



ÖZEL SAYI/SPECIAL ISSUE 44
ARALIK/DECEMBER 2022

EUROPEAN JOURNAL OF SCIENCE AND TECHNOLOGY

Avrupa Bilim ve Teknoloji Dergisi



E-ISSN 2148-2683

<https://dergipark.org.tr/en/pub/ejosat>

Prof. Dr. Osman SAĞDIÇ
Editor-in-Chief and Editor

Prof. Dr. Hüseyin TOROS
Editor

Prof. Dr. Ahmet DOĞAN
Editor

Editorial Board Members

Prof. Dr. Osman SAĞDIÇ
Subjects: Food Sciences and Engineering
Institution: Yildiz Technical University

Prof. Dr. Hüseyin TOROS
Subjects: Engineering
Institution: Istanbul Technical University

Prof. Dr. Ahmet DOĞAN
Subjects: Environmental Sciences and
Engineering, Geological Sciences and Engineering, Civil
Engineering
Institution: Yildiz Technical University

Prof. Dr. Osman TAYLAN
Subjects: Energy Systems Engineering, Machine
Learning, Quality Management, Artificial
Intelligence, Multiple Criteria Decision Making, Fuzzy Logic
Institution: Department of Industrial Engineering, Faculty of
Engineering, King Abdulaziz University.

Prof. Dr. Tuncay GÜMÜŞ
Subjects: Food Sciences and Engineering
Institution: Namık Kemal University

Assoc. Prof. Dr. Juliana JALALUDIN
Subjects: Air Pollution and Control, Environmental Sciences
and Engineering
Institution: Universiti Putra Malaysia, Faculty of Medicine
and Health Sciences, Department of Environmental and
Occupational Health

Asst. Prof. Dr. Abdulatef AHHMED
Subjects: Meat Technology
Institution: Aljfarah University

Prof. Dr. İskender AKKURT
Subjects: Physics, Computer Sciences and Engineering
Institution: Suleyman Demirel University

The European Journal of Science and Technology (EJOSAT) is a scientific and peer-reviewed journal published online four times in January, April, August, and November. The European Journal of Science and Technology is scanned in indexes such as Scilit, Index Copernicus, CiteFactor, International Innovative Journal Impact Factor, Eurasian Scientific Journal Index, SJIFactor, DRJI, Scientific Indexing Services and Google Scholar.

INDEX  COPERNICUS
I N T E R N A T I O N A L



<https://dergipark.org.tr/en/pub/ejosat>

e-ISSN 2148-2683

İÇİNDEKİLER / TABLE OF CONTENTS

- Fundus Görüntülerinden Derin Öğrenme Teknikleri ile Glokom Hastalığının Tespiti*
Özcan YILDIRIM, Feyza ALTUNBEY ÖZBAY
Sayfa: 1 - 6
- QuaVita: Sağlıklı Yaşam Mobil Uygulaması*
Osman GÜLER, Özgü CAN
Sayfa: 7 - 12
- Görüntüler İçin Kaotik Şifreleme Sistemi Ve Performans Analizi*
Gizem SEVAL, Mustafa Cem KASAPBAŞI
Sayfa: 13 - 20
- Dynamic Traffic Signal Split Control Method at Pedestrian Crossings*
Serap ERGÜN
Sayfa: 21 - 26
- Karşıt Tabanlı Öğrenme İle Geliştirilmiş Yapay Denizanası Arama Algoritması*
Gülnur YILDIZDAN
Sayfa: 27 - 34
- Analysis of SEM Images with Artificial Intelligence Methods*
Ayşe DEMİRKAN, İsmail TOPCU
Sayfa: 35 - 38
- Makine Öğrenmesi Tabanlı Mikrodizi Tekniği İle MikroRNA Hedef Tahmini: Araştırma Çalışması*
Zerrin YILDIZ ÇAVDAR, Tolga ENSARİ, Leyla TURKER SENER, Ahmet SERTBAŞ
Sayfa: 39 - 45
- Design and Simulation of a PID Neural Network Controller for PMDC Motor Speed and Position Control*
Rahaf SHEIKH DEBES, Tolgay KARA
Sayfa: 46 - 50
- Kaotik Denizatı Optimizasyon Algoritması*
Feyza ALTUNBEY ÖZBAY, Erdal ÖZBAY
Sayfa: 51 - 58
- Sensor Fusion Based on Mathematical Model of LEO Satellite*
Seda KARTAL, Tayfun DAR
Sayfa: 59 - 64
- Videolardan Kalp Atış Hızı Kestirimi Üzerine Bir İnceleme*
Mustafa KORKMAZ, Saffet VATANSEVER
Sayfa: 65 - 73
- Ön-Eğitilmiş CNN Mimarilerinin Füzyonu İle Mısır Yaprağı Hastalıklarının Sınıflandırılması*
Ahmet CİRAN, Erdal ÖZBAY
Sayfa: 74 - 83
- Sınıflandırma Probleminde Derin Özellik Birleştirme Yaklaşımıyla Domates Yaprağı Görüntülerinde Hastalık Tespiti*
Serdar ERTEM, Erdal ÖZBAY
Sayfa: 84 - 92
- Otomatik Modülasyon Sınıflandırmasında Evrimsel Sinir Ağlarının İncelenmesi*
Osman KAYA, Tansal GÜÇLÜOĞLU
Sayfa: 93 - 96
- Developing a Guided Tactile Feedback System for Visually Impaired People*
Rıza İLHAN, Fahmeed ALİ
Sayfa: 97 - 103
- Violence Detection with Machine Learning: A Sociodemographic Approach*
Tolga ENSARİ, Betül ENSARİ, Mustafa DAÇTEKİN
Sayfa: 104 - 107



Fundus Görüntülerinden Derin Öğrenme Teknikleri ile Glokom Hastalığının Tespiti

Özcan Yıldırım¹, Feyza Altunbey Özbay^{2*}

¹ Fırat Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Elazığ, Türkiye, (ORCID: 0000-0003-2776-5081), yldrmocn3@gmail.com

^{2*} Fırat Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Elazığ, Türkiye (ORCID: 0000-0003-0629-6888), faltunbey@firat.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1216404)

ATIF/REFERENCE: Yıldırım, Ö. & Altunbey Özbay, F. (2022). Fundus Görüntülerinden Derin Öğrenme Teknikleri ile Glokom Hastalığının Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 1-6.

Öz

Glokom optik siniri etkileyen ve erken teşhis edilmediği durumlarda kısmi ya da kalıcı körlüğe neden olan bir retina hastalığıdır. Zamanla görme kaybına neden olan glokomun teşhisi için doktorlar fundus görüntülerini kullanmaktadır. Glokomun etken teşhisi oldukça önemlidir. Bu çalışmada, fundus görüntülerinden glokom tespiti için Evrişimli Sinir Ağları (ESA) modellerinden olan AlexNet, ResNet-18, VGG16, SqueezeNet ve GoogleNet kullanılmıştır. Kullanılan mimariler için elde edilen sonuçlar doğruluk, duyarlılık, özgüllük ve f1-ölçütü değerleri olmak üzere farklı performans metriklerine göre değerlendirilmiştir. Sonuçlara göre test veri kümesinde en iyi duyarlılık değeri %97.96 ile VGG16 tarafından elde edildiği, özgüllük, doğruluk ve f1-ölçütü için en iyi değerlerin ise sırasıyla %98.97, %97.98 ve %98 ile GoogleNet olduğu tespit edilmiştir.

Anahtar Kelimeler: Evrişimsel Sinir Ağları, Fundus görüntüleri, Glokom, Yapay Zekâ.

Detection of Glaucoma Disease with Deep Learning Techniques from Fundus Images

Abstract

Glaucoma is a retinal disease that affects the optic nerve and causes partial or permanent blindness if not diagnosed early. To diagnose glaucoma, which causes vision loss over time, doctors use fundus images. The causative diagnosis of glaucoma is very important. In this study, Convolutional Neural Networks (CNN) models AlexNet, ResNet-18, VGG16, SqueezeNet, and GoogleNet were used for glaucoma detection from fundus images. The results obtained for the architectures used were evaluated according to different performance metrics such as accuracy, sensitivity, specificity, and f1-criterion values. According to the results, it was determined that the best sensitivity value in the test dataset was obtained by VGG16 with 97.96%, and the best values for specificity, accuracy, and f1-criterion were GoogleNet with 98.97%, 97.98%, and 98%, respectively.

Keywords: Convolutional Neural Networks, Fundus images, Glaucoma, Artificial Intelligence.

* Sorumlu Yazar: faltunbey@firat.edu.tr

1. Giriş

Glokom hastalığı genellikle göz için basıncının yükselmesinden kaynaklanmaktadır (Nayak vd., 2021). Optik sinire zarar veren bir hastalıktır. Dünya genelinde geri dönülemez körlüğün yaygın sebebidir. Ancak hastalık ilk evrede tespit edilebilirse görme kaybı önlenmektedir. Tahminlere göre, dünya genelinde 2013 yılında 40-80 yaş arası yaklaşık 64,3 milyon kişiye glokom teşhisi konduğu ve 2040 yılına kadar yaklaşık 112 milyon kişiyi etkilemesi beklenmektedir (Tham vd., 2014). Glokomun neden olduğu görme kaybı, erken teşhis ve tedavi ile önlenir. Bu nedenle glokomun erken bir aşamada tespit edilmesi önemlidir. Ancak, çoğu zaman şüpheli hastalar için manuel glokom taraması yapmak zordur. Bu nedenle, yüksek doğruluk ve verimlilik ile glokom tespiti yapabilen otomatik yöntemlerin geliştirilmesi gerekmektedir.

Glokom, optik diskin içinde ve dışında gözle görülür değişikliklerle yapısal optik sinir lifi hasarına neden olarak sonuçta fonksiyonel görme kaybına yol açmaktadır. Glokom, optik disk olarak da adlandırılan optik sinir başının (ONH) karakteristik değişiklikleri ile ilişkilidir (Weinreb vd., 2014). Klinik muayene ve optik disk fotoğraf analizi sırasında göz doktorları, genelleştirilmiş veya fokal nöral halka incelenmesi gibi tipik değişiklikleri arayarak ONH'yi değerlendirmektedir. Nöroretinal kenar incelenmesi, dikey çanak-disk oranı ölçülerek fundus fotoğraflarında ölçülebilir. Optik kap, ONH'nin orta kısmındaki ayırt edilebilir kazıdır. Normal gözlerde tipik olarak küçüktür, ancak nöroretinal halka kaybıyla artmaktadır. Bu nedenle, dikey çanak-disk oranının yüksek olması veya interoküler asimetri değerinin 0.2'den yüksek olması glokom için şüpheli kabul edilmektedir (Hemelings vd.,2021).

Derin öğrenme modelleri ve özellikle Evrişimli Sinir Ağları (ESA), tıbbi görüntü analizinde yeni ölçütler sunmakta ve her geçen popüler hale gelmektedir. Bu modeller ile cilt kanseri sınıflandırmasını araştırmak, otizmdeki karmaşık genetik etkileşimleri değerlendirmek ve yoğun bakım ünitesinde izleme gerçekleştirmek için makine öğrenmesi yöntemleri kullanılmıştır (Esteve vd., 2017, Uddin vd., 2014, Clifton vd., 2012). Derin makine öğrenimi kullanan diyabetik retinopati üzerine yakın tarihli bir araştırma, makine öğreniminin diyabetik retinopatinin saptanmasında yüksek hassasiyet ve özgüllük sergilediğini ortaya koymuştur (Özbay, 2022).

Bu çalışma, fundus görüntülerinden glokom tespiti için AlexNet, ResNet-18, VGG16, SqueezeNet ve GoogleNet gibi önceden eğitilmiş ESA modellerini kullanımına dayanmaktadır. Makalenin ikinci bölümünde literatürde glokom tespiti ile ilgili yapılmış çalışmalar incelenmiştir. Kullanılan ESA modelleri ve yöntem üçüncü bölümde açıklanmıştır. Dördüncü bölümde ise deneysel sonuçları verilerek analiz edilmiş ve son bölümde makale sonlandırılmıştır.

2. İlgili Çalışmalar

Son yıllarda, evrimli sinir ağları araştırmacılar tarafından glokom tespiti için farklı birçok çalışmada kullanılmıştır. Alghamdi vd. retina görüntülerinden optik disk anormalliklerinin saptanması için uçtan uca denetimli bir model kullanmıştır. Modelde birbini izleyen iki derin öğrenme mimarisi kullanılmıştır. Dört genel ve dört özel veri kümesinden oluşan toplam sekiz veri kümesi kullanmışlardır. Önerilen model hızlı ve güçlü performans göstermiştir (Alghamdi vd., 2016).

Chen vd. Orica ve Sces veri kümeleri üzerinde altı katmanlı yapıya sahip ESA mimarisi kullanmışlardır. Veri arttırımı metotları ile veri kümelerini test ederek %88.70 başarı oranı yakalanmıştır (Chen vd., 2015). Bir başka çalışmada Orlando vd. halka açık Drishti-gsl veri kümesini ESA mimarisi ile eğitmişlerdir. Özellik vektörleri için overFeat ve VGG-S gibi ön işleme tekniklerini kullanarak oldukça başarılı sonuçlar elde edilmiştir (Orlando vd., 2017).

Hatanaka vd. glokom tespitinde kupa alanının zor tespit edilmesinden yola çalışmalarında optik disk üzerinde dikey bir profil kullanılarak çanak-disk oranını ölçmek için yeni bir yöntem önermiştir. Önerilen yöntemde ilk olarak kan damarları görüntüden temizlenmiş ve ardından canny kenar algılama filtresi kullanılarak disk kenar tespiti yapılmıştır. Daha sonra renkli görüntü verisi üzerinde kupa-disk oranı hesaplanmıştır. 25' i glokoma olan toplamda 79 adet görüntü verisinin kullanıldığı yöntemde %80 hassasiyet ve %85 özgüllük başarımları elde edilmiştir (Hatanaka vd., 2010).

Bir diğer çalışmada, Carrillo vd., Kolombiya özelinde yaygın görülen göz tansiyonu hastalığını ele almış ve bu hastalığın otomatik olarak tespiti ile ilgili yapay zekâ tabanlı yeni bir hesaplama yöntemi önermiştir. Önerilen yeni yöntemde kupa ve disk boyutu arasındaki eşik değere göre yapılan yeni ölçüm literatürdeki diğer disk segmentasyon yöntemlerine göre başarımları daha yüksektir. Yeni yöntem glokom tespitinde %85 başarı göstermiştir (Carrillo vd., 2019).

Bir diğer yapay zekâ tabanlı çalışmada, Almazroa vd. optik kabı iki boyutlu renkli bir fundus görüntüsünden ayırmak için yeni bir teknik geliştirilmiştir. Otsu fonksiyonu ve tip iki bulanık mantık entropi prosedürünün kullanıldığı yeni yöntem, RIGA veri tabanından alınan 100 fundus görüntü üzerinde uygulanmıştır. Önerilen yöntemin başarımları %72.5' tir (Almazroa vd., 2015).

Farklı bir çalışmada Dey ve Bandyopadhy, sayısal fundus görüntüleri üzerinde glokom tespiti için yeni bir yöntem önermiştir. Bu yöntemde gürültü giderme ve kontrast geliştirme gibi görüntü ön işleme teknikleri, özellik çıkarımı için Temel Bileşen Analizi (PCA) yöntemi ve görüntü sınıflandırması için Destek Vektör Makinesi (SVM) yöntemi kullanılmıştır. Önerilen SVM sınıflandırıcı için çapraz doğrulama sonucunda önerilen yöntem doğruluk, hassasiyet ve özgüllük başarımları sırasıyla %96, %100 ve %92' dir (Dey ve Bandyopadhy, 2016).

Sevastopolsky, çalışmasında optik disk kap segmentasyonu için U-Net konvolüsyonel sinir ağı tabanlı yeni bir evrensel yöntem sunmuştur. Önerilen yöntem, DRIONS-DB, RIM-ON VE DRISTHI-GS gibi açık veri tabanları üzerinde glokom tespitinde sık başvurulan yöntemlerle karşılaştırılmıştır. Aynı çalışmada önerilen yöntemin karşılaştırılan literatürdeki diğer yöntemlere oranla hesaplama tahmini açısından daha başarılı olduğu vurgulanmıştır (Sevastopolsky, 2017).

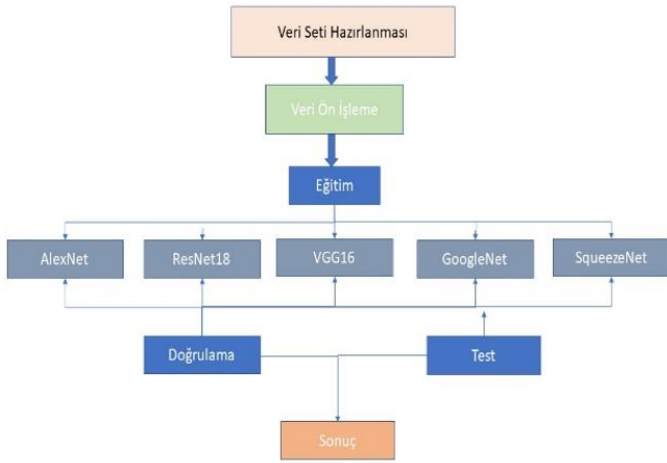
Cho vd. çalışmalarında erken ve geç glokom evrelerini otonom olarak sınıflandırabilen derin öğrenme tabanlı yeni bir yöntem geliştirmiştir. ESA mimarisi tabanlı bu yöntemde, eğitim aşamasında 3460 adet sayısal fundus görüntüsü içeren veri kümesi kullanılmıştır. Çalışma kapsamında elde edilen bulgular, önerilen yöntemin başarımları %88.1' dir (Cho vd., 2021).

Gheisari vd., çalışmalarında bir fundus görüntüsü üzerindeki uzamsal özelliklerin aksine, sıralı görüntüler (video) üzerinde gömülü geçici özellik çıkarımlarını da yapabilen ESA ve yinelemeli yapay sinir ağı tabanlı yeni bir yöntem önermiştir. Önerilen yöntemde 1810 fundus görüntüsü, 295 fundus videosu

veri kümesi olarak kullanılmıştır. Önerilen bu yöntemin fl-ölçütü değeri %96.2 iken tek başına ESA mimarisinde bu değer %79.2 olarak elde edilmiştir. Aynı çalışmada önerilen yöntemin fundus videolarından uzamsal ve zamansal özelliklerin çıkarılmasının glokom tespitinin doğruluğunu önemli ölçüde artırabileceğini göstermektedir (Gheisari vd., 2021).

3. Materyal ve Metot


Fundus görüntüleri glokom ve diyabetik retinopatiyi saptamak için kullanılmaktadır. Bu görüntülerin özellikleri kullanılarak optik sinir lifinde oluşan hasar saptanmaktadır. Ancak, glokomun erken bir aşamada teşhis edilememesi bu hastalık için önemli bir dezavantajdır. Bu çalışmada fundus görüntülerinden glokom teşhisi için ESA modellerinden AlexNet, ResNet-18, VGG16, SqueezeNet ve GoogleNet kullanılmıştır. Çalışmada öncelikle genel erişime açık glokom veri kümesinden 1000 görüntü alınmıştır. Ardından ön işlem adımında fundus görüntüleri, kullanılacak ESA mimarilerinin görüntü boyutuna dönüştürülmüştür. Daha sonra görüntüler AlexNet, ResNet-18, VGG16, SqueezeNet ve GoogleNet mimarileri ile eğitilmiştir. Tüm mimariler için eğitim oranları 0.005 olarak belirlenmiştir. Çalışmanın gerçekleştirim adımları Şekil 1’de gösterilmiştir.



Şekil 1. Önerilen yöntemin akış diyagramı

3.1. Veri Kümesi

Bu çalışmada, genel erişime açık fundus görüntülerinden oluşan Origa (-light) veri kümesi kullanılmıştır (Alsulami vd., 2022). Veri kümesinde 3000 adet glokom hastasına ve 3000 adet sağlıklı (normal) bireye ait olmak üzere toplam 6000 görüntü bulunmaktadır. Bu çalışmada veri kümesinden alınan 500 sağlıklı bireye ve 500 glokom hastasına toplam 1000 görüntü kullanılmıştır. Origa (-light) veri kümesinden sağlıklı ve hasta bireylere ait örnek görüntüler Şekil 2’de gösterilmiştir.



Şekil 2. a)glokom görüntüsü b)normal görüntü


Tablo 1 Origa-light veri kümesi dağılımı

Veri	Glokom görüntü	Normal Görüntü	Toplam
Eğitim veri kümesi	325	325	650
Doğrulama veri kümesi	76	76	152
Test veri kümesi	99	99	198

Çalışmada kullanılan dijital fundus görüntüleri %65 eğitim, %15 doğrulama, %20 test veri kümesi için ayrılmıştır. Tablo 1’de veri kümesinde bulunan normal ve glokom sayıları detaylı gösterilmektedir.

3.2. ESA Mimarileri

Günümüzde, ESA, segmentasyon, algılama, örüntü tanıma ve görüntü verileri gibi farklı birçok veri için kullanılmıştır. Son birkaç on yılda tıbbi görüntü analizinde yaygın olarak araştırmacılar tarafından kullanılmaktadır. Şekil 3, giriş katmanı, evrişim katmanı, havuzlama katmanı gibi ana öğeleri ve elde edilen sonucu temsil eden bilgilerin bir dizi yoğun katmana girdiği bir düzleştirme işlemi ile bir ESA’nın genel mimarisini grafiksel olarak göstermektedir. ESA, AlexNet, ResNet, GoogleNet ve diğerleri gibi farklı katman düzenlemelerine sahip birkaç mimariye sahiptir.




Şekil 3. ESA mimarisinin gösterimi

3.2.1. AlexNet

AlexNet, Alex Krizhevsky vd. tarafından önerilmiştir (Krizhevsky vd., 2012). Bu model 2012’de, ImageNet Büyük Ölçekli Görsel Tanıma’nın (ILSVRC) nesne algılama ve görüntü sınıflandırması için algoritmaları büyük ölçekte değerlendirdiği en zorlu mücadeleyi kazanmıştır. 60 milyon parametreye ve 650.000 nörona sahip olan AlexNet, beş konvolüsyonel katman ve üç tam bağlı katmandan oluşmaktadır. İlk iki evrişim katmanını normalleştirme ve bir maksimum havuzlama katmanı takip eder, üçüncü ve dördüncü doğrudan bağlanır ve beşinci evrişim katmanını bir maksimum havuzlama katmanı izler. Giriş görüntü boyutunu 227x227x3 pixel olarak almaktadır.

3.2.2. VGG16

Simonyan ve Zisserman tarafından önerilen VGG16 beş evrişimli ve havuzlama katmanı bloğundan oluşur, yani ilk iki bloğun her biri iki evrişimli katmana, ardından bir maksimum havuzlama katmanına sahipken, sonraki üç bloğun her biri üç evrişimli katmana ve ardından bir maksimum havuzlama katmanına sahiptir (Qassim vd., 2018). Şekil 4’te VGG16 mimarisinin görünümü verilmiştir. Giriş görüntü boyutunu 224x224x3 pixel olarak almaktadır.



Şekil 4. VGG16 mimarisi

3.2.3. ResNet18

İyi yakınsama davranışları ve zorlayıcı doğruluk gösteren derin mimariye dayanan ResNet modelleri, He ve diğerleri tarafından geliştirilmiştir. Bu sayede, 2015 yılında ILSVRC ve Bağlamdaki Ortak Nesnelere (COCO) sınıflandırma yarışmasında birinci olmuşlardır. ResNet, birkaç yığılmış artık birim tarafından inşa edilmiştir ve birçok farklı sayıda katmanla geliştirilmiştir: 18, 34, 50, 101, 152 ve 1202. Ancak, farklı mimariye bağlı olarak işlem sayısı değişebilir (Gómez-Ríos vd., 2019). Yukarıdakilerin tümü için artık birimler evrişimli, havuzlama ve katmanlardan oluşur. ResNet, VGG ağına benzemektedir ancak ResNet, VGG'den yaklaşık sekiz kat daha derindir. ResNet 18, derinlik ve performans arasında iyi bir dengelemeyi temsil eder ve bu ağ, beş evrişimli katmandan, bir ortalama havuzlamadan ve softmax ile tam bağlantılı bir katmandan oluşur. Giriş görüntü boyutunu 224x224x3 pixel olarak almaktadır.

3.2.4. GoogleNet

GoogleNet, Szegedy ve diğerlerinin çalışmasında sunulmuştur (Szegedy vd., 2015) ve 2014'te ILSVRC'nin galibi olmuştur. GoogleNet yedi milyon parametreye sahiptir ve dokuz başlangıç modülü, dört evrişimli katman, dört maksimum havuzlama katmanı, üç ortalama havuzlama katmanı, beş tam bağlı katman ve ağdaki ana yardımcı sınıflandırıcılar için üç softmax katmanı içermektedir. Ek olarak, tamamen bağlı katmanda bırakma düzenlemesini kullanır ve tüm evrişimli katmanlarda ReLU aktivasyonunu uygular. Bununla birlikte, bu ağ, toplam 22 katmanla çok daha derin ve geniştir, ancak AlexNet'e kıyasla çok daha düşük sayıda ağ parametresine sahiptir. Bu mimari görüntü boyutunu 224x224x3 pixel olarak almaktadır.

3.2.5. SqueezeNet

Bu mimari Landola ve diğerleri tarafından 2016 yılında önerilmiştir (Zavan vd., 2019). SqueezeNet, AlexNet'in 50 kat daha az parametreye ve 0,5 MB depolama alanına sahip sıkıştırılmış bir versiyonudur. SqueezeNet'te, AlexNet'teki kayan nokta işlemlerini azaltmaktan sorumlu olan sekiz ateş modülü bulunmaktadır.

3.3. Performans Değerlendirme Ölçütleri

Fundus görüntülerinden glokom tespiti için kullanılan modellerin performansını değerlendirmek için karmaşıklık matrisi kullanılmıştır. Tablo 2'de gösterilen karmaşıklık matrisi gerçek sınıf ve sınıflandırıcının tahmin ettiği sınıf olmak üzere iki boyuta sahiptir (Ahmad vd., 2022). Karmaşıklık matrisi sayesinde birçok sınıflandırma modelinin performansı değerlendirilebilmektedir.

Tablo 2 Karmaşıklık Matrisi

		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

Karmaşıklık matrisindeki terimler ve anlamları aşağıdaki gibidir:

- Doğru Pozitif (DP): Pozitif sınıfa ait olan ve sınıflandırıcı tarafından doğru şekilde sınıflandırılan verileri temsil etmektedir.
- Doğru Negatif (DN): Sınıflandırıcı tarafından doğru olarak sınıflandırılan negatif sınıfa ait verileri temsil etmektedir.
- Yanlış Pozitif (YP): Negatif sınıfa ait ifadeler yanlış sınıflandırılır ve pozitif sınıf olarak tanımlanır.
- Yanlış Negatif (YN): Gerçekte pozitif sınıfa ait olan bir örnek negatif sınıf olarak tanımlanır.

Doğruluk: Modelin performansının değerlendirilmesi için kullanılmaktadır. Modeldeki doğru tahminlerin sayısının tüm veri kümesine bölünmesiyle hesaplanmaktadır. Doğruluk değeri denklem 1'deki gibi hesaplanmaktadır.

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

Duyarlılık: Pozitif örneklerin doğruluğuna karşılık gelir ve pozitif sınıfların kaç örneğinin doğru şekilde etiketlendiğini ifade etmektedir. Duyarlılık değeri denklem 2 ile hesaplanmaktadır.

$$\text{Duyarlılık} = \frac{DP}{(DP+YN)} \quad (2)$$

Özgüllük: Modelin, örneklerinin negatif sınıf etiketini tahmin etmedeki olasılığını ifade etmektedir. Denklem 3 ile hesaplanmaktadır.

$$\text{Özgüllük} = \frac{DN}{(DN+YP)} \quad (3)$$

F1-Ölçütü: Pozitif sınıfın analizine odaklanan bir metriktir. Bu metriğin değerinin yüksek olması, modelin pozitif sınıfta daha iyi performans gösterdiğini gösterir.

$$F1 - \text{Ölçütü} = \frac{2*DP}{(2*DP+YP+YN)} \quad (4)$$

4. Araştırma Sonuçları ve Tartışma

Bu çalışmada, fundus görüntülerinden glokom tespiti için ESA modelleri kullanılarak bir değerlendirme yapılmıştır. Bu çalışmanın amacı kullanılan ESA modellerinin performanslarını doğruluk, duyarlılık, özgüllük ve f1 ölçütü bakımından karşılaştırmaktır. Elde edilen sonuçlar Tablo 3'te verilmiştir.

Tablo 3 incelendiğinde, test veri kümesi için doğruluk değeri bakımından en iyi değer %97.98 ile GoogleNet tarafından elde edilirken en kötü değer %93.43 ile SqueezeNet tarafından elde edilmiştir. Duyarlılık bakımından en iyi değeri %97.96 ile


VGG16 vermiştir. En kötü değeri ise %91.35 ile SqueezeNet vermiştir. Özgüllük değeri incelendiğinde, %98.97 değeri ile GoogleNet en iyi performansı gösterirken, %92.63 değeri ile

AlexNet en kötü performansı göstermiştir. F1-ölçütü bakımından ise en iyi değer %98 ile yine GoogleNet ile elde edilmiştir. En kötü değeri ise SqueezeNet vermiştir.

Tablo 3. AlexNet, Rensnet-18, VGG16, SqueezeNet ve GoogleNet Performans Değerlendirme Ölçütleri


Model	Duyarlılık		Özgüllük		Doğruluk		F1-Ölçütü	
	Doğrulama	Test	Doğrulama	Test	Doğrulama	Test	Doğrulama	Test
AlexNet	91.57	94.74	94.20	92.63	92.76	93.68	93.25	93.75
ResNet-18	96.15	93.27	94.74	97.87	95.45	95.45	95.54	95.57
VGG16	94.87	97.96	98.65	97.00	96.71	96.47	96.73	97.46
SqueezeNet	91.14	91.35	93.15	95.74	92.11	93.43	92.31	93.60
GoogleNet	98.70	97.03	96.05	98.97	97.39	97.98	97.44	98.00

Derin öğrenme mimarileri ile test veri kümesi için elde edilen karmaşıklık matrisleri Şekil 5'te gösterilmiştir.



Şekil 5. Mimarilerin test veri kümesi karmaşıklık matrisi

Derin öğrenme mimarileri ile doğrulama veri kümesi için elde edilen karmaşıklık matrisleri Şekil 6'da gösterilmiştir.



Şekil 6. Mimarilerin doğrulama veri kümesi karmaşıklık matrisi

5. Sonuçlar

Bu çalışmada glokom hastalığının daha hızlı ve otomatik tespiti için ESA tabanlı derin öğrenme mimarileri kullanılmıştır. Çalışmada AlexNet, ResNet-18, VGG16, GoogleNet ve SqueezeNet mimarileri kullanılmıştır. Derin öğrenme mimarilerinin doğruluk, duyarlılık, özgüllük ve f1-ölçütü değerleri yönünden karşılaştırması yapılmıştır. Değerlendirme sonucunda doğrulama veri kümesinde duyarlılık için en iyi sonucun %98.70 ile GoogleNet, özgüllük için %98.65 ile VGG16, doğruluk için %97,39 ile GoogleNet ve f1-ölçütü için ise %97.44 ile GoogleNet olduğu görülmüştür. Deneysel sonuçlar değerlendirildiğinde, test veri kümesinde duyarlılık için en iyi sonucun %97.96 ile VGG16, özgüllük, doğruluk ve f-skör için en iyi sonucun sırasıyla %98.97, %97.98 ve %98 ile GoogleNet olduğu tespit edilmiştir.

Kaynakça

- Ahmad, S., Ansari, S. U., Haider, U., Javed, K., Rahman, J. U., & Anwar, S. (2022). Confusion matrix-based modularity induction into pretrained CNN. *Multimedia Tools and Applications*, 1-27.
- Alghamdi, H. S., Tang, H. L., Waheeb, S. A., & Peto, T. (2016, October). Automatic optic disc abnormality detection in fundus images: A deep learning approach. In *Ophthalmic Medical Image Analysis International Workshop (Vol. 3, No. 2016)*. University of Iowa.
- Almazroa, A., Alodhayb, S., Burman, R., Sun, W., Raahemifar, K., & Lakshminarayanan, V. (2015, October). Optic cup segmentation based on extracting blood vessel kinks and cup thresholding using Type-II fuzzy approach. In *2015 2nd International Conference on Opto-Electronics and Applied Optics (IEM OPTRONIX)* (pp. 1-3). IEEE.
- Alsulami, F., Alseleahbi, H., Alsaedi, R., Almaghdawi, R., Alafif, T., Ikram, M., ... & WeTeach, W. HiGANCNN: A Hybrid Generative Adversarial Network and Convolutional Neural Network for Glaucoma Detection.
- Carrillo, J., Bautista, L., Villamizar, J., Rueda, J., & Sanchez, M. (2019, April). Glaucoma detection using fundus images of the eye. In *2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)* (pp. 1-4). IEEE.
- Chen, X., Xu, Y., Wong, D. W. K., Wong, T. Y., & Liu, J. (2015, August). Glaucoma detection based on deep convolutional neural network. In *2015 37th annual international conference*

- of the IEEE engineering in medicine and biology society (EMBC) (pp. 715-718). IEEE.
- Cho, H., Hwang, Y. H., Chung, J. K., Lee, K. B., Park, J. S., Kim, H. G., & Jeong, J. H. (2021). Deep learning ensemble method for classifying glaucoma stages using fundus photographs and convolutional neural networks. *Current eye research*, 46(10), 1516-1524.
- Clifton, L., Clifton, D. A., Pimentel, M. A., Watkinson, P. J., & Tarassenko, L. (2012). Gaussian processes for personalized e-health monitoring with wearable sensors. *IEEE Transactions on Biomedical Engineering*, 60(1), 193-197.
- Dey, A., & Bandyopadhyay, S. K. (2016). Automated glaucoma detection using support vector machine classification method. *British Journal of Medicine and Medical Research*, 11(12), 1.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *nature*, 542(7639), 115-118.
- Gheisari, S., Shariflou, S., Phu, J., Kennedy, P. J., Agar, A., Kalloniatis, M., & Golzan, S. M. (2021). A combined convolutional and recurrent neural network for enhanced glaucoma detection. *Scientific reports*, 11(1), 1-11.
- Gómez-Ríos, A., Tabik, S., Luengo, J., Shihavuddin, A. S. M., Krawczyk, B., & Herrera, F. (2019). Towards highly accurate coral texture images classification using deep convolutional neural networks and data augmentation. *Expert Systems with Applications*, 118, 315-328.
- Hatanaka, Y., Noudo, A., Muramatsu, C., Sawada, A., Hara, T., Yamamoto, T., & Fujita, H. (2010, March). Vertical cup-to-disc ratio measurement for diagnosis of glaucoma on fundus images. In *Medical Imaging 2010: Computer-Aided Diagnosis* (Vol. 7624, pp. 945-952). SPIE.
- Hemelings, R., Elen, B., Barbosa-Breda, J., Blaschko, M. B., De Boever, P., & Stalmans, I. (2021). Deep learning on fundus images detects glaucoma beyond the optic disc. *Scientific Reports*, 11(1), 1-12.
- Krizhevsky, A.; Sutskever, I.; Hinton, G.E. Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems*; Curran Associates, Inc.: New York, NY, USA, 2012;pp. 1097–1105.
- Nayak, D. R., Das, D., Majhi, B., Bhandary, S. V., & Acharya, U. R. (2021). ECNet: An evolutionary convolutional network for automated glaucoma detection using fundus images. *Biomedical Signal Processing and Control*, 67, 102559.
- Orlando, J. I., Prokofyeva, E., del Fresno, M., & Blaschko, M. B. (2017, January). Convolutional neural network transfer for automated glaucoma identification. In *12th international symposium on medical information processing and analysis* (Vol. 10160, pp. 241-250). SPIE.
- Özbay, E. (2022). An active deep learning method for diabetic retinopathy detection in segmented fundus images using artificial bee colony algorithm. *Artificial Intelligence Review*, 1-28.
- Qassim H, Verma A, Feinzimer D. Compressed residual-VGG16 CNN model for big data places image recognition. 8th Annual Computing and Communication Workshop and Conference. Las Vegas: IEEE;2018. p. 169-175
- Sevastopolsky, A. (2017). Optic disc and cup segmentation methods for glaucoma detection with modification of U-Net convolutional neural network. *Pattern Recognition and Image Analysis*, 27(3), 618-624.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- Tham, Y. C., Li, X., Wong, T. Y., Quigley, H. A., Aung, T., & Cheng, C. Y. (2014). Global prevalence of glaucoma and projections of glaucoma burden through 2040: a systematic review and meta-analysis. *Ophthalmology*, 121(11), 2081-2090.
- Uddin, M., Tammimies, K., Pellicchia, G., Alipanahi, B., Hu, P., Wang, Z., ... & Scherer, S. W. (2014). Brain-expressed exons under purifying selection are enriched for de novo mutations in autism spectrum disorder. *Nature genetics*, 46(7), 742-747.
- Weinreb, R. N., Aung, T., & Medeiros, F. A. (2014). The pathophysiology and treatment of glaucoma: a review. *Jama*, 311(18), 1901-1911.
- Zavan, F. H. D. B., Bellon, O. R., Silva, L., & Medioni, G. G. (2019). Benchmarking parts based face processing in-the-wild for gender recognition and head pose estimation. *Pattern Recognition Letters*, 123, 104-110



QuaVita: Sağlıklı Yaşam Mobil Uygulaması

Osman Güler¹, Özgü Can^{2*}

¹ Ege Üniversitesi, Mühendislik Fakültesi, Bilgisayar Bölümü, İzmir, Türkiye, (ORCID: 0000-0001-6444-1102), osman-guler@outlook.com

^{2*} Ege Üniversitesi, Mühendislik Fakültesi, Bilgisayar Bölümü, İzmir, Türkiye (ORCID: 0000-0002-8064-2905), ozgu.can@ege.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1216686)

ATIF/REFERENCE: Güler, O. & Can, Ö. (2022). QuaVita: Sağlıklı Yaşam Mobil Uygulaması. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 7-12.

Öz

Mobil sağlık, kullanıcıların sağlıklarını takip etmelerini, tıbbi verilerini izlemelerini, tedavi süreçleri ile ilgili hatırlatma uyarılarını almalarını, günlük aktivitelerini ve yaşam biçimlerini izlemelerini sağlamaktadır. Günümüzde mobil cihaz kullanımı sağlıklı yaşam biçiminin sürdürülmesindeki en önemli araçlardan biri haline gelmiştir. Hayatımızın bir parçası haline gelmiş olan mobil cihazlar, mobil sağlık amacı ile kullanılmakta ve kullanıcıların sağlık durumlarını kolaylıkla takip edebilmelerini sağlamaktadır. Bu çalışmada, sağlıklı yaşam sürecinin izlenmesini sağlamak için QuaVita sağlıklı yaşam mobil uygulaması geliştirilmiştir. Geliştirilen QuaVita mobil uygulaması ile kullanıcıların sağlıklı bir yaşam süreçlerine destek olmak amaçlanmaktadır. QuaVita, kullanıcıların sağlık verilerini saklamalarını, kalp ritimlerini ölçebilmelerini, ilaç alarmı, günlük adım takibi ve su tüketim takibi yapabilmelerini sağlamaktadır. Kullanıcılar ayrıca, Türkiye'deki tüm nöbetçi eczanelere uygulama üzerinden erişebileceklerdir. QuaVita uygulaması ile her yaşta kullanıcının sağlıklı yaşam hedeflerini kolay bir şekilde takip edebilmeleri amaçlanmıştır. Böylelikle, kullanıcılar sağlıkları konusunda daha bilinçli olabilecekler ve sağlıklı yaşam biçimlerine yönelik farkındalıklarını arttırabileceklerdir.

Anahtar Kelimeler: Mobil Uygulama, m-Sağlık, Sağlık Bilgi Sistemi, Sağlık Bilişim, Elektronik Sağlık.

QuaVita: A Healthy Living Mobile Application

Abstract

Mobile health enables users to track their health, monitor their medical data, receive reminders about treatment processes, and monitor their daily activities and lifestyles. Today, the use of mobile devices has become one of the most important tools in maintaining the healthy lifestyle. Mobile devices, which have become a part of our lives, are used for mobile health purposes and enable users to easily monitor their health status. In this study, QuaVita healthy living mobile application is developed to track the healthy wellness. The developed QuaVita mobile application aims to support users' healthy lifestyle. QuaVita enables users to store their health data, measure their heart rhythms, remind their medication, tracks their daily steps and water consumptions. Users will also be able to access all the pharmacies on duty in Turkey through the application. Users of all ages can easily follow their healthy life goals with the QuaVita application. Thus, users will be more attentive about their health and increase their awareness of healthy lifestyles.

Keywords: Mobile Application, m-Health, Health Information System, Health Informatics, Electronic Health.

1. Giriş

Son yıllarda mobil ekosistemin gelişmesiyle birlikte birbirinden farklı birçok alanda mobil uygulama geliştirilmeye başlanmıştır. Bu alanlardan bazıları, eğitim, sağlık, oyun, e-ticaret olarak sıralanabilir. Bu alanlardan insan hayatı için en önemli olanı sağlıktır. Hayatımızın her anında önceliğimiz her zaman sağlık olmuştur. Bu nedenle, insanların sağlıklarını bu kadar önemseydiği bir zamanda, bu çalışmada sağlık alanı temel alınmıştır.

Sağlıklı bir insan ve sağlıklı bir yaşam için en önde gelen şartlar disiplin ve kontroldür. İnsan yaşamında günlük yapılması gereken işlerden dolayı sağlıklı yaşama uymak geri planda kalmakta ve unutulmaktadır. Bu kapsamda, mobil sağlık uygulamalarının temel sağlık hedeflerine ulaşmada önemli bir yeri vardır. Mobil sağlık uygulamalarının önemi doğrultusunda literatürde de çeşitli çalışmalar bulunmaktadır (Değerli, 2019; Tezcan, 2016; Kopmaz ve Arslanoğlu, 2018, Aydın, 2020; Ünalmır vd., 2011, Istepanian vd., 2006).

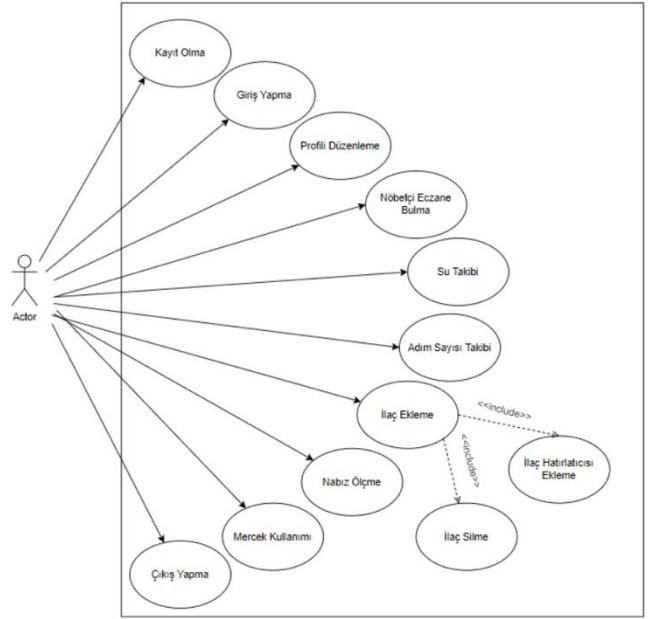
Bu çalışmada, kullanıcılarına sağlıklı yaşam için disiplini, kontrolü ve motivasyonu vaat eden bir mobil uygulama önerilmektedir. Bu kapsamda, QuaVita isimli sağlıklı yaşam alanında rakiplerinden farklı bir mobil uygulama geliştirilmiştir.

QuaVita, basit arayüzü ve kullanışlı bileşenleriyle her yaştan ve her kesimden insanlara hitap eden bir sağlık uygulaması olarak geliştirilmiştir. Bu uygulamada, sektördeki diğer uygulamalardan farklı olarak önceliği kalori takibine vermek yerine, kullanıcının kullanmakta olduğu ilaçların listesinin tutulmasına ve bunların kullanılması gereken sıklıkta hatırlatılmasına önem verilmiştir. Böylelikle, kullanıcıların alması gereken önemli ilaçlarını hayatının günlük akışında unutmadan zamanında alması hedeflenmiştir. Bununla birlikte önem verilen bir diğer konu da nöbetçi eczane bilgisidir. Her an acil bir durum olabileceğini düşünerek, kullanıcının internette nöbetçi eczane arayarak vakit kaybetmesini engellemek ve hızlıca yakınındaki nöbetçi eczaneye ulaşması amaçlanmıştır. Bunların yanında, sağlıklı yaşama destek olmak ve hayatı kolaylaştırmak amacıyla uygulamaya adım takibi, su takibi, nabız ölçer ve mercek özellikleri de eklenmiştir. Adım takibi, kullanıcının günlük hedef olarak belirlediği adım sayısını tamamlayıp tamamlamadığını görerek hareketli bir yaşam için kullanıcıyı motive ederken; su takibi de günlük hayat akışında unutilan ve hayati önemi olan suyun içilmesini teşvik ederek kullanıcıyı bu yönde motive etmektedir. Bir diğer bileşen olan nabız ölçer kullanıcının kendini aniden rahatsız hissettiği ve nabzını ölçme ihtiyacı duyduğunda, kamera vasıtasıyla nabzını ölçebilmesini sağlamaktadır. Böylelikle, kullanıcı acil ve normal olmayan bir sonuç çıkarsa hastaneye daha erken başvurabilecektir. Son olarak, mercek özelliği de görme problemi yaşayan kişilerin, kamera aracılığıyla nesnelere yakınlaştırmasını ve daha rahat görebilmesini sağlamaktadır. QuaVita, bu bileşenleri ile kullanıcının hayatını kolaylaştırmak ve ona sağlıklı bir yaşam sunmak için geliştirilen bir mobil uygulamadır.

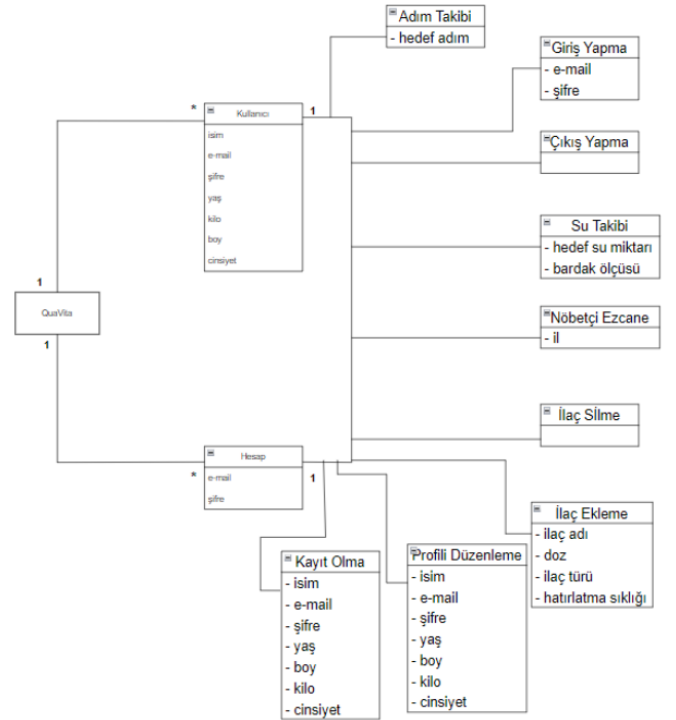
Bu çalışmanın organizasyonu şu şekildedir: ikinci bölümde yöntem ve metot açıklanmakta, üçüncü bölümde uygulamanın literatürdeki uygulamalar ile bir karşılaştırması verilmekte ve son olarak dördüncü bölümde sonuçlar sunulmaktadır.

2. Materyal ve Metot

QuaVita sağlıklı yaşam mobil uygulamasının her gruptan insanın kullanabilmesi hedeflenmiştir. Uygulama ile kullanıcılar kayıt olma, profil düzenleme, ilaç ekleme-hatırlatma-silme, nöbetçi eczane bulma, adım takibi, su takibi, nabız ölçme ve mercek işlemlerini gerçekleştirebilmektedir. Şekil 1'de kullanıcının gerçekleştirebileceği işlemlere yönelik bir kullanıcı için kullanım şekli (*use case*) diyagramı görülmektedir. QuaVita uygulamasının etki alanı modeli Şekil 2'de sunulmaktadır.



Şekil 1. Kullanıcı için kullanım şekli diyagramı.



Şekil 2. Etki alanı modeli.

QuaVita uygulamasının geliştirilmesinde Flutter (Flutter, 2022) açık kaynak çerçevesi ve Dart dili kullanılmıştır. Uygulamada sunulan nöbetçi eczane hizmetine Eczaneleri.net (Eczaneleri.net, 2022) sitesinin sağlamış olduğu API desteği ile erişilmiştir. Ek olarak, Türkiye genelindeki nöbetçi eczanelere de Rest API (Rest API, 2022) yapısı aracılığıyla ulaşılmaktadır. QuaVita uygulamasında, kimlik denetleme ve veri saklama için Firebase (Firebase, 2022) kullanılmıştır.


Kullanıcın QuaVita uygulamasını açtığında karşılaşıcağı ekran Şekil 3'de görülmektedir. Kullanıcı daha önceden uygulamaya kayıt olmuşsa, sisteme kayıtlı e-posta ve parola bilgisi ile uygulamaya giriş yapabilmektedir. Kullanıcı sisteme henüz üye olmadı ise Login düğmesi altında yer alan Create Account düğmesine tıklayarak uygulamaya kayıt olmak üzere yeni bir sayfaya yönlendirilmektedir.




Şekil 3. QuaVita açılış ekranı.

Uygulamaya daha önceden kayıt olmayan kullanıcı, giriş ekranından kayıt ekranına yönlendirilir ve ad, e-posta, parola, boy, kilo, yaş ve cinsiyet bilgilerini girerek kaydını oluşturur. Kullanıcı kaydını oluşturduktan sonra giriş ekranından e-posta ve parola bilgileriyle uygulamaya giriş yapabilmektedir. Şekil 4'te kullanıcının kayıt ekran görüntüsü verilmektedir.

Kullanıcı uygulamaya giriş yaptıktan sonra tek bir ekrandan uygulamanın tüm servislerine erişebilmektedir. Şekil 5'te uygulamanın ana ekran görüntüsü sunulmaktadır.

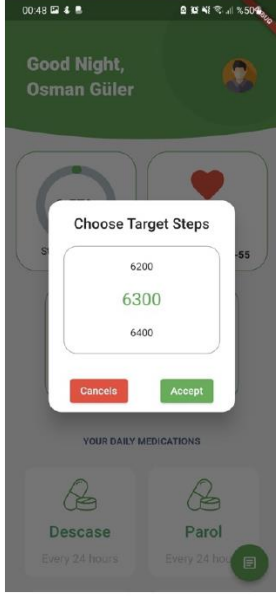


Şekil 4. Kullanıcı kayıt ekranı.



Şekil 5. QuaVita ana ekran.

Kullanıcının ana ekranındaki adım takibi widget'ına tıklamasıyla birlikte açılan ve Şekil 6'da görülen yeni ekranda kullanıcıdan günlük hedef adım sayısını seçmesi istenir. Böylelikle, kullanıcı widget üzerinden günlük hedef adım sayısının takibini gerçekleştirebilmektedir.




Şekil 6. Günlük adım hedef ekranı.



Şekil 8. Su tüketim ekranı.


Kullanıcı, ana ekrandaki kalp ritmi widget'ı aracılığıyla nabız ölçümü yapma üzere yeni bir ekrana yönlendirilmektedir. Bu ekrandan kullanıcı, kalp ikonuna basarak flaş ve kamera yardımıyla yaklaşık bir dakikalık bir sürede kalp ritmini ölçebilmektedir. Kullanıcı ayrıca, ölçüm sırasında ekranın altında bulunan grafikten de kalp ritminin düzenini izleyebilmektedir. Kullanıcı ölçümünü tamamlayıp ana ekrana döndüğünde, son yapılan ölçüm sonucunu ve ölçümün tarihini ana ekrandaki kalp ritmi widget'ının üzerinde görebilmektedir. Şekil 7'de kalp ritim ölçme ekranı sunulmaktadır.



Şekil 7. Kalp ritim ölçüm ekranı.


Kullanıcı, günlük almak istediği hedef su miktarını ve bardak büyüklüklerini ayarlamak için ana ekranda bulunan su takibi widget'ını kullanmaktadır. Şekil 8'de görülen ekran üzerinden günlük hedef su miktarı ve bardak ölçüsü seçilmektedir. Kullanıcı, ana ekrandaki widget üzerinde bulunan "+" ikonuyla tüketilen su miktarını ekleyebilmekte, "-" ikonu ile ise silme yapabilmektedir.

Kullanıcı kullandığı ve hatırlatılmasını istediği ilaçları takip sistemine ekleme işlemini QuaVita uygulaması ile gerçekleştirebilmektedir. Kullanıcı, ilaç ekleme ikonuna tıklayarak ilaç eklemek üzere ilaç ismini, miligramını, tipini, ilacı kaç saatte bir almak istediği bilgisini ve başlangıç saatini belirlemek için Şekil 9'da gösterilen ekrana yönlendirilmektedir.




Şekil 9. İlaç hatırlatma ekranı.

Eklenen ilaç ile ilgili detaylar ise Şekil 10'da görülen ekran üzerinden görülebilmektedir.



Şekil 10. İlaç detayları görüntüleme ekranı.

Kullanıcı, bulunduğu konumun yakınındaki nöbetçi eczaneleri bulmak istediğinde “Nöbetçi Eczane Ekranı” üzerinden şehir bilgisini seçtiğinde ilgili şehirdeki eczaneler listelenmektedir. Şekil 11’de listelenen nöbetçi eczaneleri gösteren ekran görülmektedir.



Şekil 11. Nöbetçi Eczane ekranı.

3. Araştırma Sonuçları ve Tartışma

Literatürde sağlıklı yaşam kapsamında çeşitli uygulamalar bulunmaktadır. QuaVita uygulamasında geliştirilen bileşenlerin belirlenmesinde sağlıklı yaşam için öncelikli gereksinimler dikkate alınmıştır. Bu doğrultuda, nöbetçi eczane bilgisine ulaşılması, tüketilen su miktarının ve günlük tüketim hedefinin takibi, günlük adım takibi ve nabız ölçümü uygulamanın öncelikli servisleri olarak belirlenmiştir. Bu çalışmada geliştirilen QuaVita uygulamasının literatürde en sık kullanılan FatSecret [11], MyFitnessPal (MyFitnessPal, 2022), MyTherapy (MyTherapy, 2022) ve Nöbetçi Eczane (Nöbetçi, Eczane, 2022) uygulamaları ile karşılaştırılması Tablo 1’de sunulmaktadır. QuaVita’nın temel hedefi tüm yaş gruplarındaki kullanıcıların sağlıklı yaşam gereksinimlerini karşılamaya yönelik bütünsel bir uygulama olması ve kullanım kolaylığı sağlamasıdır.

Tablo 1. Mevcut uygulamalar ile karşılaştırma tablosu.

Uygulama	FatSecret	MyFitnessPal	MyTherapy	Nöbetçi Eczane	QuaVita
Özellik					
Adım Takibi	✓	✓			✓
Su Takibi	✓	✓			✓
Nabız Ölçer					✓
Nöbetçi Eczane				✓	✓
İlaç Kaydetme ve Hatırlatma			✓		✓
Mercek					✓
Kalori Takibi	✓	✓			
Randevu Kaydetme			✓		
Paylaşım İmkânı	✓	✓			
Egzersiz Kaydetme		✓			
Premium Hesap	✓	✓			

4. Sonuç

Sağlıklı bir yaşam sürmek için çok basit prensiplere dayalı olsa da modern zamanın yoğun temposunda arka planda kalmaktadır. QuaVita uygulaması, kullanıcılarının sağlıklı yaşam sürmelerini göz ardı etmemesi amacıyla tasarlanmış bir uygulamadır. Bu amaç doğrultusunda uygulamaya ilk etapta sağlıklı bir yaşam ve acil durumlar için en önemli denebilecek işlevsellikteki bileşenler eklenmiştir. Bu bileşenler, ilaç eklemehatırlatma, tüketilen su takibi, nabız kontrolü, nöbetçi eczane öğrenmedir. Gelecek çalışmalar kapsamında uygulamaya sağlıklı yaşama yönelik yeni özelliklerin eklenmesi planlanmaktadır. Böylelikle, kullanıcıların sağlıklı yaşam konusunda ulaşmak istedikleri tüm servislere tek bir uygulama üzerinden erişebilmeleri ve sağlıklı yaşam hedefleri doğrultusunda günlük rutinlerini kontrol edebilmeleri sağlanacaktır.

Kaynakça

- Aydın, N., “Sağlıkta Yeni Bir Dönem: Mobil Sağlık”, International Social Mentality and Researcher Thinkers Journal, 6(38): 2438-2447, 2020.
- Değerli, M., “Mobil Sağlık Uygulamalarına Genel Bir Bakış ve Özgün Bir Mobil Sağlık Uygulaması Geliştirilmesi”, EMO Bilimsel Dergi, Cilt:11, Sayı: 21, s. 59-69, 2021.
- Eczaneleri.net, “Türkiye’nin Nöbetçi Eczaneleri”, <https://eczaneleri.net> Son Erişim: 30 Kasım 2022
- FatSecret, <https://www.fatsecret.com> Son Erişim: 30 Kasım 2022

- Firestore, <https://firebase.google.com> Son Erişim: 30 Kasım 2022
- Flutter, <https://flutter.dev> Son Erişim: 30 Kasım 2022
- Istepanian, R.S.H., Laxminarayan, S., Pattichis, C.S., M-Health: Emerging Mobile Health Systems, 1st Ed., Springer, 2006.
- Kopmaz, B. ve Arslanoğlu, A., “Mobil sağlık ve akıllı sağlık uygulamaları”, Sağlık Akademisyenleri Dergisi, 5(4): 251-255, 2018.
- MyFitnessPal, <https://www.myfitnesspal.com> Son Erişim: 30 Kasım 2022
- MyTherapy, <https://www.mytherapyapp.com> Son Erişim: 30 Kasım 2022
- Nöbetçi Eczane, <https://play.google.com/store/apps/details?id=com.adcinteractive.eczane&hl=tr&gl=US> Son Erişim: 30 Kasım 2022
- Rest API Tutorial, <https://restfulapi.net> Son Erişim: 30 Kasım 2022
- Tezcan, C., “Sağlıkta Yenilikçi Bir bakış Açısı: Mobil Sağlık”, Teknik Rapor, TÜSİAD-T/2016-03/575, 2016.
- Ünalır, E., Can, Ö. ve Ünalır, M.O., Mobil Uygulamaların Ulusal Aşı Bilgi Sistemindeki Yeri ve Önemi, Mobil Yaşam ve Uygulamaları, s. 203-215, 2011.



Görüntüler İçin Kaotik Şifreleme Sistemi Ve Performans Analizi

Gizem Seval^{1*}, Mustafa Cem Kasapbaşı²

^{1*} İstanbul Ticaret Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Anabilim Dalı Siber Güvenlik Bölümü, İstanbul, Türkiye (ORCID: 0000-0001-8869-4198), gizem.seval@istanbulticaret.edu.tr

² İstanbul Ticaret Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye (ORCID: 0000-0001-6444-6659), mckasapbasi@ticaret.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1216797)

ATIF/REFERENCE: Seval G & Kasapbaşı M.C. (2022). Görüntüler İçin Kaotik Kriptografi Sistemi ve Performans Analizi. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 13-20.

Öz

Teknoloji yıllar içinde çok hızlı bir şekilde ilerlemiş ve bu ilerleyişine hızla devam etmektedir. Bu süreçte verilerin güvenliğini sağlama konusu da her alanda önemini artırmıştır. Bu çalışmada kullanılan veri kaynağı görüntü olarak seçilmiştir. Görüntü şifrelemede histogram, korelasyon, diferansiyel saldırı, anahtar uzay, anahtar hassasiyet, zaman karmaşıklığı, entropi başarı analizleri ve istatistiksel analizlere yönelik NIST testleri kullanılmıştır. Tanımlanan analiz ve testler doğrultusunda gerçekleştirilen analiz sonuçları karşılaştırılarak görüntü şifrelemede kullanılan bu yöntemlerin çıktı olarak doğru sonuçları ve beklenen performansları verip vermediği değerlendirilmiştir. Önerilen şifreleme yönteminin çıktı olarak başarılı sonuç ve performansları verdiği gözlemlenmiştir.

Anahtar Kelimeler: Kaotik, Performans Analizi, Görüntü Şifreleme

Chaotic Encryption System For Images And Performance Analysis

Abstract

Technology has progressed very rapidly over the years and this progress continues rapidly. In this process, the issue of ensuring the security of data has increased its importance in every field. The data source used in this study was chosen as an image. In image encryption, histogram, correlation, differential attack, key space, key sensitivity, time complexity, entropy for success analysis and NIST tests for statistical analysis were used. By comparing the analysis results performed in line with the defined analysis and tests, it has been evaluated whether these methods used in image encryption give the correct results and expected performances as output. It has been observed that the proposed encryption method gives successful results and performances as output.

