilir bir hastalık olmasına rağmen tüberküloz nedeniyle her yıl 1,5 milyon kişi hayatını kaybetmektedir. Bu ölüm oranı, tüberkülozun dünyadaki en ölümcül bulaşıcı hastalık olduğunu göstermektedir. Hastalık teşhisi konulan kişilerin çoğu düşük ve orta gelirli ülkelerde yaşasa da, tüberküloz dünyanın diğer ülkelerinde de görülmektedir [1]. Hastalığın teşhisi için akciğer röntgen görüntüsü, balgam yayması, kan testi, interferon gamma salınım testi, deri testi gibi testler kullanılmaktadır. En yaygın kullanılan test mikroskopik balgam yayma testidir. Bu manuel teşhis yöntemi, uzman bilgisi, zaman ve maliyet gerektirir. Ayrıca 1-10 µm boyutundaki hastalık bakterisini görüntü üzerinde çıplak gözle tespit etmek oldukça zor ve hataya açıktır [2]. Erken teşhis süresinin hastalığın seyri için önemli olduğu ve uzman sayısının yeterli olamadığı durumlar göz önüne alındığında bilgisayar destekli otomatik sistemlerin iyi bir alternatif olduğu söylenebilir [3].

Gelişen yazılım ve donanım teknolojisi ile birlikte bilgisayarlar güncel sınıflandırma problemlerinde aktif rol oynamaktadır. Makine öğrenmesi teknikleri yardımıyla yapılan sınıflandırma işlemi, manuel yöntemlere göre daha hızlı ve başarılı sonuçlar vermesine rağmen bazı dezavantajları bulunmaktadır. Örnekler için özneliklerin çıkarılmasında insan müdahalesine duyulan ihtiyaç ve büyük veri setleri için sınırlı performans sergilemesi bunlardan bazılarıdır [4]. Derin öğrenme, veri işleme yöntemlerinde biyolojik sinir ağı yapısından esinlenerek yapay sinir ağları olarak bilinen algoritmaları kullanır. Derin öğrenmede makine öğrenmesinden farklı olarak çok katmanlı sinir ağı yapısı bulunur. Öznitelikler, derin sinir ağları tarafından otomatik olarak çıkarılır. Binlerce kategori ve milyonlarca görüntü içeren veri setleri ile eğitilip test edilmiş önceden eğitilmiş derin sinir ağları, hiyerarşik öznelik çıkarma yetenekleri sayesinde başarılı sonuçlar vermektedir. Özellikle, evrimsel derin sinir ağları, nesne algılama, örüntü tanıma, segmentasyon ve sınıflandırma problemleri gibi çeşitli görüntü işleme görevlerinde kullanılmaktadır [5, 6].

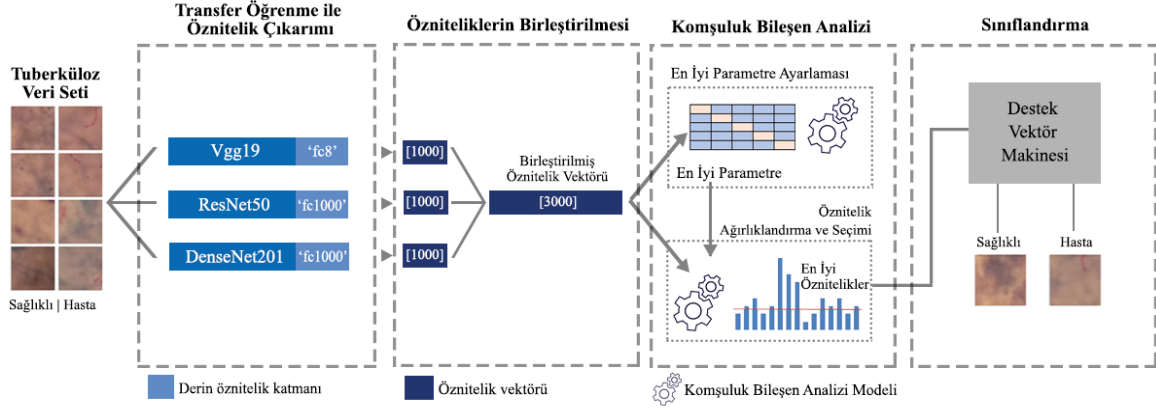
Literatürde tüberküloz teşhisi için balgam yayma mikroskop görüntüleriyle yapılan çalışmalar incelendiğinde Arisgraha ve arkadaşları (2015), mikroskop görüntülerini Mycobacterium bakterisi içeren ve içermeyen şeklinde iki ayrı sınıfa ayırmışlardır. Görüntüleri eğitip sınıflandırma amacıyla bir sinir ağı önermişlerdir. Eğitim ve test işlemi için bir uygulama geliştirmişlerdir [7]. Priya ve Srinivasan (2016), mikroskop görüntüsündeki nesnelere sınırlarını Fourier tanımlayıcısı ile tanımlamışlardır. Seçilen nesnelere destek vektörü ve geriye yayılım sinir ağı kullanarak eğitip test etmişlerdir. Çalışma sonucunda destek vektörü sinir ağı ile daha başarılı sonuçlar elde ettiklerini bildirmişlerdir [8]. Panicker ve arkadaşları (2018), mikroskop görüntülerini bakteri içeren (enfekte) ve bakteri içermeyen (sağlıklı) olarak iki sınıfa ayırmıştır. Elde ettikleri veri setini önerdikleri konvolüsyonel sinir ağı ile eğiterek sınıflandırmışlardır [2]. Hu ve arkadaşları (2019), mikroskop görüntülerini alt bölümlere ayırarak pozitif ve negatif olmak üzere iki sınıf içeren bir veri seti elde etmiştir. Veri setini InceptionV3, ResNet18 ve DenseNet derin sinir ağları ile eğitmişlerdir. Çalışmalarında InceptionV3 ile daha başarılı sonuçlar elde etmişlerdir [9]. Mithra ve Sam Emmanuel (2019), balgam yayma mikroskop görüntülerine kanal alan eşik segmentasyon tekniği uygulamış ve özneliklerini konum odaklı histogram yöntemi ile çıkarmışlardır. Çıkarılan öznelikler derin inanç ağı kullanılarak sınıflandırılmıştır [10]. Dinesh Jackson Samuel ve Rajesh Kanna (2019), enfekte ve sağlıklı örnekleri içeren veri seti kullanmışlardır. Transfer öğrenme yaklaşımı ile InceptionV3 derin sinir ağı kullanılarak öznelikleri çıkarılan veri seti, DVM ile eğitilip sınıflandırılmıştır [11]. Dinesh Jackson Samuel ve Rajesh Kanna (2020), hasta ve sağlıklı örnekleri içeren veri seti için transfer öğrenme yaklaşımı ile Vgg19 ağını kullanmış çıkarılan öznelikleri DVM ile sınıflandırmışlardır [12]. Rachmad ve arkadaşları (2020), balgam yayma mikroskop görüntülerini bölerek pozitif ve negatif olmak üzere iki sınıfa ayırmıştır. ResNet101 derin sinir ağını kullanarak elde ettikleri öznelikleri DVM, KNN, Naive Bayes ve Karar ağacı sınıflandırıcıları ile eğitip test etmişlerdir. Çalışmada en yüksek başarı DVM kullanılan model ile elde edilmiştir [13]. Ibrahim ve arkadaşları (2021), hasta ve sağlıklı bireylerin mikroskop görüntü veri setini transfer öğrenme yaklaşımı ile eğitip test etmişlerdir. Transfer öğrenme için AlexNet derin sinir ağı tercih edilmiştir [14].

Bu çalışmada balgam yayma mikroskop görüntüleri üzerinden Tüberküloz hastalığının otomatik teşhisi için hibrit bir model önerilmiştir. Önerilen modelde transfer öğrenme, öznelik seçimi ve makine öğrenmesi birlikte kullanılmıştır. Önceden eğitilmiş derin sinir ağları kullanılarak elde edilen öznelikler birleştirilip Komşuluk Bileşen Analizi ile en değerli olanları seçilmiştir. Seçilen öznelikler DVM kullanılarak eğitilmiştir. Beş kat çapraz doğrulama ile test edilen modelin performans değerleri hesaplanmıştır. Elde edilen sonuçlar öznelik seçimi yapılmadan eğitilen modellerle karşılaştırılmış, önerilen modelin hem sınıflandırma hızına hem de sınıflandırma doğruluğuna olumlu katkı sağladığı görülmüştür. Önerilen model klinikte ön tanı ve tanı süreçlerinin hızlandırılmasına yardımcı olacağı için hastalığın teşhisinde zaman ve iş gücünden tasarruf sağlar.

Çalışmanın sonraki bölümünde önerilen modelin aşamaları, kullanılan veri seti ve yöntemlerin ifade edildiği materyal ve metod bölümüne yer verilmiştir. Deneysel sonuçlar ve tartışma bölümünde çalışmada kullanılan performans metrikleri, çalışmada elde edilen ve literatürdeki çalışmalara ait deneysel sonuçlar ifade edilmiştir. Sonuç bölümünde ise çalışma hakkında genel bir değerlendirme yapılmıştır.

2. MATERYAL VE METOT


Çalışmada önerilen model dört aşamadan oluşmaktadır. İlk aşamada, önceden eğitilmiş Vgg19, ResNet50 ve DenseNet201 derin sinir ağları transfer öğrenme yöntemiyle kullanılmıştır. Bu ağların son tam bağlı katmanlarından veri setine ait her biri 1.000 adet öznetelik içeren öznetelik vektörleri elde edilmiştir. İkinci aşamada bu vektörler bir araya getirilerek içerisinde 3.000 adet öznetelik bulunan bir vektör oluşturulmuştur. Üçüncü aşamada en iyi özneteliklerin seçimi ve boyut azaltma amacıyla Komşuluk Bileşen Analizi (KBA) modeli kullanılmıştır. KBA için ilk olarak parametre ayarlaması yapılarak modele en uygun parametreler belirlenmiştir. Sonrasında bu parametrelerin kullanıldığı KBA modeli ile öznetelikler ağırlıklandırılıp en iyi olanları seçilmiştir. Son aşamada, seçilen öznetelikler DVM ile eğitilerek sınıflandırılmıştır. Şekil 1’de önerilen modelin aşamaları ifade edilmektedir.



Şekil 1. Önerilen modelin aşamaları.

2.1. Veri Seti ve Ön İşleme

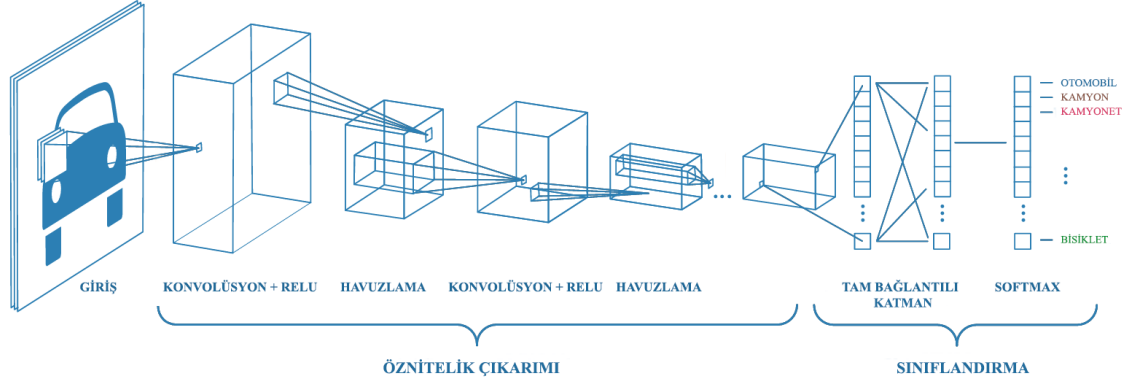
Çalışmada Kaggle’da bulunan ve erişime açık tüberküloz görüntü veri seti kullanılmıştır [15]. Veri setindeki görüntüler balgam yayma örneklerinin Ziehl–Neelsen boyası ile boyanması ile elde edilmiştir. Veri setinde 1632x1224 piksel çözünürlüğe sahip 1.265 adet mikroskopik balgam yayma görüntüsü bulunmaktadır. Bu görüntüler, çalışmada kullanılan derin sinir ağlarının giriş boyutu olan 224x224 piksel görüntülere bölünmüştür. Bu şekilde 2.265 bakteri içeren (hasta) ve 2.265 bakteri içermeyen (sağlıklı) olmak üzere iki sınıfa ait toplam 4.530 mikroskop görüntüsü bulunan bir veri seti oluşturulmuştur. Şekil 2’de orijinal görüntü ve bu görüntüden elde edilerek çalışmada kullanılan görüntüler ifade edilmiştir.



Şekil 2. a. Orijinal görüntü b. Hasta örnek c. Sağlıklı örnek.

2.2. Transfer Öğrenme

Veri setini temsil eden öznetelikler, sınıflandırma işlemi için büyük önem arz etmektedir. Öznetelikler başarılı olarak ifade edilirse sınıflandırma işlemi de aynı derecede başarılı olur. Evrişimli Sinir Ağları (ESA), derin öğrenmenin en yaygın kullanılan mimarisidir. Genellikle görüntü ve video işleme amacıyla kullanılan ESA iki bölüme ayrılmaktadır. Birinci bölümde veri setine ait özneteliklerinin çıkarıldığı katmanlar bulunurken ikinci bölümde ise sınıflandırma işleminin gerçekleştiği katmanlar yer almaktadır. Şekil 3’te ESA mimarisinin genel görünümü görsel olarak ifade edilmiştir.



Şekil 3. ESA mimarisinin genel görünümü [16].

Önceden eğitilmiş evrişimli derin sinir ağları, ImageNet gibi farklı kategorilerde binlerce sınıf ve milyonlarca görüntü içeren veri setleri ile eğitilmiş ve başarılı sonuçlar elde edilmiş ağlardır. Bu ağlar yeni problemlerin çözümünde kullanılabilir. Çünkü modeldeki katman yapısı ve parametreler öznetelik çıkarma yeteneği açısından oldukça başarılıdır [17, 18]. Önceden eğitilmiş derin sinir ağlarının yeni bir görev için kullanımına transfer öğrenme denir. Derin sinir ağının ilk katmanlarında veri setini temsil eden genel öznetelikler (sığ öznetelikler) elde edilirken, son katmanlarda ayırt edici öznetelikler (derin öznetelikler) elde edilir. Bu çalışmada, transfer öğrenme yaklaşımı ile veri setine ait öznetelikleri elde etmek için Vgg19, ResNet50 ve DenseNet201 derin sinir ağı tercih edilmiştir [19-21]. Tablo 1'de bu ağlara ait girdi görüntü boyutu, derinlik, katman sayısı, içerdiği toplam parametre sayısı ve özneteliklerin elde edildiği katmanlar ifade edilmiştir.

Tablo 1. Çalışmada kullanılan önceden eğitilmiş derin sinir ağlarının özellikleri.

Derin Sinir Ağı	Girdi Boyutu	Derinlik	Katman Sayısı	Parametre Sayısı (milyon)	Öznetelik Elde Edilen Katman
Vgg19	224x224	19	47	144	'fc8'
ResNet50	224x224	50	177	25.6	'fc1000'
DenseNet201	224x224	201	708	20	'fc1000'

2.3. Komşuluk Bileşen Analizi

Öznetelik seçimi, veri setinin tüm özneteliklerini içeren öznetelik vektöründen en iyi temsile sahip alt kümenin seçimi olarak tanımlanır. Nispeten düşük temsili olan özneteliklerin çıkarılması ile veri boyutu küçülür, hesaplama karmaşıklığı azalır ve verileri kullanan algoritmaların performansı artar [22]. Öznetelik seçim yöntemleri uzun zamandan beri birçok alanda kullanılmaktadır. Özellikle son yıllarda büyük veri setlerinden elde edilen öznetelik vektörlerinin boyutunun azaltılmasında öznetelik seçimi etkin bir rol oynamaktadır. Öznetelik seçim yöntemleri filtre tabanlı, sarmal tabanlı ve gömülü yöntemler olmak üzere üç ana gruba ayrılır. Filtre tabanlı yöntemlerde öznetelik korelasyonu herhangi bir tahmin modeli olmadan değerlendirilir. Bu yöntemler istatistiksel hesaplama dayanır. Sarmal yöntemlerde öznetelikler üzerinde arama işlemleri yapılarak seçim yapılır. Bu yöntemler tahmine dayalı model içerir. Gömülü yöntemlerde öznetelik seçimi öğrenme modeli kullanılarak yapılır. Bu yöntemler seçim için kendi sınıflandırıcısını barındırırlar [23].

Komşuluk Bileşen Analizi (KBA), parametrik olmayan, mesafeye dayalı öznetelik ağırlıklandırma ve seçim modelidir. Özneteliklerin ağırlıkları Stochastic Gradient Descent (SGD) ve Adaptive Moment Estimation (Adam) gibi optimizasyon algoritmaları kullanılarak hesaplanır. Bu ağırlıkların değeri her zaman pozitifdir. Kullanılan modelin başarısında etkisi olmayan öznetelikler küçük ağırlık değerleri ile ifade edilirken değerli özneteliklere büyük ağırlık değerleri atanır [24]. Özneteliklerin x_i , sınıf etiketinin y_i , örnek sayısını n ve boyutun d olarak belirtildiği bir öznetelik vektörünü $F = \{(x_1, y_1), \dots, (x_n, y_n)\}$ şeklinde ifade edelim. Ağırlık vektörü olan w , Eşitlik 1'de olduğu gibi x_i ve x_j örneği arasındaki $D_w(x_i, x_j)$ ağırlık mesafesi ile ifade edilir:

$$D_w(x_i, x_j) = \sum_{k=1}^d w_k^2 |x_{ik} - x_{jk}| \quad (1)$$

Sınıflandırma referans noktası olarak en yakın komşuyu seçmeye yönelik etkili yaklaşım, bu noktayı olasılık dağılımı ile belirlemektir. x_i örneğinin x_j örneğini referans noktası olarak seçme olasılığı Eşitlik 2'de tanımlanmıştır:

$$p_{ij} = \begin{cases} \frac{K(D_w(x_i, x_j))}{\sum_{k \neq i} K(D_w(x_i, x_k))}, & \text{eğer } i \neq j \\ 0, & \text{eğer } i = j \end{cases} \quad (2)$$

Denklem (1) ve Denklem (2)'den yararlanarak w ağırlık vektörünü hesaplama formülünü Eşitlik 3'teki gibi ifade edebiliriz. Eşitlikteki p_i , i örneğini doğru sınıflandırma olasılığı, w_r r 'nci özneliğin ağırlığı, λ düzenleme parametresidir.

$$w = \arg \max_w \sum_{i=1}^n p_i - \lambda \sum_{r=1}^l w_r^2 \quad (3)$$

Eşitlikteki lambda (λ) parametresi özneliklerin doğru bir şekilde ağırlıklandırılmasında belirleyicidir. Ancak başarılı bir öznelik seçimi için bu parametrenin doğru ayarlanması gerekir. Lambda büyükse, özneliklere atanan ağırlıklar sıfır ya da sıfıra çok yakın değer alacaktır. Bu durum en iyi özneliklerin seçimini zorlaştırmaktadır. Bu değerlerin sıfır olması özneliklere aynı ağırlık değerinin atanacağı anlamına gelir. Bu yüzden en iyi lambda değeri sıfırdan büyük olmak koşuluyla sıfıra çok yakın bir değer olarak ayarlanmalıdır. Çalışmada en iyi lambda değerini belirlemek için ilk olarak eğitim veri setine ait öznelikler beş kat çapraz doğrulama yaklaşımı için beşe bölünüp her katta verilerin 4/5'i eğitim seti ve 1/5'i test seti olarak kullanılacak şekilde ayrıldı. En iyi lambda adayları değerler kullanılan KBA modeli ile her katta eğitildi ve her lambda için ortalama kayıp değerleri hesaplandı. Hesaplamalar sonunda en düşük ortalama kayba karşılık gelen lambda değeri KBA modeli ile öznelik seçimi için en iyi lambda olarak belirlendi. En iyi lambdanın belirlenmesinde kullanılan hiperparametreler Tablo 2'de gösterilmiştir.

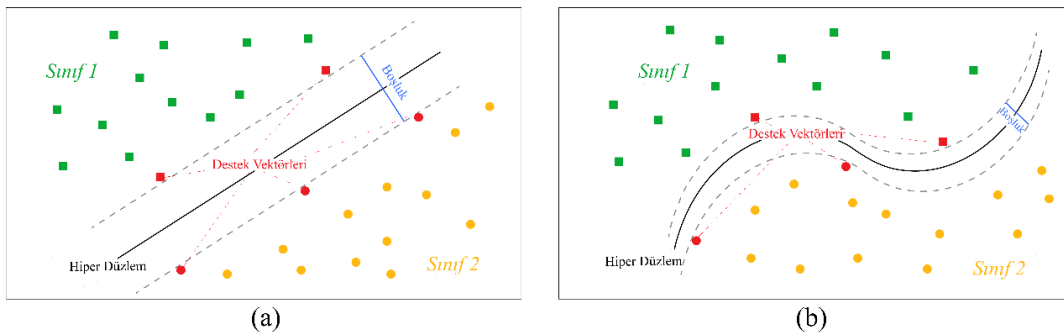
Tablo 2. En iyi lambdanın belirlenmesi için kullanılan hiperparametreler.

Hiperparametre	Değer	Kullanılan
FitMethod	average, exact, none	exact
Solver	lbfgs, minibatch-lbfgs, sgd	sgd
IterationLimit	positive integer	10
GradientTolerance	1e-x	1e-6
Standardize	true, false	true
LossFunction	binodeviance, classifcost, classiferror, exponential, hinge, logit, mincost, quadratic	classiferror

En iyi lambda değeri belirlendikten sonra eğitim veri setine ait 3.000 adet özneliğin tamamı bu değer kullanılarak KBA modeli ile işleme alınıp her birine ağırlık değeri atanmıştır. Önerilen modelde sınıflandırma amacıyla ağırlık değeri en büyük 50 öznelik seçilmiştir. Çalışmada hesaplanan en iyi lambda değeri ve ağırlıklandırılan özneliklere ait grafikler deneysel sonuçlar ve tartışma bölümünde ifade edilmiştir.

2.4. Destek Vektör Makinesi

Destek Vektör Makinesi (DVM), çok boyutlu uzayda mümkün olan en iyi sınıflandırma için alanı bölen bir hiperdüzlem bulur. Bu sınıflandırma algoritması, istatistiksel öğrenme teorisine dayanmaktadır. DVM'nin matematiksel algoritmaları, başlangıçta iki sınıflı doğrusal verilerin sınıflandırma problemi için tasarlanmış ve daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir [25, 26]. DVM tarafından üretilen doğrusal ve doğrusal olmayan hiperdüzlemler Şekil 4'te gösterilmektedir.



Şekil 4. a. Doğrusal destek vektör makinesi modeli **b.** Doğrusal olmayan destek vektör makinesi modeli.

Büyük boyutlu veri setlerinde işlem yapabilmek için DVM farklı çekirdek fonksiyonları ile birlikte daha başarılı sonuçlar verebilir. Bu çekirdek fonksiyonlarının en sık kullanılanları lineer, polinomal, sigmoid ve radyal tabanlı çekirdek fonksiyonlarıdır [27]. Bu fonksiyonlar sırasıyla Eşitlik 4, Eşitlik 5, Eşitlik 6 ve Eşitlik 7'de ifade edilmektedir.

$$f_{\text{lineer}}(x_i, x_j) = x_i^T x_j \quad (4)$$

$$f_{\text{polinomal}}(x_i, x_j) = (\alpha x_i^T x_j + c)^d \quad (5)$$

$$f_{\text{radyal}}(x_i, x_j) = \exp(-\gamma|x_i - x_j|^2) \quad (6)$$

$$f_{\text{sigmoid}}(x_i, x_j) = \tanh(\alpha x_i^T x_j + c) \quad (7)$$

Eşitliklerde α eğim, c sabit terim ve d polinom derecesidir. Bu çalışmada, lineer çekirdek fonksiyonlu DVM kullanılmıştır.

3. DENEYSEL SONUÇLAR VE TARTIŞMA

Çalışmada balgam yayma mikroskop görüntüleri kullanılarak tüberküloz hastalığının otomatik teşhisine yönelik bir model önerilmiştir. Hasta ve sağlıklı sınıfa ait toplam 4.530 görüntüden oluşan veri seti kullanılmıştır. Model performansını değerlendirmek için veri seti beş kat çapraz doğrulama ile eğitim ve test veri seti olarak ayrılmıştır. Her kat için veri setinin 4/5'i eğitim, 1/5'i test için dönüştürümlü olarak kullanılmıştır. Bu sayede veri setinde bulunan tüm görüntüler hem eğitim hem de test veri setinde değerlendirilmiştir. Model performansı hesaplanırken beş kat için ayrı ayrı elde edilen değerlerin ortalaması alınmıştır. Çalışmada Intel(R) Core(TM) i5-8400 CPU @ 2.80GHz (6 CPUs) işlemciye, NVIDIA GeForce GTX 1080 Ti NVIDIA CUDA® Cores ekran kartına ve Windows10 64 Bit İşletim Sistemine sahip bilgisayar kullanılmıştır. Uygulamalar MathWorks tarafından geliştirilen ve sayısal hesaplama yazılımı olan MATLAB kullanılarak gerçekleştirilmiştir [28]. Performans değerlendirmesinde sırasıyla Eşitlik 8, Eşitlik 9, Eşitlik 10, Eşitlik 11, Eşitlik 12'de verilen doğruluk, kesinlik, duyarlılık, özgüllük, F1-skor metrikleri ve ROC eğrisi kullanılmıştır. Eşitliklerde belirtilen TP (Doğru Pozitif) pozitif olan sınıfa pozitif, TN (Doğru Negatif) negatif olan sınıfa negatif, FP (Yanlış Pozitif) pozitif olan sınıfa negatif, FN (Yanlış Negatif) negatif olan sınıfa pozitif olarak tahminde bulunma sayısıdır. Modelin ayırt edicilik performansını ifade eden ROC Eğrisi (Receiver Operating Characteristic) sınıflandırma problemlerinde önemli bir göstergedir. Eğri X ekseninde yanlış pozitif oran (100-özgüllük), Y ekseninde ise doğru pozitif oran (duyarlılık) kullanılarak çizilir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (8)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \times 100 \quad (9)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \times 100 \quad (10)$$

$$\text{Özgüllük} = \frac{TN}{TN + FP} \times 100 \quad (11)$$

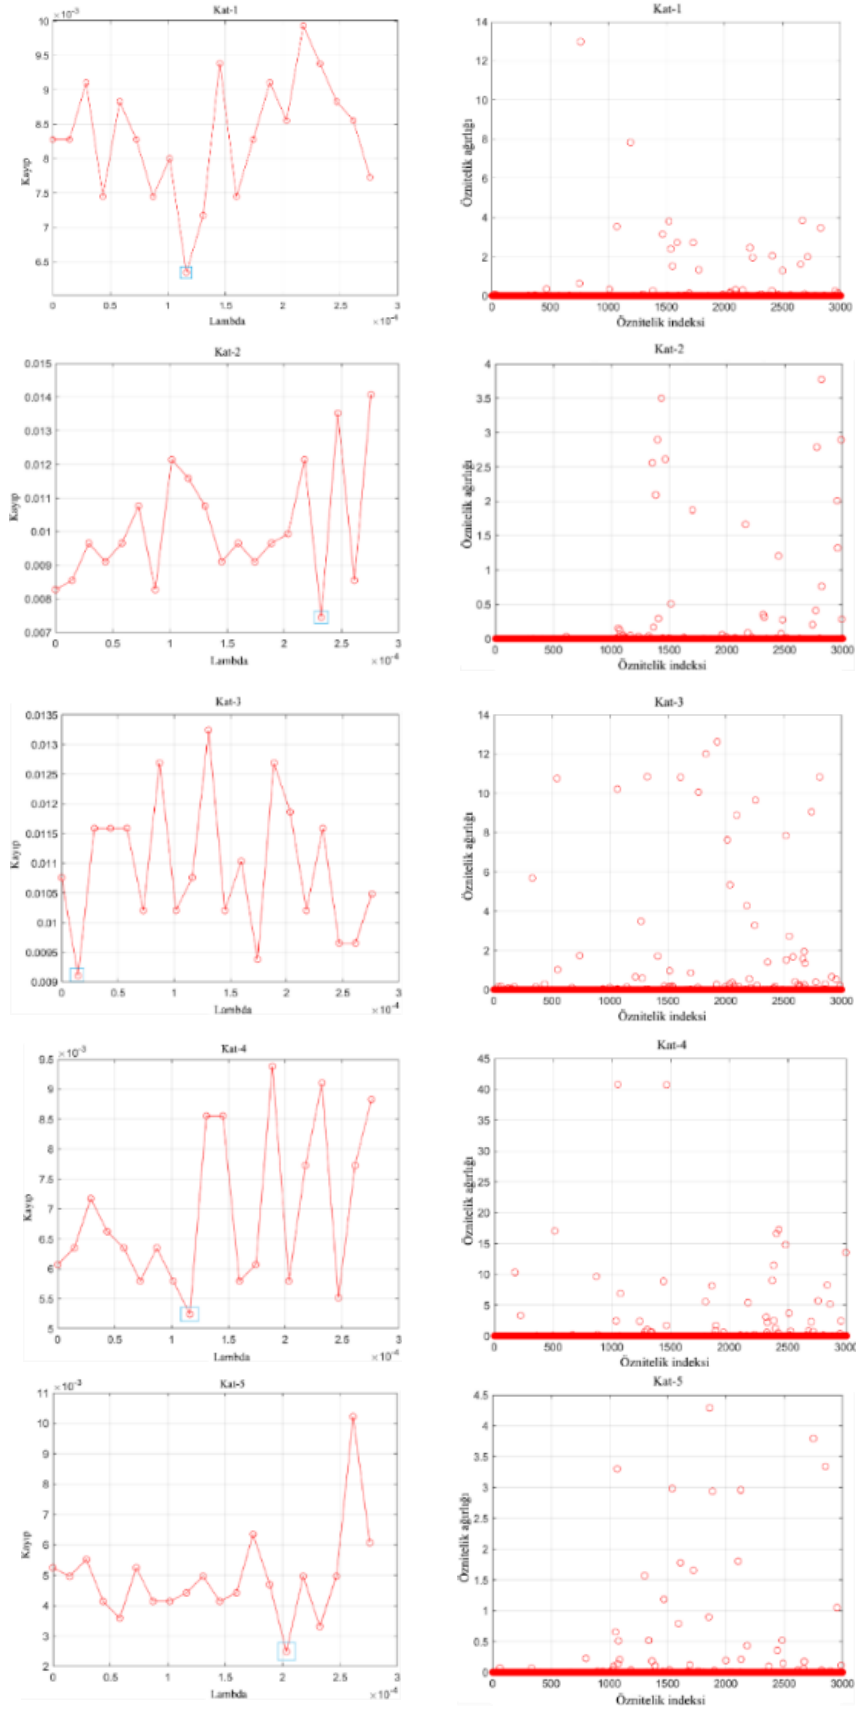
$$\text{F1-Skor} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (12)$$

Çalışmada, önceden eğitilmiş üç farklı derin sinir ağının son tam bağlı katmanlarından elde edilen öznetelik vektörlerinin birleştirilmesiyle oluşturulan vektördeki 3.000 öznetelik, KBA kullanılarak ağırlıklandırılmıştır. Ağırlıklandırma işlemi için ilk olarak en düşük ortalama kayıp değerini elde etmeyi sağlayan en iyi lambda değeri belirlenmiştir. Her kat için hesaplanan lambda/kayıp değerleri grafiği ve en iyi lambda değeri kullanılarak ağırlıklandırılmış öznetelikler Şekil 5'te verilmiştir. Hesaplanan en iyi lambda değeri grafiklerde mavi çerçeve içine alınmıştır.

Öznetelik ağırlığı/öznetelik indeksi grafiği ile belirtilen ve 3.000 öznetelik içeren vektördeki özneteliklerden 0-1.000 indeksi arası Vgg19, 1.001-2.000 indeksi arası ResNet50 ve 2.001-3.000 indeksi arası DenseNet201 kullanılarak elde edilmiştir. KBA ile ağırlıklandırılıp seçilen en iyi 50 özneteliğin arasında bu üç ağdan da öznetelik bulunması, kullanılan ağların tümünün modelin performansına katkı sağladığı anlamına gelir. Seçilen öznetelikler DVM ile eğitilip test edilmiştir. Şekil 6'da önerilen model ile beş kat çapraz doğrulama sonucu elde edilen karmaşıklık matrisleri, Tablo 3'de doğruluk, kesinlik, duyarlılık, özgüllük, f1-skor değerleri, Şekil 7'de ise ROC eğrisi ifade edilmiştir.

Tablo 3. Önerilen model ile elde edilen performans değerleri.

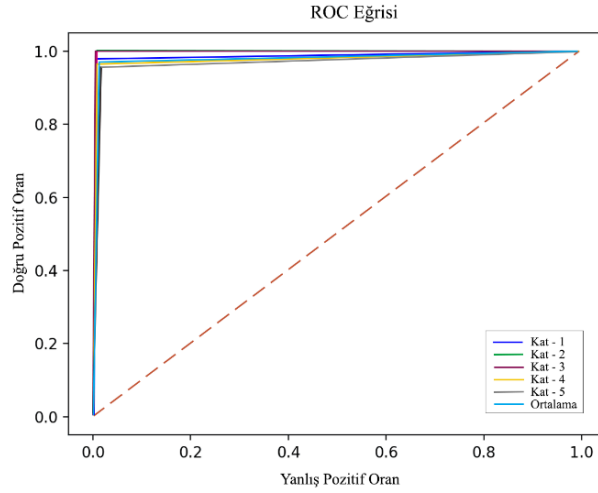
Kat	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skor (%)
Kat-1	99.12	99.55	98.68	99.56	99.11
Kat-2	99.78	99.56	100	99.56	99.78
Kat-3	99.89	99.78	100	99.78	99.89
Kat-4	98.23	98.88	97.57	98.9	98.22
Kat-5	98.12	98.43	97.78	98.46	98.1
Ortalama	99.03	99.24	98.81	99.25	99.02



Şekil 5. Lambda/kayıp grafiği ve ağırlıklandırılmış özmitelikler.

Gerçek	Tahmin		Gerçek	Tahmin		Gerçek	Tahmin		Gerçek	Tahmin		Gerçek	Tahmin		Gerçek	Tahmin	
	Pozitif	Negatif		Pozitif	Negatif		Pozitif	Negatif		Pozitif	Negatif		Pozitif	Negatif		Pozitif	Negatif
Kat-1	447	6	Kat-2	453	0	Kat-3	453	0	Kat-4	442	11	Kat-5	440	10	Toplam	2235	27
	2	451		2	451		1	452		5	448		7	449		17	2251

Şekil 6. Önerilen model ile elde edilen karmaşıklık matrisleri.



Şekil 7. Önerilen model ile elde edilen ROC eğrisi.


Önerilen modeldeki öznetelik seçimi yaklaşımının sınıflandırma başarısına etkisini ifade edebilmek için önceden eğitilmiş derin sinir ağlarının her birinden elde edilen öznetelikler ayrı ayrı ve birleştirilerek kullanılmıştır. Özneteliklerin beş kat çapraz doğrulama kullanılarak DVM ile eğitilip test edilmesi sonrası elde edilen doğruluk, kesinlik, duyarlılık, özgüllük ve f1-skor değerleri Tablo 4'te verilmiştir.

Tablo 4. Öznetelik seçiminin model performansına etkisi.

Öznetelik Vektörü	Öznetelik Sayısı	Doğruluk(%)	Kesinlik(%)	Duyarlılık(%)	Özgüllük(%)	F1-Skor(%)
Vgg19	1000	97.97	98.27	97.66	98.28	97.96
ResNet50	1000	98.23	98.49	97.97	98.5	98.23
DenseNet201	1000	98.41	98.67	98.14	98.68	98.4
Birleştirilen	3000	98.68	98.93	98.41	98.94	98.67
KBA ile Seçilen	50	99.03	99.24	98.81	99.25	99.02

Birleştirilen öznetelikler ile elde edilen sınıflandırma başarısı bu ağların her birinden ayrı ayrı elde edilen özneteliklere göre daha yüksek olsa da, öznetelik sayısının 3 katına çıkması modelin eğitim süresi ve sınıflandırma hızını olumsuz yönde etkilemiştir. Bu nedenle KBA kullanılarak gerçekleştirilen öznetelik seçimi yaklaşımı ile hem bu olumsuz etki ortadan kaldırılmış hem de modelin sınıflandırma başarısı iyileştirilmiştir.

Şekil 8'de DVM ile eğitilen özneteliklere ait ortalama eğitim süreleri ve sınıflandırma hızları verilmiştir. Öznetelik seçimi ile eğitim süresinin Vgg19, ResNet50 ve DenseNet201'den ayrı ayrı elde edilen özneteliklere göre yaklaşık 4 kat, birleştirilmesiyle elde edilen özneteliklere göre yaklaşık 15 kat kısaldığı görülmektedir. Sınıflandırma hızının ise Vgg19, ResNet50 ve DenseNet201'den elde edilen özneteliklere göre yaklaşık 15 kat, birleştirilen özneteliklere göre yaklaşık 60 kat arttığı söylenebilir.



Şekil 8. Öznetelik seçiminin eğitim süresi ve sınıflandırma hızına etkisi.

KBA ile seçilen öznelikler farklı sınıflandırıcılar ile eğitilip test edilmiş ve elde edilen sonuçlar DVM ile karşılaştırılmıştır. Özneliklerin Naive Bayes (NB), K-En Yakın Komşu (KNN), Karar Ağacı (KA), Diskriminant Analizi (DA) ile sınıflandırılması sonrasında elde edilen sonuçlar Tablo 5’de verilmiştir.

Tablo 5. Farklı sınıflandırıcılar ile elde edilen performans değerleri.

Sınıflandırıcı	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skor (%)
NB	95.94	96.24	95.73	96.15	95.98
KNN	98.26	98.71	97.79	98.72	98.25
KA	97.35	97.78	96.92	97.79	97.35
DA	98.17	98.44	97.88	98.46	98.16
DVM	99.03	99.24	98.81	99.25	99.02

Tablo 6’da balgam yayma mikroskop görüntüleri kullanılarak otomatik tüberküloz teşhisi yapılan çalışmalar ile elde edilen deneysel sonuçlar ifade edilmiştir. Çalışmalarda kullanılan veri setleri ve görüntü sayıları farklı olsa da görüntülerin tamamı balgam yayma örneklerinin Ziehl–Neelsen boyası ile boyanması yöntemiyle elde edilmiştir. Kullanılan görüntü sayısı ve sonuçlar dikkate alındığında sunulan çalışmanın kayda değer bir başarı sergilediği söylenebilir.

Tablo 6. Önerilen modelin mevcut çalışmalarla karşılaştırılması.

Çalışma	Yöntem	Görüntü Sayısı	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
Priya ve Srinivasan (2016)	ÇKA + DVM	1.537	92.5	-	95	90	92.68
Panicker ve ark. (2018)	ESA	1.800	-	-	97.13	78.4	86.76
Hu ve ark. (2019)	InceptionV3	2.630	98.40	-	98.40	98.40	98.40
Mithra ve Emmanuel (2019)	CAT+LoH+ESA	500	97.55	-	97.86	98.23	-
Samuel ve Kanna (2019)	Inception V3+ DVM	1.242	95.05	-	-	-	-
Samuel ve Kanna (2020)	Vgg19+DVM	1.242	86.60	-	-	-	-
Rachmad ve ark. (2020)	ResNet101+ DVM	1.266	96.56	96.96	96.28	-	96.60
Ibrahim ve ark. (2021)	AlexNet	2.464	98.73	-	98.59	98.84	-
Bu Çalışma (2022)	Vgg19+ResNet50+ DenseNet201+ KBA+DVM	4.530	99.03	99.24	98.81	99.25	99.02

4. SONUÇ

Tüberküloz, dünya çapında yaygın olan bakteri kaynaklı bulaşıcı bir hastalıktır. Başta akciğerler olmak üzere birçok organı etkileyebilir. Tedavisi mümkün olmakla birlikte, doğru teşhis konulamadığında ölümlerle sonuçlanabilir. Tanı için en uygun ve etkili yöntemler radyolojik ve mikroskopik görüntülemelerdir. Bu çalışmada, tüberküloz hastalığının otomatik teşhisi için balgam yayma mikroskop görüntülerinin kullanıldığı bir model önerilmiştir. Önerilen modelde, önceden eğitilmiş derin sinir ağlarının öznelik çıkarma yeteneğinden yararlanılmıştır. Elde edilen özneliklerin birleştirilmesi sayesinde veri setinin en iyi özneliklerini içeren öznelik vektörü oluşturulmuştur. Bununla birlikte birleştirilmiş öznelik vektörü, sınıflandırma üzerinde etkisi olmayan gereksiz öznelikleri de içermektedir. Ayrıca öznelik vektör boyutunun büyük olması modelin eğitim süresini ve sınıflandırma hızını da olumsuz etkilemektedir. Birleştirilmiş öznelik vektöründeki öznelik sayısı 3.000 iken, KBA yaklaşımı sonrası öznelik seçimi ile bu sayı 50’ye düşürülmüştür. En iyi özneliklerin seçilmesi modelin eğitim süresi, sınıflandırma hızı ve sınıflandırma başarısına katkı sağlamıştır. Çalışmada elde edilen %99.03 doğruluk, %99.24 kesinlik, %98.81 duyarlılık, %99.25 özgüllük ve %99.02 f1-skor değerleri hastalığın otomatik teşhisi için umut vericidir. Önerilen model, klinikte ön tanı veya kesin tanı sürecinde uzmanlara yardımcı olabilir. Sınıflandırma hızı önemli derecede artırdığı için, model gerçek zamanlı karar destek sistemleri için kullanılabilir. İleriki çalışmalarda önerilen model için gerçek zamanlı teşhise olanak sağlayan bir uygulama geliştirilmesi planlanmaktadır.

Yazar Katkıları

Yazarlar çalışmaya eşit oranlı katkı sunmuştur.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

KAYNAKÇA

- [1] WHO, “Tuberculosis, Overview”. (2021). <https://www.who.int/health-topics/tuberculosis> (Erişim Tarihi: Mart 15, 2022).
- [2] R. O. Panicker, K. S. Kalmady, J. Rajan, and M. K. Sabu, “Automatic detection of tuberculosis bacilli from microscopic sputum smear images using deep learning methods”, *Biocybernetics and Biomedical Engineering*, vol. 38, no. 3, pp. 691-699, 2018.
- [3] M. El-Melegy, D. Mohamed, and T. Elmelegy, “Automatic detection of tuberculosis bacilli from microscopic sputum smear images using Faster R-CNN, Transfer Learning and Augmentation”, In A. Morales, J. Fierrez, J. Sánchez, and B. Ribeiro (Eds.), *Pattern Recognition and Image Analysis, IbPRIA 2019, Lecture Notes in Computer Science*, pp. 270-278, Springer, Cham, 2019.
- [4] E. Korot, Z. Guan, D. Ferraz, S. K. Wagner, G. Zhang, X. Liu, L. Faes, N. Pontikos, S. G. Finlayson, H. Khalid, G. Moraes, K. Balaskas, A. K. Denniston, and P. A. Keane, “Code-free deep learning for multi-modality medical image classification”, *Nature Machine Intelligence*, vol. 3, pp. 288-298, 2021.
- [5] Ö. F. Nasip, and K. Zengin, “Deep learning based bacteria classification”, 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), pp. 1-5, 2018.
- [6] T. Haryanto, I. Wasito, and H. Suhartanto, “Convolutional Neural Network (CNN) for gland images classification”, 11th International Conference on Information and Communication Technology and System (ICTS), pp. 55-60, 2017.
- [7] F. C. Arisgraha, P. Widiyanti and R. Apsari, “Digital detection system design of mycobacterium tuberculosis through extraction of sputum image using neural network method”, *Indonesian Journal of Tropical and Infectious Disease*, vol. 3, pp. 35-38, 2015.
- [8] E. Priya, and S. Srinivasan, “Automated object and image level classification of TB images using support vector neural network classifier”, *Biocybernetics and Biomedical Engineering*, vol. 36, no. 4, pp. 670-678, 2016.
- [9] M. Hu, Y. Liu, Y. Zhang, T. Guan, and Y. He, “Automatic detection of tuberculosis bacilli in sputum smear scans based on subgraph classification”, *International Conference on Medical Imaging Physics and Engineering (ICMIPE)*, pp. 1-7, 2019.
- [10] K. S. Mithra, and W. R. Sam Emmanuel, “Automated identification of mycobacterium bacillus from sputum images for tuberculosis diagnosis”, *Signal, Image and Video Processing*, vol. 13, pp. 1585–1592, 2019.
- [11] R. Dinesh Jackson Samuel, and B. Rajesh Kanna, “Tuberculosis (TB) detection system using deep neural networks”, *Neural Computing and Applications*, vol. 31, pp. 1533–1545, 2019.
- [12] R. Dinesh Jackson Samuel, and B. Rajesh Kanna, “Cybernetic microbial detection system using transfer learning”, *Multimedia Tools and Applications*, vol. 79, pp. 5225–5242, 2020.
- [13] A. Rachmad, N. Chamidah, and R. Rulaningtyas, “Mycobacterium tuberculosis images classification based on combining of convolutional neural network and support vector machine”, *Communications in Mathematical Biology and Neuroscience*, 85, 2020.
- [14] A. U. Ibrahim, E. Guler, M. Guvenir, K. Suer, S. Serte, and M. Ozsoz, “Automated detection of Mycobacterium tuberculosis using transfer learning”, *Journal of Infection in Developing Countries*, vol. 15, no. 5, 678-686, 2021.
- [15] Kaggle. (2022, Apr 15). Tuberculosis Image Dataset [Online]. Available: <https://www.kaggle.com/datasets/saife245/tuberculosis-image-datasets>.
- [16] MathWorks. (2022, Sep 13). Convolutional Neural Network [Online]. Available: <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html>.
- [17] A. Alem, and S. Kumar, “Transfer learning models for land Cover and land use classification in remote sensing image”, *Applied Artificial Intelligence*, vol. 36, no. 1, 2022.
- [18] C. Ammatmanee, and L. Gan, “Transfer learning for hostel image classification”, *Data Technologies and Applications*, vol. 56, pp. 44-59, 2022.
- [19] K. Simonyan, and A. Zisserman, “Very deep convolutional networks for large-scale image recognition”, *CoRR*, abs/1409.1556, 2015.
- [20] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition”, *arXiv:1512.03385v1*, 2015.
- [21] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, “Densely connected convolutional networks”, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2261-2269, 2017.
- [22] C. Chen, Y. Tsai, F. Chang, and W. Lin, “Ensemble feature selection in medical datasets: Combining filter, wrapper, and embedded feature selection results”, *Expert Systems*, vol. 37, 2020.
- [23] E. Alhenawi, R. Al-Sayyed, A. Hudaib and S. Mirjalili, “Feature selection methods on gene expression microarray data for cancer classification: A systematic review”, *Computers in Biology and Medicine*, vol. 140, 2021.
- [24] W. Yang, K. Wang, and W. Zuo, “Neighborhood component feature selection for high-dimensional data”, *Journal of Computers*, vol. 7, no. 1, pp. 161-168, 2012.
- [25] L. Wang, D. Johnson, and Y. Lin, “Using EEG to detect driving fatigue based on common spatial pattern and support vector machine”, *Turkish Journal*

- of Electrical Engineering and Computer Sciences, vol. 29, no. 3, pp. 1429-1444, 2021.
- [26] M. Azimi-Pour, H. Eskandari-Naddaf and A. Pakzad, "Linear and non-linear SVM prediction for fresh properties and compressive strength of high volume fly ash self-compacting concrete", *Construction and Building Materials*, vol. 230, 2020.
- [27] S. Kilicarslan, K. Adem, and M. Celik, "Diagnosis and classification of cancer using hybrid model based on ReliefF and convolutional neural network", *Medical Hypotheses*, vol. 137, 2020.
- [28] MathWorks Inc. (2021, Oct 15). MATLAB V2021b [Online]. Available: <https://www.mathworks.com/products/matlab.html>.