Keywords: Chaotic, Image Encryption, Performance Analysis.

* Sorumlu Yazar: gizem.seval@istanbulticaret.edu.tr

1. Giriş

Verilerin güvenliğinin sağlanması konusunun önem düzeyi teknolojinin hızla gelişmesinin sonucu olarak artış göstermiştir. Şifreleme veri güvenliğinin sağlanmasında kullanılan yöntemlerdir. Önem düzeyine bağlı olarak veriler şifreli olarak kaydedilebilmekte veya aktarılabilir. Son kullanıcılar için ihtiyaç haline gelen şifreleme, verileri okunamaz duruma getirerek korumayı sağlamaktadır. Dolayısıyla verilere yetkisi olan kişiler haricinde kimse erişememekte böylece verilerin hem gizliliği hem de güvenliği sağlanmıştır. Yetkili kişiler şifre çözme yöntemlerini kullanarak verilere erişim sağlayabilmektedir.

Verilen şifrelenmesi için en çok kullanılan bazı klasik ve modern şifreleme algoritmaları Vigenere, DES (Data Encryption Standart – Veri Şifreleme Standardı), AES (Advanced Encryption Standard – Gelişmiş Şifreleme Standardı) RC4, RC5, Blowfish, IDEA olarak örnek verilebilir. (ATALAY, DOĞAN, TUNCER, & AKBAL, 2019) (CEYHAN & YOLAÇAN, 2021) Verilerin şifrelerinin çözülmesiyle şifre çözme algoritmaları kullanılarak gerçekleştirilmektedir. Bu çalışmada veri kaynağı olarak görüntü seçilmiştir çünkü multimedya kullanımı dijital çağda giderek artmakta ve kullanılan multimedya da gizlilik ve güvenliği önemli hale gelmektedir. Görüntü şifrelemelerin resimdeki bilgilerin korelasyonlarından dolayı farklı zorlukları vardır.

Bölüm 1’de görüntü şifreleme konusu hakkında gerçekleştirilen çalışmaların literatür taraması yapılmıştır. Bölüm 2’de görüntü şifrelemede kullanılan başarı analizleri tanımlanmıştır. Bölüm 3’te Bölüm 2’de tanımlanan analiz yöntemleri kullanılarak gerçekleştirilen analizlerin sonuçları sunulmuştur. Bölüm 4’te bu çalışmanın sonucunda görüntü şifrelemede kullanılan başarı analizlerinin uygulanmasıyla birlikte performansları değerlendirilerek analizlerin karşılaştırılması yapılmıştır.

İnternet üzerinden bilgi aktarımı ses, görüntü ve diğer yollarla sağlanabilmektedir. Bu sebeple bilgilerin aktarım esnasında, bilgilerin saklanması esnasında ya da bilgilere erişim esnasında güvenliklerini sağlamanın önemi artmaktadır. Literatür taraması konusu olarak görüntü şifreleme, görüntü işleme, şifreleme algoritmaları ve şifre çözme algoritmaları hakkında yapılan çalışmalara bu bölümde yer verilmiştir.

2012 yılında gerçekleştirilen bir çalışmada (Al-Maadeed, Al-Ali, & Abdalla, 2012) sıkıştırma yoluyla birleştirilmiş görüntülerin şifrelenmesi için yöntem önerilmiştir. Şifreleme için, kaotik haritaya dayalı algoritma kullanılmıştır. Sonuç olarak harici şifreleme anahtar sayıları fazlalaştıkça asıl görüntüyle şifrelenmiş görüntü arasındaki korelasyonun azaldığı bu sayede güvenliğinin arttığı belirlenmiştir.

2016 yılında Ümit Çavuşoğlu yaptığı tez çalışmasında (ÇAVUŞOĞLU, 2016), güvenliği yüksek ve kaos tabanlı hibrit tasarımları gerçekleştirmek amacıyla kaotik sistemlerin çeşitli özelliklerini ve modern şifreleme algoritmalarını harmanlamıştır. Bu harmanlamanın sonucunda geliştirilen kaos tabanlı şifreleme algoritmalarının görüntü şifrelemede kullanılmasının güvenilir olacağı kanıtlanmıştır.

Nursin Catak ve arkadaşı tarafından yapılan araştırma çalışmasında (ELMACI & CATAK, 2019), iki boyutlu dönüşümü iki boyutlu dönüşümden daha yüksek dönüşümlere

çevirmek adına kaotik dönüşüm olan Arnold’ın CAT dönüşümünü kullanılmıştır. CAT dönüşümünün şifrelenmiş görüntüdeki şifrenin çözümü için daha çok güvenlik sağlayan karışık sonuçlar sağladığı belirlenmiştir. Çalışma sonucunda şifrenin çözülmesiyle doğru bir şekilde ve kolayca sağlanmıştır.

Ye Guodong yaptığı tez çalışmasında (Guodong, 2015) kaos tabanlı görüntü şifreleme şemalarını konu olarak ele almıştır. Çalışmada Shannon teoremiyle tasarlanan difüzyon yapısıyla birlikte klasik karışıklık kullanılmıştır. Güvenlik analizlerinin sonucunda beklenen görüntü şifreleme şemalarının güvenlik seviyelerine ulaşılmıştır.

Samuel Hartman 2005 yılında yaptığı tez çalışmasında (Hartman, 2005) rastgeleliğe yeni bir bakış açısı yaratan bilim dalı olan kaos teorisini ve evrensel fonksiyon sınıfına göre oluşturulan mandelbrot kümesini konu olarak ele almıştır. Dinamik davranışlar sergilemeyen bazı kaotik şifreleme sistemlerinin güvenlik açığı olduğu tespit edilmiştir.

Zhongyun Hua ve arkadaşları bu soruna odaklanarak kosinüs dönüşümüyle ilgili kaotik sistem (CTBCS) üzerinde çalışma (Hua, Zhou, & Huang, 2018) yapmışlardır. Performans değerlendirmeleriyle birlikte güvenlik analizlerinden çıkan sonuca göre kosinüs dönüşümüyle ilgili kaotik sistem haritaları farklı yöntemler kullanılarak üretilen kaotik haritalardan daha üstün kaos performansı sergilemiştir.

Cihat Keleş 2012 yılında yaptığı tez çalışmasında (KELEŞ, 2012) kriptografinin temellerini, çoklu ortam içeriklerinin şifreleme sorunlarını, kaos teorisini ve kaos teorisinin kriptografiyle ortak noktalarını araştırmıştır. Güvenlik analizleri ile istatistiksel analizler gerçekleştirildiğinde çıkan sonuca göre bit tabanlı kaotik karıştırma piksel tabanlıya göre yayılma aşamasını daha çok etkilediği belirlenmiştir.

Chengqing Li ve arkadaşları bilgi entropisi kaotik algoritmalarının güvenliği ve güvenlik değerlendirmelerinin geçerlilikleri üzerine çalışma (LI, LIN, FENG, LÜ, & Hao, 2018) yapmışlardır. Yanlış sonuçların çıkabileceğini belirlemişler bu sebeple güvenli bir multimedya şifrelemesi için kapsamlı düşünülerek kriptanalitik çalışmaların artırılmasının gerekli olduğu sonucuna ulaşmışlardır.

Zahir Muhammed Ziad Muhammad ve Fatih Özkaynak aynı şekilde güvenlik sorunları üzerine çalışmıştır. Yaptıkları çalışmada (Muhammad & Özkaynak, 2017) şifreleme algoritmalarında bulunan güvenlik açıklıklarının analizini gerçekleştirerek analiz sonuçlarının sağlaması olarak algoritmaları bozmuşlardır. Çalışma için yazılan senaryoda algoritma geliştirilirken hedeflenen SHA-3 algoritmasına dayalı anahtar planlamadır. Çalışmanın sonucunda hesaplama makinesi değiştirilerek algoritmanın kırılabileceği kanıtlanmıştır.

Osemwegie Omoruyi ve arkadaşları yaptıkları çalışmada (Omoruyi, ve diğerleri, 2019) bir başka şifreleme algoritması olan Hill Cipher algoritmasını kullanarak görüntü izleme uygulamaları için algoritmanın şifreleme kalitesini değerlendirmişlerdir. Değerlendirme sonucunda, diğer algoritmalara göre tepe şifreleme algoritmasının daha etkin bulunduğu görülmüştür.

Musa Peker yaptığı tez çalışmasında (PEKER, 2009) kamera görüntülerinde hareket analizi için kullanılan teknikleri analiz ederek uygulamış ayrıca uygulama sonuçlarını tartışmıştır. Görüntü şifrelemede kullanılan görüntü işleme ve RGB

(Kırmızı, yeşil, mavi) konularına değinilmiştir. Kullanılan yöntem basit fark alma olarak adlandırılan hareket tespit segmentasyonudur. Bu segmentasyon koordinatlardaki piksel farklarının eşik değeriyle kıyaslanmasından elde edilen sonuçla belirlenmektedir. Çalışma sonucunda bilgisayara bağlı web kamerası hareket eden nesnelerin takibi için yönlendirilmiştir.

Serdar Solak ve Umut Altınışik yaptıkları çalışmada (Solak & Altınışik, 2018) görüntü işleme tekniklerini fındık meyvesine uygulamışlardır. Kullanılan teknik ve sınıflandırmaları karşılaştırmışlardır sonuç olarak kullanılan yöntemlerin maliyeti düşük, performansı yüksek olarak gerçekleştirilen analiz sonuçlarında belli bir oranda benzerlik gösterdiğini tespit etmişlerdir.

2. Materyal ve Metot

2.1. Resim Şifrelemede Kullanılan Başarı Analizleri

Belirli metrikler kullanılarak görüntü şifreleme (SAKAL & YILDIRIM, 2016) işlemi gerçekleştirilmektedir. İmge şifreleme analizi (Fadhel, Shafry, & Farook, 2017) olarak da adlandırılan görüntü şifreleme başarı analizleri bu metrikler doğrultusunda sonuçlandırılmaktadır. Bu çalışmada kullanılan analiz yöntemlerine ve gerçekleştirilen testlere aşağıda yer verilmiştir.

2.1.1. Histogram Analizi

Grafiksel bir gösterim olan histogram, dijital görüntüde var olan piksel yoğunluk değerlerinin frekans dağılımını belirtir. Bu analiz sonucunda beklenti histogram grafiğinin tekdüze bir dağılıma sahip olmasıdır. Şifrelenmiş resmin histogram analizi grafiğiyle resmin aslının histogram analizi grafiği farklı olmalıdır. Histogram dağılımlarının standardının tekdüze bir yapıda olmasının gerekliliği şifreleme teknikleri için kriptanaliz risklerinin bulunmasından dolayıdır.

2.1.2. Korelasyon Analizi

Şifrelenmiş görüntü üzerindeki bitişik piksellerde korelasyon bulunmamalıdır. Bitişik piksellerde korelasyon bulunması kötü niyetli herhangi bir kullanıcının resmi tekrar oluşturabilmesine ya da görüntü üzerinde değişiklikler yapabilmesine yol açabilmektedir. Korelasyon katsayıları -1 ve +1 arasındadır. -1 mükemmel negatif, +1 pozitif doğrusal ilişkiyi belirtmektedir. Bu analiz sonucunda beklenti analiz sonucunun 0'a yakın olmasıdır. Aşağıdaki verilen denklemlerle korelasyon katsayıları hesaplanabilmektedir.

$$r_{\alpha\beta} = \frac{cov(\alpha,\beta)}{\sqrt{D(\alpha)}\sqrt{D(\beta)}} \quad (1)$$

$$E(\alpha) = \frac{1}{N} \sum_{i=1}^N \alpha_i \quad (2)$$

$$D(\alpha) = \frac{1}{N} \sum_{i=1}^N (\alpha_i - E(\alpha))^2 \quad (3)$$

$$cov(\alpha,\beta) = \frac{1}{N} \sum_{i=1}^N (\alpha_i - E(\alpha))(\beta_i - E(\beta)) \quad (4)$$

2.1.3. Diferansiyel Saldırı Analizi

Pikseldeki küçük veya büyük herhangi bir değişiklik ile resmin aslıyla şifrelenmiş görüntüdeki değişiklikleri görüntülemek için yapılan analizler diferansiyel saldırı analizi olarak adlandırılmaktadır. Bu analizin yapılabilmesi için resmin aslı ile değiştirilmiş olan resmin aynı şifreleme tekniğiyle şifrelenmiş olması gerekmektedir. NPCR (Number of changing pixel rate) ve UACI (Unified averaged changed intensity) en çok kullanılan diferansiyel saldırı analizi yöntemlerindedir. UACI oranı, görüntü şifreleme için kullanılan tekniklere karşı gerçekleştirilen kötü niyetli saldırılara dayanıklılık oranıdır. NPCR oranı, resmin aslıyla pikseli değiştirilmiş olan resmin karşılaştırılması sonucunda şifreli resmin piksel sayısındaki değişim oranını belirten orandır. Bu analiz sonucundaki beklenti aşağıdaki denklem kullanılarak bulunan NPCR oranının 0.99 olmasıdır. Denklemdeki H (Height) ile W (Width) değerleri resmin yükseklik ve genişlik değerlerini ifade etmektedir. D değeri, C1 ile C2 görüntülerine eş büyüklükteki diziyi belirtmektedir ve 0 veya 1 bileşenleri kullanılmaktadır.

$$NPCR = \frac{\sum_{i=1}^H \sum_{j=1}^W D(i,j)}{W \times H} \times 100\% \quad (5)$$

$$D(i,j) = \begin{cases} 0 & C1(i,j) = C2(i,j) \\ 1 & C1(i,j) \neq C2(i,j) \end{cases} \quad (6)$$

UACI oranı, resmin aslıyla şifrelenmiş görüntü arasındaki ortalama yoğunluk farkı olarak tanımlanmaktadır. Bu analiz sonucundaki beklenti aşağıdaki denklem kullanılarak bulunan UACI oranının 0.34 olmasıdır. Denklemdeki L parametresi resmin pikselini belirten bit sayısıdır.

$$UACI = \frac{1}{W \times H} \left[\sum_{i=1}^H \sum_{j=1}^W \frac{|C1(i,j) - C2(i,j)|}{2^L - 1} \right] 100\% \quad (7)$$

2.1.4. Anahtar Uzay Analizi

Kaba kuvvet saldırılarına karşı dayanıklı şifreleme oluşturulabilmesi için anahtar uzayının fizibilitesi için belirlenen kombinasyonların yeterli olması gerekmektedir. Görüntü şifreleme algoritmalarından bazıları küçük anahtar alanlara sahiptir bu nedenle kaba kuvvet saldırılarına karşı savunmasızdır. Aşağıdaki tabloda (Tablo 1) genel olarak görüntü şifreleme algoritmalarında kullanılan anahtar uzay aralıkları verilmiştir.

Tablo 1. Anahtar Uzay Aralıkları

Anahtar Aralığı	Algoritma
2^{128}	AES
2^{128}	RC5
2^{128}	Vigenere
2^{128}	IDEA
2^{64}	Blowfish
2^{56}	DES
2^{256}	RC4

2.1.5. Anahtar Hassasiyet Analizi

Resmi şifrelerken kullanılan algoritmalarındaki anahtarda oluşan değişimleri belirlemek amacıyla yapılan analiz anahtar hassasiyet analizi olarak tanımlanmaktadır. Anahtara hassas olarak bağımlı sistemler kaotik şifreleme sistemleridir. Anahtar hassasiyeti pikseller karşılaştırılarak analiz edilmektedir. Analizde resmin şifrelenmiş halinin piksel karşılaştırması ve NPCR oranıyla anahtar değerindeki değişiklikler incelenmektedir. Analizin beklentisi, meydana gelen değişikliklerin kötü niyetli saldırılara karşı güvenli şifrelemeyi gerçekleştirebilmesidir.

2.1.6. Zaman Karmaşıklığı Analizi

Şifrelenmiş resmin şifreleme ve şifre çözme süresi zaman karmaşıklığı analizindeki zaman miktarıyla ifade edilmektedir. Analiz sonuçları farklı faktörlere (sistem konfigürasyonu, kullanılan görüntü vb.) bağlı olarak değişebilmektedir.

2.1.7. Entropi Analizi

Entropi analizi, resmin şifreli halinin karmaşıklığının analiz edilebilmesini sağlamaktadır. Karmaşıklık şifrelemenin kaliteli olduğunu göstermektedir. Resmin şifreli verileri ne kadar karmaşıkça görüntü o kadar iyi şifrelenmiş demektir. Bu analiz sonucundaki beklenti entropi değerinin 8'e yakın olmasıdır. Entropi değerinin 8'e yakınlığı şifrelemenin iyi bir entropi değerine sahip olduğunu göstermektedir.

2.1.8. İstatiksel Analiz

Şifreleme sistemlerinde yaygın olarak kullanılan analiz yöntemi istatistiksel analizdir. İstatistiksel analiz resmin aslıyla şifreli hali arasındaki ilişkiyi belirler.

Rastgelelik: Madeni paraıyla yapılan birbirinden bağımsız atışlar sonucunda her atışta 0 ya da 1 üretilme olasılığı $\frac{1}{2}$ 'dir. Üretilen 0 ile 1 değerleri rastgele dağıtılacağından madeni para rastgelelik için örnek olarak verilebilir. Bu çalışmada rastgeleliğin testi için NIST Test Suite tarafından geliştirilmiş aşağıdaki 15 test (NIST, 2010) kullanılmıştır.

1. Frekans Testi

Frekans testi, dizi içindeki 0 ve 1'lerin oranını test eder. Amaç 0 ve 1'lerin sayısının rastgele dizi için beklenen şekilde yaklaşık olarak aynı olup olmadığını gözlemlemektir. Testin beklentisi dizideki 0 ve 1'lerin sayısının yaklaşık olarak aynı olmasıdır.

2. Blok İçi Frekans Testi

Rastgelelikte M-bit bloğundakilerin frekansının yaklaşık olarak M/2 olması beklenmektedir. Beklenildiği şekilde

frekansın yaklaşık olarak M/2 olup olmadığını tespit etmek bu testin amacıdır.

3. Koşu Testi

Dizideki toplam çalışma sayısına odaklanan test koşu testi olarak tanımlanmaktadır. k uzunluğundaki bir dizi k tane özdeş bittin oluşmaktadır. Bu testin amacı, uzunlukları değişiklik gösterebilen 0 ve 1'lerin rastgele dizi için beklendiği gibi mi olduğunu tespit etmektir. Ayrıca, 0 ve 1'ler arasındaki salınının hızlı ya da yavaş olduğu da tespit edilebilmektedir.

4. Bir Bloktaki En Uzun Süreli Testler

Testi gerçekleştirilen dizideki en uzun koşunun uzunluğunun, rastgele dizide beklenen en uzun koşunun uzunluğuyla tutarlı olup olmadığını tespit edilebilmesi amacıyla bu test yapılmaktadır.

5. İkili Matris Sıra Testi

İkili matris sıra testi, dizinin ayrık alt matrislerinin sıralanmasına odaklanır. Bu test, asıl diziyiyle sabit uzunluktaki alt dizileri arasındaki doğrusal bağımlılığı kontrol etmek amacıyla kullanılmaktadır.

6. Ayrık Fourier Dönüşümü Testi

Ayrık fourier dönüşümü testi, dizinin dönüşümdeki tepe yüksekliklerine odaklanır. Amaç test edilen dizideki rastgelelikte meydana gelen sapmaları gösterecek tekrarlayan ve birbirine yakın modelleri belirlemektir. Modelleri belirlemekteki amaçsa, eşik olarak %95'i aşan tepe noktalarının sayısı %5'ten farklı mı bunu gözlemlemektir.

7. Örtüşmeyen Şablon Eşleştirme Testi

Önceden tespit edilmiş dizilerin oluşum sayısına odaklanan testler örtüşmeyen şablon eşleştirme testleri olarak adlandırılmaktadır. Örtüşmeyen şablon eşleştirme testinin amacı periyodik olmayan modellerin fazla tekrarla üreten üreticileri belirlemektir. M-bit penceresi kullanan bu testte model bulunamazsa pencere bir bit konumuna kaymaktadır. Test sonucunda model bulunursa pencere bulunan modelden sonraki bite sıfırlanarak arama devam etmektedir.

8. Örtüşen Şablon Eşleştirme Testi

Önceden tespit edilmiş dizilerin oluşum sayısına odaklanan testler örtüşen şablon eşleştirme testleri olarak adlandırılmaktadır. M-bit penceresi kullanan bu testte model bulunamazsa pencere bir bit konumuna kaymaktadır. Test sonucunda model bulunursa aramaya devam etmeden önce pencere yalnızca bir bit kaymaktadır.

9. Maurer'in Evrensel İstatistik Testi

Evrensel istatistik testi eşleşen desenler arasındaki bit sayısına odaklanmaktadır. Bu test, bilgi kaybı olmadan dizi sıkıştırılabilir mi bunu belirlemeyi amaçlamaktadır. Eğer dizi sıkıştırılabilirse kabul edilen tez dizinin rastgele olmadığıdır.

10. Doğrusal Karmaşıklık Testi

Doğrusal karmaşıklık testi LFSR (Linear-feedback shift register) uzunluğuna odaklanmaktadır. Bu test, dizinin karmaşıklığını belirleyerek rastgele olarak kabul edilip edilmeyeceğini tespit etmeyi amaçlamaktadır. Rastgele dizilerde LFSR'nin uzunluğu daha fazla olmaktadır.

11. Seri Test

Seri testi dizi boyunca örtüşen m-bit modellerinin frekanslarına odaklanmaktadır. Bu test, 2m m-bit örtüşen modellerin oluşum sayısı rastgele diziler için beklenen oluşum sayısı ile yaklaşık olarak aynı mı bunu tespit etmeyi amaçlamaktadır. Diziler rastgeleyle tekdüzedir.

12. Yaklaşık Entropi Testi

Yaklaşık entropi testi dizi boyunca örtüşen m-bit modellerinin frekanslarına odaklanmaktadır. Bu test, m ve m+1 gibi iki ardışık uzunlukta örtüşen blokların sıklığını, rastgele dizi için beklenen sıklık sonucuyla karşılaştırmayı amaçlamaktadır.

13. Kümülatif Toplamlar Testi

Dizideki hanelerin kümülatif toplamı tarafından tanımlanan rastgele yürüyüşün maksimum sapmasına odaklanan testler kümülatif toplamlar testi olarak tanımlanmaktadır. Bu test, dizide meydana gelen kısmi dizilerin kümülatif toplamın, rastgele diziler için beklenen davranışına göre büyüklük ya da küçüklüğünü tespit etmeyi amaçlamaktadır. Rastgele yürüyüş bu kümülatif toplamdır dolayısıyla test için beklenen sonuç yürüyüşün sifira yakın olmasıdır.

14. Rastgele Geziler Testi

Kümülatif toplam rastgele yürüyüşlerinde döngü sayısına odaklanan testler rastgele geziler testi olarak adlandırılmaktadır. Rastgele yürüyüş döngüsü, başlangıç noktasından başlayarak orijine geri dönmektedir. Bu dönüşte rastgele birim uzunluklar alınmaktadır. Rastgele geziler testi, bir döngü içinde gerçekleşen durumların sayısı rastgele dizi için beklenen durumların sayısından farklı mı bunu tespit etmeyi amaçlamaktadır.

15. Rastgele Geziler Varyant Testi

Kümülatif toplam rastgele yürüyüşlerinde gerçekleşen durumların toplam sayısına odaklanan testler rastgele geziler varyant testleri olarak adlandırılmaktadır. Bu test, rastgele yürüyüşteki beklenen durum sayılarından sapma olup olmadığını tespit etmeyi amaçlamaktadır.

2.2 Metodoloji

Bu çalışmada kullanılan ve önerilen şifreleme yöntemi bitxor yapısıyla oluşturulmuştur. Aşağıdaki denklemler kullanılarak 2 anahtar üretilmiştir.

$$a = 3.991461146114611;$$

$$key1 = key1 * a * (1 - key1);$$

$$b = 3.991461086108141;$$

$$key2 = key2 * b * (1 - key2);$$

Üretilen bu iki anahtar birbirleriyle ve 10^{16} ile çarpıldıktan sonra modu alınmış bu denklemlerden çıkan sonuçlar xorlanarak şifreleme yapılmıştır.

Algoritma 1'de görüntülerde kaotik şifre üretmeye yönelik algoritma tanımlanmıştır.


ALGORİTMA 1: GÖRÜNTÜLERDE KAOTİK ŞİFRE ÜRETMEK İÇİN ALGORİTMA

Girdi: a, b, key1, key2

Çıktı: işlem sonuçlarının modunun alınması

- 1 **keygenerate** ← anahtar üretmek için kullanılan keygenerate fonksiyonu
- 2 **Değişkenlerin başlatılması:** a ve b değişkenlerine sayı ata
- 3 **İşlemler:** key1'i a ve 1-key1 ile çarp, key2'yi b ve 1-key2 ile çarp
- 4 **Çıktı değerleri:** 10^{16} ile key1 ve key2'yi çarpıp 256'ya göre modunu al

Şekil 1'de kaotik şifre üretmeye yönelik akış diyagramı gösterilmiştir.



Şekil 1: Şifre Üretme Akış Diyagramı

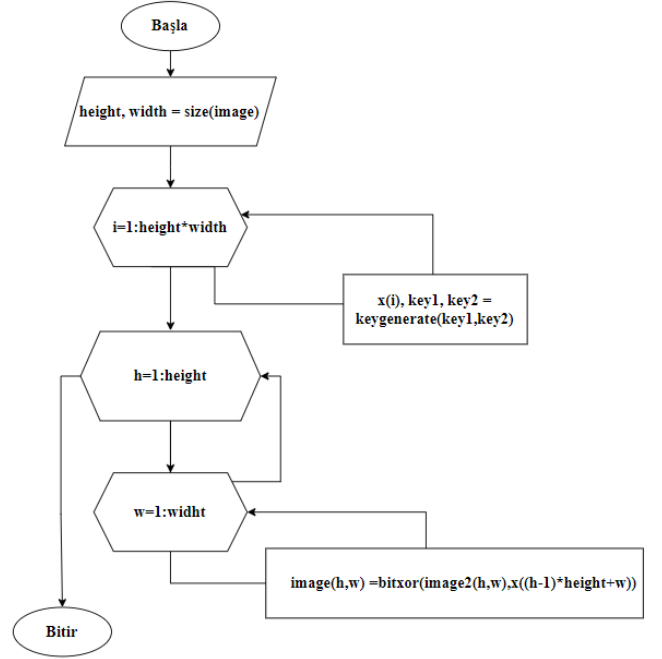
Algoritma 2'de görüntülerde kaotik şifre üretildikten sonra şifrelemeyi oluşturmak için algoritma tanımlanmıştır.

ALGORİTMA 2: KAOTİK ŞİFRELEMİYİ OLUŞTURMAK İÇİN ALGORİTMA

Girdi: image, key1, key2

Çıktı: modu alınmış denklemlerden çıkan sonuçların xorlanması


- 1 *image dosyası ← başlangıçta seçilen resmin bulunduğu dosya*
- 2 *Değişkenlerin başlatılması: height ve width değişkenlerine image'in boyutunu ata*
- 3 *for (i=1:height*width) // height ve width değerlerini çarparak l'e ata for döngüsünü başlat*
- 4 *işlemler ← key1 ve key2 kullanılarak keygenerate fonksiyonuyla üretilen anahtar x(i), key1, key2 değişkenlerine ata*
- 5 *bir sonraki i değişkenine atla*
- 6 **End**
- 7 *for(h=1:height) // height değerini h değişkenine ata*
- 8 *for (w=1:width) // width değerini w değişkenine ata*
- 9 *işlemler ← image(h,w), x((h-1)*height+w)) işleminden çıkan sonucu xorla ve image(h,w)'ye ata*
- 10 *bir sonraki w değişkenine atla*
- 11 **end**
- 12 *bir sonraki h değişkenine atla*
- 13 **end**



Şekil 2: Kaotik Şifre Oluşturma Akış Diyagramı



3. Araştırma Sonuçları ve Tartışma

Bu çalışmada görüntü şifreleme yöntemlerinin analiz ve test çıktılarını incelemek için MATLAB uygulaması kullanılmıştır. Çalışmada kullanılan 0.50000001 ve 0.50000002 anahtarlarıyla kameraman resminin orijinal, şifrelenmiş ve şifresi çözülmüş görüntüsü Şekil 3, Şekil 4, ve Şekil 5'te verilmiştir.



Şekil 3: Orijinal Şekil 4: Şifrelenmiş Şekil 5: Şifre Çözülmüş

Gerçekleştirilen histogram analizi sonucunda beklendiği gibi histogram grafiğinin tekdüze bir dağılıma sahip olduğu gözlemlenmiştir. Şifrelenmiş resmin histogram analizi grafiği (Şekil 6) ile resmin aslının histogram analizi grafiği (Şekil 7) farklıdır.




Şekil 6: Orijinal Histogram

Şekil 7: Şifrelenmiş Histogram

Şekil 2'de görüntülerde kaotik şifre üretildikten sonra kaotik şifrelemeyi oluşturmak için kullanılan algoritmaya yönelik akış diyagramı gösterilmiştir.

Gerçekleştirilen korelasyon analizi sonucunda beklendiği gibi şifrelenmiş resmin analiz sonucu 0'a yakın olarak bulunmuştur. Resmin orijinal görüntüsünün korelasyon analizi sonucu 0.9846'dır. Resmin şifrelenmiş görüntüsünün korelasyon analizi sonucu 0.2806'dır. Gerçekleştirilen entropi analizi sonucunda beklendiği gibi entropi değeri 8'e yakın olarak bulunmuştur. Resmin orijinal görüntüsünün entropi analizi sonucu 7.0134'tür. Resmin şifrelenmiş görüntüsünün entropi analizi sonucu 7.9970'tir.


Şekil 8’de resmin orijinal görüntüsünün (1) ve resmin şifrelenmiş görüntüsünün (2) entropi analizi sonuçlarının grafiği verilmiştir.



Şekil 8: Entropi Analizi


Gerçekleştirilen diferansiyel saldırı analizi sonucunda beklenildiği gibi analiz sonuçları UACI oranı 0.3354, NPCR oranı 0.9962 olarak bulunmuştur. Gerçekleştirilen zaman karmaşıklığı analizi sonucunda görüntünün şifreleme süresi 0.056462, şifre çözme süresi 0.060088 olarak bulunmuştur. 1.1161 MB/s şifreleme kapasitesiyle çalışmaktadır.

Çalışmada kullanılan 0.50000001 ve 0.50000002 anahtarlarıyla Lena resminin orijinal, şifrelenmiş ve şifresi çözülmüş görüntüsü Şekil 9, Şekil 10, ve Şekil 11’de verilmiştir.



Şekil 9: Orijinal Şekil 10: Şifrelenmiş Şekil 11: Şifre Çözülmüş


Gerçekleştirilen histogram analizi sonucunda beklenildiği gibi histogram grafiğinin tekdüze bir dağılıma sahip olduğu gözlemlenmiştir. Şifrelenmiş resmin histogram analizi grafiği (Şekil 12) ile resmin aslının histogram analizi grafiği (Şekil 13) farklıdır.



Şekil 12: Orijinal Histogram Şekil 13: Şifrelenmiş Histogram

Gerçekleştirilen korelasyon analizi sonucunda beklenildiği gibi şifrelenmiş resmin analiz sonucu 0’a yakın olarak bulunmuştur. Resmin orijinal görüntüsünün korelasyon analizi sonucu 0.9856’dır. Resmin şifrelenmiş görüntüsünün korelasyon analizi sonucu 0.2874’tür. Gerçekleştirilen entropi analizi sonucunda beklenildiği gibi entropi değeri 8’e yakın olarak bulunmuştur. Resmin orijinal görüntüsünün entropi analizi sonucu 7.4429’dur. Resmin şifrelenmiş görüntüsünün entropi analizi sonucu 7.9971’dir.


Şekil 14’te resmin orijinal görüntüsünün (1) ve resmin şifrelenmiş görüntüsünün (2) entropi analizi sonuçlarının grafiği verilmiştir.



Şekil 14: Entropi Analizi


Gerçekleştirilen diferansiyel saldırı analizi sonucunda beklenildiği gibi analiz sonuçları UACI oranı 0.3354, NPCR oranı 0.9962 olarak bulunmuştur. Gerçekleştirilen zaman karmaşıklığı analizi sonucunda görüntünün şifreleme süresi 0.056903, şifre çözme süresi 0.058524 olarak bulunmuştur.

Çalışmada kullanılan 0.50000001 ve 0.50000002 anahtarlarıyla uçak resminin orijinal, şifrelenmiş ve şifresi çözülmüş görüntüsü Şekil 15, Şekil 16, ve Şekil 17’de verilmiştir.



Şekil 15: Orijinal Şekil 16: Şifrelenmiş Şekil 17: Şifre Çözülmüş


Gerçekleştirilen histogram analizi sonucunda beklenildiği gibi histogram grafiğinin tekdüze bir dağılıma sahip olduğu gözlemlenmiştir. Şifrelenmiş resmin histogram analizi grafiği (Şekil 18) ile resmin aslının histogram analizi grafiği (Şekil 19) farklıdır.



Şekil 18: Orijinal Histogram Şekil 19: Şifrelenmiş Histogram

Gerçekleştirilen korelasyon analizi sonucunda beklenildiği gibi şifrelenmiş resmin analiz sonucu 0’a yakın olarak bulunmuştur. Resmin orijinal görüntüsünün korelasyon analizi sonucu 0.9910’dur. Resmin şifrelenmiş görüntüsünün korelasyon analizi sonucu 0.2892’dir. Gerçekleştirilen entropi analizi sonucunda beklenildiği gibi entropi değeri 8’e yakın olarak bulunmuştur. Resmin orijinal görüntüsünün entropi analizi sonucu 6.4523’tür. Resmin şifrelenmiş görüntüsünün entropi analizi sonucu 7.9970’tir.

Şekil 20’de resmin orijinal görüntüsünün (1) ve resmin şifrelenmiş görüntüsünün (2) entropi analizi sonuçlarının grafiği verilmiştir.



Şekil 20: Entropi Analizi

Gerçekleştirilen diferansiyel saldırı analizi sonucunda beklenildiği gibi analiz sonuçları UACI oranı 0.3333, NPCR oranı 0.9960 olarak bulunmuştur. Gerçekleştirilen zaman karmaşıklığı analizi sonucunda görüntünün şifreleme süresi 0.058946, şifre çözme süresi 0.063232 olarak bulunmuştur.

Gerçekleştirilen anahtar uzay analizi sonucu;

$$\begin{array}{lll} \log_2(10^{16}) & \log_2(10^{28}) & \log_2(10^{56}) \\ = 53.1508 & = 93.0140 & = 186.0280 \end{array}$$

İstatiksel analizlere yönelik test sonuçları Tablo 2'de verilmiştir.

Tablo 2. P Değerleri

İstatiksel Testler	Kameraman P Değeri	Lena P Değeri	Uçak P Değeri
Frequency	0.350485	0.066882	0.066882
BlockFrequency	0.213309	0.000439	0.002043
CumulativeSums	0.534146	0.017912	0.122325
Runs	0.534146	0.035174	0.008879
LongestRun	0.534146	0.066882	0.066882
Rank	0.911413	0.017912	0.122325
FFT	0.213309	0.035174	0.008879
OverlappingTemplate	0.213309	0.035174	0.122325
Universal	0.000000	0.000000	0.000000
ApproximateEntropy	0.911413	0.000199	0.122325
Serial	0.739918	0.066882	0.017912
LinearComplexity	0.017912	0.017912	0.122325

4. Sonuç

Verilerin güvenliği kapsamında görüntü şifreleme üzerine yapılan bu çalışmada kullanılan veri kaynağı görüntü olarak seçilmiştir. Görüntü şifreleme başarı analizleri ve istatiksel analizlere yönelik testler tanımlanmış ve uygulama üzerinden analizler gerçekleştirilmiştir. Tanımlanan analiz ve testler doğrultusunda gerçekleştirilen histogram, korelasyon, diferansiyel saldırı, anahtar uzay, anahtar hassasiyet, zaman karmaşıklığı, entropi başarı analizleri ve istatiksel analizlere yönelik frekans, blok içi frekans, koşu, bir bloktaki en uzun süreli, ikili matris sıra, ayrık fourier dönüşümü, örtüşmeyen şablon eşleştirme, örtüşen şablon eşleştirme, Maurer'in evrensel istatistik, doğrusal karmaşıklık, seri, yaklaşık entropi, kümülatif toplamlar, rastgele geziler, rastgele geziler varyant testlerinin sonuçları karşılaştırılmıştır. Görüntü şifrelemede kullanılan bu

yöntemlerin çıktısı olarak başarılı sonuç ve performansları verdiği gözlemlenmiştir.

5. Teşekkür

Çalışma boyunca analizlerin sonuçlarını değerlendirerek makale ve tez yorumlarıyla yardımcı olmasından ötürü Mustafa Cem Kasapbaşı'na teşekkürlerimi sunarım.

Kaynakça

- Al-Maadeed, S., Al-Ali, A., & Abdalla, T. (2012). A New Chaos-Based Image-Encryption and Compression Algorithm. *Hindawi Publishing Corporation Journal of Electrical and Computer Engineering*, 1-11.
- Atalay, N. S., Doğan, Ş., Tuncer, T., & Akbal, E. (2019). İmge Şifreleme Yöntem ve Algoritmaları. *DÜMF Mühendislik Dergisi*, 815-831.
- Ceyhan, M., & Yolaçan, E. N. (2021). Görüntü Dosyalarının Şifrelenerek Güvenli Şekilde Saklanması. *ESOGÜ Mühendislik Mimarlık Fakültesi Dergisi*, 28-42.
- Çavuşoğlu, Ü. (2016). Kaos Tabanlı Hibrit Simetrik ve Asimetrik Şifreleme Algoritmaları Tasarımı ve Uygulaması. *Sakarya: Sakarya Üniversitesi Fen Bilimleri Enstitüsü*.
- ELMACI, D., & CATAK, N. B. (2019). Higher Dimensional Chaotic Linear Transformations of Colored Image Encryptions. *Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi*.
- Fadhel, S., Shafry, M., & Farook, O. (2017). Chaos Image Encryption Methods: A Survey Study. *Bulletin of Electrical Engineering and Informatics*, 99-104.
- Guodong, Y. (2015). Design and Analysis of Some New Chaotic Image Encryption Schemes. *Hong Kong: City University of Hong Kong*.
- Hartman, S. (2005). *Chaos Theory and the Mandelbrot Set. Muncie, Indiana: Ball State University*.
- Hua, Z., Zhou, Y., & Huang, H. (2018). Cosine-transform-based chaotic system for image encryption. *Web of Science*.
- Keleş, C. (2012). Kaotik Haritalar Kullanarak Görüntü Şifreleme. *Trabzon: Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü*.
- Li, C., Lin, D., Feng, B., Lü, J., & Hao, F. (2018). Cryptanalysis of a Chaotic Image Encryption Algorithm Based on Information Entropy. *IEEE Access*, 2-9.
- Muhammad, Z. M., & Özkaynak, F. (2017). Security Problems of Chaotic Image Encryption Algorithms Based on Cryptanalysis Driven Design Technique. *IEEE Access*.
- NIST. (2010). A Statistical Test Suite for Cryptographic Applications. *National Institute of Standards and Technology*, 23-87.
- Omoruyi, O., Okereke, C., Okokpujie, K., Noma-Osaghae, E., Okoyeigbo, O., & John, S. (2019). Evaluation of the quality of an image encryption scheme. *Telkomnika*, 2968-2974.
- Peker, M. (2009). Görüntü İşleme Tekniği Kullanılarak Gerçek Zamanlı Hareketli Görüntü Tanıma. *Sakarya: Sakarya Üniversitesi Fen Bilimleri Enstitüsü*.
- Sakal, H., & Yıldırım, M. (2016). Görüntü Şifreleme İçin Scan Paternlerini Kullanan Hibrit Bir Yöntem. *Selçuk-Teknik Dergisi*, 264-283.
- Solak, S., & Altınışık, U. (2018). Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 56-65.



Dynamic Traffic Signal Split Control Method at Pedestrian Crossings

Serap Ergün^{1*}

^{1*} Isparta University of Applied Sciences, Faculty of Technology, Department of Computer Engineering, Isparta, Turkey, (ORCID: 0000-0003-2504-5101), serapbakioglu@isparta.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1216804)

ATIF/REFERENCE: Ergün, S. (2021). Dynamic Traffic Signal Split Control Method at Pedestrian Crossings. *European Journal of Science and Technology*, (44), 21-26.

Abstract

In order to facilitate and guarantee the safety of vehicular traffic on roadways, traffic control is crucial. Currently, there is a lot of study on how to effectively alter the control parameters of traffic lights for the aim of facilitating road traffic, but the observation targets of such research are restricted to vehicles. Traffic congestion in urban areas is a severe issue. However, the interference between automobiles and pedestrians creates the actual traffic, making pedestrians a vital aspect to take into account. In this article, we suggest a strategy for parameter-based traffic signal split control that will increase pedestrian traffic by taking both vehicle and pedestrian traffic into account.

Keywords: Traffic signal control, pedestrian, SUMO, split control method.

Yaya Geçitlerinde Dinamik Trafik Sinyali Bölünmüş Kontrol Yöntemi

Öz

Karayollarında araç trafiğinin güvenliğini sağlamak ve kolaylaştırmak için trafik kontrolü çok önemlidir. Karayolu trafiğini kolaylaştırmak amacıyla trafik ışıklarının kontrol parametrelerinin etkin bir şekilde nasıl değiştirilebileceğine dair birçok çalışma mevcuttur, ancak bu tür araştırmaların gözlem hedeflerinin temelini araçlar oluşturmaktadır. Kentsel alanlarda trafik sıkışıklığı ciddi bir sorun olmakla birlikte, otomobiller ve yayalar arasındaki müdahale gerçek trafiği oluşturarak yayaların da dikkate alınmasını gerektiren hayati bir unsur haline gelir. Bu çalışmada, hem araç hem de yaya trafiğini hesaba katarak yaya trafiğini artıracak parametre tabanlı trafik sinyali ayırım kontrolü için bir strateji önerilmiştir.

Anahtar Kelimeler: Trafik sinyal kontrolü, yaya, SUMO, bölünmüş kontrol yöntemi.

* Corresponding Author: serapbakioglu@isparta.edu.tr

1. Introduction

There is a method called fixed period control, which operates by selecting parameters set in advance. It has characteristics. A centralized type of control is the traffic control center consolidates sensor information and calculates area parameters based on that information. However, since this method aims to control the entire area, there remains the issue of responsiveness to dynamic and sudden changes in traffic flow at individual intersections (Alegre et al., 2021; Tomar et al., 2022).

On the other hand, a method has been proposed in which signal control is autonomously decentralized so that it is possible to quickly respond to changes in the conditions of individual intersections (Malena et al., 2022; Tomar et al., 2022). This is a system that changes traffic signal control parameters, and includes optimization of traffic signal control using vibration synchronization (Wang et al., 2021) and traffic signal control using multi-agent reinforcement learning.

A traffic signal control method with higher responsiveness is proposed by using autonomous decentralized traffic signal control in which each traffic signal autonomously determines its control parameters without going through the control center (Qu et al., 2022) In this control method, a control agent is assigned to each intersection, and each agent autonomously controls traffic signals. In addition, after solving the problem that it is difficult to respond quickly to the traffic conditions at individual intersections, the system is developed in a complex road environment assuming real space. It is proposed to apply the method at low cost.

On the other hand, in the method of controlling the traffic signal parameters to alleviate traffic congestion, it is important to consider pedestrians as well as vehicles (Han et al., 2022; Akyol et al., 2019).

An intersection is formed by a roadway and a sidewalk, and there is pedestrian traffic and vehicle traffic, and depending on the situation, the traffic flow changes due to interference (Sun et al., 2022).

In order to realize the application of control in a real environment, the control aimed only at smoothing vehicle traffic flow will increase the waiting time of pedestrians, and there will be situations that are not optimal for pedestrians. Pedestrian information is a factor that cannot be ignored (Artal-Villa and Bazzan, 2021).

In this study, based on the split control method proposed by Qu et al. (Qu et al., 2022), which achieved high responsiveness through autonomous decentralization, we proposed a traffic signal control method that considers pedestrian information in addition to vehicle information. We aim to smooth pedestrian traffic flow by improving the method.

The control parameters of traffic signals are appropriately manipulated according to traffic conditions to facilitate smooth traffic flow in this study. On the other hand, some studies have attempted to improve this by controlling the parameters of traffic signals, and have achieved certain results. Therefore, it is an important issue in traffic signal control to appropriately change the control parameters in response to such changes.

2. Traffic Signal Control

Traffic signal control aims to control the parameters that switch the “presentation” and to smooth the traffic flow around the intersection or in the traffic network which represents right of way (Trächtler, 2022).

The main parameters (Han et al., 2022) that control the appearance are the cycle length (the time it takes for the appearance to cycle through blue, yellow, and red, and then turn to blue again), the split (the ratio of green time for each appearance within the intersection), and the offset (cycle start time lag between intersections) are used.

Based on a given cycle length, split control sets the percentage of green time to be allocated in consideration of excessive traffic volume for each phase, improving the traffic flow at intersections in the cycle.

In offset control, the distance between adjacent intersections and traffic conditions are taken into consideration, and the cycle start time is staggered in order to smooth traffic flow between intersections.

In this study, among the three parameter controls mentioned above, we focused on and examined the method of controlling the split value.

3. Proposal method

The traffic signal control method proposed in this research optimizes the entire network by determining the control parameters of each traffic signal by means of autonomous agents placed at individual intersections.

Each agent is independent for the whole network and uses only the traffic information about the intersections that it manages to autonomously control the traffic lights. In this research, we focus on the split as a traffic light control parameter.

Each agent performs split control at the intersection they are in charge of. The update formula for split control is based on the spring model (Qu et al., 2022).

An agent placed at each intersection incorporates the traffic volume of vehicles and pedestrians at the intersection it manages into the spring balance equation, and calculates and controls the split for the next cycle just before the end of one cycle. reflected as a parameter.

By repeating this process every cycle, control is performed over the entire simulation time.

In addition, each agent has information necessary for its own control, such as various information held by its own intersection (cycle length, split, current and corresponding direction, lane information) and traffic information observed by sensors number of vehicles, number of pedestrians) can be acquired.

3.1. Traffic

In this method, the split calculation is performed by measuring the traffic volume Q at the intersection. Here, both the vehicle traffic volume and the pedestrian traffic volume are considered in the traffic volume, so each is defined separately.

For the traffic volume of vehicles, in addition to the amount of vehicles flowing into the intersection, the number of remaining

vehicles to be sorted is taken into consideration. In other words, the traffic volume $Q_{(n,v)}$ of vehicles on the roadside is expressed as follows and it represents the lane average of the number of vehicles entering the roadway.

$$Q_{(n,v)} = Q_{(n,in)} + \alpha^{Q_{(n,res)}} \quad (1)$$

The $Q_{(n,in)}$ term on the right side of Equation 1 is an exponential function with α coefficient n as the base, and by setting the condition of 1 to satisfy the condition of 1, it takes a larger value as the number of remaining vehicles at the intersection increases.

The first term on the right side of Equation 1, $Q_{(n,in)}$, represents the lane average of the number of inflowing vehicles on road n , and is the value obtained by dividing the total number of inflowing vehicles on road $n_{(v,in)}$ by n and the number of lanes on road n by n_{lane} .

The second term on the right side of Equation 1 is an exponential function with the coefficient α as the base. By setting the condition $\alpha > 1$, the larger the number of remaining vehicles at the intersection, the larger the value.

For the exponential jump, $Q_{(in,res)}$, the value obtained by dividing the total number of remaining vehicles $n_{(v,res)}$ on road n by the number of lanes is used.

For pedestrian traffic volume, we consider the number of pedestrians crossing the crosswalk at the intersection. Specifically, we adopt the number of pedestrians on the crosswalk $Q_{(m,cross)}$ observed at a specific timing in the scenario where the crosswalk nail is passable. Here, we assume that there are no pedestrians who cannot cross the crosswalk even in congested pedestrian traffic conditions, and do not introduce the concept of stray vehicles. Pedestrian traffic is counted simply as the number of people passing through the crosswalk.

3.2. Split calculation

Figure 1 shows a schematic diagram of the spring model at a two-indication intersection used in this method. At the two-indication intersection, a spring model in which two springs are connected is assumed as in the case of the number of indications. Let SPLIT1 and SPLIT2 be the split values of the first and second presentations.




Figure 1. Schematic of the split model at the intersections

In the case of Figure 1, the direction of pedestrians $A - B$ corresponds to the first phase, and the direction of $C - D$ corresponds to the second phase. As for the sidewalk, A' and B'

correspond to the first appearance, and C' and D' correspond to the second appearance. The arrows extending from the connecting part of the two springs represent the force exerted by the spring due to SPLIT1, the force exerted by the spring due to SPLIT2, and the external force, respectively. These interactions form a state of equilibrium similar to that of a physical spring.

Here, the external force on the mane is defined as the difference D between the traffic volumes in the east-west direction and the north-south direction. This traffic volume difference D is expressed using the traffic volume Q defined in Section 3.1. Specifically, when the vehicle traffic volume difference is D_v , this is the difference between the maximum east-west traffic volume $\max(Q_{(A,v)}, Q_{(B,v)})$ and the north-south maximum traffic volume $\max(Q_{(C,v)}, Q_{(D,v)})$. It is defined as the value divided by the sum. Note that $\{A, B\}$ and $\{C, D\}$ represent the roads to which the right of way is given to the first and second manifestations, respectively. The pedestrian traffic volume difference D_p is also defined in the same way.

The traffic volume difference D is defined as the force acting on the spring from the outside. It is expressed as when the constant is K :

$$X = \frac{D}{2K} \quad (2)$$

The split ratios SPLIT1 and SPLIT2 are calculated by adding and subtracting the value of the displacement X to the natural length of the spring while balancing so that the sum is kept at 1. In addition, the external force can be divided into vehicle force D_v and pedestrian force D_p calculated by the difference D .

Here, we introduce a coefficient that expresses the degree of consideration of pedestrians in control, and use the traffic volume difference D as

$$D = D_v + 1D_p \quad (3)$$

Note that when the value of the coefficient is 0, it is consistent with Ohno's control [Ohno 20], which does not consider pedestrian information at all.

4. Evaluation experiment

4.1 Experiment environment

In this experiment, a traffic simulator SUMO (Simulation of Urban MObility) is used. SUMO is open source developed by the German Aerospace Center. It is a micro-traffic simulator, and its main functions are the acceleration and speed of vehicles and pedestrians, 'driving route setting and road shape', 'traffic signal placement', and his parameter control of traffic lights. Furthermore, with a dedicated API called Traci, various information in the simulation space can be acquired in detail (Koti and Kakkasageri, 2021; Mathiane et al., 2022).

In addition, in this study, a radio wave radar, which is assumed to be used to acquire information on the roadway in the demonstration experiment, and an observation camera, which is assumed to be used to acquire information on the sidewalk, are used. Based on the settings in SUMO, information is acquired on SUMO.

The radio wave radar assumed in this study can acquire vehicle speed, vehicle position, and vehicle length as traffic information within a range of approximately 150 m from each

intersection. The observation range is the entire crosswalk at each intersection, and the number of pedestrians crossing the crosswalk at a specific timing can be obtained.

Based on the above assumptions, only this information is handled in the simulation space when conducting experiments.

4.2 Experimental setup

In this experimental environment, we used a 5x6 road network configured on SUMO to verify the effectiveness of the split control based on the spring model that considers pedestrian information, as described in Section 3. External view of the experimental environment is shown in Figure 2. The simulation period is 14400 steps, and the cycle length at each intersection is fixed at 100 steps. The basic settings of the experiment are shown in Table 1. Note that the unit of time on SUMO is step, and 1 step corresponds to 1 second in real time. Table 2 shows the various settings of vehicles and pedestrians in the simulation, and Tables 3 and 4 show the inflow patterns of vehicles and pedestrians used in the experiment.




Figure 2. Network outside view

Table 1. Experimental settings

Seeting items	Set value
Cycle length	100 steps
Simulation period	14400 steps
Comparision method	Static method
Coefficient	0 to 1 (changes in 0.1 range)
Evaluation index	Average loss

Table 2. Various settings for vehicles and pedestrians

time	Vehicle	Pedestrian
Size	4.3 m	0.215 m
Maximum speed	180 km/h	5.4 km/h
Passing priority	low	high

Table 3. Vehicle inflow pattern from each inflow route

time	East [units/h]	East [units/h]	North-South [units/h]
0~3600	1800	2100	500
0~7200	1500	2100	500
0~10800	1200	2100	500
0~14400	900	2100	500

Table 4. Pedestrian inflow pattern from each inflow route

time	East [units/h]	East [units/h]	North-South [units/h]
0~3600	500	1500	1500
0~7200	500	1500	1200
0~10800	500	1500	900
0~14400	500	1500	600

For the inflow pattern of both vehicles and pedestrians, the flow rate is changed every 3600 steps, dividing the experimental period into four. Regarding the inflow of vehicles, the main traffic flow is set to the east-west direction, and the inflow from the east direction is reduced over time. It is set perpendicular to the vehicle. In addition, in this experiment, the value of the weighting factor λ , which indicates the degree of consideration of pedestrian information, is varied in detail, and the time loss of vehicles and pedestrians at each stage is analyzed. $\lambda = 1$, and a control experiment is performed when this interval is varied by a width of 0.1. In addition, in order to evaluate the effectiveness of the proposed method in this experiment, static control with a fixed split ratio and Ohno's control [Ohno 20], which does not consider pedestrians, were used as comparison methods.

4.3 Experimental results

Figures 3 and 4 show the average time loss of pedestrians and the average time loss of vehicles in the experiment.




Figure 3. Comparison of pedestrian average loss




Figure 4. Vehicle average loss comparison

The results of control using a spring model that does not consider pedestrian information ($\lambda = 0$), control results using a

spring model that considers pedestrian information ($\alpha = 1.0$), and control results using static control (periodic) are shown. Primarily, both with and without consideration of pedestrians it can be seen that the average loss time is greatly reduced compared to static control. Also, it can be seen that control that considers pedestrian information has the effect of reducing the average lost time of pedestrians and increasing the average lost time of vehicles.

Figure 5 shows the comparison of the cumulative vehicle loss time and pedestrian cumulative loss time in the experiment. The vertical axis represents the average time loss of pedestrians. As the value of the coefficient indicating the degree of consideration of pedestrians is changed, the lost time of pedestrians decreases/increases, and conversely, the lost time of vehicles increases/decreases. It can be understood that there is a trade-off relationship.




Figure 5. Comparison of vehicle cumulative loss and pedestrian loss

4.4 Inspection

Pedestrian traffic flow in the simulation is improved by control that considered pedestrian information, and the effectiveness of the proposed method that introduced pedestrian information into control based on a spring model is demonstrated.

On the other hand, it is also confirmed that the average loss of vehicles increased in inverse proportion as the average loss of pedestrians is reduced by increasing the degree of consideration of pedestrian information. This is thought to be due to the trade-off relationship between vehicles and pedestrians in determining the split ratio in signal control.

In addition, the average loss is improved compared to static control, regardless of whether pedestrians are considered or not. This is based on the premise that the spring model, which is flexible control for changes in traffic flow, has an average loss improvement effect compared to static control, and even if this effect is distributed to vehicles and pedestrians. It is considered that it does not fall below the static control.

The experimental results showed the trade-off between the lost time of vehicles and pedestrians, but if we want to calculate the optimal value of the coefficient that expresses the degree of consideration of pedestrians, we should consider the ratio of the value of vehicles and pedestrians. It is considered necessary to do so. For example, if the average number of people in a vehicle is 2, the value of the vehicle is simply determined as twice the value of the pedestrian. However, it is generally difficult to establish

quantitative criteria for the value of vehicles and pedestrians. It is thought that it is necessary to take into consideration what kind of vehicles pass by depending on the road environment.

5. Conclusions and Future Outlooks

In this study, we proposed a traffic signal control method using a spring model that considers pedestrian information. We also confirmed that there is a trade-off between improving the traffic flow of pedestrians and vehicles.

As a future topic, when considering actual application as a signal control method, it is necessary to establish a more applicable control system that includes cycle length and offset as control parameters. It needs to be improved so that it can be applied to complex shapes existing in the environment.

In addition, we are preparing to conduct a demonstration experiment, and we would like to continue our research so that the method will be more suitable for operation in a real environment.

References

- Akyol, G., Silgu, M. A., & Celikoglu, H. B. (2019). Pedestrian-friendly traffic signal control using Eclipse SUMO. In *Proceedings of the SUMO User Conference* (pp. 101-106).
- Alegre, L. N., Ziemke, T., & Bazzan, A. L. (2021). Using reinforcement learning to control traffic signals in a real-world scenario: an approach based on linear function approximation. *IEEE Transactions on Intelligent Transportation Systems*.
- Artal-Villa, L., & Olaverri-Monreal, C. (2019, April). Vehicle-pedestrian interaction in SUMO and unity3D. In *World Conference on Information Systems and Technologies* (pp. 198-207). Springer, Cham.
- Han, G., Zheng, Q., Liao, L., Tang, P., Li, Z., & Zhu, Y. (2022). Deep Reinforcement Learning for Intersection Signal Control Considering Pedestrian Behavior. *Electronics*, 11(21), 3519.
- Koti, R. B., & Kakkasageri, M. S. (2021). Multi Agent Assisted Safety Information Dissemination Scheme for V2V Communication in VANETs: Intelligent Agent Approach. *International Journal of Intelligent Systems and Applications (IJISA)*, 13(4), 49-62.
- Malena, K., Link, C., Bußemas, L., Gausemeier, S., & Trächtler, A. (2022). Traffic Estimation and MPC-Based Traffic Light System Control in Realistic Real-Time Traffic Environments. In *International Conference on Vehicle Technology and Intelligent Transport Systems, International Conference on Smart Cities and Green ICT Systems* (pp. 232-254). Springer, Cham.
- Mathiane, M., Tu, C., Owola, P. A., & Naweji, M. C. (2022). A SUMO Simulation Study on VANET-Based Adaptive Traffic Light Control System. In *Advances in Electrical and Computer Technologies* (pp. 225-237). Springer, Singapore.
- Qu, D., Li, H., Liu, H., Wang, S., & Zhang, K. (2022). Crosswalk safety warning system for pedestrians to cross the street intelligently. *Sustainability*, 14(16), 10223.
- Sun, Q., He, C., Wang, Y., Liu, H., Ma, F., & Wei, X. (2022). Reducing violation behaviors of pedestrians considering group interests of travelers at signalized crosswalk. *Physica A: Statistical Mechanics and its Applications*, 594, 127023.
- Tomar, I., Sreedevi, I., & Pandey, N. (2022). State-of-Art Review of Traffic Light Synchronization for Intelligent Vehicles:

- Current Status, Challenges, and Emerging Trends. *Electronics*, 11(3), 465.
- Trächtler, A. (2022). Traffic Estimation and MPC-Based Traffic Light System Control in Realistic Real-Time Traffic Environments. In *Smart Cities, Green Technologies, and Intelligent Transport Systems: 10th International Conference, SMARTGREENS 2021, and 7th International Conference, VEHITS 2021, Virtual Event, April 28-30, 2021, Revised Selected Papers* (p. 232). Springer Nature.
- Wang, T., Cao, J., & Hussain, A. (2021). Adaptive Traffic Signal Control for large-scale scenario with Cooperative Group-based Multi-agent reinforcement learning. *Transportation research part C: emerging technologies*, 125, 103046.



Karşıt Tabanlı Öğrenme İle Geliştirilmiş Yapay Denizanası Arama Algoritması

Gülnur Yıldızdan^{1*}

^{1*} Selçuk Üniversitesi, Kulu Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Konya, Türkiye (ORCID: 0000-0001-6252-9012), gavsar@selcuk.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1219071)

ATIF/REFERENCE: Yıldızdan, G. (2022). Karşıt Tabanlı Öğrenme İle Geliştirilmiş Yapay Denizanası Arama Algoritması. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 27-34.

Öz

Bu çalışmada denizanalarının okyanustaki yiyecek arama davranışının modellenmesi ile oluşturulan yapay denizanası arama algoritmasının (JS) performansını geliştirmek amacıyla yeni geliştirilmiş bir algoritma önerilmiştir. Bunun için JS'ye karşıt tabanlı öğrenme yaklaşımı dahil edilerek popülasyondaki bireylerin arama uzayına daha doğru şekilde dağıtılması sağlanmıştır. Geliştirilmiş algoritma(KJS), standart kıyaslama fonksiyonları üzerinde 10,30,50,100,500 ve 1000 boyut için test edilmiştir. Elde edilen sonuçlar JS ve literatürdeki algoritmalarla karşılaştırılmış, istatistik testler ile yorumlanmıştır. Sonuçlar değerlendirildiğinde önerilen KJS algoritmasının başarılı ve kabul edilebilir sonuçlar ürettiği tespit edilmiştir.

Anahtar Kelimeler: Karşıt tabanlı öğrenme, Sürekli optimizasyon, Yapay denizanası arama algoritması.

Artificial Jellyfish Search Algorithm Developed With Opposition-Based Learning

Abstract

In this study, a newly developed algorithm was proposed to improve the performance of the artificial jellyfish search algorithm (JS), which is created by modeling the foraging behavior of jellyfish in the ocean. For this, an oppositional-based learning approach was included in JS to provide a more accurate distribution of individuals in the population to the search space. The developed algorithm (KJS) was tested on standard benchmark functions for 10,30,50,100,500 and 1000 dimensions. The obtained results were compared with JS and algorithms in the literature and interpreted with statistical tests. When the results were evaluated, it was determined that the proposed KJS algorithm produced successful and acceptable results.

Keywords: Opposition-based learning, Continuous optimization, Artificial jellyfish search algorithm.

* Sorumlu Yazar: Selçuk Üniversitesi, Kulu Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Konya, Türkiye (ORCID: 0000-0001-6252-9012), gavsar@selcuk.edu.tr

1. Giriş

Günlük hayatta karşılaştığımız problemleri içgüdüsel olarak en ideal şekilde çözümlenmeye yöneliriz. Bu davranış, kısıtlı kaynakları en iyi şekilde kullanma çabası olarak ifade edilebilir. Farklı canlı türlerinde de rastlanan bu davranış, bir amacı gerçekleştirmek için belli sınır ve kısıtlar içinde en ideal çözümün bulunmasıdır ve optimizasyon olarak isimlendirilir. Mühendislik, ekonomi, ticaret, endüstri vb. bir çok alanda karşılaştığımız optimizasyon problemlerinde hedef, amaç fonksiyonunu minimum ya da maksimum yapacak karar değişkenlerinin tespitidir. Eşitlik ve eşitsizlik kısıtlaması içeren bir minimizasyon problemi Denklem 1’de verilmiştir. Denklemde f amaç fonksiyonu, p eşitsizlik kısıtlayıcı sayısı, q eşitlik kısıtlayıcı sayısı, n karar değişkeni sayısı, Lb ve Ub sırasıyla değişkenin alt ve üst sınır değerlerini ifade eder.

Minimize: $f(x)$

Kısıtlar: $g_i(x_1, x_2, \dots, x_n) \leq 0 \quad i = 1, 2, \dots, p$

$h_i(x_1, x_2, \dots, x_n) = 0 \quad i = 1, 2, \dots, q$

$Lb_i \leq x_i \leq Ub_i \quad i = 1, 2, \dots, n \quad (1)$

Bu problemlerin çözümüne ve bilgisayar ortamında modellenmesine duyulan ihtiyaç birçok optimizasyon yönteminin önerilmesine sebep olmuştur. Bunlardan biri de son dönemde sayısı hızla artan metasezgisel algoritmalarıdır. Metasezgisel algoritmalar, doğal fenomenlerden esinlenen, kesin çözümü garanti edemeyen ancak kesin çözüm yakınındaki bir çözüme hızlı ve kolay şekilde ulaşmayı sağlayan algoritmalarıdır. Yapay Denizanası Arama Algoritması (JS) da son dönemde önerilmiş yeni metasezgisel algoritmalarından biridir (Chou & Truong, 2021). Algoritma, denizanaların okyanustaki arama davranışlarının modellenmesi ile oluşturulmuştur. Denizanalarının okyanus akıntılarında ya da sürüye bağlı olarak yaptığı iki hareket söz konusudur. Bu hareketlerin modellenmesi ile sırasıyla algoritmanın küresel ve yerel arama bölümleri oluşturulmuştur. Bu hareketler arasındaki geçiş ise zaman kontrol mekanizması sayesinde gerçekleştirilir. Algoritma literatürde, polimer değişim membranlı yakıt hücrelerinin optimizasyonu (Gouda, Kotb, & El-Fergany, 2021), güneş termoelektrik iklimlendirme sistemlerinin tahmini (Almodfer et al., 2022), birleşik ısı ve güç ekonomik dağıtımının çözümü (Ginidi, Elsayed, Shaheen, Elattar, & El-Sehiemy, 2021), güç sistemlerinde enerji tasarrufu ve tüketimin azaltılmasını sağlama (Jiang, Dao, Vu, & Ngo, 2021), frekans kısıtlı büyük ölçekli optimizasyon problemlerini çözme (Kaveh, Biabani Hamedani, Kamalinejad, & Joudaki, 2021), tıbbi görüntü bölütleme (Abdel-Basset et al., 2021), video damgalama (Dhevanandhini & Yamuna), küresel optimizasyon problemlerini çözme (Manita & Zermani, 2021; Rajpurohit & Sharma, 2022; Yıldızdan & Baykan, 2021) gibi daha birçok alanda uygulanmış ve başarılı sonuçlar elde etmiştir.

Bu çalışmada, Yapay Denizanası Arama algoritmasının (JS) yakınsama hızını artırmak için karşıt tabanlı öğrenme kavramı (Tizhoosh, 2005) ile geliştirilmiş yeni bir algoritma (KJS) önerilmiştir. Önerilen algoritma, farklı özellikte klasik kıyaslama fonksiyonları üzerinde 10,30,50,100,500 ve 1000

boyut için test edilmiştir. Sonuçlar standart algoritma ve literatürdeki diğer algoritmalarla karşılaştırılmış ve sonuçlar değerlendirilmiştir.

2. Materyal ve Metot

2.1. Yapay Denizanası Arama Algoritması (JS)

Denizanaları, hareketlerini kontrol edebilen canlılardır. Alt bölümleri bir şemsiye gibi kapanıp açılır ve böylece suyu dışarı iterek vücutlarını ileriye doğru hareket ettirebilirler. Bu özelliklerine rağmen çoğunlukla akıntılara ve gelgitlere bağlı olarak suda sürüklenirler. Denizanaları sürü oluşturabilirler ve büyük sürülere denizanası çiçeği ismi verilir. Zayıf yüzen bu canlıların akıntılara göre hareketleri denizanası çiçeklerinin korunması ve karaya oturmalarının engellenmesi için önemlidir. Denizanasının iki hareket durumu söz konusudur: sürü içinde kendi hareketi ve denizanası çiçeklenmesi için okyanus akıntısını takip eden hareketi. Bu hareketlilik, denizanalarına okyanusun her yerinde görünebilmeye kabiliyeti kazandırır. İşte denizanalarının bu arama davranışları ve hareketleri bu algoritmanın önerilmesi için motivasyon kaynağı olmuştur (Chou & Truong, 2021). JS algoritması, denizanalarının okyanus akıntılarını ya da sürüyü takip ettiği ve bu hareketler arası geçişin ‘zaman kontrol mekanizmasını’ ile gerçekleştirildiği bir algoritma olarak özetlenebilir.

2.1.1. Algoritma Adımları

- İlk olarak algoritmada popülasyon oluşturulur. JS algoritmasında çözümleri problemin arama uzayı içinde doğru bir şekilde dağıtacak daha iyi bir başlatma yolu bulmak için, tipik rastgele yöntemler yerine kaotik harita kullanılmıştır. Bu amaçla yapılan test işlemleri sonucu, Denklem 2’de verilen lojistik harita (Gandomi, Yang, Talatahari, & Alavi, 2013) formülü kullanarak başlangıç popülasyonunu oluşturmanın, erken yakınsamayı engelleyip, performansı artırdığı tespit edilmiştir (Chou & Truong, 2021). Denklemde X_0 denizanalarının başlangıç popülasyonunu oluşturmak için kullanılır. X_1 , i.denizanasının konumunun lojistik kaotik değeridir. X_0 , (0, 1) aralığında rastgele bir sayıdır. $X_0 \notin \{0.0, 0.25, 0.5, 0.75\}$ ve η değeri 4’tür.

$$X_{i+1} = \eta X_i (1 - X_i), \quad 0 \leq X_0 \leq 1 \quad (2)$$

- Popülasyon oluşturulduktan sonra, popülasyondaki en iyi uygunluk değerine sahip denizanası (X^*) belirlenir. Sonra, her denizanasının konumu okyanus akıntısına ya da sürü hareketine göre güncellenir. Okyanus akıntısına göre yeni konumun belirlenmesi (küresel arama) Denklem 3’teki gibi formülize edilir. Denklemde, r ve $r1$ çarpanı (0, 1) aralığında rastgele bir sayıyı, $\beta > 0$ dağılım katsayısını, μ popülasyondaki denizanalarının konumlarının ortalamasını ifade eder. $\beta = 3$ olarak kullanılmaktadır (Chou & Truong, 2021).

$$X_i(t+1) = X_i(t) + r * (X^* - \beta * r1 * \mu) \quad (3)$$

- Denizanalarının sürü içindeki hareketi (yerel arama), pasif hareket ve aktif hareket olmak üzere iki türdür. Pasif hareket sırasında denizanaları o anki konumları etrafında Denklem 4’e göre arama yapar, konumlarını güncellerler. Denklem (4)’de $r2$ çarpanı (0,1) aralığında rastgele bir sayı, $\gamma > 0$ denizanalarının hareket miktarı ile ilgili hareket

katsayısı, U_b ve L_b ise sırasıyla arama uzayının üst ve alt sınır değerleridir. $\gamma=0.1$ olarak kullanılmaktadır.

$$X_i(t+1) = X_i(t) + r2 * \gamma * (U_b - L_b) \quad (4)$$

Aktif hareket ise Denklem 5'teki gibi formülize edilir. Denklemde $r3$ çarpanı (0,1) aralığında rastgele bir sayı, D denizanasının hareket yönüdür. Bahsedilen hareket, daima en iyi uygunluk değerli denizanası yönündedir ve Denklem 6'da verilmiştir. Bu denklemde, j rastgele bir denizanasının indeksi, f uygunluk fonksiyonudur.

$$X_i(t+1) = X_i(t) + r3 * D \quad (5)$$

$$D = \begin{cases} X_i(t) - X_j(t), & \text{Eğer } f(X_i) < f(X_j) \\ X_j(t) - X_i(t), & \text{aksi halde} \end{cases} \quad (6)$$

- Okyanus akıntısı ve sürü içindeki hareketler arası geçiş algoritmada 'zaman kontrol mekanizması' sayesinde yapılır. Zaman kontrol fonksiyonu Denklem 7'deki gibi formülize edilir (Chou & Truong, 2021). Denklemde, t iterasyon sayısını, t_{max} maksimum iterasyon sayısını, $r4$ ise (0,1) aralığında rastgele bir sayıyı gösterir. C_0 ise sabit bir değerdir. $c(t) \geq c_0$ şartı sağlandığında denizanası okyanus akıntısına göre, aksi halde pasif ya da aktif hareket yaparak sürünün içinde hareket eder.

$$c(t) = \left| \left(1 - \frac{t}{t_{max}} \right) * (2 * r4 - 1) \right| \quad (7)$$

JS algoritmasının kaba kodu Şekil 1'de verilmiştir.

```

1. Begin
2. For i=1:Popülasyon boyutu(N) Do
3.   Denklem 7'ye göre zaman kontrol değerini c(t) hesapla
4.   If c(t) ≥ c0 then
5.     Denklem 3'e göre denizanası okyanus akıntısını takip eder
6.   Else
7.     If rand(0,1) > (1 - c(t)) then
8.       Denklem 4'e göre denizanası pasif hareket yapar
9.     Else
10.      Denklem 5'e göre denizanası aktif hareket yapar
11.   End if
12. End if
13. End For
14. End

```

Şekil 1. JS algoritmasının kaba kodu

2.2. Karşıt Tabanlı Öğrenme(OBL)

Metasezgisel algoritmalarda ilk olarak popülasyon oluşturulur. Popülasyon oluşturulurken genelde popülasyon bireyleri rastgele konumlara dağıtılır. Bir optimizasyon probleminin çözümüne iyi bir popülasyonla başlamak algoritma performansını artıracaktır. Örneğin JS algoritmasında bu amaçla popülasyon rastgele değil, kaotik harita yardımıyla oluşturulmuştur. Literatürde bu amaçla en sık kullanılan yöntem Tizhoosh tarafından 2005'de önerilmiş olan karşıt tabanlı öğrenmedir(OBL)(Tizhoosh, 2005). OBL, rastgele bir sayının karşıt konum değerinin, çözüme yeniden

ve rastgele oluşturulacak olan bir sayıdan daha yakın olduğu mantığına dayanmaktadır. Bir sayının karşıt değeriyle birlikte oluşturulan bir popülasyonun daha küçük bir arama ile çözüme yakınsayacağı düşünülür (TEMURTAŞ, Yaşar, & ÖZYÖN, 2017).

- *Karşıt sayı*: $x \in [a, b]$ olmak üzere bir gerçel sayı olsun. x 'in karşıtı Denklem 8'de verildiği gibi tanımlanır.

$$x_k = a + b - x \quad (8)$$

- *Karşıt nokta*: d -boyutlu bir uzayda $x = (x_1, x_2, \dots, x_d)$ noktasının, $x_k = (x_{k1}, x_{k2}, \dots, x_{kd})$ karşıt noktası Denklem 9'da verildiği gibi tanımlanır.

$$x_{kj} = a_j + b_j - x_j \quad (9)$$

- *Karşıt tabanlı optimizasyon*: d -boyutlu bir uzayda $x = (x_1, x_2, \dots, x_d)$ noktası bir aday çözüm, $f(x)$ bu çözümün uygunluk değeri olsun. x 'in karşıt noktasının ($x_k = (x_{k1}, x_{k2}, \dots, x_{kd})$) uygunluk değeri $f(x_k)$, $f(x)$ 'den daha iyi ise x noktası x_k olarak güncellenir. Aksi halde, x noktası korunur.

2.2. Önerilen Algoritma(KJS)

Metasezgisel algoritmalar popülasyonun oluşturulması ile başlar ve genelde popülasyon rastgele oluşturulur. Yakınsamayı hızlandırmak, yerel optimumlara takılmayı önlemek ve çözümleri arama uzayı içerisinde doğru şekilde dağıtmayı sağlamak algoritma performansına önemli ölçüde katkı sağlayacaktır. Bu çalışmada, çok sayıda metasezgisel algoritmaya daha önce uygulanmış ve algoritmaların performanslarına önemli ölçüde katkı sağladığı ispatlanmış olan OBL mantığı (Mahdavi, Rahnamayan, & Deb, 2018; Xu, Wang, Wang, Hei, & Zhao, 2014) JS algoritmasına dâhil edilmiş ve algoritma performansına olan katkısı incelenmiştir.

Önerilen algoritmada (KJS), karşıt çözümlü popülasyonunun (KÇP) oluşturulmasına ait kaba kod Şekil 2'de verilmiştir.

```

1. Mevcut P(N) popülasyonunun karşıt popülasyonu KP(N) yi oluştur.
   KPi,j = aj + bj - Pi,j
   i = 1,2, ..., N   j = 1,2, ..., d
2. Popülasyon için N adet en iyi bireyi {P ∪ KP} den seç.

```

Şekil 2. KÇP oluşturma kaba kodu

KÇP oluşturma yaklaşımı, önerilen algoritmada atlama oranı (A_o) denilen bir değere bağlı olarak evrimsel süreç içerisinde kullanılır. Böylece, algoritma mevcut popülasyona KÇP yaklaşımı uygulayarak, mevcut olan popülasyondan daha uygun olan yeni çözüm adaylarına atlamaya zorlanır. Bir atlama oranına (yani atlama olasılığına) dayanarak, JS'nin arama denklemleri ile yeni popülasyon üretildikten sonra, karşıt çözümlü popülasyon hesaplanır. Sonrasında, mevcut popülasyon ile karşıt çözümlü popülasyonun birleşiminden en iyi uygunluk değerli bireyler seçilir. Burada A_o için uygun değer belirlenmesi önemlidir. Büyük bir değer olması JS'nin arama denklemlerinin rolünü

azaltır ve algoritmanın arama sürecinin yanlış yönlendirilmesine neden olur. Bu yüzden, bu çalışmada literatürde daha önce kullanılmış olan 0.1 değeri seçilmiştir (Gupta & Deep, 2019). Bu değer, yerel optimumlardan uzaklaşmaya ve yeni optimum yön sağlamaya yardımcı olur. Bu motivasyonla oluşturulmuş olan KJS algoritmasının kaba kodu Şekil 3'te verilmiştir.

3. Araştırma Sonuçları ve Tartışma

Önerilen KJS algoritması, özellikleri Tablo 1'de verilen on iki adet standart kıyaslama fonksiyonu üzerinde 10,30,50,100,500 ve 1000 boyut için test edilmiştir. Bu fonksiyonların yedi tanesi tek modlu(U), beş tanesi çok modlu(M) yapıdadır. Algoritmalar her fonksiyon için bağımsız şekilde otuz defa çalıştırılmış ve elde edilen sonuçlara ait istatistiksel hesaplamalar (en iyi, ortanca, en kötü, ortalama ve standart sapma değerleri gibi) yapılmıştır.

```

1. Begin
2. If rand < A0 then
3.   Mevcut P(N) popülasyonunun karşıt popülasyonu KP(N) yi oluştur.
4.   Popülasyon için N adet en iyi bireyi {P ∪ KP} den seç.
5. Else
6.   For i=1:Popülasyon boyutu(N) Do
7.     Denklem 7'ye göre zaman kontrol değerini c(t) hesapla
8.     If c(t) ≥ c0 then
9.       Denklem 3'e göre denizanası okyanus akıntısını takip eder
10.    Else
11.      If rand(0,1) > (1 - c(t)) then
12.        Denklem 4'e göre denizanası pasif hareket yapar
13.      Else
14.        Denklem 5'e göre denizanası aktif hareket yapar
15.      End if
16.    End if
17.  End For
18. End
19. End

```

Şekil 3. KJS kaba kodu

Tablo 1. Klasik kıyaslama fonksiyonları

Fonksiyon	Aralık	f _{min}	Özellik
$f1(x) = \sum_{i=1}^d x_i^2$	[-100,100]	0	U
$f2(x) = \sum_{i=1}^d x_i^2 + \prod_{i=1}^d x_i $	[-10,10]	0	U
$f3(x) = \sum_{i=1}^d (\sum_{j=1}^i x_j)^2$	[-100,100]	0	U
$f4(x) = \max_i\{ x_i , 1 \leq i \leq d\}$	[-100,100]	0	U
$f5(x) = \sum_{i=1}^{d-1} [100 (x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	[-30,30]	0	U
$f6(x) = \sum_{i=1}^d ([x_i + 0.5])^2$	[-100,100]	0	U
$f7(x) = \sum_{i=1}^d i * x_i^4 + rand[0,1]$	[-1.28,1.28]	0	U
$f8 = \sum_{i=1}^d -x_i \sin(\sqrt{ x_i })$	[-500,500]	-418.9829 * d	M
$f9 = \sum_{i=1}^d [x_i^2 - 10 \cos(2\pi x_i) + 10]$	[-5.12,5.12]	0	M
$f10(x) = \sum_{i=1}^d -20 \exp\left(-0.2 \sqrt{\frac{1}{d} \sum_{i=1}^d x_i^2}\right) - \exp\left(\frac{1}{d} \sum_{i=1}^d \cos(2\pi x_i)\right) + 20 + e$	[-32,32]	0	M
$f11(x) = \frac{1}{4} \times 10^{-3} \sum_{i=1}^d x_i^2 - \prod_{i=1}^d \cos\left(\frac{x_i}{\sqrt{i}} + 1\right)$	[-600,600]	0	M
$f12(x) = \frac{\pi}{d} \left\{ 10 \sin(\pi y_1) + \sum_{i=1}^{d-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2 \right\} + \sum_{i=1}^d u(x_i, 10, 100, 4)$	[-50,50]	0	M
$y_i = \frac{x_i + 5}{4}$ $u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & \text{Eğer } x_i > a \\ k(-x_i - a)^m & \text{Eğer } x_i < -a \\ 0 & \text{diğer} \end{cases}$			

Bu test işlemleri sırasında algoritmalarda kullanılan parametre değerleri ise Tablo 2’de gösterilmiştir.

Tablo 2. Parametre değerleri

Parametre	Değer
Popülasyon boyutu (N)	50
Maksimum iterasyon sayısı	500
Yürütme(run) sayısı	30
C_0	0.5
A_0	0.1
Boyut(d)	10,30,50,100, 500,1000

Tablo 3’de standart JS ve önerilen KJS algoritmalarının d=10 için elde edilen sonuçları karşılaştırmalı olarak verilmiştir. Tablo 3 ve devamındaki diğer karşılaştırma tablolarında daha iyi olan sonuçlar kalın yazı tipi ile gösterilmiştir.

Tablo 3. JS ve KJS algoritmalarının karşılaştırma sonuçları (d=10)

		En iyi	Ortanca	En kötü	Ortalama	S. Sapma
F1	JS	5,29E-20	1,21E-17	3,19E-15	2,01E-16	6,08E-16
	KJS	3,28E-88	9,39E-82	8,08E-73	2,69E-74	1,48E-73
F2	JS	1,56E-14	1,72E-13	9,51E-13	2,95E-13	2,74E-13
	KJS	1,39E-46	6,51E-41	1,04E-38	7,72E-40	2,15E-39
F3	JS	2,14E-08	8,02E-06	6,34E-03	2,58E-04	1,16E-03
	KJS	6,98E-55	2,38E-45	1,97E-38	6,98E-40	3,59E-39
F4	JS	3,98E-04	4,36E-03	7,52E-02	8,78E-03	1,42E-02
	KJS	8,62E-42	2,94E-39	5,30E-37	7,17E-38	1,44E-37
F5	JS	6,77E-01	4,70E+00	5,93E+00	4,41E+00	1,27E+00
	KJS	5,47E-05	2,11E+00	5,75E+00	2,28E+00	1,86E+00
F6	JS	2,10E-19	8,77E-17	4,56E-14	1,80E-15	8,30E-15
	KJS	4,41E-19	7,38E-18	2,18E-16	3,18E-17	4,96E-17
F7	JS	1,95E-04	4,74E-04	1,83E-03	6,71E-04	4,77E-04
	KJS	2,14E-05	2,44E-04	7,28E-04	2,75E-04	1,86E-04
F8	JS	-4,19E+03	-3,92E+03	-3,48E+03	-3,89E+03	2,20E+02
	KJS	-4,19E+03	-4,19E+03	-3,43E+03	-4,08E+03	1,96E+02
F9	JS	0,00E+00	6,91E-12	2,98E+00	3,62E-01	7,12E-01
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F10	JS	1,25E-10	1,19E-09	8,75E-09	2,17E-09	2,14E-09
	KJS	8,88E-16	8,88E-16	4,44E-15	1,72E-15	1,53E-15
F11	JS	0,00E+00	9,99E-16	2,23E-02	3,29E-03	6,23E-03
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F12	JS	8,15E-20	2,41E-18	1,90E-15	7,40E-17	3,46E-16
	KJS	2,17E-20	9,61E-19	4,51E-17	4,42E-18	1,05E-17

Tablo 3’de verilen sonuçlar incelendiğinde tüm fonksiyonlarda önerilen KJS algoritmasının daha başarılı ortalama değerler elde ettiği tespit edilmiştir.

Benzer şekilde, Tablo 4-8 ‘de verilen tablolarda, JS ve KJS algoritmalarının sırasıyla 30,50,100,500 ve 1000 boyut için karşılaştırmalı sonuçları sunulmuştur. Tablolar incelendiğinde, Tablo 3’de olduğu gibi tüm karşılaştırmalarda KJS algoritmasının daha başarılı olduğu görülmüştür.

Tablo 4. JS ve KJS algoritmalarının karşılaştırma sonuçları (d=30)

		En iyi	Ortanca	En kötü	Ortalama	S. Sapma
F1	JS	7,75E-07	3,80E-05	5,10E-03	2,93E-04	9,34E-04
	KJS	2,23E-79	3,27E-73	1,35E-66	6,99E-68	2,59E-67
F2	JS	2,35E-05	3,52E-04	1,02E-02	1,32E-03	2,54E-03
	KJS	5,18E-41	1,26E-35	8,94E-33	6,47E-34	1,99E-33
F3	JS	4,09E+00	8,32E+01	4,35E+02	1,05E+02	1,06E+02
	KJS	5,89E-36	2,89E-27	1,51E-21	6,99E-23	2,89E-22
F4	JS	3,47E-02	1,13E-01	7,18E-01	1,60E-01	1,46E-01
	KJS	3,33E-38	3,05E-35	4,44E-33	3,36E-34	9,05E-34
F5	JS	5,56E-01	4,22E+00	2,74E+01	8,66E+00	8,87E+00
	KJS	9,35E-03	3,54E+00	2,65E+01	5,53E+00	6,62E+00
F6	JS	6,54E-06	5,14E-05	2,32E-03	1,94E-04	4,69E-04
	KJS	1,69E-10	2,12E-08	1,43E-06	7,99E-08	2,58E-07
F7	JS	3,96E-04	1,29E-03	3,35E-03	1,41E-03	6,66E-04
	KJS	2,06E-05	1,89E-04	7,61E-04	2,54E-04	1,87E-04
F8	JS	-1,08E+04	-8,27E+03	-5,64E+03	-8,15E+03	1,43E+03
	KJS	-1,21E+04	-9,07E+03	-5,95E+03	-9,17E+03	1,52E+03
F9	JS	5,59E-05	7,58E-03	3,00E+00	2,18E-01	6,65E-01
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F10	JS	1,73E-04	1,84E-03	1,33E-02	2,61E-03	2,96E-03
	KJS	8,88E-16	4,44E-15	4,44E-15	3,73E-15	1,45E-15
F11	JS	2,47E-06	4,16E-05	1,53E-02	1,50E-03	3,74E-03
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F12	JS	3,64E-08	5,87E-07	1,75E-05	1,81E-06	3,43E-06
	KJS	2,97E-11	4,15E-10	5,75E-09	8,81E-10	1,20E-09

Tablo 5. JS ve KJS algoritmalarının karşılaştırma sonuçları (d=50)

		En iyi	Ortanca	En kötü	Ortalama	S. Sapma
F1	JS	1,38E-04	1,74E-03	1,77E-01	9,91E-03	3,18E-02
	KJS	5,37E-81	4,91E-69	9,69E-63	3,75E-64	1,77E-63
F2	JS	2,18E-03	2,27E-02	1,45E-01	3,94E-02	4,18E-02
	KJS	1,90E-37	8,92E-34	7,12E-30	4,49E-31	1,47E-30
F3	JS	6,77E+01	6,39E+02	2,15E+03	8,51E+02	6,39E+02
	KJS	5,06E-32	1,65E-23	4,56E-18	1,61E-19	8,31E-19
F4	JS	3,20E-02	1,34E-01	7,13E-01	1,94E-01	1,80E-01
	KJS	1,27E-35	9,59E-34	5,63E-32	8,66E-33	1,70E-32
F5	JS	2,73E+01	1,24E+02	6,50E+02	1,58E+02	1,32E+02
	KJS	4,59E-01	7,27E+00	4,66E+01	1,23E+01	1,30E+01
F6	JS	2,23E-04	5,84E-03	5,32E-02	9,27E-03	1,08E-02
	KJS	7,89E-08	7,68E-07	9,14E-06	1,71E-06	2,53E-06
F7	JS	4,25E-04	1,50E-03	4,56E-03	1,67E-03	9,14E-04

	KJS	8,87E-05	2,80E-04	9,29E-04	3,15E-04	2,01E-04
F8	JS	-1,62E+04	-1,30E+04	-6,83E+03	-1,21E+04	2,72E+03
	KJS	-1,93E+04	-1,36E+04	-1,08E+04	-1,40E+04	2,20E+03
F9	JS	6,36E-03	1,10E-01	8,67E+00	7,54E-01	1,96E+00
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F10	JS	1,94E-03	9,17E-03	4,65E-02	1,27E-02	1,05E-02
	KJS	8,88E-16	4,44E-15	4,44E-15	3,14E-15	1,74E-15
F11	JS	5,39E-05	4,37E-03	2,08E-01	1,77E-02	4,36E-02
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F12	JS	4,01E-06	2,05E-05	6,78E-05	2,68E-05	1,75E-05
	KJS	1,23E-10	8,39E-09	1,61E-07	2,05E-08	3,64E-08

Tablo 6. JS ve KJS algoritmalarının karşılaştırma sonuçları (d=100)

		En iyi	Ortanca	En kötü	Ortalama	S. Sapma
F1	JS	1,76E-03	7,08E-02	2,15E+00	3,15E-01	5,70E-01
	KJS	1,11E-72	1,30E-66	1,01E-57	3,44E-59	1,85E-58
F2	JS	3,22E-02	1,29E-01	3,39E+00	2,90E-01	6,02E-01
	KJS	1,33E-35	3,19E-32	2,67E-25	8,93E-27	4,88E-26
F3	JS	8,72E+02	6,47E+03	1,17E+04	6,34E+03	3,09E+03
	KJS	2,88E-28	2,91E-18	7,79E-13	3,23E-14	1,43E-13
F4	JS	7,77E-02	2,84E-01	1,34E+00	3,64E-01	2,89E-01
	KJS	4,54E-36	2,11E-33	6,09E-30	2,62E-31	1,12E-30
F5	JS	9,66E-01	1,73E+01	9,77E+01	2,11E+01	2,13E+01
	KJS	7,73E-01	5,78E+00	3,79E+01	8,65E+00	9,20E+00
F6	JS	4,36E-03	9,79E-02	1,59E+00	2,26E-01	3,66E-01
	KJS	5,62E-07	9,83E-06	6,02E-04	6,79E-05	1,44E-04
F7	JS	7,33E-04	1,74E-03	1,63E-02	2,68E-03	3,46E-03
	KJS	6,89E-05	2,40E-04	1,18E-03	3,28E-04	2,45E-04
F8	JS	-2,83E+04	-1,93E+04	-1,03E+04	-1,91E+04	4,81E+03
	KJS	-3,74E+04	-2,35E+04	-1,58E+04	-2,34E+04	4,27E+03
F9	JS	1,12E-02	2,37E+00	4,10E+01	7,24E+00	1,15E+01
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F10	JS	7,90E-03	3,52E-02	5,83E-01	7,59E-02	1,17E-01
	KJS	8,88E-16	4,44E-15	4,44E-15	4,09E-15	1,08E-15
F11	JS	1,76E-03	2,84E-02	1,26E+00	1,33E-01	2,81E-01
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F12	JS	3,75E-05	1,81E-04	8,29E-04	2,16E-04	1,64E-04
	KJS	4,29E-11	4,72E-08	1,24E-06	1,09E-07	2,29E-07

Tablo 7. JS ve KJS algoritmalarının karşılaştırma sonuçları (d=500)

		En iyi	Ortanca	En kötü	Ortalama	S. Sapma
F1	JS	1,19E-01	9,24E-01	2,45E+02	1,33E+01	4,78E+01
	KJS	5,24E-73	1,17E-64	6,11E-52	2,11E-53	1,11E-52
F2	JS	5,12E-01	2,17E+00	2,40E+01	3,63E+00	4,48E+00
	KJS	2,43E-35	8,28E-30	4,54E-25	1,78E-26	8,26E-26
F3	JS	3,44E+04	2,24E+05	3,16E+05	2,13E+05	7,84E+04
	KJS	1,70E-26	4,19E-10	1,58E-03	7,12E-05	2,93E-04

F4	JS	1,71E-01	3,94E-01	1,50E+00	5,34E-01	3,77E-01
	KJS	9,78E-34	1,68E-31	6,98E-28	3,14E-29	1,29E-28
F5	JS	5,08E+00	2,20E+02	6,83E+02	2,77E+02	2,31E+02
	KJS	4,92E+00	1,61E+01	1,68E+02	3,96E+01	4,36E+01
F6	JS	1,65E-01	2,41E+00	6,66E+01	5,21E+00	1,20E+01
	KJS	7,45E-06	1,54E-04	1,64E-02	1,12E-03	3,15E-03
F7	JS	8,38E-04	2,58E-03	7,08E-03	2,81E-03	1,60E-03
	KJS	5,97E-05	3,30E-04	9,99E-04	3,20E-04	1,91E-04
F8	JS	-1,06E+05	-6,41E+04	-4,43E+04	-6,83E+04	1,29E+04
	KJS	-1,71E+05	-7,51E+04	-5,31E+04	-8,28E+04	2,71E+04
F9	JS	1,87E+00	3,25E+01	1,18E+03	1,20E+02	2,35E+02
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F10	JS	2,18E-02	9,64E-02	2,27E+00	2,10E-01	4,06E-01
	KJS	8,88E-16	4,44E-15	4,44E-15	4,32E-15	6,49E-16
F11	JS	3,03E-02	2,30E-01	4,91E+00	6,50E-01	9,94E-01
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F12	JS	2,02E-04	9,35E-04	9,62E-03	1,26E-03	1,70E-03
	KJS	2,77E-09	1,04E-07	1,14E-06	2,28E-07	3,03E-07

Tablo 8. JS ve KJS algoritmalarının karşılaştırma sonuçları (d=1000)

		En iyi	Ortanca	En kötü	Ortalama	S. Sapma
F1	JS	1,67E-01	1,21E+00	2,69E+02	2,08E+01	6,59E+01
	KJS	9,98E-72	8,02E-59	1,16E-52	4,14E-54	2,12E-53
F2	JS	1,66E+01	2,45E+02	9,19E+02	2,93E+02	2,13E+02
	KJS	1,58E-33	1,69E-28	1,90E-21	6,45E-23	3,46E-22
F3	JS	3,46E+05	8,93E+05	1,63E+06	8,85E+05	2,74E+05
	KJS	1,67E-22	8,79E-09	6,25E+00	4,44E-01	1,52E+00
F4	JS	1,84E-01	6,22E-01	4,14E+00	7,75E-01	7,92E-01
	KJS	6,52E-33	9,83E-31	5,50E-27	3,29E-28	1,10E-27
F5	JS	2,10E+01	4,40E+02	2,72E+03	6,93E+02	7,08E+02
	KJS	2,47E+00	4,92E+01	6,86E+02	9,35E+01	1,36E+02
F6	JS	5,46E-01	7,00E+00	1,47E+02	2,02E+01	3,51E+01
	KJS	3,15E-05	2,66E-04	1,54E-01	9,94E-03	3,10E-02
F7	JS	8,57E-04	2,98E-03	1,16E-02	3,45E-03	2,17E-03
	KJS	7,17E-05	3,16E-04	9,45E-04	3,53E-04	2,37E-04
F8	JS	-1,76E+05	-1,16E+05	-9,11E+04	-1,21E+05	2,11E+04
	KJS	-3,41E+05	-1,36E+05	-8,15E+04	-1,52E+05	5,95E+04
F9	JS	2,30E+00	5,24E+01	2,65E+03	2,02E+02	4,83E+02
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F10	JS	1,68E-02	8,25E-02	8,77E-01	1,20E-01	1,56E-01
	KJS	8,88E-16	4,44E-15	4,44E-15	4,32E-15	6,49E-16
F11	JS	2,51E-03	2,61E-01	2,50E+00	4,88E-01	5,71E-01
	KJS	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
F12	JS	1,00E-04	8,16E-04	1,19E+00	4,30E-02	2,16E-01
	KJS	4,99E-09	9,65E-08	3,02E-06	3,19E-07	5,94E-07

Tablo 9. JS ve KJS algoritmalarının literatürdeki algoritmalarla karşılaştırma sonuçları (d=30)

	JS	KJS	LXWOA	DDSCA	HGWO	m-SCA
F1	2,93E-04	6,99E-68	6,54E-77	1,57E-125	1,21E-32	5,70E-03
F2	1,32E-03	6,47E-34	6,09E-53	1,25E-64	9,33E-20	9,11E-04
F3	1,05E+02	6,99E-23	1,71E+04	2,43E+03	3,18E-08	8,48E+02
F4	1,60E-01	3,36E-34	1,90E+01	2,70E-03	4,16E-08	7,07E-01
F5	8,66E+00	5,53E+00	2,75E+01	3,63E-01	2,64E+01	2,96E+01
F6	1,94E-04	7,99E-08	3,01E-01	1,82E-07	3,78E-01	1,24E+00
F7	1,41E-03	2,54E-04	2,29E-03	4,30E-02	1,49E-03	1,95E-02
F8	-8,15E+03	-9,17E+03	-1,05E+04	-9,85E+03	-6,40E+03	-4,27E+03
F9	2,18E-01	0,00E+00	0,00E+00	0,00E+00	2,27E-01	7,81E+01
F10	2,61E-03	3,73E-15	4,44E-15	3,29E-14	4,26E-14	3,36E-03
F11	1,50E-03	0,00E+00	0,00E+00	0,00E+00	1,37E-03	3,84E-02
F12	1,81E-06	8,81E-10	1,70E-02	7,04E-09	3,43E-01	1,45E-01

Tablo 10. Wilcoxon işaretli sıra ve Friedman testi sonuçları

Wilcoxon işaretli sıra testi						
Algoritmalar	İyi	Kötü	Eşit	p	Sembol	
KJS vs JS	12	0	0	0,002	+	
KJS vs LXWOA	7	3	2	0,114	≈	
KJS vs DDSCA	6	4	2	0,445	≈	
KJS vs HGWO	12	0	0	0,002	+	
KJS vs m-SCA	12	0	0	0,002	+	
Friedman test						
	JS	KJS	LXWOA	DDSCA	HGWO	m-SCA
Ortalama Sıra	3,92	1,75	3,33	2,50	4,00	5,50

JS ve KJS algoritmaları literatürdeki LXWOA (Singh, 2019), DDSCA (Li, Zhao, & Liu, 2021), HGWO (Zhu, Xu, Li, Wu, & Liu, 2015) ve m-SCA (Gupta & Deep, 2019) algoritmalarıyla da karşılaştırılmıştır. Karşılaştırma literatürde sıklıkla kullanılan 30 boyut için yapılmıştır. Karşılaştırma sonuçları Tablo 9'da verilmiştir. Tablo incelendiğinde, KJS algoritmasının sekiz fonksiyonda en iyi ortalama değerleri elde edildiği tespit edilmiştir. Karşılaştırma sonuçları istatistiksel testler yardımıyla da yorumlanmıştır. Bunun için Wilcoxon işaretli sıra testi ve Friedman testleri kullanılmıştır (García, Molina, Lozano, & Herrera, 2009). Wilcoxon işaretli sıra testi, ilişkili iki ölçüm sonucu arasındaki farkın anlamlı olup olmadığını test etmek için kullanılır. Anlamlılık düzeyini belirleyen p değeri, $\alpha < 0.05$ olacak şekilde kullanılmıştır. Test sonuçları Tablo 10'da verilmiştir. Tablodaki İyi, Kötü ve Eşit sütunları sırasıyla KJS algoritmasının diğer algoritmadan kaç fonksiyonda daha iyi, daha kötü ve eşit ortalama değer bulduğunun bilgisini verir. Sembol ise p değerine bağlı olarak karşılaştırılan algoritmalar arasında anlamlı bir fark olup olmadığını gösterir. + ve - sembolleri algoritmalar arasında anlamlı bir fark olduğu anlamına gelir. \approx ise algoritmalar arasında anlamsal bir farklılık olmadığını gösterir. Tablo 10'a göre, KJS algoritması JS, HGWO ve m-SCA algoritmalarından daha iyi performans göstermiştir ve aralarında anlamlı bir fark vardır. LXWOA ve DDSCA algoritmaları ile ise aralarında anlamlı bir fark bulunmamaktadır ve benzer performans göstermişlerdir.

Friedman testi ise algoritmaları sıralamak ve aralarındaki farkı tespit etmek amacıyla bu çalışmada kullanılmıştır. Tablo 10'da verilen ortalama sıra değerlerine göre önerilen KJS algoritması, 1,75 ortalama sıra değeri ile ilk sırada yer almıştır. JS algoritması ise 3,92 ortalama sıra değeri ile dördüncü sıradadır. Dolayısıyla yapılan düzenleme ile standart algoritmanın performansının arttığı ve algoritmalar içinde ilk sıraya yükseldiği anlaşılmıştır.

4. Sonuç

Bu çalışmada son dönemde önerilmiş JS algoritmasının performansını geliştirmek amacıyla karşıt tabanlı öğrenme yaklaşımı algoritmanın evrimsel süreci içerisine dahil edilmiştir. Elde edilen gelişmiş KJS algoritmasının performansı, on iki standart kıyaslama fonksiyonu üzerinde altı farklı boyut için test edilmiştir. Elde edilen sonuçlar incelendiğinde, KJS algoritmasının tüm boyutlarda JS'den daha iyi performans gösterdiği anlaşılmıştır. Artan problem boyutu, tüm metasezgisel algoritmelerde olduğu gibi KJS algoritmasının performansında da bir miktar azalmaya neden olmuştur. Buna rağmen, tüm boyutlarda standart algoritmadan daha iyi performans göstermeyi sürdürmüştür. Literatürdeki algoritmalarla da karşılaştırılan KJS algoritması, Friedman testine göre yapılan sıralamada algoritmalar arasında ilk sırada yer almıştır. Wilcoxon işaretli sıra testi sonuçlarına göre ise karşılaştırıldığı algoritmalarla benzer ya da daha iyi performans göstermiştir. Tüm bu sonuçlar ışığında, önerilen KJS algoritmasının tercih edilebilir, yarışmacı ve başarılı bir algoritma olduğu söylenebilir. Gelecek çalışma olarak, önerilen KJS algoritmasının gerçek dünya problemleri ve CEC fonksiyonları üzerindeki performansı incelenecektir.

Kaynakça

- Abdel-Basset, M., Mohamed, R., Abouhawwash, M., Chakraborty, R. K., Ryan, M. J., & Nam, Y. (2021). An Improved Jellyfish Algorithm for Multilevel Thresholding of Magnetic Resonance Brain Image Segmentations.
- Almodfer, R., Zayed, M. E., Abd Elaziz, M., Aboelmaaref, M. M., Mohammed, M., & Elsheikh, A. H. (2022). Modeling of a solar-powered thermoelectric air-conditioning system using a random vector functional link network integrated with jellyfish search algorithm. *Case Studies in Thermal Engineering*, 101797.
- Chou, J.-S., & Truong, D.-N. (2021). A novel metaheuristic optimizer inspired by behavior of jellyfish in ocean. *Applied Mathematics and Computation*, 389, 125535.
- Dhevanandhini, G., & Yamuna, G. An Efficient Lossless Video Watermarking With Multiple Watermarks Using Artificial Jellyfish Algorithm.
- Gandomi, A. H., Yang, X.-S., Talatahari, S., & Alavi, A. H. (2013). Firefly algorithm with chaos. *Communications in Nonlinear Science and Numerical Simulation*, 18(1), 89-98.
- García, S., Molina, D., Lozano, M., & Herrera, F. (2009). A study on the use of non-parametric tests for analyzing the evolutionary algorithms' behaviour: a case study on the CEC'2005 special session on real parameter optimization. *Journal of Heuristics*, 15(6), 617-644.
- Ginidi, A., Elsayed, A., Shaheen, A., Elattar, E., & El-Sehiemy, R. (2021). An Innovative Hybrid Heap-Based and Jellyfish Search Algorithm for Combined Heat and Power Economic Dispatch in Electrical Grids. *Mathematics*, 9(17), 2053.
- Gouda, E. A., Kotb, M. F., & El-Fergany, A. A. (2021). Jellyfish search algorithm for extracting unknown parameters of PEM fuel cell models: Steady-state performance and analysis. *Energy*, 221, 119836.
- Gupta, S., & Deep, K. (2019). A hybrid self-adaptive sine cosine algorithm with opposition based learning. *Expert Systems with Applications*, 119, 210-230.
- Jiang, S.-J., Dao, T.-K., Vu, V.-D., & Ngo, T.-G. (2021). A Power System Economic Load Dispatch Using Jellyfish Search Algorithm. In *Soft Computing for Problem Solving* (pp. 321-331): Springer.
- Kaveh, A., Biabani Hamedani, K., Kamalinejad, M., & Joudaki, A. (2021). Quantum-based jellyfish search optimizer for structural optimization, *II*(2), 329-356.
- Li, Y., Zhao, Y., & Liu, J. (2021). Dimension by dimension dynamic sine cosine algorithm for global optimization problems. *Applied Soft Computing*, 98, 106933.
- Mahdavi, S., Rahnamayan, S., & Deb, K. (2018). Opposition based learning: A literature review. *Swarm and evolutionary computation*, 39, 1-23.
- Manita, G., & Zermani, A. (2021). A Modified Jellyfish Search Optimizer With Orthogonal Learning Strategy. *Procedia Computer Science*, 192, 697-708.
- Rajpurohit, J., & Sharma, T. K. (2022). Chaotic active swarm motion in jellyfish search optimizer. *International Journal of System Assurance Engineering and Management*, 1-17.
- Singh, A. (2019). Laplacian whale optimization algorithm. *International Journal of System Assurance Engineering and Management*, 10(4), 713-730.
- TEMURTAŞ, H., Yaşar, C., & ÖZYÖN, S. (2017). Nümerik fonksiyonların optimizasyonu için karşıt tabanlı yeni bir meta-sezgisel algoritma. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 17(3), 922-937.
- Tizhoosh, H. R. (2005). *Opposition-based learning: a new scheme for machine intelligence*. Paper presented at the International conference on computational intelligence for modelling, control and automation and international conference on intelligent agents, web technologies and internet commerce (CIMCA-IAWTIC'06).
- Xu, Q., Wang, L., Wang, N., Hei, X., & Zhao, L. (2014). A review of opposition-based learning from 2005 to 2012. *Engineering Applications of Artificial Intelligence*, 29, 1-12.
- Yıldızdan, G., & Baykan, Ö. K. (2021). *A Novel Artificial Jellyfish Search Algorithm Improved with Detailed Local Search Strategy*. Paper presented at the 2021 6th International Conference on Computer Science and Engineering (UBMK).
- Zhu, A., Xu, C., Li, Z., Wu, J., & Liu, Z. (2015). Hybridizing grey wolf optimization with differential evolution for global optimization and test scheduling for 3D stacked SoC. *Journal of Systems Engineering and Electronics*, 26(2), 317-328.



Analysis of SEM Images with Artificial Intelligence Methods

Ayşe Demirkan^{1*}, İsmail Topçu^{2*}

¹Nanobilim ve Nanoteknoloji / Metalurji ve Malzeme Mühendisliği, ALKÜ, Türkiye,(ORCID ID: 0000-0002-8403-7243),aedemirkan2@gmail.com

²Nanobilim ve Nanoteknoloji / Metalurji ve Malzeme Mühendisliği, ALKÜ, Türkiye,(ORCID ID: 0000-0002-2998-6569),ismail.topcu@alanya.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1219252)

ATIF/REFERENCE: Demirkan, A., Topcu, İ., (2022). Analysis of SEM Images with Artificial Intelligence Methods. *European Journal of Science and Technology*, (44), 35-38.

Abstract

Today, the quality of Nanotechnology and Nanoscience working with Artificial Intelligence is increasing day by day. Gains the importance of materials science effectively. Examination of SEM Images with Artificial Intelligence Methods represents a multidisciplinary field. In forming the data used in the experimental part, 22,000 SEM data are publicly available. It is known that CNR-IOM's TASC laboratory in Trieste was obtained as a result of 5 years of work of 100 scientists with the ZEISS SUPRA 40 resolution device. After examining the resolution, image size and quality one by one for the selection of the data in the prototype created for the experimental study, the feature that is considered is the image quality. In the creation of this data, after 100 image data are manually selected and arranged in nano and micro dimensions; A total of 1000 image data were created in 10 data sets. Then, artificial intelligence training was carried out using the CNN classification technique in the experimental study using the unsupervised learning method through machine learning. The approach used here enables the application of new methods and tools by adjusting to develop suitable parameters to solve specific properties of nanomaterials that can be applied to a wide variety of nanoscience use cases. Using it to create a materials science library may pave the way for future studies in the field of artificial intelligence and nanotechnology.

Keywords: Nanotechnology, Nanoscience, Artificial Intelligence, SEM, Materials Science.

SEM Görüntülerinin Yapay Zekâ Yöntemleriyle Analizi

Öz

Günümüzde, nanoteknoloji ve nanobilimin, yapay zekâ ile çalışma niteliğinin günden güne artması; malzeme biliminin önem kazanmasında etkili olmaktadır. SEM Görüntülerinin yapay zekâ metotları ile incelenmesi, multidisipliner bir alanı ifade etmektedir. Deneysel kısımda kullanılan verilerin oluşumu; halka açık erişim olarak sunulan 22.000 SEM verisinin; Trieste'deki CNR-IOM'un TASC laboratuvarında bulunan ZEISS SUPRA 40 çözünürlüklü cihaz ile 5 yıl boyunca 100 bilim insanının çalışmaları sonucunda elde edildiği bilinmekle birlikte; deneysel çalışma için oluşturulan prototipte yer alan verilerin seçimi için; tek tek çözünürlüğü, görüntü boyutu ve kalitesine göre incelenmesinin ardından, dikkate alınan özellik, görüntü kalitesi olmakla birlikte; bu verilerin oluşumunda 100 görüntü verisi elle manuel olarak nano boyutta ve mikro boyutta seçilip, düzenlendikten sonra; toplamda 1000 görüntü verisi 10 veri seti içerisinde oluşturuldu. Deneysel çalışmada CNN sınıflandırma tekniği ile yapay zekâ eğitimi gerçekleştirildi. Burada kullanılan yaklaşım, çok çeşitli nanobilim kullanım durumlarına uygulanabilen, nanomalzemelerin belirli özelliklerini çözmek için uygun parametreler geliştirilecek şekilde ayarlanarak yeni yöntem ve araçların uygulanmasına giden yolu makine öğrenmesinin ürüne dönüşüm boyutunda; malzeme bilimi kütüphanesi oluşturmak adına kullanımının, yapay zekâ ve nanoteknoloji alanındaki gelecek çalışmaların önünün açabilmesine katkısı olabilir.

Anahtar Kelimeler: Nanoteknoloji, Nanobilim, Yapay Zekâ, SEM, Malzeme Bilimi.

1. Introduction

Today, Nanotechnology and Nanoscience are gaining importance; working with artificial intelligence increases the awareness of the nature of these concepts day by day. Simultaneous use can pave the way for rapid developments in engineering and production, especially in the field of materials science [1], [3], [10-12].

2. Material and Method

While classifying in CNN, is one of the deep learning techniques; It is as important as possible to perform artificial intelligence training by making different function entries according to the data set. Here, the method used in the coding phase of the training with SEM images is the unsupervised learning technique of machine learning and the CNN classification technique [1], [8].

2.1. The Place and Importance of 10 Experimentally Used Datasets in Nanotechnology

Nanomaterials are important as a part of the produced system and it is known within the scope of scientific studies that materials show different properties in macro, micro, and nano dimensions. The figure shows the visuals of the SEM images used in the data sets [1], [2], [6,7].




Figure 1. *Fibres, Nanowires, Patterned_surface, Films_Coated_Surface, Biological, Porous_Sponge, Powder, Tips, Particles, MEMS_devices_and_electrodes*

2.1.1. Convolutional Neural Network Architectures (CNN)

CNN is a subcategory of deep neural networks most commonly applied for image classification and recognition. Three types of layers are generally used to create the CNN architecture between the input and output. These layers are; the convolutional layer, the pooling layer, and the fully connected layers[3-5], [8-11].

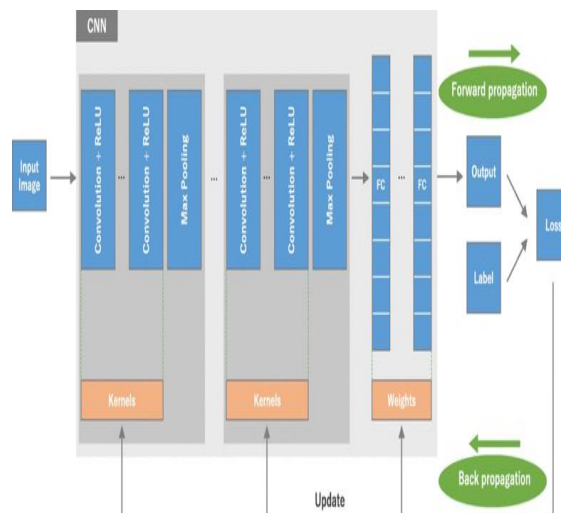


Figure 2. *Image of CNN network*

To elaborate, three primary operations are performed for the direct input/data line:

1. Preprocessing of the data in the dataset,
2. Mixing the dataset,
3. Aggregate sets within the dataset

In the experimental study, the coding phase was carried out by applying the unsupervised learning technique of machine learning and the CNN methodology used to classify images in the deep learning subcategory [5],[8].

The method used during the experiment; With "RELU-softmax" activation function, RMSprop and Adam = 0.000001 as parameters in two different speed cycles, epoch parameters are set as "25" and "100", the data can be trained by classification method in CNN with unsupervised learning technique. Carried out; The value results obtained from the graphical data obtained in matplotlib are evaluated comparatively in a comparative way.

3. Results and Discussion

When the graphical values of the findings are tabulated and all "Model accuracy rates" are examined, it can be concluded that the best value of the classification value resulted in model training with CNN, since the epoch value was 100 in the RMSprop used. It was carried out with the RELU-softmax activation function. Of course, the values here vary according to the data trained in the model data set, the number of data, the number of trainings, and the parameters.

3.1. Model training with RMSprop on CNN




Figure 3. Graphic value of model accuracy rate with Matplotlib in CNN classification training realized by setting Epoch value to 25 with RMSprop function in experimental evaluation

If we want to interpret the graph, the value approaching 1 in the model training indicates that successful training has taken place with AI.

3.2. Model training with Adam on CNN




Figure 5. Graphic value of model accuracy rate with Matplotlib in CNN classification training realized by setting Epoch value to 25 with Adam=0.000001 function in experimental evaluation

If we want to interpret the graph, the value of 0.72 shows an important dimension on the basis of comparing the results in future studies by increasing the number of data here as a correlation; AI shows poor training performance compared to RMSprop.




Figure 4. Graphic value of model accuracy rate with Matplotlib in CNN classification training realized by setting Epoch value to 100 with RMSprop function in experimental evaluation

If we need to interpret the graph, the model training is more successful than the first training and the value approaching 1 can be explained as successful training with artificial intelligence.




Figure 6. Graphic value of model accuracy rate with Matplotlib in CNN classification training realized by setting Epoch value to 100 with Adam=0.000001 function in experimental evaluation

In addition to the fact that the value formed in the graph is lower than the RMSprop, it can be said that it is more successful because it gives a result close to 1 than the training result value made by entering Adam=0.000001 and 25 epochs.

4. Conclusions and Recommendations

Table-1 Experiment Results

Epoch	RMSprop	Adam = 0.000001
25	0.97	0.72
100	0.98	0.94

When all the "model accuracy rates" in the result table are examined, it can be concluded that the classification value result in model training with CNN has the best value when using the RELU-Softmax activation function with an epoch value of 100 with RMSprop. While performing image training in CNN, one of the deep learning sub-branches of the study; It is as important

as possible in terms of evaluating the results of graphs and graph values formed by using different parameters according to activation functions and data sets. Classifying the result values according to the level of compliance with the data results and the training parameters, tabulating the model accuracy rates; Comparing the best result value are extremely important in terms of SEM image training and increasing the number of images to obtain the best result may pave the way for better studies in terms of analysis.

References

- [1] Akhtar, K., Khan, S.A., Khan, S.B., Asiri, A.M. (2018). Scanning Electron Microscopy: Principle and Applications in Nanomaterials Characterization In: *Sharma, S. (eds) Handbook of Materials Characterization. Springer, Cham.*
- [2] Topcu, İ. (2018). Investigation of Mechanical Behavior of Carbon Nanotube Reinforced Aluminum Matrix AlMg/CNT Composites. *Çanakkale Onsekiz Mart University Journal of Science Institute*, 4(1), 99-109.
- [3] Acı, M., Avcı M. (2016). ‘Artificial neural network approach for atomic coordinate prediction of carbon nanotubes’, *Appl. Phys.*, 122, 631.
- [4] Raitoharju, J., (2022). ‘Chapter 3 - Convolutional neural networks’, *Editor(s): Al. Iosifidis, A. Tefas, Deep Learning for Robot Perception and Cognition, Academic Press, 35-69, ISBN 9780323857871.*
- [5] Sowmya, B. P., Supriya, M. C. (2021). ‘Convolutional Neural Network (CNN) Fundamental Operational Survey’, *Learning and Analytics in Intelligent Systems, 21, Springer, Cham.*
- [6] Topcu, İ., Muhammet, C., Yılmaz, E.B. ‘Experimental investigation on mechanical properties of Multi Wall Carbon Nanotubes (MWCNT) reinforced aluminium metal matrix composites’, *Journal of Ceramic Processing Research*, 21 (5), 596-601.
- [7] Rauniyar, A., Hagos, D., Bağcı, U. (2022). ‘Federated Learning for Medical Applications: A Taxonomy, Current Trends, Challenges, and Future Research Directions’.
- [8] Yamashita, R., Nishio, M., Do, R.K.G. *et al.* (2018). ‘Convolutional neural networks: an overview and application in radiology. *Insights Imaging* 9’, 611–629.
- [9] Virtanen, P., Gommers, R., Oliphant, T. E., *et al.* (2020). ‘SciPy 1.0: fundamental algorithms for scientific computing in Python. *Nat Methods*’, 17, 261–272.
- [10] LeCun, Y., Bengio, Y., Hinton, G.E. (2015) ‘Deep learning’, *Nature*, 521, 436–444.
- [11] Turing, A. M. (2009). ‘Computing Machinery and Intelligence’, In: *Epstein R., Roberts G., Beber G. (eds) Parsing the Turing Test. Springer, Dordrecht.*
- [12] Booth, T. J., Baker, M.A.B. (2017). ‘Chapter 32 - Nanotechnology: Building and Observing at the Nanometer Scale’, *Pharmacognosy, Academic Press, 633-643.*



Makine Öğrenmesi Tabanlı Mikrodizi Tekniği ile MikroRNA Hedef Tahmini: Araştırma Çalışması

Zerrin Yıldız Çavdar^{1*}, Tolga Ensari², Leyla Türker Şener³, Ahmet Sertbaş⁴

^{1*} İstanbul Üniversitesi Cerrahpaşa, Bilgisayar Mühendisliği Bölümü, İstanbul 34320, Türkiye, (ORCID: 0000-0003-4299-5344), zerrin.yildizcavdar@ogr.iuc.edu.tr

² Arkansas Tech University, Department of Engineering and Computing Sciences, Russellville, USA, (ORCID: 0000-0003-0896-3058), tensari@atu.edu

³ İstanbul Üniversitesi, Biyofizik Bölümü, İstanbul 34320, Türkiye, (ORCID: 0000-0002-7317-9086), leylasen@istanbul.edu.tr

⁴ İstanbul Üniversitesi Cerrahpaşa, Bilgisayar Mühendisliği Bölümü, İstanbul 34320, Türkiye, (ORCID: 0000-0001-8166-1211), asertbas@iuc.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1220962)

ATIF/REFERENCE: Yıldız Çavdar, Z., Ensari, T., Türker Şener, L., Sertbaş, A. (2022). Makine Öğrenmesi Tabanlı Mikrodizi Tekniği ile mikroRNA Hedef Tahmini: Araştırma Çalışması. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 39-45.

Öz

Biyoenformatik, biyolojik bilgilerin bilgisayar teknolojileri yardımıyla incelenmesini ve değerlendirilmesini sağlayan bir araştırma alanıdır. Çok disiplinli bu alan sayesinde tıbbi veriler üzerinde yapılan çalışmalarda hızla yol alınabilmekte, gerek hastalıkların teşhis-tedavi süreçlerinde gerek önlenmesi süreçlerinde başarılı çözümler bulunabilmektedir.

Birçok farklı organizmada görülen ve hücre üzerinde olaylarda etkili olduğu ortaya çıkan mikroRNA (miRNA, miR olarak da isimlendirilir, mikro RiboNükleik Asit'in kısaltmasıdır)'ların genler üzerindeki etkisi ile ilgili çalışmalar da biyoenformatik yöntemler yardımıyla başarılı sonuçlar vermektedir. Özellikle kanser ile yakın ilişkili olduğu düşünülen mikroRNA'ların incelenmesinde mikrodizi teknikleri sıklıkla tercih edilmektedir. Mikrodizi olarak hazırlanan veri setleri makine öğrenmesi yöntemleri ile değerlendirilerek mikroRNA hedef genlerinin belirlenmesi, mikroRNA'ya bağlı hastalık/kanserin teşhis ve tedavi süreçleri ile ilgili hızlı ve doğruluğu yüksek sonuçlar elde edilebilmektedir.

Bu araştırma çalışmasında, mikroRNA hedef gen tahmini sürecinde makine öğrenmesi tekniklerinin kullanımı incelenmiştir.

Anahtar Kelimeler: mikroRNA, miRNA, mikrodizi, mikroRNA Hedef Tahmini.

MicroRNA Target Prediction by Machine Learning-Based Microarray Technique: Research Study

Abstract

Bioinformatics is a research field that enables the examination and evaluation of biological information with the help of computer technologies. With the help of this multidisciplinary field, studies on medical data can progress rapidly, and successful solutions can be found both in the diagnosis-treatment processes of diseases and in the prevention processes.