Auto-detection of Intermetallic and Eutectic Phases in Microstructure of the AZ91 Mg-alloys by Image Processing Techniques

AZ91 Mg Alaşımlarının Mikroyapısındaki İntermetalik ve Ötektik Fazların Görüntü İşleme Teknikleriyle Otomatik Tespiti

¹Abdullah ELEN , ²Levent ELEN 

¹Bandırma Onyedü Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Yazılım Mühendisliği Bölümü, 10200 Bandırma/Balıkesir, Türkiye

²Karabük Üniversitesi, T.O.B.B. Teknik Bilimler Meslek Yüksekokulu, Makine ve Metal Teknolojileri Bölümü, 78050 Karabük, Türkiye

¹aelen@bandirma.edu.tr, ²leventelen@karabuk.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 18 August 2022

Accepted : 3 October 2022

Keywords:

AZ91 Mg-alloys, Image Processing, Microstructure, Intermetallic Phase, Eutectic Phase

ABSTRACT

AZ91, which is used in the production of parts in the aerospace, defense and automotive industries, can be enhanced by the addition of an alloying element or the cooling rate, due to the weak strength and formability properties of advanced technology Mg-alloys. In this study, an image processing-based model is proposed that automatically recognizes the intermetallic and eutectic phases required for the analysis of microstructural properties in AZ91 Mg-alloys. The proposed method consists of two stages; In the first step, the eutectic phase template is obtained as a binary image. In the second step, the binary image containing the intermetallic and eutectic phases is obtained and the result image with only the intermetallic phases is obtained by taking the difference of these two patterns. According to segmentation results of images used in the experimental study, it was calculated as 12% eutectic, 6% intermetallic and 82% alpha phase.

© 2022 Bandırma Onyedü Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 18 Ağustos 2022

Kabul : 3 Ekim 2022

Anahtar Kelimeler:

AZ91 Mg Alaşımları, Görüntü İşleme, Mikroyapı, İntermetalik Faz, Ötektik Faz

ÖZET

Havacılık, savunma ve otomotiv endüstrilerinde parça üretiminde kullanılan AZ91, ileri teknoloji Mg alaşımlarının zayıf mukavemet ve şekillendirilebilirlik özelliklerinden dolayı bir alaşım elementi ilavesi veya soğutma hızı ile geliştirilebilir. Bu çalışmada, AZ91 Mg alaşımlarında mikroyapı özelliklerinin analizi için gerekli olan intermetalik ve ötektik fazları otomatik olarak tanımayı sağlayan görüntü işleme tabanlı bir model önerilmiştir. Önerilen yöntem iki aşamadan meydana gelmektedir; ilk aşamada ikili görüntü olarak ötektik faz şablonu elde edilir. İkinci aşamada ise intermetalik ve ötektik fazları içeren ikili görüntü elde edilir ve bu iki şablonun farkı alınarak yalnızca intermetalik fazların olduğu sonuç görüntüsüne ulaşılır. Deneysel çalışmada kullanılan görüntülerin segmentasyon sonucuna göre ortalama %12 ötektik, %6 intermetalik ve %82 alfa fazı olarak hesaplanmıştır.

© 2022 Bandırma Onyedü Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. INTRODUCTION

Magnesium (Mg) and its alloys, which are the lightest metallic building materials, are extensively used in a variety of engineering fields such as telecommunications, automobile industries, aviation and portable microelectronics due to their low densities as well as their properties like high specific strength, specific hardness, and machinability [1]. In particular, AZ91 alloy containing (on average) Mg-9%Al 0.8%Zn and 0.2%Mn is the most preferred Mg alloy, used in approximately 90% of all Mg casting products [2]. All these sectors, which are among the AZ91 alloys that are increasing in usage day by day, are waiting for AZ91 alloys with more advanced mechanical properties. Therefore, the improvement of the mechanical properties of all Mg-alloys, especially AZ91, has been the focus of academic studies. There have been some studies on improving the mechanical properties of AZ91 alloys by alloying. Elen, in his study, reported that the mechanical properties of *Sb* and *Bi* elements added at different rates in the AZ91 alloy improved [3]. Candan et al., in their studies, found that the *Ti* element increases the mechanical properties (tensile stress up to 18% and yield stress up to 47%) [4]. In his study, Türen reported that the Ultimate tensile strength (UTS) and yield strength (YS) values of the alloy increased with the addition of *Sn* to AZ91 [5]. In addition, it has been proven by studies [3, 6–8] that in general, Mg-alloys exhibit different mechanical properties with the change of cooling rate. It has been reported in studies [3, 6, 8] that the effect of cooling rate is very important in the development of microstructure and mechanical properties of AZ91 alloys. The changes in the microstructure of the differences in the proportional change of the cooling rate can be clearly observed. These changes in the microstructure have a significant (positive or negative) effect on the mechanical properties of the material. Therefore, the influence of the material's microstructure must be considered in the creation of new manufacturing processes as well as in the existing design and production of materials with high-value components. To quantify each of the microstructures with different properties, it usually requires different analysis procedures [9]. Different techniques are available to measure some microstructural properties of materials. However, the limitations of these techniques need to be developed and reviewed. The American Society for Testing and Materials, short for ASTM, produces industrially accepted standards for microstructural analysis. One of these standards, ASTM E112, defines aerodynamic methods for manually measuring average grain size based on linear intersections of line segments [10]. Parallel lines are drawn on the microstructure image obtained with the optical microscope and the places where they cross the grain boundaries are marked. The average displacement between the marked locations gives the approximate average grain size of the material. Typically, only a subset of the particles is measured and 300 measurements are required to obtain a statistically valid result. The line set can be placed randomly so that the result to be obtained can be free from possible errors. However, the aspect ratio of the grains cannot be calculated in this case. For this reason, the lines are selected manually to be able to measure the width and length of each grain and provide a more detailed measurement. However, users may make mistakes in the determination of the particles to be measured. The ASTM E562 standard, which describes techniques for measuring volume fraction, works based on the point count principle. In line with this standard, a series of dots are placed along the microstructure image, and then an expert indicates which spots are found at each stage. The percentage of points marked at any stage gives the proportion of volume that stage has. The application criteria of these standards create labor and work intensity. The E562 standard requires an estimated 15 minutes' measurement time per image for an experienced user [11]. This slows analysts down and makes them inefficient. These methods are also prone to human error and poor reproducibility, as defining the location of grain boundaries is generally dependent on personal perspective. Such situations make it difficult to detect small microstructural changes and may mislead researchers and researchers in new manufacturing processes or microstructural improvement [9]. Existing approaches to image segmentation can be subdivided depending on the type of algorithms, as well as the types of mathematical convolution applied, artificial intelligence or nature inspired. Such algorithms such as statistical approaches, clustering, artificial neural networks, nonlinear diffusion analysis, and content-based analysis [12] are used not only in the analysis of two-dimensional (2D) images, but also in one-dimensional (1D) signals and three-dimensional (3D) image processing, and plays a very important role in multidimensional calculations. However, as the size of the data increases, so does their complexity. In the case of microstructure photo analysis these methods may be more or less successful [13]. Therefore, the main objective of this study is to examine the structural change kinetic characterization and spatial variation of the α -Mg main matrix phase and β -Mg₁₇Al₁₂ intermetallic phase in the microstructure of AZ91. For this reason, in this study, the results of changes in any microstructure of AZ91 Mg alloys are analyzed by minimizing user intervention with the image processing method, thus eliminating and/or minimizing the margin of error.

This study was carried out in four stages; In the first stage, some basic concepts related to AZ91 and Mg were emphasized. In the second stage, the preparation process of AZ91 samples used in experimental studies as material and detailed explanations of the proposed method with sample images are given. In the third stage, the percentage ratios of α -Mg, β -Mg₁₇Al₁₂ (intermetallic) and α -Mg+ β -Mg₁₇Al₁₂ (eutectic) phases in the alloy on the sample microstructure images were automatically determined through experimental studies. At the last stage, the results obtained in the study are summarized.

2. MATERIALS AND METHOD

In this section, automatic segmentation of intermetallic ($\beta\text{-Mg}_{17}\text{Al}_{12}$) and eutectic ($\alpha\text{-Mg} + \beta\text{-Mg}_{17}\text{Al}_{12}$) phases in AZ91 Mg-alloys microstructure images by image processing techniques, calculation of the ratio of these phases in the alloy and GUI developed as a desktop application are discussed.

2.1. The AZ91 Mg-alloys

In the preparation of AZ91 alloy, 99.8% pure Mg and Al were used. The melting process was carried out in an environment closed to the outside atmosphere. The atmosphere of the melting furnace was kept under control by using Argon gas as the shielding gas. After the melting was completed, the melt was poured into a permanent mold made of AISI 1040 quality steel, which was heated to 250°C before casting, in order to prevent possible errors that may arise from the sudden cooling rate.

For metallographic analysis, the surfaces of the samples were polished with 400, 600 and 800 mesh abrasives, using distilled water, and polished using 1 μm alumina paste. Then, the surface of the samples was washed with distilled water and alcohol and dried. According to ASTM E407–99 samples were etched with 75% ethylene glycol, 24% distilled water, 1% HNO₃ solution. Microstructural observations of the samples were performed using optical and scanning electron microscope (SEM). Microanalysis and determination of the crystal structure of the phases in the studied alloys were performed by X-ray Diffraction (XRD) and Energy-dispersive X-ray Spectroscopy (EDX), respectively. By XRD analysis, the presence of $\alpha\text{-Mg}$ phase as well as $\beta\text{-Mg}_{17}\text{Al}_{12}$ intermetallic phase was detected in the microstructure of the AZ91 alloy as shown in Fig. (1). In addition to $\alpha\text{-Mg}$ matrix, $\beta\text{-Mg}_{17}\text{Al}_{12}$ intermetallic as a thin phase at grain boundaries and $\alpha\text{-}\beta$ eutectic has been detected in AZ91 alloy, and this has been reported in different studies [8, 9].




Fig. 1. The X-ray diffraction (XRD) analysis of the AZ91 Mg-alloy.

In addition, EDS analysis was performed for the determination of the phases and the presence of $\alpha\text{-Mg}$, $\beta\text{-Mg}_{17}\text{Al}_{12}$ and $\alpha\text{-}\beta$ phases were determined. As seen in Fig. (2), it has been determined that the AZ91 microstructure is generally composed of $\alpha\text{-Mg}$ main matrix and consists of eutectic ($\alpha\text{+}\beta$) and intermetallic $\beta\text{-Mg}_{17}\text{Al}_{12}$ phases extending along the grain boundaries.




Fig. 2. Microstructure images of the AZ91 Mg-alloy in section A after casting; (a) optical microscope, (b) Scanning Electron Microscope (SEM).

SEM images and EDX analysis of AZ91 are given in Fig. (3). When the SEM images were examined, the particles dispersed on the main matrix phase were detected. As a result of the EDX analysis, they were found to be rich in Al and Mg content.




Fig. 3. Alloy of AZ91 (a) SEM image and EDX analysis.

2.2. Proposed Method

The proposed method provides automatic segmentation of eutectic and intermetallic phases in microstructure images of AZ91 alloys. This process is carried out in two stages. In the first step, pixel areas representing the eutectic phases in the microstructure image are detected. In the second step, the input image is preprocessed for the segmentation of the intermetallic phases, and then the pixel regions representing the intermetallic phases are found by subtracting the eutectic phase image obtained in the first step. The flow chart of the proposed method is shown in Fig. (4).

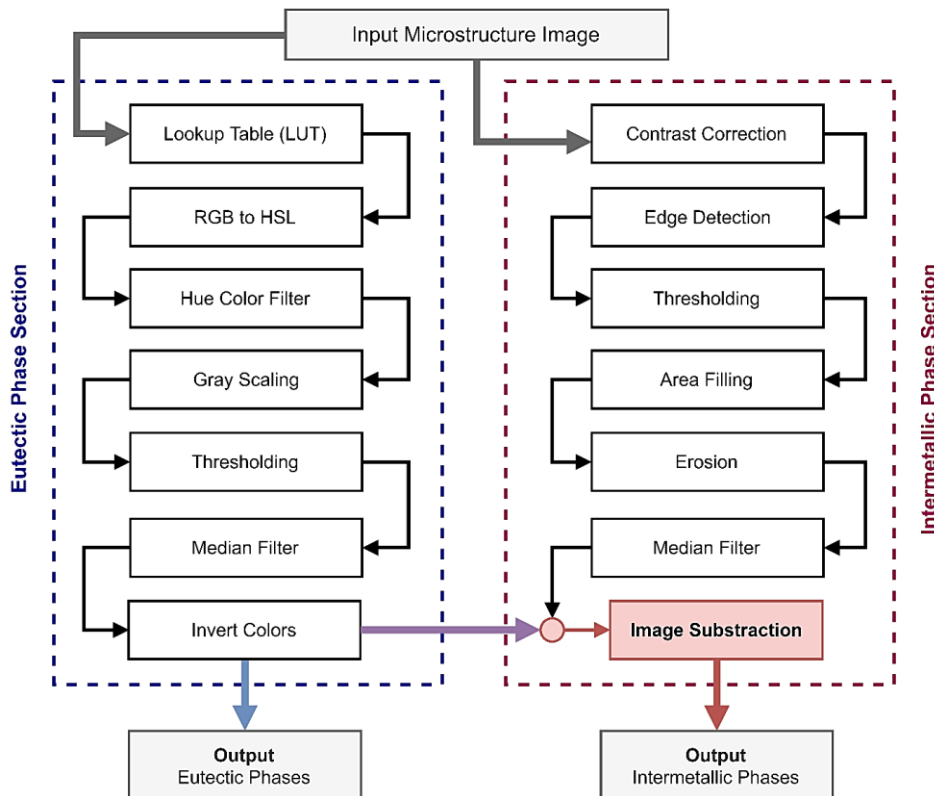


Fig. 4. Flowchart of the proposed method.

Lookup Table (LUT) is a method that enables coloring operations to express images with high color depth in simpler colors or to highlight desired objects in grayscale images. The LUT performs these operations using a reference table called a color map or palette [14], which generates the output value for each pixel in the image as shown in Eq. (1). In this study, “Union Jack” lookup table (See Appendix-1) was used.

$$LUT = \{ \{0, [R_{out}, G_{out}, B_{out}]\}, \dots, \{255, [R_{out}, G_{out}, B_{out}]\} \}; \quad (1)$$

In the first step of the proposed method, the eutectic phases of the AZ91 alloy in the microstructure images obtained in grayscale were highlighted. Thus, the pixel values containing the eutectic phases in the input image are highlighted in blue, which can be easily distinguished from the others, as shown in Fig. (5).




Fig. 5. Applying LUT to the input image; (a) input image, (b) output image.

In the next step, it is converted from RGB color space to HSL, as shown in Eq. (2), to isolate the eutectic phases in the output image obtained by the LUT.

$$Cmax = \max(R/255, G/255, B/255),$$

$$Cmin = \min(R/255, G/255, B/255),$$

$$\Delta = Cmax - Cmin,$$

$$L = (Cmax + Cmin)/2,$$

$$H = \begin{cases} 0^\circ, & \Delta = 0 \\ 60^\circ \times \left(0 + \frac{G/255 - B/255}{\Delta}\right), & Cmax = R/255 \\ 60^\circ \times \left(2 + \frac{B/255 - R/255}{\Delta}\right), & Cmax = G/255 \\ 60^\circ \times \left(4 + \frac{R/255 - G/255}{\Delta}\right), & Cmax = B/255 \end{cases} \quad (2)$$

$$S = \begin{cases} 0, & \Delta = 0 \\ \frac{\Delta}{1 - |2L - 1|}, & otherwise \end{cases}$$

Then, it was determined that the eutectic phase intervals in the image are between 180 and 300 degrees according to the Hue component of the HSL color space shown in Fig. (6), and a Hue filter function was developed accordingly, as shown in Algorithm 1. Thus, all pixel areas other than the eutectic phases are painted white, removing unnecessary details on the image.




Fig. 6. Hue component in the HSL encodings of the RGB color-space.

Algorithm 1. Applying the Hue filter to image.

```

1: function ApplyHueFilter(Image img)
2:   imgHSL  $\leftarrow$  ConvertToHSL(img);
3:   for i  $\leftarrow$  0 to img.Width do
4:     for j  $\leftarrow$  0 to img.Height do
5:       set Hue  $\leftarrow$  imgHSL.GetHue(i, j);
6:       set WhiteColor  $\leftarrow$  new Color(255, 255, 255);
7:       if (Hue < 180 and Hue > 300)
8:         img.SetPixel(i, j, WhiteColor);
9:       end if
10:    end for
11:  end for
12:  return img;
13: end function

```

The image obtained as a result of applying the Hue color filter is shown in Fig. (7).




Fig. 7. Applying Hue color filter; (a) input image, (b) output image.

Up to this stage, the eutectic phases in the microstructure images have been segmented to a large extent. In the next and subsequent stages, the image colors are inverted in the final processing step by applying gray scaling, the Otsu thresholding and Median filtering to reduce the effect of pixels representing intermetallic phases in the image and to segment intermetallic phases. Pixels representing intermetallic phases in microstructure images are closer to the background color spectrum than eutectic phases. Therefore, as the first processing step, the contrast correction of the microstructure images taken with the microscope as shown in Fig. (8), and then the enhancement of the border regions with the Kirsch [15] edge detection algorithm was provided.




Fig. 8. Contrast correction and edge detection; (a) contrast-corrected input image, (b) Kirsch edge detection result.

In the next step, the edge-detected gray-scale image was converted to binary format with Huang [16] thresholding method as shown in Fig. (9), and Hole Filling (HF) method was applied to prevent possible information loss in pixels representing intermetallic phases.

The HF consists of two stages; firstly, the objects in the binary image are detected by the method of Connected Components Labeling (CCL). In the CCL method, if we consider that an image represented by R comes from S discrete regions, objects in the image can be calculated as in Eq. (3). In the second stage, each discrete region under a certain size is painted in white color. In this study, we limited the size of the objects to be filled with 50-pixels.

$$R_f = R_b^C = \bigcup_{i=1, i \neq b}^S R_i \quad (3)$$




Fig. 9. Thresholding and area filling; (a) Huang thresholding, (b) hole filling.

Naturally, noise occurs in the images obtained as a result of these processes. In order to overcome these, the erosion method, which is a morphological processing filter, and the Median smoothing filter, respectively, are applied as shown in Fig. (10). It results in some undesired noises in the result image. The Median smoothing filter is applied to remove this problem with Eq. (4).

$$R[x, y] = \text{median} \{g[p, q]\} \quad (4)$$

where $g[p, q]$ is convolution kernel, p and q are kernel index. In this study, a 3×3 convolution matrix is chosen for performance. However, as a result of these processes, as seen in Fig. 10(b), both eutectic and intermetallic phase fields are intertwined in the output image obtained. In the last step, with the image subtraction function given in Algorithm 2, the eutectic phase areas in the output image will be deleted so that only intermetallic phase areas exist.




Fig. 10. Applying morphological and smoothing filters; (a) erosion filter, (b) median filter.

Algorithm 2. The function of image subtraction.

```

1: function ImageSubtraction(Image imgSource, Image imgTarget)
2:   set imgResult  $\leftarrow$  new Image(imgSource.Width, imgSource.Height);
3:   for i  $\leftarrow$  0 to imgSource.Width do
4:     for j  $\leftarrow$  0 to imgSource.Height do
5:       set pixelSource  $\leftarrow$  imgSource.GetPixel(i, j);
6:       set pixelTarget  $\leftarrow$  imgTarget.GetPixel(i, j);
7:       if (pixelSource - pixelTarget < 0)
8:         imgResult.SetPixel(i, j, new Color(0, 0, 0));
9:       else
10:        set valPixel  $\leftarrow$  (pixelSource - pixelTarget);
11:        set subColor  $\leftarrow$  new Color(valPixel, valPixel, valPixel);
12:        imgResult.SetPixel(i, j, subColor);
13:      end if
14:    end for
15:  end for
16:  return imgResult;
17: end function

```

As can be seen in Fig. (11), the result image in which the intermetallic phases are clearly determined with the image extraction function given in Algorithm 2 is obtained as in Fig. 11(c).




Fig. 11. Image subtraction; a) the extracted eutectic phases, b) the case where the eutectic and intermetallic phases are intertwined, c) the extracted intermetallic phases.

As a result of all these processing steps, the obtained intermetallic and eutectic phase regions applied to the input image using red and blue colors are shown in Fig. (12).




Fig. 12. Automated phase segmentation; (a) input image, (b) output image.

The graphical user interface (GUI) we have developed with the C# programming language is shown in Fig. (13). The numbers shown here are as follows; The region numbered 1 is where the microstructure input image is displayed. Region numbered 2 is where the output image of the microstructure segmented according to the proposed method is shown. The region numbered 3 is the graphical representation of the segmented α , β and $\alpha+\beta$

phases. The region numbered 4 is where the features of the microstructure input image are displayed. The region numbered 5 is where the intermetallic and eutectic phases are shown separately according to the segmentation result. Finally, in the area numbered 6, there is the control panel of the GUI.

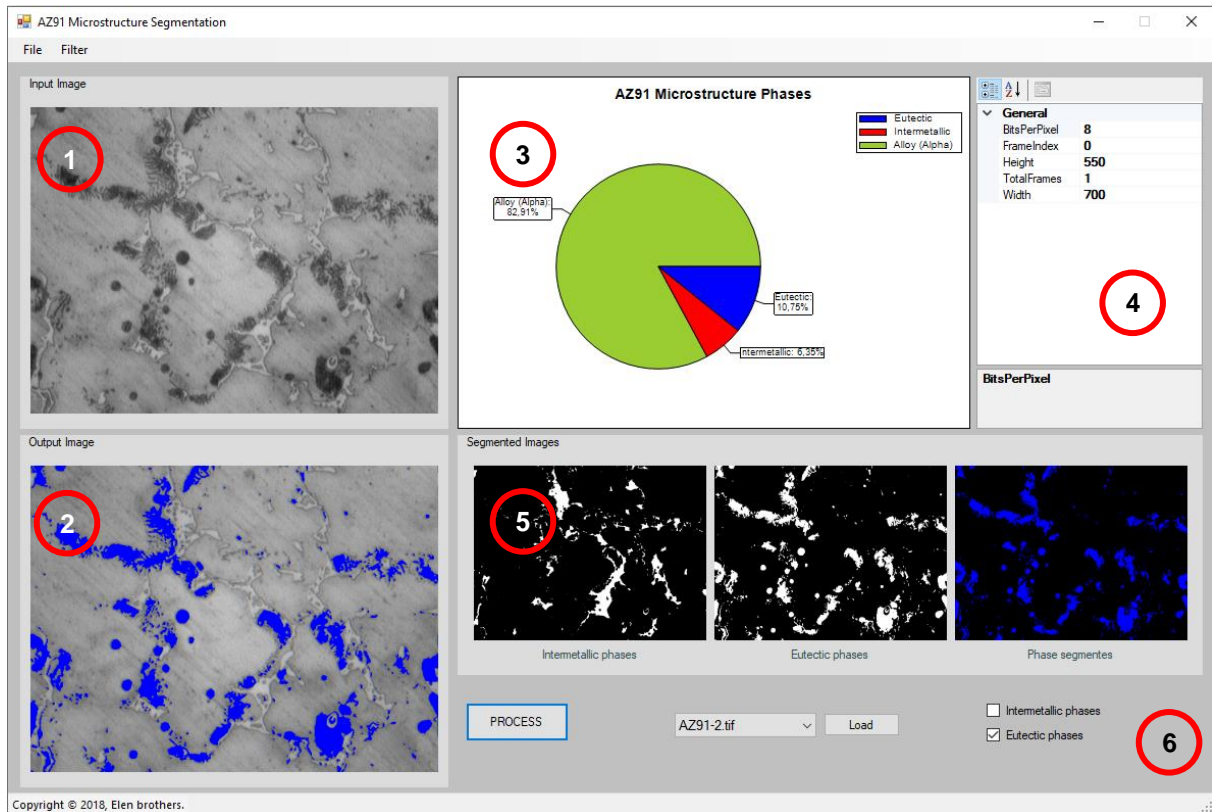


Fig. 13. The graphical user interface (GUI).

3. EXPERIMENTAL RESULTS

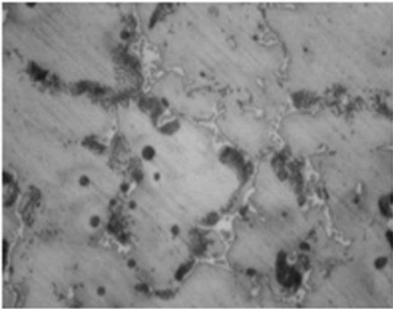
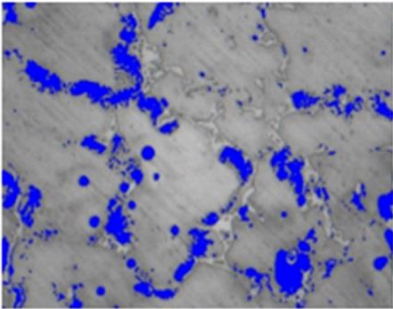
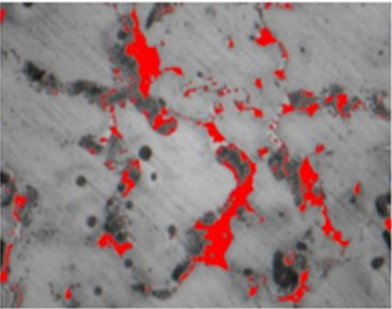
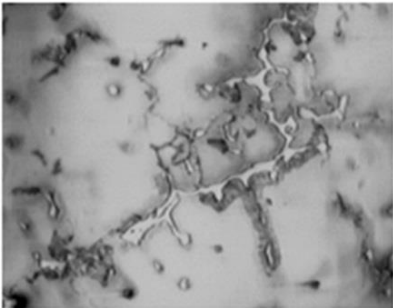
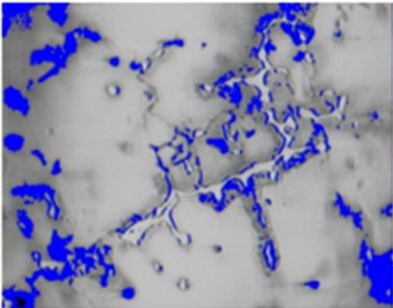
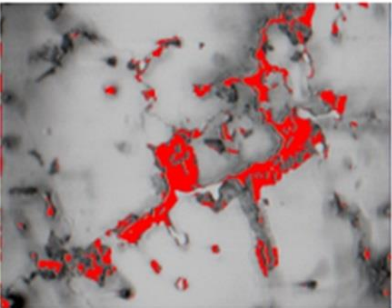
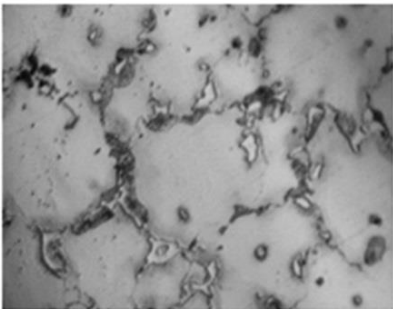
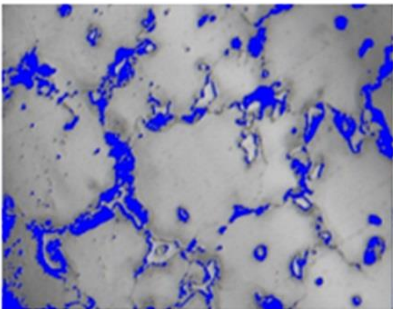
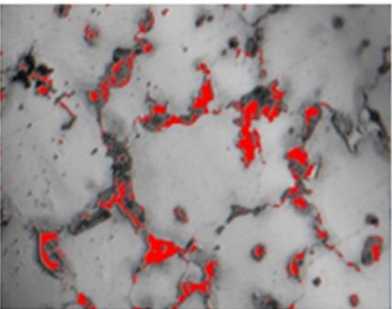
There are 10 different AZ91 microstructure images obtained with optical microscope in experimental studies. These images belong to the samples we prepared in the casting laboratories of Karabük University Metallurgical and Materials Engineering department. Each of the images is monochrome with 700x550 pixel dimensions and was obtained with a 20X microscope objective. With the GUI we have developed, the phases in the microstructure images are automatically detected in less than 500 milliseconds. The measurements we obtained according to the sample dataset as a result of the experimental studies are shown in detail in Table 1.

Table 1. Phase measurement results on the sample dataset.

Sample ID	Phases			Elapsed time (millisecond)
	Eutectic	Intermetallic	Alpha	
AZ91-01	5,54%	5,59%	88,87%	477
AZ91-02	10,74%	6,35%	82,91%	493
AZ91-03	15,46%	6,33%	78,21%	496
AZ91-04	19,05%	5,72%	75,23%	462
AZ91-05	14,12%	3,82%	82,06%	447
AZ91-06	10,66%	6,74%	82,60%	446
AZ91-07	10,60%	5,27%	84,13%	467
AZ91-08	14,23%	8,30%	77,47%	451
AZ91-09	10,37%	3,31%	86,32%	452
AZ91-10	11,31%	4,30%	84,40%	474

Table 2 shows the segmented phase results of some microstructure images in the sample dataset.

Table 2. Phase segmentation results on the sample dataset.

Input image	Segmentation Results	
	Eutectic phases	Intermetallic phases
		
		
		

4. CONCLUSION

The microstructure of AZ91 Mg alloys, which we used in our experimental studies, was observed to consist of α -Mg and aluminum-rich β -Mg₁₇Al₁₂ intermetallic phases in general. However, the presence of α + β -eutectic phases was detected near the grain boundaries. In order to quantitatively characterize these phases detected in the microstructure of AZ91, an automatic image analysis model was developed and successfully applied. In addition, this application does not apply to AZ91 alloy, which does not contain any other element and does only under normal cooling conditions. At the same time, besides cooling rate, it is valid for artificial or natural aging etc. Because the ratios/types of phases are changes with increasing time because of aging [17]. Therefore, it is a method applicable to different types of alloys and alloys with aging and cooling rates. Because this method is a type of software that includes variation of complex mathematical expressions such as surface analysis, areal size calculation and proportional distributions of phases from simple 2D optical microscope images. With the image processing method, the detection and quantification of complex phases such as eutectic phase with very small deviations and high accuracy has become a fast and easy process. However, the deformation processes applied to the alloys (*forging, rolling, extrusion, etc.*), the addition of different alloying elements or the cooling rate, make it easier to overcome the difficulties of determining the volumetric amount of intermetallic and main matrix phases by making them thinner. Possible deviations that may arise as a result of the analysis are due to the fact that the micro-voids resulting from the acid etching process performed before the microstructure imaging are burned excessively due to acid penetration or that the particles left by the abrasives while applying the surface treatment (*sanding and polishing*) are perceived as phases as a result of sticking to the surface. However, it has been determined that these deviations, which may occur in samples with a clean surface treatment, are in an acceptable range. Since automatic analysis of AZ91 Mg-alloys microstructure properties by image processing methods has not been studied before, the proposed method is promising for new studies in this field. As a result of this study, it is thought that the developed model and the results obtained will shed light on similar studies by adding important information to the literature.

Author Contributions

Each author contributed equally to the study.

Conflict of interest

The authors declare that there is no conflict of interest between them.

REFERENCES

- [1] L. Gaines, R. Cuenca, S. Wu, and F. Stodolsky, "Potential automotive uses of wrought magnesium alloys", Argonne National Lab., IL (United States), ANL/ES/CP-89958; CONF-9604136-21, 1996.
- [2] C. Blawert, N. Hort, and K. U. Kainer, "Automotive Applications of Magnesium and Its Alloys", Trans. Indian Inst. Met., vol. 57, no. 4, p. 12, 2004.
- [3] L. Elen, "Effects of Bi and Sb Additions with Solidification Rate on The Microstructure and Mechanical Properties of The AZ91 Alloys", M.Sc. Thesis, Karabük University, Graduate School of Natural and Applied Sciences Department of Metal Education, 2012.
- [4] S. Candan, M. Ünal, E. Koç, Y. Türen, and E. Candan, "Effects of Titanium Addition on Mechanical and Corrosion Behaviours of AZ91 Magnesium Alloy", Journal of Alloys and Compounds, vol. 509, no. 5, pp. 1958-1963, 2011.
- [5] Y. Türen, "Effect of Sn Addition on Microstructure, Mechanical and Casting Properties of AZ91 Alloy", Materials and Design, vol. 49, pp. 1009-1015, 2013.
- [6] L. Elen, Y. Türen, and E. Koç, "Effects of Solidification Rate on Microstructure and Mechanical Properties with Sb at Different Ratio of AZ91 Quality Mg Alloy", International Journal of Engineering Research and Development, vol. 11, no. 2, pp. 451-463, 2019.
- [7] L. Elen, B. Çiçek, E. Koç, Y. Türen, Y. Sun, and H. Ahlatcı, "Effects of Alloying Element and Cooling Rate on Properties of AM60 Mg Alloy", Mater. Res. Express, vol. 6, no. 9, pp. 096511, 2019.
- [8] M. Ünal, "Effects of Solidification Rate and Sb Additions on Microstructure and Mechanical Properties of As Cast AM60 Magnesium Alloys", International Journal of Cast Metals Research, vol. 27, no. 2, pp. 80-86, 2014.
- [9] A. Campbell, P. Murray, E. Yakushina, S. Marshall, and W. Ion, "New Methods for Automatic Quantification of Microstructural Features Using Digital Image Processing," Materials and Design, vol. 141, pp. 395-406, 2018.
- [10] ASTM E112, "Test Methods for Determining Average Grain Size," ASTM International.
- [11] ASTM E562, "ASTM E562: Standard Test Method for Determining Volume Fraction by Systematic Manual Point Count."
- [12] A. Elen, and M. K. Turan, "A new approach for fully automated segmentation of peripheral blood smears", International Journal of Advanced and Applied Sciences, vol. 5, no. 1, pp. 81-93, 2018.
- [13] L. Rauch, and L. Madej, "Application of the Automatic Image Processing in Modeling of the Deformation Mechanisms Based on the Digital Representation of Microstructure", International Journal for Multiscale Computational Engineering, vol. 8, no. 3, pp. 343-356, 2010.
- [14] R. Bourne, "Fundamentals of digital imaging in medicine", Springer Science and Business Media, pp. 20-21, 2010.
- [15] R. Kirsch, "Computer determination of the constituent structure of biological images", Computers and Biomedical Research, vol. 4, no. 3, pp. 315-328, 1971.
- [16] L.-K. Huang, and M.-J. J. Wang, "Image thresholding by minimizing the measures of fuzziness", Pattern Recognition, vol. 28, no. 1, pp. 41-51, 1995.
- [17] B. Çiçek, T. Aydoğmuş and Y. Sun, "A basic study on artificial aging in Mg-10Al₁₂Si+1Pb alloy", Materials Research Express, vol. 7, no. 1, pp. 1-9, 2020.

APPENDIX-1: Lookup table: “Union Jack”

#	RGB	#	RGB	#	RGB	#	RGB	#	RGB	#	RGB	#	RGB	#	RGB
0	(0, 0, 0)	32	(0, 0, 95)	64	(0, 0, 190)	96	(127, 127, 222)	128	(255, 255, 255)	160	(222, 127, 127)	192	(190, 0, 0)	224	(222, 127, 127)
1	(0, 0, 2)	33	(0, 0, 97)	65	(3, 3, 191)	97	(131, 131, 223)	129	(253, 251, 251)	161	(221, 123, 123)	193	(191, 3, 3)	225	(223, 131, 131)
2	(0, 0, 5)	34	(0, 0, 100)	66	(7, 7, 192)	98	(135, 135, 224)	130	(252, 247, 247)	162	(220, 119, 119)	194	(192, 7, 7)	226	(224, 135, 135)
3	(0, 0, 8)	35	(0, 0, 103)	67	(11, 11, 193)	99	(139, 139, 225)	131	(251, 243, 243)	163	(219, 115, 115)	195	(193, 11, 11)	227	(225, 139, 139)
4	(0, 0, 11)	36	(0, 0, 106)	68	(15, 15, 194)	100	(143, 143, 226)	132	(250, 239, 239)	164	(218, 111, 111)	196	(194, 15, 15)	228	(226, 143, 143)
5	(0, 0, 14)	37	(0, 0, 109)	69	(19, 19, 195)	101	(147, 147, 227)	133	(249, 235, 235)	165	(217, 107, 107)	197	(195, 19, 19)	229	(227, 147, 147)
6	(0, 0, 17)	38	(0, 0, 112)	70	(23, 23, 196)	102	(151, 151, 228)	134	(248, 231, 231)	166	(216, 103, 103)	198	(196, 23, 23)	230	(228, 151, 151)
7	(0, 0, 20)	39	(0, 0, 115)	71	(27, 27, 197)	103	(155, 155, 229)	135	(247, 227, 227)	167	(215, 99, 99)	199	(197, 27, 27)	231	(229, 155, 155)
8	(0, 0, 23)	40	(0, 0, 118)	72	(31, 31, 198)	104	(159, 159, 230)	136	(246, 223, 223)	168	(214, 95, 95)	200	(198, 31, 31)	232	(230, 159, 159)
9	(0, 0, 26)	41	(0, 0, 121)	73	(35, 35, 199)	105	(163, 163, 231)	137	(245, 219, 219)	169	(213, 91, 91)	201	(199, 35, 35)	233	(231, 163, 163)
10	(0, 0, 29)	42	(0, 0, 124)	74	(39, 39, 200)	106	(167, 167, 232)	138	(244, 215, 215)	170	(212, 87, 87)	202	(200, 39, 39)	234	(232, 167, 167)
11	(0, 0, 32)	43	(0, 0, 127)	75	(43, 43, 201)	107	(171, 171, 233)	139	(243, 211, 211)	171	(211, 83, 83)	203	(201, 43, 43)	235	(233, 171, 171)
12	(0, 0, 35)	44	(0, 0, 130)	76	(47, 47, 202)	108	(175, 175, 234)	140	(242, 207, 207)	172	(210, 79, 79)	204	(202, 47, 47)	236	(234, 175, 175)
13	(0, 0, 38)	45	(0, 0, 133)	77	(51, 51, 203)	109	(179, 179, 235)	141	(241, 203, 203)	173	(209, 75, 75)	205	(203, 51, 51)	237	(235, 179, 179)
14	(0, 0, 41)	46	(0, 0, 136)	78	(55, 55, 204)	110	(183, 183, 236)	142	(240, 199, 199)	174	(208, 71, 71)	206	(204, 55, 55)	238	(236, 183, 183)
15	(0, 0, 44)	47	(0, 0, 139)	79	(59, 59, 205)	111	(187, 187, 237)	143	(239, 195, 195)	175	(207, 67, 67)	207	(205, 59, 59)	239	(237, 187, 187)
16	(0, 0, 47)	48	(0, 0, 142)	80	(63, 63, 206)	112	(191, 191, 238)	144	(238, 191, 191)	176	(206, 63, 63)	208	(206, 63, 63)	240	(238, 191, 191)
17	(0, 0, 50)	49	(0, 0, 145)	81	(67, 67, 207)	113	(195, 195, 239)	145	(237, 187, 187)	177	(205, 59, 59)	209	(207, 67, 67)	241	(239, 195, 195)
18	(0, 0, 53)	50	(0, 0, 148)	82	(71, 71, 208)	114	(199, 199, 240)	146	(236, 183, 183)	178	(204, 55, 55)	210	(208, 71, 71)	242	(240, 199, 199)
19	(0, 0, 56)	51	(0, 0, 151)	83	(75, 75, 209)	115	(203, 203, 241)	147	(235, 179, 179)	179	(203, 51, 51)	211	(209, 75, 75)	243	(241, 203, 203)
20	(0, 0, 59)	52	(0, 0, 154)	84	(79, 79, 210)	116	(207, 207, 242)	148	(234, 175, 175)	180	(202, 47, 47)	212	(210, 79, 79)	244	(242, 207, 207)
21	(0, 0, 62)	53	(0, 0, 157)	85	(83, 83, 211)	117	(211, 211, 243)	149	(233, 171, 171)	181	(201, 43, 43)	213	(211, 83, 83)	245	(243, 211, 211)
22	(0, 0, 65)	54	(0, 0, 160)	86	(87, 87, 212)	118	(215, 215, 244)	150	(232, 167, 167)	182	(200, 39, 39)	214	(212, 87, 87)	246	(244, 215, 215)
23	(0, 0, 68)	55	(0, 0, 163)	87	(91, 91, 213)	119	(219, 219, 245)	151	(231, 163, 163)	183	(199, 35, 35)	215	(213, 91, 91)	247	(245, 219, 219)
24	(0, 0, 71)	56	(0, 0, 166)	88	(95, 95, 214)	120	(223, 223, 246)	152	(230, 159, 159)	184	(198, 31, 31)	216	(214, 95, 95)	248	(246, 223, 223)
25	(0, 0, 74)	57	(0, 0, 169)	89	(99, 99, 215)	121	(227, 227, 247)	153	(229, 155, 155)	185	(197, 27, 27)	217	(215, 99, 99)	249	(247, 227, 227)
26	(0, 0, 77)	58	(0, 0, 172)	90	(103, 103, 216)	122	(231, 231, 248)	154	(228, 151, 151)	186	(196, 23, 23)	218	(216, 103, 103)	250	(248, 231, 231)
27	(0, 0, 80)	59	(0, 0, 175)	91	(107, 107, 217)	123	(235, 235, 249)	155	(227, 147, 147)	187	(195, 19, 19)	219	(217, 107, 107)	251	(249, 235, 235)
28	(0, 0, 83)	60	(0, 0, 178)	92	(111, 111, 218)	124	(239, 239, 250)	156	(226, 143, 143)	188	(194, 15, 15)	220	(218, 111, 111)	252	(250, 239, 239)
29	(0, 0, 86)	61	(0, 0, 181)	93	(115, 115, 219)	125	(243, 243, 251)	157	(225, 139, 139)	189	(193, 11, 11)	221	(219, 115, 115)	253	(251, 243, 243)
30	(0, 0, 89)	62	(0, 0, 184)	94	(119, 119, 220)	126	(247, 247, 252)	158	(224, 135, 135)	190	(192, 7, 7)	222	(220, 119, 119)	254	(252, 247, 247)
31	(0, 0, 92)	63	(0, 0, 190)	95	(123, 123, 221)	127	(255, 255, 255)	159	(223, 131, 131)	191	(190, 0, 0)	223	(221, 123, 123)	255	(255, 255, 255)



COVID-19'un Yayılmasını Önlemek için CNN ile Yüz Maskesi Tespiti

Face Mask Detection using CNN for Preventing the Spread of COVID-19

¹Alihan DEĞİRMENCİLER , ²Berat CENGİZ , ³Kadir İLERİ 

^{1,2}Karabük Üniversitesi, Mühendislik Fakültesi, Karabük, Türkiye

³Karabük Üniversitesi, Yenice Meslek Yüksekokulu, Karabük, Türkiye

¹alihandegirmenciler@gmail.com, ²brt_cngz78@icloud.com,

³kadirileri@karabuk.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 27 August 2022

Accepted : 4 October 2022

Keywords:

Deep Learning, Image Processing, Face Mask Detection, CNN

ABSTRACT

Coronaviruses were discovered in the 1960s. This virus, which is transmitted from animals to animals, has undergone various variations until today. It came to the epidemic situation when it was first detected in a human in 2019 in Wuhan, China. There is a need to wear a mask to protect against this virus, which spreads faster in indoor areas. For this reason, wearing masks in public has become mandatory in many countries. The control of this situation has become a necessity for the countries. In this study, it was determined whether people wear masks or not using artificial intelligence and image processing techniques. The developed application detects multiple people with or without mask by using Convolutional Neural Network (CNN) in a video stream.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 27 Ağustos 2022

Kabul : 4 Ekim 2022

Anahtar Kelimeler:

Derin Öğrenme, Görüntü İşleme, Yüz Maskesi Tanıma, CNN

ÖZET

Koronavirüsler 1960'lı yıllarda keşfedilmiştir. Hayvanlardan hayvanlara bulaşan bu virüs günümüze gelene kadar çeşitli varyasyonlara uğramıştır. Salgın durumuna ilk olarak, Çin'in Vuhan kentinde 2019 yılında bir insanda tespit edilmesiyle gelmiştir. Kapalı ortamlarda daha hızlı yayılan bu virüsten korunmak için maske takma ihtiyacı ortaya çıkmıştır. Bu nedenle, toplu ortamlarda maske takmak birçok ülkede zorunlu hale gelmiştir. Bu durumun denetimi ülkeler için gereklilik halini almıştır. Bu çalışmada, insanların maske takıp takmadığı yapay zeka ve görüntü işleme teknikleri kullanılarak tespit edilmiştir. Geliştirilen uygulama, Evrişimli Sinir Ağı (CNN: Convolutional Neural Network) kullanarak bir video görüntüsünde birçok kişiyi aynı anda maskeli veya maskesiz olarak tespit etmektedir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

ORCID ID: ¹0000-0002-1514-1514

²0000-0002-6906-8789

³0000-0002-5041-6165

1. GİRİŞ

Koronavirüsünün dünya genelinde yayılarak ölümlere neden olması sonucunda Dünya Sağlık Örgütü (DSÖ) tarafından pandemi ilan edilmiştir [1,2]. Birçok ülkede özellikle kapalı alanlarda maske takma zorunluluğu getirilmiştir. İnsanların maske takıp takmadığını kontrol etmek büyük bir yük oluşturmaktadır. Bu durumun bir bilgisayar yazılım yardımıyla çözülmesi iş gücü bakımından büyük bir kolaylık sağlayacaktır.

Bir yüz maskesini tespit etmek için, nesne algılama algoritmaları kullanılabilir. Bu algoritmalarından biri olan CNN, uzamsal öznitelik çıkarma yeteneği ve daha az hesaplama maliyeti nedeniyle örüntü tanıma görevlerinde önemli bir rol oynar [2]. Çok kullanışlı uygulamalarından biri, görüntülerin ikili sınıflandırmasıdır. Qin ve Li yüz maskesi takma şeklini belirlemek için bir çalışma yapmışlardır [4]. Yüz maskesi takma şeklini, doğru maske takma, yanlış maske takma ve maske yok olmak üzere üç sınıfa ayırmışlardır. Geliştirdikleri algoritma görüntüde önce yüzü tespit eder ve sonra sınıflandırmak için SRCNet kullanır. Amit ve arkadaşları hem maskeli hem de maskesiz yüzleri algılayabilen ve CCTV kameralarla uyumlu iki aşamalı CNN mimarisi kullanan bir sistem geliştirmişlerdir [5]. Bu sistemin amacı, güvenlik ihlallerinin izlenmesine, yüz maskesi kullanımının teşvik edilmesine ve güvenli bir çalışma ortamının yaratılmasına yardımcı olmaktır. Ejaz ve arkadaşları maske tespit etme sistemi geliştirmişlerdir [6]. Temel Bileşen Analizi (PCA) uygulayarak yüzleri maskeli ve maskesiz olmak üzere iki sınıfa ayırmışlardır. Eğer yüz maskeli ise tespit etme başarısı %70'lere düşmüştür. Susanto ve arkadaşları her türlü yüz maskesini tespit edebilen bir yüz maskesi dedektörünü geliştirmişlerdir [7]. Yüz maskesini tespit etmek için YOLO V4 derin öğrenme algoritmasını seçmişlerdir. Deneysel sonuçlar gerçek zamanlı uygulamada yapılmış ve cihaz Politeknik Negeri Batam üniversitesine kurulmuştur. Geliştirilen bu cihaz, yüz maskesi takan veya takmayan kişileri çeşitli pozisyonlarda hareket etseler bile doğru bir şekilde tespit etmeyi başarmıştır. Nieto-Rodríguez ve arkadaşları sağlık personelinin tıbbi maske takıp takmadığını tespit eden bir çalışma gerçekleştirmişlerdir [8]. Bu çalışmanın ana hedefi sağlık personelinin hastanede uygun bir maske takmadığı durumda uyarı oluşturmaktır.