Studies on the effects of microRNAs (miRNA, also called miR, an abbreviation for micro RiboNucleic Acid) that are seen in many different organisms and are effective in events on the cell, also give successful results with the help of bioinformatics methods. Microarray techniques are frequently preferred especially in the examination of microRNAs that are thought to be closely related to cancer. By evaluating the data sets prepared as microarrays with machine learning methods, fast and high-accuracy results can be obtained regarding the determination of microRNA target genes, diagnosis and treatment processes of microRNA-related disease/cancer. In this research study, the use of machine learning techniques in the microRNA target gene prediction process was examined.

Keywords: microRNA, miRNA, microarray, microRNA Target Prediction.

* Zerrin YILDIZ ÇAVDAR: zerrintt@gmail.com

1. Giriş

Biyoenformatik çok disiplinli bir araştırma alanı olup, biyolojik verilerin değerlendirilebilmesi ve sonuçların görselleştirilebilmesi için; biyoloji, biyokimya, genetik, moleküler biyoloji ve genetik, istatistik, matematik ve bilgisayar bilimleri gibi birçok alanı kapsamaktadır. Biyoenformatik çalışmalar sayesinde laboratuvar ortamında çalışılması çok zaman alacak veya mümkün olmayacak çalışmalar bilgisayar desteği ile yapılabilmektedir. Hastalıklardan korunma ve hastalıkların tedavisi sürecinde genetik yatkınlık, beslenme ve yaşam şekli gibi birçok etken etkili olmakla birlikte hastalıkların teşhisi, hastalıklardan korunma ve daha etkili tedavi yöntemlerin bulunması süreçlerinde genlerin ve mikroRNA adı verilen RNA (RiboNükleik Asit) hücrelerinin rolü büyüktür.

mikroRNA'lar önemli gen düzenleyicileridirler; farklı organizmalarda görülmektedirler ve hastalıkların teşhis-tedavisinde etkili oldukları anlaşılmaktadır (Maizere vd., 2007). mikroRNA'lar bir yada birden fazla hedef geni baskılayarak hücrenin gelişim, farklılaşma, çoğalma, ölümü gibi farklı olaylarda rol oynarlar (Karagün vd., 2014).

Yapılan bu araştırma çalışmasında protein kodlamayan RNA hücreleri olan mikroRNA'ların hedef tahmin süreçleri ile ilgili teknik ve yöntemler incelenmiştir. Çalışmanın birinci bölümünde, mikroRNA'lar ile çalışmada çok tercih edilen tekniklerden olan mikrodizi tekniği ile ilgili bilgiler verilmeye çalışılmıştır. İkinci bölümde ise mikroRNA'lar, mikroRNA veri setlerini barındıran veri tabanları, makine öğrenmesi teknolojisini kullanan mikroRNA hedef tahmin araçları ve bu alanda yapılan çalışmalar incelenmiş ve karşılaştırmalara yer verilmiştir. Ayrıca mikroRNA hedef tahmini yapmak için makine öğrenmesi yöntemlerinin nasıl kullanılacağı incelenmiştir.

2. Materyal ve Metot

2.1. Mikrodizi

Bu bölümde mikrodizi tekniği hakkında bilgiler paylaşılmıştır.

Bazı kaynaklarda gençip, biyoçip, mikrodizin şeklinde de adlandırılan mikrodiziler, genomun (ACTG harflerinin bir dizisi şeklinde olan, bir canlıya ait tüm DNA bilgisi) bir çip üzerinde görüntülenmesini sağlayan bir teknolojidir. Bu teknoloji ile gen ifadesindeki farklılıklar tespit edilebilir. Mikrodizi teknolojisi için kullanılan çipleri hazırlayan Affymetrix (2021, Mart 27. <https://www.affymetrix.com/>), Illumina (2021, Mart 27. <https://www.illumina.com/>), Agilent (2021, Mart 27. <https://www.agilent.com/>), Exiqon (2021, Mart 27. <http://www.exiqon.com/>) gibi birçok firma bulunmaktadır. Bu mikrodizi teknolojisi ile mikroRNA hedef tahmini yapılabilmektedir.

Birçok araştırmacı, farklı perspektiflerden mikroRNA hedef tahminin doğruluğunu geliştirmek için yöntemler önermişlerdir. Bu yöntemler mikroRNA ekspresyon profillerini, gen ekspresyon profillerini, varsayılan mikroRNA-gen etkileşimlerini, mikroRNA dizisini ve mikroRNA hedeflerini tahmin etmek için gen dizisi verilerini içerir (Jiang vd., 2015). Örneğin; Kim ve arkadaşları (Kim vd., 2009) mikroRNA'lar ve kolorektal kanserdeki hedef genleri arasındaki ilişkileri ortaya çıkarmak için, doğrusal bir modele dayanan mikrodizi ifade profillerini ve dizi verilerinin kullanarak etkili bir yöntem önermişlerdir. Lu ve

arkadaşları ise (Lu vd., 2011), dizi tabanlı tahmin bilgisini, RISC mevcudiyetini ve mikroRNA/gen verilerini birleştirerek, mikroRNA hedeflerini tanımlamak için miRmap ismini verdikleri, mikrodizi verilerini kullanan bir regrasyon modeli önermişlerdir.

Mikrodizi teknolojisindeki gelişmeler, araştırmacıların mikroRNA ve mRNA'ların ekspresyon seviyelerini eş zamanlı olarak ölçmesini sağlamıştır. Bu teknolojiye genel olarak kullanılan yöntemler “denetimli” ve “denetimsiz” olarak kategorize edilebilir (Sedaghat vd., 2018). Mikrodizi yöntemlerinin hemen hepsi, mikroRNA hedef tahmininin zorluklarını aşmak için makine öğrenme tekniklerini kullanmışlardır (Van der Auwera vd.,2010, Liu vd., 2010, Sales vd., 2010, Lu vd., 2011, Muniategui vd., 2012, Rabiee-Ghahfarokhi vd., 2015, Abdelhadi Ep Souki vd., 2015, SaeTrom vd., 2005, Bandyopadhyay vd., 2009, Yousef vd., 2007, Reyes-Herrera vd., 2011).

2.1.1. Mikrodizi Veri Tabanları

Mikrodizi verilerini paylaşan çeşitli veri tabanları bulunmaktadır.

Bu veri tabanlarında MIAME (Minimum Information About a Microarray Experiment) kriterlerine uygun veri setleri paylaşılmaktadır (Oztemur vd., 2014, Brazma vd., 2001)

Açık erişim sağlanabilen ve çok tercih edilen birkaç veri tabanı aşağıdaki gibidir:

- NCBI – GEO (National Center for Biotechnology Information – Gene Expression Omnibus) (2022, Mart 8. <https://www.ncbi.nlm.nih.gov/geo/>)
- ArrayExpress (2022, Mart 8. <https://www.ebi.ac.uk/arrayexpress/>)
- DataMed (2022, Mart 8. <https://datamed.org/>)

2.2. mikroRNA

Bitki, hayvan, insan gibi farklı organizmalarda görülen mikroRNA'lar, protein kodlayan ve protein kodlamayan olarak sınıflandırabileceğimiz RNA'ların bir türüdür. Protein kodlamayan RNA grubunda olan mikroRNA'lar, 21-23 nükleotid uzunluğunda olan ve mRNA (messenger RNA, yine bir RNA türü) ile etkileşime girerek protein oluşumunu engelleyen küçük RNA'lardır. Önemli gen düzenleyicilerinden olan mikroRNA'lar, hücrenin çoğalması, değişimi, ölümü gibi süreçleri etkileyebilmektedir.

İlk keşfedilen küçük RNA, mikroRNA'dır (Marry K.V., 2005). mikroRNA'lar önemli gen düzenleyicileridirler, farklı organizmalarda görülmektedirler ve hastalıkların teşhis ve tedavisinde etkili oldukları anlaşılmaktadır (Maizere vd., 2007). MikroRNA'lar çeşitli hastalıkların gelişiminde ve ilerlemesinde kritik rol oynar (Chen vd., 2014). mikroRNA-mRNA hedef etkileşimlerinin tanımlanması ve validasyonu, mikroRNA'ların biyolojik süreçleri yöneten mikroRNA düzenleyici ağlarının da geniş bağlamdaki rolünü ayırt etmenin temelidir (Peterson vd., 2014). MikroRNA'lar, bir pre-miRNA'dan türetilen ve transkripsiyon sonrası düzenlemeye katılan bir endojen sınıftır (Mathelier vd., 2010).

mikroRNA'lar bitki, hayvan, mikrop, sünger, metazoan ve virüsler dahil çok sayıda organizmada tespit edilmiş olsa da suya yaşayan canlılarda görülmemiştir. mikroRNA'ların oluşumu önce uzun RNA formunda olan pri-miRNA ile başlar, sonrasında pre-miRNA aşamasına geçer ve son olarak

kısa mikroRNA şeklini alır (Saydam vd., 2011, Kwak vd., 2010).

2.2.1. mikroRNA Veri Tabanları

mikroRNA'lar üzerinde çalışabilmek için kullanılabilir birçok mikroRNA veri tabanı bulunmaktadır.

Tablo 1. mikroRNA Veri Tabanları

mikroRNA Veri Tabanları
NCBI-GEO (2022, Mart 8. https://www.ncbi.nlm.nih.gov/geo/)
TCGA (The Cancer Genome Atlas) (2022, Kasım 21. https://www.cancer.gov/)
ICGC (International Cancer Genome Consortium) (2022, Ocak 12. https://dcc.icgc.org/)
TargetScan (2022, Haziran 19. http://www.targetscan.org/)
miRWalk (2022, Haziran 19. http://mirwalk.umm.uni-heidelberg.de)
miRBase (2022, Haziran 19. http://www.mirbase.org/)
DisGeNet (2022, Haziran 19. http://www.disgenet.org/)
HMDD (the Human Microna Disease Database) (2022, Haziran 19. http://www.cuilab.cn/hmdd)

2.2.2. Makine Öğrenmesi Tabanlı mikroRNA Hedef Tahmin Araçları

mikroRNA hedef tahmininde kullanılabilir birçok araç geliştirilmiştir. Bu hedef tahmin araçlarını işlevsel olarak gruplamak istenirse 2 gruba ayrılır:

1. **Klasik Hedef Tahmin Araçları:** Yapısal özellikleri kullanarak de-novo tahminler yapmayı hedefleyen araçlardır. Bu araçlar tohum eşleştirme, termodinamik kararlılık, evrimsel koruma, hedef sitelerin erişilebilirliği ve aynı 3'UTR hedef sitelerinin sayısı gibi stratejiler kullanırlar (Riolo vd., 2020). miRANDA, miTarget gibi araçlar klasik yöntemleri kullanmaktadır.

2. **Makine Öğrenimi Destekli Araçlar:** Deneysel olarak doğrulanmış mikroRNA hedeflerinin sayısı arttıkça, "eğitim" verilerinin varlığını genel olarak kabul eden, makine öğrenmesi tabanlı, ikinci nesil araçlar ortaya çıkmıştır. Bu araçlar farklı makine öğrenmesi tekniklerini kullanırlar.

Tablo 2. Makine Öğrenmesi Tabanlı mikroRNA Hedef Tahmin Araçları

Makine Öğrenmesi Tabanlı mikroRNA Hedef Tahmin Araçları
TargetSpy: mikroRNA hedef tahmini için denetimli bir makine öğrenme yaklaşımıdır (Sturm vd., 2010).
MirSVR: miRanda tarafından öngörülen mikroRNA hedeflerin etkinliğini puanlamak ve sıralamak için bir algoritma içerir (Betel vd., 2010).

MIRENA: Genom ölçeğinde ve derin dizilim verilerinden denetimsiz mikroRNA bulmak için kullanılabilir bir araçtır (Mathelier vd., 2010).
HuntMi: pre-miRNA tanımlama aracıdır (Gudyś vd., 2013).
ComiR: Birleşimsel mikroRNA hedef tahmini için bir web aracıdır (Coronnello vd., 2013).
RFMirTarget: Random Forest sınıflandırıcılı insan mikroRNA hedef gen tahmin aracıdır (Mendoza vd., 2013).
miRClassify: Makine öğrenimine dayalı web sunucusu olarak hizmet veren bir araçtır (Zou vd., 2014).
MiXGENE: Bütüncül moleküler modellerin hızlı prototiplenmesini sağlayan, iş akışları oluşturmak için ortam sunan bir araçtır (Holec vd., 2014).
RLSMDA: Semi-supervised bir yöntem kullanan bir araçtır (Chen vd., 2014).
mirMark: Site-Level ve UTR(UnTranslated Region) düzeylerinde, makine öğrenme tabanlı miRNA hedef tahmin yöntemi kullanan bir araçtır (Menor vd., 2014).
imDC: mikroRNA verileriyle dengesiz(imbalanced) sınıflandırma için bir topluluk öğrenme yöntemi sunan araçtır (Wang vd., 2015).
MBSTAR: mikroRNA hedeflerinde belirli fonksiyonel bağlama sitelerini öngörmek için çoklu örnek (multiple instance) öğrenme yöntemi sunan araçtır (Bandyopadhyay vd., 2015).
ncRNAclass: Kodlamayan(Non-coding) RNA özelliği hesaplama ve mikroRNA hedef tahmini için web platformu sunan araçtır (Karathanou vd., 2015).
miRLocator: Bitki pre-miRNA dizileri içindeki olgun mikroRNA'ların makine öğrenmeye dayalı tahmin sağlayan araçtır (Cui vd., 2015).
RDDpred: RNA seq verilerinden duruma özgü bir RNA düzenleme tahmin modeli sunan araçtır (Kim vd., 2016).
OP-Triplet-ELM: Gerçek ve sözde mikroRNA öncüllerini belirleme aracıdır (Pian vd., 2016).
TarPmiR: mikroRNA hedef bölgesi tahmini için yeni bir yaklaşım sunan araçtır (Ding vd., 2016).
MiRTDL: mikroRNA hedef tahmini için derin öğrenme yaklaşımı sunan bir araçtır (Cheng vd. 2015).
Miracle: SMOTE ve random forest makine öğrenme yöntemleri ile pre-miRNA hedef tahmini yapan bir araçtır (Marques vd., 2016).
SpidermiR: mikroRNA verileri ile bütünleştirici analiz için bir R / biyoiletken paketi aracıdır (Cava vd., 2017).

DP-miRNA: Derin öğrenme modeli kullanılarak öncü mikroRNA'nın geliştirilmiş öngörüsünü sunan bir araçtır (Thomas vd., 2017).
izMİR: Pre-MiRNA tahmin algoritması içeren bir araçtır (Saçar Demirci vd., 2017).
Mirnovio: Decision trees kullanan küçük RNA sıralama verilerinden ve tek hücreden mikroRNA'ların genom içermeyen tahminini sağlayan bir araçtır (Vitsios vd., 2017).
microRPM: Tahmin modeli aracıdır. Bitki microRNA'sı için hazırlanmıştır (Tseng vd., 2018).
DeepMirTar: Farklı düzeylerdeki 750 özelliği göz önünde bulundurabilen bir mikroRNA-hedef tahmin yöntemi aracıdır (Wen vd., 2018).
Avishkar: mikroRNA hedef tahmini için bir algoritma paketi sunan araçtır (Ghoshal vd., 2018).
miRTPred: Hedef tanıma özelliklerinin etkileşimini keşfetmek için hassas bir mikroRNA hedef tahmin modeli sunan araçtır (Maji vd., 2018).
miES: mikroRNA önceliklendirilmesi için yeni bir algoritma sunan araçtır (Song vd., 2019).
MRMR-mv: Multi-omics verilerini kullanarak over kanser yaşantısını öngörmek için Min-Redundancy ve Max-Relevance Multi-view özellik seçimi sağlayan bir araçtır (El-Manzalawy vd., 2018).
miRTRS: mikroRNA hedeflerini öngörmek için bir öneri algoritması içeren araçtır (Jiang vd., 2018).

2.2.3. mikroRNA Hedef Tahmininde Makine Öğrenmesi Kullanımı

mikroRNA hedef tahmini için biyolojik yöntemleri kullanan klasik metotların yanında daha hızlı çözüm sağlayan ve klasik yöntemlerle sonuçlandırılması mümkün olmayan verilerin değerlendirilmesini sağlayan makine öğrenmesi yöntemleri geliştirilmiştir. Bilgisayar biliminin biyolojik verilerin değerlendirilmesi kullanması ile mikroRNA'ların anlaşılması, değerlendirilmesi, hedef tahmininin yapılması çok daha kolay bir hal almıştır. mikroRNA hedef tahmini yapmak için geliştirilmiş birçok araç bulunmaktadır. Bir üstteki bölümde kısaca değinilen bu araçların büyük bir kısmı makine öğrenmesi tekniklerini kullanmaktadır.

Makine öğrenmesi genel olarak; sistemlere deneyim yoluyla otomatik olarak iyileştirme sağlayan bir yapay zeka uygulamasıdır; örnek veri setlerinden "öğrenir" ve elde edilen bilgileri bilinmeyen veriler üzerinde tahminler yapmak için kullanır (Bishop vd., 2006). Makine öğrenmesi ile hedef tahmininde; dizi özelliklerinden yol çıkarak "de novo" tahminler yapmaktan ziyade, kanıtlanmış biyolojik öneme sahip mikroRNA-mRNA çiftlerini referans alan yöntem kullanılır (Riolo vd., 2020).

Mikrodizi araştırmalarında elde edilen veri kümesi, ham haliyle henüz kullanılabilir durumda değildir. Bu veriler üzerinde

yine makine öğrenmesi teknolojileri ile ön hazırlık adımları uygulanmaktadır. Mikrodizi tabanlı mikroRNA hedef tahmininde makine öğrenmesinin kullanılmasında genel olarak aşağıdaki adımlar uygulanmaktadır:

Şekil 1. Adım Adım mikroRNA Hedef Tahmini



mikroRNA hedef tahmini için daha önce hazırlanmış araçlar kullanılabileceği gibi R (2022, Ağustos 10. <https://www.r-project.org/>), Python (2022, Ağustos 10. <https://www.python.org/>) gibi programlama dilleri ve uygun kütüphaneleri yardımıyla da ilerlenebilir. Hazır araçlar belli

verisetlerini (örneğin bitki mikroRNA'sı için hazırlanmış bir araç insan verisi için başarılı olmayacaktır) kabul edebilmektedir. R programlama dili mikroRNA hedef tahmini için mikrodizi verileri ile çalışmaya uygun birçok kütüphane içermektedir. Özellikle Bioconductor (2022, Ağustos 10. <https://www.bioconductor.org/>) paketi ile mikroRNA verileri üzerinde çalışmalar yapılması yaygın olarak tercih edilmektedir.

3. Sonuç

mikroRNA'lar önemli gen düzenleyicilerdir. mRNA ile etkileşime girerek protein kodlanmasına engel olurlar. Birçok kanser türünün oluşma sebebinin mikroRNA'lar olduğu düşünülmektedir. mikroRNA'ların daha iyi anlaşılması ve hedef gen tahminlerinin yapılması hastalıkların tedavisi ve önlenmesi süreçlerinde büyük öneme sahiptir. Bilgisayar teknolojisi ve makine öğrenmesi teknikleri ile mikroRNA'lar her geçen gün daha fazla anlaşılmaktadır. Bu alanda yapılan çalışmalara ait verilerin ve uygulamaların birçoğunun açık paylaşımında olması süreci olumlu yönde etkilemektedir.

Bu araştırma çalışmasında mikroRNA'lar ile ilgili temel bilgiler verilmeye çalışılmış, açık veri tabanları, hedef tahmin araçları gibi bilgiler genel bir perspektiften değerlendirilerek bu alanda çalışmaya yapmak isteyen araştırmacıların hizmetine sunulmuştur. Makine öğrenmesinin bu alanda kullanılması klasik yöntemler ile sonuç alınmasının mümkün olmadığı veya çok uzun zaman alabilecek çalışmaların daha hızlı ve başarılı şekilde tamamlanmasını sağlamıştır. Makine öğrenmesi yardımıyla birçok hedef tahmini yapılabilmektedir. mikroRNA'lar keşfedilmeye devam eden RNA'lardır. Makine öğrenmesi kullanılarak bu alanda birçok yeni çalışma yapılması ve yeni tespitler mümkün olabilecektir. Yapılacak yeni çalışmalar ile mikroRNA ile ilgili bilgilerin daha da netleşmesi ve olumlu sonuçlar alınması beklenmektedir.

Kaynakça

Maziere, P., & Enright, A.J. (2007). Prediction of microRNA targets. *Drug Discovery Today*. 12(11712):452-458.

Karagün, B.Ş., Antmen, B., Şaşmaz, İ., & Kılınc, Y. (2014). Mikro RNA ve Kanser. *Türk Klinik Biyokimya Dergisi*. 12(1):45-56.

(2021, Mart 27). <https://www.affymetrix.com/>

(2021, Mart 27). <https://www.illumina.com/>

(2021, Mart 27). <https://www.agilent.com/>

(2021, Mart 27). <http://www.exiqon.com/>

Jiang, H., Wang, J., Li, M., Lan, W., Wu, F.X., & Pan, Yi. (2015). miRTRS: A Recommendation Algorithm for Predicting miRNA Targets. *Journal of Latex Class Files*. 14(8):1-10.

Kim, S., Choi, M., & Cho, K.H. (2009). Identifying the Target mRNAs of microRNAs in Colorectal Cancer. *Computational Biology and Chemistry*. 33(1):94-99.

Lu, Y., Zhou, Y., Qu, W., Deng, M., & Zhang, C. (2011). A Lasso Regression Model for the Construction of microRNA-Target Regulatory Networks. *Bioinformatics*. 27(17):2406-2413.

Sedaghat, N., Fathy, M., Modarressi, M.H., & Shojaie, A. (2018). Combining Supervised and Unsupervised Learning for Improved miRNA Target Prediction. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*. 15(5):1594-1604.

Van der Auwera, I., Limame, R., Van Dam, P., Vermeulen, P., Dirix, L., & Van Laere, S. (2010). Integrated miRNA and

mRNA Expression Profiling of the Inflammatory Breast Cancer Subtype. *British J. Cancer*. 103(4):532-541.

Liu, H., Brannon, A.R., Reddy, A.R., Alexe, G., Seiler, M.W., Arreola, A., Oza, J.H., Yao, M., Juan, D., Liou, L.S., Ganesan, S., Levine, A.J., Rathmell, W.K., & Bhanot, G.V. (2010). Identifying mRNA Targets of microRNA Dysregulated in Cancer: with Application to Clear Cell Renal Cell Carcinoma. *BMC Syst. Biology*. 4(1):51

Sales, G., Coppe, A., Bisognin, A., Biasiolo, M., Bortoluzzi, S., & Romualdi, C. (2010). MAGIA, a Web-Based Tool for miRNA and Genes Integrated Analysis. *Nucleic Acids Res*. 38(2):352-359.

Muniategui, A., Nogales-Cadenas, R., Vázquez, M., Aranguren, X. L., Agirre, X., Luttun, A., Prosper, F., Pascual-Montano, A., & Rubio, A. (2012). Quantification of miRNA-mRNA interactions. *PLoS one*. 7(2):1-10.

Rabiee-Ghahfarrokhi, B., Rafiei, F., Niknafs, A. A., & Zamani, B. (2015). Prediction of microRNA target genes using an efficient genetic algorithm-based decision tree. *FEBS open bio*. 5:877-884.

Abdelhadi Ep Souki, O., Day, L., Albrecht, A.A., & Steinhöfel, K. (2015). microRNA Target Prediction Based Upon Metastable RNA Secondary Structures. *Bioinformatics and Biomedical Engineering*. 2:456-467

SaeTrom, O. L. A., Snøve, O., & Sætrom, P. (2005). Weighted Sequence Motifs as an Improved Seeding Step in microRNA Target Prediction Algorithms. *RNA*. 11(7):995-1003.

Bandyopadhyay, S., & Mitra, R. (2009). TargetMiner: microRNA Target Prediction with Systematic Identification of Tissue-Specific Negative Examples. *Bioinformatics*. 25(20):2625-2631.

Yousef, M., Jung, S., Kossenkov, A. V., Showe, L. C., & Showe, M. K. (2007). Naïve Bayes for microRNA target predictions—machine learning for microRNA targets. *Bioinformatics*. 23(22):2987-2992.

Reyes-Herrera, P. H., Ficarra, E., Acquaviva, A., & Macii, E. (2011). miREE: miRNA recognition elements ensemble. *Bmc Bioinformatics*. 12(1):1-20.

Öztemur, Y., Aydos, A., & GÜR-DEDEOĞLU, B. (2014). Meme kanseri mikrodizin verilerinin biyoinformatik yöntemler ile bir araya getirilmesi-Meta-analiz yaklaşımları. *Türk Hijyen ve Deneysel Biyoloji Dergisi*. 72(2):155-162.

Brazma, A., Hingamp, P., Quackenbush, J., Sherlock, G., Spellman, P., Stoeckert, C., ... & Vingron, M. (2001). Minimum information about a microarray experiment (MIAME)—toward standards for microarray data. *Nature genetics*. 29(4):365-371.

(2022, Mart 8). <https://www.ncbi.nlm.nih.gov/geo/>

(2022, Mart 8). <https://www.ebi.ac.uk/arrayexpress/>

(2022, Mart 8). <https://datamed.org/>

Marry, K.V. (2005). Small RNAs: Classification, Biogenesis, and Function. *Mol Celss*. 19(1):1-15.

Chen, X., & Yan, G. Y. (2014). Semi-supervised learning for potential human microRNA-disease associations inference. *Scientific reports*. 4(1):1-10.

Peterson, S. M., Thompson, J. A., Ufkin, M. L., Sathyanarayana, P., Liaw, L., & Congdon, C. B. (2014). Common features of microRNA target prediction tools. *Frontiers in genetics*. 5:23.

Mathelier, A., & Carbone, A. (2010). MIRENA: finding microRNAs with high accuracy and no learning at genome scale and from deep sequencing data. *Bioinformatics*. 26(18):2226-2234.

- Saydam, F., Değirmenci, İ., & Güneş, H. V. (2011). MikroRNA'lar ve kanser. *Dicle Tıp Dergisi*. 38(1).
- Kwak, P. B., Iwasaki, S., & Tomari, Y. (2010). The microRNA pathway and cancer. *Cancer science*. 101(11):2309-2315. (2022, Kasım 21). <https://www.cancer.gov/>
- (2022, Ocak 12). <https://dcc.icgc.org/>
- (2022, Haziran 19). <http://www.targetscan.org/>
- (2022, Haziran 19). <http://mirwalk.umm.uni-heidelberg.de>
- (2022, Haziran 19). <http://www.mirbase.org/>
- (2022, Haziran 19). <http://www.disgenet.org/>
- (2022, Haziran 19). <http://www.cuilab.cn/hmdd>
- Riolo, G., Cantara, S., Marzocchi, C., & Ricci, C. (2020). miRNA targets: from prediction tools to experimental validation. *Methods and protocols*. 4(1):1-20.
- Sturm, M., Hackenberg, M., Langenberger, D., & Frishman, D. (2010). TargetSpy: a supervised machine learning approach for microRNA target prediction. *BMC bioinformatics*. 11(1):1-17.
- Betel, D., Koppal, A., Agius, P., Sander, C., & Leslie, C. (2010). Comprehensive modeling of microRNA targets predicts functional non-conserved and non-canonical sites. *Genome Biology*. 11(8):1-14.
- Gudyś, A., Szcześniak, M. W., Sikora, M., & Makałowska, I. (2013). HuntMi: an efficient and taxon-specific approach in pre-miRNA identification. *BMC Bioinformatics*. 14(1):1-10.
- Coronnello, C., & Benos, P. V. (2013). ComiR: combinatorial microRNA target prediction tool. *Nucleic Acids Research*. 41(1):159-164.
- Mendoza, M. R., da Fonseca, G. C., Loss-Morais, G., Alves, R., Margis, R., & Bazzan, A. L. (2013). RFMirTarget: predicting human microRNA target genes with a random forest classifier. *PLoS One*. 8(7):1-18.
- Zou, Q., Mao, Y., Hu, L., Wu, Y., & Ji, Z. (2014). miRClassify: an advanced web server for miRNA family classification and annotation. *Computers in Biology and Medicine*. 45(1):157-160.
- Holec, M., Gologuzov, V., & Kléma, J. (2014). miXGENE tool for learning from heterogeneous gene expression data using prior knowledge. *IEEE 27th International Symposium on Computer-Based Medical Systems*. 247-250.
- Menor, M., Ching, T., Zhu, X., Garmire, D., & Garmire, L. X. (2014). mirMark: a site-level and UTR-level classifier for miRNA target prediction. *Genome Biology*. 15(10):1-16.
- Wang, C. Y., Hu, L., Guo, M. Z., Liu, X. Y., & Zou, Q. (2015). imDC: an ensemble learning method for imbalanced classification with miRNA data. *Genetics and Molecular Research*. 14(1):123-133.
- Bandyopadhyay, S., Ghosh, D., Mitra, R., & Zhao, Z. (2015). MBSTAR: multiple instance learning for predicting specific functional binding sites in microRNA targets. *Scientific Reports*. 5(1):1-12.
- Karathanou, K., Theofilatos, K., Klefogiannis, D., Alexakos, C., Likothanassis, S., Tsakalidis, A., & Mavroudi, S. (2015). ncRNAclass: A web platform for non-coding RNA feature calculation and microRNAs and targets prediction. *International Journal on Artificial Intelligence Tools*. 24(01):1-17.
- Cui, H., Zhai, J., & Ma, C. (2015). miRLocator: machine learning-based prediction of mature microRNAs within plant pre-miRNA sequences. *PLoS One*. 10(11):1-15.
- Kim, M. S., Hur, B., & Kim, S. (2016, January). RDDpred: a condition-specific RNA-editing prediction model from RNA-seq data. *BMC Genomics*. 17(1):85-95.
- Pian, C., Zhang, J., Chen, Y. Y., Chen, Z., Li, Q., Li, Q., & Zhang, L. Y. (2016). OP-Triplet-ELM: Identification of real and pseudo microRNA precursors using extreme learning machine with optimal features. *Journal of Bioinformatics and Computational Biology*. 14(01):1-14.
- Ding, J., Li, X., & Hu, H. (2016). TarPmiR: a new approach for microRNA target site prediction. *Bioinformatics*. 32(18):2768-2775.
- Cheng, S., Guo, M., Wang, C., Liu, X., Liu, Y., & Wu, X. (2015). MiRTDL: a deep learning approach for miRNA target prediction. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*. 13(6):1161-1169.
- Marques, Y. B., de Paiva Oliveira, A., Ribeiro Vasconcelos, A. T., & Cerqueira, F. R. (2016). Mirnacle: machine learning with SMOTE and random forest for improving selectivity in pre-miRNA ab initio prediction. *BMC Bioinformatics*. 17(18):53-63.
- Cava, C., Colaprico, A., Bertoli, G., Graudenzi, A., Silva, T. C., Olsen, C., ... & Castiglioni, I. (2017). SpidermiR: an R/bioconductor package for integrative analysis with miRNA data. *International Journal of Molecular Sciences*. 18(2):1-14.
- Thomas, J., Thomas, S., & Sael, L. (2017, February). DP-miRNA: An improved prediction of precursor microRNA using deep learning model. *IEEE International Conference on Big Data and Smart Computing (BigComp)*. 96-99.
- Saçar Demirci, M. D., Baumbach, J., & Allmer, J. (2017). On the performance of pre-microRNA detection algorithms. *Nature Communications*. 8(1):1-9.
- Vitsios, D. M., Kentepozidou, E., Quintais, L., Benito-Gutiérrez, E., Van Dongen, S., Davis, M. P., & Enright, A. J. (2017). Mirnovo: genome-free prediction of microRNAs from small RNA sequencing data and single-cells using decision forests. *Nucleic Acids Research*. 45(21):1-11.
- Tseng, K. C., Chiang-Hsieh, Y. F., Pai, H., Chow, C. N., Lee, S. C., Zheng, H. Q., ... & Chang, W. C. (2018). microRPM: a microRNA prediction model based only on plant small RNA sequencing data. *Bioinformatics*. 34(7):1108-1115.
- Wen, M., Cong, P., Zhang, Z., Lu, H., & Li, T. (2018). DeepMirTar: a deep-learning approach for predicting human miRNA targets. *Bioinformatics*. 34(22):3781-3787.
- Ghoshal, A., Zhang, J., Roth, M. A., Xia, K. M., Grama, A. Y., & Chatterji, S. (2018). A distributed classifier for microRNA target prediction with validation through tcga expression data. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*. 15(4):1037-1051.
- Maji, R. K., Khatua, S., & Ghosh, Z. (2018). A supervised ensemble approach for sensitive microRNA target prediction. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*. 17(1):37-46.
- Song, F., Cui, C., Gao, L., & Cui, Q. (2019). miES: predicting the essentiality of miRNAs with machine learning and sequence features. *Bioinformatics*. 35(6):1053-1054.
- El-Manzalawy, Y., Hsieh, T. Y., Shivakumar, M., Kim, D., & Honavar, V. (2018). Min-redundancy and max-relevance multi-view feature selection for predicting ovarian cancer survival using multi-omics data. *BMC Medical Genomics*. 11(3):19-31.
- Jiang, H., Wang, J., Li, M., Lan, W., Wu, F. X., & Pan, Y. (2018). miRTRS: a recommendation algorithm for predicting miRNA targets. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*. 17(3):1032-1041.

Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern Recognition and Machine Learning* (Vol. 4, No. 4, p. 738). New York: Springer.

(2022, Ađustos 10). <https://www.r-project.org/>

(2022, Ađustos 10). <https://www.python.org/>

(2022, Ađustos 10). <https://www.bioconductor.org/>



Design and Simulation of a PID Neural Network Controller for PMDC Motor Speed and Position Control

Rahaf Sheikh Debes^{1*}, Tolgay Kara²

¹ Gaziantep University, Department of Electrical and Electronics Engineering, Gaziantep, Turkey, (ORCID: 0000-0002-5707-4719), rahaf.shiekh.debes@gmail.com

² Gaziantep University, Department of Electrical and Electronics Engineering, Gaziantep, Turkey, (ORCID: 0000-0003-3991-8524), kara@gantep.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies– 8-10 December 2022)

(DOI: 10.31590/ejosat.1222247)

ATIF/REFERENCE: Debes, R., S. & Kara, T. (2022). Design and Simulation of a PID Neural Network Controller for PMDC Motor Speed and Position Control. *European Journal of Science and Technology*, (44), 46-50.

Abstract

Direct current (DC) motors have many difficulties when controlling angular velocity in a variety of applications. The perfect controller cannot be carried out by traditional control alone due to the nonlinear properties of DC motors, design constraints, and mechanical variations caused by the operation conditions. This study proposes a design for an artificial neural network based PID controller (ANNPID) to control the speed of a permanent magnet DC motor (PMD) in two methods. A detailed analysis is performed based on the simulation results of both methods. The proposed controllers are numerically simulated for various test conditions including; set-point changes, step changes in the load torque, and parameter variations, then the suggested techniques were compared in a comparative study with a traditional PID controller based on the transient response specifications and the performance indices to validate the performance of the controllers. The simulation results demonstrated that the controllers have improved dynamics, static performance, and less overshoot. The methods described here achieve control more effectively than the conventional control approaches under both nominal and disturbed test conditions over different operating ranges.

Keywords: PMDC motor, PID, Artificial neural network (ANN), ANNPID, transient response.

SMDA Motorun Hız ve Konum Kontrolü için PID Sınır Ağı Denetleyicinin Tasarım ve Benzetimi

Öz

Doğru akım (DA) motorları, çeşitli uygulamalarda açısal hız kontrol edilirken birçok zorluk içerir. DA motorların doğrusal olmayan özellikleri, tasarım kısıtlamaları ve çalışma koşullarından kaynaklanan mekanik varyasyon nedeniyle mükemmel kontrol tek başına geleneksel kontrol yöntemleri ile gerçekleştirilemez. Bu çalışma, sabit miktatıslı bir DA (SMDA) motorun hızını iki yöntemle kontrol etmek için yapay sinir ağı tabanlı bir PID denetleyici tasarımı önermektedir. Her iki yöntemin benzetim sonuçlarına dayalı olarak detaylı bir analiz yapılmıştır. Önerilen denetleyiciler, ayar noktası değişiklikleri, yük torkundaki adım değişiklikleri ve parametre varyasyonları dahil olmak üzere çeşitli test koşulları için sayısal olarak simüle edilmiştir; ardından önerilen teknikler, denetleyicilerin başarımını doğrulamak için geçici tepki özelliklerine ve başarım endekslerine dayalı olarak geleneksel bir PID denetleyici ile karşılaştırılmıştır. Benzetim sonuçları, denetleyicilerin iyileştirilmiş dinamiklere, iyileştirilmiş statik performansa ve daha az en büyük aşmaya sahip olduğunu göstermiştir. Burada açıklanan yöntemler, farklı çalışma aralıklarında hem nominal hem de bozulmuş test koşulları altında geleneksel kontrol yaklaşımlarından daha etkili bir şekilde kontrol sağlamıştır.

Anahtar Kelimeler: SMDA motor, PID Denetleyici, Yapay sinir ağları (YSA), YSA-PID, Geçici tepki.

* Corresponding Author: rahaf.shiekh.debes@gmail.com

1. Introduction

DC drives have historically been the backbone of applications that demand precise speed and position control, including robot manipulators and home appliances, because of their low complexity, excellent reliability, adaptability, and attractive cost (Bansal, 2013). The motor should be accurately controlled to provide the desired result, thus the speed controller must carry out a variety of functions under a wide range of load conditions. Efficient motor drive development is crucial for many applications in industry. Control's main goal is to improve the model's performance and enable reliable operation. Although direct, easy, and reliable control is possible using a conventional control algorithm (PID), it is, however, have some drawbacks. A major problem in applying PID to speed controllers is the nonlinearity effects of DC motors. DC motors' nonlinear properties, such as friction and saturation, can affect the conventional controllers' performance. In some control systems, it can be hard to adjust the three PID controller K_P , K_I and K_D parameters. The traditional PID controller, which is applied in nonlinear, time-varying, uncertainties, or large inertia systems, will not be very effective. It can produce a high starting current that might be harmful to the motor's control electronics, etc., so the need for intelligent control arises.

The last decade has witnessed a rapid acceleration in control and automation and the emergence of intelligent controller which is a type of control system that employs different computing techniques with artificial intelligence such as self-tuning regulators, artificial neural networks (ANN), variable structure control (VSC), sliding mode control (SMC), and model reference adaptive control (MRAC). There is currently a strong interest in control science and practice for integrating classical automated control methods with artificial intelligence methods to control complex and weakly formalized objects and processes (Vassilyev et al, 2017), such as artificial neural networks (ANN) with conventional methods that are capable of eliminating system nonlinearity, the impacts of parameter variations, unanticipated changes in load, and system disturbance. The distributed and inherent parallel design of an ANN can be effectively exploited in order to control electric motors. Without being knowledgeable of any predefined model, the use of ANN can give a nonlinear mapping between an electric drive system's inputs and outputs. As a result, the application of an ANN to superior performance motor drives will make the system more reliable, effective, and resistant to undesirable conditions of operation. Although the Artificial neural network's historical development dates go back to 1943, the utilization of the neural network for control systems is relatively recent. Antonio E. B. Ruano (1992) presented the artificial neural networks' usefulness for control systems and their ability to implement nonlinear mappings. On the other hand, there was a lot of research on controlling the speed of DC motors with different algorithms. A PI (Proportional integral) controller and FL (fuzzy logic) controller are used for controlling the speed of the PMDC motor (Tuna, 2015). A Fuzzy controller compared to the PI had an improved variable speed load control performance. Guzin et al (2015) presented a comparison of several tuning approaches for cascade Proportional Integral (Derivative) parameters of the controller for the (PMDC) motor drives. Cozma et al (2008) presented a control system depending on ANN and PID controllers for permanent magnet DC motor drives. Through a variety of auto-tuning techniques, the system offers an automatic assessment of the PID controller's variables. The employed neural

controller is learned offline with data acquired from the system's experiments. The main challenge was to create a structure that could give the highest sample rate and the lowest time of response. Muthusamy et al (2012) presented a PMDC drive in a closed loop control by an inner controller of current and an outside PID with an ANN-based speed controller. A NABSC (neuro adaptive backstepping control) technique using Chebyshev polynomial with a single-layer based neural network is presented for the tracking of angular velocity for a permanent magnet dc motor which is feeding with a buck converter (Nizami et al, 2017). A novel adaptive backstepping control technique that integrates a single functional layer Legendre neural network into the DC-DC step down converter for a permanent magnet DC motor system is also presented (Gangula et al, 2022). The standard method for modeling a DC motor is to ignore the effects of nonlinearity and create a representation of the linear transfer function for the relationship between the input output characteristics of the direct current motor and the load it powers. This assumption is adequate and valid for classical control problems. However, if the DC motor slowly operates and rotates in both directions, or if the operating range is wide and the application requires high precision control, assuming the effects of nonlinearity on the system are negligible leads to intolerable, increasing modeling errors and degraded control performance, therefore, there are many studies involving nonlinearity in DC motor modeling (Liu et al, 2013; Ahmad, 2011). An intelligent control system composed of two different neural network controllers for PMDC motor that can deal with the system's nonlinearities and load changes to reach high efficiency of the overall system and improve its performance is presented. The analysis, design, and simulation of the proposed controllers are described. Good and robust control performance is achieved. This work is divided into four sections. Section 1 presents an introduction and related investigations. The Material and method was exhibited in Section 2. Section 3 describes the results and discussion. Finally, the conclusions based on this research are shown in part 4.

2. Material and Method

2.1. PMDC motor modeling

The DC motor used for this study is PMDC, which controls the speed by armature voltage control method. We aim in building the mathematical model for the PMDC motor to model and simulate it and to link the voltage provided to the armature to the motor's velocity, we use the system's mechanical and electrical dynamics as in (1-2),

$$\frac{di_a}{dt} = \frac{v}{L} - \frac{R_a}{L} i_a - \frac{K_v}{L} \omega_m \quad (1)$$

$$\frac{d\omega_m}{dt} = \frac{T_L}{j} + \frac{K_t}{j} i_a - \frac{B}{j} \omega_m \quad (2)$$

Where v is the voltage source, R_a is the armature resistance, i_a is the armature current, ω_m is the angular speed, L is the inductance of armature, B is the damping coefficient, K_v is the velocity constant, K_t is the torque constant, j is the inertia of the rotor, and T_L is the torque of the mechanical load. The following equations (3-4) describe the transfer functions of the motor,

$$I_a(s) = \frac{-K_v \omega_m(s) + v(s)}{L_a s + R_a} \quad (3)$$

$$\omega_m(s) = \frac{-K_t I_a(s) - T_L(s)}{j s + B} \quad (4)$$




Figure 1. Nonlinear simulation model of PMDC motor.

The parameters of the PMDC motor are in the Appendix. The assumption that the nonlinear effects on the system are negligible may result in poor control performance, so we design the control system by taking into consideration all the nonlinearities as a backlash, dead-zone, and friction (Gómez et al, 2020). The simulation model of the system with nonlinearities is presented in Figure 1.

The following Figure represents the response of the system in an open loop.




Figure 2. Open loop response of nonlinear model of PMDC motor.

We notice here there is a big overshoot in the curve that is undesirable, so, it is crucial to design a speed controller of the DC motor at different desired speeds.

2.2. Design of PID controller

Proportional Integral Derivative (PID) control is one of the earliest control strategies used in all fields where closed-loop control is applied. It produces a control depending on an error signal.

$$u(t) = K_p e(t) + K_I \int e(t) + K_D \frac{de}{dt} \quad (5)$$

The weighted total of all these gains is used to change the process via controlling. We can tune the three constants of the PID controller algorithm to meet our specific operational needs. By tuning of PID Controller by Zeigler Nichols and after some other tunings we will fix the values of the PID parameters as $K_p = 35$, $K_I = 260$, $K_D = 0.05$.

2.3. Design and structure of ANN- PID controller

The study of neural networks in control systems to enhance the degree of automated processes and the economy's effectiveness of industry is of great importance. The error between the system output and predicted values can be minimized by using neural network PID controllers in place of conventional PID controllers. We have designed the controller in two different ways depending on the inputs, outputs, and structure of the neural network.

2.3.1. First controller

The first controller tested in the study is made up of a classic PID controller plus a neural controller, which we denote as ANNPID1 in short. It incorporates the advantages of neural and PID controllers. Traditional PID directly regulates the controlled

object using a closed loop, while neural networks adjust their control gains K_D , K_I and K_p based on the system's operational condition to achieve performance optimization. The model of the ANNPID1 controller with PMDC motor is shown in the Fig 3.




Figure 3. ANNPID1 control system block diagram.

The inputs of the controller are the reference speed, the error signal, and the output signal. Where the outputs of the controller are: Derivative gain K_D , Integral gain K_I , and proportional gain K_p . The function fitting is performed using a feedforward network with two-layer, whereas the transfer functions that we used are a linear transfer function, and a tan sigmoid transfer function for the output layer, and the hidden layer. The structure of this network is 3-10-3. The data are gathered from the traditional PID controller's closed loop response and were used to constitute a database to train the NN. We use a repeating sequence signal as a reference signal which has the sequence values of [0 300 300 300 -300 -300].

2.3.2. Second controller

The second controller which is denoted as ANNPID2 mimics a PID controller. It is designed to generate a control signal that is utilized to control the velocity of the PMDC motor. Three inputs are fed into the controller to generate a single output. The structure of ANNPID2 is depicted in Figure 4.




Figure 4. ANNPID2 controller model.

The inputs of the controller are the error signal between reference speed and actual value, the integration of the error signal, and the derivative of the error signal. Where the controller output is the control signal of the PMDC. The function fitting is also here performed using a feedforward network with two-layer, whereas the transfer functions that we used are a linear transfer function, and a tan sigmoid transfer function for the output layer, and the hidden layer. The structure of this network is 3-15-1.

3. Results and Discussion

In this work, the performance of a PMDC motor with different control strategies, two artificial neural networks, and conventional PID is evaluated on the basis of rise time t_r , settling time t_s , and maximum overshoot M_p . Three testing scenarios are carried out, which are set-point changes, disturbance rejection,

and uncertainty rejection. Three different objective functions which are, Integral Square Error (ISE), Integral Absolute Error (IAE), and Integral of Time Weighted Absolute Error (ITAE) performance indices are calculated for each case in order to analyze the performance of each controller.




Figure 5. The response speed of the ANNPID1 (blue), ANNPID2 (purple), PID (green) with random reference speed input (red)

Table 1. Performance indices of PID, ANNPID1, ANNPID2 with random reference speed inputs

	PID	ANNPID1	ANNPID2
ISE	2.953	1.7	1.219
IAE	2.423	1.839	1.293
ITAE	14.02	7.312	5.483




Figure 6. The response speed of the second controller PID (purple), ANNPID1 (blue), ANNPID2 (green) with 270 rpm reference speed inputs (red) and [0 300 300 300 -300 -300]

Table 2. Transient Response Specification of PID, ANNPID1, ANNPID2 with disturbance

	PID	ANNPID1	ANNPID2
Rise time	0.2203	0.0808	0.1671
Settling time	9.3056	9.4040	9.3043
Overshoot	11.0627	10.0554	10.9446

Table 3. Performance indices of PID, ANNPID1, ANNPID2 with disturbance

	PID	ANNPID1	ANNPID2
ISE	3497	5730	2806
IAE	119	118.9	100.4
ITAE	560.6	560.8	472




Figure 7. The response speed of PID (blue), ANNPID1 (green), ANNPID2 (purple) with 300 rpm reference speed inputs (red) and change of parameters $B=1.5, J=0.01$

Table 4. Transient Response Specification of PID, ANNPID1, ANNPID2 with unit step reference input and change of parameter

	PID	ANNPID1	ANNPID2
Rise time	0.4078	0.1341	0.2908
Settling time	1.8243	1.6579	1.4866
Overshoot	3.7650e-04	3.3307e-13	3.3307e-13

Table 5. Performance indices of PID, ANNPID1 and ANNPID2 with unit step reference input and change of parameters

	PID	ANNPID1	ANNPID2
ISE	2907	6119	2333
IAE	38.12	37.41	27.04
ITAE	47.92	43.02	31.11

To test the robustness properties of PID, and ANN controllers to set point variations, we used a random reference signal. The output responses of PID, ANNPID1, and ANNPID2 with random reference are shown in Figure 5. The transient response specifications and performance indices of random reference input are represented in Table 1. The proposed ANNPID2 has the smallest values of all performance indices. While the ANNPID1 comes after it. PID controller has the worst values for performance indices.

In order to test the robustness of the designed controllers to disturbance inputs, a random load torque signal is used with a 270 reference speed. The output responses of PID, ANNPID1, and ANNPID2 with a step signal and a random load torque signal are given in Figure 6. The transient response specifications and performance indices with a random load torque t are represented in Table 2, Table 3. The proposed ANNPID2 has the smallest values of all performance indices. Where the ANNPID1 has the smallest value of rise time and overshoot.

To test the performance of presented controllers against the uncertainty rejection we have changed the value of B from 0.002 to 1.5 and the value of j from 0.00471 to 0.01. The output

responses of PID, ANNPID1, and ANNPID2 with a change of parameters are given in Figure 7. The transient response specifications and performance indices with a random load torque are represented in Table 4, Table 5. The two proposed controllers show improved performance for disturbance rejection. PID controller has smaller values for ISE than the ANNPID1.

4. Conclusions and Recommendations

This paper investigates the effectiveness of enhancing a controller design for a PMDC motor. The speed of the permanent magnet DC motor is controlled using the proposed ANN-based PID controller in two methods. The simulation model of the control system has been established based on an analysis of the mathematical model for the PMDC motor based on the electrical and mechanical equations for the PMDC. A nonlinear model of the PMDC motor is used. First, a PID controller is designed and the PID parameters are tuned using the Zeigler-Nichols method. Next, an ANN-based PID speed controller is designed. The performance of the proposed controllers is validated by subjecting the PMDC motor system to angular velocity tracking set points, load torque changes, and parameter variation tests, then several characteristics are studied, including the rise time, overshoot, settling time, and many performance indices that are all crucial for the development of the DC motor performance.

The results show that the speed control of the DC motor by an ANN-based PID has better performance, high resilience, and good accuracy without oscillation. In comparison to conventional approaches, the controller also demonstrates good efficiency when tracking the motor speed, successful rejection of load torque uncertainties, and parameter variations.

References

Bansal, U.K., & Narvey, R. (2013). Speed Control of DC Motor Using Fuzzy PID Controller, *Advance in Electronic and Electric Engineering* 3(9).1209-1220.

Antonio E. B. Ruano (1992). Applications of Neural Networks to Control Systems, *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*. University of Wales, Bangor.

Vassilyev, S.N., Kelina, A.Yu., Kudinov, Y.I., & Pashchenko, Fedor F. (2017). Intelligent Control Systems. *Procedia Computer Science*. 103. 623-628.

Tuna, M., Fidan, C. B., Kocabey, S., & Görgülü, S. (2015). Effective and Reliable Speed Control of Permanent Magnet DC (PMD) Motor under Variable Loads, *Journal of Electrical Engineering and Technology*. 10(5), 2170-2178.

Gücin, T. N., Biberöglü, M., Fincan, B., & Gülbağçe, M. O. (2015). Tuning cascade PI(D) controllers in PMDC motor drives: A performance comparison for different types of tuning methods, *Proceedings of the 9th International Conference on Electrical and Electronics Engineering (ELECO)* . 1061-1066.

Cozma, A., & Pitica, D. (2008). Artificial neural network and PID based control system for DC motor drives, *Proceedings of the 11th International Conference on Optimization of Electrical and Electronic Equipment*. 161-166.

Muthusamy, M., & Muruganandam. M. (2012). SIMULATION AND IMPLEMENTATION OF PID-ANN CONTROLLER FOR CHOPPER FED EMBEDDED

PMDC MOTOR. *ICTACT Journal on Soft Computing*. 2. 319-324.

Liu, L., Liu, Y.J., & Chen, C.L.P. (2013). Adaptive Neural Network Control for a DC Motor System with Dead-Zone, *Nonlinear Dyn* 72, 141–147.

Ahmad, N. J., Ebraheem, H. K., Alnaser, M. J., & Alostath, J. M. (2011). Adaptive control of a DC motor with uncertain deadzone nonlinearity at the input, *Chinese Control and Decision Conference (CCDC)*. 4295-4299.

Nizami, T. Khan., Chakravarty, A., & Mahanta, C. (2017). Design and implementation of a neuro-adaptive backstepping controller for buck converter fed PMDC-motor. *Control Engineering Practice*, 58. 78-87.

Nizami, T. K., Gangula, S. D., Reddy, R., & Dhiman H. S. (2022). Legendre Neural Network based Intelligent Control of DC-DC Step Down Converter-PMDC Motor Combination, *IFAC PapersOnLine* 55- . 162–167.

Gómez, C.A.P., Liceaga, J., & Alcalá, I.I.S. (2020). Hard Dead Zone and Friction Modeling and Identification of a Permanent Magnet DC Motor Non-Linear Model. *WSEAS TRANSACTIONS ON SYSTEMS AND CONTROL*. 15. 527-536.

Zhang, S., Zhou, X., & Yang, L. (2011). Adaptive PID regulator based on neural network for DC motor speed control, *2011 International Conference on Electrical and Control Engineering*. 1950-1953.

Kumar, N. S., Sadasivam, V., & Asan Sukriya, H. M. (2008) A Comparative Study of PI, Fuzzy, and ANN Controllers for Chopper-fed DC Drive with Embedded Systems Approach, *Electric Power Components and Systems*, 36:7, 680-695.

Yildiz, A.B., & Bilgin, M.Z. (2006). Speed Control of Averaged DC Motor Drive System by Using Neuro-PID Controller, *Knowledge-Based Intelligent Information and Engineering Systems*. 1075-1082.

Appendix

Parameter	Symbol	Value
<i>Armature Resistance</i>	R_a	0.5 Ω
<i>Armature Inductance</i>	L_a	0.012 H
<i>Inertia of the Rotor</i>	J	0.00471kg m ²
<i>Torque Constant</i>	K_t	0.5 Nm/A
<i>Velocity constant</i>	K_v	0.5 Vs/rad
<i>Damping Coefficient</i>	B	0.002 Nms/rad



Kaotik Denizatı Optimizasyon Algoritması

Feyza Altunbey Özbay^{1*}, Erdal Özbay²

^{1*} Fırat Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Elazığ, Türkiye, (ORCID: 0000-0003-0629-6888), faltunbey@firat.edu.tr

² Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye (ORCID: 0000-0002-9004-4802), erdalozbay@firat.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1216396)

ATIF/REFERENCE: Altunbey Özbay, F. & Özbay, E. (2022). Kaotik Denizatı Optimizasyon Algoritması. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 51-58.

Öz

Global optimizasyon teknikleri olarak bilinen metasezgisel algoritmalar, çeşitli karmaşık ve gerçek optimizasyon problemlerini çözmek için başarıyla kullanılmaktadır. Metasezgisel yöntemler, fizik, sürü zekâsı ve biyolojinin farklı ilkelerinden ilham almaktadır. Denizatı Optimizasyon Algoritması (DOA), denizatlarının doğadaki hareket, avlanma ve üreme davranışlarından esinlenerek önerilmiş sürü zekâsına tabanlı metasezgisel bir optimizasyon algoritmasıdır. Sürü zekâsına dayalı metasezgisel optimizasyon algoritmalarından daha hızlı ve yüksek doğrulukta yakınsama elde etmek için farklı yöntemler önerilmiştir. Bu çalışmada, DOA'nın yakınsama hızını artırmak ve yerel çözümlerde takılıp kalmasını engellemek için rastgele değerler yerine Chebyshev, Circle, Gauss, Iterative, Logistic, Piecewise ve Sine olmak üzere yedi farklı kaotik harita uygulanmıştır. İlk kez bu çalışmada önerilen Kaotik Denizatı Optimizasyon Algoritması (KDOA), tek modlu, çok modlu ve sabit boyutlu çok modlu olmak üzere yedi farklı kıyaslama fonksiyonuna uygulanmıştır. Önerilen KDOA'nın performansını değerlendirmek için klasik DOA karşılaştırılmıştır. Deneysel sonuçlara göre, KDOA'nın yedi farklı kıyaslama fonksiyonunda klasik DOA'ya göre daha iyi sonuçlar elde ettiği gözlemlenmiştir.

Anahtar Kelimeler: Denizatı optimizasyon algoritması, Kaotik haritalar, Metasezgisel algoritmalar, Optimizasyon.

Chaotic Seahorse Optimization Algorithm

Abstract

Metaheuristic algorithms, known as global optimization techniques, have been successfully used to solve a variety of complex and real optimization problems. Metaheuristic methods are inspired by different principles of physics, swarm intelligence, and biology. The Seahorse Optimization Algorithm (SOA) is a suggested swarm intelligence-based metaheuristic optimization algorithm inspired by the movement, hunting, and breeding behavior of seahorses in nature. Different methods have been proposed to achieve faster and higher accuracy convergence than metaheuristic optimization algorithms based on swarm intelligence. In this study, seven different chaotic maps, namely Chebyshev, Circle, Gauss, Iterative, Logistic, Piecewise, and Sine, were applied instead of random values in order to increase the convergence speed of SOA and to prevent it from getting stuck in local solutions. The Chaotic Seahorse Optimization Algorithm (CSOA), proposed for the first time in this study, has been applied to seven different benchmarking functions. Classic SOA was compared to evaluate the performance of the proposed CSOA. According to the experimental results, it was observed that CSOA achieved better results than classical SOA in seven different comparison functions.

Keywords: Seahorse optimization algorithm, Chaotic maps, Metaheuristic algorithms, Optimization.

* Sorumlu Yazar: faltunbey@firat.edu.tr

1. Giriş

Son yıllarda, mühendislik alanında çeşitli optimizasyon problemlerinin üstesinden gelmek için çok sayıda algoritma önerilmiştir (Onay & Aydemir, 2022). Bu optimizasyon problemleri, amaç fonksiyonunu optimize etmek için belirli koşullar altında birkaç parametrenin değerini belirlemektedir. Genel olarak amaç fonksiyonu, probleme dayalı olarak minimum veya maksimum bir çözüm sağlayan belirli bir özelliktir. Optimum çözüm elde edilirken çeşitli optimizasyon problemleri ortaya çıkmaktadır. Bu optimizasyon problemleri dinamik veya statik, sürekli veya ayırık, tek amaçlı veya çok amaçlı, kısıtlı veya kısıtsız olmak üzere çeşitli tiplere ayrılmaktadır. Bu nedenle, bu tür optimizasyon problemlerinin doğruluğunu ve verimliliğini artırmak için, birçok araştırmacı, kolay uygulanabilen, gradyan bilgisi gerektirmeyen ve yerel çözümlerden kaçınmak veya atlamak için metasezgisel algoritmalar önermiştir (Hassan, 2021).

Metasezgisel optimizasyon algoritmaları (MOA), gerçek dünya problemlerini çözmek için sıklıkla kullanılan optimizasyon yöntemleridir. Optimizasyon süreci ile, amaç fonksiyonunu minimize veya maksimize ederek bir problemin optimal karar değişkenlerini bulunmaktadır. Bu algoritmalar yüksek verimlilikleri ve düşük hesaplama karmaşıklıkları nedeniyle hem matematik hem mühendislik problemlerinin çözümünde de başarıyla kullanılmaktadır. MOA'lar keşif ve sömürü olmak üzere iki ana aşamadan oluşmaktadır. MOA'da en önemli durum bu iki aşama arasındaki dengedir (Kaveh & Mahdavi, 2014). Son 10 yılda, keşif ve sömürü aşamalarını dengelemek için fizik, sürü zekası ve biyolojiden esinlenerek birçok yeni MOA önerilmiştir. Örneğin; genetik algoritma, Darwin'in evrim teorisinden esinlenerek önerilmiştir (Holland, 1992). Diferansiyel evrim algoritması, genetik algoritmadaki mutasyon ve çaprazlama ile aynı operatörleri farklı bir yaklaşım ile kullanmaktadır (Storn & Price, 1997). Parçacık sürüsü optimizasyonu, kuşların ve balıkların yiyecek yakalamak için sergiledikleri sosyal davranışlarından ilham almıştır (Eberhart & Kennedy, 1995). Yapay arı kolonisi algoritması, bal arılarının bilgi paylaşım kabiliyetini ve yiyecek arama davranışını taklit etmektedir (Karaboga & Basturk, 2007). Gri kurt optimizasyon algoritması, doğadaki gri kurtların avlanma davranışından ilham alarak önerilmiştir (Mirjalili vd., 2014). Sinüs ve kosinüs algoritması, sinüs ve kosinüs fonksiyonları temelinde matematiksel bir fonksiyon kullanmaktadır (Mirjalili, 2016). Yerçekimi arama algoritması, yerçekimi ve hareket yasalarını kullanmaktadır (Rashedi vd., 2009). Yarasa algoritması, yarasalarda yer alan ekolokasyon davranışını taklit etmektedir (Yang, 2010). Atom arama optimizasyonu (ASO), atom dinamiklerine dayalı olarak doğadaki atomların hareketini taklit etmektedir (Zhao vd., 2019).