Bu çalışmada, insanların kapalı alanlara girişte maske takma kuralına uyup uymadığını kontrol etmeyi amaçlayan CNN ile maske tanıma yazılımı geliştirilmiştir. Geliştirilen maske tanıma yazılımı için öncelikle veri seti elde edilmiştir. Bu veri setinde maskeli ve maskesiz olmak üzere iki farklı havuz oluşturulmuş ve bu havuzlardaki veriler yapay zekanın eğitim aşamasında kullanılmıştır. Bu aşamada Derin Öğrenme'den (Deep Learning) yararlanılmıştır. Derin öğrenme, bir makine öğrenmesi yöntemidir. Verilen bir veri kümesi ile çıktıları tahmin edecek bir yapay zekayı eğitmeye olanak sağlar. Yapay zekayı eğitmek için hem denetimli hem de denetimsiz öğrenme kullanılabilir.

Yapay sinir ağları giriş katmanı, ara katman ve çıktı katmanı olmak üzere üç katmandan oluşur. Derin öğrenmedeki "Derin" ifadesi birden fazla gizli katmana sahip olma anlamına gelir. Derin öğrenmedeki en zorlayıcı kısım yapay sinir ağı eğitmektir. Bunun sebepleri:

- Büyük bir veri kümesine ihtiyaç olması,
- Yüksek miktarda hesaplama gerektirmesidir [9].

Yapay zekayı eğitmek için veri kümesindeki girdiler ve çıktılar arasında karşılaştırma yapılır. Derin öğrenmeye ihtiyaç duymamızın sebebi ise oluşan verilerin çok fazla olması ve bu verilerin işlenmesinin hızlandırılması gereğidir. Gelişen teknoloji ile GPU'ların (Ekran Kartı) gücünün artması öğrenme işleminin hızlı bir şekilde yapılabilmesine olanak tanımıştır.

Sürekli olarak güncellenen ve kendini geliştiren Python, sahip olduğu kütüphaneler sayesinde görüntü işleme teknolojisinin en rahat uygulandığı kodlama dilidir. Bu sebeple, bu proje için en uygun yazılım dili olan Python programlama dili seçilmiştir. Ayrıca, görüntü işleme kütüphanesi olan OpenCV ile derin öğrenme kütüphanesi olan Keras ve Tensorflow'dan yararlanılmıştır.

Bu çalışmanın katkısı, veri seti çeşitliliği sayesinde farklı açılardan yakalanmış görüntülerdeki kişilerin maske takıp takmadıklarını tespit edebilmesi ve maskenin uygun bir şekilde takılmadığı durumu da maskesiz olarak belirleyebilmesidir.

Bu çalışma, üç bölüme ayrılmıştır. İlk bölüm giriş ve literatür taraması, ikinci bölüm materyal ve yöntem son bölüm ise sonuç kısmından oluşmaktadır.

2. METARYEL VE YÖNTEMLER


Bu bölümde Evrişimli Sinir Ağı (CNN), veri setini elde edilmesi, eğitim işlemi anlatılmıştır. Ayrıca elde edilen sonuçlar gösterilmiştir.

2.1. Evrişimli Sinir Ağları

Evrişimli Sinir Ağı (CNN), biyolojik bir terim gibi gözükse de bu mekanizma, nesne tanımda kullanılan çok etkili bir yöntemdir. Buradaki ana fikir bir görüntüdeki nesnelere tespit etmektir. İnsanoğlu nasıl bir kedi ile köpeği ayrı ayrı tespit edebiliyorsa, CNN yöntemi de nesnelere tespit etmek için geliştirilmiştir. Bu çalışmada maske tanımda kullanılmak üzere geliştirilen sistem, maskeyi ve yüzü birer obje olarak öğrenecek, ardından maskeli veya maskesiz olduğunu tespit edebilecektir.

CNN görüntüyü tek katmanda değil, birçok katman üzerinden inceler (Şekil 1). Bu katmanlar:

- Evrişimsel katman (Convolutional Layer): nitelikleri belirlemek için kullanılan katman,
- Doğrusalsızlık katmanı (Non-Linearity Layer): doğrusal olmayan parçanın sisteme tanıtıldığı katman,
- Ortaklama katmanı (Pooling Layer): havuz oluşturarak fazlalığı azaltır ve uygunluğu denetler,
- Düzleştirme katmanı (Flattening Layer): verilerin yapay sinir ağı girişi için hazırlandığı katman,
- Tam bağlantılı katman (Fully-Connected Layer): tam bağlı sinir ağıdır, son aşamadır [10-13].



Şekil 1. Evrişimli Sinir Ağı katmanları [10].

2.1.1. Evrişimsel Katman (Convolutional Layer)


Bu katman, CNN sistemin temelini oluşturur. Fotoğrafın özelliklerini algılar, düşük ve yüksek seviyedeki özellikleri ayırt etmek için bazı filtreler uygular. Buradaki her bağlantı tıpkı insan beynindeki nöronlar gibi işler. Bir bilgi önceki katmandan sonrakine iletilir. Bu şekilde verilerin sınıflandırılması gerçekleştirilmiş olur. Her ağ verileri işleyerek özellikleri öğrenmeye başlar. Bir görüntüdeki her piksel bir giriş oluşturur. Örneğin, 1920x1080 piksel boyutundaki bir görüntü 2.073.600 ağırlığa (giriş) sahiptir. Bu durum çok işlem yükü gerektirdiğinden öğrenme işlemi çok uzun sürmektedir. Bu sorun, piksel sayısı azaltılarak çözülür [10].

2.1.2. Doğrusalsızlık Katmanı (Non-Linearity Layer)

Evrişimsel katmanından sonra genellikle doğrusalsızlık katmanı gelir. Görüntülerde doğrusallık problem oluşturur. Tüm katmanlar doğrusal bir fonksiyon olabildiğinden sinir ağı bunları tek bir katman olarak algılayabilir. Bu katman aktivasyon katmanı olarak ta adlandırılır. Önceleri sigmoid ve tahn gibi doğrusal olmayan fonksiyonlar kullanılmıştır, fakat en hızlı sonuç Rectifier (ReLu) fonksiyonu ile alındığından artık bu fonksiyon kullanılmaktadır [11].

2.1.3. Ortaklama Katmanı (Pooling Layer)


Bu katman, CNN'deki ardışık ağlar arasına eklenir. Amacı, katmanlar arasındaki hesaplama yükünü azaltmaktır. Bu sayede ağlardaki uyumsuzluk da kontrol edilmiş olur. Örneğin 4x4 boyutundaki piksellerden oluşan bir görüntüde toplam 16 ağırlık vardır. Bu görüntüye 2x2 boyutunda bir filtre (katmanlardaki en büyük sayıyı alan) uygulandığında Şekil 2'deki işlem gerçekleşir [10]. Böylece 16 ağırlık 4 ağırlığa indirgenmiş olur.



Şekil 2. Ortaklama katmanı gösterimi.

2.1.4. Düzleştirme Katmanı (Flattening Layer)


Bu katmanda ise son katman için giriş verilerini hazırlamaktadır. Genel olarak, sinir ağı giriş verilerini tek boyutlu dizi şeklinde alır (Şekil 3). Burada bulunan veriler ise bir önceki katmanlardan gelen matrislerin tek boyutlu bir diziye çevrilmiş halidir [10].



Şekil 3. Düzleştirme katmanı gösterimi.

2.1.5. Tam Bağlantılı Katman (Fully-Connected Layer)

CNN'in son ve en önemli katmanıdır. Öğrenme işlemi burada son bulur. Bu katmandaki düğümlerde özellikler tutulur. Evrimsel katmanından ve ortaklama katmanından geçen ve matris halinde olan veriler düz bir vektör haline getirilir. Ortaya çıkan bu vektör sinir ağına giriş olarak verilir. Yapay sinir ağının ağırlıkları ve bias (modelin yanlılık miktarı) değeri değiştirilerek öğrenme işlemi gerçekleştirilir.



Şekil 4. Tam bağlantılı katman gösterimi.

Yapay sinir ağındaki her nöron kendinden önceki katmandan alınan verilerle bilgileri aktarır ve çıktıları hesaplar (Şekil 4). Giriş değerlerine uygulanan işlev, bir ağırlık vektörü ve bir önyargı (genellikle gerçek sayılar) ile belirlenir. Öğrenme, bu ağırlıkların ve önyargıların tekrar tekrar güncellenmesiyle meydana gelir. Önyargı ve ağırlık vektörü, filtreler olarak isimlendirilir. Bu filtreler, girdinin belirli özelliklerini ifade eder. Birçok nöronun aynı filtreyi paylaşabilmesi, CNN'lerin ayırt edici bir özelliğidir. Bu durum, bellek ayak izinin azalmasını sağlar. Çünkü her alıcı alanın kendi önyargısına ve vektör ağırlığına sahip olmasının aksine, bu filtreyi paylaşan tüm alıcı alanlarda tek bir önyargı ve tek bir ağırlık vektörü kullanılır [11-14].

2.2. Veri Seti

Bu çalışmada, gerekli olan veri havuzu maskeli ve maskesiz görüntüler olmak üzere etiketlenerek oluşturulmuştur. Bu havuz oluşturulurken; kadın, erkek ve çocuklardan oluşan kişilerin maskeli ve maskesiz fotoğrafları kullanılmıştır. Değişik açılardan yalnızca yüz kısmını alacak şekilde fotoğraflar çekilmiştir. Bu fotoğraflar hem maskeli hem maskesiz olarak çekilmiştir. Bu fotoğraf havuzundaki fotoğrafların boyutunu azaltmak için fotoğrafların boyutları 100x60 piksel olacak şekilde boyutları küçültülmüştür (Şekil 5 ve Şekil 6).



Şekil 5. Farklı açılardan maskesiz fotoğraf örnekleri.



Şekil 6. Farklı açılardan maskeli fotoğraf örnekleri.

Veri havuzu oluştururken, kişilerin maskeyi çenesinde bırakması durumuna karşı maskenin çenede olduğu durumdaki fotoğraflarda çekilerek maskesiz olarak etiketlenmiş ve veri havuzuna eklenmiştir. Buradaki amaç, maskenin tam kapalı konumda olmadığı durumlarda da geliştirilen sistemin bu kişileri maskesiz olarak algılayabilmesini sağlamaktır. Ayrıca fotoğraflar farklı konumlarda sağa ve sola çevrilerek veri havuzu genişletilmiştir (Şekil 7).




Şekil 7. Maskenin doğru takılmadığı durumlardaki fotoğraf örnekleri.

Veri havuzu oluşturulurken; maskeli 705 adet, maskesiz 998 adet fotoğraf kullanılmış ve maskenin çenede olduğu durum için de 144 adet fotoğraf kullanılmıştır. Böylece, veri havuzu toplam 1847 adet fotoğraf ile oluşturulmuştur.

2.3. Eğitim

Veri seti toplandıktan sonra maskeli ve maskesiz olarak etiketlenmiştir. Daha sonra CNN kullanarak eğitim işlemi gerçekleştirilmiştir. Eğitim için, TensorFlow üzerinde çalışan Keras derin öğrenme kütüphanesinden yararlanılmıştır. Eğitim, yapay sinir ağının ağırlıklarının güncellenmesi işlemidir. Bu güncelleme işlemi her bir eğitim adımında tekrarlanır. Bu işlem, oluşturulan model için en uygun ağırlık değerleri hesaplanana kadar devam eder. Eğitim adımlarının her biri epoch olarak adlandırılır. Epoch sayısının az olması eğitim yeterli bir şekilde yapılamamasına neden olurken gereğinden fazla olması ise aşırı öğrenmeye (overfitting) neden olur. Bu iki husus istenmeyen bir durumdur ve yapay sinir ağının doğru çalışmasına engel olur. Bu yüzden optimum epoch değerinin seçilmesi gerekmektedir. Optimum epoch değeri analiz edilmiştir. Elde edilen doğruluk (accuracy) ve kayıp (loss) değerleri Şekil 8'de gösterilmiştir. Eğitim kaybının (training loss) ve doğrulama kaybının (validation loss) 20 epoch'tan sonra artmaya başladığı gözlemlenmiştir. Bu seviyeden sonra aşırı öğrenme (overfitting) gerçekleşmemesi için epoch değeri 20 olarak belirlenmiştir.



Şekil 8. Elde edilen doğruluk ve kayıp değerleri.


2.4. Geliştirilen Sistem

Veri toplama ve ardından gerçekleştirilen eğitim işleminden sonra elde edilen yapay sinir ağı bir video kameradan alınan görüntüler üzerinde insanların maskeli olup olmadıklarını tespit etmiştir (Şekil 9).



Şekil 9. Maskeli ve maskesiz durumun tespit edildiği örnekler.

Ayrıca, geliştirilen sistem, Şekil 10'da görüldüğü gibi gerçek zamanlı olarak çoklu tespit yapabilmektedir.



Şekil 10. Aynı anda birden fazla kişinin olduğu durumdaki maske tespiti.

3. SONUÇ

Koronavirüs nedeniyle global bir salgın oluşmuştur. Bu salgın, birçok ülkede kapalı alanlarda maske takma zorunluluğu getirilmesine sebep olmuştur. Kişilerin maske takıp takmadığının kontrolü zor bir hal almıştır. Bu durumu çözmek için yapay zeka kullanan bir sistem geliştirilmiştir. Derin öğrenme kütüphanesi Kares'i destekleyen Python programlama dili kullanarak geliştirilen bu sistem için CNN algoritması tercih edilmiştir. Maskeli ve maskesiz olmak üzere toplanan veriler ile yapay sinir ağı eğitilmiştir. Sistem, gerçek zamanlı olarak kişilerin maske takıp takmadığını tespit edebilmektedir. Maskeyi doğru bir şekilde takmayan kişileri maskesiz olarak belirleyebilmektedir. Buna ek olarak, video yayınında birden fazla kişinin bulunduğu durumda da çoklu olarak kimlerin maske takıp takmadığını yakalayabilmektedir.

Gelecekteki çalışmalarda, daha fazla veri toplanıp sistemin başarısı iyileştirilebilir. Ayrıca, maske tanımanın üzerine ek olarak ateş ölçer, kimlik kartı kontrolü gibi eklemeler yapılabilir.

Yazar Katkıları

Yazarlar çalışmaya eşit oranlı katkı sunmuşlardır.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

KAYNAKÇA

- [1] Y.-H. Lin, C.-H. Liu, and Y.-C. Chiu, "Google searches for the keywords of "wash hands" predict the speed of national spread of COVID-19 outbreak among 21 countries. *Brain, Behavior, and Immunity*", 2020.
- [2] H. Özbay, and A. Dalcalı, "Effects of COVID-19 on electric energy consumption in Turkey and ANN-based short-term forecasting", *Turkish Journal of Electrical Engineering and Computer Sciences*, vol. 29, no. 1, pp. 78-97, 2020.
- [3] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database", *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 248-255, 2009.
- [4] B. Qin, and D. Li, "Identifying facemask-wearing condition using image super-resolution with classification network to prevent COVID-19", *Sensors (Basel)*, vol. 20, no. 18, p. 5236, 2020.
- [5] A. Chavda, J. Dsouza, and S. Badgujar, "Multi-Stage CNN Architecture for Face Mask Detection", 6th International Conference for Convergence in Technology (I2CT) Pune, 2021.
- [6] M. S. Ejaz, M. R. Islam, M. Sifatullah, and A. Sarker, "Implementation of principal component analysis on masked and non-masked face recognition", 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT), pp. 1-5, 2019.
- [7] S. Susanto, F. A. Putra, R. Analia, and I. K. L. Nur, "The Face Mask Detection For Preventing the Spread of COVID-19 at Politeknik Negeri Batam", 2020 3rd International Conference on Applied Engineering (ICAE), Batam, Indonesia, 2020.
- [8] A. Nieto-Rodríguez, M. Mucientes, and V. M. Brea, "System for Medical Mask Detection in the Operating Room Through Facial Attributes", In: Paredes R., Cardoso J., Pardo X. (eds) *Pattern Recognition and Image Analysis*. IbPRIA 2015. *Lecture Notes in Computer Science*, vol. 9117, 2015.
- [9] N. Y. Şimsek, "Derin Öğrenme (Deep Learning) Nedir ve Nasıl Çalışır?", <https://nyilmazsimsek.medium.com/derin-ogrenme-deep-learning-nedir-ve-nasil-calisir-2d7f5850782> (Erişim Tarihi: 9 Temmuz 2022).
- [10] T. Ergin, "Convolutional Neural Network (ConvNet yada CNN) nedir, nasıl çalışır?", <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad> (Erişim Tarihi: 18 Temmuz 2022).
- [11] S. Albawi, T. A. Mohammed and S. Al-Zawi, "Understanding of a convolutional neural network", 2017 International Conference on Engineering and Technology (ICET), pp. 1-6, 2017.
- [12] A. Ajit, K. Acharya, and A. Samanta, "A Review of Convolutional Neural Networks", 2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE), pp. 1-5, 2020.
- [13] N. Aloysius, and M. Geetha, "A review on deep convolutional neural networks", 2017 International Conference on Communication and Signal Processing (ICCSP), pp. 0588-0592, 2017.
- [14] Fukushima, K., "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position", *Biol. Cybernetics*, pp. 193-202, 1980.



Kenevirden İmal Edilen Geotekstilin Sıkıştırılmış Zeminlerin Dayanımı Üzerindeki Etkisi

The Effect of Geotextile Made of Hemp on the Strength of Compacted Soils

¹Erdem DEMİR , ²Ersin KOLAY , ³Yekta KARADUMAN 

¹Yozgat Bozok Üniversitesi Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yozgat, Türkiye

²Yozgat Bozok Üniversitesi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Yozgat, Türkiye

³Yozgat Bozok Üniversitesi Üniversitesi, Kenevir Araştırma Enstitüsü, Yozgat, Türkiye

¹erdem7229@gmail.com, ²ersin.kolay@yobu.edu.tr,

³yekta.karaduman@yobu.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 29 August 2022

Accepted : 3 October 2022

Keywords:

Compacted Soil, Geotextile, Hemp, Soil Improvement

ABSTRACT

In this study, it was investigated whether geotextile obtained from hemp will have an effect on the engineering properties of the improved soil. Five different soil types (SC, SM, ML, MH and CH) were used in the study. Hemp rope was supplied and geotextile was produced by knitting method. Classification tests of soils, Proctor tests for compression conditions and strength tests were carried out respectively. Unreinforced, one and two hemp reinforced soil samples were tested by unconfined compression and triaxial compression tests. The unconfined compressive strength, cohesion and internal friction angle values of the samples were comparatively examined according to the reinforcement situation. The results obtained from the unconfined and triaxial compression tests show that geotextile made from hemp can be used to increase the strength of compacted soils.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 29 Ağustos 2022

Kabul : 3 Ekim 2022

Anahtar Kelimeler:

Sıkıştırılmış Zemin, Geotekstil, Kenevir, Zemin İyileştirme

ÖZET

Bu çalışmada kenevirden elde edilen geotekstilin iyileştirilmiş zeminin mühendislik özellikleri üzerinde etkisinin olup olmayacağı araştırılmıştır. Çalışmada beş farklı zemin tipi (SC, SM, ML, MH ve CH) kullanılmıştır. Kenevir ip temin edilmiş ve örme yöntemiyle geotekstil elde edilmiştir. Önce zeminlerin sınıflandırma deneyleri, sonra sıkışma koşulları için Proctor deneyleri ve daha sonra dayanım deneyleri yapılmıştır. Donatısız, bir ve iki kenevir donatılı olarak sıkıştırılmış zemin örnekleri serbest basınç ve üç eksenli basınç deneyleriyle test edilmiştir. Örneklerin serbest basınç dayanımları, kohezyon ve içsel sürtünme açısı değerleri donatı durumuna göre karşılaştırmalı olarak incelenmiştir. Serbest ve üç eksenli basınç deneylerinden elde edilen sonuçlar, kenevirden üretilmiş geotekstilin sıkıştırılmış zeminlerin dayanımını artırmak amacıyla kullanılabileceğini göstermektedir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

ORCID ID: ¹0000-0003-0119-9819

²0000-0002-7118-5722

³0000-0001-6960-3828

1. GİRİŞ

Dünya üzerinde insan nüfusunun ve ihtiyaçlarının artması mühendislik özellikleri uygun yapı alanlarının azalmasına ve yetersiz kalmasına neden olmuştur. Bu nedenle mühendislik özellikleri zayıf alanların da yapı alanı olarak değerlendirilmesini gündeme getirmiştir. Zeminler doğal halde ya da bir yerden alınıp diğer bir yerde dolgu olarak yapı temellerinin altında taşıyıcı seviyeler olarak karşımıza çıkabilmektedir. Böylece zeminlerin iyileştirmesi hemen her yapıda karşımıza çıkabilmektedir [1]. Zeminler baraj gövdesi ve yol inşaatı gibi projelerde doğal yapı malzemesi olarak kullanılmaktadır. Zeminlerin mühendislik özellikleri her zaman istenilen düzeyde olmayabilmektedir. Bu gibi durumlarda zeminlerin özelliklerinin iyileştirilmesi yoluna gidilmektedir [2]. Mühendislik projesinin beklentileri de göz önünde bulundurularak, zeminin dayanımının artırılması, geçirimsizliğinin azaltılması, boşluk suyu basıncının azaltılması ve sıvılaşmanın önlenmesi gibi hedefler için çalışmalar yapılmaktadır. Zemin iyileştirme çalışmaları amaçlar doğrultusunda geçici ya da kalıcı olarak yapılabilmektedir [1]. Bu çalışmalar genel olarak küçük alanları kapsamakta ve her iyileştirme çalışmasının farklı özellikleri olabilmektedir.

Zemin iyileştirmeleri için pek çok yöntem geliştirilmiş olup; iyileştirme yüzeysel ve derin olarak gerçekleştirilebilir. Yüzeysel zemin iyileştirme yöntemleri arasında; kompaksiyon, zemin drenajı, kireç, kül ve bitüm karıştırarak iyileştirme sayılabilir. Ön yükleme, düşey drenler, taş kolonlar, ısıtma-dondurma, dinamik kompaksiyon, enjeksiyon ve patlama ise derin zemin iyileştirme metodları arasındadır. Zayıf zeminlerin güçlendirilmesindeki ana kurallar; zemin taneleri arasındaki boşlukların azaltılması, boşlukların farklı maddelerle doldurulması, zemindeki su içeriğini azaltılması ya da boşluk suyu basıncının düşürülmesi ve farklı amaçlar için donatılar kullanılarak zeminin dayanımının artırılmasıdır [3].

Zemin iyileştirilme yöntemlerinden birisi de çeşitli elemanların kullanılmasıyla zeminin güçlendirilmesidir. Zeminlerde donatı olarak kullanılan sentetik tekstil ürünleri (geosentetikler) birçok inşaat mühendisliği projesinde değişik amaçlarla kullanılmaktadır. Geosentetik terimi “geo” ve “sentetik” kelimelerinin birleşmesinden oluşmaktadır. “Geo” ürünlerin çoğunlukla geoteknik projelerde kullanılmasından, “Sentetik” ise bu ürünlerin çoğunlukla insan yapımı yani sentetik olmasından gelmektedir. Başlıca geosentetik türleri; geogridler, geotekstilller, geomembranlar ve geokompozitler olarak sınıflandırılabilir [4]. Geotekstilller son yıllarda yol inşaatları, drenaj işleri ve şev iyileştirme gibi mühendislik projelerinde yaygın olarak kullanılan inşaat malzemeleridir [5]. Geotekstilller inşaat projelerinde destek ve ayırıcı, donatı, erozyon kontrolü ve drenaj amacıyla kullanılmaktadır. Geotekstilller zeminin dayanımını arttırmak için kullanılan sentetik-polimer bazlı malzemeler olarak tanımlanmaktadır. Esnek, ince ve geçirgen yapılarından kaynaklanan çekme dayanımı nedeniyle, belirli deformasyon altında iyileştirici olarak kullanılmaktadır [4]. Aksoy [6] örgülü geotekstillerin, zeminin yük taşıma kapasitesinin arttırmak, alt temel tabakasının kalınlığının sınırlandırılmak ve zemin ile alt temel tabakasının ayrılması sağlamak amacıyla kullanıldığını belirtmektedir. Günümüzde kullanılan geotekstilller polyester ve polipropilen hammaddelerinden üretilmekte olup, ya hammadde ya da son ürün olarak ithalat yoluyla temin edilmektedir. Bunun yanında bitki, hayvan ve mineral kökenli doğal malzemelerden de üretilmektedirler [7]. Hint keneviri, Hindistan cevizi, keten ve kenevir lifleri doğal geotekstil üretiminde kullanılan malzemelerdir. Doğal geotekstilller biyolojik olarak parçalanabilir özelliktedir. Bu nedenle kısa süreli mühendislik projelerinde kullanılabilir. Dahası, geotekstillerde doğal liflerin kullanılmasının temel nedeni düşük maliyet, sağlamlık, dayanıklılık, bulunabilirlik, iyi örülebilme ve çevre dostu olmalarıdır. Birçok araştırmacı donatılı zeminlerin davranışlarını belirlemek üzere geçmişten günümüze araştırmalar yapmışlardır. Binquet ve Lee [8] kumlu zeminlerde yaptığı çalışma sonucunda, az miktarda takviye kullanılmasıyla hem oturma hem de nihai taşıma kapasitesi açısından önemli faydalar elde edilebileceğini göstermiştir. Das vd. [9] yol alt zemininin dayanımı yetersiz olduğunda, inşaat sırasında daha yüksek dayanımlı jeotekstillerin takviye malzemesi olarak kullanılabileceğini belirtmektedir. Çiçek vd. [10] geotekstil donatılı kum zeminlerde donatı sayısı arttıkça oturma azaldığını belirtmektedir. Tan vd. [11] zemin-geotekstil ile hazırlanan örneklerin direkt kesme deneyinde halka kesme deneyine göre daha yüksek içsel sürtünme açısı verdiğini belirtmiştir. Haeri vd. [12] kuru sahil kumlarının geotekstil ile donatılması sonucunda maksimum dayanımda ve kırılma açısında artış olduğunu belirtmektedir. Akyüz [13] geosentetikle güçlendirilmiş istinat duvarlarında güçlendirme uzunluklarının kısaltılabileceğini belirtmektedir. Noorzad ve Mirmoradi [14] kil zeminlerde geotekstil donatı sayısı arttıkça dayanımın arttığını belirtmektedir.

Kenevir lifleri oldukça sağlam yapıda olduğundan, endüstride ip, halat, ağ, çadır bezi vb. malzemelerin üretiminde kullanılmaktadır. Kenevir bitkisi Orta Asya kökenli olup, günümüzde Fransa, Çin, İsrail ve Amerika Birleşik Devletleri kenevir üretiminde önde gelen ülkelerdir [15]. 100 kilogram kenevir sapından (Şekil 1), değişkenlik göstermekle birlikte, 18-25 kilogram kadar kenevir lifi sağlanabilmektedir. Kenevir eskiden beri tekstil üretimi için önemli olmuştur (Şekil 1). 20 yüzyılın başına kadar dünyada üretilen tekstil ürünlerinin %80'inin hammaddesi kenevir lifidir. 1930'lu yıllardan sonra uyuşturucu karşıtı yasalar nedeniyle kenevir tarımı kısıtlanmış, ayrıca geliştirilen sentetik liflerle beraber kenevir tekstiller önemini kaybetmiştir [16]. Kenevir sapı son derece iyi bir biyokütle kaynağı olup, enerji açısından ithalatçı durumda olan ülkemiz için bu durum büyük önem taşımaktadır [17]. Son yıllarda kenevir bitkisinin sanayide üretilen birçok ürün için hammadde olarak kullanılması gündemdedir. Ülkemizde de 19 ilimizde, Tarım ve Orman Bakanlığı'nın iznine bağlı olarak onay verilen arazilerde kenevir ekimine başlanacaktır [18].

Toprak dolgu gövdeli baraj, gölet ve batardo inşası, karayolu altyapısı inşası ve zemin iyileştirme çalışmaları gibi mühendislik işlerinde zeminler sıkıştırılarak mühendislik özelliklerinin iyileştirilmesi sağlanmaktadır. Bu çalışmada sıkıştırılmış zeminlerin dayanımını artırmak amacıyla kenevir liflerinden üretilen örgülü geotekstil kullanılmış ve yöntemin etkinliği serbest basınç ve üç eksenli basınç deneyleri ile incelenmiştir. Geotekstil imalatında kenevir liflerinin de kullanılabilirliğinin ortaya konulmasıyla, daha ekonomik ve sürdürülebilir bir hammaddeye dikkat çekmek hedeflenmiştir.



Şekil 1. Kenevir sapsarı (a,b) ve kenevir liflerinden üretilmiş kumaş (c) [18].

2. MATERYAL VE YÖNTEM

2.1. Materyal

Çalışmada iri ve ince taneli beş farklı zemin örneği ile kenevir ipten örülmüş geotekstil kumaş kullanılmıştır. Zemin örnekleri Yozgat ve yakın çevresindeki beş farklı lokasyondan temin edilmiştir (Şekil 2a).


2.2. Yöntem

Örnekler 4.75mm açıklığa sahip 4 nolu elekten elenerek, her birinden 10'ar kilogram olacak şekilde hazırlanmıştır (Şekil 2b). Laboratuara getirilen örnekler dörde bölünerek çeyrekleme yöntemiyle deneylerde kullanılacak miktara indirgenmiştir (Şekil 2c). Bu örneklerle TS 1900-1 [19] ve TS 1900-2 [20]'ye göre deneyler gerçekleştirilmiştir.



Şekil 2. Deney örneklerinin araziden alınması (a), 4 nolu elekten elenmesi (b) ve çeyrekleme yöntemiyle azaltılması (c).

Çalışmada kullanılmak için çözgü ve atkı ipliği olarak, iplik numarası Nm 10 olan ağartılmış kenevir ipliği temin edilmiştir. 1mm'lik iplik kalınlığını elde edebilmek için, iplikler 5 kat olacak şekilde hafif büküm verilerek katlama işlemine tabi tutulmuştur. Katlama işlemi sonrasında nihai iplik numarası Nm 2 olmuştur. Daha sonra atkı ve çözgü iplik numarası Nm 2/5 olan iplik ile kenevir esaslı dokuma kumaş üretilmiştir. Dokuma kumaşlar, bezayağı (1/1) örgü kullanılarak, Yozgat Bozok Üniversitesi Kenevir Araştırmaları Enstitüsü bünyesinde bulunan sekiz çerçeveli armürlü numune dokuma tezgâhında üretilmiştir (Şekil 3a). Tez çalışması kapsamında kullanılan kenevir kumaşın atkı sıklığı 3 adet/cm, çözgü sıklığı 5 adet/cm'dir (Şekil 3b).



Şekil 3. Kenevir iplerin örgü makinesine yerleştirilmesi (a) ve örgü makinesinde örülen kenevir kumaş (Geotekstil) (b).

Serbest basınç ve üç eksenli basınç deneyleri için sıkıştırılarak hazırlanan örneklerin içine yerleştirmek üzere kenevir geotekstilden 49 mm çapında dairesel parçalar kesilmiştir (Şekil 4). Bu parçalar deney örneklerinin hazırlanması esnasında, bir donatılı sıkıştırmada örneğin ortasına, iki donatılı sıkıştırmada ise örnek yüksekliğinin 1/3 ve 2/3' ü seviyelerine yerleştirilmiştir (Şekil 5).




Şekil 4. Kenevir geotekstilden makas yardımıyla (a) 49 mm çapında hazırlanan kenevir geotekstilleri (b).

3. BULGULAR

3.1. Kenevir Geotekstilin Özellikleri

Kenevir geotekstilin bazı fiziksel ve mekanik özellikleri DSİ laboratuvarında test ettirilmiştir. Sonuçlar Tablo 1'de verilmiştir. Tablo incelendiğinde çalışmada kullanılan kenevir geotekstilin özelliklerinin genel olarak Devlet Su İşleri (DSİ) Geotekstil Şartnamesinin [21] sınır değerlerini sağladığı görülmektedir. Mühendislik uygulamalarında kullanılan geotekstillerin kalınlığı projenin gereksinimlerine göre 0.2 ile 10 mm arasında olabilmektedir [22]. Bu çalışmada 1mm kalınlığındaki kenevir ipin örgüde kullanılmasıyla yaklaşık 1.5 mm kalınlığında kenevir kumaş geotekstil olarak üretilmiştir. Üretim sırasında ip kalınlığı, örgü açıklığı ve örgü yöntemi gibi parametrelerin değiştirilmesiyle kenevir geotekstilin özelliklerini iyileştirme imkanı da bulunmaktadır.



Şekil 5. Serbest basınç deneyi için hazırlanan donatısız (a), bir donatılı (b) ve iki donatılı (c) silindirik örnekler.

Tablo 1. Kenevir geotekstilin bazı fiziksel ve mekanik özellikleri ve 500 g/m² birim alan kütlelerine sahip geotekstil için DSİ şartnamesi.

Deney adı	Standart	Sonuç	DSİ Şartnamesi (500g/m ² için)
2 kPa yük altında kalınlık	TS EN ISO 9863-1, Prosedür-A	1.53 mm	-
20 kPa yük altında kalınlık	TS EN ISO 9863-1, Prosedür-A	1.46 mm	-
Birim alan kütlesi	TS EN ISO 9864	490 g/m ²	500 g/m ²
Maksimum Yükteki Çekme Dayanımı (Boy)		37.59 kN/m	25 kN/m (En az)
Maksimum Yükteki Çekme Dayanımı (En)	TS EN ISO 10319	39.20 kN/m	25 kN/m (En az)
Maksimum Yükteki Uzama (Boy)		% 13.8	% 50 (En az)
Maksimum Yükteki Uzama (En)		% 6.5	% 50 (En az)
Dinamik delinme direnci (Delik çapı)	TS EN ISO 13433	7.67 mm	8 mm (En fazla)
Statik delinme kuvveti (CBR deneyi)	TS EN ISO 12236	4.22 kN	5.2 kN


3.2. Zemin Sınıflandırma Deneyi Bulguları

Çalışmadaki zeminler birleşik zemin sınıflandırma yöntemine sınıflandırılmıştır. Bu kapsamda zeminlerin iri taneli kısımlarında tane boyu dağılımları ıslak ve kuru elek analizleri ile belirlenmiştir. Z1, Z2, Z3, Z4 ve Z5 grubu zeminlere ait kümülatif tane boyu dağılım eğrileri Şekil 6'da görülmektedir.

Z1 örneğinin ince taneli kısmı ile kıvam limitleri deneyleri gerçekleştirilememiştir. Dolayısı ile bu zemin plastik olmayan (non-plastik) zemin olarak değerlendirilmiş ve simgesi M (silt) olarak belirlenmiştir. Zeminlerin ince taneli kısımlarına ait kıvam limitleri ve birleşik zemin sınıflandırmasına göre simgeleri Tablo 2'de verilmiştir. Buna göre çalışmanın materyali iki adet iri taneli zemin (Z1 ve Z2) ile üç adet ince taneli (Z3, Z4 ve Z5) zeminden oluşmaktadır. Birleşik zemin sınıflamasına göre Z1 örneği SM (Siltli kum), Z2 örneği SC (Killi kum), Z3 örneği ML (Düşük plastisiteli silt), Z4 örneği MH (Yüksek plastisiteli silt) ve Z5 örneği CH (Yüksek plastisiteli kil) sınıfındadır.

Tablo 2. Zeminlerin kıvam limitleri ve birleşik zemin sınıflandırmasına göre zemin sınıfları.

Örnek	LL (%)	PL (%)	PI (%)	İnce Tane Sınıfı	Zemin Sınıfı
Z1	-	-	-	M	SM
Z2	60	29	31	CH	SC
Z3	35	25	10	ML	ML
Z4	66	45	21	MH	MH
Z5	61.5	29.5	32	CH	CH




Şekil 6. Çalışmada kullanılan beş zeminin kümülatif tane boyu dağılım eğrileri.

3.3. Sıkıştırma (Standart Proctor) Deneyi Bulguları

Serbest basınç ve üç eksenli basınç deneyine tabi tutulacak örneklerin en iyi sıkıştırma koşullarını belirlemek için standart Proctor deneyleri yapılmıştır. Her örnek için farklı su içeriğinde en az dört sıkıştırma yapılmış ve kompaksiyon eğrileri çizilmiştir (Şekil 7). Kompaksiyon deneyi ile belirlenen optimum su içerikleri (w_{opt}) ve maksimum kuru yoğunlukları ($\rho_{d(max)}$) Tablo 4.3'te verilmiştir.

Tablo 3. Zeminlerin optimum su içerikleri (w_{opt}) ve maksimum kuru yoğunlukları ($\rho_{d(max)}$).

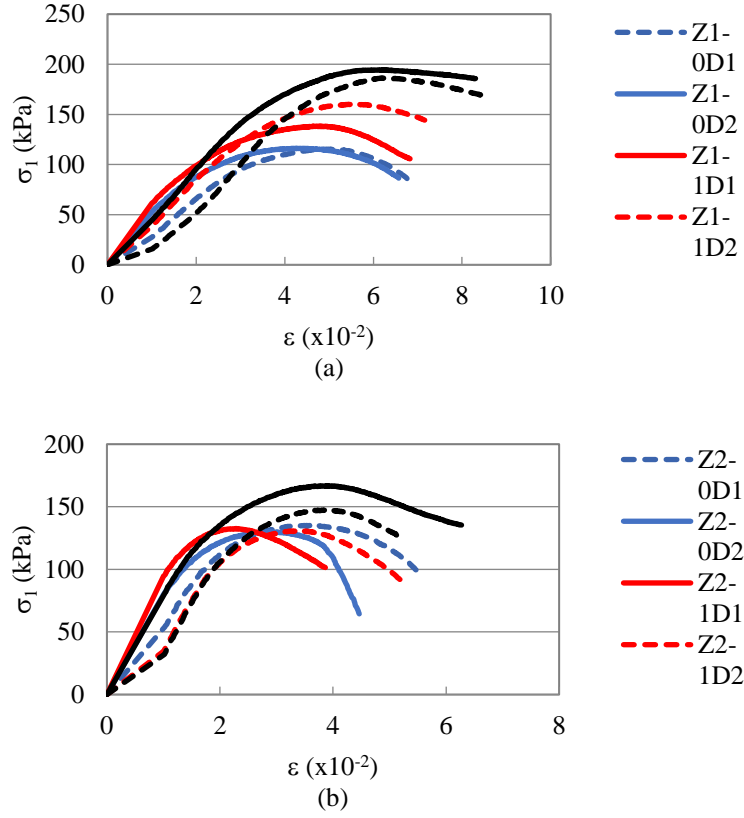
Zemin	w_{opt} (%)	$\rho_{d(max)}$ (g/cm ³)
Z1	17.5	1.73
Z2	17.5	1.72
Z3	15	1.82
Z4	28	1.42
Z5	25.5	1.48



Şekil 7. Zeminlerin kompaksiyon eğrileri.

3.4. Serbest Basınç Deneyi Bulguları

Çalışmanın amacı doğrultusunda her zemin grubunda donatısız (0D), bir kenevir donatılı (1D) ve iki kenevir donatılı (2D) sıkıştırılmış örneklerin serbest basınç dayanımı deneyleri yapılmıştır. Şekil 8'de iri taneli, Şekil 9'da ise ince taneli zeminlerin gerilme-şekil değiştirme (σ - ϵ) grafikleri verilmiştir. Çalışmada her örnek grubu için tüm donatı koşullarında ikişer örnek test edilmiştir. Grafiklerdeki Z2-0D1 şeklindeki gösterim, Z2 zemininde donatısız (0) birinci (1) örneği ifade etmektedir.




Şekil 8. İri taneli Z1 (a) ve Z2 (b) örneklerinin serbest basınç deneyinde elde edilen σ - ε grafikleri.

Donatı durumuna göre örneklerin, serbest basınç dayanımları (σ_1), yenilme anındaki deformasyon oranı (ε), ve dayanımda meydana gelen değişimler iri taneli zeminler için Tablo 4'te, ince taneli zeminleri için Tablo 5'te özetlenmiştir.

İri ve ince taneli zeminlerin donatısız ve donatılı örneklerinin yenilme sonrasındaki durumları Şekil 10 ve 11'de verilmiştir.

Tablo 4. İri taneli zeminlere (Z1, Z2) ait örneklerin serbest basınç deneyi bulguları.

Örnek	ε ($\Delta L/L$)	σ_1 (kPa)	Ortalama (kPa)	Değişim (%)
Z1-0D1	0.05	115.4	115.85	-
Z1-0D2	0.043	116.3		
Z1-1D1	0.048	138.4	149.4	28.96
Z1-1D2	0.055	160.4		
Z1-2D1	0.063	194.6	190.5	39.19
Z1-2D2	0.062	186.4		
Z2-0D1	0.035	135.2	132.65	-
Z2-0D2	0.029	130.1		
Z2-1D1	0.023	132.7	131.8	-0.64
Z2-1D2	0.033	130.9		
Z2-2D1	0.039	167	157.25	15.64
Z2-2D2	0.039	147.5		




Şekil 9. İnce taneli Z3 (a), Z4 (b) ve Z5 (c) örneklerinin serbest basınç deneyinde elde edilen σ - ε grafikleri.

Şekil 8-9 ve Tablo 4-5 incelendiğinde, özellikle iki kenevir donatı kullanıldığında zeminin serbest basınç dayanımının önemli ölçüde arttığı görülmektedir.

3.5. Üç Eksenli Basınç Deneyi Bulguları

Sıkıştırılmış zeminlerde kenevir dolgunun kullanılmasının zemin makaslama dayanımı üzerindeki etkisi hızlı üç eksenli deney (UU) ile incelenmiştir. Deney örnekleri serbest basınç deneyinde olduğu gibi optimum sıkıştırma koşullarında donatısız, bir donatılı ve iki donatılı olacak şekilde hazırlanmış ve 0 kPa, 25 kPa ve 40 kPa'lık çevre basınçlarına (σ_3) karşılık zemini kırarak en büyük asal gerilme (σ_1) belirlenmiştir. Zemin gruplarında donatılı ve donatısız olarak hazırlanmış sıkıştırılmış örneklerin üç eksenli basınç (UU) deneyinden elde edilen c ve ϕ değerleri ile kenevir donatı ile sıkıştırılmış örneklerin sonuçlarının donatısız örneklerin sonuçlarına göre değişimleri Tablo 6'da özetlenmiştir.




(a)

(b)

(c)

Şekil 10. İri taneli (SM) zeminde donatısız (a), bir donatılı (b) ve iki donatılı (c) durumlarda yenilme sonrasında gelişen yenilme düzlemleri.



(a)

(b)

(c)

Şekil 11. İnce taneli (ML) zeminde donatısız (a), bir donatılı (b) ve iki donatılı (c) durumlarda yenilme sonrasında gelişen yenilme düzlemleri.

Tablo 5. İnce taneli zeminlere (Z3, Z4, Z5) ait örneklerin serbest basınç deneyi bulguları.

Örnek	ε ($\Delta L/L$)	σ_1 (kPa)	Ortalama (kPa)	Değişim (%)
Z3-0D1	0.052	126.2	129.5	-
Z3-0D2	0.043	132.8		
Z3-1D1	0.072	156.5	160.5	23.94
Z3-1D2	0.071	164.5		
Z3-2D1	0.106	188.8	192	32.55
Z3-2D2	0.09	195.2		
Z4-0D1	0.065	69.9	75	-
Z4-0D2	0.061	80.1		
Z4-1D1	0.069	86.8	86.9	15.87
Z4-1D2	0.063	87		
Z4-2D1	0.085	102.5	101.8	26.33
Z4-2D2	0.098	101.1		
Z5-0D1	0.073	62.3	68.35	-
Z5-0D2	0.06	74.4		
Z5-1D1	0.05	68.5	73.45	7.46
Z5-1D2	0.06	78.4		
Z5-2D1	0.049	77.5	79.8	14.35
Z5-2D2	0.052	82.1		

Tablo 6. Üç eksenli basınç deneyi bulgularının özeti.

Zemin	Donatı	c (kPa)	c değişim (%)	ϕ (°)	ϕ değişim (%)
Z1	0D	40	0	29.7	0
	1D	40	0	33.5	13
	2D	40	0	42.2	42
Z2	0D	40	0	23	0
	1D	40	0	28.9	27
	2D	40	0	36.6	39
Z3	0D	30	0	40.2	0
	1D	40	33	38.7	-4
	2D	30	0	50	24
Z4	0D	27	0	20.6	0
	1D	25	-8	27.5	33
	2D	25	-8	34.2	66
Z5	0D	23	0	29.3	0
	1D	23	0	21.2	-28
	2D	28	22	16.2	-45

Üç eksenli basınç deneyi sonuçlarına göre (Tablo 6), CH sınıfı zemin hariç, sıkıştırma işlemleri sırasında zemin içerisine kenevir geotekstil yerleştirildiğinde genel olarak kohezyon değerlerinde bir değişim olmadığı ancak içsel sürtünme açılarında kayda değer artışlar olduğu anlaşılmaktadır. Noorzad ve Mirmoradi [14] CL ve CH sınıfı zeminlerle yaptığı çalışmada, geotekstil kullanıldığında sıkıştırılmış zeminin serbest basınç dayanımlarında önemli artışlar elde ederken, kohezyon ve içsel sürtünme açılarında kayda değer bir değişim olmadığını belirtmektedir. Bu çalışmada CH sınıfı zeminden elde edilen bulguların Noorzad ve Mirmorad [14] ile uyumlu olduğu görülmektedir. Çakar [23] çalışmasında farklı geotekstil tipleri kullanarak killi zeminlerin serbest basınç dayanımlarındaki değişimleri incelemiştir. Çalışmasında yükleme hızından ziyade, bu çalışmada olduğu gibi donatı sayısı arttıkça zeminlerin gerilme-şekil değiştirme özelliklerinin iyileştiğini belirlemiştir.

4. TARTIŞMALAR VE SONUÇLAR

Çalışmada kullanılan zeminler birleşik zemin sınıflama sistemine göre SM (Siltli kum), SC (Killi kum), ML (Düşük plastisiteli silt), MH (Yüksek plastisiteli silt) ve CH (Yüksek plastisiteli kil) sınıfındadır. Zeminlerin en iyi sıkışma koşullarını tanımlayan maksimum kuru yoğunluk (g/cm^3) ve optimum su içerikleri (%) zemin sırasına göre sırasıyla; Z1:1.73-17.5; Z2: 1.72-17.5; Z3: 1.82-15; Z4: 1.42-28; Z5: 1.48-25.5 olarak bulunmuştur.

Serbest basınç deneyinde yenilmeye uğrayan örnekler incelendiğinde, kenevir donatı kullanılmadığı durumda örneklerin yenilme yüzeyi yaklaşık 45° ile örneğin yüksekliği boyunca oluşurken, kenevir donatı kullanıldığı durumlarda yenilme yüzeyi dikleştiği ve örneğin belirli bölgesinde sınırlı kaldığı görülmüştür.

Bir kenevir donatı kullanıldığı durumlarda serbest basınç dayanımları Z2 örneği hariç (değişim olmamış) diğerlerinde %7.46 ile %28.46 oranında artmıştır. En az artış Z5 (CH), en çok artış ise Z1 (SM) grubunda olmuştur. İki kenevir donatı kullanılması durumunda tüm zemin gruplarının serbest basınç dayanımlarında artış gerçekleşmiştir. Artış oranı %14.35 ile %39.19 arasındadır.

Konsolidasyonsuz-drenajsız (UU) üç eksenli basınç deneyi sonuçlarına göre, Z5 (CH) grubu zemin örneklerinde kenevir donatı kullanılmasıyla kayma dayanımı parametreleri arasında anlamlı bir ilişki gözlenmemiştir. Z1 ve Z2 gruplarında donatı kullanıldığında kohezyon değişmemiş ancak içsel sürtünme açısında bir donatılı durumda sırasıyla %13 ve %27, iki donatılı durumda ise sırasıyla %42 ve %39 artış olmuştur. Z3 grubunda bir donatılı durumda kohezyonda (%33), iki donatılı durumda ise içsel sürtünme açısında (%24) artış olmuştur. Z4 grubu örneklerde bir ve iki donatılı durumda kohezyonda çok az bir azalma gözlenirken (%-8) içsel sürtünme açısı önemli ölçüde artmıştır (sırasıyla %33, %66). Genel olarak sıkıştırılan örneklerde kenevir donatı kullanımının daha çok zeminin içsel sürtünme açısı üzerinde etkili olduğu söylenebilir.

Bu çalışmadaki kenevirden üretilmiş geotekstil ile yapılan iyileştirme çalışmalarına ait sonuçların, literatürdeki sentetik geotekstillere gerçekleştirilen çalışmaların [8-14, 23] sonuçlarına benzer olduğu görülmektedir. Sonuç olarak, serbest basınç ve üç eksenli basınç deneyi verilerine göre, sıkıştırılacak SM, SC, ML ve MH sınıfı zeminlerde kenevir donatı kullanımının zemin dayanımı üzerinde olumlu yönde önemli bir etkisi olduğu söylenebilir. Ancak zemin türünün sonuçlar üzerinde etkili olduğu görülmektedir.

5. ÖNERİLER

En iyi iyileştirme koşulunu belirlemek amacıyla, dolguda kullanılacak kenevir geotekstiller arasındaki mesafe ve katman sayısı gibi parametreler göz önüne alınarak benzer çalışmaların devam ettirilmesi gerekmektedir.

Performans ve maliyet durumu göz önünde tutularak farklı örgü açıklığında ve ip kalınlığında üretilcek kenevir geotekstiller ile deneysel çalışmalar devam ettirilmelidir.

Özellikle iri taneli zeminlerde sıkıştırma işlemleri sırasında kenevir geotekstilin zarar görmesi muhtemeldir. Bu durumda kenevir geotekstilin altında ve üstünde koruyucu ekipman kullanılması gerekebilir.

Kenevirden imal edilmiş tekstilin sahip olduğu teknik özellikler göz önüne alındığında, petrol ürünlerinden üretilen geotekstiller yerine zemin iyileştirmede kullanılabilme potansiyelinin olduğu söylenebilir. Bunun yanında, kenevir donatının atmosferik şartlara dayanımı ve bulunduğu koşullar altında zaman içindeki deformasyon özelliklerinin belirlenmesinin mühendislik yapısının ömrü açısından önem arz ettiği göz ardı edilmemelidir.

Yazar Katkıları

Erdem Demir %40, Ersin Kolay %40, Yekta Karaduman %20.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler



Teşekkür

Bu çalışma Yozgat Bozok Üniversitesi Proje Koordinasyon Uygulama ve Araştırma Merkezince FYL-2021-910 proje kodu ile desteklenmiştir. Yazarlar makalenin iyileştirilmesine katkı koyan hakemlere teşekkür eder.

KAYNAKÇA

- | | |
|---|--|
| [1] M. Şahan "Yapım İşlerinde Zemin İyileştirme Yöntemleri", Uzmanlık Tezi, İller Bankası Anonim Şirketi, Ankara, 2016. | [3] A. Sağlamer "Zemin Islah Metotları", Dolgu Barajlar Yönünden Zemin Mekaniği Semineri, Devlet Su İşleri Genel Müdürlüğü, Adana, 1985. |
| [2] A. Demiröz, ve M. Karaduman "Zemin iyileştirme metodları", Selçuk Teknik Dergisi, vol. 8 no. 3, pp. 176-192, 2009. | [4] E. İ. Töremiş, E. İ. "Geotekstiller ve Plaxis Sonlu Elemanlar Programı" Yüksek Lisans Tezi, İTÜ, 98s, 2003. |

- [5] E. Toğrol, E. Güler, ve E. Merdin “Zemin Mekanik Uygulamalarında Geotekstillerin Kullanılması”, TMOB İnşaat Mühendisleri Odası, Türkiye İnşaat Mühendisliği 8. Teknik Kongresi, 1985.
- [6] İ. M. Aksoy “Modern yol inşaatında geotekstil ve geogrid uygulaması konularında araştırma”. Yüksek Lisans Tezi, İTÜ, 1993.
- [7] S. C. Das, D. Paul, M. M. Fahad, T. Islam, and E. H. Nizam “Geotextiles A Potential Technical Textile Product”, Journal of Scientific and Engineering Research, vol. 4, no. 10, pp. 337-350, 2017.
- [8] J. Binquet, and K .L. Lee “Bearing capacity tests on reinforced earth slabs”, Journal of Geotechnical Engineering Division, ASCE, vol. 101, pp. 1241-1255, 1975.
- [9] B. M. Das, and M. T. Omar “The effects of foundation width on model tests for the bearing capacity of sand with geogrid reinforcement”, Geotechnical and Geological Engineering, vol. 12, no. 2, pp.133-141, 1994.
- [10] E. Çiçek, E. Güler, ve T. Yetimoğlu “Geotekstil ve Geogrid donatılı kum zemin üzerindeki bir yüzeysel şerit temel modeli”, 5. Ulusal Geosentetikler Konferansı, İstanbul, 2012.
- [11] S. A. Tan, S. H. Chew, and W. K. Wong “Sand-geotextile interface shear strength by torsional ring shear tests”, Geotextiles and Geomembranes, vol. 16, no. 3, pp. 161-174, 1998.
- [12] S. M. Haeri, R. Nourzad, and A. M. Oskrouch “Effect of geotextile reinforcement on the mechanical behavior of sands”, Geotextiles and Geomembranes, vol. 18, no. 6, pp. 385-402, 2000.
- [13] İ. Akyüz “Donatılı ve Donatısız Zemin Güçlendirme Yöntemlerinin Karşılaştırılması”, Yüksek Lisans Tezi, İTÜ, 58-73 s, 2009.
- [14] R. Noorzad and S. H. Mirmoradi, “Laboratory evaluation of the behavior of a geotextile reinforced clay”, Geotextiles and Geomembranes, vol. 28, pp. 386–392, 2010.
- [15] Ş. Karataş “Endüstriyel Kenevir Forumu I-II”, Aydın Üniversitesi, 2019.
- [16] M. Kostic, B. Pejic, and P. Skundric “Quality Of Chemically Modified Hemp Fibers”, Bioresource Technology, vol. 99, pp. 94–99, 2008.
- [17] M. Acar, ve A. Dönmez “Kenevire Farklı Bir Bakış”, 2. Ulusal Biyoyakıtlar Sempozyumu bildiriler kitabı, pp. 265-270, 2016.
- [18] M. Acar, “Kenevire Farklı Bir Bakış”, https://arastirma.tarimorman.gov.tr/ktae/Belgeler/End%20C3%BCstriel%20Kenevir%20Ger%C3%A7e%C4%9Fi%20Paneli%20Sunular%C4%B1/ekg_2.pdf, Ağustos-2022.
- [19] TS 1900-1: “İnşaat mühendisliğinde zemin laboratuvar deneyleri-Bölüm 1: Fiziksel özelliklerin tayini”, 2006.
- [20] TS 1900-2: “İnşaat mühendisliğinde zemin laboratuvar deneyleri-Bölüm 2: Mekanik özelliklerin tayini”, 2006.
- [21] DSİ, “DSİ Genel Müdürlüğü Tarafından Yapılacak Kanallarda, Rezervuarlarda ve Barajlarda Kullanılacak Geotekstillere ve Geotekstille İlgili Mamuller İçin Teknik Şartname”, Ankara, 2014.
- [22] A. Sağıroğlu “Geotekstillere İncelenmesi ve Uygulandığı Yerler”, Uzmanlık Tezi, İller Bankası Anonim Şirketi, Ankara, 2015.
- [23] G. Çakar “Geotekstil Donatılı Killerin Davranışlarının Laboratuvarında İncelenmesi”, Yüksek Lisans Tezi, Balıkesir Üniversitesi, 102s, 2016.



Investigation of the Sample Disturbance Effects on Consolidation Parameters Obtained from Conventional Oedometer Tests

Numune Örselenmesinin Geleneksel Ödometre Deneyleri ile Belirlenen Konsolidasyon Parametrelerine Olan Etkilerinin İncelenmesi

¹Muharrem DUMANLILAR , ²Mustafa FENER , ³Mehmet Can BALCI 

¹Republic of Turkey Ministry of Interior Disaster and Emergency Management Presidency, Ankara, Turkey

²Ankara University, Engineering Faculty, Department of Civil Engineering, Ankara, Turkey

³Batman University, Engineering and Architecture Faculty, Department of Civil Engineering, Batman, Turkey

¹muharrem.dumanlilar@afad.gov.tr, ²mfener@ankara.edu.tr,

³mehmetcan.balci@batman.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 30 August 2022

Accepted : 2 October 2022

Keywords:

Systematic Sample Disturbance, Preconsolidation Stress, Oedometer Test, Consolidation Parameters

ABSTRACT

This study explores the effects of sample disturbance on the compression curves obtained from oedometer tests and the inferred effective preconsolidation stress (σ_p'). The samples were systematically disturbed by removing different fractions of the soil ranging from 10%, 20%, 30%, 40%, and 50% and remolding them back into place to reach the same initial void ratio. It was found that when the rate of disturbance was increased, it became more difficult to determine the σ_p' values on the compression curve; the typical bending point on the compression curve became increasingly indistinct, and negligible changes occurred in the σ_p' values of the disturbed soil samples up to a disturbance rate of 40%. If the soil samples whose consolidation parameters, such as preconsolidation stress, can't be determined are subjected to disturbances greater than 40%, it is recommended that no consolidation parameter for such samples be specified.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 30 Ağustos 2022

Kabul : 2 Ekim 2022

Anahtar Kelimeler:

Sistemik Numune Örselenmesi, Ön Konsolidasyon Gerilmesi, Odometre Deneyi, Konsolidasyon Parametreleri

ÖZET

Bu çalışmada, numune örselenmesinin geleneksel konsolidasyon deneyleriyle elde edilen sıkışma eğrileri ve ön konsolidasyon gerilmesine (σ_p') olan etkileri incelenmiştir. Laboratuvara getirilen numuneler sistematik olarak %10, %20, %30, %40 ve %50 oranında içleri boşaltılıp geri doldurularak örselenmiştir. Örselenme oranının artmasıyla, sıkışma eğrisi üzerinde σ_p' değerlerinin belirlenmesinin giderek zorlaştığı, sıkışma eğrisindeki tipik büküm noktasının giderek belirsiz bir hale geldiği ve %40 örselenme oranına kadar örselenen zemin numunelerinin σ_p' değerlerinde önemsenmeyecek miktarda değişimlerin olduğu tespit edilmiştir. Ön konsolidasyon gerilmesi gibi konsolidasyon parametrelerinin belirlenemediği zemin numunelerinin %40'dan daha fazla örselenmeye maruz kaldığı ve bu tür örnekler üzerinde konsolidasyon parametrelerinin belirlenmemesi gerektiği önerilmektedir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

ORCID ID: ¹0000-0001-9727-8129

²0000-0003-0491-3205

³0000-0003-3737-2556

1. INTRODUCTION

To demonstrate the effects of mechanical and textural properties of soils on engineering parameters, the stresses that they have been exposed to since their formation and the effects of those stresses on the soil structure should be determined. The calculation of long-term settlement due to forces directly transmitted to the soil through the foundation, particularly in clayey soil, is of great importance for the engineering branches dealing with soil mechanics. The parameters obtained from the oedometer test are taken into account when calculating the amount of consolidation settlement. Casagrande (1932) suggested that soil has memory, and trapped in its texture is the maximum effective stress it has been exposed to since its formation. He defined the maximum effective stresses recorded in the texture of the soils as the effective preconsolidation stress σ_p' , and developed the method named after him for determination of this value. The determination of consolidation parameters in soil mechanics through various calculations and analyses of graphical relationships has contributed greatly to investigations of grain size distribution, coefficient of permeability, preloading times, preconsolidation stresses, and the effects of such stresses on soil memory.

Stresses in soils can occur in any direction as a result of preconsolidation stress on the soil, the construction of engineering structures on the soils, or geological events such as folding, faulting, and creep [1]. If the loadings that apply stress to the soil have a long-term effect on the soil, all of the total stresses are recorded in the soil memory as effective stress [2]. Many researchers have developed different methods for the determination of the preconsolidation stresses that soils were subjected to in the past [3-9]. The reviews performed by these researchers are all based on Casagrande's method. Among the methods employed to determine the σ_p' value, the most reliable and frequently used is the one devised by the Casagrande (1936) method. Examples of numerous studies exploring the effects of sample disturbance on the mechanical properties of soils can be summarized as follows.

Ward et al. (1959) even identified the maximum horizontal effective stresses that the soil had been subjected to in the past using Casagrande's (1936) method [10]. On the other hand, Cetin (1997; 2000) determined the movement pattern of the fault 1100 years ago (seismic/aseismic) by finding the preconsolidation stresses recorded in the soil memory along the Meers fault in the USA [11-12]. Gunaydin and Cetin (2020) also used the same method on the East Anatolian Fault [13]. Yang et al. (2020) studied the effects of sample disturbance on the cyclic shear strength of clays [14]. Lim et al. (2019) assessed the geotechnical parameters of soils during design, which were obtained by different types of samplers depending on the disturbance in the soil caused by the samplers [15]. Tommasi et al. (2019) evaluated the disturbance of open sea sediments using two types of gravity piston coring techniques [16]. Lukas et al. (2019) explored the effects of soil disturbance caused by samplers used in low-plasticity soils on undrained shear strength [17]. D'Ignazio et al. (2017) reported the disturbance that occurs during the preparation, handling, and storage of soil samples taken from quick clay using the finite elements method [18]. Carroll and Long (2017) assessed the effects of disturbance on the results of cone penetration tests with pore water pressure and shear wave velocity tests using different types of samplers in silt soils [19]. Karlsson et al. (2016) commented on the effects of sample disturbance on estimations of the amount of settlement in soft clay [20]. Zapata-Medina et al. (2014) questioned the effects of stress history and sample disturbance on over-consolidated clays in the laboratory [21]. Horng et al. (2011) studied the change in the undrained shear strength of disturbed samples [22]. Ingles and Lafeber (1966) explored whether or not the pore distribution and grain orientation of soils can change due to the alteration of stresses caused by disturbance, etc., on the soil [23]. The mentioned studies, however, deal mainly with the effects of the type of sampler on disturbance and the effects of disturbance on the mechanical parameters of the soil.

While there has been no study to date directly addressing the effects of systematic sample disturbance on σ_p' values determined through conventional oedometer consolidation tests, the studies that most closely resemble the present study are those conducted by Lunne et al. [24-25]. Lunne et al. (2008) over-consolidated natural soil samples by preloading in the laboratory. They conducted drained constant rate of strain (CRS) consolidation tests and undrained triaxial tests on natural soil samples and soil samples that they had disturbed through different loading techniques to explore the stress-strain relationship in both types of soil samples. They determined the effects of the applied disturbance method on this relationship [26].

In the present study, a systematic disturbance method was employed, and the effects of sample disturbance on σ_p' were addressed, for which identical soil samples were taken from the field and brought to the laboratory. The samples were systematically disturbed at a rate of 10%, 20%, 30, 40%, and 50% in the laboratory. The purpose of systematically disturbing the samples was to create further stresses on the soil structure and texture, in addition to the stresses they had been subjected to in their natural formation environments, with the aim of investigation of the effects of these stresses on the typical compression curves and σ_p' of the soils. Oedometer tests were conducted on the systematically disturbed soil samples and those with a disturbance rate of 0% (intact: not subject to any disturbance). Parameters such as σ_p' , compression index (C_c), recompression index (C_r), void ratio (e), and curvature angle (C_a) values were determined by the oedometer tests on the soil samples with a disturbance rate of 0% and the systematically disturbed soil samples. In this study, a specific method was employed to determine the change of curvature in the void ratio (e)-effective stress (σ') graph. This method involves the intersection of the straight-line portion of the virgin compression curve and the linear extension line up to the σ_p' to determine the

angle between them in degrees. This angle is defined as the “curvature angle” (C_a) and is shown in Figure 1. The consolidation parameters such as C_c , C_r , σ_p' , and C_a values of each sample were compared using the e - σ' graphs.




Figure 1. Approach to determine the curvature angle (C_a).

2. MATERIAL

2.1. Soil samples

The disturbed and undisturbed soil samples used in the study were taken from the Quaternary sediments of the Nigde stocks in the southeast of the Central Anatolian Region, Turkey, where clayey silt is densely located. The index properties of the soil samples were determined and presented in Table 1.

Table 1. Index properties of soil samples used in this study.

Symbol	Definition	Unit	Value (Average)
γ_n	Unit weight	g/cm^3	1.74
γ_d	Dry unit weight	g/cm^3	1.21
γ_{sat}	Saturated unit weight	g/cm^3	1.76
γ_s	Solid unit weight	g/cm^3	2.65
e	Void ratio	%	118.41
n	Porosity	%	54.38
w	Water content	%	43.02
S_r	Saturation	%	96.35
LL	Liquid limit	%	52
PL	Plastic limit	%	38
USCS	Unified Soil Classification System	-	MH

MH: Inorganic silt of high plasticity.

3. METHODS

3.1. Sampling

The samples were taken in two groups, namely, disturbed and undisturbed, from a foundation, where the disturbance was minimum and where the water content was maximum. The disturbed samples were collected from the sidewall of the foundation excavation using the grooving method such that they weighed 20 kg. The samples were then reduced to 5 kg using the quartering method. The undisturbed samples were taken using two different methods, namely, consolidation rings and tubes.

Usually, block samples are brought to the laboratory for consolidation tests, and the process of inserting them into the consolidation ring (50 mm in diameter and 20 mm in height) is carried out in the laboratory. In this study, this process was carried out in the field as the sample disturbance was significant. For the insertion of undisturbed

samples into the consolidation rings, the inner surfaces of the rings were lubricated, after which the rings were seated on the soil surface and pressed into the soil with the help of the mold placed on them. To keep sample disturbance to a minimum, the consolidation rings were not hit with a hammer or any other tool, with only pressure applied to take the samples. A total of 18 intact samples were taken using this method. Each oedometer test was performed for 3 soil samples, and their average values were given in the study. In the sampling process with the sample tube, the weight of the standard sampling device was dropped from a certain height so that the soil sample penetrated the tube. This method was applied to fill 5 sample tubes. Index properties of soils were determined using tube samples. The different stages of the sampling process are shown in Figure 2. Oedometer tests were performed according to the American Society of Testing Materials (ASTM) D2435 standard (ASTM, 2003) on the systematically disturbed and undisturbed soil samples by applying 24-h incremental loading [27]. When the preconsolidation stress is being approached, the load increments placed on the soil samples are reduced to more precisely define the transition between the reloading curve and the virgin compression curve.



Figure 2. a) Tube sampling with sampling device, b) cleaning the outer side walls of the tube samples, c) waxing of the upper and lower parts of the tube samples, d) undisturbed soil sample image was taken into the consolidation ring.

3.2. Systematic sample disturbance

For the purpose of the study, the soil samples brought to the laboratory for oedometer tests were artificially disturbed at the rates of 10%, 20%, 30%, 40%, and 50%. Details of systematic disturbance of the soil samples are as follows: First, molds were formed on transparent paper, having the same diameter as the consolidation rings. Disturbance rates were selected for each mold. Boundary lines were drawn on the edges of the molds, and the boundaries of the sections to be disturbed were determined with a ruler. The marked areas were emptied using a pointed tool (Figure 3). The emptied sections were filled back with the soil removed from the voids. The same procedure was carried out for the remaining samples and for all selected percentiles.




Figure 3. a) Percentage slices determined on transparent paper, b) marking the boundaries, c) marking the determined percentile on the soil sample and d) views of the slices to be emptied on the soil sample.

This process involves the selection of slices in different directions so that the disturbance is spread across the soil sample. Precautions were taken to protect the water content of the soil sample by carrying out the process as quickly as possible. The tests were started by placing the prepared samples immediately into the oedometer cell. It was avoided going beyond the determined boundaries of disturbance. Figure 4 shows the amount of systematic disturbance in the soil samples.




Figure 4. a) Intact soil sample (0% disturbance), b) 10% disturbed soil sample, c) 20% disturbed soil sample, d) 30% disturbed soil sample, e) 40% disturbed soil sample and f) 50% disturbed soil sample.

4. EXPERIMENTAL RESULTS

Data for the oedometer test of the intact soil samples that had a disturbance rate of 0%, and the other soil samples that were systematically disturbed, are presented in Table 2. The results of the consolidation tests indicate that the σ_p' values of all systematically disturbed soil samples, excluding the sample with a disturbance rate of 50% (i.e., those with a disturbance rate of 10%, 20%, 30%, and 40%), and the undisturbed soil samples (a disturbance rate of 0%), were approximately 1.85 kg/cm². Figure 5 shows the σ_p' values of all soil samples. As can be concluded from the data, it is seen that there is a significant change in the preconsolidation stress of up to 20% disturbance. From this ratio (20% disturbance), it is possible to say that there is no significant change in the pre-consolidation stress.




Figure 5. Preconsolidation stress values of soil samples obtained by Casagrande's method from oedometer tests.

The compression index values of the soil samples used in this study are given in Table 3. Recompression index (C_r) values of the soil samples increase with an increase in the amount of disturbance due to the change depending on the slope of the recompression curve. According to Table 3, it is possible to say that there are decreasing and increasing changes in the compression indexes.

Table 2. Odometer test data of disturbed soil samples.

Sample Disturbance Ratio:			0%		10%		20%	
Time (Hour)	Load (kg)	σ_v' (kg/cm ²)	D (cm)	e	D (cm)	e	D (cm)	e
24	0.25	0.127	0.010	1.456	0.010	1.456	0.015	1.449
48	0.50	0.255	0.021	1.440	0.025	1.435	0.033	1.423
72	0.75	0.382	0.029	1.429	0.034	1.422	0.047	1.403
96	1.0	0.509	0.036	1.419	0.042	1.410	0.056	1.391
120	1.50	0.764	0.045	1.406	0.056	1.391	0.069	1.372
144	2.0	1.019	0.059	1.386	0.069	1.372	0.081	1.355
168	3.0	1.528	0.085	1.349	0.090	1.342	0.101	1.327
192	4.0	2.037	0.120	1.300	0.120	1.300	0.125	1.293
216	8.0	4.074	0.229	1.145	0.229	1.145	0.210	1.172
240	12.0	6.112	0.296	1.050	0.296	1.050	0.270	1.087
264	16.0	8.149	0.342	0.985	0.342	0.985	0.312	1.027
288	20.0	10.186	0.375	0.938	0.375	0.938	0.349	0.975
312	28.0	14.260	0.427	0.864	0.427	0.864	0.405	0.895
336	32.0	16.297	0.446	0.837	0.446	0.837	0.437	0.850
336	22.0	11.205	0.436	0.852	0.436	0.852	0.413	0.884
360	10.0	5.093	0.429	0.862	0.429	0.862	0.386	0.923
386	3.0	1.527	0.414	0.883	0.414	0.883	0.346	0.978
Sample Disturbance Ratio:			30%		40%		50%	
Time (Hour)	Load (kg)	σ_{vc}' (kg/cm ²)	D (cm)	e	D (cm)	e	D (cm)	e
24	0.25	0.127	0.002	1.449	0.010	1.456	0.000	1.470
48	0.50	0.255	0.032	1.423	0.046	1.405	0.016	1.447
72	0.75	0.382	0.050	1.403	0.067	1.375	0.028	1.430
96	1.0	0.509	0.063	1.391	0.083	1.353	0.038	1.416
120	1.50	0.764	0.085	1.372	0.108	1.317	0.055	1.392
144	2.0	1.019	0.104	1.355	0.128	1.289	0.069	1.372
168	3.0	1.528	0.131	1.327	0.154	1.252	0.093	1.338
192	4.0	2.037	0.159	1.293	0.181	1.213	0.115	1.307
216	8.0	4.074	0.248	1.172	0.255	1.108	0.175	1.222
240	12.0	6.112	0.305	1.087	0.301	1.044	0.224	1.152
264	16.0	8.149	0.346	1.027	0.336	0.993	0.261	1.100
288	20.0	10.186	0.379	0.975	0.360	0.959	0.289	1.060
312	28.0	14.260	0.421	0.895	0.403	0.899	0.336	0.993
336	32.0	16.297	0.441	0.850	0.423	0.871	0.355	0.967
336	22.0	11.205	0.430	0.884	0.401	0.902	0.353	0.969
360	10.0	5.093	0.398	0.923	0.379	0.932	0.345	0.981
386	3.0	1.527	0.361	0.980	0.353	0.970	0.330	1.000

σ_{vc}' : Effective vertical consolidation stress, D: Displacement, e: Void ratio.

Table 3. Compression index values of soil samples obtained from oedometer tests.

Sample Disturbance Ratio	C _r	C _c
0%	0.056	0.51
10%	0.070	0.51
20%	0.090	0.51
30%	0.143	0.48
40%	0.169	0.38
50%	0.183	0.42

C_r: Recompression index, C_c: Compression index.

As for the curvature angle (C_a) values in all of the soil samples, the undisturbed sample had the lowest C_a value (140°) and the most disturbed sample had the highest C_a value (165°), meaning that as the rate of disturbance increases, so do the C_a values. Figure 6 gives the C_a values of the soil samples.




Figure 6. Curvature angle (C_a) values of soil samples.

All e - σ' graphs of the soil samples used in the study are presented in Figure 7. As can be seen in Figure 7, a comparison of the compression curves of the soil samples (except for the compression curve of the sample with a disturbance rate of 50%) suggests a relationship similar to that observed in the relevant literature. Because the structure and texture of the sample that was moved at a rate of 50% were moved at a rate higher than a certain rate, it behaves differently than the other samples.

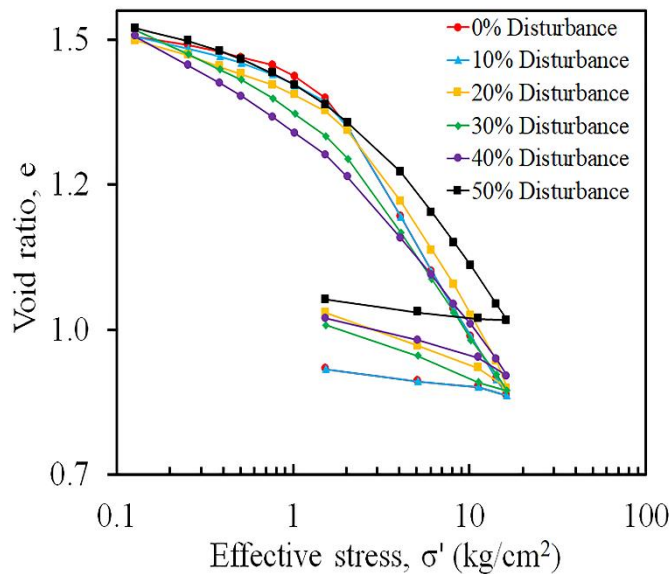


Figure 7. Void ratio (e) – effective stress (σ') graphs of the soil samples.

The initial void ratios (e_0) and final void ratios (e_f) given in Figure 8 indicate that the e_0 values of all soil samples are close to each other, but the e_f values differ depending on the deformations. The e_f values were noted to increase as the amount of disturbance increased. The fact that the e_0 values are so close to each other indicates that the prepared samples were identical and that the systematic disturbance had been carried out for the purpose of the study.

With the increase in the amount of disturbance, the compression curves shift downward and leftward in the e - σ' graphs. This is thought to be since the soil samples converge with the σ_p' values with increasing disturbance, and that immediately afterward, their structures change rapidly and become over-consolidated. The fact that the e_0 values of the undisturbed soil samples (0% disturbance) and those disturbed at varying rates are almost equal is an indication that the disturbance process and the re-establishment of the samples have been carried out successfully. There has been no research to date on the relationship between the level of proportional disturbance and σ_p' and e - σ_p' graphs, other than those investigating the e - σ_p' graph relationships of undisturbed samples and the same type of fully disturbed (remolded) samples.




Figure 8. Initial void ratio (e_0) and final void ratio (e_f) values of soil samples.

As such, the significant results obtained from the systematically disturbed soil samples in this study can be considered the contributions of this study to the literature. Quigley and Thompson (1966) studied the compression curves of a sensitive marine clay called Laurentian or Leda clay [28]. From this point of view, fracture or sudden bending when the preconsolidation stress is reached is typical for highly sensitive clays. The curve slopes slightly up to this point; but as soon as the preconsolidation stress is reached, the structure of the soil collapses quickly and dramatically [29].

It has been observed that the void ratio - effective stress curves determined in this study behave as accepted in the literature. All of the results show that it would be helpful to have a wider range of samples to learn more about how systematic disturbance affects consolidation.

5. CONCLUSION

The results obtained in this study can be listed as follows:

It was found that negligible changes had occurred in the σ_p' values of the disturbed soil samples up to a certain disturbance rate 40%.

It was seen that the C_a values went up as the soil samples that were tested were moved around more.

It was found that as the level of disturbance of the soil samples was increased, the breaking and bending points in the typical compression curves became increasingly indistinct due to the rising stress in the soil samples with greater disturbance levels.

The breaking and bending points that cannot be clearly distinguished on the compression curves of $e-\sigma_p'$ graphs in such experimental applications must be derived from soil samples with a disturbance rate of more than 40%. Such soil samples are not recommended for use in determining σ_p' values and other consolidation parameters.

It is thought that using a larger number of soil samples with different rates of disturbance will give results that back up this study even more.

Author's Contributions

Muharrem DUMANLILAR: Investigation, Resources, Validation, Formal analysis

Mustafa FENER: Supervision, Term, Methodology, Validation, Formal analysis

Mehmet Can BALCI: Investigation, Writing - Original Draft, Writing - Review & Editing

Statement of Conflict of Interest

The authors of the article declare that there is no conflict of interest between them.

REFERENCES


- [1] J. Fedá, "Stress in Subsoil and Methods of Final Settlement Calculation", *Developments in Geotechnical Engineering*, vol. 18, p. 216, 1978.
- [2] A. Casagrande, "The Structure of Clay and Its Importance in Foundation Engineering", *Boston Society Civil Engineers Journal*, 1932.
- [3] A. Casagrande, "The determination of pre-consolidation load and its practical significance", *Proceedings of the International Conference on Soil Mechanics and Foundation Engineering*, Cambridge, Massachusetts, vol. 3, p. 60, 1936.
- [4] J. H. Schmertmann, "The Undisturbed Consolidation Behaviour of Clay", *Transactions of the American Society of Civil Engineers*, vol. 120, no. 1, pp. 1201-1227, 1955.
- [5] F. Pacheco Silva, "A new graphical construction for determination of the preconsolidation stress of a soil sample", *Proceedings of the 4th Brazilian Conference on Soil Mechanics and Foundation Engineering*, Rio de Janeiro, vol. 2, no. 1, pp. 225-232, 1970.
- [6] R. E. Smith, H. E. Wahls, "Consolidation Under Constant Rates of Strain", *Journal of the Soil*

- Mechanics and Foundations Division, vol. 95, no. 2, pp. 519-539, 1969.
- [7] J. Lowe III, E. Jonas, V. Obrican, "Controlled Gradient Consolidation Test", *Journal of Soil Mechanics and Foundations Divisions*, vol. 95, no. 1, pp. 77-97, 1969.
- [8] F. Tavenas, S. Leroueil, "Effects of stresses and time on yielding of clays", *Ninth International Conference on Soil Mechanics and Foundation Engineering*, pp. 319-326. 1977.
- [9] S. Leroueil, J. P. LeBihan, F. Tavenas, "An Approach for the Determination of the Preconsolidation Pressure in Sensitive Clays", *Canadian Geotechnical Journal*, vol. 17, no. 3, pp. 446-453, 1980.
- [10] W. H. Ward, S. G. Samuels, M. E. Butler, "Further Studies of the Properties of London Clay", *Geotechnique*, vol. 9, no. 2, pp. 33-58, 1959.
- [11] H. Cetin, "How did the Meers Fault Scarp Form? Paleearthquake or Aseismic Creep? A Soil Mechanical Perspective", *Eng Geol*, vol. 47, pp. 289-310, 1997a.
- [12] H. Cetin, "An Experimental Study of Soil Memory and Preconsolidation Adjacent to An Active Tectonic Structure: The Meers Fault, Oklahoma, USA", *Eng Geol*, vol. 57, no. 3-4, pp. 169-178, 2000.
- [13] O. Gunaydin, H. Cetin, "Determination of Stress Distribution on Active Fault by Means of Casagrande Method; An Innovative Approach", *Soil Dynamics and Earthquake Engineering*, vol. 129, p. 105920, 2020.
- [14] S. Yang, K. H. Andersen, T. Lunne, G. Yetginer "Effect of Sample Disturbance on Cyclic Shear Strength of Normally to Lightly OC Clays", *International Journal of Geotechnical Engineering*, vol. 14, no. 3, pp. 242-253, 2020.
- [15] G. T. Lim, J. Pineda, N. Boukpeti, J. A. H. Carraro, A. Fourie, "Effects of Sampling Disturbance in Geotechnical Design", *Canadian Geotechnical Journal*, vol. 56, no. 2, pp. 275-289, 2019.
- [16] P. Tommasi, A. Avalle, F. Budillon, R. Romeo, A. Caburlotto, A. Conforti, G. Di Martino, A. Pagliaroli, M. Magagnoli, R. Urgeles, J. Llopart, "Evaluation of Disturbance Induced on Soft Offshore Sediments by Two Types of Gravity Piston Coring Techniques", *Marine Geology*, vol. 417, pp. 106005, 2019.
- [17] W. G. Lukas, D. J. DeGroot, J. T. DeJong, C. P. Krage, G. Zhang, "Undrained Shear Behavior of Low-Plasticity Intermediate Soils Subjected to Simulated Tube-Sampling Disturbance", *Journal of Geotechnical and Geoenvironmental Engineering*, vol. 145, no. 1, p. 04018098, 2019.
- [18] M. D'Ignazio, H. P. Jostad, T. Länsivaara, V. Lehtonen, J. Mansikkamäki, C. Meehan "Effects of sample disturbance in the determination of soil parameters for advanced finite element modelling of sensitive clays", *Landslides in Sensitive Clays.*, Springer, 45-154, 2017.
- [19] R. Carroll, M. Long, "Sample Disturbance Effects in Silt", *Journal of Geotechnical and Geoenvironmental Engineering*, vol. 143, no. 9, 2017.
- [20] M. Karlsson, A. Emdal, J. Dijkstra, "Consequences of Sample Disturbance When Predicting Long-Term Settlements in Soft Clay", *Canadian Geotechnical Journal* vol. 53, no. 12, pp. 1965-1977, 2016.
- [21] D. G. Zapata-Medina, R. J. Finno, C. A Vega-Posada, "Stress History and Sampling Disturbance Effects on Monotonic and Cyclic Responses of Overconsolidated Bootlegger Cove clays", *Canadian Geotechnical Journal*, vol. 51, no. 6, pp. 599-609, 2014.
- [22] V. Horng, H. Tanaka, H. Hirabayashi, R. Tomita, "Sample Disturbance Effects on Undrained Shear Strengths -Study From Takuhoku Site, Saparro", *Soils and Foundations*, vol. 51, no. 2, pp. 203-213, 2011.
- [23] O. G. Ingles, D. Lafeber, "The Influence of Volume Defects on the Strength and Strength Isotropy of Stabilized Clays", *Engineering Geology*, vol. 1, no. 4, pp. 305-310, 1966.
- [24] T. Lunne, T. Berre, S. Strandvik, "Sample disturbance effects in deep water soil investigations", *Offshore Site Investigation and Foundation Behaviour New Frontiers: Proceedings of an International Conference Society of Underwater Technology* January, pp. 98-199, 1998.
- [25] T. Lunne, T. Berre, K. H. Andersen, S. Strandvik, M. Sjursen, "Effects of Sample Disturbance and Consolidation Procedures on Measured Shear Strength of Soft Marine Norwegian Clays", *Canadian Geotechnical Journal*, vol. 43, no. 7, pp. 726-750, 2006.
- [26] T. Lunne, T. Berre, K. H. Andersen, M. Sjursen, N. Mortensen, A. B. Huang, P. W. Mayne, "Effects of sample disturbance on consolidation behaviour of soft marine Norwegian clays", *International Conference on Site Characterization*, vol. 3, pp. 1471-1479, 2008.
- [27] American Society for Testing Materials, "Standard Test Method for One-Dimensional Consolidation Properties of Soils, ASTM Standard D2435", West Conshohocken, PA, 2003.
- [28] R. M. Quigley, C. D. Thompson, "The Fabric of Anisotropically Consolidated Sensitive Marine Clay", *Canadian Geotechnical Journal*, vol. 3, no.2, pp. 61-63. 1966.
- [29] R. D. Holtz, W. D. Kovacs, and T. C. Sheahan, "An introduction to geotechnical engineering", Englewood Cliffs: Prentice-Hall., vol. 733, 1981.



BMBAD
BJESR

Mühendislik Bilimleri ve Araştırmaları Dergisi
Journal of Engineering Sciences and Researches



Ceyhan Bölgesi Bazaltlarının Bazı Fiziksel ve Mekanik Özelliklerinin P Dalga Hızı ile Tahmini

Prediction of Some Physical and Mechanic Properties of Basalts in Ceyhan Region Using P wave Velocity

¹Esma KAHRAMAN 

¹Çukurova Üniversitesi, Mühendislik Fakültesi, Maden Mühendisliği Bölümü Sarıçam/Adana, Türkiye

ekahraman@cu.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 31 August 2022
Accepted : 18 October 2022

Keywords:

Basalt, Uniaxial Compressive Strength, P Wave Velocity, Physico-Mechanic Properties

ABSTRACT

Basalt is one of the most important construction materials because hardness, durability and strength properties and it is used widely. Before using basalts as a building material, some properties such as unit volume weight, water absorption rate, uniaxial compressive strength and Brazilian tensile strength should be determined. But these tests have some disadvantages in practice. Testing procedures and sample preparations are very difficult and time-consuming. In addition, their applications are needed expertise. In this study, P wave velocity (V_p), a fast and non-destructive test method, was used to determine some physical and mechanical properties of basalts. Empirical relationships for determination of unit volume weight, water absorption rate, uniaxial compressive strength and Brazilian tensile strength were developed. Good correlation coefficients ($R^2= 73.2-85.6$) were obtained between V_p and unit volume weight, water absorption rate, uniaxial compressive strength and Brazilian tensile strength.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 31 Ağustos 2022
Kabul : 18 Ekim 2022

Anahtar Kelimeler:

Bazalt, Tek Eksenli Basınç Dayanımı, P Dalga Hızı, Fiziko-Mekanik Özellikler

ÖZET

Bazalt, sertlik, dayanıklılık ve mukavemet özellikleri nedeniyle en önemli yapı malzemelerinden biridir ve yaygın olarak kullanılmaktadır. Bazaltları yapı malzemesi olarak kullanmadan önce birim hacim ağırlığı, su emme oranı, tek eksenli basınç dayanımı ve Brezilya çekme dayanımı gibi bazı özelliklerinin belirlenmesi gerekmektedir. Ancak, bu testlerin pratikte bazı dezavantajları vardır. Test prosedürleri ve numune hazırlama işlemleri çok zor ve zaman alıcıdır. Ayrıca bu test uygulamaları uzmanlık gerektirir. Bu çalışmada, bazaltların bazı fiziksel ve mekanik özelliklerini belirlemek için hızlı ve tahribatsız bir test metodu olan P dalga hızı (V_p) kullanılmıştır. Birim hacim ağırlığı, su emme oranı, tek eksenli basınç dayanımı ve Brezilya çekme dayanımının belirlenmesi için ampirik ilişkiler geliştirilmiştir. V_p ile birim hacim ağırlığı, su emme oranı, tek eksenli basınç dayanımı ve Brezilya çekme dayanımı arasında iyi korelasyon katsayıları ($R^2= 73.2-85.6$) elde edilmiştir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Teknolojik ilerlemeler ve artan nüfus ile birlikte köprü, yol, baraj gibi temel yapı ve konut inşaları da hızla artmaktadır. Bu durum doğal yapı taşlarına olan ihtiyacı da önemli ölçüde etkilemektedir. Bazaltlar ülkemizde yaygın olarak bulunması, dayanıklı olması, atmosferik koşullardan çok az etkilenmesinden dolayı oldukça geniş bir kullanım alanına sahiptir. Bazalt doğada çok geniş yayılım alanına sahip küçük kristalli veya camsı, koyu gri ile siyah arasında değişen renklere ve farklı porozite oranlarına sahip volkanik bir kayadır [1]. Bazalt su emme, paslanma, dona, darbelere, renk değişimine, asitlere ve sürtünmelere karşı oldukça dayanıklıdır. Bu durum yapılarda uzun süre leke ve kılcal çatlaklar oluşmasını engelleyerek yapı ömrünü arttırır [2].

Ülkemizde bulunan bazaltların mühendislik özelliklerinin belirlenmesine yönelik literatür de pek çok araştırma mevcuttur. Keskin ve Kılıç [3] yaptıkları çalışmada Doğu Akdeniz yöresi bazaltlarının fiziksel ve mekanik özelliklerini incelemişler ve deney sonuçlarına göre bölgeden elde edilen bazaltların kırılma şeması olarak değerlendirilebileceğini belirtmişlerdir. Kahveci ve Kadayıfçı [1] yaptıkları çalışmada Diyarbakır bölgesi bazaltlarının fiziksel, mekanik, özgül ısı kapasitesi, kuruma deneyleri, parlatılabilirlik ile kesilebilirlik özelliklerini araştırmışlardır. Çalışmalarının sonucunda porozitesi düşük olan bazaltların daha dayanıklı olduğuna işaret etmişlerdir. Orhan ve arkadaşları [4] Elazığ ili Maden ilçesinden elde ettikleri bazaltların beton agregası olarak kullanımını değerlendirmişlerdir. Çalışmada, Elazığ ilinin Maden ilçesinden elde edilen doğal bazaltlardan ürettikleri betonları incelemişlerdir. Üretilen beton numunelerinin; ısıl iletkenlik analizleri, dayanım analizleri ve mikroorganizmalara karşı tutumu incelemişlerdir. Çalışmaları sonucunda dayanıklı, yanıcı olmayan, çevre dostu, toksik olmayan beton üretmişler, sağlıklı ve konforlu bir yaşam ortamı yaratılmasına büyük katkı sağlamışlardır. Kahraman ve Yapıcı [5] yaptıkları çalışmada Kurtpınar bazaltlarının fiziksel, mekanik ve petrografik özelliklerini belirlemişlerdir. Deney sonuçlarını demiryolu balast malzemesi şartnamesine göre değerlendirmişler ve Kurtpınar bazaltlarının demiryolu konvansiyonel hatlarında balast malzemesi olarak kullanılabilirliğini göstermiştir.

Bazı araştırmacılar ise bazaltların özelliklerini istatistiksel ilişki kurarak incelemişlerdir. Erişiş ve arkadaşları [6] yaptıkları çalışmada bazaltik kayaların bileşimi, mineral yüzdeleri, dokusu ve kristal boyutlarını, fiziksel ve mekanik özelliklerini incelemişlerdir. Çalışmalarının sonucunda kayaların mineralojik bileşiminin fiziksel ve mekanik özellikleri ile ilişkili olduğu kanaatine varmışlardır. Karakuş ve Atakay [7] yaptıkları çalışmada tarihi yapılarda kullanılan bazaltların ana malzeme özelliklerinin örnek alınmadan tahmin edilmesi amacıyla Diyarbakır yöresinin bazaltlarının P dalgası hızı ile diğer özellikleri arasındaki istatistiksel ilişkileri araştırmışlardır. Sonuç olarak, P dalgası hızı ile yoğunluk, gözeneklilik, tek eksenli basınç dayanımı, Brezilya çekme dayanımı, elastisite modülü ve Poisson oranı arasında oldukça ilişkili modeller elde etmişlerdir.

P dalga hızı hem laboratuvarında hem de arazide uygulanabilen yeraltı üretim yöntemlerinde, taş ocağı işletmeciliğinde, delme-patlatma faaliyetlerinde inşaat, jeoteknik ve madencilik projelerinde yaygın olarak kullanılabilecek bir tahribatsız test yöntemidir. Bu tahribatsız test yöntemi kaya kütlesi deformasyon özelliklerini, kaya ayrışma derecesini, yeraltı açıklığı ve tüneller çevresinde gelişen hasar bölgelerini tahmin etmede kullanılmaktadır [8, 9, 10, 11]. Bazı araştırmacılar ise farklı kayaların özelliklerini tahmin etmede P dalga hızı üzerine yoğunlaşmıştır. Bu çalışmalardan elde edilen denklemler Tablo 1'de özetlenmiştir.

Tablo 1. P dalga hızı kullanılarak elde edilen bazı tahmin denklemleri.

Eşitlik	R ²	Kaya Tipi	Kaynaklar
$TEBD = 0.03467V_p - 85.246$	0.85	Bazalt	Karakuş ve Atakay [12]
$BDÇD = 0.003078V_p - 7.873$	0.85		
$(n) = 17.9111 - 0.002933 V_p$	0.88		
$Yoğunluk (\rho) = 0.0003098 V_p + 1.0058$	0.89		
$CAI=0.0009 V_p + 1.9375$	0.76	Kuvarsit,	Khandelwal ve Ranjith [13]
$SH = 0.013V_p + 3.265$	0.81	Granit,	
$VH = 0.144 V_p - 75.63$	0.77	Dolomit, Mermer	
$TEBD = 35.54V_p - 55$	0.80	19 farklı granit	Tugrul ve Zarif [14]
$TEBD = 64.2V_p - 117.99$	0.90	Kumtaşı, fillit kömür, mikaşist, kuvars, bazalt	Sharma ve Singh [15]
$TEBD = 0.026V_p - 20.47$	0.91	Marn	Azimian ve Ajalloeian [16]
$Aw = -0.004 V_p - 20.39$	0.83		
$lnTEBD = 3.94lnV_p - 28.12$	0.88	Bazalt ve Riyolit	Kallu ve Roghanchi [17]
$TEBD = 2.304V_p^{2.43}$	0.94	19 farklı kayalar	Kılıç ve Teymen, [18]
$BDÇD = 0.49V_p^{1.8723}$	0.92		
$TEBD = 0.033V_p - 34.83$	0.87	Kuvarsit, Granit, Dolomit, Mermer, Şeyl	Khandelwal [19]
$BDÇD = 0.001V_p + 0.662$	0.88		
$Yoğunluk (\rho) = 0.2029 V_p + 1794.7$	0.86		

*V_p: P dalga hızı, BHA: birim hacim ağırlık, Aw: Ağırlıkça su emme oranı, TEBD: Tek eksenli basınç dayanımı, BDÇD: Brazilian dolaylı çekme dayanımı, n: porozite, CAI: Cerchar aşındırma indeksi, SH: Shore sertliği, VH: Vickers sertliği.

Kayaçların bilinen özelliklerinden bilinmeyen tahmin etmede lineer regresyon teknikleri yaygın olarak kullanılmaktadır [14, 15, 16, 20]. Ayrıca bazaltların fiziksel ve mekanik özelliklerinin tahmini pek çok çalışmada ortaya konmuştur. Fakat bölgesel çalışmalar oldukça kısıtlıdır. Bu çalışmanın amacı Ceyhan bölgesinden elde edilen bazaltların P dalga hızı (V_p) kullanılarak birim hacim ağırlık (BHA) ve ağırlıkça su emme oranı (Aw), Tek eksenli basınç dayanımı (TEBD) ve Brazilian dolaylı çekme dayanımı (BDÇD) değerlerinin pratik ve anlamlı şekilde tahmin edilmesi için ampirik formüller geliştirmektir. Çalışma sonucunda elde edilen eşitlikler ile kolay ve kısa zamanda P dalga hızı kullanılarak bazaltların araştırılan diğer özellikleri belirlenmiş olacaktır. Böylelikle artan sektör ihtiyacı karşılırken deney aşamaları beklenmeden daha pratik ve hızlı bir şekilde elde edilen malzeme için ön değerlendirme olanağı sağlanmış olacaktır.