Bu çalışmada, Denizati Optimizasyon Algoritmasındaki (DOA) rastgele bir değişken yedi farklı kaotik harita ile kontrol edilerek yeni bir Kaotik Denizati Optimizasyon Algoritması (KDOA) geliştirilmiştir. Önerilen KDOA tek modlu, çok modlu ve sabit boyutlu çok modlu fonksiyonlar olmak üzere farklı kıyaslama problemleri üzerinde test edilmiştir. KDOA, kullanılan kıyaslama problemlerinde klasik DOA'dan daha iyi sonuçlar vermiştir.

Bu çalışmanın geri kalanı şu şekilde planlanmıştır: DOA hakkında bilgiler ikinci bölümde verilmiştir. Üçüncü bölümde kaos teorisine dayalı kaotik haritalar incelenmiştir ve önerilen KDOA açıklanmıştır. Dördüncü bölümde ise KDOA performansı

değerlendirilmiştir. Son bölümde, sonuçlar ve gelecek çalışmalar incelenmiştir.

2. Denizati Optimizasyon Algoritması

Denizati optimizasyon algoritması (DOA), temel olarak hareket, avlanma ve üreme olmak üzere üç önemli bileşenden meydana gelmektedir. DOA'nın keşfini ve kullanımını dengelemek adına geliştirilen yerel ve küresel arama stratejileri sırasıyla hareket ve yırtıcılığın sosyal davranışları için tasarlanmıştır. İlk iki bileşene ait davranışların tamamlanması halinde üreme davranışı gerçekleştirilmektedir. Bu bölümde DOA'nın matematiksel modelleri ayrıntılı olarak açıklanmaktadır (Zhao vd., 2022).

2.1. Başlatma

Çoğu MOA'da olduğu gibi DOA'da da bir başlangıç popülasyonu bulunmaktadır. Her bir denizatının, problemlerin arama uzayında bir aday çözümü temsil ettiklerini varsayarsak denizatlarının tüm popülasyonu Denklem 1'de verildiği şekilde ifade edilebilir (Zhao vd., 2022):

$$\text{Denizatları} = \begin{bmatrix} x_1^1 & \dots & x_1^{Dim} \\ \vdots & \ddots & \vdots \\ x_{pop}^1 & \dots & x_{pop}^{Dim} \end{bmatrix} \quad (1)$$

burada Dim değişkenin boyutunu, pop ise popülasyon boyutunu göstermektedir. Her bir çözüm, belirli bir problemin alt sınırı ve üst sınırı arasında sırasıyla AS ve US ile gösterildiği gibi rastgele oluşturulmaktadır. X_i^j 'nin i 'inci bireysel ifadesinin temsil edildiği arama uzayındaki $[AS, US]$ Denklem 2'de verildiği gibi hesaplanmaktadır:

$$X_i = [x_i^1, \dots, x_i^{Dim}] \\ x_i^j = \text{rast} \times (US^j - AS^j) + AS^j \quad (2)$$

burada $\text{rast} [0, 1]$ aralığında rastgele bir değeri göstermektedir. x_i^j , i . bireydeki j . boyutu ifade etmektedir. i , 1 ile pop arasında değişen pozitif bir tamsayıdır. j , $[1, Dim]$ aralığındaki pozitif bir tamsayı ile ifade edilmektedir. AS^j ve US^j , optimize edilmiş problemin j . değişkeninin alt sınırını ve üst sınırını ifade etmektedir. Minimum optimizasyon probleminin örnek alındığı minimum uygunluğa sahip olan birey, X_{elit} ile gösterilen elit birey olarak kabul edilmektedir. X_{elit} Denklem 3'te verildiği üzere elde edilmektedir (Zhao vd., 2022):

$$X_{elit} = \text{argmin} (f(X_i)) \quad (3)$$

burada $f(\cdot)$, verilen bir problemin amaç fonksiyonunun değerini temsil etmektedir.

2.2. Denizatinın Hareket Davranışları

İlk davranış için, denizatlarının farklı hareket kalıpları yaklaşık olarak rast (0, 1) normal dağılımını takip etmektedir. Keşif ve sömürü performansından ödün vermemek adına, kesme noktası olarak belirlenen $r_1 = 0$ ifadesinin yarısı yerel arama ve diğer yarısı küresel arama için alınmaktadır. Dolayısıyla hareketler iki duruma ayrılarak tanımlanmıştır (Zhao vd., 2022):

Durum-1: Denizdeki girdap olayı ile birlikte denizatının yaptığı sarmal hareket olarak tanımlanmıştır. Rastgele normal değer r_1 kesme noktasının sağ tarafında bulunduğu, esas olarak DOA'nın yerel kullanımını gerçekleştirmektedir. Denizatları spiral hareketi takip ederek elite X_{elit} doğru ilerlemektedir. Özellikle, Lévy uçuşu, denizatlarının erken iterasyonlarda diğer pozisyonlara geçme olasılığı yüksek olan ve DOA'nın aşırı yerel

sömürsünden kaçınan denizatlarının hareket adım boyutunu simüle etmek için kullanılmaktadır (Mantegna, 1994). Aynı zamanda, denizatının bu spiral hareket modu, mevcut yerel çözümlerin komşuluklarını genişletmek için dönme açısını sürekli olarak değiştirmektedir. Bu durumda denizatının yeni konumu matematiksel olarak şöyle ifade edilmiştir:

$$X_{yeni}^1(t+1) = X_i(t) + Levy(\lambda)((X_{elit}(t) - X_i(t)) \times x \times y \times z + X_{elit}(t)) \quad (4)$$

burada $x=\rho \times \cos(\theta)$, $y=\rho \times \sin(\theta)$ ve $z=\rho \times \theta$, arama ajanlarının pozisyonlarının güncellenmesine yardımcı olan sırasıyla sarmal hareket altındaki koordinatların (x, y, z) üç boyutlu bileşenlerini göstermektedir. $\rho=u \times e^{\theta v}$ logaritmik spiral sabitleri u ve v tarafından tanımlanan gövdelerin uzunluğunu temsil etmektedir ($u=0,05$ ve $v=0,05$ olarak ayarlanmıştır). θ , $[0, 2\pi]$ aralığında rastgele bir değer olarak tanımlıdır. Lévy(z), Lévy uçuş dağılım fonksiyonudur ve Denklem 5'te verildiği gibi hesaplanmaktadır (Mantegna, 1994):

$$Levy(z) = s \times \frac{k \times \sigma}{|w|^{\frac{1}{\lambda}}} \quad (5)$$

burada λ , $[0, 2]$ aralığında tanımlı rastgele bir sayıdır (çalışmada $\lambda = 1,5$ olarak belirlenmiştir). s , 0,01 olarak tanımlanmış sabit bir değerdir. k ve w $[0, 1]$ aralığında rastgele sayılardır. σ Denklem 6'da verildiği şekilde hesaplanmaktadır:

$$\sigma = \frac{\Gamma(1 + \lambda) \times \sin\left(\frac{\pi \lambda}{2}\right)}{\Gamma\left(\frac{1+\lambda}{2}\right) \times \lambda \times 2^{\left(\frac{\lambda-1}{2}\right)}} \quad (6)$$

Durum-2: Denizatının deniz dalgaları ile birlikte yaptığı Brownian hareketi olarak tanımlanmıştır. Sürüklenme eylemi altında, r_1 kesme noktasının sol tarafında bulunduğu DOA'nın keşfi gerçekleştirilmektedir. Bu durumda, arama işlemi DOA'nın yerel ekstremumdan kaçınması için önemlidir. Arama uzayında daha iyi bir keşfi sağlamak adına denizatının başka bir hareketli uzunluğunu taklit etmek için Brownian hareketi uygulanmaktadır. Bu durumun matematiksel ifadesi Denklem 7'de verilmiştir:

$$X_{yeni}^1(t+1) = X_i(t) + rast * l * \beta_t * (X_i(t) - \beta_t * X_{elit}) \quad (7)$$

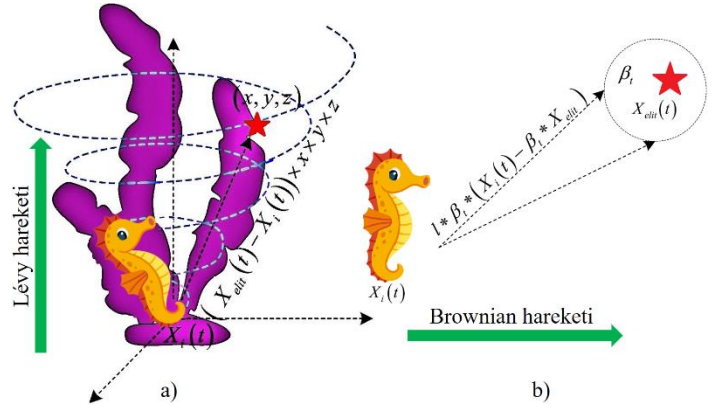
burada l sabit katsayıdır (çalışmada $l=0,05$ olarak belirlenmiştir). β_t , rastgele bir değer olarak standart normal dağılıma uyan Brownian hareketinin rastgele yürüyüş katsayısıdır ve Denklem 8'de verildiği gibi hesaplanmaktadır (Einstein, 1956):

$$\beta_t = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right) \quad (8)$$

Genel olarak bu iki durumun toplamında, denizatının t iterasyonundaki yeni konumunun elde edilmesinde Denklem 9'da verilen formül uygulanmaktadır:

$$= \begin{cases} X_{yeni}^1(t+1) \\ X_i(t) + Levy(\lambda) \\ \left((X_{elit}(t) - X_i(t)) \times x \times y \times z + X_{elit}(t) \right) r_1 > 0 \\ X_i(t) + rast * l * \beta_t * (X_i(t) - \beta_t * X_{elit}) r_1 \leq 0 \end{cases} \quad (9)$$

burada $r_1 = \text{rast}()$ rastgele normal bir sayıdır. Denizatının iki farklı türdeki yani spiral veya Brownian hareket modunu takip ederek konum güncelleme diyagramı Şekil 1'de gösterilmiştir. Lévy ve Brownian hareket kalıplarının her ikisi de denizdeki belirsiz ortama dayalı olarak denizatının hareket eden rastgeleliğini yansıtmaktadır.



Şekil 1. Denizatının denizdeki a) Lévy, b) Brownian hareketleri

2.3. Denizatının Yırtıcı Davranışları

Denizatının zooplankton ve küçük kabukluları avlama çabası iki neticeyle sonuçlanır, bunlar; başarı ve başarısızlıktır. Denizatının yiyecek yakalamayı başarma olasılığının %90'ın üzerinde olduğu göz önünde bulundurulduğunda, DOA'nın bu iki sonucu ayırt etmek için tasarlanmış rasgele sayısı r_2 , 0,1 gibi kritik bir değere ayarlanmıştır. Elitin, belirli bir dereceye kadar, avın yaklaşık konumunu gösterdiği varsayıldığından, avlanma başarısı DOA'nın sömürü yeteneğini vurgulamaktadır. $r_2 > 0,1$ ise denizatının yırtıcı hareketinin başarılı olduğu kabul edilmektedir yani denizatı avına (elit) gizlice yaklaşır, avdan daha hızlı hareket ederek onu yakalamaktadır. Bunun aksine, avlanma başarısız olduğunda, her ikisinin de tepki hızı öncekinin tersi olarak kabul edilir, bu da denizatının arama alanını keşfetme eğilimlerini ima etmektedir. Bu yırtıcı davranışın matematiksel ifadesi Denklem 10'da verilmiştir:

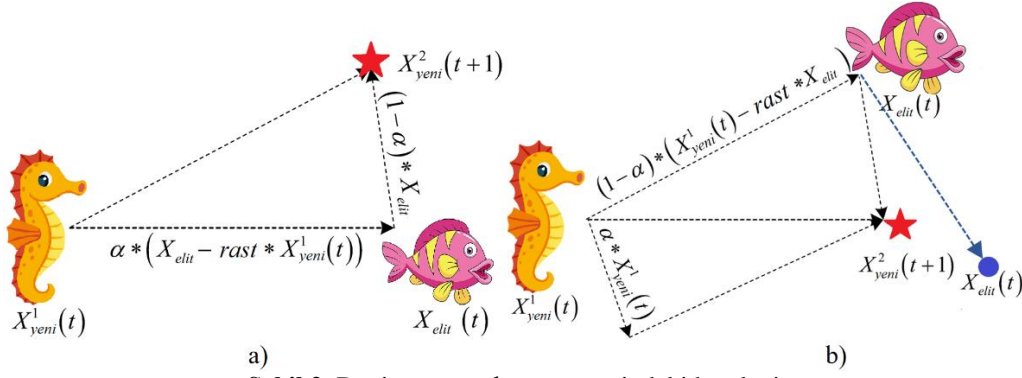
$$X_{yeni}^2(t+1) = \begin{cases} \alpha * (X_{elit} - rast * X_{yeni}^1(t)) + \\ (1 - \alpha) * X_{elit} & r_2 > 0,1 \\ (1 - \alpha) * (X_{yeni}^1(t) - rast * X_{elit}) + \\ \alpha * X_{yeni}^1(t) & r_2 \leq 0,1 \end{cases} \quad (10)$$

burada $X_{yeni}^1(t)$, t yinelemesindeki hareketten sonra denizatının yeni konumunu belirtmektedir. r_2 , $[0, 1]$ aralığındaki rastgele bir değer olarak tanımlanmıştır. α , denizatının avlanacak ava doğru hareket edilen adım boyutunun ayarlanması için yinelemelerle doğrusal olarak azaltılmaktadır ve Denklem 11'de verildiği gibi hesaplanmaktadır:

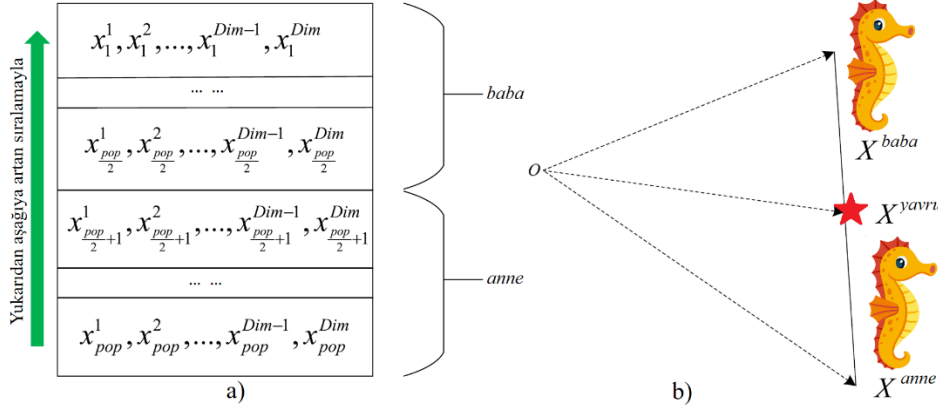
$$\alpha = \left(1 - \frac{t}{N}\right)^{\frac{2t}{N}} \quad (11)$$

burada N , maksimum yineleme sayısını göstermektedir.

Denizatının yırtıcı davranışının iki olası sonucu Şekil 2'de gösterilmektedir. Buna göre, kırmızı yıldız konumu denizatının güncellenmiş konumunu göstermektedir ve avın yaklaşık konumu mavi nokta ile işaretlenmiştir. Denizati başarılı bir şekilde avlandığı taktirde, denizatının elit konuma geçtiği Şekil 2a'da görülmektedir. Bu durumda α parametresinin kontrolü altında, artan iterasyonlarla birlikte kademeli olarak global optimal bireye yakınsayacaktır. Şekil 2b'de, av yakalanmadığı için global arama yapılmaktadır. $1-\alpha$ parametresi, mevcut birey ile elit arasındaki vektöre uygulanmaktadır ve α , güncel olarak güncellenen birey üzerinde hareket etmektedir. Bu yaklaşım, denizatlarının ilk yinelemelerde küresel olarak arama yapmasına ve sonraki yinelemelerde aşırı kullanımdan kaçınmasına izin vermek için tasarlanmıştır.



Şekil 2. Denizatının avlanma sürecindeki hareketi



Şekil 3. Denizatının üreme sürecinde, a) bireylerin sıralanması, b) yavrunun konumu

2.4. Denizatının Üreme Davranışları

Popülasyon, uygunluk değerlerine göre erkek veya kadın gruplarına ayrılmaktadır. DOA, erkek denizatlarının üremeden sorumlu olduklarından dolayı, en iyi uygunluk değerlerine sahip bireylerin yarısının baba, diğer yarısının ise anne olarak alındığını vurgulamak gerekmektedir. Bu bölünme, gelecek neslin devamlılığı için anneler ve babalar arasındaki iyi özelliklerin mirasını kolaylaştıracak ve yeni çözümlerin aşırı yerleştirilmesini önleyecektir. Denizatlarının üremedeki rol atamasının matematiksel ifadesi Denklem 12’de verilmiştir:

$$\begin{aligned} baba &= X_{sıra}^2(1 : pop/2) \\ anne &= X_{sıra}^2(pop/2 + 1 : pop) \end{aligned} \quad (12)$$

burada $X_{sıra}^2$, artan uygunluk değerleri sırasına göre tüm X_{yeni}^2 ’leri göstermektedir. Babalar ve anneler sırasıyla erkek ve kadın popülasyonlarını göstermektedir. Erkekler ve dişiler, yeni yavrular üretmek için rastgele çiftleştirilmektedir. Önerilen DOA’yı kolayca yürütmek için, her bir denizati çiftinin sadece bir çocuk dünyaya getirdiği varsayılmıştır. Denklem 13’te i . yavrunun matematiksel ifadesi verilmiştir:

$$X_i^{yavru} = r_3 X_i^{baba} + (1 - r_3) X_i^{anne} \quad (13)$$

burada r_3 [0, 1] aralığında rastgele bir sayıdır. i , [1, $pop/2$] aralığında pozitif bir tamsayıdır. X_i^{baba} ve X_i^{anne} , sırasıyla erkek ve kadın popülasyonlarından rastgele seçilen bireyleri temsil etmektedir.

Denizatlarının üreme süreci Şekil 3’te gösterilmektedir. Şekil 3a’da görüldüğü üzere, her birey uygunluk değerlerine göre artan düzende sıralanmıştır. Şekil 3b, yeni oluşturulmuş bir yavrunun konumunu yaklaşık olarak göstermektedir. İki alt popülasyon arasında genetik bilgiyi etkili bir şekilde ileten ebeveynler arasındaki çizgide rastgele oluşturulmaktadır.

2.5. DOA’nın Uygulama Süreci

Algoritma-1

- Girdi:** Popülasyon boyutu pop , değişken boyutu Dim , Maksimum yineleme sayısı N
Çıktı: Optimum arama ajanı X_{best} , onun uygunluk değeri f_{best}
- 1: Denizati başlatılır $X_i (i = 1, \dots, N)$
 - 2: Her bir denizati için uygunluk değeri hesaplanır
 - 3: En iyi denizati X_{elit} belirlenir
 - 4: **while** ($t < N$) **do**
 - 5: **if** ($r_1 = rastn > 0$) **do** //Hareket davranışlı
 - 6: Sabit $u=0,05$ $v=0,05$ parametreleri ayarlanır
 - 7: Dönüş açısı θ , $Rast[0, 2\pi]$
 - 8: Denklem 5 ile Lévy katsayıları oluşturulur
 - 9: Denklem 4 ile Denizatının pozisyonu güncellenir
 - 10: **else if do**
 - 11: $l = 0,05$ sabit parametre ayarlanır
 - 12: Denklem 7 ile Denizatının pozisyonu güncellenir
 - 13: **end if**
 - 14: Denklem 10 ile Denizatının pozisyonu güncellenir //Yırtıcı davranışlı
 - 15: Sınır aralığının dışındaki değişkenler işleme alınır
 - 16: Her bir denizati için uygunluk değeri hesaplanır
 - 17: Denklem 12 ile $baba$ ve $anne$ seçilir //Üreme davranışlı
 - 18: Denklem 13 ile yavru dünyaya getirilir
 - 19: Sınır aralığının dışındaki değişkenler işleme alınır
 - 20: Her bir yavru için uygunluk değeri hesaplanır
 - 21: Yavrulardan bir sonraki yineleme popülasyonu seçilir ve uygunluk değerlerinde en iyi ebeveynler pop sıralanır
 - 22: Elit pozisyonu X_{elit} güncellenir
 - 23: $t = t + 1$
 - 24: **end while**

Önerilen DOA'nın sözde kodu Algoritma-1'de gösterilmektedir. DOA'nın uygulama süreci, bir dizi rastgele çözüm oluşturularak popülasyonun başlatılmasıyla ilerlemektedir. Denizati popülasyonu Denklem 9 ve 10 ile güncellendikten sonra, yavruları yetiştirmek için Denklem 13 kullanılmaktadır. Yeni bir popülasyon, yavrular ve daha önce güncellenen denizatlarından oluşmaktadır. Ancak, bu yeni popülasyonun boyutu 1,5 *pop*'tur. Popülasyonun sınırsız genişlemesini önlemek için yeni popülasyondaki her bir birey tahmin edilmektedir. Bireyler uygunluk değerlerine göre yukarıdan aşağıya doğru artan düzende sıralanmaktadır ve ilk pop denizatları bir sonraki evrimsel süreç için yeni popülasyon olarak iteratif olarak seçilmektedir.

3. Kaotik Denizati Optimizasyon Algoritması

Matematiğin bir alt dalı olan kaos teorisi, doğrusal olmayan ve karmaşık dinamik sistemlere dayanan deterministik bir rastgelelik durumudur. Optimizasyon algoritmalarında çözüm uzayında aramalar genellikle rastgele yapılmaktadır. Metasezgisel optimizasyon algoritmalarında kullanılan rastgele değerler yerine kaotik haritalar kullanılarak tekrarlamaya ve rastgelelikten kaynaklanan ergodik olmayan problemler kontrol edilir ve bu da algoritmaların performansına katkıda bulunmaktadır. Kaotik sistemler bağımsızdır ve kaotik haritalama ile yerel minimum ve maksimum problemlerden kaçınılabilir (Arora & Anand, 2019).

Tablo 1. Kaotik haritalar ve matematiksel tanımları

Harita adı	Matematiksel ifade
Chebyshev	$x_{k+1} = \cos(k \cos^{-1}(x_k))$
Circle	$x_{k+1} = \text{mod}(x_k + b - \frac{a}{2\pi} \sin(2\pi x_k), 1)$
Gauss	$x_{k+1} = \begin{cases} 1, & x_k = 0 \\ \frac{1}{\text{mod}(x_k, 1)}, & \text{Diğer} \end{cases}$
Iterative	$x_{k+1} = \sin(\frac{a\pi}{x_k})$
Logistic	$x_{k+1} = \alpha x_k (1 - x_k)$
Piecewise	$x_{k+1} = \begin{cases} \frac{x_k}{P}, & 0 \leq x_k < P \\ \frac{x_k - P}{0.5 - P}, & P \leq x_k < 0.5 \\ 1 - P - x_k, & 0.5 \leq x_k < 1 - P \\ \frac{0.5 - P}{1 - x_k}, & 1 - P \leq x_k < 1 \end{cases}$
Sine map	$x_{k+1} = \frac{a}{4} \sin(\pi x_k)$

İkinci bölümde de belirttiği gibi denizatları denizdeki girdap olayı ile birlikte sarmal olarak hareket etmektedir. Arama ajanlarının sarmal hareket altındaki *x*, *y* ve *z* koordinatları dönme açısı θ 'ya bağlı olarak değişmektedir. Klasik DOA'da θ değeri $[0, 2\pi]$ arasındaki rastgele olarak değerler almaktadır. Bu çalışmada, klasik DOA'nın rastgele θ parametresi için yedi farklı kaotik harita uygulanmıştır. Bu haritalar Tablo 1'de açıklanmıştır.

4. Deneysel Sonuçlar

Tablo 2. Kıyaslama fonksiyonları

Fonksiyon	Fonksiyon Denklemi	Arama Uzayı []	Dim	f_{\min}
Sphere	$f(x) = \sum_{i=1}^n x_i^2$	-100,100	30	0
Rosenbrock	$f(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	-30,30	30	0
Schwefel	$f(x) = -x_i \sin(\sqrt{ x_i })$	-500,500	30	-418.9829×D
Penalized2	$f(x) = 0.1 \left\{ \sin^2(3\pi x_i) + \sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] + (x_n - 1)^2 + [1 + \sin^2(2\pi x_n)] \right\} + \sum_{i=1}^n u(x_i, 5, 100, 4)$	-50,50	30	0
Kowalik	$f(x) = \sum_{i=1}^{11} [a_i - \frac{x_i(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4}]^2$	-5,5	4	0.00030
Hartman6	$f(x) = -\sum_{i=1}^4 c_i \exp(-\sum_{j=1}^6 a_{ij}) - p_{ij}^2)$	0,1	6	-3.32
Shekel10	$f(x) = -\sum_{i=1}^{10} [(X - a_i)(X - a_i)^T + c_i]^{-1}$	0,10	4	-10.5363

Önerilen KDOA'nın performansını değerlendirmek için yedi farklı kıyaslama fonksiyonu kullanılmıştır. Bu fonksiyonlardan Sphere ve Rosenbrock tek modlu, Schwefel ve Penalized2 çok modlu ve Kowalik, Hartman6 ve Shekel10 sabit boyutlu çok modlu kıyaslama fonksiyonlarıdır. Bu kıyaslama fonksiyonlarına ilişkin bilgiler Tablo 2'de verilmiştir. Bu çalışmada Klasik DOA ve önerilen KDOA'lar için popülasyon sayısı 30, maksimum iterasyon sayısı 500 olarak belirlenmiş ve 30 kez çalıştırılmıştır. Tüm deneyler Intel(R) Core(TM) i7-7700, 4.0 GHz CPU, 32 GB RAM, GTX1070 8GB GDDR5 Grafik Kartı, Win 11 ve Matlab 2021b ile gerçekleştirilmiştir.

Tablo 3. Kıyaslama fonksiyonlarının karşılaştırılmalı sonuçları

		Klasik	Chebyshev	Circle	Gauss/ mouse	Iterative	Logistic	Piecewise	Sine
Sphere	Min	1.12E-141	2.81E-147	3.84E-147	2.08E-148	3.17E-149	1.61E-148	1.42E-148	8.71E-150
	Maks	6.92E-141	8.13E-143	6.88E-143	1.38E-142	5.93E-143	3.66E-143	8.71E-144	1.80E-144
	Ort	3.13E-141	7.50E-144	6.13E-144	6.40E-144	6.43E-144	1.74E-144	1.20E-144	1.87E-145
	Std	1.7E-141	1.67E-143	1.4E-143	2.5E-143	1.5E-143	6.7E-144	2E-144	3.6E-145
Rosenbrock	Min	2.81E+01	2.72E+01	2.70E+01	2.72E+01	2.72E+01	2.70E+01	2.71E+01	2.72E+01
	Maks	2.89E+01	2.81E+01	2.81E+01	2.81E+01	2.80E+01	2.79E+01	2.79E+01	2.79E+01
	Ort	2.86E+01	2.76E+01	2.76E+01	2.76E+01	2.74E+01	2.73E+01	2.74E+01	2.74E+01
	Std	2.78E-01	3.80E-01	3.90E-01	3.38E-01	2.56E-01	2.33E-01	2.14E-01	2.38E-01
Schwefel	Min	-6.64E+03	-7.54E+03	-7.07E+03	-7.30E+03	-7.63E+03	-8.61E+03	-7.74E+03	-7.57E+03
	Maks	-5.05E+03	-6.01E+03	-6.09E+03	-6.16E+03	-6.10E+03	-6.15E+03	6.27E+03	-6.25E+03
	Ort	-5.80E+03	-6.53E+03	-6.46E+03	-6.64E+03	-6.60E+03	-6.78E+03	-6.12E+03	-6.71E+03
	Std	4.10E+02	3.34E+02	3.00E+02	3.00E+02	3.22E+02	4.86E+02	2.37E+03	3.29E+02
Penalized 2	Min	1.76E+00	1.44E+00	1.46E+00	1.34E+00	1.13E+00	1.27E+00	1.39E+00	1.25E+00
	Maks	2.70E+00	2.30E+00	2.20E+00	2.21E+00	2.19E+00	1.99E+00	2.20E+00	2.00E+00
	Ort	2.16E+00	2.01E+00	1.90E+00	1.84E+00	1.87E+00	1.79E+00	1.81E+00	1.79E+00
	Std	2.58E-01	2.19E-01	2.04E-01	1.78E-01	1.82E-01	1.52E-01	1.78E-01	1.81E-01
Kowalik	Min	3.23E-04	3.08E-04	3.08E-04	3.08E-04	3.08E-04	3.08E-04	3.08E-04	3.08E-04
	Maks	5.18E-04	3.48E-04	3.52E-04	3.57E-04	3.54E-04	3.23E-04	3.19E-04	3.31E-04
	Ort	4.02E-04	3.16E-04	3.15E-04	3.17E-04	3.14E-04	3.13E-04	3.13E-04	3.14E-04
	Std	5.18E-05	9.52E-06	9.6E-06	1.21E-05	9.99E-06	4.23E-06	3.55E-06	6.11E-06
Hartman6	Min	-3.09E+00	-3.32E+00	-3.32E+00	-3.32E+00	-3.32E+00	-3.32E+00	-3.32E+00	-3.32E+00
	Maks	-2.84E+00	-3.01E+00	-3.19E+00	-3.09E+00	-3.02E+00	-3.02E+00	-3.01E+00	-3.01E+00
	Ort	-3.01E+00	-3.26E+00	-3.31E+00	-3.29E+00	-3.22E+00	-3.24E+00	-3.28E+00	-3.21E+00
	Std	8.46E-02	1.02E-01	2.30E-02	7.47E-02	1.03E-01	1.14E-01	8.71E-02	1.13E-01
Shekel10	Min	-1.05E+01	-1.05E+01	-1.05E+01	-1.05E+01	-1.05E+01	-1.05E+01	-1.05E+01	-1.05E+01
	Maks	-5.02E+00	-5.11E+00	9.88E+00	7.68E+00	-8.39E+00	-5.12E+00	-8.36E+00	-8.56E+00
	Ort	-6.35E+00	-8.80E+00	-8.66E+00	-9.31E+00	-1.00E+01	-9.87E+00	-9.96E+00	-1.00E+01
	Std	2.23E+00	2.28E+00	4.00E+00	3.25E+00	4.72E-01	1.09E+00	5.41E-01	4.79E-01

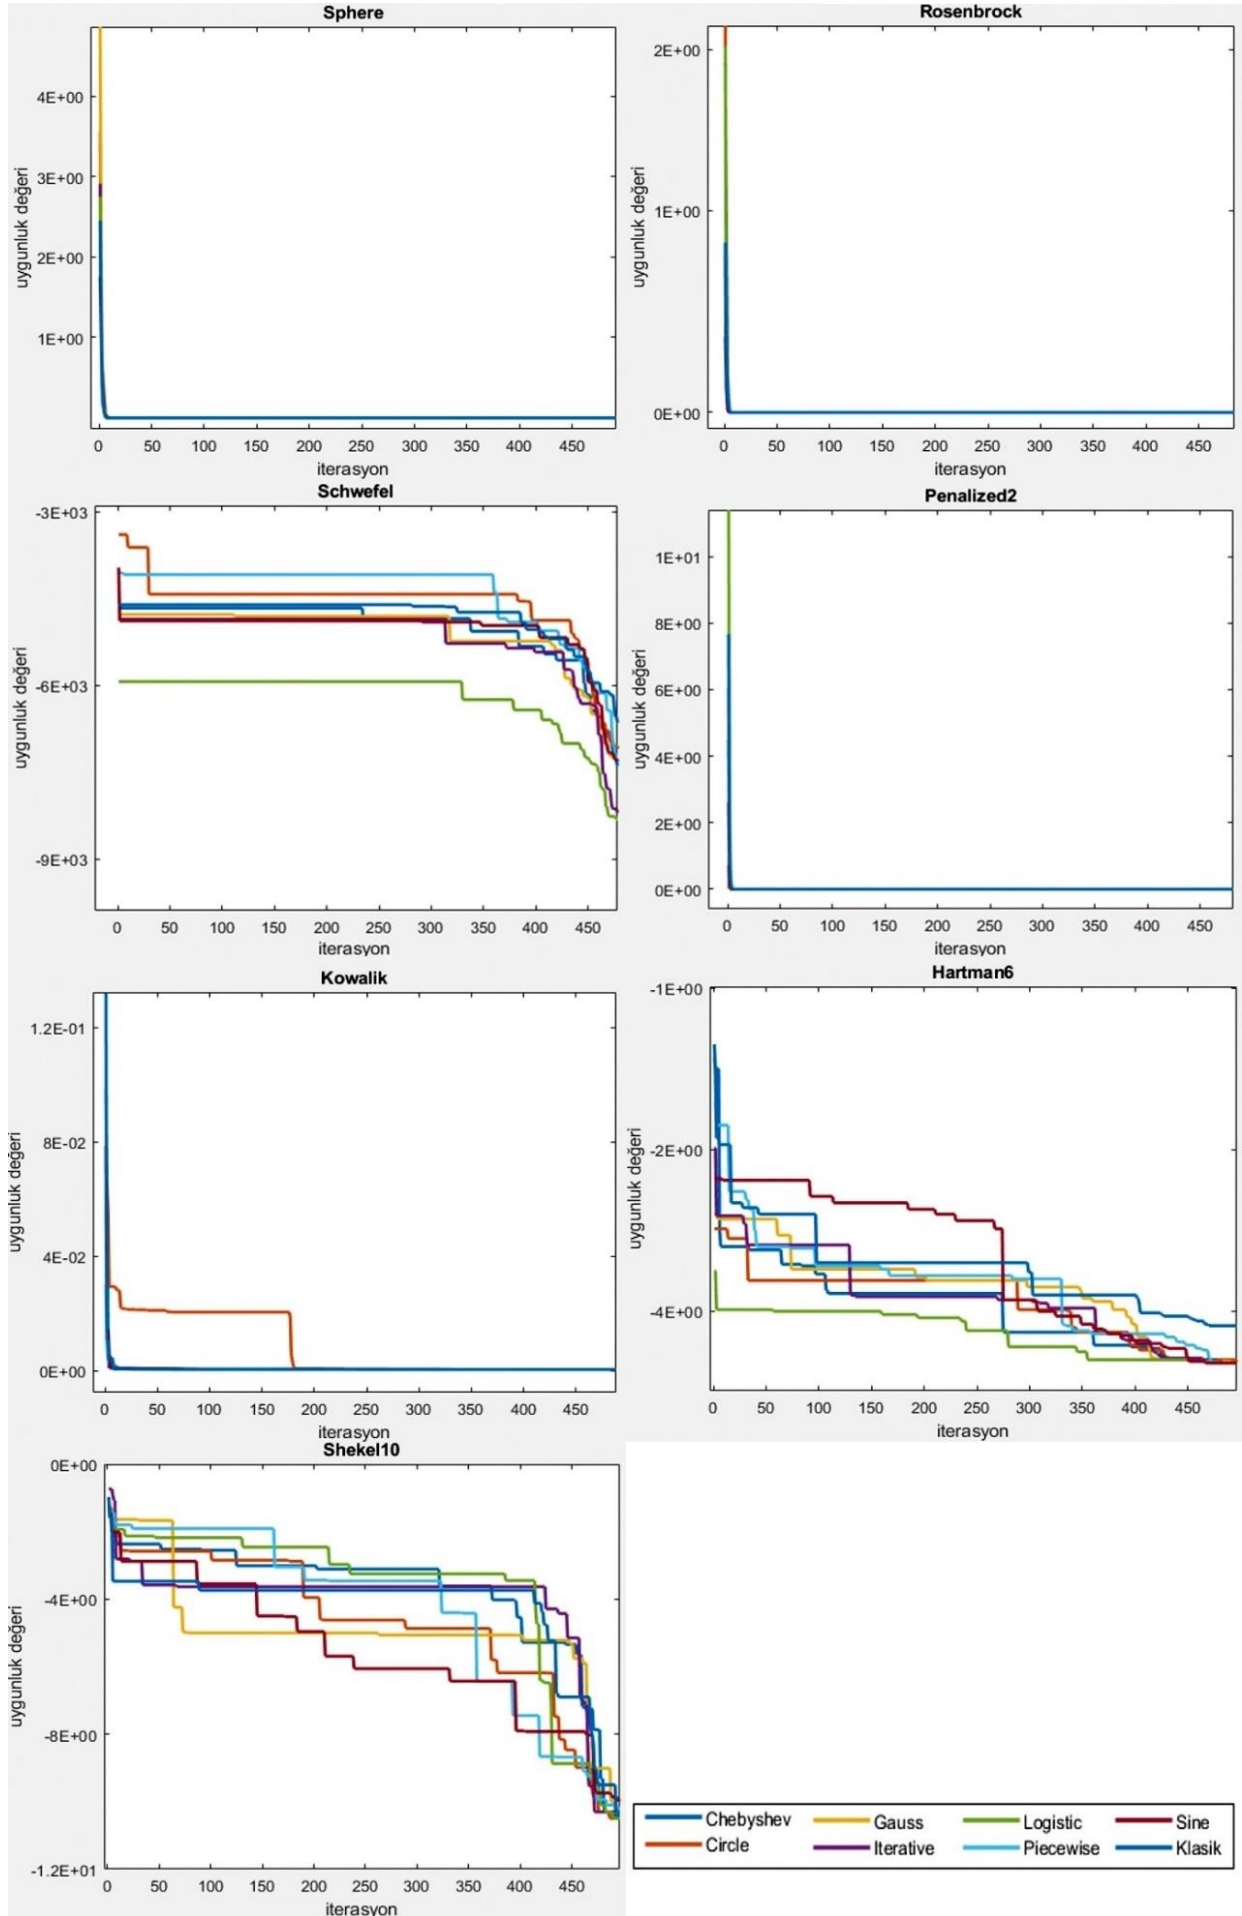
DOA ve KDOA'ların performansını değerlendirmek için minimum (Min), maksimum (Maks), ortalama (Ort) ve standart sapma (Std) değerleri kullanılmıştır. Elde edilen sonuçlar Tablo 3'te listelenmiştir. Tablo 3, incelendiğinde Sphere kıyaslama fonksiyonuna göre en iyi minimum değer Sine harita, Rosenbrock fonksiyonuna göre Circle ve Logistic harita, Schwefel fonksiyonuna göre Logistic harita, Penalized2 fonksiyonuna göre Iterative harita, Kowalik ve Hartman6 fonksiyonuna göre tüm haritalar ile elde edilmiştir. Shekel10 fonksiyonuna göre en iyi minimum değer bakımından birbirine çok yakın sonuçlar elde edilmiştir.

Tablo 3 değerlendirildiğinde, elde edilen ortalama değerlere göre tek modlu Sphere fonksiyonu için Sine harita, Rosenbrock fonksiyonu için Logistic harita ile en başarılı sonuçlar elde edilmiştir. , çok modlu Schwefel ve Penalized2, sabit boyutlu çok modlu Kowalik, Hartman6, Shekel10 fonksiyonlarında klasik DOA'dan daha iyi performans elde ettiği görülmektedir.

Klasik DOA ve KDOA'ların kıyaslama fonksiyonları için yakınsama grafikleri Şekil 4'te verilmiştir.

5. Sonuçlar

Gerçek dünya problemleri, doğrusal olmayan ve karmaşık sistemlerle temsil edilebilir. Bu sistemler kaotik haritalar ile daha net ifade edilebilir. Bu nedenle kaotik haritalar, metasezgisel algoritmalarla birlikte kullanıldığında daha iyi yakınsama yeteneği kazanmaktadır. Kaotik haritalar kullanılarak optimizasyon algoritmalarının çözüm kalitesi önemli ölçüde artırılabilir. Metasezgisel algoritmalarda, sömürü ve keşif aşaması arasındaki denge, algoritmanın etkin yakınsamasında önemli bir rol oynamaktadır. Bu çalışmada, kaotik haritalar DOA'ya entegre edilmiştir. Klasik DOA'nın daha hızlı yakınsama ve daha yüksek doğruluk elde etmek için yedi farklı kaotik harita KDOA'lar geliştirilmiştir. KDOA'nın performansı tek modlu, çok modlu ve sabit katsayılı çok modlu olmak üzere farklı kıyaslama fonksiyonları ile test edilmiştir. Bu çalışmada elde edilen sonuçlar, kaotik haritaların optimizasyon yöntemlerinin performansını artırdığını göstermektedir. DOA'da arama yapmak için rastgele değişkenler kullanmak yerine kaotik haritaları kullanmak daha uygun olabilir. Gelecekte DOA'nın dağıtılmış, çok amaçlı ve paralel versiyonları literatüre kazandırılabilir ve metasezgisel optimizasyon problemlerinde etkin bir şekilde kullanılabilir.



Şekil 4. Klasik DOA ve KDOA'ların yakınsama grafikleri

Kaynakça

- Arora, S., & Anand, P. (2019). Chaotic grasshopper optimization algorithm for global optimization. *Neural Computing and Applications*, 31(8), 4385-4405.
- Eberhart, R., & Kennedy, J. (1995, October). A new optimizer using particle swarm theory. In *MHS'95. Proceedings of the sixth international symposium on micro machine and human science* (pp. 39-43). Ieee.
- Einstein, A. (1956). *Investigations on the Theory of the Brownian Movement*. Courier Corporation.
- Hassan, B. A. (2021). CSCF: a chaotic sine cosine firefly algorithm for practical application problems. *Neural Computing and Applications*, 33(12), 7011-7030.
- Holland, J. H. (1992). Genetic algorithms. *Scientific american*, 267(1), 66-73.
- Karaboga, D., & Basturk, B. (2007). A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm. *Journal of global optimization*, 39(3), 459-471.
- Kaveh, A., & Mahdavi, V. R. (2014). Colliding bodies optimization: a novel meta-heuristic method. *Computers & Structures*, 139, 18-27.
- Mantegna, R. N. (1994). Fast, accurate algorithm for numerical simulation of Levy stable stochastic processes. *Physical Review E*, 49(5), 4677.
- Mirjalili, S. (2016). SCA: a sine cosine algorithm for solving optimization problems. *Knowledge-based systems*, 96, 120-133.
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46-61.
- Onay, F. K., & Aydemir, S. B. (2022). Chaotic hunger games search optimization algorithm for global optimization and engineering problems. *Mathematics and Computers in Simulation*, 192, 514-536.
- Rashedi, E., Nezamabadi-Pour, H., & Saryazdi, S. (2009). GSA: a gravitational search algorithm. *Information sciences*, 179(13), 2232-2248.
- Storn, R., & Price, K. (1997). Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, 11(4), 341-359.
- Yang, X. S. (2010). A new metaheuristic bat-inspired algorithm. In *Nature inspired cooperative strategies for optimization (NICSO 2010)* (pp. 65-74). Springer, Berlin, Heidelberg.
- Zhao, S., Zhang, T., Ma, S., & Wang, M. (2022). Sea-horse optimizer: a novel nature-inspired meta-heuristic for global optimization problems. *Applied Intelligence*, 1-28.
- Zhao, W., Wang, L., & Zhang, Z. (2019). A novel atom search optimization for dispersion coefficient estimation in groundwater. *Future Generation Computer Systems*, 91, 601-610.



Sensor Fusion Based on Mathematical Model of LEO Satellite

Seda (Karadeniz) Kartal^{1*}, Tayfun Dar²

^{1,2}TÜRKSAT Ar-Ge ve Uydu Tasarım Direktörlüğü, Ankara, Turkey, (ORCID: 0000-0003-4756-5490), skartal@turksat.com.tr, tdar@turksat.com.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1216679)

ATIF/REFERENCE: Karadeniz Kartal, S. & Dar, T. (2022). Sensor Fusion Based on Mathematical Model of LEO Satellite *European Journal of Science and Technology*, (44), 59-64.

Abstract

In this study, the mathematical model of attitude motion is obtained for low orbit satellite (LEO) with its kinematic and dynamic equations. The mathematical model of orbit motion for LEO satellite is obtained using Kepler parameters. Sensor data are generated adding zero mean Gaussian noise to data comes from model response. These measurement data are fused using INS/GPS integration structure. Extended Kalman filter algorithm is used to sensor fusion. Compare the estimated data comes from extended Kalman filter and the actual data generated from mathematical model. It has been observed from the results that the estimated data is closest to the actual attitude data. All study is performed at the MATLAB/Simulink environment.

Keywords: LEO satellite, mathematical model, orbit model of satellite, attitude model of satellite, sensor fusion, integration navigation system

Alçak Yörünge Uydu Matematiksel Model Tabanlı Sensör Füzyonu

Öz

Bu çalışmada bir alçak yörünge uydusunun kinematik ve dinamik denklemleri elde edilerek döngüsel hareket için matematiksel model oluşturulmuştur. Kepler parametreleri kullanılarak bu alçak yörünge uydusunun yörünge hareket modeli elde edilmiştir. Döngüsel hareket modelden elde edilen yönelim bilgilerine gürültü eklenerek yönelim sensör verileri üretilmiştir. INS/GPS entegre navigasyon yapısı için sistem ve ölçüm modelleri elde edilerek farklı sensörlerden alınan yönelim bilgileri birleştirilmiştir. Sensör veri birleştirmede genişletilmiş Kalman filtre algoritmaları kullanılmıştır. Kestirilen yönelim bilgisi ile ölçülen ve gerçek yönelim bilgisi karşılaştırılmıştır. Sonuçlardan kestirilen yönelim bilgisinin gerçek yönelim bilgisine en yakın değer olduğu gözlemlenmiştir. Tüm çalışma MATLAB/Simulink ortamında gerçekleştirilmiştir.

Anahtar Kelimeler: Alçak yörünge uydu, matematiksel modelleme, yörünge modeli, döngüsel hareket modeli, sensör veri birleştirme, entegre navigasyon sistemi

* Corresponding Author: sedakaradeniz@gmail.com, skartal@turksat.com.tr

1. Introduction

Satellites are used for observation, positioning, and communication purposes as LEO (low Earth orbit), MEO (middle Earth orbit), GEO (Geosynchronous Equatorial Orbit) according to the orbit level [1], [2]. Although MEO satellites signals are commonly used for navigation system, in the recent years, low orbit satellites group's signals are used for positioning system [3], [4]. It is important that the satellites used for all this purpose should remain stable in a certain orbit and attitude for position accuracy. The orbit and attitude stability of satellite is distributed due to perturbation torques. The reaction wheels integrated the satellites generate torque to balance these perturbation torque acting on the satellite. These reaction wheels should be controlled depending on the difference between the data comes from measurement sensors on the satellite and the desired orbit and attitude information value.

For more accurate control of them, measurement data defined the satellite's orbit and attitude should be taken correctly. For this purpose, it is necessary to measure the same data from more than one sensor and these sensor data should be fused. There are many algorithms used to sensor fusion. The most used algorithm is Kalman filter [5]. Fuzzy algorithm for tuning the extended Kalman filter estimation was used to multi sensor fusion [6]. Federated Unscented Kalman filter designed for multiple satellites formation flying in LEO [7]. Sensor fusion was performed by creating an integrated navigation system [8]. INS/GPS integrated navigation structure was designed by using the position, speed and attitude error propagation equations of INS integrated into satellite body [9].

Sensor data can be generated by obtaining the mathematical model of satellite in order to analyze the sensor fusion algorithm. Obtain the orbit and attitude motion model of satellite is important for the error model due to these motion on the positioning system used the satellite's signals [10], [11].

In this study, the mathematical model for attitude and orbit motion of satellite is obtained. The angular velocity propagation of satellite is obtained with the attitude motion model. The sensor data is generated using the mathematical model response. Measured information from multiple sensors are fused with the integrated navigation system.

The remainder of this paper is organized as follows. Section 2 presents the mathematical model of attitude motion for low orbit satellite. We provide a detailed information of orbit model for low orbit satellite in Section 3. Section 4 presents integrated navigation system and sensor fusion and simulation results. Lastly, the conclusion and future work are presented in Section 5.

2. Mathematical Model of Attitude Motion for Low-Orbit Satellite

The dynamic and kinematic equations are implemented to obtain the mathematical model of low orbit satellite.

2.1 Dynamic Model

The dynamic model given the derivation of angular velocity for satellite is as [12]:

$$\dot{w}_{ib}^b = I_s^{-1} [M_D - \dot{H}_{RW}^b - \Omega(w_{ib}^b) I_s w_{ib}^b - \Omega(w_{ib}^b) H_{RW}^b] \quad (1)$$

where

I_s ; inertia tensor matrix of satellite

M_D ; the torque based on perturbations

H_{RW}^b ; the momentum generated by reaction wheels

\dot{H}_{RW}^b ; the torque produced by reaction wheels

w_{ib}^b ; the angular velocity of satellite in body-frame

$\Omega(w_{ib}^b)$; the skew-symmetric matrix based on angular velocity of satellite

The perturbation torques due to the gravity gradient, solar radiation, aerodynamic, magnetic dipole moment are affected to the attitude motion of satellite [12], [13]. This perturbation torques are balanced with reaction wheels or magnetic torque sticks. In this study, the torques generated by reaction wheels is considered the control torque $\dot{H}_{RW}^b = M_C$.

The inertia tensor matrix is considered diagonal matrix since the contribution of the off-diagonal matrix is small [14].

$$I_s = \begin{bmatrix} I_{sxx} & 0 & 0 \\ 0 & I_{syy} & 0 \\ 0 & 0 & I_{szz} \end{bmatrix} \quad (2)$$

The skew-symmetric matrix based on angular velocity of satellite in the x, y and z axis is as [14]:

$$\Omega(w_{ib}^b) = \begin{bmatrix} 0 & -w_{ib,z}^b & w_{ib,y}^b \\ w_{ib,z}^b & 0 & -w_{ib,x}^b \\ -w_{ib,y}^b & w_{ib,x}^b & 0 \end{bmatrix} \quad (3)$$

The block diagram of dynamic model of low orbit satellite obtained in Simulink environment is shown as Figure 1. As seen Figure 1, the angular velocity propagation of satellite is obtained using the inertia tensor data of satellite, reaction wheel's momentum data and torques generated by reaction wheel against the perturbation torques. So, the output of this block is the angular velocity changing in the body frame. The angular velocity in the body-frame is obtained by integrating the output of this block related to equation 1.




Figure 1. The Simulink block diagram of dynamic model for LEO satellite

2.1.1 Reaction Wheel Model

The reaction wheels integrated the satellites generate torque to balance the external impact forces acting on the satellite. The location and number of these wheels affect the torque produced. In this study, the reaction wheels configuration is considered as tetrahedron. The angular momentum (H_{RW}) and generated tork of each wheel (M_C) are as [12]:

$$H_{RW} = I_{RW}W_{RW} \quad (4)$$

$$M_C = I_{RW}\dot{W}_{RW} \quad (5)$$

Each reaction wheel is considered as identical and the inertial tensor matrix parameter of each wheel is equal $I_{RW} = I_{RW,x} = I_{RW,y} = I_{RW,z}$. The location matrix of reaction wheels is given by [15]:

$$L = \begin{bmatrix} \sqrt{3}/3 & -\sqrt{3}/3 & -\sqrt{3}/3 & \sqrt{3}/3 \\ \sqrt{3}/3 & -\sqrt{3}/3 & \sqrt{3}/3 & -\sqrt{3}/3 \\ \sqrt{3}/3 & \sqrt{3}/3 & -\sqrt{3}/3 & -\sqrt{3}/3 \end{bmatrix} \quad (6)$$

The generated torque by each wheel in the x, y and z axis is written as [15]:

$$\begin{bmatrix} M_{c,x} \\ M_{c,y} \\ M_{c,z} \end{bmatrix} = L \begin{bmatrix} T_1 \\ T_2 \\ T_3 \\ T_4 \end{bmatrix} \quad (7)$$

where T_1, T_2, T_3, T_4 applied torque to each reaction wheel respectively. The derivative of angular velocity is obtained as $\dot{W}_{RW} = \frac{M_C}{I_{RW}}$. The tork produced by each reaction wheel at each axis is defined by:

$$T_C = \begin{bmatrix} \dot{H}_{RW,x}^b + H_{RW,z}^b W_{ib,z}^b - H_{RW,y}^b W_{ib,z}^b \\ \dot{H}_{RW,y}^b + H_{RW,x}^b W_{ib,z}^b - H_{RW,z}^b W_{ib,x}^b \\ \dot{H}_{RW,z}^b + H_{RW,y}^b W_{ib,x}^b - H_{RW,x}^b W_{ib,y}^b \end{bmatrix} \quad (8)$$

The generated torque block diagram by four reaction wheels is shown as Figure 2. As seen block diagram, the torque and momentum generated by reaction wheels using the angular velocity of satellite and the applied force to each wheel. The max torque applied to each wheel is 0.018 Nm.




Figure 2. The Simulink block diagram for torque and momentum generated by reaction wheels

2.2 Kinematic Model

Kinematic model supply transformation between different frames. The angular velocity of satellite is transformed from body to orbit frame using the kinematic model. The transformation matrix consists of Euler angles is used to this transformation. The transformation matrix $C(q)_o^b$ defined by quaternion vectors, $[q_1 \ q_2 \ q_3 \ q_4]$, are used in this study because Euler angles are undefined at some angles (90 degree) [12]. Kinematic model;

$$\dot{q} = \frac{1}{2}\Omega(w_{ob}^b)q \quad (9)$$

where $\Omega(w_{ob}^b)$ is the skew-symmetric matrix in terms of angular velocity of satellite in the orbit frame and it is obtained as [12]:

$$\begin{bmatrix} w_x \\ w_y \\ w_z \end{bmatrix}_{ob}^b = \begin{bmatrix} w_x \\ w_y \\ w_z \end{bmatrix}_{ib}^b - C_o^b \begin{bmatrix} 0 \\ -w_0 \\ 0 \end{bmatrix} \quad (10)$$

where w_{ob}^b is the angular velocity of satellite in the orbit frame, w_{ib}^b is the angular velocity of satellite in the body frame. The mean motion of satellite represented by w_0 is obtained as:

$$w_0 = \sqrt{\frac{GM_e}{R^3}} \quad (11)$$

G is the gravity constant of Earth, M_e is the Earth mass, R is the distance between satellite and Earth. In this study, the value of w_0 is taken as approximately 0,0069 rad/s [13]. The transformation matrix from body to orbit frame is defined as [12].

$$C(q)_o^b = \begin{bmatrix} C(q)_{11} & C(q)_{12} & C(q)_{13} \\ C(q)_{21} & C(q)_{22} & C(q)_{23} \\ C(q)_{31} & C(q)_{32} & C(q)_{33} \end{bmatrix} \quad (12)$$

$$\begin{aligned}
 C(q)_{11} &= q_1^2 + q_4^2 - q_2^2 - q_3^2 \\
 C(q)_{12} &= 2(q_1q_2 + q_3q_4) \\
 C(q)_{13} &= 2(q_1q_3 - q_2q_4) \\
 C(q)_{21} &= 2(q_1q_2 - q_3q_4) \\
 C(q)_{22} &= q_4^2 - q_1^2 + q_2^2 - q_3^2 \\
 C(q)_{23} &= 2(q_2q_3 + q_1q_4) \\
 C(q)_{31} &= 2(q_2q_3 + q_1q_4) \\
 C(q)_{32} &= 2(q_1q_3 - q_1q_4) \\
 C(q)_{33} &= q_4^2 - q_1^2 - q_2^2 + q_3^2
 \end{aligned} \tag{13}$$

The block diagram of kinematic model of satellite occurred in Simulink environment is shown as Figure 3. As seen Figure 3, quaternion elements are obtained using the input data of block with mean motion value of satellite and angular velocity data of the satellite in the body frame. So, the angular velocity of the satellite can be transformed from body frame to orbit frame.

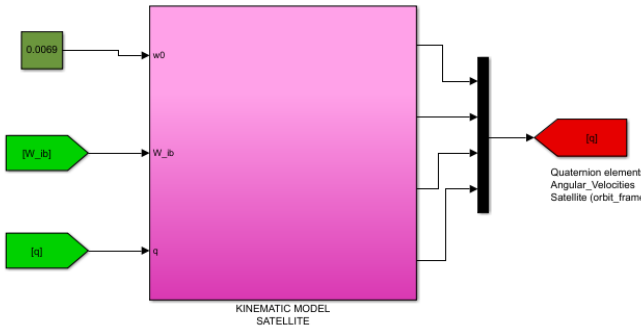


Figure 3. The Simulink block diagram of LEO kinematic model

3. Orbit Propagation Model

The orbit propagation model of LEO is obtained using Kepler parameters [9]. These parameters are orbit inclination (i), right ascension of ascending node (Ω), eccentricity (e), argument of perigee (w), mean anomaly (M), mean motion (n), eccentric anomaly (E). In this study, constant values of Kepler parameters are taken from TLE data series (Two lines element data) of FLP satellite.

The time derivation of the mean anomaly and the time derivation of eccentric anomaly are as [12], [13]:

$$M(t_0 + t) = M(t_0) + n \cdot t \tag{14}$$

$$E(t) = M(t) + e \cdot \sin E(t) \tag{15}$$

$$E_{i+1} = E_i + \frac{M_i + e \cdot \sin(E_i) - E_i}{1 - e \cdot \cos(E_i)} \tag{16}$$

where n , mean motion is the a

average angular velocity that defines the sizes of the ellipse. It is obtained using the Kepler's third law as:

$$n = \sqrt{\frac{\mu_e}{a^3}}, \mu_e = G \cdot M_e \tag{17}$$

where G is the gravity constant of Earth, M_e is the Earth mass. So, the position of satellite in orbit frame (r^{oc}) is obtained. The position of satellite in the Earth frame and inertial frame is obtained using the transformation matrix [12].

$$r^{oc} = a \begin{bmatrix} \cos E - e \\ \sqrt{1 - e^2} \sin E \\ 0 \end{bmatrix} \tag{18}$$

The perturbations torque effected to orbit motion of satellite are due to the Earth gravity harmonics, Earth tides effect, Sun and Moon gravitational effect, solar radiation pressure, atmospheric drag.

4. Integrated Navigation System and Sensor Fusion

The flow diagram of the integrated navigation and sensor fusion is shown in Figure 4. The yaw angle occurred with perturbation torque and reaction wheels torque is measured by magnetometer and gyro of IMU. These sensor measurement data are fused Extended Kalman filter algorithm. System and measurement model for integrated navigation system and sensor fusion are obtained follow chapter.

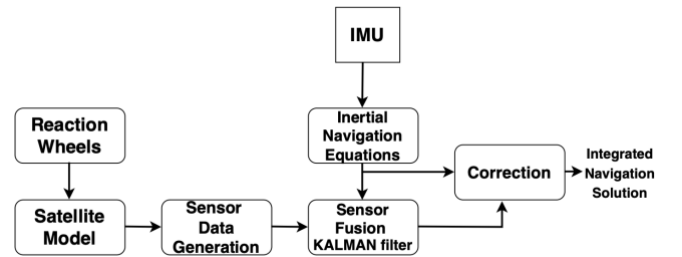


Figure 4. The flow diagram for sensor fusion and integrated navigation system

4.1 System Model

In this study, attitude error states are estimated. Extended Kalman filter algorithm is used for estimation [8]. Error states are chosen as attitude, velocity, position errors and accelerometer and gyro biases in terms of Earth frame and they are defined as [16].

$$x_{eb}^e = [\delta\varphi_{eb}^e \quad \delta v_{eb}^e \quad \delta r_{eb}^e \quad b_a \quad b_g]^T \tag{19}$$

$\delta\varphi_{eb}^e$: attitude error vector,

δv_{eb}^e : velocity error vector,

δr_{eb}^e : position error vector.

The time derivation of attitude error as

$$\dot{\delta\varphi}_{eb}^e = \hat{C}_b^e b_g - \Omega_{ie}^e \delta\varphi_{eb}^e \tag{20}$$




Figure 5. Perturbations torques applied to satellite in the x, y and z axis




Figure 6. Actual yaw angle (blue line), measurement yaw angle from gyro (green line), measurement yaw angle from magnetometer (pink line), estimated yaw angle comes from Kalman filter (red line)

5. Conclusion

In this study, the attitude mathematical model of low orbit satellite is obtained with dynamic and kinematic equations of motion. The measurement data comes from magnetometer and gyro are generated using the attitude mathematical model response. System model and measurement model are occurred for INS/GPS integrated navigation system. Different sensor data are fused with extended Kalman filter algorithm. All this study is performed in MATLAB/Simulink environment. Orbit propagation model of satellite is obtained using Kepler parameters but the sensor data generated with orbit motion model response is not used in this study. Perturbations torques will be improved and implemented to GEO satellite and the different controllers of reaction wheel will be designed for the future work.

References

[1] F. Vatalaro, G.E. Corazza, C. Ferralli, “Analysis of LEO, MEO and GEO global mobile satellite systems in the presence of

interference and fading”, IEEE Journal on Selected areas in Communication.

[2] C. Saunders, “The role of small satellites in military communications”, IET Seminar on Military Satellite Communication, 2013.