2. MALZEME VE YÖNTEM

2.1. Çalışma Sahası Hakkında Genel Bilgiler

Bu çalışmada, Adana İli, Ceyhan ilçesi sınırları içerisinde bulunan Köşreli, Mustafabeyli, Kurtkulağı ve Kurtpınar mahallelerinden elde edilen bazalt örnekleri üzerinde çalışılmıştır (Şekil 1).

2.2. Numunelerin Hazırlanması

Çalışma sahasının farklı bölgelerinden blok numuneler getirilmiş ve blok numunelerden karot numuneleri Uluslararası Kaya Mekaniği Standartlarına (ISRM 2007) [21] göre hazırlanmıştır (Şekil 2).



Şekil 1. Örneklerin alındığı bölgelerin yer bulduru haritası.



Şekil 2. Çalışma sahasından getirilen numune ve hazırlanan karot örnekleri.

2.3. Deneysel Çalışmalar

Numunelerin birim hacim ağırlık (BHA) ve ağırlıkça su emme oranı (A_w) değerlerini belirlemek için ISRM [21] standardında açıklanan laboratuvar testleri kullanılmıştır. Birim hacim ağırlığın belirlenmesi için numunelerin toplam hacmi, kumpas okumalarının ortalamaları kullanılarak hesaplanmış ve numunelerin kuru ağırlığı 0,01 hassasiyetinde tartım yapabilen bir terazi ile belirlenmiştir. Her bir numune için numunenin kuru ağırlığı numune hacmine bölünmüş ve birim hacim ağırlık değerleri hesaplanmıştır. Ağırlıkça su emme oranları, suya doymuş numunenin ağırlığı ile kuru numune ağırlığı farkının numunenin kuru ağırlığına oranı olarak hesaplanmıştır [22]. Tek eksenli basınç dayanımı (TEBD) için blok numunelerden 4.2 cm çapında ve boy/çap oranı 2-2.5 olan karot numuneleri alınmıştır. Deneyde 3000 kN-ELE otomatik pres kullanılmıştır ve TS EN 1926 [23] standardı uygulanmıştır. Deney sonucunda elde edilen kırılma yükü kaydedilmiş ve Eşitlik 1 kullanılarak hesap yapılmıştır.

$$\sigma_t = \frac{P}{A} \text{ (kg/cm}^2\text{)} \quad (1)$$

Burada;

P= Kırılma yükü (kg)

A= Yüzey alanı (cm²)

Brazilian dolaylı çekme dayanımı (BDÇD) testi için boy/çap oranı 0.5-1.0 arasında olan karot numuneleri kullanılmıştır [24]. Karot örneklerinin boyu ve çapı kumpas yardımıyla belirlenmiştir. Test için kullanılan aparat içerisine yerleştirilerek 3000 kN-ELE otomatik pres ile yenilme anındaki kuvvet belirlenmiştir. Deney sonucunda BDÇD değeri eşitlik 2 kullanılarak hesaplanmıştır.

$$\sigma_c = \frac{2xP}{\pi x D x L} \text{ (kg/cm}^2\text{)} \quad (2)$$

Burada;

σ_c : Brazilian çekme dayanımı, kg/cm²,

P : Yarılma yük değeri, kg,

D : Karot çapı, cm,

L : Karot kalınlığı, cm.

V_p ölçümleri, TS EN 14579 [25] standardına göre Proceq PL-200 pümit ve iki adet 54 kHz dönüştürücü kullanılarak karot numuneler üzerinde gerçekleştirilmiştir. Numunelerin V_p değerleri Eşitlik 3 kullanılarak hesaplanmıştır.

$$V_p = L/T_p \text{ (m/s)} \quad (3)$$

L= örnek boyu (m)

T_p =Geçiş süresi (s)

2.4. Basit Regresyon Analizi

Çalışma kapsamında elde edilen deney sonuçları basit doğrusal regresyon analizine tabi tutulmuştur. Bağımlı değişken (Y) ile bir bağımsız değişken (X) arasındaki ilişkiyi değerlendiren metoda basit regresyon analizi denilmektedir. $Y = a+bX$ biçiminde ifade edilen modele basit doğrusal regresyon denklemi denir. Basit doğrusal regresyonda bağımlı değişken ile bağımsız değişken arasındaki bağıntı Eşitlik 4 kullanılarak ifade edilir [26].

$$Y = X\beta + \varepsilon \quad (4)$$

Bu modelde;

Y: ($n \times 1$) boyutlu bağımlı değişken gözlem vektörü,

X: ($n \times (p+1)$) boyutlu bağımsız değişken gözlem matrisi,

β : ($(p+1) \times 1$) boyutlu katsayılar vektörü,

ε : ($n1$) boyutlu hata vektörüdür.

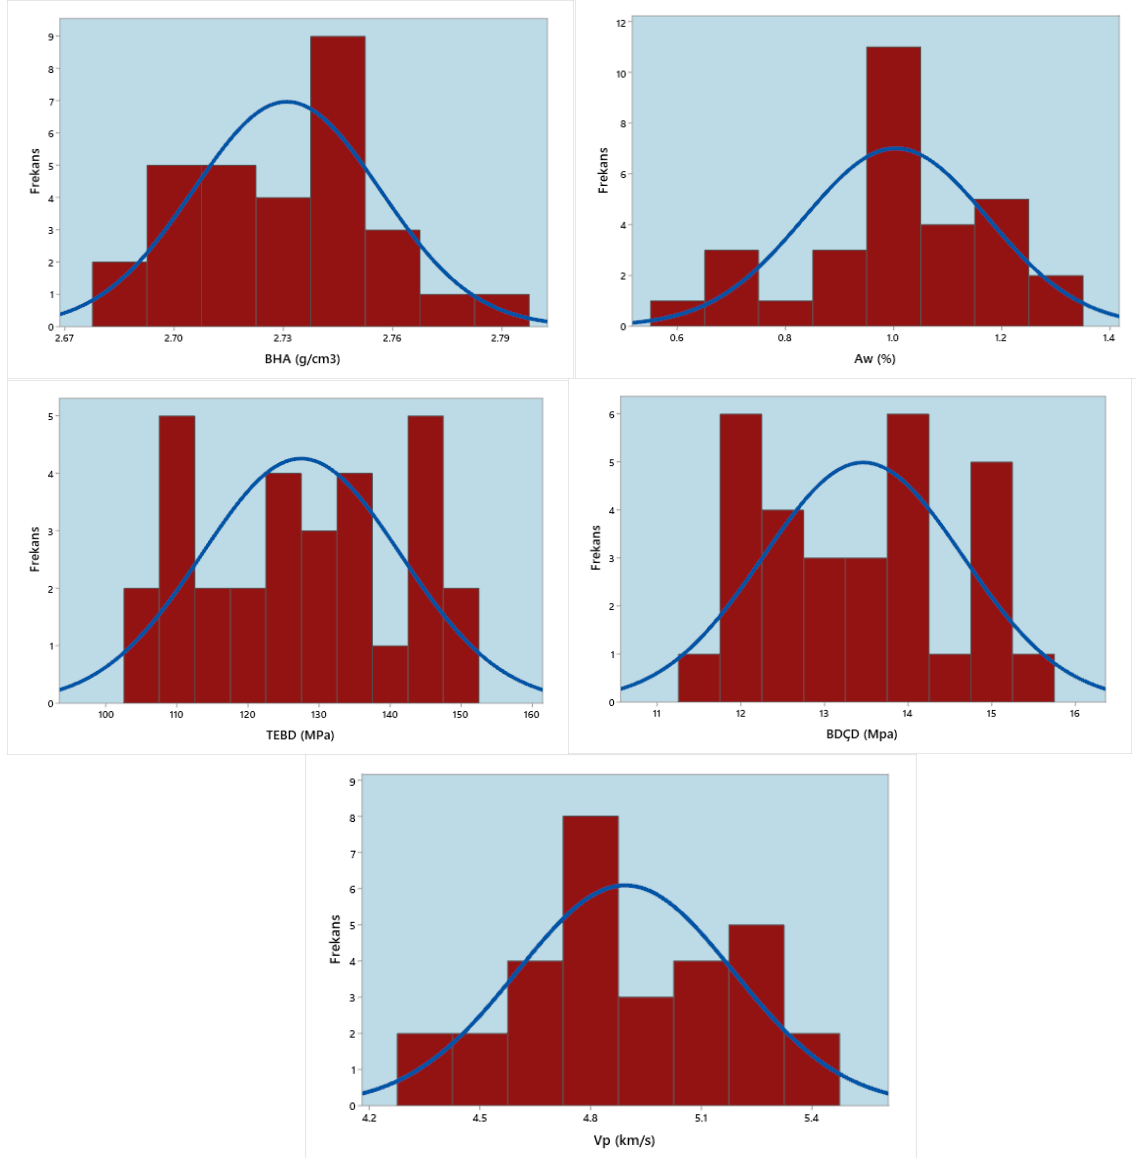
3. BULGULAR

Kayaçların fiziksel ve mekanik özellikleri temel yapıların tasarımı, inşası, duraylılığı ve ömrü açısından önem arz etmektedir. Ayrıca çalışma sırasında gerekli iş ekipman ve makinelerinde gerçekleştirilecek mühendislik çalışmaları öncesinde kayaçların fiziksel ve mekanik özelliklerinin belirlenmesi kazı ekipmanı seçimi değerlendirilirken oldukça etkindir [17].

Çalışma sahasını tam olarak temsil etmesi açısından bölgede 4 farklı lokasyondan blok numune temin edilmiş ve karot örnekleri alınmıştır. Karot numuneleri üzerinde BHA, A_w , TEBD, BDÇD ve V_p deneyleri gerçekleştirilmiş, deney sonuçları değerlendirilerek en yüksek ve en düşük değerler veri setinden çıkarılmış ve her bir deney için toplam 30 değerden oluşan bir veri seti oluşturulmuştur. Deney sonuçlarından elde edilen veri setine ait tanımlayıcı istatistikler Tablo 2’de, histogram grafikleri ise Şekil 3’te verilmiştir.

Tablo 2. Fiziksel ve mekanik test sonuçlarına ait tanımlayıcı istatistikler.


Değişken	Standart Sapma	Minimum	Ortalama	Maksimum	Çarpıklık	Basıklık
BHA (g/cm ³)	0.0257	2.6860	2.7309	2.7893	-0.01	-0.46
A _w (%)	0.1708	0.6460	1.0039	1.2600	-0.58	-0.20
TEBD (MPa)	14.05	105.24	127.47	149.02	0.00	-1.35
BDÇD (Mpa)	1.198	11.560	13.462	15.420	0.14	-1.28
V _p (km/s)	0.2947	4.3367	4.8939	5.4300	-0.07	-0.74

**Şekil 3.** Fiziksel ve mekanik test sonuçlarına ait histogram grafikleri.

Bazaltların kullanım alanlarının değerlendirilmesinde önemli yere sahip olan BHA, Aw, TEBD ve BDÇD parametrelerinde en küçük kareler yöntemi kullanılmıştır. İncelenecek parametreler basit, hızlı ve tahribatsız test yöntemi olan V_p kullanılarak en uygun doğru denklemi korelasyon katsayısı R² ve p değeri incelenerek belirlenmiştir. %70'in altındaki korelasyon katsayıları anlamlı kabul edilmemiştir. Regresyon analizleri Minitab 19 paket programı kullanılarak yapılmıştır. R² ve p değeri değerlendirilerek en uygun modelin lineer model olduğu görülmüştür. Böylelikle korelasyon ile kullanılan özellikler kabaca tahmin edilmiştir.


BHA ve Aw kayaların kullanım alanını belirleyen en önemli fiziksel özellikler arasındadır. Şev stabilitesinde, temel ve kazı çalışmalarında, tahkimat tasarımında, liman dolgularında, balast malzemesi seçiminde kayaların bu fiziksel özelliklerinin belirlenmesi oldukça önemlidir. Ayrıca atmosferik koşullarının değişken ve yeraltı suyunun problem olduğu durumlarda incelenen fiziksel parametreler etkin rol oynamaktadır.

Çalışma kapsamında incelenen bazalt örneklerinin BHA ile V_p arasındaki doğrusal ilişki, tahmin eşitliği ve R² değeri Şekil 4'de verilmiştir.



Şekil 4. Vp ile BHA arasındaki ilişki.

Çalışma kapsamında A_w 'nin V_p ile tahmin edilmesi etüv gibi bazı laboratuvar ekipmanları olmadan ve arazi koşullarında tahribatsız olarak daha pratik ve hızlı bir şekilde belirlenebilecektir. Bazalt örneklerinin A_w ile V_p arasındaki ters doğrusal ilişki, tahmin eşitliği ve R^2 değeri Şekil 5'de verilmiştir.




Şekil 5. Vp ile A_w arasındaki ilişki.


Kayaçların TEBD ve BDÇD testleri için blok numunelerden istenilen ölçülerde karotların hazırlanması oldukça zahmetli ve zaman alıcıdır. Belirlenecek özelliklerin yerinde test yöntemi kullanılarak tahmin edilmesi kayaç özellikleri açısından öngörü sağlayacaktır.

V_p ve TEBD arasındaki ilişki Şekil 6'da gösterilmiştir. Şekil 6'dan anlaşılacağı gibi TEBD değeri V_p değeri ile doğrusal olarak artmaktadır ve elde edilen tahmin denklemi %85.6 korelasyon katsayısı ile şekil üzerinde verilmektedir.

V_p ve BDÇD arasındaki ilişki Şekil 7'de gösterilmiştir. Şekil 7'den anlaşılacağı gibi BDÇD değeri V_p değeri ile doğrusal olarak artmaktadır ve elde edilen tahmin denklemi %81.8 korelasyon katsayısı ile şekil üzerinde verilmektedir.



Şekil 6. Vp ile TEBD arasındaki ilişki.



Şekil 7. Vp ile BDÇD arasındaki ilişki.

4. SONUÇ

İnşaat sektöründe yaygın olarak kullanılan bazaltların fiziko-mekanik özelliklerini tahmin etmek amacıyla 30 farklı bazalt numunesi üzerinde deneyler yapılmıştır. İncelenen bu özellikler bazaltların kullanım alanlarını oldukça etkilemektedir ve bu özelliklerin tahribatsız yöntem olan Vp ile tahmini pratik olarak kullanılabilir. Yapılan regresyon analizi sonucunda aşağıdaki sonuçlara ulaşılmıştır.

- Vp bazaltların BHA, Wa, TEBD ve BDÇD'nin tahmini için iyi bir göstergedir ve aralarında doğrusal bir ilişki vardır.
- BHA kayaçların ağırlığının boşluklu hacmine oranıdır ve kullanım alanlarının belirlenmesinde önemli bir parametredir. Vp ile BHA arasında yüksek korelasyon katsayısına ($R^2=76.8$) sahip doğrusal bir ilişki vardır. Çalışma sahasına ait bazaltlarda BHA değerleri elde edilen eşitlik kullanılarak tahmin edilebilir.
- Aw kayaçların ayrışmasına sebep olan önemli parametrelerdendir. Özellikle deniz, baraj gibi suya temas eden yapılarda kullanılan bazaltların Aw değerinin belirlenmesi gerekmektedir. Vp ile Aw arasında yüksek korelasyon katsayısına ($R^2=73.2$) sahip ters doğrusal bir ilişki vardır. Çalışma sahasına ait bazaltlarda Aw değerleri elde edilen eşitlik kullanılarak tahmin edilebilir.

- TEBD ve BDÇD kayaçların en önemli mekanik özelliklerindedir. Çalışma bölgesindeki bazaltların bu TEBD ve BDÇD arasında doğrusal ve yüksek korelasyona sahip (TEBD için R^2 : 85.6 ve BDÇD için R^2 : 81.8) ilişki vardır. Elde edilen eşitlikler kullanılarak bazaltların incelenen mekanik özellikleri tahmin edilebilir.
- Çalışma sahasından elde edilen bazaltların V_p değeri ile elde edilen korelasyonlar fiziksel özelliklerin tahmininde biraz daha düşüktür. Fakat mekanik özelliklerden elde edilen korelasyon katsayılarının daha yüksek olduğu görülmüştür.
- Çalışma sonucunda elde edilen eşitlikler bölgede ilerlemekte olan sanayi çalışmaları ile birlikte yapım çalışmalarına başlanacak ve devam etmekte olan kıyı yapıları için bölge bazaltların değerlendirilmesine hızlı ve pratik şekilde katkı sağlayacaktır.

Yazar Katkıları

Yazar çalışmaya eşit oranlı katkı sunmuştur.

Çıkar Çatışması

Yazar çıkar çatışması bildirmemiştir.

KAYNAKÇA

- [1] A. E. Kahveci, and A. Kadayıfçı, “Diyarbakır yöresi bazalt taşının yapısal özelliklerinin incelenmesi”, Uluslararası Teknolojik Bilimler Dergisi, vol. 5, no. 3, pp. 56-69, 2013.
- [2] Y. Erkan, “Magmatik petrografi”, Hacettepe Üniversitesi Mühendislik Fakültesi Jeoloji Mühendislik Bölümü Raporu 44s. Ankara, 1995.
- [3] Ö. Keskin and A. M. Kılıç. “Doğu Akdeniz yöresi bazaltlarının kırmataş olarak değerlendirilme olanakları”, III Ulusal Kırmataş Sempozyumu, pp. 152-157, 2003.
- [4] A. Orhan, A. K. Namık, A. Erensoy, and Ç. E. K. Nurettin, “Betonda bazalt agreganın kullanımı ve özellikleri”, Avrupa Bilim ve Teknoloji Dergisi, vol. 19, pp. 524-532, 2020.
- [5] E. Kahraman, and N. Yapıcı “Kurtpınar (Ceyhan) bazaltlarının demiryolu balastı olarak kullanımının değerlendirilmesi”, Demiryolu Mühendisliği, vol. 16, pp. 14-22, 2022.
- [6] S. Erişiş, A. Tuğrul, E. R. Selman, and M. Yılmaz, “Bazaltik kayaların bileşim ve dokusal özelliklerinin mekanik davranışlarına etkisi”, Jeoloji Mühendisliği Dergisi, vol. 43, no. 2, pp. 259-278, 2019.
- [7] C. Karpuz, and A. G. Paşamehmetoğlu, “Field characterization of weathered Ankara andesites”, Engineering Geology, vol. 46, pp. 1 – 17, 1997.
- [8] J. A. Hudson, E. J. W. Jones, and B. M. New, “P-wave velocity measurements in a machine-bored, chalk tunnel”, Quarterly Journal of Engineering Geology and Hydrogeology, vol. 13, no. 1, pp. 33-43, 1980.
- [9] M. T. Gladwin, “Ultrasonic stress monitoring in underground mining”, In International Journal of Rock Mechanics and Mining Sciences and Geomechanics Abstracts, vol. 19, no. 5, pp. 221-228, 1982.
- [10] N. Turk, W. R. A. Dearman, “A suggested approach to rock characterization in terms of seismic velocities”, In The 27th US Symposium on Rock Mechanics (USRMS), OnePetro, 1986.
- [11] F. K. Boadu, “Fractured rock mass characterization parameters and seismic properties: Analytical studies”, Journal of Applied Geophysics, vol. 37, no. 1, pp. 1-19, 1997.
- [12] A. Karakus, and M. Akatay, “Determination of basic physical and mechanical properties of basaltic rocks from P-wave velocity”, Nondestructive Testing and Evaluation, vol. 28, pp. 342–353, 2013.
- [13] M. Khandelwal, and P. G. Ranjith, “Correlating index properties of rocks with P-wave measurements”, Journal of Applied Geophysics, vol. 71, pp. 1 –5, 2010.
- [14] A. Tuğrul, and I. H. Zarif, “Correlation of mineralogical and textural characteristics with engineering properties of selected granitic rocks from Turkey”, Engineering Geology, vol. 51, pp. 303–317, 1999.
- [15] P. K. Sharma, and T. N. Singh, “A correlation between P wave velocity, impact strength index, slake durability index and uniaxial compressive strength”, Bulletin of Engineering Geology and the Environment, vol. 67, pp. 17–22, 2008.
- [16] A. Azimian, and R. Ajalloeian, “Empirical correlation of physical and mechanical properties of marly rocks with P wave velocity”, Arabian Journal of Geoscience, vol. 8, no. 4, pp. 2069-2079, 2015.
- [17] R. Kallu, and P. Roghanchi, “Correlations between direct and indirect strength test methods” International Journal of Mining Science Technology, vol. 25, no. 3, pp. 355-360, 2015.
- [18] A. Kılıç, and A. Teymen, “Determination of mechanical properties of rocks using simple methods”, Bulletin of Engineering Geology and the Environment, vol. 67, no. 2, pp. 237-244, 2008.
- [19] M. Khandelwal, “Correlating P-Wave Velocity with the Physico-Mechanical Properties of Different Rocks, Pure Appl”, Geophys, vol. 170, no. 4, pp. 507-514, 2013.
- [20] S. Yagiz, “P-wave velocity test for assessment of geotechnical properties of some rock materials”, Bulletin of Materials Science, vol. 34, pp. 947 – 953, 2011.

- [21] ISRM (2007), "Suggested methods prepared by the commission on testing methods", International society for rock mechanics, compilation arranged by the ISRM Turkish National Group Ankara, Turkey, 628 p.
- [22] TS EN 1097-6, "Agregaların mekanik ve fiziksel özellikleri için deneyler-bölüm 6: Tane yoğunluğunun ve su emme oranının tayini", TSE, Ankara, 2013.
- [23] TS EN 1926, "Doğal taşlar- Deney metotları- Basınç dayanımı tayini", TSE, Ankara, 2007.
- [24] TS 7654, "Kayaçların çekme mukavemetinin dolaylı (indirekt) metotla tayini" TSE, Ankara, 1989.
- [25] TS EN 14579, "Doğal taşlar-Deney yöntemleri-Ses hızı ilerlemesinin tayini", TSE, Ankara, 2006.
- [26] B. Biçkici, "Çok değişkenli varyans analizi ve çoklu doğrusal regresyon analizinin uygulamalı olarak karşılaştırılması", Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Yüksek lisans tezi, Erzurum. 54 p., 2007.



Yüksek Boyutlu Nümerik Optimizasyon Problemlerinin Çözümünde Kelebek Optimizasyon Algoritmasının Performansının Değerlendirilmesi

Evaluation of The Performance of Butterfly Optimization Algorithm in Solving High-Dimensional Numerical Optimization Problems

¹Ceren BAŞTEMUR KAYA , ²Ebubekir KAYA 

¹Nevşehir Hacı Bektaş Veli Üniversitesi, Bilgisayar Teknolojileri Bölümü, Merkez/Nevşehir, Türkiye

²Nevşehir Hacı Bektaş Veli Üniversitesi, Bilgisayar Mühendisliği Bölümü, Merkez/Nevşehir, Türkiye

¹ceren@nevsehir.edu.tr, ²ebubekir@nevsehir.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 5 September 2022

Accepted : 16 October 2022

Keywords:

Butterfly Optimization Algorithm, High-Dimensional Problems, Global Optimization, Metaheuristic Algorithms

ABSTRACT

The butterfly optimization algorithm is one of the metaheuristic algorithms that models the foraging behavior of butterflies. It appears in the literature that it has been used successfully in the solution of many problems. Control parameters and dimension of problem directly affect the performance of a metaheuristic algorithm. When possible, problems are evaluated, some may be low-dimensional, while others may be high-dimensional. At the same time, it is expected that metaheuristic algorithms are successful on high-dimensional problems as well. In this study, the performance of the butterfly optimization algorithm is evaluated in solving high-dimensional numerical optimization problems. The performance of butterfly optimization algorithm is compared with artificial bee colony algorithm, harmony search and flower pollination algorithm. Wilcoxon signed-rank test is used to analyze the significance of the results. The results show that the butterfly optimization algorithm is generally more successful than other algorithms in solving high-dimensional numerical optimization problems.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 5 Eylül 2022

Kabul : 16 Ekim 2022

Anahtar Kelimeler:

Kelebek Optimizasyon Algoritması, Yüksek Boyutlu Problemler, Global Optimizasyon, Meta-Sezgisel Algoritmalar

ÖZET

Kelebek optimizasyon algoritması, kelebeklerin yiyecek arama davranışını modelleyen güncel meta-sezgisel algoritmalarından biridir. Pek çok problemin çözümünde başarılı bir şekilde kullanıldığı literatürde görülmektedir. Bir meta sezgisel algoritmanın başarısını, kontrol parametreleri ve problem boyutu doğrudan etkilemektedir. Muhtemel problemler değerlendirildiğinde, bazıları düşük boyutlu iken, bazıları yüksek boyutlu olabilmektedir. Bununla birlikte, meta-sezgisel algoritmaların yüksek boyutlu problemler üzerinde de başarılı olması beklenmektedir. Bu çalışmada, yüksek boyutlu nümerik optimizasyon problemlerinin çözümünde kelebek optimizasyon algoritmasının performansı değerlendirilmiştir. Kelebek optimizasyon algoritması; yapay arı koloni algoritması, armoni arama algoritması ve çiçek tozlaşma algoritması ile karşılaştırılmıştır. Sonuçların anlamlılığının analizi için Wilcoxon işaretli sıralar testi uygulanmıştır. Sonuçlar, çok boyutlu nümerik optimizasyon problemlerinin çözümünde, kelebek optimizasyon algoritmasının diğer algoritmalarından genel olarak daha başarılı olduğunu göstermiştir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Gerçek dünya karmaşık, çok yönlü, kısa zamanda en iyi sonuçların elde edilebileceği çözüm yöntemlerine ihtiyaç duyan problemler içermektedir. Bu ihtiyaç doğrultusunda karmaşık problemleri gerçek zamanlı çözebilen algoritmalar geliştirilmiştir [1]. Özellikle doğadan ilham alan meta-sezgisel yöntemler performans açısından iyi sonuçlar vermektedir [2]. Her meta-sezgisel algoritma, iyi bilinen bir doğal olayı modellemeye çalışır ve modelini optimizasyon problemlerini çözmek için uygular. Meta-sezgisel algoritmaları; evrimsel, sürü zekası tabanlı, fizik tabanlı ve insan tabanlı olarak dört başlık altında gruplandırmak mümkündür [3]. Doğadaki canlıların yiyecek arama, eş seçme ve hayatta kalmak için sergiledikleri davranışlar incelendiğinde bazı zeki yaklaşımlar olduğu görülmektedir. Bu yaklaşımlar meta-sezgisel algoritmalara dönüştürüldüğünde, gerçek dünya problemlerini çözmeye çok iyi sonuçlar verdikleri görülmüştür [4]. Özellikle endüstriyel ve bilimsel çalışmalar için karmaşık optimizasyon problemlerinin çözümü büyük önem arz etmektedir. Bu algoritmalar optimum çözüme yakınsayabilir ve kısa sürede etkili çözümler üretebilir [5]. Bu durum meta-sezgisel algoritmaların yoğun bir şekilde kullanılmasının önemli sebeplerinden biridir ve pek çok alandaki optimizasyon problemlerinin çözümünde kullanılmaktadırlar [6,7].

Literatür incelendiğinde farklı davranışların modellendiği birçok meta-sezgisel algoritmaya rastlamak mümkündür. Yapay Arı Kolonisi (Artificial Bee Colony-ABC) [8], Genetik Algoritma (Genetic Algorithm-GA) [9], Karınca Koloni Optimizasyonu (Ant Colony Optimization-ACO) [10], Parçacık Sürü Optimizasyonu (Particle Swarm Optimization-PSO) [11], Yapay Bağışıklık Sistemi (Artificial Immune System-AIS) [12] popüler olan meta-sezgisel algoritmalarından bazılarıdır.

Doğadan ilham alan meta-sezgisel yöntemlerden biri de kelebek optimizasyon algoritmasıdır (Butterfly Optimization Algorithm-BOA). BOA kelebeklerin yiyecek arama ve eş seçme davranışlarını temel almaktadır. Kelebekler nektar vb. yiyecekleri ararken veya eş seçme için partnerin yerini belirlerken koku duyarını kullanmaktadır. Bu strateji esas alınarak algoritma geliştirilmiştir [13]. Bu algoritma yeni geliştirilmiş olmasına rağmen kısa sürede pek çok gerçek dünya probleminin çözümünde kullanıldığı görülmektedir ve bu çalışmalardan bazıları literatür bölümünde sunulmuştur. Meta-sezgisel algoritmalara ait kontrol parametreleri ve problem boyutu performansı etkileyen önemli hususlardandır. Özellikle gerçek dünyadaki problemler düşük veya yüksek boyutlu olabilmektedirler. BOA açısından bakıldığında; düşük boyutlu problemlerin çözümü üzerine pek çok çalışma bulunmasına rağmen yüksek boyutlu problemler açısından sınırlı sayıda çalışma olduğu görülmektedir. Literatürde BOA'nın yüksek boyutlu nümerik optimizasyon problemlerinin çözümüne yönelik çalışmanın olmayışı bu çalışmayı yenilikçi kılmaktadır. Bu çalışma kapsamında, gelecekte yapılacak çalışmalara yol göstermek amacıyla, yüksek boyutlu nümerik optimizasyon problemlerinin çözümünde BOA'nın performansı değerlendirilmiştir. Bununla birlikte, ilgili problemlerin çözümü için daha etkili olabilecek kontrol parametre değerlerinin tespitine yönelik uygulamalar gerçekleştirilmiştir. Ayrıca, BOA'nın performansı, literatürdeki popüler bazı meta-sezgisel algoritmalarla karşılaştırılmıştır.

Bu çalışmanın ilerleyen bölümleri şu şekilde organize edilmiştir: 2. bölümde literatür çalışması verilmiştir. 3. bölümde BOA'nın detayları anlatılmıştır. 4. bölümde simülasyon sonuçları sunulmuştur. Son bölümde ise tartışma ve sonuca yer verilmiştir.

2. LİTERATÜR ÇALIŞMASI

Yıldız ve ark. [14] BOA'yı otomotiv endüstrisinde kullanmıştır. Çalışmada bileşenlerin bağlantıları, şekilleri, ağırlıkları vb. özelliklerinde çalışılmış ve BOA'nın optimum bileşen tasarlamasında yararlı olduğu vurgulanmıştır. Tubishat ve ark. [15] makine öğreniminde BOA'nın geliştirilen bir versiyonu olan dinamik BOA'yı önermişlerdir. UCI deposundan alınan 20 veri seti kullanılarak GA, çekirge optimizasyon algoritması (Grasshopper Optimization Algorithm-GOA), PSO, karınca aslanı optimizasyonu (Antlion Optimization Algorithm-AOA), sinüs kosinüs algoritması (Sine Cosine Algorithm-SCA), BOA ve dinamik BOA'nın sonuçları karşılaştırılmıştır. Sınıflandırma doğruluğu, uygunluk değerleri, seçilen özneliklerin sayısı, istatistiksel sonuçlar ve yakınsama eğrileri gibi ölçütlerinin çoğunda dinamik BOA'nın daha iyi performans gösterdiği belirtilmiştir.

Arora ve ark. [16] mekanik tasarım optimizasyon problemlerini çözmek amacıyla modifiye edilmiş BOA'yı önermişlerdir. 15 test fonksiyonu ve 3 mühendislik tasarım problemi ile algoritmayı doğrulamışlardır. BOA, PSO, kovaryans matris adaptasyonu evrim stratejisi, ateşböceği algoritması (Firefly Algorithm-FA), uyarlanabilir diferansiyel evrim algoritması (Differential Evolution Algorithm-DEA), N-M SDSA ve Q-N LSA sonuçları karşılaştırılmış ve modifiye edilmiş BOA'nın rekabetçi sonuçlar ortaya koyduğu ifade edilmiştir.

Arora ve Singh [17] BOA uygulaması kullanan düğüm lokalizasyon şeması önermiştir. Önerdikleri şemanın performansı ile PSO ve FA şemalarının performansını karşılaştırmışlardır. BOA uygulaması kullanan şemanın daha doğru ve tutarlı konum gösterdiğini belirtmişlerdir.

Arora ve Singh [18] BOA'nın performansını arttırmak amacıyla 10 kaotik harita kullanmıştır. Önerdikleri kaotik kelebek optimizasyon algoritmalarını tek modlu ve çok modlu test fonksiyonlarında ve mühendislik tasarım problemlerinde doğrulamışlardır. Kaotik haritaların performansı önemli ölçüde arttırabildiğini ifade etmişlerdir.

Sharma [19] BOA'nın yeni bir varyantı olan çift yönlü BOA'yı önermiştir. Farklı kıyaslama problemlerinde algoritmanın performansını değerlendirmişlerdir. GA, PSO, DEA, BOA ve önerilen çift yönlü BOA ait sonuçlar kıyaslanmış ve önerilen varyantın rekabetçi sonuçlar gösterdiği belirtilmiştir.

Mortazavi ve Moloodpoor [20] BOA'nın kapasitesini geliştirmek amacıyla sanal kelebek adı verilen yardımcı bir kavramı ele alarak, modifiye bir versiyon olan bulanık BOA'yı önermişlerdir. Önerilen BOA yaklaşımı, standart BOA da dahil olmak üzere bazı algoritmalarla karşılaştırılmıştır. Sonuç olarak geliştirilen versiyon ile BOA'nın arama kabiliyetinin geliştirildiği vurgulanmıştır.

Sharma ve ark. [21] BOA'nın keşif yeteneği ile simbiyotik organizmalar arama algoritmasının problem çözme avantajlarını birleştirerek kombinatoriyal optimizasyon yaklaşımını tanıtmışlardır. İlgili yaklaşımın performansını, bazı optimizasyon algoritmaları ile karşılaştırmışlardır. Sonuçlarda önerilen yöntemin daha üstün ve güvenilir olduğunu belirtmişlerdir.

Arora ve Singh [22] BOA'yı yerel optimumda çalışmasının daha etkili olmasını ve doğruluk seviyesinin artırılmasını sağlayacak şekilde geliştirmişlerdir. Geliştirilen versiyon bazı problemlere uygulanmıştır. ABC algoritması, FA ve PSO ile performansını karşılaştırmışlardır. Sonuçlar incelendiğinde önerilen versiyonun çözüme ulaşması ve yakınsama oranının daha iyi olduğunu ifade etmişlerdir.

Jalali ve ark. [23] yapay sinir ağı ve BOA'nın birleşimine dayalı olan sınıflandırma yöntemi kullandı. İyi bilinen iki veri seti kullanılarak farklı yöntemlerle önerilen sınıflandırma yöntemini karşılaştırmışlardır. Deneysel sonuçlar incelendiğinde diğer yöntemlere üstünlük sağlandığı vurgulanmıştır.

Sharma ve ark. [24] yakınsamayı geliştirmek amacıyla çift yönlü arama yapılan BOA'yı önermiştir. Üç gerçek dünya problemi ve yedi tek modlu problem ele alınarak önerilen algoritmanın performansı değerlendirilmiştir.

3. KELEBEK OPTİMİZASYON ALGORİTMASI

Kelebekler koku, görme, tat alma, dokunma ve işitme duyularını kullanarak hayati fonksiyonlarını sürdürürler. Başta yiyecek ve eş seçme için partner bulma olmak üzere, göç etmede, tehlikelerden kaçmada ve yumurtlama için uygun yer bulmada bu duyularından yararlanırlar. Ancak duyularının içinde koku en önemli olanıdır [25]. Koku almak için kullandıkları duyu alıcıları anten, bacak, el parmakları vb. uzuvlarında bulunmaktadır. Duyu alıcıları kemoreseptör olarak adlandırılan vücut yüzeyindeki sinir hücreleridir [26]. Kemoreseptör sayesinde nektarın kaynağını bulabilirler. Ayrıca kemoreseptörler güçlü genetik yapılarını sürdürmek amacıyla en iyi çiftleme partneri bulma konusunda rehberlik ederler. Dişi kelebeğin yaydığı koku salgısı feromondur. Erkek kelebek feromon sayesinde dişiyi tanımlayabilir.

BOA'da kelebekler arama araçlarıdır. Bir kelebek uygunluk durumuna bağlı olarak koku üretecektir. Uygunluk bir konumdan başka bir konuma geçme durumuna göre değişmektedir. Mesafe boyunca kelebek koku yayar ve diğer kelebekler bu kokuyu hissedebilir, başka kelebeklerle paylaşabilir. Böylece kolektif bir sosyal bilgi ağı oluşturulabilir. BOA'da bir kelebeğin başka bir kelebeğin kokusunu aldığı anda ona doğru hareket etmesi global arama olarak adlandırılmaktadır. Bir kelebeğin koku algılamadığında rastgele hareket etmesi ise yerel arama olarak adlandırılır [13].

Kelebeğin yaydığı her kokunun kendine özgü yapısı vardır. Ses, ışık, sıcaklık vb. bir uyarıcı/yöntem tarafından koku etkilenebilir. BOA'da algılama yöntemi; duyu modalite (c), uyarıcı yoğunluğu (I) ve güç katsayısı (a) parametrelerine dayanmaktadır. Duyusal modalitede (c), algılayıcılar tarafından kullanılan ham girdi kullanılır. Duyusal enerji ölçülür ve aynı şekilde işlenir. Buradaki farklı yöntemler ses, ışık, sıcaklık, koku olabilir. BOA'da yöntem kokunun algılanan büyüklüğüdür (f). Uyarıcı yoğunluğu (I) uyarıcının büyüklüğünü ifade eder. Güç katsayısı (a) ise yoğunluğun yükseltildiği katsayıdır. a parametresi düzenli ifadeye, doğrusal tepkiye ve tepki sıkışmasına izin verir. Tepki genişlemesinde I artarsa; f, I'dan daha hızlı artar. Tepki sıkışmasında I arttığında; f, I'dan daha yavaş artar. Doğrusal tepkide I arttığında; f orantılı olarak artar. BOA'da I'nın büyüklüğünü takip etmek için tepki sıkışması kullanılır [13, 17, 27, 28].

Kelebeklerin doğal varlığı I'nın varyasyonuna ve f'nin formülasyonuna dayanmaktadır. Kokuyu diğer yöntemlerden ayırt etmek için c kullanılır. Daha az I'lı kelebek, daha çok I'lı kelebeğe hareket ettikçe; f, I'dan daha hızlı artar. Bu yüzden f'nin a ile elde edilen bir absorpsiyon derecesi ile değişmesine izin verilir [13].

$$f = cI^a \quad (1)$$

Uygulamadaki durumların çoğunda a ve c [0, 1] aralığında alınabilir. a=1 olması durumu kokunun idealize edilmiş bir ortamda yayıldığını gösterir. a=0 ise, herhangi bir kelebeğin yaydığı kokunun diğer kelebekler tarafından hiç hissedilemeyeceği anlamına gelir. Teorik olarak c ∈ [0,∞]'dir. c optimizes edilecek sistemin karakteristiği ile belirlenir. a ve c değerleri, algoritmanın yakınsama hızını önemli ölçüde etkiler [13].

BOA'da üç aşama bulunmaktadır: (1) başlatma aşaması, (2) iterasyon aşaması ve (3) son aşamadır. BOA'nın her çalışmasında, önce başlatma aşaması yürütülür, ardından tekrarlamalı bir şekilde arama yapılır ve son aşamada en iyi çözüm bulunduğu anda algoritma sonlandırılır. Başlatma aşamasında algoritmanın tarafsız fonksiyonu ve çözüm aralığı tanımlanır. Parametre değerleri atanır. Sonrasında optimizasyon için ilk kelebek popülasyonu oluşturulur. Kelebeklerin konumları, koku ve uygunluk değerleri ile birlikte arama aralığında rastgele oluşturulur. İterasyon aşamasında oluşturulan yapay kelebeklerle arama başlatılır. Her iterasyonda çözüm aralığındaki kelebekler yeni pozisyonlara hareket eder ve uygunluk değerleri değerlendirilir. Algoritmada önce çözüm aralığındaki tüm kelebeklerin uygunluk değerleri hesaplanır. Sonrasında kelebekler Denklem 1 kullanılarak koku üretir. Algoritma

global arama ve yerel arama adımlarını içerisinde barındırır. Global arama aşamasında Denklem 2 kullanılarak en uygun çözüm bulunur [13].

$$x_i^{t+1} = x_i^t + (r^2 \times g^* - x_i^t) \times f_i \quad (2)$$

Burada x_i^t 'de, t iterasyon sayısındaki i'inci kelebek için çözüm vektörü x_i^t 'dir. g^* , mevcut iterasyondaki tüm çözümler arasında bulunan mevcut en iyi çözümü temsil eder. i'inci kelebeğin kokusu f_i ile temsil edilir ve r, [0, 1] aralığında rastgele bir sayıdır. Yerel arama aşaması şu şekilde temsil edilebilir:

$$x_i^{t+1} = x_i^t + (r^2 \times x_j^t - x_k^t) \times f_i \quad (3)$$

Burada x_j^t ve x_k^t , çözüm uzayından j'inci ve k'inci kelebekleridir. x_j^t ve x_k^t aynı kümeye aitse ve r [0, 1] aralığında rastgele bir sayıysa, Denklem 3 ile yerel rastgele gezinti yapılır. BOA'da ortak global arama ile yoğun yerel arama arasında geçiş yapmak için bir değiştirme (anahtarlama) olasılığı p kullanılır. Durdurma kriterlerine ulaşıncaya kadar iterasyon aşamasına devam edilir. Durdurma kriterleri; kullanılan maksimum CPU süresi, ulaşılan maksimum iterasyon sayısı, iyileştirme yapılmayan maksimum iterasyon sayısı, belirli bir hata oranı değerine ulaşılması veya diğer uygun kriterler gibi farklı şekillerde tanımlanabilir. İterasyon aşaması sona erdiğinde, algoritma en iyi uygunluk değeri ile bulunan en iyi çözümü verir [13].

BOA'nın algoritmik yapısı Algoritma 1'de sunulmuştur.

Algoritma 1. Kelebek optimizasyon algoritması [13]

1. Uygunluk fonksiyonu $f(\mathbf{x})$, $\mathbf{x}=(x_1, x_2, \dots, x_{dim})$, dim=boyut parametrelerini belirle
 2. n kelebeğin başlangıç popülasyonu oluştur $x_i=(i=1, 2, \dots, n)$
 3. x_i 'deki uyaran yoğunluğu I_i , $f(x_i)$ kullanarak belirle
 4. Sensör modalitesi c'yi, güç katsayısı a'yı ve değiştirme (anahtarlama) olasılığı p'yi tanımla
 5. **while** durdurma kriteri karşılanmadı **do**
 6. **for each** popülasyondaki her bf kelebeği için **do**
 7. Denklem 1 kullanarak bf için koku hesapla
 8. **end for**
 9. En iyi bf'yi bul
 10. **for** popülasyondaki her bf kelebeği için **do**
 11. [0,1] arasında rastgele bir r sayısını üret
 12. **if** $r < p$ **then**
 13. Denklem 2'yi kullanarak en iyi kelebeğe/çözüme doğru ilerle
 14. **else**
 15. Denklem 3'ü kullanarak rastgele hareket et
 16. **end if**
 17. **end for**
 18. a'nın değerini güncelle
 19. **end while**
-

4. SİMÜLASYON SONUÇLARI

Çok boyutlu nümerik optimizasyon problemi çözümünde BOA'nın performansı değerlendirilmiştir. Uygulamalarda Tablo 1'de verilen ve literatürde yoğun bir şekilde kullanılan klasik test fonksiyonları üzerinde çalışılmıştır. Verilen yedi test fonksiyonundan beş tanesi tek modlu (U- unimodal), iki tanesi ise çok modlu (M-multi-modal) 'dur. Tüm test fonksiyonlarının global minimum değeri sıfırdır. Problem boyutu 100, 200 ve 300 için analizler gerçekleştirilmiştir. Bilindiği üzere popülasyon büyüklüğü ve jenerasyon sayısı performansı etkileyen kriterlerdendir. Bu yüzden uygulamalarda popülasyon büyüklüğü olarak 10, 20 ve 50 için sonuçlar elde edilmiştir. Bu popülasyon büyüklükleri için uygulanan maksimum jenerasyon sayıları sırasıyla 2000, 1000 ve 400'dür. İstatistiksel sonuçların elde edilebilmesi ve sonuçların güvenilirliği açısından her uygulama 30 kere çalıştırılmıştır ve ortalama uygunluk değerleri (f) elde edilmiştir. Bununla birlikte, 30 kere çalıştırma sonuçları kullanılarak standart sapma (σ) değerleri de hesaplanmıştır.

Tablo 2'de problem boyutu 100 için BOA ile elde edilen sonuçlar verilmiştir. F1, F2, F3, F5 ve F6 problemlerinde en iyi uygunluk değeri n değeri 10 olduğu zaman elde edilmiştir. Bu test fonksiyonlarında popülasyon sayısı azaldıkça, daha etkili uygunluk değerleri elde edilmiştir. F4 probleminde tüm popülasyon büyüklükleri için 0 (sıfır) değerine ulaşılmıştır. F7 probleminde en başarılı sonuç n değeri 20 olduğu zaman bulunmuştur. Bununla birlikte n değeri 50 olduğu zaman elde edilen sonuçta oldukça başarılıdır.

Tablo 3'de problem boyutu 200 için BOA ile elde edilen sonuçlar sunulmuştur. d değeri 200 olduğunda F1, F2, F3, F5 ve F6 problemleri için en iyi sonuçlar n değerinin 10 olması durumunda bulunmuştur. F4 probleminde tüm popülasyon büyüklükleri için 0 (sıfır) değeri elde edilmiştir. F7 probleminde en başarılı sonuca n değeri 50 olduğu zaman ulaşılmıştır.

Tablo 4'de problem boyutunun 300 olması durumunda BOA ile elde edilen sonuçlar verilmiştir. d değerinin 100 ve 200 olması durumunda F1, F2, F3, F5 ve F6 problemlerinde olduğu gibi en başarılı sonuca n değeri 10 olduğu

zaman ulaşılmıştır. F4 probleminde tüm popülasyon büyüklükleri için 0 (sıfır) değeri bulunmuştur. F7 probleminde n değeri 50 olduğu zaman en iyi uygunluk değerine ulaşılmıştır. Tablo 2, 3 ve 4 genel olarak değerlendirildiğinde f değerlerinin kabul edilebilir olduğu görülmektedir. Buradaki f değeri, 30 çalıştırmaya ait ortalama uygunluk değeridir. f, tüm çalıştırma sonuçları hakkında genel bilgi vermektedir. Sonuçların f değerine yakın ve uzaklığını analiz etmek için σ değerine bakılmalıdır. Çoğunlukla tüm problemlerde, farklı popülasyon büyüklükleri ve farklı problem boyutları için bulunan σ değerlerinin f değerinden daha küçük olduğu görülmektedir. Bu durum 30 çalıştırmadaki her bir uygunluk değerinin ortalama uygunluk değerine yakın olduğunu göstermektedir. Yani, çoğunlukla benzer sonuçlar çıkmaktadır. Bu durum algoritmanın gürbüz (robust) olduğunun bir işaretidir.

Tablo 1. Uygulamalarda kullanılan test problemleri.