[3] Prol F. S., Ferre R. M., Saleem Z., “Position, Navigation, and Timing (PNT) Through Low Earth Orbit (LEO) Satellites, IEEE Access, 2022.

[4] Neinovare M., Khalife J. and Kassas Z. M., “Exploiting starlink Signals for Navigation: First Results”, GNSS Conferences, 20-24 September, 2021.

[5] B. Gao, G. Hu, Y. Zhong, and X. Zhu, “Cubature Kalman Filter with Both Adaptability and Robustness for Tightly-coupled GNSS/INS Integration,” IEEE Sensors Journal, 2021.

[6] Tan N. D., Vinh T. Q., Tuyen B. T., “A new approach for Small Satellite Gyroscope and Star Tracker Fusion”, Indian Journal of Science and Technology, Vol 9(17), 2016

[7] Ilyas M., Lim J., Lee J. G., Park C. G., “Federated unscented Kalman filter design for multiple satellites formation flying in LEO”, IEEE 2008 International conference on control automation and systems

[8] I. Lee, H. Li, N. Hoang, and J. Lee, “Navigation system development of the underwater vehicles using the GPS/INS sensor fusion,” 14th International Conference on Control, Automation and Systems, pp. 610– 612, 2014.

[9] R. Song, and Y. Fang, “Vehicle state estimation for INS/GPS aided by sensors fusion and SCKF-based algorithm,” Mechanical Systems and Signal Processing, vol. 150, pp. 107315, 2021.

[10] Sadaf Tafazoli, Mohammad Reza Mosavi, “Performance Improvement of GPS GDOP Approximation Using Recurrent Wavelet Neural Network”, Journal of Geographic Information System, 2011, 3, 318-322

[11] Tahsin M., Reza T., Sultan S., Haider M. “Analysis of DOP and its Preciseness in GNSS Position Estimation “Int'l Conf. on Electrical Engineering and Information & Communication Technology (ICEEICT) 2015

[12] Kutlu Aykut “Design of Kalman Filter Based Attitude Determination Algorithms for a LEO Satellite and for a Satellite Attitude Control Test Setup”, METU, Master Thesis.

[13] Karataş Soner, “LEO SATELLITES: Dynamic Modelling, Simulations and Some Nonlinear Attitude Control Techniques”, METU, Master Thesis.

[14] Efendioğlu Gamze, “Design of Kalman Filter based Attitude Determination and Control Algorithms for a LEO Satellite”, METU, Master Thesis.

[15] Kök İbrahim, “Comparison and Analysis of Attitude Control Systems of a Satellite Using Reaction Wheel Actuators” Lulea University of Technology, METU, Master Thesis.

[16] Groves P. “Principles of GNSS, Inertial, and Multisensor Integrated Navigation Systems”

[17] Karadeniz Kartal S., Leblebioğlu M. K., Ege E., “Acoustic-based navigation and system identification of an unmanned underwater vehicle”, Transaction Measurement and Control, 2019



Videolardan Kalp Atış Hızı Kestirimi Üzerine Bir İnceleme

Mustafa Korkmaz^{1*}, Saffet Vatansever²

^{1*} Bursa Teknik Üniversitesi, Mekatronik Mühendisliği, Bursa, Türkiye, (ORCID: 0000-0002-1874-1814), mmustafaa.korkmaz@gmail.com

² Bursa Technical University, Mekatronik Mühendisliği, Bursa, Türkiye, (ORCID: 0000-0002-4680-1263), saffet.vatansever@btu.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1221945)

ATIF/REFERENCE: Korkmaz, M. & Vatansever, S. (2022). Videolardan Kalp Atış Hızı Tespiti Üzerine Bir İnceleme. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 65-73.

Öz

Kalp atış hızı; kişinin sağlığı, aktivite seviyesi, stres durumu, zindeliği ve benzeri fizyolojik durumları hakkında önemli ipuçları vermektedir. Kalp atış hızı, elektrokardiyogram (EKG) ve nabız oksimetreleriyle ölçülebilir olmakla birlikte, bu cihazlar sürekli temas gerektirdiğinden zamanla rahatsız edici olabilmektedir. Bilgisayarlı görü (computer vision) alanındaki son gelişmeler, bir kişiye elektrot veya nabız oksimetreleri takmanın mümkün veya uygun olmadığı durumlarda, videolardan kişinin kalp atış hızını tespit etmeye olanak sağlamıştır. Uzaktan fotoplethysmografi (rPPG), bir video kamera aracılığıyla derideki hassas renk değişikliklerini yakalayıp, yaşamsal belirtilerin tespit edilmesine imkân sağlayan bir teknolojidir. Son yıllarda yapılan çalışmalar, uzaktan kalp atış hızı tespiti için en uygun bölgenin yüz olduğunu göstermiştir. Bu çalışmada; videolar aracılığıyla kişilerin yüz bölgesinden kalp atışı hızı kestiriminin nasıl yapılabildiği, kalp atışı hızı kestirimi sürecindeki aşamaların nasıl iyileştirilebileceği ve nasıl daha yüksek doğrulukta kalp atışı hızı tespiti yapılabileceği hakkında literatürdeki mevcut yöntemler incelenerek kapsamlı bir analiz yapılmıştır.

Anahtar Kelimeler: Kalp atış hızı, uzaktan fotoplethysmografi (rPPG), yüz videoları, derin öğrenme.

Heart Rate Estimation from Videos: A Review

Abstract

Heartbeat rate provides important signs about a person's health, activity level, stress level, vitality, and other related physiological conditions. Although electrocardiograms (ECG) and pulse oximeters can be exploited to measure the heart rate, these instruments might become uncomfortable with time due to the requirement for constant contact. Recent advances in computer vision have made it achievable to detect a person's heart rate from videos when it is impossible or impractical to attach electrodes or pulse oximeters to a person. Remote photoplethysmography (rPPG) is a technology that detects vital physiological information by capturing considerably precise color changes in the skin via a video camera. Recent studies have shown that the face is the most appropriate area to use for remote heart rate detection. In this study, a comprehensive analysis has been conducted by investigating the existing methods in the literature on how to estimate the heartbeat rate from a person's face through videos, how to improve the stages in the heart rate estimation process, and hence to improve the accuracy of the estimations.

Keywords: Heartbeat rate, remote photoplethysmography (rPPG), face videos, deep learning.

* Sorumlu Yazar: mmustafaa.korkmaz@gmail.com

1. Giriş

Kişilerin sağlık durumlarının takibi, araştırmacıların dikkatini çeken önemli konulardan biridir. Kalp atış hızı, vücut ısısı, solunum hızı, kan oksijen doygunluğu, kalp hızı değişimi ve kan basıncı gibi yaşamsal belirtiler, insan vücudunun fizyolojik ve duygusal durumunu izlemek için kullanılan yaygın işaretlerdir (Cheng ve ark., 2021). Kalp, insan vücudundaki en önemli organlardan biridir. Kalp atış hızındaki anormalliklere, kalbin kan pompalama hareketini kontrol eden normal elektriksel uyarıyı bozan fizyolojik ve patolojik faktörler neden olmaktadır (Hassan ve ark., 2017). Yüksek tansiyon, sigara, ateş, ani stres, ilaçların yan etkileri, uyku apnesi, miyokardit ve yaşlanma gibi etmenler kalp dokularında hasara yol açarak ciddi sağlık sorunlarına sebebiyet verebilmektedir. Kalp atış hızının düzenli takibi, kardiyovasküler sorunların erken tespit edilmesini ve önlenmesini sağlayabilir. Sağlıklı yetişkinlerde kalp atış hızı dakikada 60 ila 100 arasında değişen atım sayısı (bpm) olarak ölçülmektedir (Hassan ve ark., 2017; Sinhal ve ark., 2020). Araştırmacılar kalp atış hızını tespit etmek için çeşitli temaslı ve temassız yöntemler geliştirmişlerdir.

Elektrokardiyogram (EKG) ve nabız oksimetreleri ile kalp atış hızı, tespit edilebilmektedir. Elektrokardiyogram, cilde yerleştirilen elektrotlar aracılığıyla kalbin elektriksel aktivitesindeki voltaj değişikliklerini ölçmektedir. Nabız oksimetreleri ise fotopletismografik (ppg) sinyallerinden faydalanarak ölçüm yapmaktadır (Pagano ve ark., 2022). Fotopletismografi, vücuttaki kan dolaşımından kaynaklanan derideki renk değişimlerinin bir sensör yardımıyla yakalanarak dijitalleştirilmesi işlemidir (YAMAN, 2018). Oksimetreler temel olarak bir ışık kaynağı ve ışık detektöründen oluşan sensör aparatından ibarettir. Ölçüm işlemi, genellikle kulak memesi ya da parmağın sensör aparatının arasına yerleştirilmesi ile gerçekleştirilir. EKG için kullanılan yapışkan jel elektrotlar ile kulak ve parmağa takılan oksimetreler; yaşlılar, bebekler, hastalar, sporcular gibi sürekli kalp atış hızı tespiti gereken gruplar için rahatsız edici olabilmektedir (Bush, 2016).

Uzaktan fotopletismografi (rPPG) kullanarak ciltteki küçük renk değişimlerini veya vücut hareketlerini analiz ederek yüz görüntülerinden ve videolardan kalp atış hızının tespiti son zamanlardaki en önemli araştırma konularından biri olmuştur. Biyosinyallerin uzaktan algılanması, temas gerektiren kalp atış hızı ölçüm araçlarıyla ilişkili kablolu ve dağınıklığı minimuma indirmiştir (Bush, 2016). Sağlık durumu takibi, bulaşıcı hastalıkların kontrolü, biyometrik canlılık tespiti, tele tıp, yeni doğan bebeklerin kontrolü, doğal afetler sırasında hayatta kalanları aramak için ve sporcuların durum takibi gibi konularda videodan kalp atış hızı tespitinden yararlanılabilmektedir (Deng & Kumar, 2020). Bu çalışmada, videolardan kalp atış hızı tespitinde literatürdeki renk yoğunluk temelli ve derin öğrenmeye dayalı teknikler incelenerek, nasıl daha güvenilir kalp atış hızı tahmini yapılabileceği analiz edilmiştir.

2. Uzaktan Fotopletismografi (rPPG)

Uzaktan Fotopletismografi (rPPG) genel olarak, kalbin kan pompalama döngüsüyle ciltte gerçekleşen küçük renk değişimlerinin bir sensör veya kamera ile yakalanıp analiz edilerek dolaşım sistemiyle alakalı bilgilerin elde edilmesine dayanan bir çalışma alanıdır. rPPG yöntemlerinde, temas tabanlı

PPG sinyali elde etmede kullanılan ışık yayan diyot ortam aydınlatmasıyla, algılayıcı sensör ise bir dijital kamerayla (örneğin, web kamerası, standart RGB kamera, yakın kızılötesi kamera), değiştirilmektedir. Deri altındaki kan damarlarının hacimsel değişikliklerini ölçmek için bir ışık kaynağı ve kamera kullanılmaktadır. Dokunun aydınlatılması ile kan akışından yansıyan veya iletilen ışık yoğunluğundaki küçük değişiklikler kamera tarafından yakalanarak, rPPG sinyali elde edilmektedir (Shao ve ark., 2021; Sun & Thakor, 2016).



Şekil 1. Ciltten yansıyan PPG sinyalinin kamera tarafından yakalanması (Wang, 2017).

Kalp döngüsü sırasında, hemoglobin konsantrasyonundaki küçük değişiklikler, kan damarları tarafından emilen ışık miktarında dalgalanmalara neden olarak cilt yoğunluğu değerlerinde değişikliklere neden olur (Swinehart, 1962). Hemoglobinin, yeşil rengi kırmızıya göre daha iyi emmektedir. Ayrıca yeşil renk dokularda daha iyi ilerleyebilmektedir. Bu sebeple yeşil renk, diğer renklere göre daha güçlü PPG sinyalleri elde etmeye imkan sağlamaktadır. (Tamura ve ark., 2014). rPPG yöntemi ile cildin epidermis katmanındaki speküler ve hipodermisteki difüzyon yansıma bileşenleri arasındaki kontrast ölçülmektedir. Deriden yansıyan kırmızı, mavi ve yeşil renk kanalları uygun bir hesaplama yaklaşımı kullanılarak fizyolojik bir sinyal elde edilmektedir. (Premkumar & Hemanth, 2022).

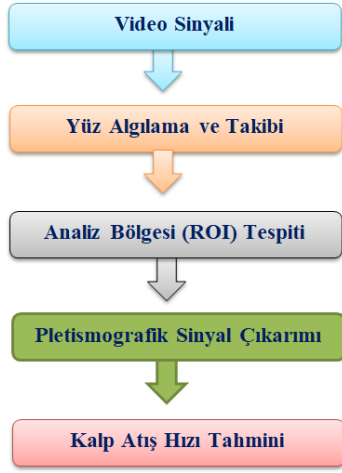
Kalbin kasılması ve gevşemesi esnasında damarlarda farklı durumlar gözlenir. Kalbin vücuda kanı pompalaması ile damarlardan geçen kan miktarı artar, ışık miktarı ise azalır. Kalbin gevşemesi sırasında ise damarlardan geçen kan miktarı azalır, ışık miktarı ise artar (Elgendi, 2012). Tipik bir PPG sinyali; kemik, kas ve deriden geçen ve kan damarlarından geçen olmak üzere iki ayrı bileşenden oluşmaktadır (Aydemir, 2019). Kan damarlarından geçen sinyalin yükseltilmesi, istenen bilginin çıkarılmasında kritik rol oynamaktadır (Aydemir, 2019).

3. Kalp Atış Hızı Tespit Süreci

Videolardan kalp atış hızının elde edilme süreci Şekil 2'deki blok diyagramda özetlenmiştir. Ayrıca bu süreçte kullanılan renk yoğunluk temelli ve derin öğrenme tabanlı tekniklerinin analiz ve incelemesi yapılmıştır. Kalp atış hızı kestirim süreci; Analiz Bölgesi (ROI) tespiti, Pletismografik Sinyal Çıkarımı ve Kalp Atış Hızı Tahmini olarak 3 ana aşamaya ayrılmış ve her aşamada kullanılan yöntemler Şekil 2'de incelenmiştir.

Bir kamera, damarlardaki kan hacmi değişimiyle insan cildinden kalp atış hızını yakalayabilir ve optik spektrumun farklı bölgelerini örnekleyerek kırmızı, yeşil ve mavi işlenmemiş sinyal izleri üretebilir. Bu ham sinyaller daha sonra fizyolojik bilgi içeren bir pletismografi sinyali elde etmek için işlenmektedir. Genel olarak, videolardan kalp atış hızı ölçümü

için uzaktanfotopletismografide kullanılan teknikler literatürdeki kullanım sıklığına göre renk yoğunluk temelli ve derin öğrenme tabanlı yöntemler olarak 2 kısımda açıklanabilir.



Şekil 2. Kalp Atış Hızı Tespit Süreci Blok Diyagramı.

Renk yoğunluk temelli yöntem, giriş video karelerinin işlenmesine yönelik denetimsiz bir yaklaşımdır. İlk olarak, giriş videosunun her karesinden bir analiz bölgesi (ROI) tespit edilir ve ardından kırmızı, yeşil ve mavi kanalların uzamsal olarak ortalaması alınarak işlenmemiş sinyal izleri oluşturulur. Bu izler daha sonra fotopletismografik sinyali elde etmek için farklı sinyal işleme teknikleriyle işlenir. Son olarak zaman veya frekans bölgesi analizleri yapılarak kalp atış hızı tespit edilmeye çalışılır. rPPG araştırmasının biçimlendirici dönemi, 2008 yılında Verkruysse ve meslektaşlarının, ortam ışığı altında bir denegin yüzünün video kayıtlarının kalp atış hızını ölçmek için yeterince zengin bir sinyal içerdiğini göstermeleriyle başlamıştır (Rouast ve ark., 2018; Verkruysse ve ark., 2008).

Literatürdeki son trendler, kalp atış hızı ölçümünde geleneksel temassız yöntemlerin performansını iyileştirmek için derin öğrenme yöntemlerini kullanmaktadır. Son zamanlarda geliştirilen derin öğrenme tabanlı yöntemler, geleneksel renk yoğunluk temelli yöntemlere göre daha umut verici sonuçlar göstermektedir (Premkumar & Hemanth, 2022). Öğrenme tabanlı yöntemler, kalp atış hızını doğrudan video girişinden tespit edebilmekte ya da sistemin rPPG mekanizmasını baştan öğrenebilmektedir. Derin öğrenme modelleri için gerekli veri kümeleri, RGB kameralar kullanılarak toplanır. Derin öğrenmeye dayalı yöntemler, renk yoğunluk temelli ve derin öğrenme yöntemlerinin kombinasyonu ve rPPG sinyalinin uçtan uca herhangi manuel bir adım olmadan elde edilmesi olarak iki kategoride değerlendirilebilir. Bu iki yöntemde de derin öğrenme tabanlı yaklaşımlar kullanıldığı için çalışmamızda ikisini de derin öğrenme tabanlı yaklaşımın içerisinde inceleyeceğiz.

3.1. Yüz Algılama ve Takibi

rPPG işlemlerinin ilk aşaması video görüntüsünden yüz bölgesinin tespit edilmesidir. Çalışmaların çoğunda, bir makine öğrenmesi yaklaşımına dayanan Viola-Jones algoritması kullanılarak otomatik olarak yüz algılama gerçekleştirilmiştir. Yüz algılama için kullanılan diğer popüler algoritmalar; dlib (Kazemi & Sullivan, 2014), mtcnn (Zhang ve ark., 2016) ve Kanade-Lucas-Tomasi yaklaşımı (Rautaray & Agrawal, 2012) yüksek doğruluğa sahiptir.

3.2. Analiz Bölgesi (ROI) Tespiti

Görüntüde yüz bölgesi tespit edildikten sonra genel algoritmanın doğruluğu ve güvenilirliği üzerinde doğrudan bir etkisi olduğundan, uygun bir ilgi bölgesi (ROI) seçilmesi ve yüzün belli bir alanının analiz edilmesi diğer zorlu adımdır. ROI, algoritma için ham sinyal sağlayan pikselleri içeren bir video karesi içindeki alandır.

3.2.1. Renk Yoğunluk Temelli Yaklaşım

Kalbin kanı pompalaması ile, tendeki renk değişimi literatürdeki çeşitli çalışmalarla doğrulanmıştır (Verkruysse ve ark., 2008). Bu değişim çıplak gözle görülemese de, kameralar tarafından kolayca yakalanabilmektedir. Özellikle görüntülerdeki insan yüzleri analiz edilerek tendeki renk değişim bilgisine ulaşılabilmektedir. Bununla birlikte yüz bölgesindeki bazı alanlar diğer kısımlara göre bu bilgiyi daha güçlü taşımaktadır. Literatürdeki çalışmalar, alın ve yanak bölgelerinin bu bilgiyi taşıyan en hassas bölgeler olduğunu göstermiştir (Meinzer ve ark., 2013). ROI nin tespiti, en önemli PPG bilgisine sahip bir piksel kümesini bulur ve bu piksellerin uzamsal olarak ortalaması alınarak pletismografi sinyali elde edilir (Kwon ve ark., 2015). Birçok araştırmacı, yüzün diğer bölgelerine kıyasla kas hareketlerine daha az duyarlı oldukları için (ElMaghraby ve ark., 2014) alın ve yanaklarını en önemli ROI alanları olarak seçmiştir. Kişi hareketinin neden olduğu gürültü, sinyali rPPG için işe yaramaz hale getirebilir. Bu nedenle, ROI takibinin amacı, ROI'de bulunan piksellerin kişi hareketinden bağımsız bir cilt bölgesine ait olmasını sağlamaktır.


3.2.2 Derin Öğrenme Tabanlı Yaklaşım

Giriş sinyali, bir dijital kamera tarafından kaydedilen orijinal videodur. Bu nedenle, alakasız arka plan bilgilerini yok saymak için yüz algılama veya cilt segmentasyonu gereklidir. Ayrıca, alın ve yanaklar gibi bazı spesifik cilt bölgeleri daha güçlü sinyaller içerir ve genellikle ROI olarak seçilmektedir (Meinzer ve ark., 2013). Bu bölümde, daha etkili sinyal çıkarımı sağlamak için kullanılan derin öğrenme tabanlı sinyal optimizasyon yöntemlerinden birkaçı incelenmektedir.

Tang ve arkadaşları, konvolüsyonel sinir ağı (CNN) ve kamera tabanlı uzaktan fotopletismografi (rPPG) yöntemlerini birleştirerek yaptıkları çalışmada, cilt tespiti için bir 2D CNN oluşturulmuş ve özel bir video veritabanı üzerinde eğitmiştir (Tang ve ark., 2018). Yaygın olarak kullanılan diğer üç aşamalı cilt algılama yöntemiyle (yani yüz algılama, yüz izleme ve cilt sınıflandırması) karşılaştırıldığında, burada kullanılan CNN yöntemi, cilt algılamayı tek bir adımda gerçekleştirerek, izleme olasılığını arttırılabileceğine odaklanmıştır. CNN-rPPG yöntemi ile düşük maliyetli kamera kullanarak, herhangi bir yüz veya cilt bölgesinden biyosinyalleri çıkararak kalp atış hızı izlenebilmektedir.

Sabokrou ve arkadaşlarının gerçekleştirdiği çalışmada kalp atış hızı tahmin yöntemlerinin genel performansının, büyük ölçüde analiz bölgesinin belirlenmesi ve temsiline bağlı olduğu belirtilmiştir (Sabokrou ve ark., 2021). Analiz Bölgesini (ROI), yüz hareket ve ifade değişikliklerine karşı daha güçlü ve ten rengindeki farklılıkları dikkate alarak temsil etmeyi amaçlamışlardır. Doğru bir kalp atış hızı hesabı için, derin öğrenme yöntemleri kullanılarak analiz bölgesinin (ROI) iyileştirilmesi hedeflenmiştir. Önerilen yöntem Back-End (BE) ve Front-End (FE) olarak iki kısımdan oluşmaktadır. BE kısmı FE' nin çıktısını giriş olarak alarak kalp atış hızını tahmin

etmektedir. FE bölümünde ise ROI tespiti ve iyileştirilmesi (Şekil 3) yapıp ppg sinyalleri elde edilmektedir. Gerçekçi durumlarda, özellikle yüz hareketinin fazla olduğu veya yüzün bazı kısımlarının görünmediği durumlarda ROI'yi tespit etmek zordur. Bu nedenle doğru ve hızlı nesne algılaması için Receptive Field Block (RFB) derin ağı (Receptive Field Block Net for Accurate and Fast Object Detection) tercih edilmiştir. Tespit edilen ROI nin kalitesini arttırmak için çekişmeli üretici ağ (GAN) tarzı bir modül hazırlanmıştır. Yöntemin gerçekçi koşullarda verimli bir şekilde çalışabileceğini göstermek için HR-D veri setini sunmuşlardır. HR-D ve MAHNOB veri kümeleri üzerindeki sonuçlarla, yöntemlerinin gerçek zamanlı bir yöntem olarak çalışabileceğini ve ortalama kalp atış hızını diğer çalışmalardan daha iyi tahmin ettiklerini belirtmişlerdir.



Şekil 3. Yüksek kaliteli ROI tespiti için kullanılan Deep-HR Mimarisi (Sabokrou ve ark., 2021) .

3.3 Pletismografik Sinyal Çıkarımı

Sinyal çıkarma, uzaktan kalp atış hızı ölçüm hattındaki en önemli kısımdır. Temel amacı, kalp atış hızı tahmini için videolardan rPPG sinyalini çıkarmaktır. Daha iyi kalp atış hızı tahmini için çıkarılan rPPG sinyalinin iyileştirilmesi, tahmin doğruluğunu arttırmaya yönelik önemli bir yaklaşımdır (Cheng ve ark., 2021). Sinyal kestiriminde istenmeyen piksel bölgelerinin hesaba katılması sinyalin doğruluğunu olumsuz yönde etkilemektedir. İstenmeyen bu piksel bölgeleri; deneyin hareketi sonucu ROI bölgesinde kayma, kamera sensör gürültüsü ve görüntü sıkıştırılması olmak üzere üç temel etmenden kaynaklanmaktadır (Li ve ark., 2014).

3.3.1 Renk Yoğunluk Temelli Yaklaşım

Sinyali olumsuz etkileyen durumların, rPPG sinyali hesaplaması yapılmadan önce filtrelenmesi ve boyut indirgeme işleminin yapılması gerekmektedir.


Filtreleme, kalp atış hızı frekans bilgisine dayalı olarak ham sinyal işaretlerine dijital filtrelerin uygulandığı süreçtir. Boyut indirgeme uygulamadan önce, iyi bir sinyal-gürültü (SNR) oranı elde etmek için ham sinyaller üzerinde bir filtreleme işlemi gerçekleştirilmelidir. Amaç, sinyal-gürültü oranını artırmak ve böylece tahmini pletismografik sinyalin kalitesini iyileştirmektir (Premkumar & Hemanth, 2022). İşlenmemiş sinyal; öznenin hareketine, aydınlatma değişikliklerine ve diğer faktörlere bağlı olarak istenmeyen gürültü içerebilir (Rouast ve ark., 2018). Hem istenmeyen yüksek hem de düşük frekanslı gürültü, bant geçiren filtreleme kullanılarak ortadan kaldırılabılır. Bu, insan kalp atış hızı için uygun olan frekans bandına ilişkin bir varsayımı gerektirir. 0.7 Hz-4 Hz yaygın bir bant seçimi olup, bu da dakikada 42 ile 240 vuruş (bpm) arasında bir kalp atım hızına karşılık gelir (Bush, 2016). Filtrelenen sinyal, pletismografik sinyal tespiti için doğrudan kullanılabilir (Bousefsaf ve ark., 2013). Poh ve arkadaşlarının yaptığı çalışmaya göre (M. Poh ve ark., 2010) yeşil kanal sinyali diğer kanallara kıyasla daha fazla PPG bilgisi içerir. Bununla birlikte, kırmızı ve mavi kanallar da bazı tamamlayıcı bilgiler taşımaktadır. Yeşil kanal yaklaşımında, bir PPG sinyali elde etmek için filtrelenmiş yeşil kanal bileşeni alınır.

Boyut indirgeme yöntemleri, daha doğru ve sağlam bir PPG bilgi sinyali elde etmek için kullanılmaktadır. rPPG yöntemlerinin ana sınıflandırmaları, ham izlerden pletismografi sinyallerini nasıl çıkardıklarına dayanmaktadır (Premkumar & Hemanth, 2022). Sinyal çıkarma yöntemleri genel olarak üç kategoride sınıflandırılabilir (Hassan ve ark., 2017). 1) Kör kaynak ayırma, 2) Model tabanlı yöntemler, 3) Tasarım tabanlı yöntemler.

Kör kaynak ayrıştırması, karışık sinyaller arasından orijinal sinyalin çıkarımı işlemidir. Bir PPG sinyali, ham sinyallerin ağırlıklı toplamının doğrusal bir kombinasyonu olarak temsil edilen tek boyutlu bir sinyal olarak kabul edilir ve ağırlıkların tahmin etmek zordur (Djeldji et al., 2019). Kör kaynak ayırma (BSS) algoritmalarının amacı, istatistiksel bağımsızlık ve korelasyon nedeniyle istenen PPG sinyalini gürültü ve yapaylıklardan ayırmaktır (Wedekind et al., 2017). Temel bileşen analizi (PCA) ve bağımsız bileşen analizi (ICA), boyutluluk indirgeme için yaygın olarak uygulanan tipik kör kaynak ayrıştırma teknikleridir.

Bu yöntem ile yüksek korelasyonlu değişkenler bir araya getirilir ve çok boyutlu bir veri, aralarında korelasyon içermeyen daha az sayıda değişken ile gösterilmeye çalışılır. PCA, verideki gerekli bilgileri tutarak boyut indirgemeyi sağlamaktadır. Temel bileşenler analizi ile ulaşılmak istenen sonuç, ilgilenilen veri setindeki varyansın en büyük olduğu yani verinin en çok değişim gösterdiği doğrultuyu tespit etmektir. (Aydemir, 2019).

Bağımsız Bileşen Analizi (ICA), çok değişkenli veri kümesinde doğrusal olan, koordinat sistemini bulmaya yarayan istatistiksel bir yöntemdir. Bağımsız bileşen analizi, gürültü giderme, veri madenciliği ve öznitelik çıkarımı ve benzeri problemlerin çözümünde sıklıkla tercih edilmektedir (Aydemir, 2019). Ayrıca kör kaynak ayırma problemlerinde kullanılan yöntemlerden de biridir. Amaç, birden fazla kaynaktan karışmış sinyalleri birbirinden ayırmaktır. Bileşenlerin her biri birbirinden bağımsızdır. Hesaplanan vektörlerin, PCA' da olduğu gibi birbirlerine dik olma şartı yoktur (Şekil 4). PCA' da bazı bileşenler daha yüksek öneme sahip iken, ICA'da tüm bileşenler eşit öneme sahiptir (Aydemir, 2019)



Şekil 4. PCA ve ICA yöntemlerinin karşılaştırılması.

Model tabanlı yaklaşıma ait olan krominans tabanlı (CHROM) algoritmalar, kör kaynak ayrıştırma algoritmasındaki nesne hareketi sorunlarını azaltmaktadır (De Haan & Jeanne, 2013). Bu yaklaşım, aydınlatma rengini normalleştirmek için ayrı ayrı R, G ve B kanallarının işlevlerini araştırmaktadır. Algoritma, ilgili dağınık yansıma bileşenlerine özdeş bir aynasal kesir ekleyerek yansıtıcı yansımanın tüm kanalları etkilediğini varsayar. Böylece, speküler yansıma bileşeni, renk farkı sinyali yani krominans sinyali kullanılarak elimine edilebilir (Premkumar & Hemanth, 2022). Sinyal çıkarma, uzaktan kalp atış hızı ölçüm hattındaki en önemli kısımdır. Temel amacı, kalp atış hızı tahmini için videolardan rPPG sinyalini çıkarmaktır. Daha iyi kalp atış hızı tahmini için çıkarılan rPPG sinyalinin

düzeltilmesi, tahmin doğruluğunu iyileştirmeye yönelik bir yöntemdir.

3.3.2 Derin Öğrenme Tabanlı Yaklaşım

Geleneksel yöntemlerle çıkarılan rPPG sinyali vücut hareketlerinden, aydınlatma değişikliklerinden, kamera sensöründen kaynaklanan çok sayıda gürültüden etkilenmektedir. Bian ve diğerleri tarafından yapılan çalışmada (Bian, 2019), iki katmanlı bir Long Short-Term Memory (LSTM) kullanılarak, gürültülü olan rPPG sinyalinin filtrelenmesi ve gürültüsüz bir rPPG sinyali elde edilmesi için yeni bir regresyon modeli önerilmiştir (Şekil 5). Çok sayıda sentetik gürültü veri eğitiminden sonra, veri odaklı gürültü sinyallerini filtreleyip modelleyebilmesi ve kalp atış hızı tahmininde birçok faydalı sinyali koruyabilmesinden dolayı LSTM tercih edilmiştir. İlk olarak çok sayıda zaman alanı sentetik sinyaliyle LSTM ağı eğitilmektedir. Ardından ağı parametrelerinin hassas ayarını yapmak için, ROI'den çıkarılan sinyal normalleştirilip genel MMSE-HR veri tabanı sinyalinin bir kısmı LSTM ağına alınmaktadır.




Şekil 5. Bian ve ark. tarafından kullanılan mimari (Bian, 2019).

Tsou ve arkadaşları daha iyi bir rPPG sinyali elde etmek için 3 boyutlu CNN'e dayalı bir çerçeve olan Siamese-rPPG ağını kullanmıştır (Tsou ve ark., 2020). Bu ağın arkasındaki fikir, farklı yüz bölgelerinin farklı gürültülerden etkilenebileceği ve kendine ait görünüme sahip olabileceğidir. Ancak, yaklaşık olarak aynı rPPG özelliklerini taşımalıdır. Bu nedenle öncelikle ROI olarak, daha fazla rPPG bilgisi içeren alın ve yanak bölgeleri seçilmiştir. Daha sonra, bu iki ROI'deki pikselleri çıkarmak için sırasıyla alın ve yanak kısmına ikisi de aynı mimariye sahip 3D CNN uygulanmıştır. Bu iki kısma da ağırlık paylaşım mekanizması uygulanır. Böylece yanak veya alın bölgesi gürültü içerse bile, ağı diğer bölgeyi sinyal çıkarmak için kullanarak genel sağlamlığı iyileştirilebilmektedir. Bu iki kısımdan gelen çıktılar, tahmin edilen rPPG sinyalini üretmek için bir ekleme yapılarak iki tane 1 boyutlu evrişim işlemi ve ortalama bir pooling ile birleştirilmektedir.

rPPG uygulamalarında daha farklı kardiyak özellikleri hesaplamak için stres algılama, duygusal sınıflandırma ve sağlık izleme gibi çalışmalarda yüksek kaliteli dalga formları önemlidir (Song ve ark., 2021). Gürültü bileşeni ve model sınırlaması nedeniyle geleneksel yöntemlerin, dalga biçimlerinin kalitesinin düşük kaldığını belirten Song ve arkadaşları bir koşullu üretken çekişmeli ağı (cGAN) ile rPPG sinyalini elde etmek için PulseGAN (Şekil 6) adlı yeni bir yapı sunmuşlardır (Song ve ark., 2021). Bu yöntemde, ilk olarak, 68 noktalı yüz işaretleri tespit edilmekte ve sol ve sağ yanakları kapsayan bu işaret noktalarına göre bir analiz bölgesi (ROI) tespit edilmektedir. Daha sonra, ROI'nin rgb sinyalleri videolardan çıkarılır. Filtreleme işlemlerinden sonra, ham sinyalleri elde etmek için CHROM algoritması kullanılmaktadır. CHROM yöntemi hareket etkilerine karşı hızlı ve kararlı olduğu için seçilmiştir. Hem zaman hem de spektrum alanlarında tanımlanan hata kayıplarına sahip bir üretken çekişmeli ağı çerçevesine dayalı olarak tasarlanan PulseGAN, giriş olarak ham CHROM sinyalini


almakta ve derin üretken model aracılığıyla gelişmiş bir rPPG sinyalini vermektedir. Genel 3 veri setinde test edilen PulseGAN mimarisi geleneksel yöntemleri ve GAN'ı etkin bir şekilde birleştirmektedir. Ayrıca mevcut bazı rPPG yöntemleriyle kolayca entegre edilebilmekte ve rPPG tekniklerinin uygulama kapsamını genişletebilmektedir.



Şekil 6. PulseGAN mimarisi (Song ve ark., 2021).

Chen ve McDuff, 2018'de DeepPhys adlı derin bir evrişimsel ağı kullanarak video tabanlı kalp ve solunum hızı için uçtan uca bir yöntem geliştirmiştir (Chen & McDuff, 2018). Kişinin hareketinden kaynaklanan sorunu çözmek için önerilen bu yöntem, yüzey yansıma modeline dayalı bir hareket temsil algoritması kullanılmaktadır. Sonuç olarak hareketler daha etkili bir şekilde yakalanabilmektedir. Sunulan çalışma, bir hareket ve görünüm modelini birlikte eğiten VGG tarzı bir 2D CNN'dir.


Bugüne kadar yapılan geleneksel çalışmaların çoğunda yalnızca ortalama kalp atış hızının tespit edilmeye çalışıldığı ve bunun atriyal fibrilasyon (AF) tespiti gibi birçok tıbbi uygulamada yeterli olmadığı Yu ve diğerleri tarafından bildirilmiştir. Ayrıca, kalp atış hızı değişkenliği (HRV) analizi için yüzden hassas rPPG sinyallerinin ölçülmesi gerektiği açıklanmıştır (Z. Yu ve ark., 2020). Derin öğrenme yaklaşımlarını kullanarak kalp atış hızını uzaktan tahmin etmek için yapılan bazı çalışmalar birkaç dezavantaj içermektedir: 1) Manuel özellikler içeren ön işleme veya işleme sonrası adımlar gerektirmektedir. 2) Zorlu tıbbi uygulamalarda kullanımı sınırlayan bireysel nabız tepe bilgisi kaybedilmektedir. 3) rPPG ölçüm problemi için gerekli olan zamansal bağlam özelliklerini dikkate almayan 2 boyutlu uzamsal sinir ağına (2D CNN) dayanmaktadır. İşlenmemiş yüz videolarından tam rPPG sinyallerini yeniden oluşturmak için ilk derin uzamsal-zamansal ağı kullanan, PhysNet olarak tanımlanan bir rPPG ölçüm yöntemi sunulmuştur (Şekil 7). Ağın girişi, RGB kanallı T-frame yüz görüntüleridir. Uzamsal-zamansal özellikleri temsil etmek için 2 ana model bulunmaktadır. Video algılama için yaygın olarak kullanılan ve aynı anda zamansal bağlam içeren 3D CNN tabanlı ve CNN uzamsal özellikleri arasında zamansal bağlamı da yakalayabilen RNN tabanlı olmak üzere 2 ana model bulunmaktadır. PhysNet, OBF ve MAHNOB-HCI veri kümeleri üzerinde test edilmiştir. Sonuçların yalnızca ortalama kalp atış hızı tespitinde değil, aynı zamanda AF tespiti ve duygu tanıma için etkili olduğu açıklanmıştır. HRV özelliklerini ve vuruşlar arası aralık (IBI) bilgilerini ölçmek için üstün performans gösterdiği belirtilmiştir.



Şekil 7. 3D CNN PhysNet Mimarisi (Z. Yu ve ark., 2020).

Yu ve ark. karşılaştıkları bazı sorunları şu şekilde aktarmıştır: Geleneksel yöntemlerle rPPG elde etme

çalışmalarında, analiz bölgesi (ROI) tespiti bilgi kaybına neden olabilecek şekilde keyfi olarak seçilmiştir. Teorik olarak tüm cilt pikselleri, rPPG sinyallerinin elde edilmesine katkıda bulunabilmektedir. Ortalama kalp atış hızı tahmininde, önerilen bazı derin öğrenme yöntemleri ise rPPG ölçümü için gerekli olan zamansal özellikleri içermeyen uzamsal 2D CNN'ye dayanmaktadır. Yüksek oranda sıkıştırılmış videolardan ölçülen rPPG sinyalleri, video sıkıştırma işleminin hem frame içi hem de frameler arası kodlamasından kaynaklanan bilgi kaybından dolayı genellikle gürültülü eğri şekli ve hatalı pik konumuyla karşılaşmaktadırlar. Farklı bit hızlarına sahip sıkıştırılmış videolar kullanıldığında, rPPG ölçümünün performansının çeşitli düzeylerde düştüğüne dair yapılmış birkaç çalışma bulunmaktadır. Bu belirtilen problem ve eksikliklerin üstesinden gelmek için iki aşamalı, uçtan uca derin öğrenmeye dayalı bir yöntem olarak STVEN ve rPPGNet mimarisi (Şekil 8) tasarlanmıştır (Z. Yu ve ark., 2019). Kullanılan metotta, STVEN ağı ilk önce videoları iyileştirmektedir. Ardından rPPGNet'in, kalp atış hızı (HR) ve kalp atış hızı değişkenliği (HRV) özellik ölçümü için rPPG sinyallerini elde etmesi amaçlanmaktadır. Yöntem, yüksek oranda sıkıştırılmış videolardan rPPG sinyallerinin elde edilmesi için OBF ve MAHNOB-HCI veri setlerinde test edilmiştir.



Şekil 8. STVEN ve rPPGNet mimarisi (Z. Yu ve ark., 2019).

3.4 Kalp Atış Hızı Tahmini

3.4.1 Renk Yoğunluk Temelli Yaklaşım


Pletismografik sinyalin yaklaşık bir $p(t)$ sinyali verildiğinde, kalp atış hızı, frekans analizi kullanılarak tespit edilebilir. Bu amaçla, belirgin bir periyodiklik içeren bu sinyal, ayrık bir Fourier dönüşümü kullanılarak frekans alanına dönüştürülebilir. Çoğu yazar tarafından tercih edilen algoritma Fast Fourier Transform (FFT) dur. Ayrıca DCT (Irani ve ark., 2014), Welch yöntemi (Li ve ark., 2014) ve kısa süreli Fourier dönüşümünü (STFT) kullanılmaktadır. Frekans alanında, en yüksek spektral güce sahip indekse karşılık gelen frekans, kalp atış hızı frekansı için bir tahmin olarak seçilmektedir.

Sinyalin zirve noktalarını kullanarak, vuruşlar arası aralıklardan kalp atış hızı değişkenliği gibi daha fazla bilgi çıkarmak mümkündür. Pik tespiti yapıp sinyali iyileştirmek için, sinyal genellikle bir kübik spline fonksiyonu (McDuff ve ark., 2014b, 2014a; M. Z. Poh ve ark., 2011) kullanılarak enterpolasyon yapılır. Pikler, sinyal içindeki maksimumlar olduklarından hareketli bir pencere kullanılarak kolayca tanımlanabilmektedir.

3.4.2 Derin Öğrenme Tabanlı Yaklaşım


Geleneksel yöntemlerle yapılan önceki çalışmaların çoğunda kişilerin hareketsiz kalmaları istenmektedir. Bu nedenle yüz videolarının çoğu doğal yüz ifadeleri ve aydınlatma değişiklikleri içermemektedir (Yang ve ark., 2018). Ancak gerçek hayatta hareketler ve aydınlatma değişiklikleri kaçınılmazdır. Gürültülü girişimlerin üstesinden gelmek, modelin periyodik kalp atış hızı özelliğini otomatik olarak öğrenmesini sağlamak için, zaman serilerinin, karşılık gelen spektruma dönüştürüldüğü ve ardından CNN aracılığıyla regresyon yapıldığı sağlam ve

verimli bir yaklaşım Yang ve arkadaşları tarafından sunulmuştur (Yang ve ark., 2018). Önerilen yöntem (Şekil 9) dört adımdan oluşmaktadır. İlk başta, analiz bölgesi (ROI) tanımlanır ve yoğunluk değişiklikleri, ROI üzerinden ortalama yoğunluk değeri hesaplanarak kaydedilmektedir. Daha sonra farklı ön işleme yaklaşımları kullanılmaktadır. Her bir zaman alanı sinyali ve ilgili frekans alanı bileşeni bir spektrum görüntüsünde birleştirilerek farklı ön işleme yöntemleri arasındaki performansı karşılaştırılmaktadır. Son olarak, kalp atış hızı sinyali doğrudan spektrum görüntülerinden tahmin etmek için ImageNet veri seti ile önceden eğitilmiş ResNet18 (He ve ark., 2016) tabanlı bir kalp atış hızı tahmincisi kullanılmaktadır. Yöntemin, ışık değişimi ve baş hareketlerinin neden olduğu girişimin üstesinden gelebildiği ve önceki çalışmaların çoğuna kıyasla üstün performans elde ettiği belirtilmiştir.



Şekil 9. Yang ve diğerleri tarafından kullanılan mimari (Yang ve ark., 2018).

Huang ve arkadaşları tarafından, görsel nabız hızı tahmini veya rPPG elde etme için derin öğrenme teknolojilerine dayanan öncü yaklaşımların bazı eksiklerinin bulunduğu belirtilmiştir: 1) Videolardan veri işleme süreleri uzundur. 2) Tek aşamalı veri hattına sahiptirler. 3) Video kareleri arasında gizlenen geçici bilgiler tam olarak dikkate alınmamaktadır. Bu gibi sınırlılıkların üstesinden gelmek için PRnet (Şekil 10) adını verdikleri ağı tasarlamışlardır (Huang ve ark., 2021). Önerilen mimari, sabit videolardan kalp atış hızı çıkarımı yapmak için tek aşamalı bir derin öğrenme modelidir. PRnet; 3 boyutlu CNN (3D CNN), LSTM ve FC kısımlarından oluşmaktadır. Tanımlanan ROI'den, gizli uzamsal ve zamansal özellikleri çıkarmak için 3D CNN kullanılır. Daha sonra, çıktı özellik haritası, global zamansal özelliklerin elde edilmesi için bir LSTM çıkarıcıya beslenmektedir. Son olarak, çıkarılan özellik haritasından kalp atış hızını tahmin etmek için tam bağlantılı bir katman uygulanmaktadır. PRnet ağı güç spektral yoğunluğu (PSD) ve Hızlı Fourier Dönüşümü (FFT) gibi hiçbir ek geleneksel algoritmanın uygulanmadığı ortak bir optimizasyon mimarisidir. Bu nedenle, önerilen mimari, veri işleme gecikmesi açısından önemli bir avantaj sunmaktadır. Darbe hızını, diğer geleneksel ve derin öğrenme yöntemlerinin büyük çoğunluğundan daha kısa bir pencere boyutuyla (2 sn, 60 kare video) tahmin edebilmektedir.




Şekil 10. PRNet Mimarisi (Huang ve ark., 2021).

Öğrenmeye dayalı bir model kullanan bir yüz video dizisinden uzaktan kalp atış hızı tahmini, eğitim verilerinin eksikliği, hareket, ortam ışığı vb. nedenlerle zor olabilmektedir. Bu zorlukları ele alan SynRhythm mimarisi (Niu ve ark., 2018), derin kalp atış hızı regresyon modelini önceden eğitmek için ImageNet ve büyük miktarda sentetik ritim uzamsal-zamansal haritaları kullanılmaktadır. Yüz video dizilerinden kalp atış hızı


sinyallerinin transfer öğrenimi yoluyla genelden özele uzamsal-zamansal temsillerinde kalp atış hızını doğrudan tahmin etmeyi amaçlamaktadır.

Yüz videolarından kalp atış hızı tespitinde baş hareketi, aydınlatma ve sensör çeşitliliğindeki farklılıklar karşılaşılan bazı problemlerdir. Niu ve diğerleri tarafından bu gibi problemlerin üstesinden gelmesi amacıyla daha stabil bir kalp atış hızı tespiti için derin öğrenmeye dayalı RhythmNet mimarisi (Şekil 11) tasarlanmıştır (Niu ve ark., 2020). Bir giriş video dizisi verilip birden çok kısa video klibe bölünmekte ve yüz hizalaması için her karede yüz ve yer işareti tespiti gerçekleştirilmektedir. Ardından, kalp atış hızı sinyallerini temsil etmek için video klip başına hizalanmış yüz görüntülerinden uzamsal-zamansal haritalar (spatial-temporal maps) üretilmektedir. Daha sonra kalp atış hızını uzamsal-zamansal haritalardan tahmin etmek için CNN'den çıkarılan özellikler, ölçümler arasındaki zamansal ilişkiyi modellemek için bir hücre, bir sıfırlama geçidi ve bir güncelleme geçidinden oluşan tek katmanlı bir GRU (Gated Recurrent Unit) yapısına beslenmektedir. Son olarak, giriş video dizisi için tahmin edilen kalp atış hızı, tek tek video kliplerden tahmin edilen tüm kalp atış hızlarının ortalaması olarak hesaplanmaktadır.



Şekil 11. RhythmNet Mimarisi (Niu ve ark., 2020).

HR-CNN adı verilen uçtan uca derin öğrenme yaklaşımı, bir dizi yüz görüntüsünden kalp atış hızını tahmin etmek amacıyla Şpetlik ve arkadaşları tarafından sunulmuştur. HR-CNN mimarisi (Şekil 12), bir çıkarıcı ve kalp atış hızı tahminicisi içeren, iki aşamalı evrimsel sinir ağından (CNN) oluşmaktadır (Şpetlik ve ark., 2018). Çıkarıcı bir dizi görüntü üzerinde çalıştırılarak, bir NrPPG sinyali olan bir dizi skaler çıktı üretilmektedir. NrPPG sinyali, kalp atış hızını veren tahminciye beslenmektedir. İlk olarak, sinyal-gürültü oranını (SNR) en üst düzeye çıkarmak için eğitilmektedir. Ardından, tahmin edici, gerçek ve tahmin edilen kalp atış hızının ortalama mutlak hatasını (MAE) en aza indirmek için eğitilmektedir. Yöntem, yoğun hareket kaynaklı gürültülere ve ışık girişimine karşı değerlendirmek için kullanılmıştır.



Şekil 12. HR-CNN Mimarisi (Şpetlik ve ark., 2018).

5. Sonuç

Bu çalışmada, videolardan kalp atış hızı tespiti üzerine literatürdeki mevcut yöntemlerin kapsamlı bir incelemesi gerçekleştirilmiştir. Kalp atış hızı kestirim süreci; yüz analiz bölgesi (ROI) tespiti, pletismografik sinyal çıkarımı ve kalp atış

hızı tahmini olarak 3 ana aşamada incelenmiş ve her bir aşama için önerilen yaklaşımlar renk yoğunluk temelli ve derin öğrenme tabanlı olmak üzere ayrı ayrı ele alınmıştır. Özellikle derin öğrenme yöntemleri ile kalp atışı hızı kestirimi sürecindeki aşamaların nasıl iyileştirilebileceği ve nasıl daha yüksek doğrulukta kalp atışı hızı tespiti yapılabileceği analiz edilmiştir. Bununla birlikte derin öğrenme tabanlı yöntemler için karşılaşılan en büyük zorluklardan biri çok fazla eğitim verisi gerektirmesidir. Gerçek zamanlı ve koyu ten rengine sahip kişilerin videolarından fizyolojik sinyallerin tespitindeki problemler ele alınması gereken diğer önemli zorluktur. Çeşitli veri kümeleriyle, farklı yöntemlerin analiz edilmesi ve karşılaştırılması yeni model ve mimarilerin oluşturulmasında katkı sağlayacaktır.

Kaynakça

- Aydemir, B. (2019). *Egzersiz esnasında toplanan fotopletizmografi sinyallerinden kalp atım hızı ve ventilasyon hızı değişkenlerinin ayrıştırılması* [MARMARA ÜNİVERSİTESİ].
<https://acikbilim.yok.gov.tr/handle/20.500.12812/282457>
- Bian, M. (2019). Pattern Recognition and Computer Vision. In *Fundamentals of Uncertainty Calculi with Applications to Fuzzy Inference*. https://doi.org/10.1007/978-94-015-8449-4_9
- Bousefsaf, F., Maaoui, C., & Pruski, A. (2013). Continuous wavelet filtering on webcam photoplethysmographic signals to remotely assess the instantaneous heart rate. *Biomedical Signal Processing and Control*, 8(6), 568–574. <https://doi.org/10.1016/j.bspc.2013.05.010>
- Bush, I. (2016). *Measuring Heart Rate from Video*. https://web.stanford.edu/class/cs231a/prev_projects_2016/finalReport.pdf
- Chen, W., & McDuff, D. (2018). DeepPhys: Video-Based Physiological Measurement Using Convolutional Attention Networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11206 LNCS, 356–373. https://doi.org/10.1007/978-3-030-01216-8_22
- Cheng, C. H., Wong, K. L., Chin, J. W., Chan, T. T., & So, R. H. Y. (2021). Deep learning methods for remote heart rate measurement: A review and future research agenda. In *Sensors* (Vol. 21, Issue 18). MDPI. <https://doi.org/10.3390/s21186296>
- De Haan, G., & Jeanne, V. (2013). Robust pulse rate from chrominance-based rPPG. *IEEE Transactions on Biomedical Engineering*, 60(10), 2878–2886. <https://doi.org/10.1109/TBME.2013.2266196>
- Deng, Y., & Kumar, A. (2020). *Standoff heart rate estimation from video – a review*. 6. <https://doi.org/10.1117/12.2560683>
- Djeldjli, D., Bousefsaf, F., Maaoui, C., & Bereksi-Reguig, F. (2019). Imaging Photoplethysmography: Signal Waveform Analysis. *Proceedings of the 2019 10th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications, IDAACS 2019*, 2, 830–834. <https://doi.org/10.1109/IDAACS.2019.8924239>
- Elgendi, M. (2012). On the Analysis of Fingertip Photoplethysmogram Signals. *Current Cardiology Reviews*, 8(1), 14–25. <https://doi.org/10.2174/157340312801215782>
- ElMaghraby, A., Abdalla, M., Enany, O., & Y. El Nahas, M. (2014). Detect and Analyze Face Parts Information using

- Viola- Jones and Geometric Approaches. *International Journal of Computer Applications*, 101(3), 23–28. <https://doi.org/10.5120/17667-8494>
- Hassan, M. A., Malik, A. S., Fofi, D., Saad, N., Karasfi, B., Ali, Y. S., & Meriaudeau, F. (2017). Heart rate estimation using facial video: A review. In *Biomedical Signal Processing and Control* (Vol. 38, pp. 346–360). Elsevier Ltd. <https://doi.org/10.1016/j.bspc.2017.07.004>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-Decem, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Huang, B., Lin, C.-L., Chen, W., Juang, C.-F., & Wu, X. (2021). A novel one-stage framework for visual pulse rate estimation using deep neural networks. *Biomedical Signal Processing and Control*, 66(June 2020), 102387. <https://doi.org/10.1016/j.bspc.2020.102387>
- Irani, R., Nasrollahi, K., & Moeslund, T. B. (2014). Improved pulse detection from head motions using DCT. *VISAPP 2014 - Proceedings of the 9th International Conference on Computer Vision Theory and Applications*, 3, 118–124. <https://doi.org/10.5220/0004669001180124>
- Kazemi, V., & Sullivan, J. (2014). One millisecond face alignment with an ensemble of regression trees. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1867–1874. <https://doi.org/10.1109/CVPR.2014.241>
- Kwon, S., Kim, J., Lee, D., & Park, K. (2015). ROI analysis for remote photoplethysmography on facial video. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2015-Novem*, 4938–4941. <https://doi.org/10.1109/EMBC.2015.7319499>
- Li, X., Chen, J., Zhao, G., & Pietikäinen, M. (2014). Remote heart rate measurement from face videos under realistic situations. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 4264–4271. <https://doi.org/10.1109/CVPR.2014.543>
- McDuff, D., Gontarek, S., & Picard, R. W. (2014a). Improvements in remote cardiopulmonary measurement using a five band digital camera. *IEEE Transactions on Biomedical Engineering*, 61(10), 2593–2601. <https://doi.org/10.1109/TBME.2014.2323695>
- McDuff, D., Gontarek, S., & Picard, R. W. (2014b). Remote detection of photoplethysmographic systolic and diastolic peaks using a digital camera. *IEEE Transactions on Biomedical Engineering*, 61(12), 2948–2954. <https://doi.org/10.1109/TBME.2014.2340991>
- Meinzer, H. P., Deserno, T. M., Handels, H., & Tolxdorff, T. (2013). ROI Selection for Remote Photoplethysmography. *Informatik Aktuell*, 99–103. <https://doi.org/10.1007/978-3-642-36480-8>
- Niu, X., Han, H., Shan, S., & Chen, X. (2018). SynRhythm: Learning a Deep Heart Rate Estimator from General to Specific. *Proceedings - International Conference on Pattern Recognition*, 2018-Augus(i), 3580–3585. <https://doi.org/10.1109/ICPR.2018.8546321>
- Niu, X., Shan, S., Han, H., & Chen, X. (2020). RhythmNet: End-to-End Heart Rate Estimation from Face via Spatial-Temporal Representation. *IEEE Transactions on Image Processing*, 29, 2409–2423. <https://doi.org/10.1109/TIP.2019.2947204>
- Pagano, T. P., Santos, V. R., Bonfim, Y. da S., Paranhos, J. V. D., Ortega, L. L., Sá, P. H. M., Nascimento, L. F. S., Winkler, I., & Nascimento, E. G. S. (2022). Machine Learning Models and Videos of Facial Regions for Estimating Heart Rate: A Review on Patents, Datasets, and Literature. *Electronics (Switzerland)*, 11(9). <https://doi.org/10.3390/electronics11091473>
- Poh, M., McDuff, D. J., & Picard, R. W. (2010). Noncontact automated cardiac pulse measurements using video imaging and blind.pdf. *Medical Optics and Biotechnology*, 18(10), 795–805.
- Poh, M. Z., McDuff, D. J., & Picard, R. W. (2011). Advancements in noncontact, multiparameter physiological measurements using a webcam. *IEEE Transactions on Biomedical Engineering*, 58(1), 7–11. <https://doi.org/10.1109/TBME.2010.2086456>
- Premkumar, S., & Hemanth, D. J. (2022). Intelligent Remote Photoplethysmography-Based Methods for Heart Rate Estimation from Face Videos: A Survey. In *Informatics* (Vol. 9, Issue 3). MDPI. <https://doi.org/10.3390/informatics9030057>
- Rautaray, S. S., & Agrawal, A. (2012). *R Eal T Ime H and G Esture R Ecognition*. 3(1), 21–31.
- Rouast, P. V., Adam, M. T. P., Chiong, R., Cornforth, D., & Lux, E. (2018). Remote heart rate measurement using low-cost RGB face video: a technical literature review. In *Frontiers of Computer Science* (Vol. 12, Issue 5, pp. 858–872). Higher Education Press. <https://doi.org/10.1007/s11704-016-6243-6>
- Sabokrou, M., Pourreza, M., Li, X., Fathy, M., & Zhao, G. (2021). Deep-HR: Fast heart rate estimation from face video under realistic conditions. *Expert Systems with Applications*, 186. <https://doi.org/10.1016/j.eswa.2021.115596>
- Shao, D., Liu, C., & Tsow, F. (2021). Noncontact Physiological Measurement Using a Camera: A Technical Review and Future Directions. *ACS Sensors*, 6(2), 321–334. <https://doi.org/10.1021/acssensors.0c02042>
- Sinhal, R., Singh, K., & Raghuvanshi, M. M. (2020). An Overview of Remote Photoplethysmography Methods for Vital Sign Monitoring. *Advances in Intelligent Systems and Computing*, 992, 21–31. https://doi.org/10.1007/978-981-13-8798-2_3
- Song, R., Chen, H., Cheng, J., Li, C., Liu, Y., & Chen, X. (2021). PulseGAN: Learning to Generate Realistic Pulse Waveforms in Remote Photoplethysmography. *IEEE Journal of Biomedical and Health Informatics*, 25(5), 1373–1384. <https://doi.org/10.1109/JBHI.2021.3051176>
- Spetlik, R., Franc, V., Cech, J., & Matas, J. (2018). Visual heart rate estimation with convolutional neural network. *British Machine Vision Conference 2018, BMVC 2018*, 1–12.
- Sun, Y., & Thakor, N. (2016). Photoplethysmography Revisited: From Contact to Noncontact, from Point to Imaging. *IEEE Transactions on Biomedical Engineering*, 63(3), 463–477. <https://doi.org/10.1109/TBME.2015.2476337>
- Swinehart, D. F. (1962). The Beer-Lambert law. *Journal of Chemical Education*, 39(7), 333–335. <https://doi.org/10.1021/ed039p333>
- Tamura, T., Maeda, Y., Sekine, M., & Yoshida, M. (2014). Wearable photoplethysmographic sensors—past and present. *Electronics*, 3(2), 282–302. <https://doi.org/10.3390/electronics3020282>
- Tang, C., Lu, J., & Liu, J. (2018). Non-contact heart rate monitoring by combining convolutional neural network skin detection and remote photoplethysmography via a low-cost

- camera. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 2018-June, 1390–1396. <https://doi.org/10.1109/CVPRW.2018.00178>
- Tsou, Y. Y., Lee, Y. A., Hsu, C. T., & Chang, S. H. (2020). Siamese-rPPG network: Remote photoplethysmography signal estimation from face videos. *Proceedings of the ACM Symposium on Applied Computing*, 2066–2073. <https://doi.org/10.1145/3341105.3373905>
- Verkruijse, W., Svaasand, L. O., & Nelson, J. S. (2008). Remote plethysmographic imaging using ambient light. *Optics Express*, 16(26), 21434. <https://doi.org/10.1364/oe.16.021434>
- Wang, W. (2017). *Robust And Automatic Remote Photoplethysmography* (Vol. 1, Issue 2017). https://pure.tue.nl/ws/files/78340965/20171023_Wang.pdf%0Ahttps://research.tue.nl/en/publications/robust-and-automatic-remote-photoplethysmography%0Ahttps://pure.tue.nl/ws/portalfiles/portal/78340965/20171023_Wang.pdf
- Wedekind, D., Trumpp, A., Gaetjen, F., Rasche, S., Matschke, K., Malberg, H., & Zaunseder, S. (2017). Assessment of blind source separation techniques for video-based cardiac pulse extraction. *Journal of Biomedical Optics*, 22(3), 035002. <https://doi.org/10.1117/1.jbo.22.3.035002>
- YAMAN, A. U. (2018). *Yüz tanıma sistemlerinin yanıtılmasına karşı bir yöntem: yüz videolarında nabız tespiti ile canlılık doğrulaması* [Ankara Üniversitesi]. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp?id=UwWffTuiMVwjS85blanc6Q&no=LlzkDJAuYHVHoM9tysjGIA>
- Yang, W., Li, X., & Zhang, B. (2018). Heart Rate Estimation from Facial Videos Based on Convolutional Neural Network. *Proceedings of 2018 6th IEEE International Conference on Network Infrastructure and Digital Content, IC-NIDC 2018*, 45–49. <https://doi.org/10.1109/ICNIDC.2018.8525602>
- Yu, Z., Li, X., & Zhao, G. (2020). Remote photoplethysmograph signal measurement from facial videos using spatio-temporal networks. *30th British Machine Vision Conference 2019, BMVC 2019*.
- Yu, Z., Peng, W., Li, X., Hong, X., & Zhao, G. (2019). Remote heart rate measurement from highly compressed facial videos: An end-to-end deep learning solution with video enhancement. *Proceedings of the IEEE International Conference on Computer Vision, 2019-October*, 151–160. <https://doi.org/10.1109/ICCV.2019.00024>
- Zhang, K., Zhang, Z., Li, Z., & Qiao, Y. (2016). Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks. *IEEE Signal Processing Letters*, 23(10), 1499–1503. <https://doi.org/10.1109/LSP.2016.2603342>



Ön-Eğitilmiş CNN Mimarilerinin Füzyonu ile Mısır Yaprağı Hastalıklarının Sınıflandırılması

Ahmet Ciran¹, Erdal Özbay^{2*}

¹ Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye, (ORCID: 0000-0003-0280-5542), aciran@gmail.com

^{2*} Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye (ORCID: 0000-0002-9004-4802), erdalozbay@firat.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1216356)

ATIF/REFERENCE: Ciran, A. & Özbay, E. (2022). Ön-Eğitilmiş CNN Mimarilerinin Füzyonu ile Mısır Yaprağı Hastalıklarının Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 74-83.

Öz

Mısır, dünyanın birçok yerinde temel gıda olarak kullanılmaktadır. Mısır, yağ ve yüksek fruktozlu mısır şurubu yapmak için kullanılabilecek iyi bir nişasta kaynağıdır. Mısır ve mısır unu çok hayati ürünler olduğundan, Yanık, Pas ve Gri Yaprak Lekesi gibi bazı hastalıkların erken teşhisiyle bitkilerin iyileştirilmesini sağlanarak ürün kalitesinin düşmesi önlenilebilecektir. Bu sayede hem ürünün kalitesi hem de elde edilen ürün miktarı artırılabilir. Bu çalışmada, Evrişimli Sinir Ağı (CNN) tabanlı VGG-19, DenseNet-201 ve NasNet-Large modelleri kullanılarak mısır yaprağı görüntülerinden öznetelik çıkarımı yapılmıştır. Veri setindeki dengesizliğin giderilmesi için Sentetik Azınlık Yüksek Örneklem Tekniği (SMOTE) yöntemi ile balans ayarı yapılmıştır. Öznetelik sayısını düşürmek için boyut indirgeme yöntemlerinden Temel Bileşen Analizi (PCA) kullanılmıştır. Mısır yaprağındaki hastalıkları sınıflandırmak amacıyla Destek-Vektör Makinaları (SVMs) algoritması kullanılmıştır. Algoritmanın performansını artırmaya yönelik GridSearchCV yaklaşımı ile mısır yapraklarındaki hastalıkları tanımlamak için Kernel function ve Box constrain hiperparametreleri optimize edilmiştir. Elde edilen deneysel sonuçlar genel erişime açık Kaggle mısır veya mısır yaprağı hastalığı veri kümesi üzerinde test edilmiştir. Elde edilen deneysel sonuçlarda sadece CNN ile özellik çıkarımı yapılan görüntülerin LibSVM ile sınıflandırılmasında 4 sınıf için sırasıyla %94,5, %94,4, %94,3, ve %96,2 doğruluk oranlarına ve %94,3 ağırlıklı ortalamaya ulaşılmıştır. Önerilen yöntem kullanılarak LibSVM ile 4 sınıf için sırasıyla %96,7, %96,7, %96,7 ve %97,8 doğruluk oranlarına ve %96,7 ağırlık ortalamaya ulaşılmıştır. Böylece önerilen yöntemle elde edilen sınıflandırma doğruluğunda optimizasyon yapılmadan elde edilen sınıflandırma doğruluğuna göre birinci sınıf için %2,2, ikinci sınıf için %2,3, üçüncü sınıf için %2,4 ve dördüncü sınıf için %1,6, bununla birlikte ağırlıklı ortalamada %2,4 oranında iyileşme sağlandığı görülmüştür.

Anahtar Kelimeler: CNN, LibSVM, Mısır yaprağı, Optimizasyon, PCA, Sınıflandırma.

Classification of Maize Leaf Diseases by Fusion of Pre-Trained CNN Architectures

Abstract

Maize is used as a staple food in many parts of the world. Maize is a good source of starch that can be used to make oil and high fructose corn syrup. Since maize and maize flour are very vital products, early diagnosis of some diseases such as Blight, Rust, and Gray Leaf Spot can prevent the deterioration of product quality by improving the plants. In this way, both the quality of the product and the amount of product obtained can be increased. In this study, feature extraction was performed from corn leaf images using Convolutional Neural Network (CNN) based VGG-19, DenseNet-201, and NasNet-Large models. In order to eliminate the imbalance in the data set, the balance was adjusted with the Synthetic Minority Over-Sampling Technique (SMOTE) method. Principal Component Analysis (PCA), one of the dimension reduction methods, was used to reduce the number of features. Support-Vector Machines (SVMs) algorithm was used to classify diseases in maize leaves. With the GridSearchCV approach to improving the

* Sorumlu Yazar: erdalozbay@firat.edu.tr

performance of the algorithm, the Kernel function and Box constrain hyperparameters have been optimized to identify diseases in corn leaves. The experimental results obtained were tested on the publicly accessible Kaggle corn or maize leaf disease dataset. In the experimental results obtained, 94.5%, 94.4%, 94.3%, and 96.2% accuracy rates and a weighted average of 94.3% were achieved for the 4 classes, respectively, in the classification of the images with only CNN and feature extraction with LibSVM. Using the proposed method, 96.7%, 96.7%, 96.7%, and 97.8% accuracy rates and 96.7% weight average were achieved for 4 classes with LibSVM, respectively. Thus, according to the classification accuracy obtained without optimization in the classification accuracy obtained with the proposed method, it was observed that there was an improvement of 2.2% for the first class, 2.3% for the second class, 2.4% for the third class, and 1.6% for the fourth class, and 2.4% in the weighted average.

Keywords: CNN, LibSVM, Maize leaf, Optimization, PCA, Classification.

1. Giriş

Son yıllarda mısır, modern dünyanın gıda ürünü ve çok çeşitli şekillerde kullanılabilen en önemli tahıl ürünü haline gelmiştir. İnsan beslenmesinde buğday ve pirinçten sonra en çok kullanılan bitkilerden biridir. Mısır, dört ay gibi bir sürede 2,5-4,5 metreye kadar büyüebilmekte ve bitki başına 600-1000 tohum verebilmektedir (Kırtok, 1998).

Mısır bitkisi tahıl ve otsu gövde olmak üzere iki şekilde kullanılabilir. Tahıl olarak doğrudan insan beslenmesinde (ekmek ve atıştırma olarak) kullanılmaktadır, ancak aynı zamanda yemeklik yağ, nişasta, glikoz ve yem sektörlerinde de kullanılabilir. Otsu vücut ise hayvan besini olarak kullanılmaktadır (Şahin, 2001).

Tarım ürünlerindeki genel mahsul, dünya nüfusu arttıkça önem kazanmıştır. Bu nedenle, en önemli araştırma alanlarından biri, bütün bitkileri etkileyen bitki hastalıklarının belirlenmesidir. Bitki hastalıkları, tarımsal verimliliği ve kaliteyi etkileyen faktörlerden biridir (Weizheng, 2008). Hem verim hem de kalite kaybına neden olan bu hastalıklar önlenmediği takdirde tüm ürünler bundan etkilenmektedir. Bitkilerdeki hastalıkların tespiti için belirli peryotlarla bitki yapraklarının gözlemlenmesi gerekmektedir.

Mısırdaki gri yaprak lekesi, *Cercospora zeae-maydis* mantarının neden olduğu bir mısır hastalığıdır. Şu anda dünya çapında mısırın en önemli verim sınırlayıcı hastalıklarından biri olarak görülmekte ve doğu Amerika Birleşik Devletleri'nin birçok bölgesinde ve daha yakın zamanda ABD Mısır Kemer ve Afrika'nın geniş alanlarında mısır üretimi için ciddi bir tehdit oluşturmaktadır. Tipik olarak, semptomları alt yapraklarda görülmektedir (Ward, 1999). Şekil 1'de gri yaprak lekesi hastalığına sahip bir mısır yaprağı örneği gösterilmektedir.



Şekil 1. Gri yaprak lekeli mısır yaprağı

Düşük sıcaklıklar (16-23 °C) ve yüksek bağıl nem (%100), mısırdaki patojen *Puccinia sorghi*'nin neden olduğu yaygın pas mısır hastalıklarını desteklemektedir (Campus, 2012). Lezyonlar fonksiyonel yaprak alanını ve fotosentezi azaltmaktadır. Bu hastalığa bağlı olarak yaprakların hem üst hem de alt tarafında lekeler oluşmaktadır (Dillard & Seem, 1990). Şekil 2'de yaygın

pas lekeli hastalığına sahip bir mısır yaprağı örneği gösterilmektedir.



Şekil 2. Yaygın pas lekeli mısır yaprağı

Mısır yaprağı yanıklığı, *Exserohilum turcicum* mantarının neden olduğu bir mısır hastalığıdır. Bu hastalık düşük ila orta sıcaklıklarda ve yüksek bağıl nemde gelişmektedir. Semptomlar, yapraklar üzerinde oldukça büyük, gri, puro şeklinde lezyonların gelişmesi ile karakterize edilmektedir (Sibiya & Sumbwanyambe, 2019). Şekil 3'te yanık hastalığına sahip bir mısır yaprağı örneği gösterilmektedir.



Şekil 3. Yanık hastalıklı mısır yaprağı

Bu araştırma, biyolojik önemi büyük olan mısır hastalıklarını yapay zekâ yöntemlerinden biri olan derin öğrenme ile tespit etmeyi amaçlamaktadır. Bu konuda, literatürde yapılmış birçok çalışma bulunmaktadır.

Mevcut çalışmalardan yapılmış deneylerden birinde çeşitli görüntü işleme tekniklerini kullanarak mısır hastalığını tespit etmek için bir sistem oluşturulmuştur. RGB yaklaşımı yaprak görüntülerindeki renkleri tanımlamak için kullanılmış ve çeşitli özellik çıkarma yaklaşımları uygulanmıştır. Bu çalışmada destek vektör makineleri, karar ağaçları, rastgele orman ve naive bayes sınıflandırıcıları kullanılmıştır. Uygulanan birçok sınıflandırıcı ile RGB'yi tanımlamada başarılı sonuçlar elde edilmiştir (Kusumo vd., 2018).

Başka bir çalışma, genetik algoritmalar kullanan destek vektör makinelerinin, mısır hastalığı sınıflandırmasında destek vektör makinelerinden daha iyi sonuçlar üretilebileceği gösterilmiştir (Zhang vd., 2015).

Bhange vd., meyvelerin fotoğraflarını bir sisteme yükleyerek çiftçilerin meyve hastalıklarını tanımlamasına yardımcı olmak adına web tabanlı bir teknik önermişlerdir. Bu algoritma, nar tohumlarından önceden öğrenilmiş bir veri kümesini kullanmıştır. Kullanıcılar analiz etmek üzere sisteme çeşitli fotoğraflar aktarma yoluyla katkı sağlamıştır ve bu fotoğraflar, eğitim veri setindeki görüntülerle karşılaştırılarak hastalık şiddetini belirlemek için birkaç işlem adımından geçmiştir. Önerilen yaklaşımın deneysel sonuçlarında %82 doğruluk değerine ulaşılmıştır (Bhange & Hingoliwala, 2015).

Pujari vd. tarafından destek vektör makinaları (SVM'ler) ve YSA'ları karşılaştıran bir çalışma yürütülmüştür (Pujari vd., 2016). Buğday hastalıklarının yaprak görüntüleme ve veri işleme teknikleri kullanılarak tanımlanması, son zamanlarda çiftçiler tarafından büyük tarlaları izlemek için yaygın olarak kullanılmaktadır. SVM'ler, buğdaydaki hastalıkları tespit etmek ve sınıflandırmak için Dixit ve Nema gibi araştırmacılar tarafından kullanılmıştır. Araştırmada buğday yapraklarının SVM tanımlamasının önündeki temel endişeleri ve engelleri ayrıntılı olarak tartışmışlardır (Dixit & Nema, 2018).

2. İlgili Çalışmalar

Mısır yaprağı hastalığının anında ve kesin teşhisi için çok sayıda çalışma ortaya konmuştur. Araştırmacılar, farklı semptomlara sahip çeşitli bitki hastalıklarının hızlı tespiti için birçok yöntemi test etseler de, deneyimsiz çiftçiler için teşhis etmek profesyonel bitki patoloğlarına göre çok kolay değildir (Miller vd., 2009). Bitkilerin hastalık teşhisi ile tecrübesiz çiftçilere yardımcı olunabilmesi bakımından bitkilerin görsel görünümü ile farklı hastalıkları otomatik tespit etmek oldukça önemlidir.

Sayısal görüntü işleme yöntemleri, destek vektör makineleri, yapay sinir ağları ve diğer birkaç teknik yardımıyla yaprak hastalıklarının tespiti ve sınıflandırılması yapılmıştır (Song vd., 2007, Chen vd., 2011, Qi vd., 2016, Xu vd., 2015). Song vd., farklı mısır yaprağı hastalıklarını %89.6 doğrulukla saptamak için bir SVM yöntemi uygulamışlardır (Song vd., 2007). Bu SVM tabanlı sınıflandırma yöntemi, en iyi doğruluğu sağlamasa da küçük veri kümeleri ve büyük veri kümeleri için faydalıdır.

Sibiya ve ark., akıllı telefon kameraları tarafından toplanan mısır yaprağı hastalığı görüntülerini tanımak ve sınıflandırmak için bir CNN ağını eğiterek kullanmıştır. Araştırmada elde edilen %92,85'lik ortalama doğruluk değeri, CNN'in bu alanda uygulanabilirliğini göstermiştir (Sibiya & Sumbwanyambe, 2019).

Kapon, mısır yaprağı hastalıklarıyla ilgili yaptığı çalışmada CNN mimarilerinden EfficientNet'i kullanmıştır. Önerilen yöntemde dört sınıf için sırasıyla %91,30, %97,71, %93,10 ve %100 doğruluk oranı elde etmiştir (Kapon, 2022).

Whxna, yaptığı çalışmalarda CNN mimarilerinden SqueezeNet'i ve optimize edici olarak Adam yöntemini kullanmıştır (Whxna, 2022).

Rage, mısır yaprağı hastalıklarıyla ilgili yaptığı çalışmada CNN mimarilerinden VGG16'yı ve optimize edici olarak Adam yöntemini kullanmıştır. Önerilen yöntemde mısır yaprakları için elde edilen doğruluk oranı %90,82'dir (Rage, 2022).

Panigrahi vd., düzeltilmiş doğrusal birim aktivasyon fonksiyonu ve bir Adam optimize edici ile parametreler değiştirilerek, geliştirilmiş CNN modeli ile ortalama % 98.78'lik doğruluk oranına ulaşmışlardır. (Panigrahi vd., 2020).

Olasılıksal sinir ağı (PNN) ve görüntü işleme yaklaşımı kullanılarak mısır yaprağı hastalıklarının tanımlanması için Chen ve Wang tarafından bir yöntem önerilmiştir (Chen vd., 2011). Bu yöntemler kullanılarak %90,4 doğruluk elde edilmektedir. Burada PNN sınıflandırıcısının dezavantajı, eğitim örneklerindeki artış nedeniyle hem doğruluk hem de yöntem hızının azalmasıdır. Xu vd., yedi tip mısır yaprağı üzerinde denenen adaptif ağırlıklandırma çoklu sınıflandırıcı füzyonuna dayalı mısır yaprağı hastalığı tespiti için bir yöntem önermişlerdir (Xu vd., 2015). Ortalama tanıma oranında %94,71'e ulaşılmıştır. Wang vd., Qi vd. ve Zhang mısır yapraklarının hastalıklarını tanımlamak için çeşitli görüntü işleme yöntemleri ve kombinasyon özellikleri önermişlerdir (Wang vd., 2009, Qi vd., 2016, Zhang vd., 2013). Bu çalışmalar maksimum %95,3 tanıma doğruluğuna sahiptir. Önerilen bu model, en iyi tanıma doğruluğu için mevcut talepleri karşılayamamaktadır. Derin öğrenme, son yıllarda mükemmel ilerlemeler sağlamıştır (Krizhevsky vd., 2017). Daha büyük boyutlu giriş görüntüsünden kullanışlı özellik gösterimi çıkarma yeteneğine sahiptir. Ayrıca, tarım alanında doğruluğun iyileştirilmesine ve bilgisayarlı görme kapsamının genişletilmesine yardımcı olan, mahsul hastalıklarının doğru bir şekilde tanımlanması için dedektörlere yardımcı olmaktadır.

Al-Amin, patates yapraklarından patates hastalığını tahmin etmek için Evrişimli Sinir Ağı (CNN) modelini önermiştir (Al-Amin vd., 2019). Önerilen yaklaşım modelleriyle en yüksek %98,33 doğruluğa ulaşılmıştır. Lu vd., 10 çeşit pirinç hastalığının tespiti için farklı algoritmalar, havuzlama işlemleri ve filtre boyutları kullanmış ve burada %95,48 doğruluk elde eden CNN tabanlı bir model önermiştir (Lu vd., 2017).

DeChant vd., mısırın kuzey yaprak yanıklığı hastalığının tespiti için CNN modelini kullanmış ve %96,7 doğruluk elde etmiştir (DeChant vd., 2017). Bu yöntemler, daha uzun yakınsama süresi ve daha fazla parametre ile daha iyi doğruluk sağlamasına rağmen, tanımlama oranına zarar vermektedir.

Sonuç olarak literatürde yapılmış mevcut çalışmalardan da anlaşılacağı üzere çalışmada ele alınan konu birçok araştırmacı tarafından üzerinde çalışılan popüler ve aktif bir çalışma alanıdır.

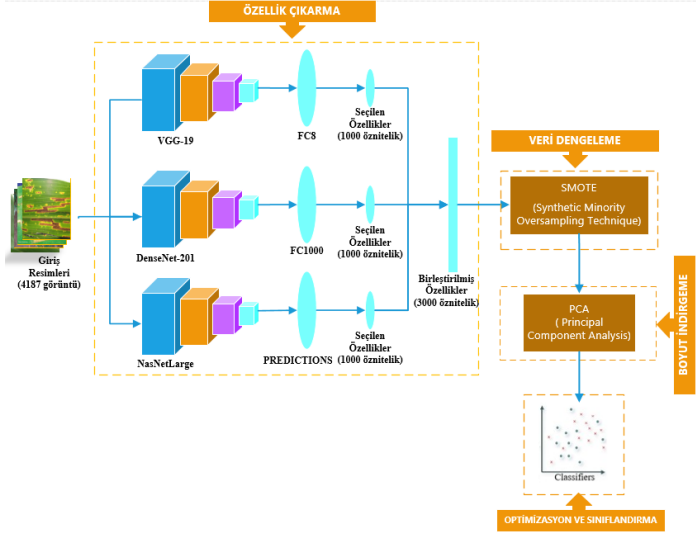
3. Materyal ve Metot

Bu çalışmada literatürde yaygın olarak kullanılan CNN tabanlı VGG-19, DenseNet-201 ve NasNet-Large modeller hibrit bir şekilde kullanılarak 24 bitlik görüntülerden özellik çıkarımı yapılmıştır. Elde edilen özelliklere, SMOTE işlemi yapılarak veri setinde balans ayarı yapılmış ve PCA ile boyut indirgeme tekniği uygulanmıştır. Daha sonra makina öğrenmesi sınıflandırıcılarından LibSVM modeli GridSearchCV yöntemiyle optimize edilerek mısır yaprakları hastalıkları tespit edilmiştir.

Makine öğrenmesi teknikleri ile yapılan sınıflandırmaların testlerle etkinliğinin tespit edilmesi önemlidir. Bu bakımdan doğruluk belirlenirken oluşturulan modelin performansı da dikkate alınmaktadır. Bu performansı belirlemek için bir karmaşıklık matrisi kullanılmıştır. Bu matris daha sonra doğruluk, kesinlik, duyarlılık ve F-ölçütü endekslerini

hesaplamak için kullanılmıştır. Bu sayede mısır yaprağı hastalıklarının belirlenmesi için bir yol haritası oluşturulmuştur.

Bu bölümde çalışmada kullanılan veri seti, CNN mimarileri, PCA, makine öğrenmesi sınıflandırmaları ve optimizasyon yöntemleri incelenmiştir. Makalede önerilen yöntemin akış diyagramı Şekil 4'te verilmiştir.



Şekil 4. Önerilen yöntemin akış diyagramı

3.1. Veri Seti

Çalışmanın veri seti kamuya açık bir veri kümesidir (Ghose, 2022). İlişkili veri setinde toplamda 4187 adet görüntü kullanılmıştır. Bu görüntülerin 1306 tanesi yaygın pas hastalığı olan görüntüler, 574 tanesi gri yaprak lekesi hastalığı olan görüntüler, 1145 tanesi yanık hastalığı olan görüntüler ve 1162 tanesi sağlıklı mısır yaprağı olan görüntülerdir. Veri setinde kullanılan görüntüler 24-bit ve renkli görüntülerdir.

3.2. Özellik Çıkarımı


Yeni bir CNN mimarisi tasarlamak, büyük miktarda veri ve kaynak gerektirdiğinden zaman alıcı bir süreçtir. Bununla birlikte ön-egitilmiş CNN mimarilerinin etkili bir şekilde kullanılmasıyla verimli sonuçlar elde etmek mümkündür. AlexNet, ResNet-101, DarkNet-53, VGG-19, DenseNet-201 ve NasNet-Large gibi önceden eğitilmiş modeller transfer öğrenimi için kullanılabilir.

Bu çalışmada transfer öğrenimi için ImageNet veri setinden ağırlıklar kullanılarak, önceden eğitilmiş VGG-19, DenseNet-201 ve NasNet-Large modelleri ile özellik çıkarımları yapılmıştır. Şekil 4'te önerilen yöntemle özellik çıkarımı gösterilmiştir.

3.2.1. Evrişimli Sinir Ağı (CNN)

Yapay zekânın bir dalı olan derin öğrenme, günümüzde son derece önemlidir. Ancak teknoloji ve veriler geliştikçe 2010'ların başında yeniden ortaya çıkmaya başlamıştır (Floridi, 2020). Son derece güçlü performans sonuçları üreten CNN modeli, bu ilginin ana itici güçlerinden birisidir. CNN yapısı, çağrışımları kullanan çok katmanlı bir YSA olarak düşünülebilir, en az bir katman matematiksel bir işlemi temsil etmektedir. Evrişimli katmanlara ek olarak, doğrusal olmayan katmanlar, havuz katmanları, düzgülleştirme katmanları ve YSA ile aynı işlevselliğe sahip tam bağlantılı katman bulunmaktadır (Albawi ve diğ., 2017).

Çok katmanlı yapısı, CNN'nin görüntüleri tek yapılı yapay sinir ağlarından daha hızlı ve daha iyi sonuçlarla sınıflandırmasını sağlamaktadır. CNN modelleri, evrişim katmanları, havuz katmanları, etkinleştirme işlevi katmanları ve tam bağlantılı katmanlar olmak üzere dört ana katmandan oluşmaktadır. Şekil 5'te tipik bir CNN mimarisi gösterilmektedir.




Şekil 5. CNN mimarisi

3.2.1.1. VGG-19 Modeli

VGG-19, 224×224 görüntü giriş boyutunu almaktadır. VGG'nin evrişimli katmanları, minimum alıcı bir alandan, yani 3×3'ten en küçük boyuttan yararlanmaktadır. Bunu bir ReLU aktivasyon fonksiyonu izlemektedir. ReLU, düzeltilmiş doğrusal birim aktivasyon fonksiyonu anlamına gelmektedir. ReLU'nun girişin pozitif olması için parça parça doğrusal bir fonksiyon olması demektir. Aksi halde girişin negatif olması çıkışın sıfır olması demektir. Evrişimden sonra uzamsal çözünürlüğün korunmasını sağlamak için sonraki adım 1 pikselde sabitlenmektedir (Geekycodesco, 2022).

VGG-19, tam bağlantılı üç katmana sahiptir. Üç katmanın ilk ikisinde her biri 4096 düğüm bulunmaktadır ve üçüncü katmanda 1000 düğüm bulunmaktadır. Bu, imagenet veri kümesinin sahip olduğu toplam sınıf sayısıdır (Geekycodesco, 2022). Şekil 6'da VGG-19 mimarisinin yapısı gösterilmiştir.




Şekil 6. VGG-19 mimarisi

Bu çalışmada CNN mimarisinde ön eğitimli VGG-19 modeli kullanılarak toplamda 4187 görüntüden 1000 öznelikli bir çıktı elde edilmiştir.

3.2.1.2. DenseNet-201 Modeli

DenseNet (Huang vd., 2017), verimli ve derin bir model oluşturmak için tüm katmanları bütünleştirmektedir. ResNet'e çok benzer, ancak bazı önemli farklılıkları bulunmaktadır. DenseNet, her katmanın bir sonraki katmanı beslemesi bakımından ResNet'e benzer bir modeldir. Bu ileri beslemeli bağlantılar sayesinde katman sayısı L'den L(L + 1)/2'ye artmaktadır (Miglanı & Bhatia, 2020). Her katmanın girişi, önceki tüm seviyeler için özellik haritalarını içermektedir. DenseNet, kaybolan gradyanları çözme yeteneği gibi birçok avantaja sahiptir (Lumini & Nanni, 2019). Şekil 7, DenseNet-201 mimarisini göstermektedir.




Şekil 7. DenseNet-201 mimarisi

Bu çalışmada CNN mimarisinde ön eğitilmiş DenseNet-201 modeli kullanılarak toplamda 4187 görüntüden 1000 öznitelikli bir çıktı elde edilmiştir.

3.2.1.3. NasNet-Large Modeli

Görüntü sınıflandırması için önemli bir ağ mimarisi oluşturmuşlardır. Küçük bir veri kümesinde mimari ağ blokları bulmayı ve ardından blokları daha büyük bir veri kümesine taşımayı önermişlerdir. Bu teknolojinin ana katkısı, NASNet arama kapsamı olarak bilinen yeni bir arama kapsamının oluşturulmasıdır. En uygun evrişim katmanını ("hücre") küçük bir veri kümesinde bulabilir ve daha büyük bir veri kümesine uygulayabilirsiniz. Bu ağ bileşenlerini daha fazla istifleyerek ağ, daha karmaşık ve daha büyük veri kümelerini işleyebilir. Bu ağ evrişim tasarımı NASNet mimarisi olarak adlandırılmıştır (Zoph vd., 2018). Şekil 8, NasNet-Large mimarisini göstermektedir.



Şekil 8. NasNet-Large mimarisi

Bu çalışmada CNN mimarisinde ön eğitilmiş nasnetlarge modeli kullanılarak toplamda 4187 görüntüden 1000 öznitelikli bir çıktı elde edilmiştir.

3.2.2. Mimari Birleştirme

Bu araştırmada CNN modellerinden VGG-19, DenseNet-201 ve NasNet-Large mimarileri kullanılarak 4187 görüntüden öznitelikler çıkarılmıştır. Daha sonra MATLAB 2021b ortamı ile elde edilen öznitelikler birleştirilip hibrit bir model oluşturulmuştur. Bu model tarafından yapılan öznitelik çıkarılması sonucunda 4187 görüntüden 3000 öznitelik bulunmuştur. Şekil 4'te modellerin birleştirilmiş hali gösterilmektedir.

3.3. Veri Dengeleme

e-ISSN: 2148-2683

Sınıflandırma veya tahmine dayalı modellemede yüksek model doğruluğu sağlamak için modele sağlanan verilerin kalitesi iyileştirilmelidir. Birçok veri ön işleme tekniği, aykırı değerlerin kaldırılması, yinelenen değer işleme, normalleştirme, eksik değerler vb. gibi sorunları ele alır, ancak gözden kaçan önemli bir konu, dengesiz sınıf dağılımlarının düşük doğruluk oranlarına yol açabilmesidir (Arık, 2021). Şekil 4' te veri dengeleme mimarisi gösterilmiştir. Bu çalışmada verilerin dengesiz sınıf dağılımı problemini ortadan kaldırmak için sentetik azınlık aşırı örnekleme (SMOTE) yöntemi kullanılmıştır.

3.3.1. SMOTE (Synthetic Minority Over-Sampling Technique)

SMOTE, sentetik veriler üreten bir aşırı örnekleme işlemidir. Bu, veri bilimi projelerinde en sık kullanılan yöntemlerden biridir. Bu yöntem, veri sayısı az olan sınıfının örnekleri arasında belirli işlemleri gerçekleştirerek sınıfının yeni bir örneğini oluşturmaktadır. Sentetik örnekler oluşturma basamakları şu şekildedir: Öncelikle incelenen öznitelik vektörü (E_i) ile en yakın komşusu arasındaki farkı alınır, sonra bu farkı 0 ile 1 arasında rastgele bir sayı δ ile çarpılır ve çıkan sonuç incelenen özellik vektörüne eklenir ve yeni örnekler oluşturulmaktadır (Muratlar, 2021). Sentetik örnek hesaplaması Denklem 1' deki gibi formüle edilmektedir:


$$E_{yeni} = E_i + (E_i - E_j)\delta \quad (1)$$

3.4. PCA Boyut İndirgeme

Algoritmalar, veri kümesinin tüm niteliklerini modele sığdırmaya çalıştıklarından dolayı yanlış tahminlere yol açabilmektedir. Bu sorunu çözmek ve büyük veri kümelerinin aşırı uyum ve karmaşıklığını önlemek için veri boyutunu azaltma teknikleri geliştirilmiştir (Mosetti, 2016).


Bu çalışmada boyut indirgeme yöntemlerinden PCA kullanılmıştır. PCA, değişken kombinasyonlarının temel veri türü özelliklerini tanımlayan istatistiksel bir yaklaşımdır (Ali vd., 2022).

PCA, özellik çıkarma ve boyut küçültme açısından iyi bir performans sergilemektedir. Veri seti, değişken sayısı ve gözlem sayısını içeren bir matris ile belirtilir ve matris, tek değerli ayrıştırma kullanılarak yeni bir matrise yorumlanmadan önce birim varyans ve sıfır anlamlılık ile normalleştirilmektedir (Ali vd., 2022).



Şekil 9. PCA uygulanmadan önceki 3 boyutlu veri seti

Şekil 9’da PCA uygulanmadan önceki 3 boyutlu veri seti gösterilmiştir. Şekil 10’da PCA uygulandıktan sonraki 2 boyutlu veri seti gösterilmektedir.



Şekil 10. PCA uygulandıktan sonraki 2 boyutlu veri seti

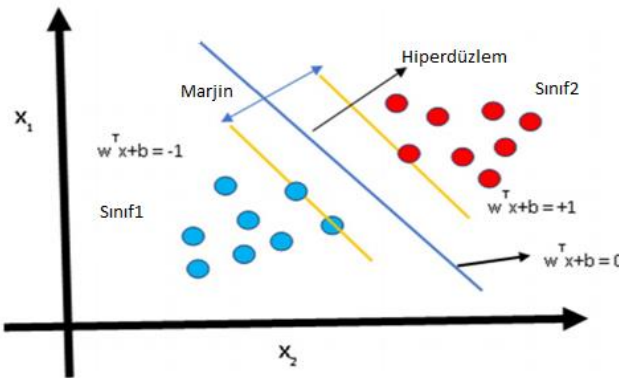
3.4.1. PCA Uygulanmış Veri Seti

Bu çalışmada, CNN ile öznetelikleri çıkartılmış mısır yaprağı görüntülerine PCA uygulanmıştır. CNN ile 4187 görüntüden 3000 öznetelik çıkartılmış iken PCA yöntemi uygulandıktan sonra öz netelik sayısı 191’e düşürülmüştür. Şekil 4’te VGG-19, DenseNet-201 ve NasNet-Large modelleri birleştirildikten sonra PCA uygulanmış hali gösterilmektedir.

3.5. Destek Vektör Makinaları (SVMs)

SVMs, 1963 yılında Vladimir Vapnik ve Alexey Chervonenkis tarafından istatistiksel öğrenme teorisine dayalı olarak geliştirilen denetimli bir makine öğrenme algoritmasıdır (Akpınar, 2014). Çekirdek işlevli SVM, doğrusal olmayan ayrılabilir veriler için mükemmel bir çözüm sunmaktadır (Metlek & Kayaalp, 2020).

İstatistiksel öğrenme teorisine dayanan SVMs, olası makine öğrenme tekniklerinden birisidir. SVMs hem doğrusal hem de doğrusal olmayan verileri işleyebilen bir sınıflandırma sistemidir. Verileri iki gruba ayırın ve yüksek boyutlarda doğrusal bir optimal ayırma hiperdüzlemi oluşturmak için destek vektörlerini ve kenarları (veya sınıfları) kullanmaktadır. Uygun bir doğrusal olmayan eşleme kullanarak orijinal eğitim verilerini daha yüksek boyutlara dönüştürmektedir. Bir hiperdüzlem ile verileri iki sınıfa ayırabilmektedir (Atallah & Al-Mousa, 2019).



Şekil 11. SVMs ile sınıflandırma örneği

Şekil 11’de görülebileceği gibi, SVM’nin temel gereksinimi, pozitif örnekler kümesini negatif örnekler kümesinden ayırt etmek için en büyük marjı olan hiperdüzlemi bulmaktır. Destek

vektör makinelerini kullanarak $f(x) = b + wx$ tipi doğrusal sınıflandırma gerçekleştirilmektedir. En büyük kenarı ve türünün doğrusal sınıflandırmasını kullanarak optimal hiperdüzlemi hesaplamak için bir destek vektör makinesi kullanılmaktadır. $f(x) = b + wx$ burada w ağırlık vektörünü, x eğitim örneklerini ve b bias’ı temsil etmektedir.

3.5.1. LibSVM

LibSVM, SVM’de kullanılan bir kütüphanedir. Amacı, SVM’yi kullanışlı bir araç olarak tanıtmaktır. Epsilon SVM regresyonunu, nu-SVM regresyonunu, tek sınıf SVM’yi, C-SVM sınıflandırmasını ve nu-SVM sınıflandırmasını birleştirmektedir. Ayrıca, otomatik model seçimi için bir C-SVM sınıflandırma aracı sağlamaktadır. En son sürümü Ağustos 2022’de yayınlanan 3.3’tür (Fan & Lin, 2005).

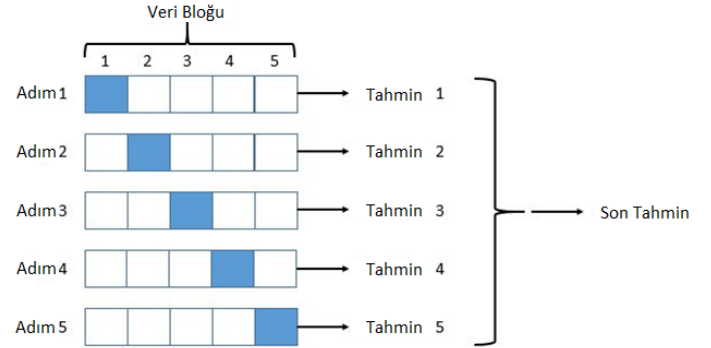
Bu çalışmada mısır yaprakları hastalıklarının sınıflandırılması için LibSVM kullanılmıştır.

3.6. Optimizasyon Yöntemi

Bu çalışmada Weka programında, GridSearchCV hiperparametre optimizasyon yöntemi ile LibSVM algoritmasının performansı artırılmıştır.

3.6.1. GridSearchCV Hiper-parametre Optimizasyonu

GridSearchCV, tahmin edici parametrelerini değiştirmek için Scikit öğrenme çerçevesi tarafından sağlanan bir sınıftır. Tipik olarak, önce aranacak bir parametre sözlüğü oluşturmakta, ardından GridSearchCV en uygun parametreleri sağlamak için gerekli model değişikliklerini yapmaktadır (Huang vd., July 2004).



Şekil 12. 5 katmanlı GridSearchCV örneği

Şekil 12’de görüldüğü gibi çapraz doğrulama sırasında veriler birkaç parçaya bölünebilmektedir. Örneğin, 5 bileşene bölünen verilerin beşte birini dışarıda bırakarak modele beş kez sığdırılmaktadır. Bu eksik veriler performansı değerlendirmek için kullanılmaktadır.

3.7. Model Performans Değerlendirme Metrikleri

Seçilen parametrelerin sınıflandırma doğruluğu üzerindeki etkisini görmek için önce farklı hiperparametrelerle deneyler yapılmış ve sonuçları bildirilmiştir. Sonuçları karşılaştırmak ve daha iyi kararlar almak için model değerlendirme metriklerinden doğruluk ölçüleri kullanılmıştır. Doğruluk, beklenen sınıf ile gerçek sınıfın uyumunu oransal olarak veren bir ölçümdür. Örneğin doğruluk, model tarafından mısır hastalığı riski altında olduğu tahmin edilen vakaların sayısı ile gerçek risk altındaki tüm vakaların sayısı ile model tarafından risksiz olarak tahmin edilen vakaların gerçek risk altındaki vakalara oranı olarak ifade edilmektedir. Sınıflandırma doğruluk değerleri Tablo 1’de

gösterilen karmaşıklık matrisinde belirtilen metriklerden elde edilmektedir.

Tablo 1. İki sınıflı karmaşıklık matrisi

		Tahmin Edilen Sınıf	
		Risk Var	Risk Yok
Gerçek Sınıf	Risk Var	TP (True Positive)	FP (False Pozitive)
	Risk Yok	FN (False Negative)	TN (True Negative)

Karmaşıklık matrisi terimleri ve anlamları aşağıda listelenmiştir.

- True pozitive (TP): pozitif sınıfa ait olan ve sınıflandırıcı tarafından doğru şekilde sınıflandırılan veri kümelerini temsil etmektedir.
- True Negative (TN): Sınıflandırıcı tarafından doğru olarak sınıflandırılan negatif sınıfa ait veri kümesini temsil etmektedir.
- False pozitive (FP): Uygulamada, negatif sınıfa ait ifadeler yanlış sınıflandırılır ve pozitif sınıf olarak tanımlanır.
- False Negative (FN): Aslında pozitif sınıfa ait olan bir taksonomik terim, negatif sınıf olarak tanımlanır.

Sınıflandırma performansını belirlemek için karmaşıklık matrisi kullanılarak belirlenen metrikler, açıklamalarıyla birlikte aşağıda listelenmiştir:

Doğruluk: Önerilen modelin başarısının değerlendirilmesi için kullanılmaktadır. Modeldeki doğru tahminler kümesinin tüm veri kümesine bölünmesiyle bir doğruluk değeri hesaplanmaktadır (Öğündür, 2019). Performans değerlendirme metrikleri kullanılarak Denklem 2’de verildiği gibi hesaplanmaktadır.

$$Doğruluk (Acc) = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (2)$$

Kesinlik: Özellikle yanlış pozitif tahminlerin maliyeti yüksek olduğunda önemlidir. Örneğin model, e-posta kutunuza gelmesi gereken bir maili spam (FP) olarak işaretlerse, almanız gereken önemli maili göremezsiniz ve kayıp bir durumda olursunuz. Kesinlik, bir model seçerken önemli bir kriterdir (Öğündür, 2019). Denklem 3’te verildiği şekilde hesaplanmaktadır.

$$Kesinlik (Pre) = \frac{TP}{(TP+FP)} \quad (3)$$

Duyarlılık: Yanlış negatifleri tahmin etmenin maliyetinin yüksek olduğu durumlarda da yararlı bir ölçümdür. Mümkün olduğunca yüksek olmalıdır. Örneğin oluşturduğumuz bir dolandırıcılık tespit modeli, hileli bir işlemi hileli değil olarak işaretliyorsa böyle bir durumun sonuçları bankalar için sorun teşkil etmektedir (Öğündür, 2019). Denklem 4’te gösterildiği şekilde hesaplanmaktadır.

$$Duyarlılık (Rec) = \frac{TP}{(TP+FN)} \quad (4)$$

F-ölçütü: Bu değer hassaslık ve duyarlılık (geri çağırma) değerlerinin harmonik ortalamasını vermektedir (Öğündür, 2019). Denklem 5’te verildiği gibi hesaplanmaktadır.

$$F - ölçütü = 2 * \frac{(kesinlik * duyarlılık)}{(kesinlik + duyarlılık)} \quad (5)$$

AUC: ROC eğrisi sınıflandırma problemleri için önemli bir diğer performans ölçümüdür. ROC bir olasılık eğrisidir ve altında kalan alan olarak adlandırılan AUC değeri ayrılabilirliğin derecesini veya ölçüsünü temsil etmektedir. AUC [0, 1] aralığında değerler üretmektedir. AUC değerinin 1’e yaklaşmasıyla sınıflandırıcının daha doğru bir tahmin yaptığı söylenebilir. 0,5 değeri ise sınıflandırıcının rastgele tahminler yaptığını göstermektedir. Bu değer altındaki değerler için sınıflandırıcının iyi performans göstermediği vurgulanmaktadır (Kılıç, 2013).

Ağırlıklı Ortalama: Ağırlıklı ortalama F1 puanı, her sınıfın desteğini hesaba katarken, sınıf başına tüm F1 puanlarının ortalaması alınarak belirlenmektedir (Leung, 2021).

4. Araştırma Sonuçları ve Tartışma

Bu çalışmada mısır yaprağı hastalıklarının tespiti için öncelikle 3. bölümde açıklanan veri setinin üzerine yine 3. bölümde yer alan CNN mimarilerinden VGG-19, DenseNet-201, NasNet-Large modelleri uygulandıktan sonra SMOTE, PCA, LibSVM ve GridSearchCV yöntemleri uygulanmıştır. Çalışmada Cross-Validation yöntemi ile 10 katlı bir çapraz doğrulama işlemi gerçekleştirilmiştir.


İlk olarak mısır yaprağı görüntülerinden öznetelik çıkarımı yapmak için CNN mimarilerinden sırasıyla VGG-19, DenseNet-201 ve NasNet-Large modelleri kullanılmıştır. Yapılan deney sonucunda herbir model için 1000’er öznetelik elde edilmiştir. Daha sonra kullanılan bu üç model birleştirilerek 3000 öznetelikli veri seti oluşturulmuştur. Oluşturulan veri setine WEKA 3.8.6 programı ile LibSVM sınıflandırıcısı uygulanmış ve %94,3 oranında doğruluk elde edilmiştir. Ayrıca Tablo 2’de karmaşıklık matrisi görülmektedir. Şekil 13’te ise sınıfların ROC eğrileri gösterilmiştir.

Tablo 2. VGG-19, DenseNet-201 ve Nasnet-Large modelleri birleştirilerek öznetelik çıkarılmış görüntülere LibSVM uygulandıktan sonraki karmaşıklık matrisi

VGG-19, DenseNet-201 ve NasNet-Large		Blight	Common Rust	Gray Leaf Spot	Healthy
True Class	Blight	1091	8	43	3
	Common Rust	45	1259	2	
	Gray Leaf Spot	116	14	442	1
	Healthy	3	1		1158
		Predicted Class			

Tablo 6. Öznitelik çıkarım yöntemi ve sınıflandırıcıya göre kesinlik, duyarlılık, F-1 ölçütü ve ROC sonuçları

Öznitelik Çıkarım Yöntemi	Öznitelik Sayısı	Sınıflandırıcı	Sınıf Adı	Pre	Rec	F ₁	ROC
VGG-19 + DenseNet-201 + NasNet-Large	3000	LibSVM	Blight	%86,9	%95,3	%90,9	%94,9
			Common Rust	%98,2	%96,4	%97,3	%97,8
			Gray Leaf Spot	%90,8	%77,1	%83,4	%87,9
			Healthy	%99,7	%99,7	%99,7	%99,7
			Ağırlıklı Ortalama	%94,5	%94,4	%94,3	%96,2
VGG-19 + DenseNet-201 + NasNet-Large + SMOTE + PCA + Optimizasyon (Önerilen Yöntem)	191	LibSVM	Blight	%92,5	%94,4	%93,4	%96
			Common Rust	%99	%95,6	%97,3	%97,6
			Gray Leaf Spot	%95,5	%97	%96,2	%97,8
			Healthy	%99,5	%99,7	%99,6	%99,8
			Ağırlıklı Ortalama	%96,7	%96,7	%96,7	%97,8



Şekil 13. (a) Blight hastalığı için ROC eğrisi (b) Common Rust hastalığı için ROC eğrisi (c) Gray Leaf Spot hastalığı için ROC eğrisi (d) Healthy için ROC eğrisi

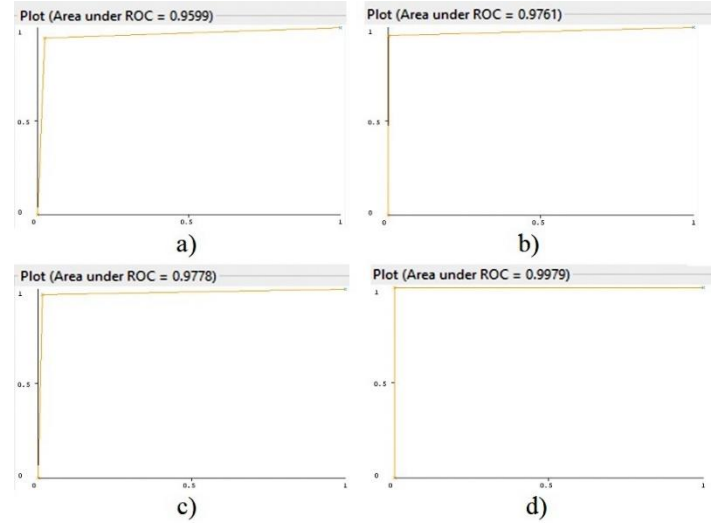
Oluşturulan veri setine, dengesiz sınıf dağılımlarını önlemek için WEKA 3.8.6 programı ile SMOTE sentetik veri üretme yöntemi uygulanarak balans ayarı yapılmıştır. Bu çalışma sonucunda sınıflarda sırasıyla 1145, 1306, 1146 ve 1162 toplamda 4759 veri elde edilmiştir. Böylece veri setinde bulunan 4187 adet veri SMOTE işleminden sonra 4759'a yükseltilmiştir.

Tablo 3. VGG-19, DenseNet-201 ve Nasnet-Large modelleri ile öznitelik çıkarılmış görüntülere SMOTE, PCA, LibSVM ve GridSearch uygulandıktan sonraki karmaşıklık matrisi

VGG-19, DenseNet-201 ve NasNet-Large + SMOTE+PCA+ OPTİMİZASYON		Blight	Common Rust	Gray Leaf Spot	Healthy
True Class	Blight	1081	11	48	5
	Common Rust	52	1248	5	1
	Gray Leaf Spot	34		1112	
	Healthy	2	1		1159
		Predicted Class			

Ardından önerilen yaklaşımda WEKA 3.8.6 programı ile PCA yöntemi kullanılarak bileşen azaltma kriteri olarak açıklanan varyansı belirtme seçeneği aktif edilmiş ve açıklanan varyans oranı %90 olarak belirlenmiştir. Yapılan deneyler sonucunda PCA uygulanmadan önce 3000 öznitelige sahip veri seti PCA uygulandıktan sonra 191 öznitelige sahip olmuştur.

Son olarak 191 öznitelige sahip 4759 veriye GridSearchCV optimizasyon yönteminde Xproperty cost ve Yproperty gamma olarak seçilip LibSVM sınıflandırıcısı uygulanmış ve %96,7 doğruluk oranı elde edilmiştir. Ayrıca Tablo 3'te karmaşıklık matrisi görülmektedir. Şekil 14'te ise sınıfların ROC eğrileri gösterilmiştir.



Şekil 14. (a) Blight hastalığı için ROC eğrisi (b) Common Rust hastalığı için ROC eğrisi (c) Gray Leaf Spot hastalığı için ROC eğrisi (d) Healthy için ROC eğrisi

Mısır yaprağı hastalıklarının teşhisi için hiper-parametre optimizasyonu yapılmamış ve önerilen yöntem ile LibSVM algoritması kullanılarak yapılan sınıflandırmanın ortalama performans sonuçları Tablo 6'da karşılaştırılmıştır.

Bu çalışmada çoklu sınıflar ile çalışıldığı için her sınıfın ayrı ayrı F-ölçütü değeri hesaplanmış ve bu değerlerin ağırlıklı ortalaması alınmıştır. Çalışmada optimizasyon yapılmayan LibSVM ile mısır yaprağı hastalığı teşhisinde %94,3 ağırlıklı ortalama bulunurken, optimizasyon yapılan LibSVM ile mısır yaprağı hastalığının teşhisinde %96,7 ağırlıklı ortalama elde edilmiştir.

5. Sonuçlar

Bu çalışmada mısır yaprağı hastalıklarının etkili bir şekilde teşhis edilebilmesi için optimize edilmiş LibSVM algoritması kullanılarak sınıflandırma doğruluğunun artırılması amaçlanmıştır. Bu kapsamda CNN mimarisinden VGG-19 +DenseNet-201+ Nasnet-Large modelleri kullanılarak mısır yaprağı görüntülerinden sınıflandırmada kullanılacak öznetelikler elde edilmiştir. Elde edilen bu öznetelikler SMOTE, PCA ve GridsearchCV yöntemleri ile veri dengeleme, boyut azaltma ve optimizasyon yapılarak en yüksek doğruluk oranı elde edilmiştir. Önerilen yöntemden önceki doğruluk oranı %94,3 iken önerilen yöntemle bu oran %96,7 doğruluk oranı elde edilmiştir.

Yapılan testler sonucunda elde edilen deneysel sonuçlar, LibSVM sınıflandırıcısının dengeli veri, doğru parametreler ve optimizasyon yardımıyla yüksek sınıflandırma doğruluğuna ulaştığını göstermektedir. Ayrıca boyut indirgeme metodu ile de maliyet ve zamandan tasarruf edildiği görülmüştür. LibSVM sınıflandırıcısının performansının artırılmasında özellikle GridSearchCV yönteminin kullanımının sınıflandırma doğruluğunu artırdığı vurgulanmıştır. Yapılan çalışmalar neticesinde LibSVM sınıflandırıcısının düşük verimlilik probleminin doğru parametreler yardımıyla çözülebildiği görülmüştür. Ayrıca diğer sınıflandırıcılar gibi LibSVM sınıflandırıcısının da mısır yaprağı hastalıklarının teşhisinde önemli bir teşhis yöntemi olduğu ifade edilebilmektedir.

Kaynakça

- Akpınar, H. (2014). Data: Veri Madenciliği Veri Analizi, 1. baskı. Papatya Yayıncılık Eğitim, İstanbul.
- Al-Amin, M., Karim, D. Z., & Bushra, T. A. (2019, December). Prediction of rice disease from leaves using deep convolution neural network towards a digital agricultural system. In 2019 22nd International Conference on Computer and Information Technology (ICCIT) (pp. 1-5). IEEE.
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017, August). Understanding of a convolutional neural network. In 2017 international conference on engineering and technology (ICET) (pp. 1-6). Ieee.
- Ali, H., Maulud, A. S., Zabiri, H., Nawaz, M., Suleman, H., & Taqvi, S. A. A. (2022). Multiscale Principal Component Analysis-Signed Directed Graph Based Process Monitoring and Fault Diagnosis. ACS omega, 7(11), 9496-9512.
- Arik, A. O. (2021, Jan 14). Medium: <https://okanarik.medium.com/smote-synthetic-minority-oversampling-technique-c52d4fbec47e>. Erişim: 04.10.2022
- Atallah, R., & Al-Mousa, A. (2019, October). Heart disease detection using machine learning majority voting ensemble method. In 2019 2nd international conference on new trends in computing sciences (ictcs) (pp. 1-6). IEEE.
- Bhange, M., & Hingoliwala, H. A. (2015). Smart farming: Pomegranate disease detection using image processing. Procedia computer science, 58, 280-288.
- Campus, P. (2012). Inoculation methods and disease rating scales for maize diseases. (Revised). Directorate of Maize Research, New Delhi.
- Chen, L., & Wang, L. Y. (2011). Research on application of probability neural network in maize leaf disease identification. J. Agricult. Mech. Res, 33(6), 145-148.
- DeChant, C., Wiesner-Hanks, T., Chen, S., Stewart, E. L., Yosinski, J., Gore, M. A., ... & Lipson, H. (2017).

- Automated identification of northern leaf blight-infected maize plants from field imagery using deep learning. Phytopathology, 107(11), 1426-1432.
- Dillard, H. R., & Seem, R. C. (1990). Incidence-severity relationships for common maize rust on sweet corn. Phytopathology, 80(9), 842-849.
- Dixit, A., & Nema, S. (2018). Wheat leaf disease detection using machine learning method-a review. Int. J. Comput. Sci. Mob. Comput, 7(5), 124-129.
- Fan, P. H. C. R. E., & Lin, C. J. (2005). Dimensionality Reduction via Sparse Support Vector Machines. Journal of Machine Learning Research, 6, 1889-1918.
- Floridi, L. (2020). AI and its new winter: From myths to realities. Philosophy & Technology, 33(1), 1-3.
- Geekycodesco. (2022, Mart 13). By geekycodesco: <https://geekycodes.in/what-is-the-vgg-19-neural-network/> Erişim: 28.09.2022
- Ghose, S. (2022). Kaggle. Kaggle: <https://www.kaggle.com/datasets/smaranjitghose/corn-or-maize-leaf-disease-dataset>. Erişim: 17.09.2022
- Hao, W., & Zhang, Z. (2019). Spatiotemporal distilled dense-connectivity network for video action recognition. Pattern Recognition, 92, 13-24.
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2004, July). Extreme learning machine: a new learning scheme of feedforward neural networks. In 2004 IEEE international joint conference on neural networks (IEEE Cat. No. 04CH37541) (Vol. 2, pp. 985-990). Ieee.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition; 2017. Honolulu, HI.[Google Scholar].
- Kapon, O. (2022, February). Kaggle: <https://www.kaggle.com/code/omreekapon/corn-and-maize-diseases-classification/notebook>. Erişim: 04.10.2022
- Kılıç, S. (2013). Klinik karar vermede ROC analizi. Journal of Mood Disorders, 3(3), 135-40.
- Kırtok, Y. (1998). Mısır: üretimi ve kullanımı. Kocaoluk Yayınevi.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. Communications of the ACM, 60(6), 84-90.
- Kusumo, B. S., Heryana, A., Mahendra, O., & Pardede, H. F. (2018, November). Machine learning-based for automatic detection of corn-plant diseases using image processing. In 2018 International conference on computer, control, informatics and its applications (IC3INA) (pp. 93-97). IEEE.
- Leung, K. (2021, Jan 4). Towards Data Science: <https://towardsdatascience.com/micro-macro-weighted-averages-of-f1-score-clearly-explained-b603420b292f>. Erişim: 03.10.2022
- Li, C., & Lanying, W. (2011). Research on Application of Probability Neural Network in Maize Leaf Disease Identification [J]. J Agric Mechan Res, 6.
- Lu, Y., Yi, S., Zeng, N., Liu, Y., & Zhang, Y. (2017). Identification of rice diseases using deep convolutional neural networks. Neurocomputing, 267, 378-384.
- Lumini, A., & Nanni, L. (2019). Deep learning and transfer learning features for plankton classification. Ecological informatics, 51, 33-43.

- Metlek, S., & Kayaalp, K. (2020). Makine Öğrenmesinde, Teoriden Örnek MATLAB Uygulamalarına Kadar Destek Vektör Makineleri. İksad Yayınevi.
- Miglani, V., & Bhatia, M. P. S. (2020, February). Skin lesion classification: A transfer learning approach using efficientnets. In International Conference on Advanced Machine Learning Technologies and Applications (pp. 315-324). Springer, Singapore.
- Miller, S. A., Beed, F. D., & Harmon, C. L. (2009). Plant disease diagnostic capabilities and networks. Annual review of phytopathology, 47(1), 15-38.
- Mosetti, R. (2016). Principal Component Analysis of quantum correlation. The European Physical Journal Plus, 131(12), 1-8.
- Muratlar, E. R. (2021, Temmuz 9). Dengesiz Veri Setlerinde Modelleme. Veri Bilimi: [https://www.veribilimiokulu.com/dengesiz-veri-setlerinde-modelleme/#:~:text=SMOTE\(Synthetic%20Minority%20Over%2DSampling,yeni%20az%C4%B1n%C4%B1k%20s%C4%B1n%C4%B1f%C4%B1%20C3%B6rneklere%20yaratmakt%C4%B1r](https://www.veribilimiokulu.com/dengesiz-veri-setlerinde-modelleme/#:~:text=SMOTE(Synthetic%20Minority%20Over%2DSampling,yeni%20az%C4%B1n%C4%B1k%20s%C4%B1n%C4%B1f%C4%B1%20C3%B6rneklere%20yaratmakt%C4%B1r). Erişim: 05.10.2022
- Öğündür, G. (2019, Nov 9). Medium: <https://medium.com/@gulcanogundur/do%C4%9Fruluk-accuracy-kesinlik-precision-duyarl%C4%B1%C4%B1k-recall-ya-da-f1-score-300c925feb38>. Erişim: 02.10.2022
- Panigrahi, K. P., Sahoo, A. K., & Das, H. (2020, June). A cnn approach for corn leaves disease detection to support digital agricultural system. In 2020 4th International Conference on Trends in Electronics and Informatics (ICOEI)(48184) (pp. 678-683). IEEE.
- Pujari, D., Yakkundimath, R., & Byadgi, A. S. (2016). SVM and ANN based classification of plant diseases using feature reduction technique. IJIMAI, 3(7), 6-14.
- Qi, Z., Jiang, Z., Yang, C., Liu, L., & Rao, Y. (2016). Identification of maize leaf diseases based on image technology. Journal of Anhui Agricultural University, 43(2), 325-330.
- Rage, S. (2022). Kaggle: <https://www.kaggle.com/code/sailikhitara/maize-mutant-classification-using-vgg16/notebook>. Erişim: 04.10.2022
- Sibiya, M., & Sumbwanyambe, M. (2019). A computational procedure for the recognition and classification of maize leaf diseases out of healthy leaves using convolutional neural networks. AgriEngineering, 1(1), 119-131.
- Song, K., Sun, X. Y., & Ji, J. W. (2007). Corn leaf disease recognition based on support vector machine method. Transactions of the CSAE, 23(1), 155-157.
- Şahin, S. (2001). Türkiyede Mısır Ekim Alanlarının Dağılışı Ve Mısır Üretimi. Gazi Üniversitesi Gazi Eğitim Fakültesi Dergisi, 21(1).
- Wang, N., Wang, K., Xie, R., Lai, J., Ming, B., & Li, S. (2009). Maize leaf disease identification based on fisher discrimination analysis. Scientia Agricultura Sinica, 42(11), 3836-3842.
- Ward, J. M., Stromberg, E. L., Nowell, D. C., & Nutter Jr, F. W. (1999). Gray leaf spot: a disease of global importance in maize production. Plant disease, 83(10), 884-895.
- Weizheng, S., Yachun, W., Zhanliang, C., & Hongda, W. (2008, December). Grading method of leaf spot disease based on image processing. In 2008 international conference on computer science and software engineering (Vol. 6, pp. 491-494). IEEE.
- Whxna. (2022, August). Kaggle: <https://www.kaggle.com/code/jiaowoguanren/corn-or-maize-leaf-dataset-tf-squeezenet/notebook>. Erişim: 04.10.2022
- Xu, L., Xu, X., Hu, M., Wang, R., Xie, C., & Chen, H. (2015). Corn leaf disease identification based on multiple classifiers fusion. Transactions of the Chinese Society of Agricultural Engineering, 31(14), 194-201.
- Zhang, F. (2013). Recognition of corn leaf disease based on quantum neural network and combination characteristic parameter. Journal of Southern Agriculture, 44(8), 1286-1290.
- Zhang, Z. Y., He, X. Y., Sun, X. H., Guo, L. M., Wang, J. H., & Wang, F. S. (2015). Image recognition of maize leaf disease based on GA-SVM. Chemical Engineering Transactions, 46, 199-204.
- Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 8697-8710).



Sınıflandırma Probleminde Derin Özellik Birleştirme Yaklaşımıyla Domates Yaprağı Görüntülerinde Hastalık Tespiti

Serdar Ertem¹, Erdal Özbay^{2*}

¹Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye, (ORCID: 0000-0003-2921-5673), serdarertem01@gmail.com

^{2*}Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye (ORCID: 0000-0002-9004-4802), erdalozbay@firat.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI:10.31590/ejosat.1216380)

ATIF/REFERENCE: Ertem, S. & Özbay, E. (2022). Sınıflandırma Probleminde Derin Özellik Birleştirme Yaklaşımıyla Domates Yaprağı Görüntülerinde Hastalık Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 84-92.