Fonksiyon No	Arama Aralığı	Fonksiyon Adı	Formül	Global Minimum	Tür
F1	[-10,10]	Sphere	$f(x) = \sum_{i=1}^n x_i^2$	0	U
F2	[-10,10]	High conditioned elliptic	$f(x) = \sum_{i=1}^n (10^6)^{i-1} x_i^2$	0	U
F3	[-10,10]	Ackley	$f(x) = -20 \exp \left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right) - \exp \left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i) \right) + 20 + e$	0	M
F4	[-100,100]	Step	$f(x) = \sum_{i=1}^n (x_i + 0.5)^2$	0	U
F5	[-1,1]	Sum of Different Powers	$f(x) = \sum_{i=1}^n x_i ^{i+1}$	0	U
F6	[-10,10]	Sum Squares	$f(x) = \sum_{i=1}^n i x_i^2$	0	U
F7	[-5,5]	Levy	$f(x) = \sin^2(\pi w_1) + \sum_{i=1}^{n-1} (w_i - 1)^2 [1 + 10 \sin^2(\pi w_i + 1)] + (w_d - 1)^2 + [1 + \sin^2(2\pi w_d)]$ $w_i = 1 + \frac{x_i - 1}{4}$	0	M

Problem boyutu 100, 200 ve 300 ile elde edilen sonuçlar ABC algoritması, FPA ve HS ile karşılaştırılmıştır. ABC algoritmasının “Limit” kontrol parametresinin değeri (popülasyon büyüklüğü x problem boyutu)/2 alınmıştır. HS’nin PAR ve HMCR kontrol parametre değerleri sırasıyla 0.3 ve 0.95’dir. FPA’nın değişim olasılığı (switch probability) ise 0.8 alınmıştır. İlgili meta-sezgisel algoritmalar ile elde edilen sonuçlar sırayla Tablo 5, Tablo 6 ve Tablo 7’de verilmiştir. Tüm algoritmalar için koloni büyüklüğü ve maksimum jenerasyon sayısı sırasıyla 10 ve 2000 alınmıştır. İstatiksel analizlerin gerçekleştirilebilmesi için her uygulama 30 kere çalıştırılmış ve ortalama uygunluk değeri hesaplanmıştır. Tablolarda yer alan uygunluk değerleri 30 çalıştırmaya ait ortalama değerlerdir. F1, F2, F3, F4, F5 ve F6 problemlerinde en iyi sonuç BOA ile elde edilmiştir. BOA’dan sonra ise en iyi sonuç ABC algoritması ile bulunmuştur. F7 probleminde ise en iyi sonuca ABC algoritması ile ulaşılmıştır. ABC algoritmasından sonra en iyi sonuç BOA’ya aittir.

Elde edilen sonuçların istatistiksel olarak anlamlılığını belirlemek için Wilcoxon işaretli sıra testi uygulanmıştır. F7 dışındaki tüm örneklerde p=0.000 sonucu elde edilmiştir. Bu durum F7 dışındaki tüm problemlerde BOA’nın diğer algoritmalarından anlamlı olarak başarılı olduğunu göstermektedir. F7 probleminde ise ABC algoritması lehine anlamlı sonuçlar bulunmuştur. F7 probleminde ABC algoritması dışındaki sonuçlarda; BOA’nın FPA ve HS’ye göre istatistiksel olarak anlamlı sonuçlara sahip olduğu tespit edilmiştir.

Tablo 2. BOA ile elde edilen sonuçlar (d=100).

Test Fonksiyonu	Popülasyon Büyüklüğü					
	n=50		n=20		n=10	
	f	σ	f	σ	f	σ
F1	9.00721e-11	6.09649e-12	1.77197e-14	1.01097e-15	2.44174e-17	9.18958e-19
F2	1.14347e-10	8.37831e-12	2.07107e-14	1.15262e-15	2.63364e-17	1.23917e-18
F3	3.08325e-08	1.98785e-09	1.1004e-11	4.78211e-13	1.93623e-14	1.42112e-15
F4	0	0	0	0	0	0
F5	4.74446e-13	5.1679e-13	3.46646e-16	3.113e-16	6.94086e-19	3.33583e-19
F6	1.05061e-10	5.64313e-12	1.9456e-14	9.78891e-16	2.54411e-17	9.99414e-19
F7	9.2193	0.196196	9.20221	0.244644	9.29592	0.214403

Tablo 3. BOA ile elde edilen sonuçlar (d=200).

Test Fonksiyonu	Popülasyon Büyüklüğü					
	n=50		n=20		n=10	
	f	σ	f	σ	f	σ
F1	9.41047e-11	5.79545e-12	1.82942e-14	1.00866e-15	2.44096e-17	1.00092e-18
F2	1.16376e-10	5.89108e-12	2.09957e-14	1.2112e-15	2.70309e-17	1.17804e-18
F3	3.13705e-08	1.37342e-09	1.1155e-11	4.95147e-13	1.99544e-14	1.71207e-15
F4	0	0	0	0	0	0
F5	3.02649e-13	2.24052e-13	2.23141e-16	2.56049e-16	6.97082e-19	2.24924e-19
F6	1.08794e-10	7.93772e-12	1.99807e-14	1.01787e-15	2.57271e-17	1.15855e-18
F7	18.516	0.0494321	18.5419	0.0392034	18.5961	0.0421195

Tablo 4. BOA ile elde edilen sonuçlar (d=300).

Test Fonksiyonu	Popülasyon Büyüklüğü					
	n=50		n=20		n=10	
	f	σ	f	σ	f	σ
F1	9.43137e-11	4.56474e-12	1.85061e-14	1.02513e-15	2.44954e-17	7.43834e-19
F2	1.20001e-10	5.77089e-12	2.07803e-14	1.21436e-15	2.64329e-17	9.30073e-19
F3	3.1065e-08	1.24352e-09	1.11366e-11	6.02741e-13	1.97175e-14	1.6281e-15
F4	0	0	0	0	0	0
F5	2.66934e-13	1.24623e-13	3.1111e-16	2.57464e-16	6.70836e-19	3.70877e-19
F6	1.11008e-10	6.08555e-12	2.0107e-14	8.2465e-16	2.58377e-17	1.02885e-18
F7	27.6446	0.0251591	27.6605	0.0346833	27.7045	0.0401644

Tablo 5. BOA ve diğer algoritmalar ile elde edilen sonuçlar (d=100).

Test Fonksiyonları	BOA	ABC	FPA	HS
F1	2.44174e-17	5.43198e-04	2.04583e+02	3.57534e+02
F2	2.63364e-17	56.6816	5.14954e+06	2.56713e+06
F3	1.93623e-14	0.701012	6.18034	7.96431
F4	0	3.1	22400.7	37380.1
F5	6.94086e-19	3.90688e-11	0.00084601	3.80221e-05
F6	2.54411e-17	0.00638635	9388.18	14963.1
F7	9.29592	0.164277	19.6359	22.6103

Tablo 6. BOA ve diğer algoritmalar ile elde edilen sonuçlar (d=200).

Test Fonksiyonları	BOA	ABC	FPA	HS
F1	2.44096e-17	7.07583	550.125	1339.66
F2	2.70309e-17	104724	1.84675e+07	1.79368e+07
F3	1.99544e-14	2.76478	6.64731	9.77193
F4	0	419.967	57651.7	133295
F5	6.97082e-19	1.22028e-05	0.000931957	0.000298581
F6	2.57271e-17	136.156	50753.1	122176
F7	18.5961	1.56232	59.8887	89.8553

Tablo 7. BOA ve diğer algoritmalar ile elde edilen sonuçlar (d=300).

Test Fonksiyonları	BOA	ABC	FPA	HS
F1	2.44954e-17	91.1405	968.722	2696.33
F2	2.64329e-17	4.85842e+06	3.60536e+07	5.0605e+07
F3	1.97175e-14	4.67604	6.98881	10.7026
F4	0	8701.97	93790.2	272627
F5	6.70836e-19	0.000151676	0.00447091	0.000469817
F6	2.58377e-17	10989.4	134007	364937
F7	27.7045	16.1303	114.89	181.578

5. TARTIŞMA VE SONUÇ

Problem boyutunun düşük ve yüksek olması meta-sezgisel optimizasyon algoritmalarının performansını etkilemektedir. BOA'nın düşük boyutlu optimizasyon problemlerinde başarılı olduğu literatürde görülmektedir. Bu çalışma kapsamında yüksek boyutlu nümerik optimizasyon problemlerinde BOA'nın performansı değerlendirilmiştir. Bununla birlikte, farklı popülasyon büyüklükleri ve problem boyutları üzerinde sonuçlar incelenmiştir. BOA için değerlendirildiğinde yüksek boyutlu problemlerde popülasyon sayısının azalması performansı arttırmıştır. Özellikle n değerinin 10, 20 ve 50 olması durumunda elde edilen sonuçlar düşünüldüğünde en iyi sonuçlar çoğunlukla 10'da bulunmuştur. Problem boyutu 100, 200 ve 300 için elde edilen sonuçlardan problem boyutunun artması çözüm kalitesinin düşmesine sebep olmaktadır.

Algoritmanın performansını etkileyen önemli hususlardan biride problemin yapısıdır. Kullanılan test fonksiyonları tek ve çok modlu olmak üzere iki aşamada değerlendirilmiştir. Tek modlu problemlerde global minimuma ulaşmak daha kolayken, çok modlu problemlerin yapısı gereği global minimuma ulaşmak daha zordur. BOA ile elde edilen sonuçlar değerlendirildiğinde, tek modlu problemlerde bulunan sonuçların çok modlu problemlere göre daha etkili olduğu görülmektedir. Buna karşın, bu çalışmada yüksek boyutlu problemler incelenmiştir. Çok modlu problemlerde yüksek boyutların kullanılmasına rağmen, BOA ile başarılı sonuçların elde edildiği tespit edilmiştir. Özellikle BOA'nın çözüm üretme mekanizmasında global en iyi çözümün kullanılması hızlı yakınsamaya sahip olmasının temel sebeplerinden biridir. Bununla birlikte, sensör modalitesi, güç katsayısı ve değiştirme olasılığı gibi kontrol parametreler problem yapısına göre ayaralanarak etkili çözümlere ulaşılabilmektedir. Bu özellikler BOA'nın tek modlu problemlerin çözümünde başarılı olmasının önemli sebeplerindedir. Bununla birlikte, çok modlu problemlerin çözümünde de etkili olabileceği görülmüştür.

BOA'nın performansını değerlendirmek için popüler sezgisel algoritmalar ABC, FPA ve HS ile karşılaştırılmıştır. Her üç problem boyutu için BOA algoritması ile elde edilen sonuçların diğer algoritmalarından daha başarılı olduğu gözlemlenmiştir. Bir algoritma ile elde edilen ortalama uygunluk değeri, algoritmanın başarısı hakkında genel bir fikir verir. Bununla birlikte, elde edilen sonuçların anlamlılığını incelemek gerekmektedir. Çözüm kalitesinin daha iyi olması, sonuçların anlamlı olduğunu göstermez. Elde edilen sonuçların anlamlılığını tespit etmek için Wilcoxon işaretli sıra testi uygulanmıştır. $p=0.05$ anlamlılık derecesine göre analizler gerçekleştirilmiştir. $p<0.05$ olması durumunda anlamlı bir fark olduğundan söz edilebilir. Aksi durumda sonuçlar arasında anlamlı bir fark olmayacaktır. Wilcoxon işaretli sıra testi sonuçları analiz edildiğinde, genel olarak BOA'ya ait sonuçlarda anlamlı bir farkın olduğu görülmüştür. Düşük boyutlu problemlerde algoritmaların performanslarının etkili olması muhtemeldir. Fakat problem boyutunun artması, ilgili problemi daha karmaşık hale getirmektedir. Problemin zor ve karmaşık hale gelmesi, çözüm kalitesini olumsuz etkileyen bir durumdur. Özellikle bir algoritmanın yüksek boyutlu problemlerde de iyi sonuçlara ulaşması güçlü bir yapıya sahip olduğunun bir göstergesidir. BOA ile elde edilen sonuçlarda yüksek boyutlu problemlerde dahi çok başarılı sonuçlar elde edildiği görülmüştür.

Bu çalışma kapsamında yüksek boyutlu test fonksiyonları üzerinde analizler gerçekleştirilmiş ve BOA'nın başarılı olduğu tespit edilmiştir. Bu sebeple gelecekte yapılacak çalışmalarda test problemleri dışında yüksek boyutlu gerçek dünya problemlerinin çözümünde BOA'nın performansının değerlendirilmesi literatüre önemli katkı sağlayacaktır. Bununla birlikte probleme özgü olarak BOA'nın yeni varyantlarının geliştirilmesi mümkündür. Geliştirilecek yeni varyantların yüksek boyutlu optimizasyon problemlerinin çözümündeki performansı değerlendirilebilir. BOA'nın sensör modalitesi, güç katsayısı ve değiştirme olasılığı kontrol parametrelerinin belirlenmesine yönelik adaptif yaklaşımlar geliştirilebilir.

Yazar Katkıları


Yazarlar çalışmaya eşit oranlı katkı sunmuşlardır.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.



KAYNAKÇA

- [1] A. Gogna, and A. Tayal, "Metaheuristics: Review and application", Journal of Experimental and Theoretical Artificial Intelligence, vol. 25, no. 4, pp. 503-526, 2013.
- [2] X.-S. Yang, "Nature-inspired metaheuristic algorithms", Luniver press, 2010.
- [3] S. Aslan, and S. Demirci, "Immune plasma algorithm: a novel meta-heuristic for optimization problems", IEEE Access, vol. 8, pp. 220227-220245, 2020.
- [4] I. Fister Jr, X.-S. Yang, I. Fister, J. Brest, and D. Fister, "A brief review of nature-inspired algorithms for optimization", 2013.
- [5] I. H. Osman, and G. Laporte, "Metaheuristics: A bibliography", Springer, 1996.
- [6] S. Aslan, and S. Aslan, "Gürültü minimizasyonu için kafes tabanlı yeni bir yapay arı kolonisi algoritması", Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, vol. 38, no. 1, pp. 15-27, 2023.
- [7] S. Aslan, and T. Erkin, "An immune plasma algorithm based approach for UCAV path planning", Journal of King Saud University-Computer and Information Sciences, 2022.
- [8] D. Karaboga, "An idea based on honey bee swarm for numerical optimization", Technical report-tr06, Erciyes University, Engineering Faculty, 2005.
- [9] K.-S. Tang, K.-F. Man, S. Kwong, and Q. He, "Genetic algorithms and their applications", IEEE Signal Processing Magazine, vol. 13, no. 6, pp. 22-37, 1996.
- [10] M. Dorigo, V. Maniezzo, and A. Colomi, "Ant system: Optimization by a colony of cooperating agents", IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), vol.26, no.1, pp. 29-41, 1996.
- [11] J. Kennedy, and R. Eberhart, "Particle swarm optimization", In Proceedings of ICNN'95-International Conference on Neural Networks, IEEE, 1995.
- [12] J. D. Farmer, N. H. Packard, and A. S. Perelson, "The immune system, adaptation, and machine learning", Physica D: Nonlinear Phenomena, vol. 22, no. 1-3, pp. 187-204, 1986.
- [13] S. Arora, and S. Singh, "Butterfly optimization algorithm: A novel approach for global optimization", Soft Computing, vol. 23, no. 3, pp. 715-734, 2019.
- [14] B. S. Yıldız, A. R. Yıldız, E. İ. Albak, H. Abderazek, S. M. Sait, and S. Bureerat, "Butterfly optimization algorithm for optimum shape design of automobile suspension components", Materials Testing, vol. 62, no. 4, pp. 365-370, 2020.
- [15] M. Tubishat, M. Alswaiti, S. Mirjalili, M. A. Al-Garadi, and T. A. Rana, "Dynamic butterfly optimization algorithm for feature selection", IEEE Access, pp. 194303-194314, 2020.
- [16] S. Arora, S. Singh, and K. A. Yetilmezsoy, "Modified butterfly optimization algorithm for mechanical design optimization problems", Journal of The Brazilian Society of Mechanical Sciences and Engineering, vol. 40, no. 1, pp. 1-17, 2018.
- [17] S. Arora, and S. Singh, "Node localization in wireless sensor networks using butterfly optimization algorithm", Arabian Journal for Science and Engineering (Springer Science and Business Media BV), vol. 42, no. 8, 2017.
- [18] S. Arora, and S. Singh, "An improved butterfly optimization algorithm with chaos", Journal of Intelligent and Fuzzy Systems, vol. 32, no. 1, pp. 1079-1088, 2017.
- [19] T. K. Sharma, "Enhanced butterfly optimization algorithm for reliability optimization problems", Journal of Ambient Intelligence and Humanized Computing, pp. 1-25, 2020.
- [20] A. Mortazavi, and M. Moloodpoor, "Enhanced butterfly optimization algorithm with a new fuzzy regulator strategy and virtual butterfly concept", Knowledge-Based Systems, vol. 228, pp. 107291, 2021.
- [21] S. Sharma, A. K. Saha, and S. Nama, "An enhanced butterfly optimization algorithm for function optimization", in Soft Computing: Theories and Applications, Springer, pp. 593-603, 2020.
- [22] S. Arora, and S. Singh, "An improved butterfly optimization algorithm for global optimization", Advanced Science, Engineering and Medicine, vol. 8, no. 9, pp. 711-717, 2016.
- [23] S. M. J. Jalali, S. Ahmadian, P. M. Kebria, A. Khosravi, C. P. Lim, and S. Nahavandi, "Evolving artificial neural networks using butterfly optimization algorithm for data classification", in International Conference on Neural Information Processing, Springer, 2019.
- [24] T. K. Sharma, A. K. Sahoo, and P. Goyal, "Bidirectional butterfly optimization algorithm and engineering applications", Materials Today: Proceedings, pp. 736-741, 2021.
- [25] R. B. Blair, A. E. Launer, "Butterfly diversity and human land use: Species assemblages along an urban gradient". Biological Conservation, vol. 80, no. 1, pp. 113-125, 1997.
- [26] E. Pollard, and T. J. Yates, "Monitoring butterflies for ecology and conservation: The british butterfly monitoring scheme", Springer Science and Business Media, 1994.
- [27] J. C. Baird, and E. J. Noma, "Fundamentals of scaling and psychophysics", John Wiley and Sons, 1978.
- [28] D. M. MacKay, "Psychophysics of perceived intensity: A theoretical basis for fechner's and stevens' laws", Science, vol. 139, no. 3560, pp. 1213-1216, 1963.



Twitter Platformundan Elde Edilen Türkçe Saldırgan Dil Derlemi

A Corpus of Turkish Offensive Language on Twitter Platform

¹Şeyma ŞAHİNER YILMAZ , ²İlyas ÖZER , ³Hadi GÖKÇEN 

¹Bandırma Onyediy Eylül University, Management Information System Department, Bandırma, Turkey

²Bandırma Onyediy Eylül University, Computer Engineering Department, Bandırma, Turkey, AINTELIA Artificial Intelligence Technologies Company, Bursa, Turkey

³Gazi University, Industrial Engineering Department, Ankara, Turkey

¹ssahiner@bandirma.edu.tr, ²iozer@bandirma.edu.tr,

³hgokcen@gazi.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 10 September 2022

Accepted : 10 October 2022

Keywords:

Sentiment Analysis, Deep Learning, Offensive Language, Social Media, Twitter

ABSTRACT

It has been observed that content with offensive language among users' posts on social media platforms has increased significantly. The study aims to contribute to the solution of this problem in Turkish language. In this study, a data set obtained from the Twitter platform was created. This data set, consisting of 14752 Turkish tweet texts, was annotated manually by the annotator and the classification performances of LSTM (Long ShortTerm Memory) and GRU (Gated Recurrent Units) models were compared. It is the first study in which multi-classification was made for Turkish on offensive language. Here, word representations were obtained with the word2vec method. Thus, the contribution of the use of extended corpus to the classification performances was compared. The highest performance GRU model F1-score value is 94.49% with the use of extended corpus in the binary classification made in the study. The classification performance values obtained in multiclassification are 71.97% and 54.10% of the GRU F1-macro value with the contribution of the expanded corpus. The datasets and expanded corpus word vectors of the current study will be shared in order to contribute to the Turkish language literature in this field.

© 2022 Bandırma Onyediy Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 10 Eylül 2022

Kabul : 10 Ekim 2022

Anahtar Kelimeler:

Duygu Analizi, Derin Öğrenme, Saldırgan Dil, Sosyal Medya Uygulaması, Twitter

ÖZET

Sosyal medya platformlarında kullanıcıların paylaşımlar arasında saldırgan dil barındıran içeriklerin önemli oranda arttığı gözlemlenmiştir. Çalışma Türkçe dilinde bu sorunun çözümüne katkı sağlamayı amaçlamaktadır. Bu çalışmada Twitter platformundan elde edilen bir veri seti oluşturulmuştur. 14752 Türkçe tweet metninden oluşan bu veri seti etiketleyiciler tarafından manuel olarak etiketlenmiş ve LSTM (Long ShortTerm Memory) ve GRU (Gated Recurrent Units) modellerinin sınıflandırma performansları karşılaştırılmıştır. Bilinebildiği kadarıyla saldırgan dil tespitine yönelik bu alanda yapılan çalışmalara bakıldığında çalışma Türkçe dilinde çoklu sınıflandırma yapılan ilk çalışmadır. Burada word2vec yöntemi ile kelime temsilleri elde edilmiştir. Böylelikle genişletilmiş derlem kullanımının sınıflandırma performanslarına katkısı karşılaştırılmıştır. Çalışmada yapılan ikili sınıflandırma da genişletilmiş derlem kullanımıyla en yüksek performans GRU modeli F1-makro değeri %94,49'dur. Çoklu sınıflandırmada elde edilen sınıflandırma performans değerleri genişletilmiş derlemin katkısıyla GRU F1-makro değeri %71,97 ve %54,10'dur. Bu alanda Türk dili literatürüne katkı sağlamak amacıyla mevcut çalışmanın veri setleri ve genişletilmiş derlem kelime vektörleri paylaşılacaktır.

© 2022 Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

ORCID ID: ¹0000-0002-3301-9491

²0000-0003-2112-5497


³0000-0002-5163-0008

1. GİRİŞ

Twitter gibi sosyal medya mecralarının hızlı büyümesiyle birlikte daha fazla kullanıcı, görüşlerini ve fikirlerini çevrimiçi olarak paylaşmaktadır. Bu büyümenin ardından, bilgisayar bilimlerinde en verimli araştırma alanlarından biri olan duygu analizi çalışmaları artmıştır [1]. Duygu analizi çalışmalarında Twitter verileri yaygın olarak kullanılmıştır. Duygu analizi, insanların varlıklara yönelik fikirlerini, duygularını, değerlendirmelerini, tutumlarını ve bunların yazılı metinde ifade edilen niteliklerini analiz eden çalışma alanıdır [2]. Fikir, düşünce madenciliği olarak da adlandırılan duygu analizi, 2000'li yılların başından beri Doğal Dil İşleme (DDİ) en aktif araştırma alanlarından biri olmuştur [2].

Sosyal medya insanlara görüşlerini, bilgilerini, deneyimlerini ve duygularını ifade etmeleri için çevrimiçi bir platform sağlamaktadır. Ancak sosyal medya etkileşimleri taciz edici, küfürlü ve hakaret içeren saldırgan içerikli yorumlar yapılan bir platform haline geldiğinde büyük bir sorun ortaya çıkmaktadır. Bu durumda kullanıcılar saldırgan içeriklere maruz bırakılmaktadır. Dolayısıyla kullanıcılar bu durumdan rahatsız olmaktadır. Saldırgan içeriklere maruz kalan kullanıcılar arasında 11-15 ergen yaş grubu azımsanmayacak sayıda bulunmaktadır [3]. Ergen yaş grubu için saldırgan içerikler psikolojik açıdan geriye dönülmesi mümkün olmayan zararlar vermektedir. Zorbalık veya nefret söylemi gibi potansiyel olarak zararlı olayların çoğu internetten önce gelmiş olsa da internetin erişimi ve kapsamı bu olaylara milyarlarca insanın hayatını etkilemek için benzeri görülmemiş bir güç ve etki sağlamıştır. Bu olayların web kullanıcıları için zihinsel ve psikolojik acı yaratmasının yanında insanları hayatları ile ilgili kararlar hakkında zorladığı ve aşırı durumlarda intihara meyillendirdiği de bilinmektedir [4]. Aynı zamanda şirketlerde sosyal medya platformlarında bu tür saldırgan içerikle çoğu kez karşılaşmaktadır [5]. Bu içeriklerle baş etmek sosyal medyanın hızı göz önüne alındığında ve kullanıcıların konuşma özgürlüğü hakkından ödün vermeden saldırgan dil kullanımına zamanında müdahale etmek oldukça zorlu bir görev olarak görülmektedir. Bu gibi sebepler ile saldırgan içeriklerin tespit edilmesine yönelik çalışmalar, gelecekte bu içeriklerin engellenebilmesi hususunda önem arz etmektedir. Çalışmada bu alana Türkçe dilinde bir veri seti kazandırılmıştır. Böylelikle derin öğrenme yöntemleri kullanarak sosyal medyada saldırgan içeriklerin tespiti alanına katkı sağlamak amaçlanmıştır.

Günümüzde sosyal ağ sitelerinde saldırgan içerik artmıştır. Bu sitelerin çoğunun, siber zorbalık, ırk, etnik köken, din, cinsiyet ve milliyet gibi korunan özelliklerine göre bireylere veya gruplara saldıran veya tehdit eden gönderileri yasaklayan nefret ve saldırgan dil söylemi politikaları vardır. Bu politikaya yönelik rapor sunan Twitter platformu 2020 rapor verilerini sunmuştur [6]. Twitter şirketinin 2020 yılı Temmuz- Aralık ayını kapsayan raporuna ilişkin veriler, Şekil 1.'de gösterilmektedir. Grafikte düşey eksen, Twitter şirketinin kendi politikaları çerçevesinde yaptırma sebep olan içerikleri başlıklandırmıştır. Yatay eksen ise bu içerikleri üreten kişi sayısını göstermektedir. Bununla birlikte grafikte yer alan % oranlar temmuz ayından aralık ayına kadar belirtilen içeriklerin üretimindeki artışı göstermektedir. Bu artışların özellikle hassas içerik barındıran artışların bu kadar çok olması ve içeriklerin kaldırılması ve askıya alınması arasındaki farkın az olması bir içeriğin farklı kullanıcılar arasındaki potansiyel yayılma hızını göstermektedir. Sonuç olarak çevrimiçi ortamlarda bazı içerikler hızlı yayılmaktadır. Bu durum zamanında yanıt veren çözümlerin gerekli olduğunu göstermektedir. Aynı zamanda bu rapora göre sadece 6 ay da 1 milyon hesap askıya alınmıştır. Bu yaptırımların yarısından fazlası çocuk cinsel istismarı sebebiyle yapılmıştır. Tüm bunlar, otomatik yöntemlerle rahatsız edici dil algılama sorununu çözen doğru ve ölçeklenebilir bir çözüm bulma ihtiyacını doğurmaktadır. Böylelikle saldırgan dil söylemi tespiti alanında çeşitli duygu analizi araştırma çalışmaları ve TRAC, SemEval, OffensEval, GermEval gibi yarışmalar bu alana dikkat çekmektedir.



Şekil 1. Twitter yaptırımları Temmuz- Aralık 2020 raporu.

Türkçe zengin morfolojik yapıya sahip ve sondan eklemeli bir dildir. Literatürde üstün başarı gösteren İngilizce gibi dillere göre bu alanda yapılan çalışmalar Türkçe için zorlu bir görevdir. Örneğin; bir isim olan “masa” kelimesinden üretilebilecek sözcük sayısı 548 bin 390 iken “oku” kelimesinden üretilebilecek sözcük sayısının 1 milyon 461 bin 211 olduğu görülmüştür [7]. Buna ek olarak Türkçe’de bir kelimeyle anlatılan bir ifadenin İngilizce gibi dillerde bir cümleye tekabül etmesi ve birleşik sözcüklerin kelimenin kökündeki anlamını yitirmesi gibi durumların Türkçe’nin DDİ alanında az çalışılmasına sebep olmaktadır. Ayrıca diğer dillere nazaran başarısını kısıtladığı da görülmüştür. Türkçe için bazı dillere göre kural tabanlı yaklaşımlar zorlu bir görevdir ve kaynaklar da azdır [7]. Örneğin; Türkçe için Senti-TurkNet [8] gibi kaynaklar ve 2.000 kelimedenden oluşan bir kelime kümesi [9], Türkçe WordNet 15 bin kelimedenden oluşan kavramsal sözlük [10] oluşturulmuştur. Bununla birlikte biçimbilimsel çözümleme [11], biçimbilimsel tekleştirme [12] gramer tabanlı çözümleme [13], ağaç yapılı derlem ile ekleri çözümleme [14] gibi kural tabanlı yöntemler bulunmaktadır. Ancak Türkçe’nin zengin morfolojik yapısı ve çok sayıda kelime oluşumunu sağlayan ek yapısı, morfolojik belirsizliklerin (kalem vb.) bulunması gibi zorluklar sebebiyle bu yaklaşımlar önerilmemektedir [15, 47]. Ayrıca sosyal medyada kullanılan ifadeler, dil bilgisi kurallarından uzak, yazım hataları, sözlükte yer almayan kelimeler ve kısaltmalar da oldukça fazladır. Bu durum duygu analizinde sınıflandırma problemlerine sebep olmuştur. Önerilen yöntem ise, alana özgü verileri kullanarak problemi çözmektir. Böylelikle Türkçe metinlerin sınıflandırılmasında başarılı sonuçlar elde edilmiştir [15]. Bu çalışmada, genişletilmiş derlem ile Türkçe dilinde birlikte kullanılan kelimelere ve cümleye göre anlam yakalamanın sınıflandırma başarımlarına etkisinin gösterilmesi amaçlanmıştır.

Türkçe dilinde yapılan çalışmaların az olmasının sebeplerinden biri de Türkçe dilinde yeteri kadar veri setinin bulunmamasıdır. Bu durum Türkçe dilinde yapılan DDİ çalışmalarını mukayeseden yoksun kılmaktadır. Böylelikle Türkçe dilinde yeteri kadar farklı veri setleri kullanılarak modellerin denenmediği ve bazı kalıplara oturtulamadığı görülmüştür. Bu sebeple Türkçe dilinde yapılan çalışmaların diğer bazı diller ile yapılan çalışmaların gerisinde kaldığı görülmüştür. Buna ek olarak literatürde yer alan Türkçe veri setlerinin bazılarının otomatik veya manuel olarak İngilizce dilinden çevrilip elde edildiği de görülmüştür [16-17]. Bu durumda çeviri metinlerde yaşanan özellikle sosyal medya platformlarında yer alan metinlerin doğası olan gayri resmi dil kullanımı, kısaltmalar, Türkçe’nin kendine özgü doğasının göz ardı edilip cümlenin anlamını ve etkisini yitirmesi [7] gibi durumlar ile karşılaşılabilir. Böylelikle bu çalışmada alana katkı sağlamasını amaçladığımız Twitter platformundan elde edilmiş yaklaşık 15 bin tweetten oluşan veri seti sunulmaktadır.

Çalışmada, alana özgü verilerin olduğu iki ayrı veri seti kullanılmıştır. Bunlardan biri alana özgü verilerden oluşan genişletilmiş derlem ve yaklaşık 1 milyon 866 bin 546 tweet metninden oluşmaktadır. İkinci veri seti ise 14 bin 752 tweet metninden oluşan veri setidir. Bu veri seti Python dili kullanılarak Twitter platformundan elde edilmiştir. Bu çalışmada, oluşturduğumuz veri setini etiketlemek için Zampieri ve arkadaşlarına benzer genel bir yaklaşım izlenmiştir [18-19]. Tanımlamalarımız her iki çalışmadan farklılıklar gösterse de her iki çalışmada [18-19] olduğu gibi sınıf etiketleri için hiyerarşik bir şema izlenmiştir. Bu şemanın ilk aşamasında tweet metni “saldırgan” ya da “saldırgan değil” olarak etiketlenmiştir. Tweet herhangi bir hakaret ya da aşağılama içermiyorsa saldırı değil olarak etiketlenmiştir. Eğer metin “saldırgan” olarak tanımlanırsa, “hedefli” ve “hedefsiz” olarak etiketlenmektedir. Çalışmada “hedefsiz” olarak tanımlananlar net bir hedef olmaksızın her türlü saldırı dil kullanımı içermektedir. Birini hedef almayan bir hakaret ya da küfür kullanımı, kişinin kendisini hedef alması veya cümlenin sonunda gelişigüzel kullanılan saldırı ifadelerinde bu etiket grubuna girmektedir. Buna ek olarak hakaret olarak algılanabilecek ama arkadaşça, şaka amaçlı kullanılan ifadeler içinde bu etiket kullanılmıştır. Bu durum özellikle çocuklar için uygunsuz olarak nitelendirilmektedir.

Eğer metin “hedefli” olarak tanımlanırsa ise grup, birey ve diğer olmak üzere etiketleme yapılmıştır. Gruba yönelik saldırı dil toplulukları hedef almıştır. Tweet insanların aidiyetine yönelik bir hakaret ya da nefret söylemi içeriyorsa (cinsiyet, etnik kimlik, politik görüş, ya da din gibi genel ve kalıcı bir birlikteliği içeren gruplar) bu etiket grubuna girmektedir. Buna ek olarak birden fazla kişiye yönelik saldırı ifadeler bu kategoride değerlendirilmiştir. Grup tanımına uymayan bir kişiye yönelik işlenen suç, bireyleri hedef alan bir suç olarak kabul edilmektedir. Bireye karşı yapılan saldırı dil ise genellikle siber zorbalık, cinsel taciz suçunu içermektedir. Siber zorbalık genellikle çocuklara karşı işlenmekte ve birey üzerindeki etkileri de oldukça olumsuz olmaktadır. Cinsel taciz suçu ise cinsel arzu ve isteklere yönelik rahatsız edici sözleri kapsamaktadır [20]. Suçun hedefinin bu kategorilerden hiçbirine uymadığı durum da vardır. Bir organizasyon veya olay gibi insan olmayan bir varlığa yönelik suç buna örnek verilebilir. Bu gibi durumlarda hedef “diğer” olarak kabul edilmiştir. Kısaca saldırı ve saldırı değil olarak yapılan ikili sınıflandırma, ardından saldırı değil, hedefli ve hedefsiz olarak üçlü sınıflandırma, sonrasında saldırı değil, hedefsiz, birey, grup ve diğer olarak beşli sınıflandırma şeklinde veri seti etiketlenmiştir. Yapılan etiketleme ile ilgili bilgiler, Bölüm 3.’de ayrıntılı olarak işlenmiştir.

Çalışmada bu veri setleri kullanılarak word2vec-CBOW ile her bir tweet metninde yer alan kelimenin vektörel temsili elde edilmiştir. Bununla birlikte LSTM, GRU gibi güncel ve etkinliği kanıtlanmış derin öğrenme yöntemleri ile sınıflandırma işlemi yapılmıştır. Sınıflandırma performansını değerlendirme ölçümü olarak F1-makro değerine karar verilmiştir. Bu performans ölçümü literatürde bu alanda sıklıkla kullanılan ölçüm yöntemidir.

Yukarıda belirtilen zorluklar dikkate alındığında, bu çalışmanın temel katkıları şu şekilde sıralanabilir:

- Veri seti oluşturma kriterleri belirtilmiştir ve veri çeşitliliğinin nasıl sağlandığına değinilmiştir.
- Veri etiketleme kriterleri belirtilip yaşanan uyum probleminden bahsedilmiştir.

- Veri seti oluşturmak ve etiketlemenin psikolojik iyi oluşu kötü yönde etkilediği saldırgan dil metinlerine maruz kalan etiketleyiciler tarafından dile getirilmiştir.
- Popüler derin öğrenme modellerinin Türkçe saldırgan dil tespitinde başarımları değerleri görülmüştür.
- Genişletilmiş derlem kullanımının sınıflandırma performanslarına olan iyileştirici etkisinin hangi oranda olduğu görülmüştür.
- Çoklu sınıflandırmada modelin performansının nasıl etkilendiği görülmüştür.

Bu çalışmada amacımız gelecekteki çalışmalara katkı sağlayacağını düşündüğümüz etiketlenmiş Türkçe veri setini alana kazandırmaktır. Buna ek olarak Türkçe dilinde saldırgan dil tespit etmek için çözümler sunmaktır. Böylelikle çoğunlukla kullanılan başarımları kanıtlanmış derin öğrenme yöntemlerinin performansları test edilerek bu modellerin Türkçe dilinde etkisi görülmüştür. Genişletilmiş derlem kullanımının bu yöntemlere iyileştirici etkisi karşılaştırılmıştır.

2. LİTERATÜR

Son on yılda, Web’ de özellikle Facebook ve Twitter gibi popüler sosyal medya platformlarının ortaya çıkmasıyla birlikte kullanıcılar tarafından oluşturulan içeriklerde büyük bir artış olmuştur [21]. Artık çevrimiçi herhangi bir bilgi milyarlarca insana saniyeler içinde ulaşma gücüne sahiptir. Bu durum, yalnızca olumlu fikir alışverişiyle sonuçlanmakla kalmamış, aynı zamanda saldırgan ve potansiyel olarak zararlı içeriğin web üzerinde yaygın bir şekilde yayılmasına da yol açmıştır. Zorbalık veya nefret söylemi gibi potansiyel olarak zararlı ifadelerin çoğu internette önce gelmiş olsa da internetin erişimi ve kapsamı bu olaylara milyarlarca insanın hayatını etkilemek için benzeri görülmemiş bir güç ve etki sağlamıştır. Bu olayların sadece web kullanıcıları için zihinsel ve psikolojik acı yaratmadığı, aslında insanları hayatları ile ilgili kararlar hakkında zorladığı ve aşırı durumlarda intihara meyillendirdiği bilinmektedir [4]. Ayrıca sözlü sohbetlerde, üniversite öğrencilerinin söylediği kelimelerin %0,5’inin küfür olduğu belirtilmektedir [22]. Twitter’da bu oran iki kattan fazla, %1,2 ve %7,7 küfür içeren tweetler olarak görünmektedir [23]. Saldırgan gönderilerin %9’ undan daha büyük bir kısmının da küfür içermesi muhtemeldir [24].

Bu alandaki çalışmalarının çoğu, belirli bir saldırgan dil biçimini açıklar ve çoğu zaman, belirli bir uygulamada kullanılmak üzere tasarlanmıştır. Şimdiye kadar en yaygın uygulama, nefret söylemi algılamadır. Nefret söyleminin net bir tanımı olmamasına rağmen, tipik olarak ırk, etnik köken, cinsiyet, cinsel yönelim, sosyo-ekonomik sınıf, siyasi bağlantı veya din gibi özelliklere dayalı olarak bir grubu (veya bazen bir kişiyi) hedef alan saldırgan dili kapsar [25]. Bu çalışmalardan bazıları kapsamı belirli bir hedefe, genellikle ırk [26-27] kadınlar [26] ve mülteciler [28], belirli bir ideolojiye sahip nefret söylemi [29] veya tek bir önemli olayla ilgili nefret söylemidir [30]. Bir diğer yaygın saldırgan dil alt alanı da siber zorbalığın tespit edilmesidir [24, 31-34]. Nefret söyleminin aksine, siber zorbalığın hedefi genellikle tek bir kişidir ve bu genellikle bir çocuktur. Zorbalığın çevrimiçi versiyonu siber zorbalık, ciddi bir sağlık sorunu olarak kabul edilmektedir [35]. Bu nedenle, siber zorbalığın otomatik tespitinin tipik bir uygulaması, çocuklar için daha güvenli çevrimiçi iletişim sağlamaktır [36]. Uygulamalar farklı olsa da önemli bir örtüşme vardır. Örneğin, siber zorbalık genellikle nefret söylemi olarak kabul edilen ifadeler barındırır. Dahası, metinlerin hem dil özellikleri hem de bunları tespit etme yöntemleri benzerdir.

Genel kültürel ve ahlaki kurallar, saldırgan dili tanımlamaya fayda sağlasalar da bir ifadenin saldırgan olup olmadığı, çoğunlukla öznel ve büyük ölçüde bağlama bağlıdır. Son zamanlarda yapılan birçok çalışmada sık sık gündeme getirilen bir nokta, saldırgan dilin tanımı ve alt kategorileri konusunda fikir birliğinin olmaması ve bunun sonucunda farklı derlemlerde etiketlemelerin uyumsuzluğudur. Birkaç istisna bir yana, saldırgan dille ilgili etiketleme görevlerinden herhangi biri üzerindeki yorumcuların aynı kararı almasındaki uyuşma durumu nispeten düşüktür. Saldırgan dil etiketlemesinde kullanıcılar arasında Wiegand ve diğerleri (2018) rapor $\kappa = 0.66$ ve Zampieri ve diğerleri (2019) %60 uyuşma bildirmiştir [18-19, 37]. Ancak saldırgan dil de net tanımlar ve sınıflandırmalar için daha nesnel olmalarını sağlama amaçlı girişimler bulunmaktadır [38-39]. Zampieri ve diğerleri (2019) tarafından yapılan çalışmaya göre saldırgan dilde hedef, bir birey veya ırkına, cinsiyetine, siyasi / ideolojik yakınlığına, dinine veya benzer bir mülke dayalı bir grup insandır. Eğer ki hedef bir bireyse; kategori genellikle siber zorbalık eylemlerini içerirken, hedef bir grup ise, muhtemelen bir nefret söylemi örneğidir. Ayrıca 2019 yılında Zampieri ve arkadaşları, hedefin bazen (açıkça) insanlar değil, örneğin bir organizasyon veya olay olduğunu da söylemektedir [18]. Hedef alınmayan hakaretler de yaygındır. Hedeflenmemiş suç, küfürlü veya müstehcen dil veya genel olarak, bir bireyi veya bir grubu rencide etme niyeti veya etkisi olmaksızın kullanılan ifadeleri içerir. Bu durum tipik olarak bir suça karşılık gelmez [18]. Bununla birlikte, çocuk kullanıcılar ve kurumsal şirket hesapları için bu dil biçimlerinden kaçınılmaktadır.

Öznel ve bağlama bağlı olduğu bilinen çeşitli saldırgan dil biçimlerinin otomatik olarak tanımlanması çalışmalarının yöntemleri ve başarı oranı da değişiklik göstermektedir. Genel olarak, başarı oranı da göreve ve veri setine bağlı olarak değişir. Çalışmaya en yakın otomatik tanımlama deneyi seti OffensEval-2019/2020 [18, 40] ve GermEval [19] yarışmalarındaki saldırgan dil tanımlama görevleridir. Her ikisinin de birbirini izleyen görevler mevcuttur. OffensEval 2019’ da ilk alt görev, saldırgan dili saldırgan olmayan dilden ayırmayı içermektedir. İkinci görev ise, verilen saldırgan belgenin hedeflenip hedeflenmediğini belirlemektir ve son olarak üçüncü alt görevler, hedef türü (grup, birey veya diğer) belirlemektir. Diğer bir benzer çalışma ise GermEval yarışmalarındaki saldırgan dil tanımlama görevidir. Bu çalışma da Struß ve arkadaşları tarafından yapılan Alman

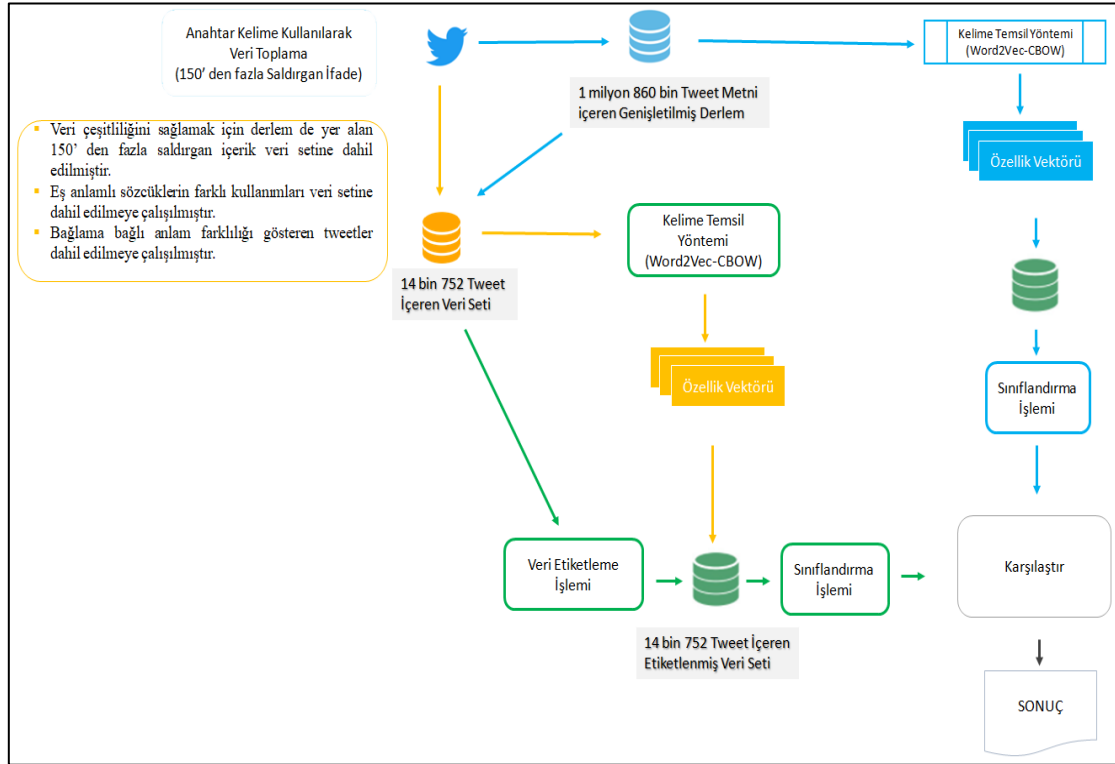
saldırğan dili tanımlama görevi, saldırğan dilin tanımlanması gibi ikili bir görevle başlar ve ardından saldırğan dilin türünü (küfür, taciz veya hakaret) tanımlamayı gerektiren ikinci bir görev izler. Alman saldırğan dili tanımlama görevinde çoklu etiket sınıflandırma söz konusudur [37]. Çalışmamıza benzer olarak her iki yarışmanın birinci görevin de ulaşılan başarı oranı yüksektir (sırasıyla; %82,9 F1 ve %76,8 F1). Diğer alt görevler de ise başarı oranı da düşmektedir (sırasıyla; %66 F1 ve %53 F1).

Saldırğan dili belirli konulara bölmeden (siber zorbalık, ırkçılık gibi) bunları bir bütün olarak gören derlemin, farklı saldırğan dil türleri arasındaki farklılık ve benzerlikleri anlaması daha olasıdır. Belirli bir konuya yönelik veri kümesinin eğitilmesi, saldırğan dil örneklerinin diğer biçimlerini belirlenen konuya yönelik saldırğan dil türünden ayırt etmekte başarısız olabilir. Örneğin, nefret söyleminin tanımlanmasını amaçlayan bir çalışma, durumu iyi temsil etmeyen bir derlem ile eğitilmişse, siber zorbalık içeren saldırğan dil biçimlerini nefret söylemi olarak karıştırabilir. Bu karışıklığın yaygın bir nedeni de bağlam eksikliğidir. Bazı tweetler bağlam olmadan saldırğan görünebilirken ‘hayvan gibi güzel oynadı herif’, doğru bağlamda iltifat olabilir. Diğer durumlarda, tweetler rahatsız edici görünmeyebilir. Ancak devam eden konuşmada veya dile özgü sosyal bağlamda saldırğan dil kullanılmış olabilir. ‘6s’ in GS futbol takımına söylenmesi, ironi olarak yapılan iltifatlar veya ‘insan olmayı başarabilseydin’ gibi koşullu cümleler buna örnek verilebilir.

3. UYGULAMA

Çalışma üç aşamayı kapsamaktadır (Şekil 2.)

- Veri toplama aşaması
- Veri etiketleme aşaması
- Sınıflandırma aşaması



Şekil 2. Uygulama akış diyagramı.

Veri toplama aşaması verilerin Twitter uygulamasından toplanma aşamasıdır. Toplanan verilerden iki ayrı veri seti elde edilmiştir. Bunlar ‘genişletilmiş derlem’ ve etiketlenmiş veri setidir. *Veri etiketleme aşamasında* veri setinde yer alan tweet metinlerini etiketleme işlemi yapılmıştır. Etiketleme yapılırken belirli kriterler kullanılmış ve 4 ayrı kişi tarafından etiketleme yapılmıştır. Etikete oy çokluğuna göre karar verilmiştir. Oy eşitliğinde ise ilgili tweet metni için 3 farklı kişiden görüş alınmıştır. *Sınıflandırma aşamasında* ise kullanılan veri setlerine kelime temsil yöntemlerinden word2vec-CBOW uygulanmıştır. Burada tweetler de yer alan boşluk gözetilerek her bir kelime veya ifade içeren varlık için vektörel temsil elde edilmiştir. Karşılaştırılacak olan genişletilmiş derlem ile etiketlenen veri setine LSTM, GRU sınıflandırma algoritmaları uygulanmıştır. Her bir algoritmaya uygun parametreler belirlenip model seçilmiştir. Her modelin performans değerlendirme ölçütleri elde edilmiştir. Bu ölçütler, genişletilmiş derlemin sınıflandırma algoritmalarının performansına etkisini göstermiştir. Buna ek olarak sınıflandırma algoritmalarını da karşılaştırabilmemizi sağlamıştır.

3.1. Veri Toplama

Bu başlıkta oluşturulan iki ayrı veri setinden bahsedilecektir. Sınıflandırma için oluşturulan veri setini etiketleme kriterleri örnekleriyle açıklanmıştır.

3.1.1. Veri Seti

Bir veri setinin dört temel özelliği; gerçek dünyaya uygun, nispeten büyük, elektronik yollarla elde edilmiş ve alana özgü kriterleri barındırıyor olmasıdır [50]. Akademik dil, konuşma dili, sosyal medyada kullanılan gayri resmi dil, gazete yazıları, romanlar- hikayeler ve yasal davalar gibi kısa metinlerin yanı sıra metin türleri olarak bilinen çeşitli dil dizgesi içeren veri setleri oluşturulmaktadır. Öte yandan her bir dilin kendi modeline ve keskin dil kalıbına sahip olduğu görülmüştür [51]. Buna ek olarak veri setinin boyutuyla ilgili belirli kural yoktur. Ancak veri seti kullanılan hedef dil kalıplarının sistematik bir analizini yapacak kadar büyük olması gerekmektedir. Böylelikle bir kelimenin yalnızca kendisinin metne yön veremediği aynı zamanda çevresindeki kelimelerin öğrenmeye katkısı olduğu bulunmuştur. Bu da bir kelimenin anlamını ve faydasını artıran bir durumdur.


Bu çalışmada, Python programlama dili ile kendi oluşturduğumuz veri seti kullanılmıştır. Türkçe’ de bilinen 150’den fazla saldırgan dil içeren kelime ve kelime öbekleri aratılarak veri seti oluşturulmuştur. 14.02.2020-17.06.2020 tarihleri arasında filtreleme yapılarak 1 milyon 860 bin tweetten oluşan bir genişletilmiş derlem elde edilmiştir. Ancak veri toplama periyodunun kısa olması tweet çeşitliliğinin yetersiz olmasına yol açabilmektedir. Bununla ilgili 2018 yılında Wiegand ve arkadaşlarının yaptıkları çalışmada Almanca olarak saldırgan dili temsilen veri seti oluşturmuşlardır ancak veri setinde mültecilere yönelik içeriklerin veri setine hâkim olduğu görülmüştür [19]. 2019 yılında bunun üstesinden gelebilmek için Strub ve arkadaşları bu veri setini iyileştirmek için kullanıcıya göre tweet metni toplamışlardır [37]. Ancak yine de belirli bir konunun veri setine hâkim olduğu görülmüştür. Bu dezavantajı gidermek için Python da geçmişe dayalı uzun bir periyotta arama kodu kullanılarak filtreleme yapılmıştır. Böylelikle genişletilmiş derlemde kullanılan tweetlerin tarihleri 5.09.2010- 17.06.2020 tarihleri arasındadır. Şekil 7. 2’de de görüldüğü gibi derlemde elde edilen kelime bulutunda herhangi bir konu yani birey grup veya olay veri setine hâkim değildir. Böylelikle bahsettiğimiz dezavantajın aksine veri setimizde konu çeşitliliğinin sağlanabildiği söylenebilir. Bu tarihler baz alınarak oluşturulan genişletilmiş derlemde 3 milyon 859 bin 322 adet eşsiz ifade bulunmaktadır. Her bir ifade için çeşitli boyutlarda vektörel temsiller elde edilmiştir. Derlem için word2vec olarak bilinen kelime temsil yöntemi kullanılmıştır. Böylelikle vektör uzayında anlamsal olarak yakın kelimeler bilinmektedir. Derlem kullanımının öğrenmeye bariz fayda sağladığı görülmüştür [41]. Çünkü derlem kullanımı, sınırlı verilere dayanmak yerine derlemde yer alan kelimelerin frekans dağılım özelliklerinin ve ilgili konunun gerçek dünyayı yansıtan dil kullanımının gözlemlenmesine ve incelenmesine izin vermektedir. Bununla birlikte belirli bir alana uygun oluşturulan derlem sözcük kalıplarına dayalı yeni duygu sözcüklerini keşfetmektedir.



Şekil 3. Genişletilmiş derlemde elde edilen kelime bulutu.

Şekil 3.’te genişletilmiş derlemde yer alan tweetler de en çok geçen 500 kelimenin kelime kullanım sıklığına göre boyutunun belirlendiği bir kelime bulutu elde edilmiştir. Örneğin bu-bir-ve-ama-için-kadar kelimeleri tweetler de oldukça fazla geçmektedir. Bu kelimeler veri temizleme işlemi yapılarak derlemde çıkarılabilir. Yapılan bazı çalışmalarda belirli kullanım sıklığının üzerinde olan kelimelerin veri ön süreç aşamasında temizlendiği

metnin hedef aldığı türlere göre ayrılmaktadır. Buradaki “grup” tanımı, herhangi bireyler topluluğunu (örn. mülteci, futbol takımı, grup gibi) ya da birden çok kişiyi (örn. hainler) ifade etmektedir. Birey ise, grup tanımına uymayan kişiyi hedef alan suçlardır. Suçun hedefinin bu durumlardan herhangi birine uymadığı durumlar vardır, tipik olarak bir organizasyon veya olay gibi insan olmayan bir varlığa yönelik suçları kapsamaktadır. Bu gibi durumlarda, hedef, diğer olarak işaretlenmektedir. Burada, Zampiere ve diğerlerinin etiketleme yöntemi izlenmektedir [18]. Ancak bazı tanımlar, bu çalışmadan farklılıklar göstermektedir. Bununla birlikte saldırgan dil ile ilgili tanımlamaların kullanılan öğrenme yöntemlerin performansını iyileştirici etkisi olduğunu bilinmektedir [43].




Şekil 5. 'hakem' kelimesinin anlamsal yakınlıklarının gösterimi.

Saldırgan içeriklerin belirlenmesi öznel yargı içermektedir. Bu sebeple etiketleyiciler tarafından bir metnin saldırganlığı belirlenirken kişiye göre değişiklik göstermektedir. Zampiere ve diğerleri tarafından yapılan çalışma da etiketlemelerde kişiler arasında %60 uyum olduğu gösterilmiştir [40]. Wiegand ve diğerleri ise %66 uyuma olduğunu belirtmiştir [19]. Bu alanda yapılan çalışmalar da bu durumun dezavantajından bahsetmiştir. Benzer olarak bu çalışmada da etiketlemecilerin saldırgan metinleri etiketlerken uyum sorunu yaşadığı görülmüştür. Örneğin; “Devleti ve milleti hedef aldı! İşte alçak saldırının faturası”. Bu tweet metninde yer alan “alçak” kelimesi bir olayı nitelemesi sebebiyle saldırganıdır. Ancak aynı zamanda terör olaylarını ifade etmek adına kamuoyunda kullanılan genel bir ifadedir. Bu tweet metni genel bir ifadeyi içermesi sebebiyle saldırgan değil olarak etiketlenmesine yorumlayıcılar tarafından karar verilmiştir.

Etiketleme işlemi, 4 kişi tarafından yapılmıştır. Bu kişiler en az lisans düzeyinde öğrenim görmüştür ve ana dilleri Türkçe’dir. Etiketlemeler çoğunluğun kararına uygun olarak yapılmıştır. Etiketlemeciler arasında eşit oy söz konusu olduğunda ise farklı 3 etiketleyici oylamaya dahil edilerek karar verilmiştir. Bununla birlikte çalışmada yukarıda belirtildiği gibi daha net ve basit etiketleme kriterleri koyulmuştur. Böylelikle tweet metnini etiketlerken daha tutarlı olmak ve genel yargı içeren etiketlenmiş veri seti elde etmek hedeflenmiştir.


Veri setinin boyutuyla ilgili belirli kural yoktur. Ancak çalışmada kullanılan dil kalıbını öğrenmesi beklenmektedir. Çalışmada Türkçe tweetler kullanılmıştır. Veri setimizdeki tweet sayısı 14752’dir. Burada ‘Saldırgan Değil’ etiketli tweet sayısı 4528 iken ‘Saldırgan’ etiketli tweet sayısı 10224’ dür. Saldırgan etiketli tweetlerin 9931’i ‘Hedefli’, 293’ü ‘Hedefsiz’ olarak etiketlenmiştir. Hedefli olarak etiketli tweetlerin 6346’sı ‘Birey’, 3184’ü ‘Grup’ ve 401’i ‘Diğer’ olarak etiketlenmiştir (Şekil 5).



Şekil 6. Veri etiketleme aşaması.

3.3. Veri Ön İşleme

Verilerin sınıflandırma performansını iyileştirmek için bazı ön işleme adımlarını gerçekleştirmek önemlidir. Verilerin sınıflandırma performansını iyileştirmek için bazı ön işleme adımlarını gerçekleştirmek önemlidir. Çalışmada yer alan veri seti, doğrudan Twitter' dan çıkarılan tamamen ham verilerden oluşmaktadır. Bunlardan faydalı bilgiler çıkarmak için veri ön işleme aşamasına ihtiyaç duyulmaktadır. Ancak 'hashtag', 'tamamı büyük harf', 'uzatılmış', 'tekrarlanan', 'vurgu', 'sansürlü' 'emoji' içeren tweet metinleri herhangi bir ön işlem uygulamasına dahil edilmemiştir. Çünkü bunlar güçlü bir duygu veya alaycılık ve ironi ifadelerini temsil etmek için kullanılmaktadır [42]. Bu sebeple tweet metinlerine yukarıda bahsedilen ön işleme aşamaları uygulanmamıştır. Ancak sınıflandırma algoritmaları tarafından daha kolay öğrenilebilir hale getirmek için sayısal forma dönüştürülmüştür. Bunun için kelime temsil yöntemlerinden olan word2vec-CBOW'u kullanarak kelime dizileri yerine gerçek sayı vektör dizileri elde edilmiştir. Bununla birlikte 14752 tweet metni içeren veri seti için Türkçe verilerde iyileştirici etkisi bilinen [52] tüm karakterlerin küçük harfe dönüştürülmesi, sayısal karakter içeren ifadelerin ve noktalama işaretlerinin çıkarılması ön işleme uygulanmıştır (Şekil 7).



Şekil 7. Veri ön işleme aşaması.

Kelime Temsil Yöntemi

Derin öğrenme modelleri veri yoğun çalışma modelini benimsemeleridir. Bu modeller de denetimli öğrenme kullanılırken çok büyük miktarda veri gerektirir. Çoğu DDİ görevi için veri setleri yalnızca birkaç bin insan etiketli örnek içermektedir. Bu, veri kümelerinde derin öğrenme modellerinin sınıflandırma performansını kısıtlamıştır. Bu sorunun çözümü, önceden eğitilmiş olarak bilinen bir yöntemle gelmiştir [44][46][48]. Bu yöntemin arkasındaki fikir, metnin genel temsilini öğrenmek ve çok miktarda etiketlenmemiş metinden oluşan genişletilmiş derlemi eğitmektir. Böylelikle alana özel söz dizimsel ve anlamsal özellikleri anlamaktadır. Etiketlenmemiş tümceler kolayca erişilebilir durumdadır ve bu nedenle daha uzun dönemler içeren ve daha kapsamlı verileri eğitmekte kullanılmaktadır. Etiketlenmemiş metinden oluşan derlemin birçok DDİ görevine katkısı görülmüştür [45]. Çalışmada etiketlenmemiş verilerden oluşan genişletilmiş derlem kullanımıyla elde edilen 1 milyon 860 bin tweetten 3 milyon 859 bin 322 eşsiz ifade elde edilmiştir. Böylelikle genişletilmiş derlem kullanımının sınıflandırma performansına katkısı görülmüştür.

4. BULGULAR

Türkçe gibi zengin morfolojik dil yapısına sahip olmak, bu alanda yapılan çalışmaların sayısını da etkilemiştir. Öyle ki Türkçe dilinde saldırgan içeriklerin tespit edilmesine yönelik çalışmanın oldukça az olduğu görülmüştür. Çalışmada bu alana katkı sağlamak amaçlanmıştır.

Çalışma da alana özgü verilerden oluşan bir genişletilmiş derlem elde edilmiştir. Çalışmanın bu bölümünde ise bu derlemden oluşturulan kelime temsillerinin başarıya katkısı gözlemlenmiştir. Buna ek olarak çalışmada hem ikili hem de çoklu sınıflandırma işlemleri yapılmıştır. Bilinebildiği kadarıyla çalışma, saldırgan içeriğin tanımlanmasına yönelik Türkçe dilinde ilk çoklu sınıflandırma yapan çalışmadır. Burada LSTM, GRU modellerinin Türkçe dilinde sınıflandırma başarıları karşılaştırılmıştır. Bu sınıflandırma işlemleri, metin sınıflandırma çalışmalarında en çok kullanılan derin öğrenme modelleri arasında yer almaktadır [49].

4.1. İki Sınıflı Verilerin Sınıflandırma Başarımlarının Değerlendirilmesi

Bu bölümde ilk olarak saldırgan ve saldırgan değil olarak sırasıyla '1' ve '0' olarak etiketlenmiş iki sınıflı verilerin sınıflandırma başarımları değerlendirilmiştir. Burada 14752 tweetten oluşan veri setinin 11802'si eğitim veri seti iken 2950'si test veri setidir. Rastgele seçilmiş olan test veri setinin 913'ü saldırgan olmayan, 2037'si saldırgan içerik barındırmaktadır. Böylelikle Tablo 1' de görülen başarımların değerleri, saldırgan içeriğin tespit edilebilme performansını göstermektedir. Bununla birlikte modeller eğitilirken alana özgü elde edilen genişletilmiş derlem kullanımının modellerin sınıflandırma performansına etkisi gösterilmiştir. Burada sınıflandırma performans değerlendirme ölçütlerinden F1-makro değeri baz alınmıştır.

Veri setinden elde edilen word2vec-CBOW kelime temsilleri kullanılarak iki sınıflı verilerin sınıflandırma başarımları F1-makro değeri LSTM %85,19 iken GRU %87,99 arasındadır (Tablo 1). Genişletilmiş derlemin sınıflandırma performansını yaklaşık %10 artırabildiği görülmüştür (Tablo 1). Buna ek olarak genişletilmiş derlem kullanılması değerlendirme sonuçlarını da yaklaştırmıştır. Bu durum genişletilmiş derlem kullanımının seçilen derin öğrenme yönteminin etkisini azalttığını göstermektedir. Ayrıca GRU ve LSTM arasında sınıflandırma performanslarına bakıldığında belirgin bir üstünlük görülmemiştir.

Tablo 1. Sınıflandırma işlemi F1-makro değer gösterimi.

	Veri Seti	Veri Seti+ Genişletilmiş Derlem
LSTM	85,19	94,21
GRU	87,99	94,49

4.2. Çok Sınıflı Verilerin Sınıflandırma Başarımlarının Değerlendirilmesi

Çalışmada sınıflandırma işlemi üç aşamalıdır. İlk aşamada veri seti saldırgan ve saldırgan değil olarak etiketlenmiştir. Burada ikili sınıflandırma söz konusudur. İkinci aşamada ise saldırgan olarak etiketlenen veriler, hedefli ve hedefsiz olarak alt sınıflara ayrılmıştır. Bu aşamada saldırgan olan tweet metninin bir hedefe yönelik olup olmadığına bakılarak etiketleme işlemi yapılmıştır. Üçüncü aşama da ise saldırgan olup hedefli olarak etiketlenen veriler birey, grup ve diğer olarak alt sınıflara ayrılmıştır. Burada saldırgan içeriğin yöneldiği hedefe göre etiketleme yapılmıştır. Bu ek olarak çoklu sınıflandırma yapılırken üstün sınıflandırma başarımları sebebiyle GRU modelinin performansına bakılmıştır.

İkinci aşama sınıflar bazında başarımlar değerlendirilmesi:

İkinci aşamada, ilk olarak hedefsiz, hedefli ve saldırgan değil sırasıyla '0', '1' ve '2' olarak etiketlenmiş çok sınıflı verilerin sınıflandırma başarımları değerlendirilmiştir. Burada 14752 tweetten oluşan veri setinin 11802'si eğitim veri seti iken 2950'si test veri setidir. Rastgele seçilmiş olan test veri setinin 913'ü saldırgan olmayan, 2037'si saldırgan içerik barındırmaktadır. 2037 saldırgan içerik barındıran tweetten 66'sı hedefsiz, 1971'i hedefli olarak etiketlenmiş verilerdir. Çoklu sınıflandırmayla ise F1-makro değeri %56,17'e ulaşmıştır. Genişletilmiş derlem kullanımıyla F1-makro değeri %15 oranında artış göstererek %71,97'e ulaşmıştır (Tablo 2).

Tablo 2. Çoklu sınıflandırma işlemi F1-makro değer gösterimi

	Veri Seti	Veri Seti+ Genişletilmiş Derlem
GRU	56,17	71,97

Üçüncü aşama sınıflar bazında başarımlar değerlendirilmesi:

Üçüncü aşamada, ilk olarak hedefsiz, birey, grup, diğer ve saldırgan değil sırasıyla '0', '1', '2', '3' ve '4' olarak etiketlenmiş çok sınıflı verilerin sınıflandırma başarımları değerlendirilmiştir. Burada 14752 tweetten oluşan veri setinin 11802'si eğitim veri seti iken 2950'si test veri setidir. Rastgele seçilmiş olan test veri setinin 913'ü saldırgan olmayan, 2037'si saldırgan içerik barındırmaktadır. 2037 saldırgan içerik barındıran tweetten 66' sı hedefsiz, 1971'i hedefli olarak etiketlenmiş verilerdir. 1971 hedefli içeriğin 1233'ü birey, 646 grup ve 92'si diğer olarak etiketlenmiş verilerdir.

Üçüncü aşama çoklu sınıflandırma başarımların değerleri karşılaştırılmıştır (Tablo 3.). Burada genişletilmiş derlem kullanımıyla F1-makro değerinde %14 oranında iyileşme sağlayarak %54,10 başarımların değeri elde edilmiştir. Bu değer modelin yeterince iyi olmadığını göstermektedir. Burada dengesiz veri problemine yönelik yöntemlerin değerlendirme performansını artıracığı düşünülmektedir. Ancak bu yöntemlerin değerlendirilmesi bu çalışmanın dışındadır.

Tablo 3. Çoklu sınıflandırma işlemi F1-makro değer gösterimi

	Veri Seti	Veri Seti+ Genişletilmiş Derlem
GRU	39,49	54,10

5. SONUÇLAR

Çalışmada Twitter platformundan elde edilen metin verileri sınıflandırılmıştır. Sınıflandırma işlemi üç aşamalıdır. Birinci aşamada saldırgan ve saldırgan değil olarak ikili sınıflandırma yapılmıştır. İkinci aşamada saldırgan olan tweet metni hedefli ve hedefsiz olarak ayrılmıştır. Böylelikle bu aşamada hedefli, hedefsiz ve saldırgan değil olarak çoklu sınıflandırma yapılmıştır. Üçüncü aşamada ise, hedefli olan tweet metni birey, grup, diğer olarak ayrılmıştır. Bu aşamada ise saldırgan değil, hedefsiz, birey, grup ve diğer olarak çoklu sınıflandırma yapılmıştır. Ayrıca bilinebildiği kadarıyla saldırgan dil tespitine yönelik bu alanda yapılan çalışmalara bakıldığında bu çalışma Türkçe dilinde çoklu sınıflandırma yapan ilk çalışmadır. Buna ek olarak çalışmada Türkçe’ de bilinen 150’den fazla saldırgan dil içeren kelime ve kelime öbekleri aratılarak veri seti ve genişletilmiş derlem oluşturulmuştur. Burada veri çeşitliliği sağlamak için geçmişe dayalı arama yapılmıştır. Veri setinde yer alan 14752 tweet metni yukarıda belirtilen sınıflandırma kriterlerine göre manuel olarak etiketlenmiştir. Burada saldırgan dil etiketleme işleminin öznel yargılar barındırmasından kaynaklı etiketleyiciler arasında uyum problemi ile karşılaşmıştır. Bu problemin çözümünde oy sistemi ile çoğunluğun kararına bakılmıştır. Ayrıca 1 milyon 860 bin alana özgü tweet metinlerinden oluşan genişletilmiş derlem elde edilmiştir. Böylelikle genişletilmiş derlemde word2vec-CBOW yöntemi kullanılarak elde edilen kelime temsillerinin sınıflandırma performansına katkısı görülmüştür. İki sınıflı verilerin sınıflandırma başarımları F1-makro değeri LSTM %85,19 iken GRU %87,99 arasındadır. Genişletilmiş derlem kullanımı LSTM modeli sınıflandırma performansını yaklaşık %10 artırarak %94,21’e ulaştırmıştır. Bununla birlikte GRU modelinin genişletilmiş derlem kullanımı ile sınıflandırma performansı %94,49’tür. Bu iki model arasında belirgin bir üstünlüğün olmaması ile birlikte çoklu sınıflandırma yapılırken daha üstün performans gösteren GRU modeli tercih edilmiştir. Böylelikle GRU modelinin performansı genişletilmiş derlem kullanımının etkisiyle çoklu sınıflandırmada sırasıyla %15,08 artış ile %71,97 ve 14,61 artış ile de %54,10 olmuştur. Sonuç olarak çalışmada genişletilmiş derlemin sınıflandırma performanslarına iyileştirici etkisi görülmüştür.

Yazarların Katkısı

Yazarlar çalışmaya eşit oranlı katkı sunmuşlardır.

Çıkar Çatışması

Makale yazarları, aralarında herhangi bir çıkar çatışması olmadığını beyan ederler

KAYNAKÇA

- [1] E. Cambria, S. Poria, A. Gelbukh, and M. Thelwall, “Sentiment Analysis Is a Big Suitcase”, IEEE Intelligent Systems, vol. 32, no. 6, pp. 74–80, 2017.
- [2] B. Liu, “Sentiment analysis and opinion mining”, Synthesis Lectures on Human Language Technologies, vol. 5, no. 1, pp. 160-167, 2012 .
- [3] W. Craig, M. Boniel-Nissim, N. King, S. D. Walsh, M. Boer, P. D. Donnelly, and R. Van den Eijnden, “Social media use and cyber-bullying: a cross-national analysis of young people in 42 countries”, Journal of Adolescent Health, vol. 66 no. 6, pp. 100-108, 2020.
- [4] S. Hinduja, and J. W. Patchin, “Bullying, cyberbullying and suicide”, Archiands of suicide Research, vol. 14, no. 3, pp. 206-221, 2010.
- [5] C. Newberry, “36 Twitter Stats All Marketers Need to Know in 2021”, <https://blog.hootsuite.com/twitter-statistics/> (Erişim Tarihi: Nisan 12, 2022).
- [6] Twitter, Rules Enforcement, <https://transparency.twitter.com/en/reports/rules-enforcement.html#2020-jul-dec> (Erişim Tarihi: Haziran 12, 2021).
- [7] K. Oflazer, “Türkçe ve Doğal Dil İşleme”, Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, vol. 5, no. 2, 2016.
- [8] R. Dehkharghani, Y. Saygin, B. Yanikoglu, and K. Oflazer, “SentiTurkNet: a Turkish polarity lexicon for sentiment analysis”, Language Resources and Evaluation, vol. 50, no. 3, pp. 667-685, 2016.
- [9] R. Dehkharghani, B. Yanikoglu, D. Tapucu, and Y. Saygin, “Adaptation and use of subjectivity lexicons for domain dependent sentiment classification”, In 2012 IEEE 12th International Conference on Data Mining Workshops, pp. 669-673, 2012.
- [10] S. Stamou, A. Ntoulas, J. Hoppenbrouwers, M. Saiz-Noeda, and D. Christodoulakis, “Euroterm: Extending the eurowordnet with domain-specific terminology using an expand model approach”, In Proceedings of the 1st International Global Wordnet Conference, 2002.
- [11] K. Oflazer, “Two-level description of Turkish morphology”, Literary and Linguistic Computing, vol. 9, no. 2, pp. 137-148, 1994.
- [12] D. Z. Hakkani-Tür, K. Oflazer, and G. Tür, “Statistical morphological disambiguation for agglutinative languages”, Computers and The Humanities, vol. 36, no. 4, pp. 381-410, 2002.
- [13] K. Oflazer, and I. Kuruoz, “Tagging and morphological disambiguation of Turkish text”, arXiv preprint cmp-lg/9407026, 1994.
- [14] K. Oflazer, B. Say, D. Z. Hakkani-Tür, and G. Tür, “Building a Turkish treebank”, In Treebanks, pp. 261-277, 2003
- [15] Z. Özer, “The effect of normalization on the classification of traffic comments”, Doctorate Thesis,


- Karabük University, Computer Science Enstitute, Karabük, pp. 15-23., 2019.
- [16] A. Safaya, E. Kurtuluş, A. Göktoğan, and D. Yuret, “Mukayese: Turkish NLP Strikes Back”, Association for Computational Linguistics, pp. 846-863, 2022
- [17] S. Yılmaz, and S. Toklu, “A deep learning analysis on question classification task using Word2vec representations”, Neural Computing and Applications, vol. 32, no. 7, pp. 2909-2928, 2020.
- [18] M. Zampieri, S. Malmasi, P. Nakov, S. Rosenthal, N. Farra, and R. Kumar, “SemEval-2019 Task 6: Identifying and Categorizing Offensive Language in Social Media (OffensEval)”, In Proceedings of the 13th International Workshop on Semantic Evaluation, pp. 75–86.
- [19] M. Wiegand, M. Siegel, and J. Ruppenhofer, “Oandvview of the GermEval 2018 shared task on the identification of offensiand language”, In Proceedings of the GermEval 2018 Workshop at Konandns, pp. 1– 10, 2018.
- [20] Ş. Sarmaşık, “İşyerinde cinsel taciz algılaması ve yönetim ilişkilerine etkisi hakkında bir araştırma”, Yüksek Lisans Tezi, 2009.
- [21] D. Reinsel, J. Gantz and J. Rydning, “Data Age 2025: The Evolution of Data to Life-Critical,” www-content/our-story/trends/files/SeagateWPDataAge2025-March-2017 ((Erişim Tarihi: Ağustos 12, 2020).
- [22] M. R. Mehl, and J. W. Pennebaker, “The sounds of social life: A psychometric analysis of students’ daily social environments and natural conandrsations”, Journal of Personality and Social Psychology, vol. 84, no. 4, p. 857, 2003.
- [23] W. Wang, L. Chen, K. Thirunarayan, and A. P. Sheth, “Cursing in english on twitter”, In Proceedings of the 17th ACM conference on Computer Supported Cooperatiand Work and Social Computing, pp. 415-425, 2014.
- [24] J. M. Xu, K. S. Jun, X. Zhu, and A. Bellmore, “Learning from bullying traces in social media”, In Proceedings of the 2012 conference of the North American chapter of the association for computational linguistics: Human Language Technologies, pp. 656-666, 2012.
- [25] Ç. Çöltekin, “A corpus of Turkish offensiand language on social media”, In Proceedings of the 12th Language Resources and Evaluation Conference, pp. 6174-6184, 2020.
- [26] V. Basile, C. Bosco, E. Fersini, N. Debora, V. Patti, F. M. R. Pardo, and M. Sanguinetti, “Semeval-2019 task 5: Multilingual detection of hate speech against immigrants and women in twitter”, In 13th International Workshop on Semantic Evaluation, pp. 54-63, 2019.
- [27] I. Kwok, and Y. Wang, “Locate the hate: detecting tweets against blacks”, Proceedings of the Twenty-Seventh AAAI Conference on Artificial Intelligence, pp. 1621-1622, 2013.
- [28] B. Ross, M. Rist, G. Carbonell, B. Cabrera, N. Kurowsky and M. Wojatzki. “Measuring the reliability of hate speech annotations: The case of the european refugee crisis”, In Proceedings of NLP4CMC III: 3rd Workshop on Natural Language Processing for Computer-Mediated Communication, vol. 17, no. 1, pp. 6–9, 2016.
- [29] S. Jaki, and T. De Smedt, “Right-wing German hate speech on Twitter: Analysis and automatic detection”, arXiv:1910.07518, 2019.
- [30] P. Burnap, M. L. Williams, L. Sloan, O. Rana, W. Housley, A. Edwards, and A. Voss, “Tweeting the terror: modelling the social media reaction to the Woolwich terrorist attack”, Social Network Analysis and Mining, vol. 4, no. 1, pp. 1-14, 2014.
- [31] M. Dadvar, D. Trieschnigg, R. Ordelman, and F. de Jong, “Improving cyberbullying detection with user context” In European Conference on Information Retrieval, pp. 693–696, 2013.
- [32] M. Dadvar, D. Trieschnigg, and F. de Jong, “Experts and machines against bullies: A hybrid approach to detect cyberbullies”, In Canadian Conference on Artificial Intelligence, pp. 275–281, 2014.
- [33] K. Dinakar, B. Jones, C. Havasi, H. Lieberman, and R. Picard, “Common sense reasoning for detection, preandntion and mitigation of cyberbullying”, ACM Transactions on Interactiand Intelligent Systems (TiiS), vol. 2, no. 3, pp. 18, 2012.
- [34] T. Nitta, F. Masui, M. Ptaszynski, Y. Kimura, R. Rzepka, and K. Araki, “Detecting cyberbullying entries on informal school websites based on category relevance maximization”, In Proceedings of the Sixth International Joint Conference on Natural Language Processing, pp. 579-586, 2013.
- [35] American Psychological Association, “APA resolution on bullying among children and youth”, <http://www.apa.org/about/goandnance/council/policy/bullying.pdf>. (Erişim Tarihi: Haziran 20, 2020).
- [36] Y. Chen, Y. Zhou, S. Zhu, and H. Xu, “Detecting offensiand language in social media to protect adolescent online safety”, In 2012 International Conference on Privacy, Security, Risk and Trust and 2012 International Confernece on Social Computing, pp. 71–80, 2012.
- [37] J. M. Struß, M. Siegel, J. Ruppenhofer, M. Wiegand, and M. Klenner, “Oandvview of GermEval task 2, 2019 shared task on the identification of offensiand language”, In Preliminary proceedings of the 15th Conference on Natural Language Processing (KONANDNS 2019), pp. 352– 363, 2019.
- [38] Z. Waseem, T. Davidson, D. Warmesley, and I. Weber, “Understanding Abuse: A Typology of Abusive Language Detection Subtasks”, In Proceedings of the First Workshop on Abusiand Language Online, pp. 78–84, 2017.
- [39] J. Ruppenhofer, M. Siegel, and M. Wiegand, “Guidelines for IGGSA shared task on the identification of offensiand language.” <https://github.com/uds-lsv/GermEval-2018-Data/blob/master/guidelines-iggga-shared.pdf>, 2018 (Erişim Tarihi: Kasım 20, 2020).
- [40] M. Zampieri, S. Malmasi, P. Nakov, S. Rosenthal, P. Atanasova, G. Karadzov, H. Mubarak, L. Derczynski, Z. Pitenis, and Ç. Çöltekin, “SemEval-

- 2020 Task 12: Multilingual Offensive Language Identification in Social Media (OffensEval 2020)”, In Proceedings of the Fourteenth Workshop on Semantic Evaluation, pp. 1425–1447, 2020.
- [41] Ş. Ş. Yılmaz, İ. Özer, ve H. Gökçen, “Türkçe Metinlerde Derin Öğrenme Yöntemleri Kullanılarak Duygu Analizi”, In International Symposium of Scientific Research and Innovative Studies, vol. 22, pp. 971-982, 2021.
- [42] E. Filatova, “Irony and Sarcasm: Corpus Generation and Analysis Using Crowdsourcing”, In Lrec, pp. 392-398, 2012.
- [43] M. Sharma, I. Kandasamy, and V. Kandasamy, “Deep Learning for predicting neutralities in Offensive Language Identification Dataset”, Expert Systems with Applications, vol. 185, p. 115458, 2021.
- [44] H. Qiu, Y. Zeng, T. Zhang, Y. Jiang, and M. Qiu, “FenceBox: A Platform for Defeating Adversarial Examples with Data Augmentation Techniques”, ArXiv: 2012.01701, 2020.
- [45] P. Bojanowski, E. Graand, A. Joulin, and T. Mikolov, “Enriching word andctors with subword information”, Transactions of the Association for Computational Linguistics, vol. 5, pp. 135-146, 2017.
- [46] I. Ozer, Z. Ozer, and O. Findik, “Noise robust sound event classification with convolutional neural network”, Neurocomputing, vol. 272, pp. 505-512, 2018.
- [47] Z. Ozer, I. Ozer, and O. Findik, “Diacritic restoration of Turkish tweets with word2vec”, Engineering Science and Technology, an International Journal, vol. 21, no. 6, pp. 1120-1127, 2018.
- [48] I. Ozer, Z. Ozer, and O. Findik, “Lanczos kernel-based spectrogram image features for sound classification”, Procedia computer science, vol. 111, pp.137-144,2017.
- [49] A. Ligthart, C. Catal, and B. Tekinerdogan, “Systematic reviews in sentiment analysis: a tertiary study”, Artificial Intelligence Revolution, vol. 54, pp. 4997–5053, 2021.
- [50] L. Bowker, and J. Pearson, “Working with specialized language: A practical guide to using corpora”, New York: Routledge, pp. 15-29, 2002.
- [51] U. Römer, “The inseparability of lexis and grammar: Corpus linguistic perspectives”, Annual Review of Cognitive Linguistics, vol. 7, no. 1, pp. 140-162, 2009.
- [52] A. K. Uysal, and S. Gunal, “The impact of preprocessing on text classification”, Information Processing and Management, vol. 50, no.1, pp. 104-112, 2014.



BMBAD
BJESR

Mühendislik Bilimleri ve Araştırmaları Dergisi
Journal of Engineering Sciences and Researches



Evaluation of Machine Learning Performance in Wildfire Susceptibility Mapping Under Limited Training Data Condition

Sınırlı Eğitim Verileri Durumunda Orman Yangını Duyarlılık Haritalamasında Makine Öğrenimi Performansının Değerlendirilmesi

¹Mahyat SHAFAPOURTEHRANY 

¹Kandilli Observatory and Earthquake Research Institute, Department of Geodesy, Bogazici University, 34680 Cengelkoy, Istanbul, Turkey

mahyat.shafapour@boun.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 12 September 2022
Accepted : 13 October 2022

Keywords:

Wildfire, Inventory, Turkey, Susceptibility, Geospatial

ABSTRACT

Wildfire susceptibility mapping can be affected by several factors. One of the most influential factors is inventory data, its extent, format, and reliability. This study aims to evaluate if the Support Vector Machine (SVM) has the capability to identify wildfire susceptible regions under limited training data conditions. To test this hypothesis wildfires in Muğla province in the Eastern Mediterranean Region of Turkey have been selected as a pilot study area. The wildfire started in Muğla, on 29 July 2021, that considerably affected the residential areas, animals, and vast areas of forests. Fourteen wildfire influential variables have been used in the analysis as independent variables. Accuracy assessment has been implemented using the Area Under the Curve (AUC) technique. Success rate and prediction rates were (91.42%) and (87.69%) respectively. According to the prediction rate, SVM successfully recognized other burnt areas as the most susceptible regions.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 12 Eylül 2022
Kabul : 13 Ekim 2022

Anahtar Kelimeler:

Orman Yangını, Envanter, Türkiye, Duyarlılık, Jeo-uzamsal

ÖZET

Orman yangını duyarlılık haritalaması çeşitli faktörlerden etkilenebilir. En etkili faktörlerden biri envanter verileri, kapsamı, biçimi ve güvenilirliğidir. Bu çalışma, Support Vector Machine'in (SVM) sınırlı eğitim verisi koşulları altında orman yangınına duyarlı alanları tespit etme ve haritalama kabiliyetine sahip olup olmadığını değerlendirmeyi amaçlamaktadır. Bu hipotezi test etmek için Türkiye'nin Doğu Akdeniz Bölgesi'nde yer alan Muğla ilindeki orman yangınları pilot çalışma alanı olarak seçilmiştir. Bahsedilen orman yangını Muğla'da 29 Temmuz 2021'de başlamış ve yerleşim alanlarını, hayvanları ve geniş ormanlık alanları önemli ölçüde etkilemiştir. Bağımsız değişkenler olarak on dört orman yangını etkili değişken analizinde kullanılmıştır. Doğruluk değerlendirmesi için Area Under the Curve (AUC) tekniği kullanılarak uygulama yapılmıştır. Başarı oranı ve tahmin oranları sırasıyla (%91.42) ve (%87.69)'dir. Tahmin oranına göre, SVM diğer yanık alanları en hassas bölgeler olarak başarıyla tanımladı.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. INTRODUCTION

Wildfire is among the most harmful natural disasters affecting both lives and properties around the world [1]. Global temperature rise, reduction in precipitation, and human activities led to an increase in wildfire occurrences [2; 3]. Natural hazards usually occur under specific conditions and in partially predicted areas [4]. Therefore, they can be studied and prevented up to some levels [5]. Remote Sensing (RS) technology and Geographical Information Systems (GIS) are wonderful systems to monitor and analyze wildfires over large areas in a timely and cost-effective manner [6]. Studying the wildfire can be done from different aspects. Some of the most popular studies are related to wildfire susceptibility [7], hazard [8], vulnerability [9], risk [10] and etc. Wildfire susceptibility considers a basis for other evaluations. In the natural hazard scope, a susceptibility map recognizes regions that are more or less disposed to a potential wildfire occurrence using low to high possibility values/classes [11]. In order to perform wildfire susceptibility, two main datasets of previous wildfire extent (dependent variable) and a set of conditioning factors (independent variables) are essential [12]. Inventory data, conditioning factors, and the used method, each play an important role in the precision and reliability of the results. Therefore, they have to be selected carefully. This research focuses on the role of wildfire inventory. In some cases, an inventory extent might be limited due to non-accessibility to all affected areas. Therefore, the hypothesis is that performing a robust method along with an adequate conditioning factors dataset could compensate for the limitation of wildfire inventory data.

In summer 2021, due to the severe heatwave and dry weather, Turkey faced its worst wildfires in years [13]. During that summer around 130 wildfires have been detected in 30 provinces [14]. Wildfires mostly occurred along the Mediterranean and the Aegean Sea coasts. According to the European Forest Fire Information Service, about 136,000 hectares have burned which was about three times the average for an entire year [13]. Fortunately, a complete set of inventories is available for this region. Therefore, a small portion of this dataset was used for training and performing the wildfire susceptibility modeling. The rest of the inventory has been kept and used for accuracy assessment. The aim was to examine whether SVM can predict other susceptible areas or not. There are a large number of methods available in order to perform wildfire susceptibility mapping. They can be grouped into qualitative and quantitative methods [15]. Qualitative methods like Analytical Hierarchy Process (AHP) [9] and fuzzy logic have been utilized by several researchers to assign weight to wildfire conditioning factors according to their significance in wildfire occurrence. Such techniques are mostly based on experts' knowledge that in some cases might contain errors.

Quantitative techniques predict wildfire susceptibility regions using mathematical assessment of the data [16]. In addition, the subjectivity of qualitative approaches is not included in quantitative techniques. Logistic Regression (LR) [17], Frequency Ratio (FR) [18], Evidential Belief Function (EBF) [19], the Weight of Evidence (WOE) [18], Artificial Neural Network (ANN) [20], etc. are a few examples of quantitative methods. Among the broad range of quantitative methods, Machine Learning (ML) techniques are widely used in natural hazard studies [12; 21]. They recognize and model non-linear correlations among wildfire and their relevant conditioning factors. Wildfire inventory is an essential factor in ML analysis. Compared to qualitative techniques like AHP, the proficiency of ML methods is that they perform more reliable and faster outcomes [22]. The undeniable efficiency of ML in natural hazard solutions motivated us to test the hypothesis of this study using this technique. Among all ML methods, Support Vector Machine (SVM) [23] has been selected to find the association between wildfire conditioning factors and inventory data.

2. STUDY AREA

Mugla province has been chosen as the study area. It is between 27°13'30" and 29°41'00"W longitude and 36°18'22" and 37°35'10"N latitude. Mugla is situated at the intersection between the Aegean and the Mediterranean Sea. Pine honey production makes the forests of this region so valuable. According to Forest General Directorate (<https://www.ogm.gov.tr/tr>), 9% of Turkey's wildfires have occurred in Mugla province [24]. Every year around 500 ha of its forests has been destroyed. Mugla has a warm temperature and rain falls mostly in the winter. The study area's location along with a few wildfire figures that occurred in 2021 are represented in Figure 1.



Figure 1. Mugla province and wildfire inventory.

3. METHODOLOGY

3.1. Data Used

As has been mentioned in the introduction section, wildfire inventory and conditioning factors are two essential elements in wildfire susceptibility mapping. Both dataset details and their sources have been listed in Table I. The wildfire inventory map (summer 2021 wildfires) in Mugla has been received from Fire Information for Resource Management System Website (FIRMS). Selected areas in Figure 2 represents the portion of the inventory map which was utilized for training purpose, and the rest of the inventory points were used in order to test the outcomes.




Figure 2. Training and testing points.

Wildfire conditioning factors have been chosen according to the literature. Altitude, slope, aspect, curvature, TWI, TRI, TPI, precipitation, NDVI, wind, distance to rivers, distance to roads, temperature, and LULC have been used as the wildfire's most influential factors in the analysis (Figure 3). Altitude has an influence on the wind behavior and climatic conditions such as precipitation and temperature [25]. Altitude data was received with a 30 m resolution. Subsequently, other wildfire conditioning factors were resampled to the same spatial resolution. The direction of fire spread and fire rate is controlled by the slope factor [26]. In addition, the slope has a significant role in wind speed. Higher slopes cause faster wildfire spread. Aspect which shows the slope faces directions affects the amount of sunlight received [27]. Knowing the slope aspect, the temperature and humidity of the region can be predicted. For instance, the southern faces received more sunlight compared to the northern faces. Therefore, they are more prone to wildfires as they have the longest exposure time to sunlight. Meaning that fuels on the southern faces dry faster compared to other aspects of the region. The morphology of topography is represented by curvature [28]. Positive and negative curvatures show that the surface is convex and concave at that cell respectively. Also, a value of zero shows that the surface is flat at that cell. In wildfire studies the wetness of the ground is important, therefore, TWI has been measured as well, which is calculated based on (1) [29]:

$$TWI = \ln \frac{\alpha}{\tan \beta} \quad (1)$$

where α is the cumulative up slope area and $\tan \beta$ is the slope angle at the point. TRI is another wildfire influential factor. TRI is the ratio of the variable surface area to the planimetric surface area that is given as (2):

$$TRI = \frac{(Area_v - Area_1)}{(Area_p - Area_1)} \quad (2)$$

The higher the TRI values the greater the topographic roughness. This factor can range from 1 to 800. Value 1 represents the completely flat area [30]. Precipitation is another wildfire influential factor that has a great impact on fuel moisture and soil moisture. NDVI factor has been used in order to measure the vegetation cover. It was prepared using Landsat-8 images according to (3):

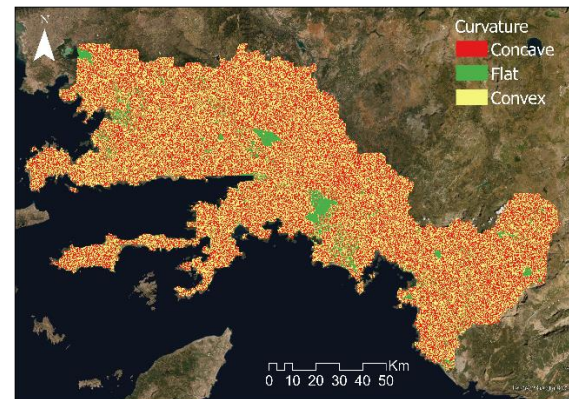
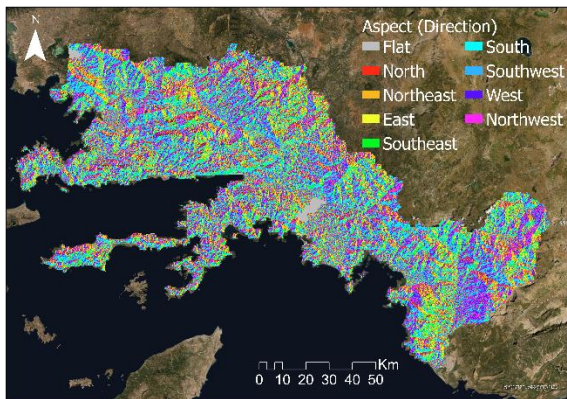
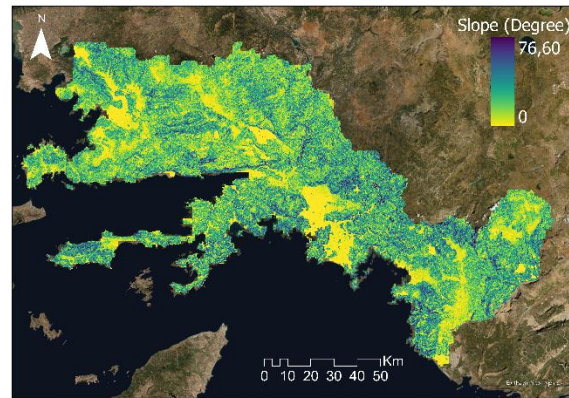
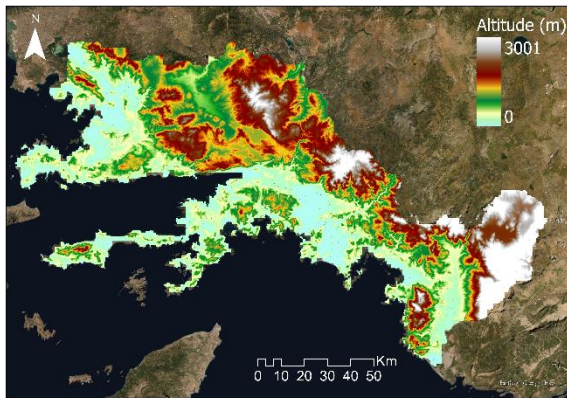
$$NDVI = \frac{NIR - R}{NIR + R} \quad (3)$$

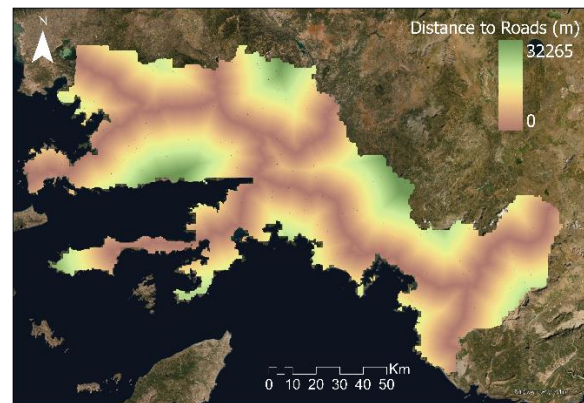
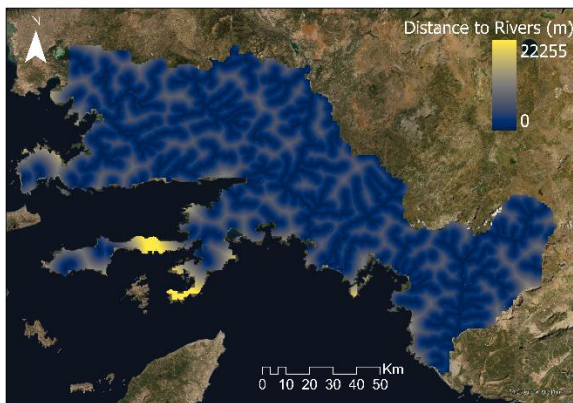
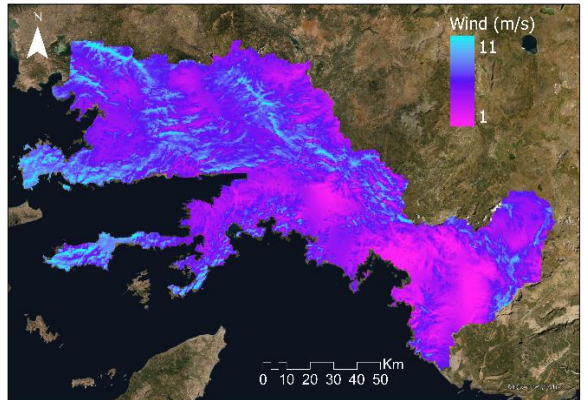
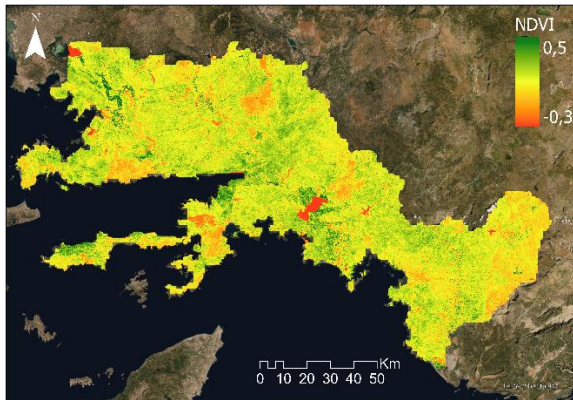


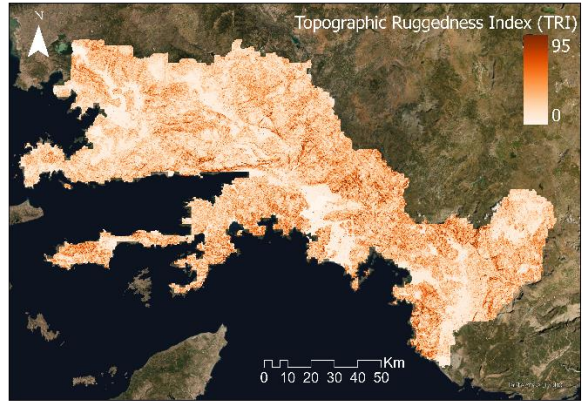
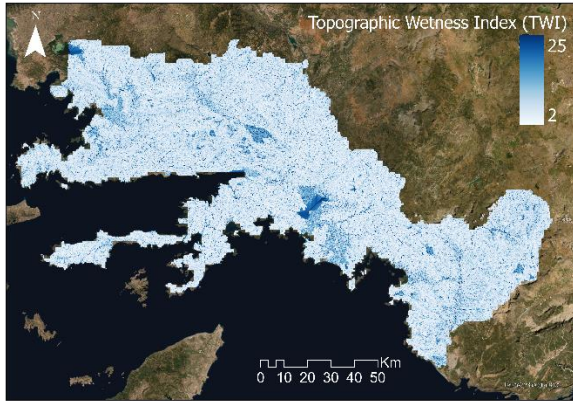
where NIR and R values are the infrared and red bands, respectively. Another critical conditioning factor is wind. It has a great effect on the spread and direction of the wildfire [32]. Therefore, it is necessary to consider it as one of the conditioning factors as well. Rivers and roads are liner features that act as a barrier to wildfire spread. Therefore, the distance to these factors has been measured and used in the analysis. Another factor that has an impact on fuel availability and condition is the temperature [23]. Therefore, this factor also has been included in

the wildfire susceptibility assessment. Wildfires act differently in different types of forests [33]. For instance, shrub species and flammable forest vegetation types increase the ignition risk [34]. Dense and dry forests are more susceptible to wildfire occurrences compared to moist vegetated areas [35].

Table 1. The sources of data used.

Data	Sources
Forest fire inventories	Fire Information for Resource Management System Website https://firms.modaps.eosdis.nasa.gov/
Altitude	Digital Elevation Model (DEM) from Earthdata Website https://www.earthdata.nasa.gov/
Slope, Aspect, Curvature, TWI, TRI, TPI,	Derived from Digital Elevation Model (DEM)
Precipitation	WorldClim Website https://www.worldclim.org/
NDVI	Landsat 8
Wind	https://globalwindatlas.info/area/Australia
Distance to rivers	https://land.copernicus.eu/imagery-in-situ
Distance to roads	OpenStreetMap https://www.openstreetmap.org/
Temperature	WorldClim Website https://www.worldclim.org/
LULC	CORINE https://land.copernicus.eu/pan-european/corine-land-cover





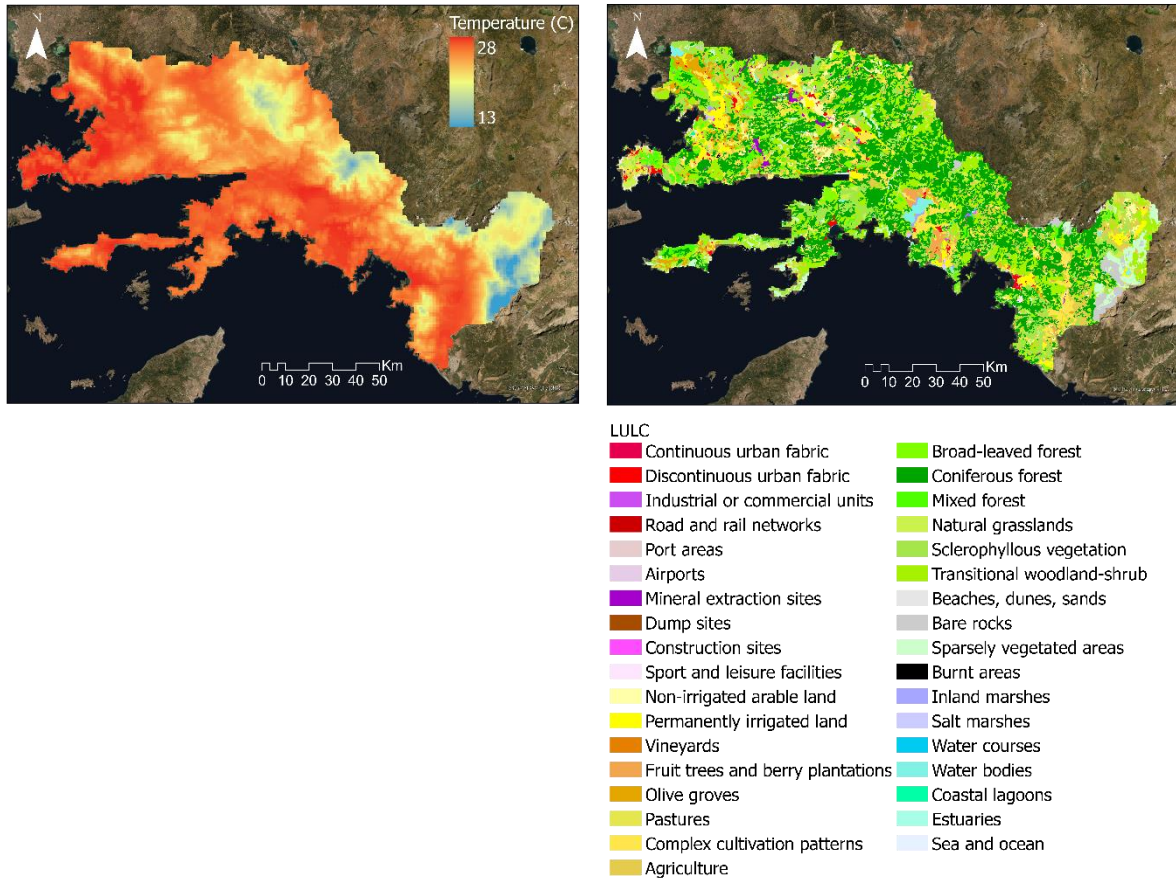


Figure 3. Wildfire conditioning factors.

3.2. Support Vector Machine (SVM)

In the literature, the SVM method has been used to solve complex classification and regression problems in flood [36], landslide [37], wildfire [38], earthquake [39], etc. domains. It is a supervised ML method that performs based on statistical learning theory [40]. SVM reforms the nonlinear world into the linear using hyper-plane which makes it simple and processable [41]. The aforementioned data transformation will be done using a mathematical function called kernel function [42]. SVM is able to transform the original input into a high-dimensional feature space. A separating hyper-plane is generated in the original space of n coordinates (x_i parameters in vector x) between the points of two distinct classes. SVM finds a maximum margin of separation between the classes and builds a classification hyper-plane in the center of the maximum margin [43]. The point will be classified as +1, in the case that it is overhead the hyper-plane and if not, it will be classified as -1. Subsequently, new data will be grouped according to its characteristics. The closest training points to the hyperplane are called support vectors.

For instance, consider a training dataset of instance-label pairs (x_i, y_i) with $x_i \in R^n$, $y_i \in \{-1, 1\}$, and $i = 1, \dots, m$. In the present circumstance of wildfire susceptibility, x is a vector of input space that contains altitude, slope, aspect, curvature, TWI, TRI, TPI, precipitation, NDVI, wind, distance to rivers, distance to roads, temperature, and LULC. The two classes $\{-1, 1\}$ specify wildfire pixels and non-wildfire pixels. Recognizing the optimal separating hyper-plane is the goal of SVM, which can separate the two classes into wildfire and non-wildfire $\{-1, 1\}$ from the training dataset. For the case of linearly separable data, a separating hyper-plane can be defined as (4):

$$y_i (w \cdot x_i + b) \geq 1 - \xi_i \quad (4)$$

where w is a coefficient vector that defines the orientation of the hyper-plane in the feature space, b is the offset of the hyper-plane from the origin, and ξ_i is the positive slack variables. A comprehensive description of SVM and its internal calculations are presented in Noble [44], Suthaharan [45], Meyer *et al.* [46], etc.

3.3. Area Under the Curve (AUC)

Among a variety of accuracy assessment techniques, AUC is the most popular technique in natural hazard studies which provides the prediction and success rates [18; 47; 48]. The proficiency of AUC in evaluating the susceptibility mapping outcomes has been assessed in the literature. AUC evaluates the existence of the known

natural hazard inventory data in the derived susceptibility map. Firstly, the wildfire susceptibility map was divided into equal intervals and hierarchically ranked from minimum to maximum. The calculated values of all cells were sorted into descending order, and cell values were split into 100 classes with 1% accumulation intervals. The “tabulate area” tool in ArcGIS was utilized to examine the existence of wildfire in each class. Finally, the success curve and prediction curve indicated the percentage of wildfires in each interval.

4. RESULTS AND DISCUSSION

SVM has been applied and a wildfire susceptibility map has been generated. The correlation between wildfire inventory and conditioning factors was evaluated using SVM. The wildfire inventory map (summer 2021 wildfires) in Mugla has been received from FIRMS. A small portion of inventory data (30%) was used to train SVM and 70% was utilized for accuracy assessment. The reason is to test if SVM was able to perform accurately in case of limited training data. Regarding the conditioning factors, altitude, slope, aspect, curvature, TWI, TRI, TPI, precipitation, NDVI, wind, distance to rivers, distance to roads, temperature, and LULC have been used. Altitude was derived from DEM downloaded from “Earthdata Website” which ranged from 0 to 3001 meters. Other topographical factors of slope (0-76.60°), aspect (nine slope directions), curvature (concave, flat, and convex), TWI (2-25), TRI (0-95) and TPI (-119-105) were derived from DEM. WorldClim Website was used to extract the annual precipitation (3-20) in the study area. NDVI factor (-0.3-0.5) was calculated from Landsat imagery. Wind factor (1-11 m/s) was downloaded from the global wind atlas website. Distance to rivers (0-22255m) and roads (0-32265) were calculated using the Euclidean distance tool in ArcGIS. The temperature (13-28C) factor was received from WorldClim Website and detailed LULC with 35 categories was received from CORINE Website.

Figure 4 shows the wildfire susceptibility map for Mugla province. It illustrates the susceptibility of wildfire incidents according to the related wildfire conditioning variables. The quantile classification technique has been used to group the wildfire susceptibility maps into classes of “very high”, “high”, “moderate”, “low”, and “very low”. Figure also represents the inventory point around the region. Interestingly, inventory points are mostly placed in “high” and “very high”. In order to prove the success of the SVM in detecting susceptible areas, AUC has been applied. Success rate and prediction rates were (91.42%) and (87.69%) respectively. Hence, visually and mathematically it has been proven that SVM can undertake wildfire susceptibility mapping under limited training data conditions with high accuracy. As can be seen in figure, the most susceptible areas are the regions with high slope degrees, high temperature, less precipitation, and higher wind speed. These areas need to be carefully monitored and managed for future planning and disaster management.

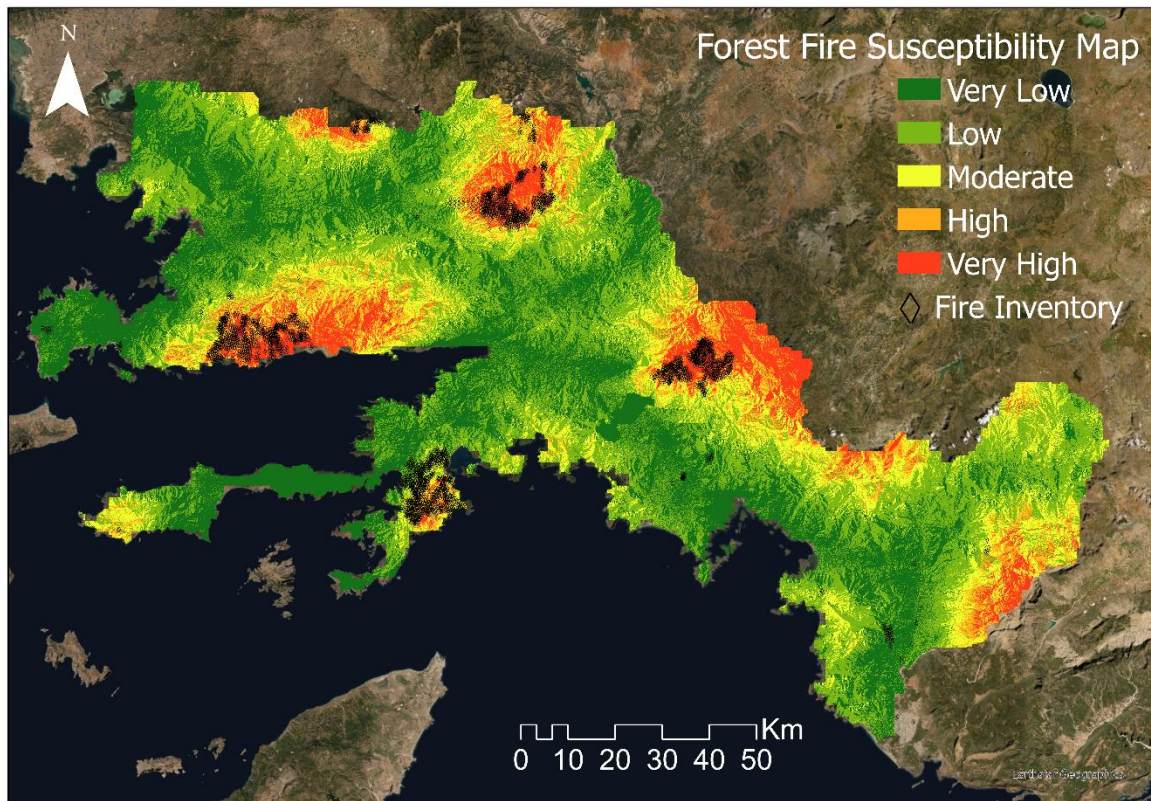


Figure 4. Wildfire susceptibility map.

5. CONCLUSION

The wildfire susceptibility map helps several sectors in order to study, plan, manage and mitigate this disaster. It can considerably contribute to detecting the susceptible zones and subsequently prevent possible damage in the future. RS and GIS technologies proved to be promising tools in the natural hazard studies domain. This study performed wildfire susceptibility mapping using small inventory data and tested the reliability of the outcomes using the actual inventory which has not been used in training the method. The aim was to examine if SVM is capable to provide accurate susceptibility analysis in the case of lack of training. In some regions, there is limited access to the affected areas, therefore, the inventory dataset will not be as accurate as possible. The susceptibility mapping has been performed and the study area has been classified into different susceptible regions. Subsequently, the AUC method has been applied and the prediction rate of 87.69% has been achieved. It has been concluded that a combination of relevant and accurate conditioning factors datasets with the ML method can compensate for the limited inventory dataset in similar cases.

Statement of Conflict of Interest:


Author has declared no conflict of interest.

REFERENCES

- [1] P. Barmpoutis, P. Papaioannou, K. Dimitropoulos, and N. Grammalidis, "A review on early forest fire detection systems using optical remote sensing", *Sensors*, vol. 20, p. 6442, 2020.
- [2] A. Aldersley, S. J. Murray, and S. E. Cornell, "Global and regional analysis of climate and human drivers of wildfire", *Science of the Total Environment*, vol. 409, pp. 3472-3481, 2011.
- [3] Y. Liu, Y. Liu, J. Fu, C.-E. Yang, X. Dong, H. Tian, B. Tao, J. Yang, Y. Wang, and Y. Zou, "Projection of future wildfire emissions in western USA under climate change: contributions from changes in wildfire, fuel loading and fuel moisture", *International Journal of Wildland Fire*, vol. 31, pp. 1-13, 2021.
- [4] A. Brenning, "Spatial prediction models for landslide hazards: review, comparison and evaluation", *Natural Hazards and Earth System Sciences*, vol. 5, pp. 853-862, 2005.
- [5] N. Boers, B. Bookhagen, H. M. Barbosa, N. Marwan, J. Kurths, and J. Marengo, "Prediction of extreme floods in the eastern Central Andes based on a complex networks approach", *Nature communications*, vol. 5, pp. 1-7, 2014.
- [6] K. Perera, R. Tateishi, K. Akihiko, and S. Herath, "A Combined Approach of Remote Sensing, GIS, and Social Media to Create and Disseminate Bushfire Warning Contents to Rural Australia", *Earth 2*, pp. 715-730, 2021.
- [7] K. Crawford-Flett, D. M. Blake, E. Pascoal, M. Wilson, and L. Wotherspoon, "A standardised inventory for New Zealand's stopbank (levee) network and its application for natural hazard exposure assessments", *Journal of Flood Risk Management*, vol. 15, pp. e12777, 2022.
- [8] M. E. Jenkins, M. Bedward, O. Price, and R.A. Bradstock, "Modelling bushfire fuel hazard using biophysical parameters", *Forests* 11, p. 925, 2020.
- [9] O. Ghorbanzadeh, T. Blaschke, K. Gholamnia, and J. Aryal, "Forest fire susceptibility and risk mapping using social/infrastructural vulnerability and environmental variables", *Fire* 2, vol. 2, no. 3, p. 50, 2019.
- [10] E. Moskwa, D. K. Bardsley, G. M. Robinson, and D. Weber, "Generating narratives on bushfire risk and biodiversity values to inform environmental policy", *Environmental Science and Policy*, vol. 89, pp. 30-40, 2018.
- [11] M. Shafapour Tehrany, L. Kumar, M. Neamah Jebur, and F. Shabani, "Evaluating the application of the statistical index method in flood susceptibility mapping and its comparison with frequency ratio and logistic regression methods", *Geomatics, Natural Hazards and Risk*, vol. 10, pp. 79-101, 2019.
- [12] K. Gholamnia, T. Gudiyangada Nachappa, O. Ghorbanzadeh, and T. Blaschke, "Comparisons of diverse machine learning approaches for wildfire susceptibility mapping", *Symmetry* vol. 12, p. 604, 2020.
- [13] S. Taseen, M. Abbas, F. Munir, I. Ullah, and M. Tahir, "Impact of Overlapping Disaster in Turkey: COVID-19 Pandemic and Wildfires", *Journal of Contemporary Studies in Epidemiology and Public Health*, vol. 3, 2022.
- [14] M. Eke, F. Cingiroglu, and B. Kaynak, "Impacts of summer 2021 wildfire events in Southwestern Turkey on air quality with multi-pollutant satellite retrievals", *Copernicus Meetings*, 2022.
- [15] G. Ljubomir, D. Pamučar, S. Drobñjak, and H. R. Pourghasemi, "Modeling the spatial variability of forest fire susceptibility using geographical information systems and the analytical hierarchy process, Spatial modeling in GIS and R for earth and environmental sciences", *Elsevier*, pp. 337-369, 2019.
- [16] M. S. Tehrany, H. Özener, B. Kalantar, N. Ueda, M. R. Habibi, F. Shabani, V. Saeidi, and F. Shabani, "Application of an ensemble statistical approach in spatial predictions of bushfire probability and risk mapping", *Journal of Sensors*, 2021.
- [17] M. Hosseini, and S. Lim, "Gene expression programming and ensemble methods for bushfire susceptibility mapping: a case study of Victoria", *Geomatics, Natural Hazards and Risk*, vol. 12, pp. 2367-2386, 2021.

- [18] M. Hosseini, and S. Lim, "Gene expression programming and data mining methods for bushfire susceptibility mapping in New South Wales", *Natural Hazards*, pp. 1-17, 2022.
- [19] M. Nami, A. Jaafari, M. Fallah, and S. Nabiuni, "Spatial prediction of wildfire probability in the Hyrcanian ecoregion using evidential belief function model and GIS", *International journal of environmental science and technology*, vol. 15, pp. 373-384, 2018.
- [20] R. Eslami, M. Azarnoush, A. Kialashki, and F. Kazemzadeh, "Gis-based forest fire susceptibility assessment by random forest, artificial neural network and logistic regression methods", *Journal of Tropical Forest Science*, vol. 33, pp. 173-184, 2021.
- [21] A. Shmuel, and E. Heifetz, "Global Wildfire Susceptibility Mapping Based on Machine Learning Models", *Forests* vol. 13, p. 1050, 2022.
- [22] S. Tavakkoli Piralilou, G. Einali, O. Ghorbanzadeh, T.G. Nachappa, K. Gholamnia, T. Blaschke, and P. Ghamisi, "A Google Earth Engine approach for wildfire susceptibility prediction fusion with remote sensing data of different spatial resolutions", *Remote Sensing*, vol. 14, p. 672, 2022.
- [23] L. Gigović, H. R. Pourghasemi, S. Drobnjak, and S. Bai, "Testing a new ensemble model based on SVM and random forest in forest fire susceptibility assessment and its mapping in Serbia's Tara National Park", *Forests*, vol. 10, p. 408, 2019.
- [24] F. Sari, "Forest fire susceptibility mapping via multi-criteria decision analysis techniques for Mugla, Turkey: A comparative analysis of VIKOR and TOPSIS", *Forest Ecology and Management*, vol. 480, p. 118644, 2021.
- [25] J. Verde, and J. Zêzere, "Assessment and validation of wildfire susceptibility and hazard in Portugal", *Natural Hazards and Earth System Sciences*, vol. 10, pp. 485-497, 2010.
- [26] S. Khan, M. Crozier, and D. Kennedy, "Influences of place characteristics on hazards, perception and response: a case study of the hazardscape of the Wellington Region", *Natural Hazards*, vol. 62, pp. 501-529, 2012.
- [27] S. Pouyan, H. R. Pourghasemi, M. Bordbar, S. Rahmanian, and J. J. Clague, "A multi-hazard map-based flooding, gully erosion, forest fires, and earthquakes in Iran", *Scientific Reports*, vol. 11, pp. 1-19, 2021.
- [28] H. R. Pourghasemi, "GIS-based forest fire susceptibility mapping in Iran: a comparison between evidential belief function and binary logistic regression models", *Scandinavian Journal of Forest Research*, vol. 31, pp. 80-98, 2016.
- [29] M. C. Iban, and A. Sekertekin, "Machine learning based wildfire susceptibility mapping using remotely sensed fire data and GIS: A case study of Adana and Mersin provinces", *Ecological Informatics*, vol. 69, p. 101647, 2022.
- [30] M. C. Stambaugh, and R. P. Guyette, "Predicting spatio-temporal variability in fire return intervals using a topographic roughness index", *Forest Ecology and Management*, vol. 254, pp. 463-473, 2008.
- [31] S. Sachdeva, T. Bhatia, and A. Verma, "GIS-based evolutionary optimized Gradient Boosted Decision Trees for forest fire susceptibility mapping", *Natural Hazards*, vol. 92, pp. 1399-1418, 2018.
- [32] P. Deb, H. Moradkhani, P. Abbaszadeh, A. S. Kiem, J. Engström, D. Keellings, and A. Sharma, "Causes of the widespread 2019–2020 Australian bushfire season", *Earth's Future* vol. 8, p. e2020EF001671, 2020.
- [33] D. Huyen, and V.A. Tuan, "Applying GIS and multi criteria evaluation in forest fire risk zoning in son la province, Vietnam, International Conference on Geoinformation Spatial-Infrastructure Development", Hanoi, Vietnam, pp. 9-11, 2008.
- [34] C. Güngöroğlu, "Determination of forest fire risk with fuzzy analytic hierarchy process and its mapping with the application of GIS: The case of Turkey/Çakırlar", *Human and Ecological Risk Assessment: An International Journal*, vol. 23, pp. 388-406, 2017.
- [35] R. Ajin, A.-M. Loghini, M. K. Jacob, P. Vinod, and R. Krishnamurthy, "The risk assessment study of potential forest fire in Idukki Wildlife Sanctuary using RS and GIS techniques", *International Journal of Advanced Earth Science and Engineering*, vol. 5, pp. 308-318, 2016.
- [36] B. Choubin, E. Moradi, M. Golshan, J. Adamowski, F. Sajedi-Hosseini, and A. Mosavi, "An ensemble prediction of flood susceptibility using multivariate discriminant analysis, classification and regression trees, and support vector machines", *Science of the Total Environment*, vol. 651, pp. 2087-2096, 2019.
- [37] M. Marjanovic, B. Bajat, and M. Kovacevic, "Landslide susceptibility assessment with machine learning algorithms, 2009 International Conference on Intelligent Networking and Collaborative Systems, IEEE, pp. 273-278, 2009.
- [38] O. Ghorbanzadeh, K. Valizadeh Kamran, T. Blaschke, J. Aryal, A. Naboureh, J. Einali, and J. Bian, "Spatial prediction of wildfire susceptibility using field survey gps data and machine learning approaches", *Fire* 2, vol. 43, 2019.
- [39] J. Dou, A. P. Yunus, D. Tien Bui, M. Sahana, C.-W. Chen, Z. Zhu, W. Wang, and B. T. Pham, "Evaluating GIS-based multiple statistical models and data mining for earthquake and rainfall-induced landslide susceptibility using the LiDAR DEM", *Remote Sensing*, vol. 11, p. 638, 2019.
- [40] V. N. Vapnik, "An overview of statistical learning theory", *IEEE Transactions on Neural Networks*, vol. 10, pp. 988-999, 1999.
- [41] X.-Z. Wang, Q. He, D.-G. Chen, and D. Yeung, "A genetic algorithm for solving the inverse problem of support vector machines", *Neurocomputing*, vol. 68 pp. 225-238, 2005.
- [42] A. Patle, and D. S. Chouhan, "SVM kernel functions for classification", 2013 International Conference on Advances in Technology and Engineering (ICATE), IEEE, pp. 1-9, 2013.

- [43] K. P. Bennett, and E. J. Bredensteiner, "Duality and geometry in SVM classifiers", ICML, Citeseer, pp. 57-64, 2000.
- [44] W. S. Noble, "What is a support vector machine?", Nature biotechnology, vol. 24, pp. 1565-1567, 2006.
- [45] S. Suthaharan, "Support vector machine, Machine learning models and algorithms for big data classification", Springer, pp. 207-235, 2016.
- [46] D. Meyer, F. Leisch, and K. Hornik, "The support vector machine under test", Neurocomputing, vol. 55, pp. 169-186, 2003.
- [47] D. Van Dao, A. Jaafari, M. Bayat, D. Mafi-Gholami, C. Qi, H. Moayedi, T. Van Phong, H.-B. Ly, T.-T. Le, and P.T. Trinh, "A spatially explicit deep learning neural network model for the prediction of landslide susceptibility", Catena, vol. 188, p. 104451, 2020.
- [48] B. T. Pham, B. Pradhan, D. T. Bui, I. Prakash, and M. Dholakia, "A comparative study of different machine learning methods for landslide susceptibility assessment: A case study of Uttarakhand area (India)", Environmental Modelling and Software, vol. 84, pp. 240-250, 2016.



LED Aydınlatma Sistemlerinde Derin Öğrenme Tabanlı Harmonik Tahminleme Deep Learning Based Harmonic Estimation in LED Illumination Systems

¹İlyas ÖZER , ²Harun ÖZBAY , ³Serhat Berat EFE 

^{1,2,3}Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bandırma/Balıkesir, Türkiye

¹iozer@bandirma.edu.tr, ²hozbay@bandirma.edu.tr,

³sefe@bandirma.edu.tr,

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 13 September 2022

Accepted : 2 October 2022

Keywords:

LED Illumination, Energy Quality, Deep Learning, Machine Learning

ABSTRACT

LED illumination systems are frequently used in both indoor and outdoor lighting, and these elements offer great advantages especially in terms of energy efficiency. However, these systems cause energy quality problems due to the switching elements included in the driver circuits necessary for their operation. The main motivation of this study is the estimation of the power quality distortions, which are called harmonics, produced by the related systems. In this context, electrical data were measured from an experimentally designed LED lighting system and power quality problems caused by the relevant system were revealed as a result of the necessary calculations. However, based on the fact that the enlargement of the system size will increase the computational complexity, a deep learning-based algorithm has been developed to detect the aforementioned problems. Quality distortions were estimated by using basic electrical parameters free from computational complexity, in the GRU and BiGRU models, the lowest MAE value was 0,031 and the lowest RMSE value was 0,099 compared to actual data. The same values were realized as 0,028 and 0,097 in LSTM and BiLSTM models, respectively.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 13 Eylül 2022

Kabul : 2 Ekim 2022

Anahtar Kelimeler:

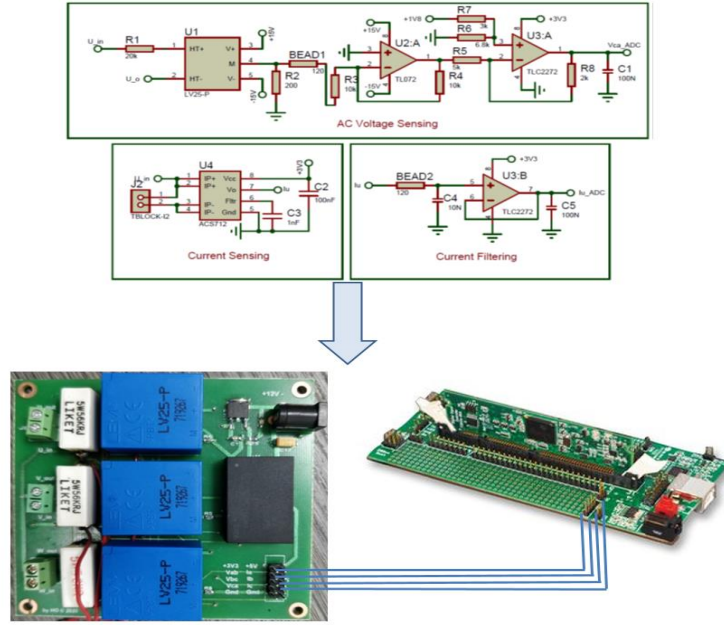
LED Aydınlatma, Enerji Kalitesi, Derin Öğrenme, Makine Öğrenmesi

ÖZET

LED aydınlatma sistemleri, hem iç hem de dış aydınlatmada sıklıkla kullanılmakta olup, bu elemanlar özellikle enerji verimliliği bakımından büyük avantajlar sunmaktadır. Ancak söz konusu sistemler, çalışmalarını için gerekli olan sürücü devrelerinin içerdiği anahtarlama elemanları nedeniyle, enerji kalitesi açısından sorunlara neden olmaktadır. Bu çalışmanın temel motivasyonunu, ilgili sistemler tarafından üretilen ve harmonik adı verilen güç kalitesi bozulmalarının tahminlenmesi oluşturmaktadır. Bu kapsamda, deneysel olarak tasarlanan bir LED aydınlatma sisteminden elektriksel veriler ölçülerek gerekli hesaplamalar sonucunda ilgili sistemin neden olduğu güç kalitesi problemleri ortaya çıkarılmıştır. Ancak sistem boyutunun büyümesinin hesaplama karmaşasını artıracığından yola çıkılarak, bahse konu problemlerin tespiti için derin öğrenme tabanlı bir algoritma geliştirilmiştir. Kalite bozulmaları, temel elektriksel parametreler kullanılmış ve hesaplama karmaşasından arındırılarak tahminlenmiş, gerçek veriler ile karşılaştırıldığında, GRU ve BiGRU modellerinde en düşük MAE değeri 0,031 ve en düşük RMSE değeri ise 0,099 olarak elde edilmiştir. Aynı değerler LSTM ve BiLSTM modellerinde sırasıyla 0,028 ve 0,097 olarak gerçekleşmiştir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

Deneyisel veriler kaydedilirken bu işlem için tasarlanan ve yüksek örnekleme frekansına sahip bir ölçüm devresi kullanılmıştır [22]. Bu devre Şekil 5'te gösterilmiştir.



Şekil 5. Ölçüm kartı.


Uygulama sistemi, 3 adet 50 W, 2 adet 100 W, 2 adet 150 W ve 2 adet 200 W gücünde LED projektör kullanılarak tasarlanmıştır. Tüm projektörler devredeyken 4 m uzaklıkta toplam 3939 lüks değerinde aydınlık düzeyi değeri ölçülmüştür. Elektriksel parametreler Şekil 5'te gösterilen ölçüm kartı ile kaydedilerek işlenmesi amacıyla taşınabilir bilgisayara aktarılmıştır.

4. DENEYSEL SONUÇLAR VE TARTIŞMA

Harmoniklerin tespit edilmesi, güç kalitesi problemleri ile etkin bir mücadele gerçekleştirebilmek için oldukça kritik bir unsurdur. Ayrıca güç sistemlerinin dinamik yapısı gereği harmonikler zaman içerisinde sürekli olarak değişmektedir. Bu nedenle şebekede harmoniklerin sürekli olarak izlenmesi gerekir. Öte yandan iletim sistemindeki her bir veri yolunun analizörler, harmonik ölçerler veya güç analizörü gibi cihazlar vasıtasıyla izlenmesi yüksek maliyetler nedeniyle her zaman mümkün olmamaktadır [23]. Bu tarz cihazlarda yaygın olarak hızlı Fourier dönüşümü (HFD) ile harmonik hesabı gerçekleştirilmektedir.

Bu çalışma kapsamında harmoniklerin HFD kullanılarak hesaplanması yerine doğrudan akım verisi üzerinden yapay sinir ağları (YSA) tabanlı bir model ile tahmin edilmesi hedeflenmektedir. Bu doğrultuda RNN tabanlı LSTM ve GRU ağlarının kullanılması önerilmiştir. Bu ağlar aralarında zamansal bağımlılık olan veriler üzerinde diğer birçok YSA modeline kıyasla oldukça yüksek performans sergilemektedir.

Uygulama sisteminden ölçülen ve kaydedilen veriler, çalışmanın amacı kapsamında çeşitli basamaklar halinde işlenmiştir. İşlem basamakları Şekil 6' da verilen blok şemada özetlenmiştir.



Şekil 6. Veri işleme ve tahminleme işlem basamakları.

Veri toplama kartından alınan akım verileri her biri 300 noktadan oluşan veri segmentlerine ayrılmaktadır. Her bir segmentin THD değeri HFD ile hesaplanmaktadır. Bu değerler modelin eğitimi ve test işlemi aşamasında model


performansının kıyaslanması amacıyla kullanılmaktadır. Tüm ölçüm verilerinin %80'i modellerin eğitimi kalan %20'lik bölümü de test işlemi için ayrılmıştır. 300 noktadan oluşan her bir veri segmenti modellere girdi olarak uygulanırken THD verileri de çıktı bilgisi olarak ele alınmaktadır. . Bu doğrultuda toplam 724.500 adet akım verisinden 2415 adet segment elde edilmiş ve bunların 1932 adeti eğitim için geriye kalan 483 adeti ise test işlemi için ayrılmıştır.

Bu çalışma kapsamında THD değerinin tahmin edilmesi için 8 farklı model kullanılmıştır. Bu modeller LSTM, BiLSTM, GRU ve BiGRU ağlarından oluşmaktadır. Tahmin için kullanılan modeller girdi, LSTM/GRU ve çıktı katmanlarından oluşmaktadır. LSTM/GRU katmanlarının yerine çift yönlü versiyonları (BiLSTM/BiGRU) da kullanılmıştır. Ayrıca bunların tek katman ve iki katmandan oluşan mimarileri de test edilmiştir. Gizli katmanlardaki nöron sayısı 100 olarak belirlenmiştir. Optimizasyon metodu olarak Adam algoritması tercih edilmiştir. Tüm modeller 500 tekrar boyunca eğitilmiş ve test işlemi için en küçük kayıp değerine sahip olan ağırlıklar kullanılmıştır. Tahmin edilen THD değerlerini gerçek THD değeri ile kıyaslamak için RMSE ve MAE hata değerleri hesaplanmıştır. Tablo 1'de, 8 ayrı testin sonucuna ilişkin skorlar verilmiştir.

Tablo 1. Modellerin hata değerlerinin karşılaştırılması.


		LSTM	BiLSTM	GRU	BiGRU
1 Katman	RMSE	0,100	0,106	0,109	0,104
	MAE	0,033	0,031	0,039	0,034
2 Katman	RMSE	0,097	0,101	0,099	0,106
	MAE	0,031	0,028	0,031	0,032

GRU ve BiGRU modellerinde en düşük MAE değeri 0,031 ve en düşük RMSE değeri ise 0,099 olarak elde edilmiştir. Aynı değerler LSTM ve BiLSTM modellerinde sırasıyla 0,028 ve 0,097 olarak gerçekleşmiştir. Genel olarak LSTM ve BiLSTM modellerine ilişkin hata değerlerinin GRU tabanlı modellere kıyasla daha iyi olduğu görülmektedir. Bunun sonucunun LSTM tabanlı ağların uzun süreli bağımlılıkları yakalama noktasındaki başarısından kaynaklandığı değerlendirilmektedir. LSTM ve BiLSTM modellerinde iki katman kullanmanın sonuca olumlu katkı sağladığı görülmektedir. LSTM modellerinde bir ve iki katman için RMSE değerleri sırasıyla 0,1 ve 0,097 olarak gerçekleşmiştir. MAE değerleri ise sırasıyla 0,33 ve 0,31'dir. BiLSTM modellerinde tek katman için RMSE ve MAE değerleri 0,106 ve 0,031'dir. İki katmanlı BiLSTM modelinde bu değerler sırasıyla 0,101 ve 0,028 olarak gerçekleşmiştir.



Şekil 7. İki katmanlı LSTM modeline ait gerçek ve tahmin edilen THD değerleri.

Şekil 7'de iki katmanlı LSTM modelinin gerçek ve tahmin edilen değerleri görülmektedir. İki katmanlı BiLSTM modeline ait değerler ise Şekil 8'de verilmiştir. Sonuç olarak tahmin edilen değerlerin büyük ölçüde gerçek değerler ile örtüştüğü görülmektedir.



Şekil 8. İki katmanlı BiLSTM modeline ait gerçek ve tahmin edilen THD değerleri.

5. SONUÇ

LED aydınlatma elemanları, yapılarında barındırdıkları ve çalışmaları için gerekli olan sürücü devreleri nedeniyle birer harmonik kaynağıdır. Bu yapıların fazla sayıda bir arada kullanılması ile elde edilen aydınlatma sistemleri ise elektrik enerji şebekesi üzerinde büyük bozucu etkilere neden olmaktadır. Enerji sisteminin düzgün çalışması ve şebekeye bağlı kullanıcılara kaliteli enerji arzı için söz konusu harmoniklerin detaylı biçimde tespit edilmesine ve analizine ihtiyaç vardır. Bu çalışmada, LED aydınlatma sistemlerinden kaynaklanan harmoniklerin, hesaplama adımlarına ihtiyaç olmadan tahminlenmesi amacıyla derin öğrenme temelli bir algoritma geliştirilmiştir.

Güç sistemlerinin analizinde ve özellikle enerji kalitesi çalışmalarında, sistemdeki tüm parametrelerin hesaba katılması ve gerçeğe en uygun sonuçların elde edilmesi açısından deneysel verilerin kullanılması önem arz etmektedir. Bu nedenle, çalışma kapsamında deneysel bir sistem oluşturularak veriler elde edilmiş, önerilen tahminleme modelinin eğitimi ve testleri bu veriler kullanılarak yapılmıştır.

Bu çalışmada enerji kalitesindeki bozulmalar, 8 farklı modelle tahminlenmiştir. Bu modeller LSTM, BiLSTM, GRU ve BiGRU ağlarından oluşmaktadır. Ayrıca bunların tek katman ve iki katmandan oluşan mimarileri de test edilmiştir. Tahmin edilen THD değerlerini gerçek THD değeri ile kıyaslamak için RMSE ve MAE hata değerleri hesaplanmış, grafikler ve tablolar üzerinden değerlendirilerek tartışılmıştır. Buna göre, GRU ve BiGRU modellerinde en düşük MAE değeri 0,031 ve en düşük RMSE değeri ise 0,099 olarak elde edilmiştir. Aynı değerler LSTM ve BiLSTM modellerinde sırasıyla 0,028 ve 0,097 olarak gerçekleşmiştir. Ortaya çıkan sonuçlar üzerinden genel değerlendirme yapıldığında, hata değerleri bakımından LSTM ve BiLSTM modellerinin GRU tabanlı modellere kıyasla daha iyi performans gösterdiği tespit edilmiştir. Bunun durumun, LSTM tabanlı ağların uzun süreli bağımlılıkları yakalama noktasındaki başarısından kaynaklandığı değerlendirilmektedir.

Yazar Katkıları

Tüm yazarların çalışmadaki katkı oranları eşittir.

Çıkar Çatışması

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

Destek ve Teşekkür Beyanı

Bu çalışma Bandırma Onyedü Eylül Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir. Proje Numarası: BAP-20-1004-004.

KAYNAKÇA

- [1] O. Akalp, H. Ozbay, and S. B. Efe, "Design and Analysis of High-Efficient Driver Model for LED Luminaires," *Light Eng.*, vol. 29, no. 2, pp. 96–106, 2021.
- [2] S. B. Efe and D. Varhan, "Interior Lighting of a Historical Building by using LED Luminaires: A Case Study of Fatih Paşa Mosque," *Light Eng.*, vol. 28, no. 4, pp. 77–83, 2020.

- [3] M. S. Cengiz, "The relationship between maintenance factor and lighting level in Tunnel lighting," *Light Eng.*, vol. 27, no. 3, pp. 75–84, 2019.
- [4] M. S. Cengiz and Ç. Cengiz, "Numerical analysis of tunnel LED Lighting maintenance factor," *IIUM Eng. J.*, vol. 19, no. 2, pp. 154–163, 2018.
- [5] M. S. Cengiz and S. Yetkin, "Thermal Analysis in Fixed, Flowed and Airless Environment for Cooling in LED Luminaires," *Light Eng.*, vol. 28, no. 6, pp. 28–35, 2020.
- [6] S. Rüstemli and M. S. Cengiz, "Active filter solutions in energy systems," *Turkish J. Electr. Eng. Comput. Sci.*, vol. 23, pp. 1587–1607, 2015.
- [7] S. B. Efe, H. Özbay, and İ. Özer, "Dynamic Voltage Restorer Application to Eliminate Power System Harmonics," in *International Engineering and Natural Sciences Conference (IENSC 2019)*, pp. 705–709, 2019.
- [8] International Electrotechnical Commission (IEC). IEC 61000-3-2:2018., "Electromagnetic Compatibility (EMC)—Part 3-2: Limits—Limits for Harmonic Current Emissions (Equipment Input Current ≤ 16 A per Phase)." <https://webstore.iec.ch/publication/62553>
- [9] J. Valenzuela and J. Pontt, "Real-time interharmonics detection and measurement based on FFT algorithm," *2009 Appl. Electron. Int. Conf. AE 2009*, no. 1, pp. 259–264, 2009.
- [10] N. Severoglu and O. Salor, "Statistical Models of EAF Harmonics Developed for Harmonic Estimation Directly from Waveform Samples Using Deep Learning Framework," *IEEE Trans. Ind. Appl.*, vol. 57, no. 6, pp. 6730–6740, 2021.
- [11] N. Severoglu and O. Salor, "Amplitude and phase estimations of power system harmonics using deep learning framework," *IET Gener. Transm. Distrib.*, vol. 14, no. 19, pp. 4089–4096, 2020.
- [12] İ. Özer, S. B. Efe, and H. Özbay, "CNN / Bi-LSTM-based deep learning algorithm for classification of power quality disturbances by using spectrogram images," *Int. Trans. Electr. Energy Syst.*, vol. 31, no. 12, pp. 1–16, 2021.
- [13] H. Özbay and A. Dalcali, "Effects of COVID-19 on electric energy consumption in Turkey and ANN-based short-term forecasting," *Turkish J. Electr. Eng. Comput. Sci.*, vol. 29, no. 1, pp. 78–97, 2021.
- [14] I. Ozer, S. B. Efe, and H. Ozbay, "A combined deep learning application for short term load forecasting," *Alexandria Eng. J.*, vol. 60, no. 4, pp. 3807–3818, 2021.
- [15] I. Ozer, Z. Ozer, and O. Findik, "Noise robust sound event classification with convolutional neural network," *Neurocomputing*, vol. 272, pp. 505–512, 2018.
- [16] Z. Ozer, I. Ozer, and O. Findik, "Diacritic restoration of Turkish tweets with word2vec," *Eng. Sci. Technol. an Int. J.*, vol. 21, no. 6, pp. 1120–1127, 2018.
- [17] I. Ozer, Z. Ozer, and O. Findik, "Lanczos kernel based spectrogram image features for sound classification," *Procedia Comput. Sci.*, vol. 111, no. 2015, pp. 137–144, 2017.
- [18] J. Bedi and D. Toshniwal, "Deep learning framework to forecast electricity demand," *Appl. Energy*, vol. 238, no. July 2018, pp. 1312–1326, 2019.
- [19] K. Cho et al., "Learning phrase representations using RNN encoder-decoder for statistical machine translation," *EMNLP 2014 - 2014 Conf. Empir. Methods Nat. Lang. Process. Proc. Conf.*, pp. 1724–1734, 2014.
- [20] R. Jozefowicz, W. Zaremba, and I. Sutskever, "An empirical exploration of Recurrent Network architectures," in *32nd International Conference on Machine Learning, ICML 2015*, vol. 3, pp. 2332–2340, 2015.
- [21] D. Amodei and Et.al, "Deep Speech 2 : End-to-End Speech Recognition in English and Mandarin," in *International Conference on Machine Learning, 2016*, vol. 48, pp. 1–10.
- [22] S. B. Efe, H. Ozbay, and I. Ozer, "Experimental Design and Analysis of Adaptive LED Illumination System," *Light Eng.*, vol. 30, no. 4, pp. 63–70, 2022.
- [23] S. K. Jain and S. N. Singh, "Harmonics estimation in emerging power system: Key issues and challenges," *Electr. Power Syst. Res.*, vol. 81, no. 9, pp. 1754–1766, 2011.