Öz

Domates, yaşadığımız coğrafya ve dünyanın birçok yerinde üretimi yapılan ve en çok tüketilen önemli sebze türlerindedir. Domates üretiminde verim ve kaliteyi olumsuz yönde etkileyen en önemli faktörlerin başında zararlı organizma olarak adlandırılan hastalık gelmektedir. Domates, çevresel ve iklim faktörlerine bağlı olarak ekim sürecinin her aşamasında birçok hastalığa yakalanabilir. Bitki hastalıklarında yapılması gereken ilk şey hastalığın doğru tespit edilmesi ve gereken önlemlerin alınmasıdır. Bu çalışmada 9 hastalıklı ve 1 sağlıklı sınıftan oluşan toplam 18.160 domates yaprağı görüntüsü bulunan veri seti kullanılmıştır (Kaggle, 2021). Genel erişime açık Kaggle domates yaprağı hastalığı veri seti üzerinde deneysel sonuçlar elde edilmiştir. Analizler yapılırken veri seti, %80 eğitim ve %20 test verisi olarak ayrılmıştır. Çalışmada, Evrişimli Sinir Ağı (CNN) tabanlı DenseNet-201, ResNet-101 ve ShuffleNet modelleri kullanılarak domates yaprağı görüntülerinden 3000 adet öznetelik çıkarılmıştır. Bu çalışmada öznetelik sayısını düşürmek için Temel Bileşen Analizi (PCA) kullanılarak boyut indirgeme yapılmıştır. Domates yaprağındaki hastalıkları sınıflandırmak amacıyla Destek-Vektör Makinaları (SVM) algoritması kullanılmıştır. Eğitilen ağ mimarileri tek tek incelenmiştir. Bu incelemeler sonucunda mimarilerin doğruluk oranları AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet için sırası ile %93.5, %97.1, %91.0, %94.5, %97.4 ve %96.6 bulunmuştur. Yapılan analizlerden sonra doğruluk oranı yüksek olan DenseNet-201, ResNet-101 ve ShuffleNet ön eğitilmiş ağ mimarileri birleştirilerek ve Temel Bileşen Analizi (PCA) kullanılarak boyut indirgeme yapılmıştır. Bu çalışmada yapılan sınıflandırma analizlerine göre en iyi performans gösteren Cubic SVM sınıflandırıcı ve One-vs-All Çok Sınıflı bileşen metodu ile %99.2 doğruluk oranına ulaşılmıştır. Literatür incelemeleri sonucunda domates yaprağı hastalık tespiti için bu çalışmanın etkili ve yüksek bir performans gösterdiği sonucuna ulaşılmıştır.

Anahtar Kelimeler: Domates yaprağı, CNN, SVM, PCA, Sınıflandırma.

Disease Detection in Tomato Leaf Images by Deep Feature Combination Approach in Classification Problem

Abstract

Tomato is one of the most important vegetable species produced and consumed mostly in the geography we live in and in many parts of the world. One of the most important factors that negatively affect yield and quality in tomato production is a disease called harmful organisms. Tomatoes can suffer from many diseases at every stage of the planting process, depending on environmental and climatic factors. The first thing to do in plant diseases is to correctly identify the disease and take the necessary precautions. In this study, a dataset with a total of 18.160 tomato leaf images consisting of 9 diseased and 1 healthy class was used (Kaggle, 2021). Experimental results were obtained on the publicly accessible Kaggle tomato leaf disease dataset. During the analysis, the data set was divided into 80% training and 20% test data. In the study, 3000 features were extracted from tomato leaf images by using Convolutional Neural Network (CNN) based DenseNet-201, ResNet-101, and ShuffleNet models. In this study, dimension reduction

*Sorumlu Yazar: erdalozbay@firat.edu.tr

was made using Principal Component Analysis (PCA) to reduce the number of features. Support-Vector Machines (SVM) algorithm was used to classify diseases in tomato leaves. The trained network architectures were examined one by one. As a result of these examinations, the accuracy rates of the architectures were found to be 93.5%, 97.1%, 91.0%, 94.5%, 97.4%, and 96.6% for AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101, and ShuffleNet, respectively. After the analysis, size reduction was made by combining DenseNet-201, ResNet-101, and ShuffleNet pre-trained network architectures with high accuracy and using Principal Component Analysis (PCA). According to the classification analyses made in this study, the Cubic SVM classifier and the One-vs-All Multi-Class component method, which performed the best, achieved 99.2% accuracy. As a result of the literature review, it was concluded that this study showed an effective and high performance for tomato leaf disease detection.

Keywords: Tomato leaf, CNN, SVM, PCA, Classification.

1. Giriş

Yeryüzünde çok fazla bitki türü olduğu bilinen bir gerçektir. Gün geçtikçe yeni bitki türleri keşfedilirken bazı bitki türlerinin de nesli tükenmektedir (Arivazhagan, Shebiah, Ananthi, & Varthini, 2013). Bu yok olan bitki türlerinin korunup gelecek kuşaklara aktarılabilmesi ekolojik denge bakımından hayati önem taşımaktadır. İklimsel değişiklikler, hava kirliliği, yetiştirme sürecinde bakteri, mantar ve virüs gibi nedenlerden dolayı bitkilerde hastalıklar oluşmaktadır. Bitkilerdeki görülen çoğu hastalığın teşhisi geleneksel yöntemlerle anlaşılmaktadır (Brahimi, Boukhalfa, & Moussaoui, 2017a).

Domates, yaşadığımız coğrafya ve dünyanın birçok yerinde üretimi yapılan ve en çok tüketilen önemli sebze türlerindedir. Domates üretiminde verim ve kaliteyi olumsuz yönde etkileyen en önemli faktörlerin başında zararlı organizma olarak adlandırılan hastalık gelmektedir. Domates, çevresel ve iklim faktörlerine bağlı olarak ekim sürecinin her aşamasında birçok hastalığa yakalanabilir. Bitki hastalıklarında yapılması gereken ilk şey hastalığın doğru tespit edilmesi ve gereken önlemlerin alınmasıdır.

Bitki üreticileri bu hastalıkları bilebilir fakat tanımlaması güçtür. Hastalığı bilse bile hastalığı tedavi etmek için uygulanması gereken metotlar hakkında bilgisi olmayabilir (Ferentinos, 2018; Sannakki, Rajpurohit, Sumira, & Venkatesh, 2013).

Teknolojinin ilerlemesiyle birlikte yapay zekâ uygulamaları zirai alanda hastalığın tespiti ve bitki türü sınıflandırmasında da rol almaya başlamıştır (Ferentinos, 2018). Yapay zeka metotları güvenilirliği yüksek ve seri sınıflandırma yapabilmesinden dolayı hem zamanı verimli kullanmayı sağlar hem de iş yoğunluğunu azaltması açısından avantaj sağlamaktadır (Arsenovic, Karanovic, Sladojevic, Anderla, & Stefanovic, 2019).

Domates, dünyada tüketiminin fazla olması nedeniyle büyük bir pazar payına sahiptir. Verimli domateslere sahip olmak için domates hastalıklarının önlemek şarttır. Bu çalışmada domates bitkisinin yapraklarında meydana gelen hastalıkların teşhisi için sınıflandırma yapılmıştır.

Renkli ve reel domates yaprağı görüntülerinden oluşan veri kümesi 10 sınıf ve 18160 tane görüntüden oluşmaktadır (Kaggle, 2021).


Yaygın domates bitkisi hastalıklarından erken yanıklık (Early blight), bu yaygın domates bitkisi hastalığı, bir bitkinin alt yapraklarında boğa gözü şeklinde kahverengi lekeler olarak ortaya çıkar. Genellikle lekelerin etrafındaki doku sararır. Sonunda, enfekte olmuş yapraklar bitkiden düşecektir. Çoğu durumda, hastalık belirtileri bitkide ilerlese bile domatesler olgunlaşmaya devam edecektir (Walliser, J., 2018).

Hastalıklı yaprak görüntülerinden bazıları Şekil 1'deki gibidir.



Şekil 1. Hastalıklı yaprak görüntüleri

Sağlıklı yaprak görüntülerinden bazıları Şekil 2'deki gibidir.



Şekil 2. Sağlıklı yaprak görüntüleri

Bu çalışmada ön eğitilmiş ESA algoritmalarından AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet mimarileri ile hastalığın tespiti ve sınıflandırma çalışması yapılmıştır. Bu mimarilerin sınıflandırma doğruluğu analiz edilmiştir. Bu değerlendirmeler sonucunda domates yaprağında oluşan hastalıkların tespiti için doğruluk oranı en yüksek CNN mimarileri birleştirilerek doğruluk oranı artırılmaya çalışılmıştır. Çalışma ile ilgili literatür taraması yapılmış, yapılan analizler hakkında ve elde edilen sonuçlar hakkında bilgiler verilmiştir.

2. İlgili Çalışmalar

Bu başlık altında bitki hastalıklarının tespiti konusunda yapılan sınıflandırma çalışmaları hakkında bilgiler verilmiştir.

Agarwal ve ark. Bir CNN mimarisi kullanılmıştır. 10 sınıflı bir veri kümesinde ortalama %91.2 doğruluk elde etmişler. Referans 5'te, PlantVillage veri kümesinden elde edilen yedi sınıftan oluşan domates yapraklarının görüntüleri Toalexnet ve VGG16 mimarileri olarak verilir. Görüntü numarası, mini parti boyutu ve önyargı gibi parametrelerin sınıflandırma doğruluğu üzerindeki etkisi gözlemlendi ve en iyi koşullar altında Alexnet ve VGG16 sırasıyla %97.29 ve %97.49'a ulaştı. Referans 6'da önerilen evrişim ağ yapısının performansını artırmak için görüntüye ön işleme uygulanmıştır. Sekiz gizli katmandan oluşan yöntem, ilgili veri kümesinde %98,4 başarı elde etti (Agarwal ve ark., 2020).

Cheng ve ark., tarımsal zararları tanımlamak için ResNet ve Alexnet kullanmışlardır. Aynı zamanda, SVM ve BP sinir ağları ile karşılaştırmalı deneyler yapmışlar; Sonuçta, ResNet-101 tarafından %98,67'lik en iyi doğruluğu elde etmişlerdir (Cheng ve ark., 2017). Liu ve diğ., 13.689 resimden, 4 sınıftan oluşan çalışmalarında AlexNet ve GoogleNet metotları ile %97,92

doğruluk oranları sonucuna ulaşmışlardır (Liu, Tang, Zhou, Meng, & Dong, 2016).

Arsenovic ve diğ., 139.011 görüntü ve 42 sınıfı olan veri setine AlexNet, VGG19, Inceptionv3, DenseNet201 ve ResNet152 mimarilerini uygulayarak %93,67 doğruluk oranı sonucunu bulmuşlardır (Arsenovic ve ark., 2019). Cheng ve Matson, ot ve pirinci tanımlamak için karar ağacı, destek vektör makinesi (SVM) ve sinir ağı kullanarak elde ettikleri en iyi doğruluk, % 98,2'dir (Cheng & Matson, 2015).

Mohanty ve diğ., AlexNet ve GoogleNet yöntemini kullanmış ve % 99,34 başarı oranı elde etmiştir. Çalışmada 38 sınıflı 54.308 görüntüden oluşan veri seti kullanmıştır (Mohanty, Hughes, & Salathé, 2016).

Geetharamani ve diğ., Derin Evrişimli Sinir Ağı yöntemini kullandığı 39arklı bitki yaprağı sınıfı ve arka plan görüntüsünden oluşan veri setinde %96,46 doğruluk oranı elde etmiştir (GeethaRamani, & ArunPandian, 2019).

Song vd., Sayısal görüntü işleme yöntemleri, destek vektör makineleri, yapay sinir ağları ve diğer birkaç teknik yardımıyla yaprak hastalıklarının tespiti ve sınıflandırılması yapılmıştır (Song vd., 2007, Chen vd., 2011, Qi vd., 2016, Xu vd., 2015). Song vd., farklı mısır yaprağı hastalıklarını %89.6 doğrulukla saptamak için bir SVM yöntemi uygulamışlardır (Song vd., 2007).

Shruthi ve ark., çalışmalarında bitki hastalıklarını tespit etmek ve sınıflandırmak için destek vektör makinelerini (SVM), yapay sinir ağlarını (YSA), k-en yakın komşu algoritmasını (k-NN), fuzzy sınıflandırıcıyı ve CNN mimarilerini kullanan çalışmalarını analiz etmişlerdir. Nihayetinde, CNN mimarileri kullanılarak yapılan sınıflandırmanın diğer dört sınıflandırma yöntemine göre daha yüksek doğrulukla daha fazla sayıda hastalık tespit ettiği sonucuna varmışlardır (Shruthi ve ark., 2019).

Sibiya ve ark., akıllı telefon kameraları tarafından toplanan mısır yaprağı hastalığı görüntülerini tanımak ve sınıflandırmak için bir CNN ağını eğiterek kullanmıştır. Araştırmada elde edilen %92,85'lik ortalama doğruluk değeri, CNN'in bu alanda uygulanabilirliğini göstermiştir (Sibiya & Sumbwanyambe, 2019). Al-Amin, patates yapraklarından patates hastalığını tahmin etmek için Evrişimli Sinir Ağı (CNN) modelini önermiştir (Al-Amin vd., 2019). Önerilen yaklaşım modelleriyle en yüksek %98,33 doğruluğa ulaşılmıştır.

Suryawati ve ark., Alexnet, GoogleNet ve VGGNet kullanarak modeli eğitmek için PlantVillage veri setinden domates yaprağı renkli görüntü örneklerini kullanmış ve sırasıyla %91.52, %89.68 ve %95.25 test doğruluğu elde etmişlerdir (Suryawati ve ark., 2018).

Tan ve ark., PlantVillage veri kümesi kullanılarak domates hastalığı sınıflandırmak için en doğru ML/DL modellerini belirlemeyi amaçlamıştır. Makine öğrenimi algoritması uygulaması için hastalık özelliklerini manuel olarak çıkarmak için farklı yöntemler kullanmışlardır. Çalışmalarında, yerel ikili desen (LBP) ve gri düzey birlikte oluşum matrisi (GLCM) yöntemlerini kullanarak toplam 52 doku özneteliği ve renk momenti ve renk histogramı yöntemlerini kullanarak 105 renk özneteliği çıkarmıştır. Farklı yöntemleri karşılaştırarak, test edilen derin öğrenme ağlarının (AlexNet, VGG16, ResNet34, EfficientNet-b0 ve MobileNetV2) metriklerini (doğruluk, kesinlik, hatırlama, F1 puanı) bulmuşlardır. Ölçülen makine

öğrenme algoritmalarından destek vektör makinesi (SVM), k-en yakın komşu (kNN) ve rastgele ormandan (RF) daha iyi olduğunu tespit etmişlerdir. Ayrıca, veri seti ve sınıflandırma görevimiz için test edilen ML/DL algoritmaları arasında ResNet34 ağına %99,7 doğruluk, %99,6 kesinlik, %99,7 hatırlama ve %99,7 F1 puanı ile en iyi sonuçları elde ettiğini bulmuşlardır (Tan, L., Lu, J., & Jiang, H.,2021).

Mokhtar ve ark., Sınıflandırma aşaması için farklı çekirdek fonksiyonlarına sahip Destek Vektör Makinesi (SVM) algoritması kullanılmaktadır. Hem eğitim hem de test aşamaları için toplam 800 sağlıklı ve enfekte domates yaprağı görüntüsü veri seti kullanılmıştır. Sunulan yaklaşımın performansını değerlendirmek için N-kat çapraz doğrulama tekniği kullanılır. Deneysel sonuçlar, önerilen sınıflandırma yaklaşımının doğrusal çekirdek fonksiyonunu kullanarak %99.83 sınıflandırma doğruluğu elde ettiğini göstermiştir (Mokhtar, U. ve ark.,2015).

Bakr ve ark., DenseNet201 adlı transfer öğrenme modeline dayalı bir CNN sınıflandırıcı önermiştir. Hangisinin bitki hastalıklarını en yüksek doğrulukla tespit edebileceğini görmek için dört derin öğrenme modelinin (VGG16, Inception V3, ResNet152V2 ve DenseNet201) analizi yapılmış. Kullanılan görüntü veri seti, domates için 9 hastalık ve bir sağlıklı sınıf, patates için 2 hastalık ve bir sağlıklı sınıf ve biber için 1 hastalık ve bir sağlıklı olmak üzere 15 farklı sınıfa ayrılmış 3 mahsul, domates, patates ve biberin 28310 yaprak fotoğrafını içermektedir. Deneysel sonuçlar önerilen modelin %99.44 ile en yüksek eğitim doğruluğuna ve %98.70 doğrulama doğruluğuna ulaştığını göstermektedir (Bakr ve ark., 2022).

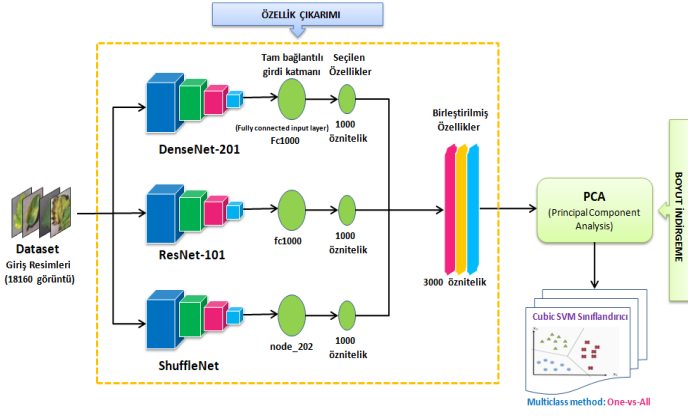
Too ve diğ., 38 sınıf ve 54.306 görüntüden oluşan veri seti üzerinde VGG16, Inception-v4, ResNet50, ResNet101, ResNet152 ve DenseNet121 CNN modellerini uygulamışlardır. %99,75 doğruluk oranını yakalamışlardır (Too, Yujian, Njuki, & Yingchun, 2019).

Sonuç olarak yapılan çalışmalar incelendiğinde bitki hastalıklarının tespitinde ve sınıflandırmasında Evrişimli Sinir Ağı (CNN) mimarileri kullanılarak yüksek doğruluk oranı elde edildiği görülmektedir.

3. Materyal ve Metot

Bu çalışmada Literatür taraması sonucunda yaygın olarak kullanılan CNN tabanlı AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet kullanılmıştır. Yapılan analizlerden sonra doğruluk oranı yüksek olan DenseNet-201, ResNet-101 ve ShuffleNet ön eğitilmiş ağ mimarileri birleştirilmiştir. 24 bit derinliğe sahip görüntülerden özellik çıkarımı yapılmıştır. Elde edilen özelliklere PCA ile boyut indirgeme tekniği uygulanmıştır. Daha sonra makine öğrenmesi sınıflandırıcılarından Cubic SVM ve One-vs-All sınıflandırma yöntemiyle optimize edilerek domates yaprakları hastalıkları tespit edilmiştir.

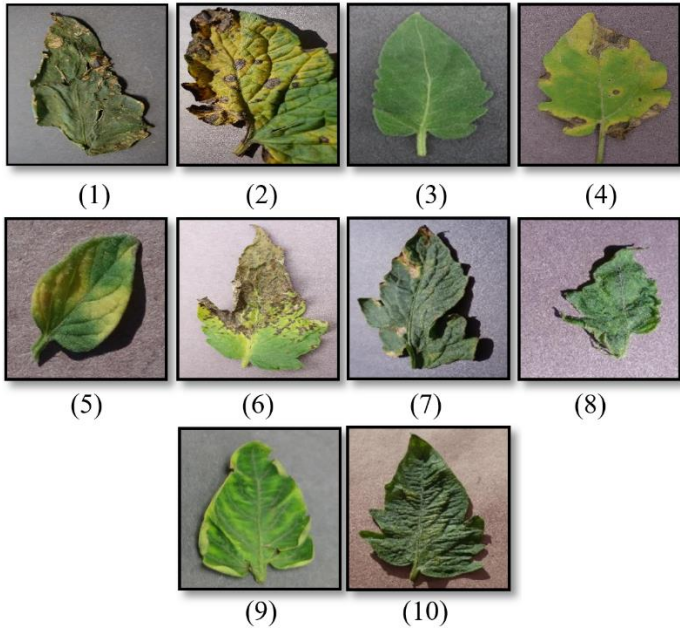
Bu bölümde çalışmada kullanılan veri seti, CNN mimarileri, PCA ve makine öğrenmesi sınıflandırmaları yöntemleri incelenmiştir. Bu çalışmada kullanılan yöntemin akış diyagramı Şekil 3'te verilmiştir.



Şekil 3.Önerilen yaklaşımda kullanılan yöntemin akış diyagramı

3.1. Veri Seti

Bu çalışmada 9 hastalıklı ve 1 sağlıklı sınıftan oluşan ve 18.160 domates yaprağı görüntüsü bulunan veri seti kullanılmıştır (Kaggle, 2021). Genel erişime açık Kaggle domates yaprağı hastalığı veri setinde bulunan görüntüler ve sınıflar Şekil 4'teki gibidir.



Şekil 4. Veri seti sınıfları ve örnek görüntüler (Kaggle, 2021)

Tablo 1. Veri Setindeki Sınıflara Ait Görüntü Sayısı ve Hastalık Tipi (Kaggle, 2021)

Hastalık Tipi	Sınıf	Görüntü Sayısı
Bakteri Lekesi	1	2127
Erken Yanıklık	2	1000
Sağlıklı	3	1591
Geç Yanıklık	4	1909
Yaprak Kalıbı	5	952
Septoria Yaprak Lekesi	6	1771
Hedef Nokta	7	1404
Mozaik Virüsü	8	373
Sarı Yaprak Kıvrılma Virüsü	9	5357
Örümcek Akarları	10	1676

Bu çalışmada kullanılan veri seti 18160 görüntü ve 9 hastalıklı ve 1 sağlıklı olmak üzere toplam 10 sınıftan oluşmaktadır. Veri seti 2127 tane bakteri lekeli, 1000 tane erken yanıklık, 1591 tane sağlıklı, 1909 tane geç yanıklık, 952 tane yaprak kalıbı, 1771 tane septoria yaprak lekeli, 1404 tane hedef nokta, 373 tane mozaik virüsü, 5357 tane sarı yaprak kıvrılma virüsü ve 1676 tane örümcek akarları yaprak görüntülerinden oluşmaktadır. Çalışmada kullanılan veri setinde bulunan sınıflara ait görüntü sayıları ve hastalık tipi Tablo 1'de verilmiştir.


3.2. Öznitelik Çıkartma

Yapısal olmayan verilerde öznitelik çıkartma işlemi yapmak için bu verilerin matematiksel formda yapılara, yani nümerik değerlere dönüştürülmesi gerekmektedir. Özellik çıkartma işlemlerini gerçekleştirebilmek için öncelikle yapısal olmayan veriler algoritmalar tarafından anlaşılabilir temsillere dönüştürülür. Daha sonra özellik çıkartma işlemleri yapılır. Çeşitli metotlarla görsellerdeki özellikleri (features) çıkaran ve onları sınıflandıran CNN mimarileri farklı katmanlardan oluşmaktadır. Bu mimariler ile etkili ve verimli sonuçlar alınabilir. Çalışmada AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet mimarileri kullanılarak doğruluk oranları analiz edilmiştir. Yapılan analizlerden sonra doğruluk oranı yüksek olan DenseNet-201, ResNet-101 ve ShuffleNet ön eğitilmiş ağ mimarileri birleştirilerek özellik çıkartma yapılmıştır. Şekil 3'te önerilen yaklaşımda kullanılan yöntemle özellik çıkartma gösterilmiştir.

3.2.1. Evrişimli Sinir Ağları (Convolutional Neural Network – CNN)

Evrişimli sinir ağları (CNN) çok katmanlı algılayıcıların bir türüdür. En etkili ve doğruluk oranı yüksek sonuçlar alındığı için özellikle görüntü işleme alanında daha çok kullanılmaktadır. (Tüfekçi & Karpat, 2019).

CNN mimarileri çok katmanlı bir yapıya sahiptir. Görüntüler üzerinde daha hızlı ve doğruluk oranı yüksek sonuçlarla sınıflandırma işlemi yapılmasını sağlamaktadır. CNN mimarilerinde bulunan temel katmanlar Giriş, Evrişim Katmanı, Havuzlama Katmanı ve Sınıflandırma (Tam bağlantılı katman) katmanıdır. CNN mimarisi ve katmanlar Şekil 5'te verilmiştir.



Şekil 5. CNN mimarisi ve katmanlar


Bu çalışmada AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet ön eğitilmiş Evrişimli Sinir Ağı modelleri ile sınıflandırma çalışması yapılmıştır.

3.2.2. Mimari Birleştirme

Bu çalışmada CNN modellerinden DenseNet-201, ResNet-101 ve ShuffleNet ön eğitilmiş ağ mimarileri kullanılarak 18160 domates yaprağı görüntüsünden 3000 tane öznitelik çıkartılmıştır. Elde edilen öznitelikler MATLAB R2021b uygulamasında birleştirilip karma (hibrit) bir Evrişimli Sinir Ağı

modeli oluşturulmuştur. Şekil 3'te Evrişimli Sinir Ağı modelinin birleştirilmiş hali gösterilmektedir.

Şekil 6'da Mimariler birleştirildikten sonraki veri seti sınıf dağılımı ve sınıflar gösterilmiştir.



Şekil 6. Mimariler birleştirildikten sonraki veri seti sınıf dağılımı ve sınıflar

3.3. PCA Metodu ile Boyut İndirgeme

Jolliffe, PCA (Principal Component Analysis) verideki önemli örüntüleri ortaya çıkartan ve veriyi analiz etmek için kullanılan istatistiksel bir yöntemdir (Jolliffe, 2002).

Öksüz ve ark., PCA metodu büyük boyutlu bir veri setini daha düşük boyutlu bir veri seti haline getirir. Bu yöntemde en büyük özdeğere sahip olandan en düşük özdeğere sahip olana doğru sıralanır. İstenilen değişimi yakalayan sayıda özvektör seçildikten sonra bir doğrusal dönüşüm yapılır. (Öksüz ve ark., 2020).

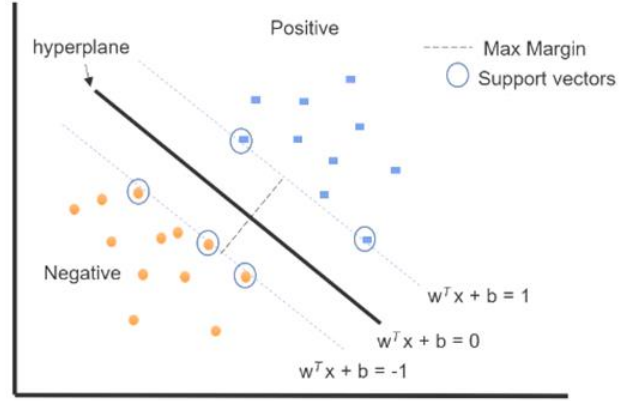
Bu çalışmada, elde edilen hibrit CNN mimarisi ile öznelikleri çıkartılmış domates yaprağı görüntülerine PCA tekniği uygulanmıştır. 18160 görüntüden 3000 öznelikli çıkartılmış iken PCA yöntemi uygulandıktan sonra doğruluk oranı en yüksek sonuç alındığı gözlemlenen 1500 öznelikli boyutuna indirgenmiştir. Şekil 3'te DenseNet-201, ResNet-101 ve ShuffleNet modelleri birleştirildikten sonra PCA uygulanmış hali gösterilmektedir.

3.4. Destek Vektör Makineleri (SVMs)

Farklı çekirdek fonksiyonlarına sahip Destek Vektör Makineleri, verileri özellik alanına yansıtarak ve daha sonra optimal ayrı hiper-düzlemi bularak doğrusal olmayan bir problemi doğrusal olarak ayrılabilir bir soruna dönüştürebilir. Bu yöntem başlangıçta iki sınıf problemleri çözmek için önerilmiştir. Daha sonra, bu tekniği çok sınıflı sınıflandırma problemlerine genişletmek için birkaç stratejinin önerilmiştir (Vapnik, 1995).

Ön işleme ve özellik (öznelikli) çıkartma adımları bittikten sonra, el yazısı basamaklı görüntülerin sınıflandırılması SVM sınıflandırıcısı tarafından gerçekleştirilir. SVM sınıflandırıcısının eğitimi, matris formunda depolanan özellik vektörleri alınarak yapılmıştır. Sakının testi, eğitim sonucu kullanılarak yapılmıştır. Hibrit CNN SVM modelinde, otomatik olarak oluşturulan özellikler el yazısı basamak veri kümesini eğitmek ve test etmek için SVM modülüne aktarılır. MNIST'in test verileri benzer şekilde önceden işlenir ve daha sonra sınıflandırıcısı test etmek için kullanılır (Ahlawat & Choudhary, 2020).

Şekil 7'de SVM'nin asıl olarak ihtiyacı olan, pozitif örnekler sınıfını negatif örnekler sınıfından ayırt etmek için en büyük marjı olan hiper-düzlemi bulmak olduğu görülmektedir.



Şekil 7. SVM ile sınıflandırma

3.4.1. Cubic SVM

Sünnetci ve ark., 137 COVID-19, 90 normal ve 90 pnömoni kişilerden alınan görüntülerden oluşan veri seti üzerinde AlexNet CNN mimarisi kullanmışlardır. Her görüntü için 1000 özelliği çıkartılmıştır. Kübik destek vektör makinesi (Cubic Support Vector Machine, Cubic SVM) sınıflandırıcısı kullanılarak % 95.27 doğruluk elde etmişlerdir (Sünnetci ve ark., 2021).

Bu çalışmada domates yaprakları hastalıklarının tespiti ve sınıflandırılması için diğer sınıflandırıcı yöntemleri sonuçları gözlemlenmiş ve en başarılı doğruluk sonucu alınan Kübik Destek Vektör Makinesi (Cubic SVM) Sınıflandırıcısı ve One-vs-All multi-class metodu (tekniki) kullanılmıştır.

3.5. Model Performans Ölçüm Metrikleri

CNN mimarileri ile eğitilen veri setlerinin doğru sınıflandırma oranını hesaplamak için Hata (Karmaşıklık) matrisi kullanılır. Hata (karmaşıklık) matrisinde tahmin edilen ve gerçek değerlerin Gerçek pozitif (True Positive-TP), Yanlış pozitif (False Positive-FP), Yanlış negatif (False Negative -FN) ve Yanlış negatif (True Negative-TN) parametreleri verilir. Doğruluk, duyarlılık, kesinlik ve F-score bu parametrelerle elde edilir. Sınıflandırma doğruluk oranları Tablo 2'de gösterilen hata matrisinde belirtilen ölçümler ile hesaplanmaktadır.

Hata matrisi terimlerinin anlamları aşağıdaki gibidir:

- ✓ True Positive (TP): Pozitif sınıfa ait olan ve sınıflandırıcı tarafından doğru şekilde sınıflandırılan veri kümeleridir.
- ✓ True Negative (TN): Sınıflandırıcı tarafından doğru olarak sınıflandırılan negatif sınıfa ait veri kümesidir.
- ✓ False Positive (FP): Negatif sınıfa ait olduğu halde yanlış sınıflandırılır ve pozitif sınıf olarak tanımlanır.
- ✓ False Negative (FN): Gerçekte pozitif sınıfa ait olduğu halde negatif sınıf olarak tanımlanır.

Tablo 2. Hata (Karmaşıklık) matrisi

Hata Matrisi	Tahmin Edilen		
	1 (Positive)	0 (Negative)	
Gerçek	1	True Positive (TP)	False Positive (FP)
	0	False Negative (FN)	True Negative (TN)

Oluşturulan model üzerinde yapılan sınıflandırma performansını belirlemek için hata matrisi kullanılarak metrikler aşağıdaki denklemlerdeki gibi hesaplanır.

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

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

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

$$F - \text{score} = 2 * \frac{(\text{kesinlik} * \text{duyarlılık})}{(\text{kesinlik} + \text{duyarlılık})} \quad (4)$$

Sınıflandırma problemleri için önemli olan diğer performans metriği de ROC eğrisidir. ROC eğrisinde hatasız olan incelemede eğri (0,0), (0,1) ve (1,1) noktalarından geçer. En hatalı olan ROC eğrisi (0,0) dan (1,1) noktalarından geçer. Bu iki eğriye göre değerlendirmeler yapılır (Hoo ve ark., 2017). TP değerinin FP değerine oranı ROC eğri grafiğini göstermektedir. ROC eğrisinin altında kalan alan (AUC) değerini verir. Bu değer 0'dan 1'e doğru yaklaşması pozitif değerlerin negatif değerlerden başarılı bir şekilde ayrıldığı anlamına gelir (Chaovalitwongse vd., 2007).

4. Deneysel Sonuçlar ve Tartışma

Bu çalışmada domates yaprağı hastalıklarının sınıflandırılması için Materyal ve Metod bölümünde belirtilen veri seti üzerinde DenseNet-201, ResNet-101 ve ShuffleNet ön eğitilmiş ağ mimarileri birleştirilerek uygulandıktan sonra PCA, Cubic SVM Cubic SVM sınıflandırıcı ve One-vs-All Çok Sınıflı bileşen yöntemleri uygulanmıştır. Bu çalışmada ayrıca Cross-Validation yöntemi ile 10 katlı bir çapraz doğrulama işlemi gerçekleştirilmiştir.

Öncelikle genel erişime açık Kaggle domates yaprağı görüntülerinden oluşan veri seti üzerinde AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet CNN mimarileri uygulanmıştır. Her bir model için 1000'er öznitelik elde edilmiştir. Tablo 3'te AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet CNN mimarileri sınıflandırma doğruluk oranları analiz edilmiştir. Her bir mimaride doğruluk oranı en yüksek sınıflandırıcının Cubic SVM olduğu gözlemlenmiştir.

Tablo 3. AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet CNN mimarileri sınıflandırma doğruluk oranları (%)

CNN Mimarileri	Cubic SVM
AlexNet	93.5
DenseNet-201	97.1
GoogleNet	91.0
MobileNet	94.5
ResNet-101	97.4
ShuffleNet	96.6


Daha sonra doğruluk oranı en yüksek DenseNet-201, ResNet-101 ve ShuffleNet CNN mimari modelleri birleştirilerek

uygulanmış ve bu mimarilerin 3000 öznitelik çıkarılmış ve veri seti oluşturulmuştur.

		Model 1									
True Class		Predicted Class									
		1	2	3	4	5	6	7	8	9	10
1		2117	1		2		2	1		3	1
2		7	938		14	2	5	27	1		6
3				1576				13		1	1
4		1	17	2	1878	4	2	4			1
5		3	2			929	5	2			11
6		4	6	1	1	3	1744	9	1		2
7		1	6		1		7	1367		1	21
8						3			368		2
9		4				1				5342	10
10					1			20			1655

Şekil 8. DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin Karmaşıklık Matrisi

DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin Karmaşıklık Matrisi Şekil 8'deki gibidir. DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin doğruluk oranı %98.6 bulunmuştur. DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin ROC Eğrisi Şekil 9'daki gibidir.



Şekil 9. DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin ROC Eğrisi

Oluşturulan veri setine PCA ile boyut indirilmesi yapılarak öznitelik sayısı 1500'e indirilmiştir. Yapılan analizlere göre mimariler üzerinde doğruluk oranı en yüksek çıkan Cubic SVM sınıflandırıcısı ve One-vs-All çok sınıflı bileşen metodu uygulanarak %99.2 doğruluk oranına ulaşılmıştır. Şekil 10'da DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin PCA ile boyut indirilmesi yapılarak, Cubic SVM sınıflandırıcı ve One-vs-All çok sınıflı bileşen metodu ile oluşan Karmaşıklık Matrisi gösterilmiştir. Önerilen yöntemin sınıflandırma performansını sınıf bazında değerlendirmek üzere metrikler üzerinden elde edilen deneysel sonuçlar Tablo 4'te verilmiştir.

True Class	1	2	3	4	5	6	7	8	9	10
1	2121	1		1			2		2	
2	5	954	1	17	3	4	12	1		3
3			1586				3		1	1
4		11	2	1890	2	1	2		1	
5		1			946	2	1		1	1
6	2	1			1	1762	4	1		
7	1	4	3			6	1372	2	1	15
8							1	372		
9									5353	4
10		1					9		1	1665

Şekil 10. DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin PCA ile boyut indirgenmiş halinin karmaşıklık matrisi

Şekil 11'de önerilen modelin gerçek pozitif (TPR-True Positive Rates) ve yanlış negatif oranlarının (FNR-False Negative Rates) karmaşıklık matrisi gösterilmiştir.

True Class	1	2	3	4	5	6	7	8	9	10	TPR	FNR
1	99.7%	0.0%		0.0%			0.1%		0.1%		99.7%	0.3%
2	0.5%	95.4%	0.1%	1.7%	0.3%	0.4%	1.2%	0.1%		0.3%	95.4%	4.6%
3			99.7%				0.2%		0.1%	0.1%	99.7%	0.3%
4		0.6%	0.1%	99.0%	0.1%	0.1%	0.1%		0.1%		99.0%	1.0%
5		0.1%			99.4%	0.2%	0.1%		0.1%	0.1%	99.4%	0.6%
6	0.1%	0.1%			0.1%	99.5%	0.2%	0.1%			99.5%	0.5%
7	0.1%	0.3%	0.2%			0.4%	97.7%	0.1%	0.1%	1.1%	97.7%	2.3%
8							0.3%	99.7%			99.7%	0.3%
9									99.9%	0.1%	99.9%	0.1%
10		0.1%					0.5%		0.1%	99.3%	99.3%	0.7%

Şekil 11. Önerilen modelin TPR ve FNR oranları

Şekil 12'de pozitif tahmin değerleri (Positive Predictive Values-PPV) ve yanlış keşif oranları (False Discovery Rates-FDR) gösterilmiştir.

True Class	1	2	3	4	5	6	7	8	9	10
1	99.6%	0.1%		0.1%			0.1%		0.0%	
2	0.2%	98.0%	0.1%	0.9%	0.3%	0.2%	0.9%	0.3%		0.2%
3			99.6%				0.2%		0.0%	0.1%
4		1.1%	0.1%	99.1%	0.2%	0.1%	0.1%		0.0%	
5		0.1%			99.4%	0.1%	0.1%		0.0%	0.1%
6	0.1%	0.1%			0.1%	99.3%	0.3%	0.3%		
7	0.0%	0.4%	0.2%			0.3%	97.6%	0.5%	0.0%	0.9%
8							0.1%	98.9%		
9									99.9%	0.2%
10		0.1%					0.6%		0.0%	98.6%

PPV	99.6%	98.0%	99.6%	99.1%	99.4%	99.3%	97.6%	98.9%	99.9%	98.6%
FDR	0.4%	2.0%	0.4%	0.9%	0.6%	0.7%	2.4%	1.1%	0.1%	1.4%

Şekil 12. Önerilen modelin PPV ve FDR oranları

Şekil 13'te önerilen yöntemin sınıflara göre ROC eğrileri gösterilmiştir. 3. Bölümde çalışmada kullanılan veri setindeki sınıf numaralarına karşılık gelen hastalık tipi Tablo 1'de verilmiştir.

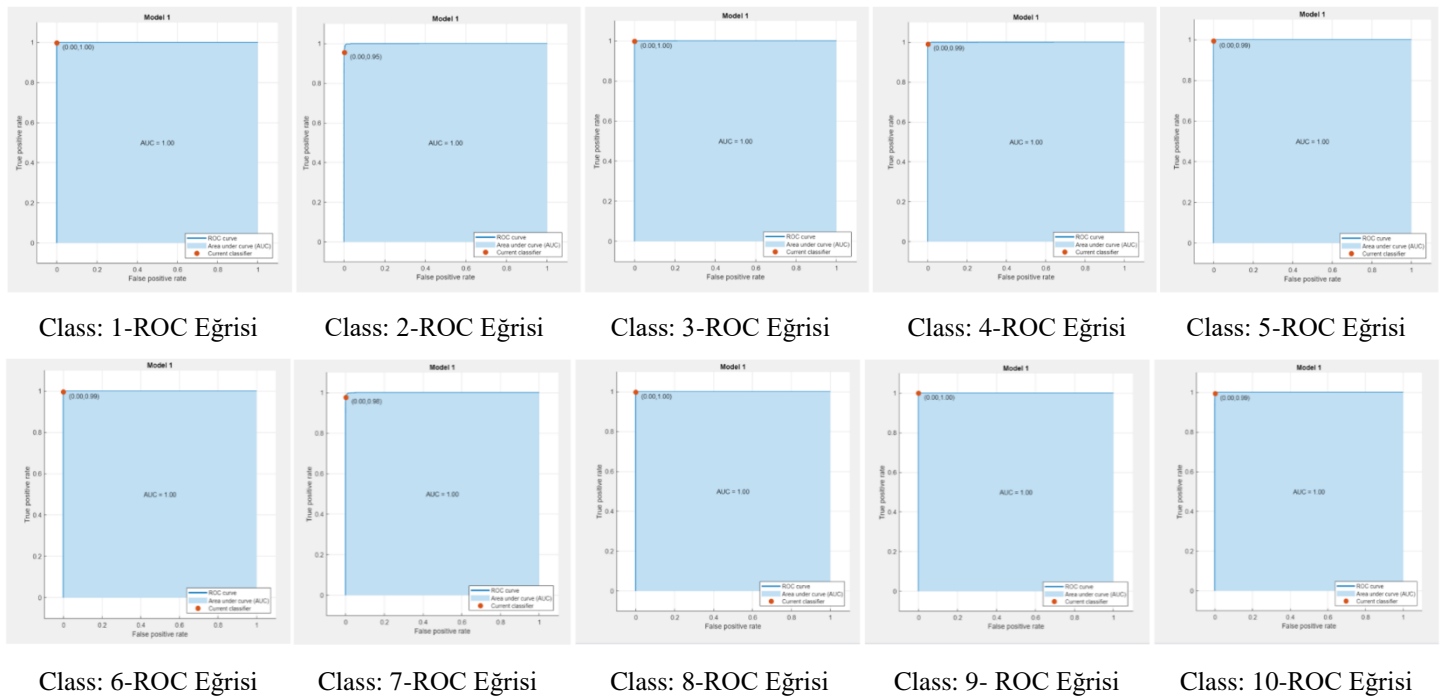
5. Sonuçlar

Bu çalışmada domates yaprağı hastalıklarının etkili bir şekilde tespit edilebilmesi için Cubic SVM algoritması ve One-vs-All çok sınıflı bileşen metodu kullanılarak sınıflandırma doğruluğunun artırılması amaçlanmıştır. Bu kapsamda CNN mimarisinden DenseNet-201+ ResNet-101+ ShuffleNet mimarileri kullanılarak domates yaprağı görüntülerinden sınıflandırmada kullanılacak özellikler elde edilmiştir. Elde edilen bu özellikler PCA yöntemi ile boyut azaltma işlemi yapılarak en yüksek doğruluk oranı elde edilmiştir. Önerilen yöntemden önceki mimarilerde tek tek incelendiğinde doğruluk oranı bireysel olarak en yüksek %97,4 iken önerilen yöntemle doğruluk oranı %99,2 olmuştur.

Yapılan analizler sonucunda elde edilen deneysel sonuçlar, Cubic SVM sınıflandırıcısının doğru parametreler ve optimizasyon yardımıyla yüksek sınıflandırma doğruluğuna ulaştığı görülmektedir. Ayrıca boyut indirgeme metodu ile de maliyet ve zamandan tasarruf edildiği görülmüştür. Yapılan çalışmalar sonucunda sınıflandırma işleminin doğru parametreler yardımıyla yüksek doğruluk oranları elde edileceği gözlemlenmiştir. Ayrıca diğer sınıflandırıcılar gibi Cubic SVM sınıflandırıcısının da domates yaprağı hastalıklarının teşhisinde önemli ve etkili bir tespit yöntemi olduğu söylenebilir.

Tablo 4. Öznitelik çıkarım yöntemi ve sınıflandırıcıya göre doğruluk, kesinlik, duyarlılık ve F_1 (%) sonuçları

Yöntem	Öznitelik Sayısı	Sınıflandırıcı	Sınıf Adı	Acc	Pre	Rec	F_1
DenseNet-201, ResNet-101 ve ShuffleNet + PCA (Önerilen Yöntem)	1500	CSVM	<i>Bakteri Lekesi</i>	99,92	99,71	99,62	99,67
			<i>Erken Yanıklık</i>	99,64	95,40	98,04	96,70
			<i>Sağlıklı</i>	99,93	99,68	99,62	99,65
			<i>Geç Yanıklık</i>	99,79	99,00	99,05	99,03
			<i>Yaprak Kalıbı</i>	99,93	99,36	99,36	99,36
			<i>Septoria Yaprak Lekesi</i>	99,87	99,49	99,26	99,37
			<i>Hedef Nokta</i>	99,63	99,72	97,58	97,65
			<i>Mozaik Virüsü</i>	99,97	99,73	98,93	99,33
			<i>Sarı Yaprak Kıvrılma Virüsü</i>	99,93	99,92	99,86	99,89
			<i>Örümcek Akarları</i>	99,80	99,34	98,57	98,95
Ağırlıklı Ortalama				99,84	98,93	98,99	98,96



Şekil 13. Önerilen yöntemin sınıflara göre ROC eğrileri

Kaynakça

- Acikgoz, H. (2022). A novel approach based on integration of convolutional neural networks and deep feature selection for short-term solar radiation forecasting. *Applied Energy*, (305). doi:https://doi.org/10.1016/j.apenergy.2021.117912.
- Agarwal, M., Singh, A., Arjaria, S., Sinha, A., & Gupta, S. (2020). ToLeD: Tomato leaf disease detection using convolution neural network. *Procedia Computer Science*, 167, 293-301.
- Ahlatwat, S., & Choudhary, A. (2020). Hybrid CNN-SVM classifier for handwritten digit recognition. *Procedia Computer Science*, 167, 2554-2560.
- Al-Amin, M., Karim, D. Z., & Bushra, T. A. (2019, December). Prediction of rice disease from leaves using deep convolution neural network towards a digital agricultural system. In 2019 22nd International Conference on Computer and Information Technology (ICCIT) (pp. 1-5). IEEE.
- Arivazhagan, S., Shebiah, R. N., Ananthi, S. N., & Varthini, S. V. (2013). Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features. *Agricultural Engineering International: The CIGR Journal*, 15, 211-217.
- Arsenovic, M., Karanovic, M., Sladojevic, S., Anderla, A., & Stefanovic, D. (2019). Solving Current Limitations of Deep Learning Based Approaches for Plant Disease Detection. *Symmetry*, 11(7). doi:10.3390/sym11070939
- Bakr, M., Abdel-Gaber, S., Nasr, M., & Hazman, M. (2022). DenseNet Based Model for Plant Diseases Diagnosis. *European Journal of Electrical Engineering and Computer Science*, 6(5), 1-9.
- Brahimi, M., Boukhalfa, K., & Moussaoui, A. (2017). Deep learning for tomato diseases: classification and symptoms visualization. *Applied Artificial Intelligence*, 31(4), 299-315.
- Chaovalitwongse, W. A., Fan, Y. J., & Sachdeo, R. C. (2007). On the time series \$k\$-nearest neighbor classification of abnormal brain activity. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 37(6), 1005-1016.

- Cheng B. and Matson E. T., "A feature-based machine learning agent for automatic rice and weed discrimination," International Conference on Artificial Intelligence and Sof Computing, pp. 517– 527, 2015.
- Cheng, X., Zhang, Y., Chen, Y., Wu, Y., and Yue, Y., "Pest identification via deep residual learning in complex background," Computers and Electronics in Agriculture, vol. 141, pp. 351–356, 2017.
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. doi:<https://doi.org/10.1016/j.compag.2018.01.009>
- GeethaRamani, R., & ArunPandian, J. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Comput. Electr. Eng.*, 76, 323-338.
- H. Sabrol, & K. Satish. (2016). Tomato plant disease classification in digital images using classification tree (pp. 1242–1246). Presented at the 2016 International Conference on Communication and Signal Processing (ICCSP). doi:10.1109/ICCSP.2016.7754351
- Hoo, Z. H., Candlish, J., & Teare, D. (2017). What is an ROC curve? *Emergency Medicine Journal*, 34(6), 357–359. doi:10.1136/emermed-2017-206735
- Jolliffe, I. T. (2002). *Principal component analysis for special types of data* (pp. 338-372). Springer New York.
- Kaggle. (2021, December 6). Kaggle. *Kaggle data set*. dataset. <https://www.kaggle.com/datasets>. Erişim: 18.10.2022
- Liu, Y., Tang, F., Zhou, D., Meng, Y., & Dong, W. (2016). Flower classification via convolutional neural network. In *2016 IEEE International Conference on Functional-Structural Plant Growth Modeling, Simulation, Visualization and Applications (FSPMA)* (pp. 110–116). doi:10.1109/FSPMA.2016.7818296
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, 7.
- Mokhtar, U. *et al.* (2015). SVM-Based Detection of Tomato Leaves Diseases. In: *, et al. Intelligent Systems'2014. Advances in Intelligent Systems and Computing*, vol 323. Springer, Cham. https://doi.org/10.1007/978-3-319-11310-4_55
- Öksüz, C., & Güllü, M. K. (2020, October). Deep Feature Extraction Based Fine-Tuning. In *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Sannakki, S., Rajpurohit, V. S., Sumira, F., & Venkatesh, H. (2013). A neural network approach for disease forecasting in grapes using weather parameters. In *2013 Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT)* (pp. 1–5). doi:10.1109/ICCCNT.2013.6726613
- Shruthi, U., Nagaveni, V., & Raghavendra, B. K. (2019, March). A review on machine learning classification techniques for plant disease detection. In *2019 5th International conference on advanced computing & communication systems (ICACCS)* (pp. 281-284). IEEE.
- Sibiya, M., & Sumbwanyambe, M. (2019). A computational procedure for the recognition and classification of maize leaf diseases out of healthy leaves using convolutional neural networks. *AgriEngineering*, 1(1), 119-131.
- Song, K., Sun, X. Y., & Ji, J. W. (2007). Corn leaf disease recognition based on support vector machine method. *Transactions of the CSAE*, 23(1), 155-157.
- Suryawati, E., Sustika, R., Yuwana, R. S., Subekti, A., & Pardede, H. F. (2018, October). Deep structured convolutional neural network for tomato diseases detection. In *2018 international conference on advanced computer science and information systems (ICACSIS)* (pp. 385-390). IEEE.
- Sünnetçi, K. M. , Alkan, A. & Tar, E. (2021). Göğüs X-Ray görüntülerinin AlexNet tabanlı sınıflandırılması . *Computer Science , 5th International Artificial Intelligence and Data Processing symposium*, 375-384. DOI: 10.53070/bbd.989192
- Tan, L., Lu, J., & Jiang, H. (2021). Tomato Leaf Diseases Classification Based on Leaf Images: A Comparison between Classical Machine Learning and Deep Learning Methods. *AgriEngineering*, 3(3), 542–558. <https://doi.org/10.3390/agriengineering3030035>
- Too, E. C., Yujian, L., Njuki, S., & Yingchun, L. (2019). A comparative study of fine-tuning deep learning models for plant disease identification. *Comput. Electron. Agric.*, 161, 272–279.
- Tüfekçi, M., & Karpat, F. (2019). Derin Öğrenme Mimarilerinden Konvolüsyonel Sinir Ağları (CNN) Üzerinde Görüntü İşleme-Sınıflandırma Kabiliyetinin Arttırılmasına Yönelik Yapılan Çalışmaların İncelenmesi. In *International Conference on Human-Computer Interaction, Optimization and Robotic Applications* (pp. 28-31).
- Vapnik, V. N. (1995). The nature of statistical learning. *Theory*.
- Walliser, J. (2018). *How to identify and control tomato plant disease*. <https://savvygardening.com/tomato-plant-disease/>



Convolutional Neural Networks for Automatic Modulation Classification

Osman Kaya^{1*}, Tansal Güçlüoğlu²

^{1*} Yıldız Teknik Üniversitesi, Mühendislik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, İstanbul, Türkiye, (ORCID: 0000-0003-4902-2166), osmnkaya11@gmail.com

² Yıldız Teknik Üniversitesi, Mühendislik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, İstanbul, Türkiye, (ORCID: 0000-0002-4090-005X), tansal@yildiz.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1224925)

ATIF/REFERENCE: Kaya, O. & Güçlüoğlu, T. (2022). Convolutional Neural Networks for Automatic Modulation Classification. *European Journal of Science and Technology*, (44), 93-96.

Abstract

Automatic Modulation Classification (AMC) is the process of determining the modulation type of the signal which is taken by receiver in a communication system. Deep learning is a machine learning method having recently attracted great attention due to its superior performance of classifying complex data structures. The automatic modulation classification process, having a critical role in both civil and military applications, is examined in this study by using Convolutional Neural Networks (CNN), one of the deep learning approaches. Within this scope, the performance of the changes made on the net has been interpreted for different signal-to-noise ratio (SNR) values.

Keywords: Automatic modulation classification, deep learning, convolutional neural networks

Otomatik Modülasyon Sınıflandırmasında Evrişimsel Sinir Ağları

Öz


Otomatik modülasyon sınıflandırma (AMC) bir haberleşme sisteminde alıcıya gelen sinyalin modülasyon türünün belirlenmesi işlemidir. Derin öğrenme ise karmaşık veri yapılarını üstün performansla sınıflandırması nedeniyle son zamanlarda büyük ilgi gören bir makine öğrenmesi yöntemidir. Hem sivil hem de askeri uygulamalarda kritik bir rol oynayan otomatik modülasyon sınıflandırma işlemi, bu çalışmada derin öğrenme yaklaşımlarından biri olan Evrişimsel Sinir Ağları (CNN) kullanılarak incelenmiştir. Bu kapsamda ağ üzerinde yapılan değişikliklerin başarımı farklı sinyal-gürültü oranı (SNR) değerleri için yorumlanmıştır.

Anahtar Kelimeler: Otomatik modülasyon sınıflandırma, derin öğrenme, evrişimsel sinir ağları

* Corresponding Author: osmnkaya11@gmail.com

1. Giriş

Bilgi işaretinin taşıyıcı adı verilen belli bir frekanstaki elektriksel işaret yardımıyla iletim ortamının özelliklerine uygun hale getirilmesi işlemine modülasyon adı verilmektedir. Bilginin iletişim sürecine dahil edilmeden önce biçiminin değiştirilmesi olarak da ifade edilmektedir (Avcı, 2008). Bir haberleşme sisteminde iletişimin başarılı sayılması verici tarafından gönderilen sinyal modülasyonunun alıcı tarafından demodüle edilmesine bağlıdır. Modülasyon türü bilgisinin saptanabilmesi için ihtiyaç duyulan ön bilgi başta askeri olmak üzere mahremiyet gerektiren uygulamalarda çoğunlukla bulunmamaktadır. Otomatik Modülasyon Sınıflandırma(AMC) herhangi bir ön bilgiye ihtiyaç duymadan alıcı tarafından algılanan sinyalin modülasyon formatının otomatik olarak tanınmasını ve kategorize edilmesini ifade etmektedir. AMC işlemi alıcı için sinyal algılama ve demodülasyon arasındaki ara adımdır (Dobre, Abdi, Bar-Ness ve Su, 2007). Bir haberleşme sistemine AMC'nin nasıl dahil edildiği Şekil 1'de gösterilmiştir.



Şekil 1. Haberleşme sisteminde modülasyon tespiti blok diagramı

Otomatik Modülasyon Sınıflandırması(AMC) yapısının doğruluk değerinin yüksek, işlem karmaşıklığının düşük ve birden fazla amaca hizmet edebilir olması beklenilmektedir. Literatürde bu hususta yapılan çalışmaların ise olabilirlik tabanlı ve öznitelik tabanlı olmak üzere iki ana kategoriye ayrıldığı görülmektedir (Çukur ve Serbes, 2019; Zhang, Ding, Zhang, Xie, Li ve Han, 2018; Rajendran, Meert, Giustiniano ve Lenders ve Pollin, 2018). Olabilirlik tabanlı yöntem, alınan sinyalin tüm modülasyon türleri için olasılık fonksiyonunun hesaplanmasını ve daha sonra tüm olasılıkların karşılaştırılarak maksimum olasılığa (olabilirliğe) göre karar verilmesini sağlamaktadır (Xu, Su ve Zhou, 2011). Olabilirlik tabanlı yöntemin genellikle yüksek doğruluk elde etmesi ve hata olasılığını minimuma indirmesi gibi avantajları olsa da ön bilgi isteme ve işlem karmaşıklığı gibi çeşitli dezavantajları da bulunmaktadır. Öznitelik tabanlı makine öğrenmesi yöntemleri ise öznitelik çıkarımı ve sınıflandırma olmak üzere iki aşamadan oluşmaktadır. Bu yöntem alınan sinyalden ayırt edici özniteliklerin çıkarılarak bir sınıflandırma yöntemi ile eğitilmesi esasına göre çalışır. Söz konusu iki yöntem mukayese edilecek olursa, son dönemde modülasyon tanıma ve sınıflandırma alanında yapılan araştırmaların ve çalışmaların birçoğu öznitelik tabanlı yöntemlerle gerçekleştirilmiştir. Bu durumun nedeni işlem karmaşıklığının olabilirlik tabanlı yöntemlere göre daha düşük seviyelerde olması ve

performansının daha yüksek olmasıdır. Belli bir bilgi kümesi için kurulan sistemin bir başka bilgi kümesi için uygulanabilirliğinin mümkün olmaması, bu iki yöntemin de genellenebilir olmadığını göstermektedir (Karahan ve Kalaycıoğlu, 2020).


Endüstri, tıp, finans, çeviri, robotik, görüntü işleme gibi alanlarda epeydir kullanılan derin öğrenme yaklaşımının haberleşme ve AMC algoritmalarında kullanımı son dönemlerde başlamıştır (Çukur ve Serbes, 2019; O'Shea, Roy ve Clancy, 2018). Derin öğrenme metotları herhangi bir ön bilgi ve ayırt edici nitelik çıkarımına gerek duymamaktadır. Otomatik Modülasyon Sınıflandırması (AMC) işleminde derin öğrenme yaklaşımları kullanıldığında olabilirlik tabanlı yöntem ve öznitelik tabanlı yöntemlere göre hem doğruluk düzeyinin daha yüksek olduğu hem de genellenebilirlik potansiyelinin daha yüksek olduğu bilinmektedir. Gerek askeri gerekse sivil maksatlı birçok uygulamada son derece önemli bir role sahip olan AMC işlemi (Xu, Su ve Zhou, 2011), bu çalışmada derin öğrenme tabanlı CNN yaklaşımıyla incelenmiştir. CNN, son dönemlerde görüntü ve ses işlemede ayrıca görüntülerin sınıflandırılması alanlarında doğruluk düzeyi yüksek, genellenebilir ve etkili bir yaklaşım olarak kabul görmüştür (Çalışır, 2022). Literatür incelendiğinde bu yaklaşımla ilgili başarılı çalışmalar yapıldığı görülmüştür.

Literatür incelendiğinde çalışma alanının öncülerinden O'Shea vd. (O'Shea, Corgan ve Clancy, 2016), IQ veri ifadesi üzerinde eğitilen CNN'lerin genel makine öğrenmesi algoritmalarına göre otomatik modülasyon sınıflandırmada önemli ölçüde üstün olduklarını göstermiştir. Selim vd. (Selim, Paisana, Arokkiam, Zhang, Doyle ve DaSilva, 2017) çalışmasında genlik ve faz farkı verisinin CNN sınıflandırıcılar ile radar sinyallerinin varlığının yüksek tutarlılık ile saptandığı bir yöntem önermiştir. Akaret vd. (Akeret, Chang, Lucchi ve Réfrégier, 2017) bir radyo teleskopundan elde edilen 2 boyutlu zaman bölgesi verilerinin CNN'ler ile eğitilerek, radyo frekans girişimlerini yüksek doğrulukta saptayabildikleri özgün bir yöntem önermişlerdir. Meng vd. (Meng, Chen, Wu ve Wang, 2018) çalışmasında en çok olabilirlik yöntemi ve CNN'ler ile AMC başarımını karşılaştırmışlardır. Kumar vd. (Kumar, Sheoran, Jajoo ve Yadav, 2020) çalışmasında ASK, PSK ve QAM modülasyon türlerinin yıldız küme yoğunluk matrislerini ResNet-50 ve Inception ResNet-V2 derin öğrenme modelleri ile sınıflandırılmıştır. Huang vd. (Huang, Jiang, Gao, Feng ve Zhang, 2019) çalışmasında kontrastlı CNN ile yıldız küme diyagramları kullanılarak AMC işlemi gerçekleştirilmiştir.

Derin öğrenme yaklaşımlarından, CNN yaklaşımını kullanarak 7 farklı modülasyon türünün farklı ağ derinlikleri için sınıflandırma doğruluğunun karşılaştırılmasını amaçlayan bu çalışmanın 2. bölümünde çalışma kapsamında incelenen CNN hakkında kısaca bilgi verilmektedir. 3.bölümde ise deneysel sonuçlar paylaşılmış olup, 4.bölümde sonuçlar incelenmektedir.

2. Materyal ve Metot

Derin öğrenme, üzerinde çalışılan veriden katmanlı yapısı sayesinde istatistiksel çıkarımlar yaparak model türeten verigüdümlü bir yöntemdir. Bu yöntemde alan bilgisi yerine ham veriden yararlanılmaktadır. Verinin yapısı, sayısı, gösterimi ve ağırlık çeşidi, derinliği gibi değişkenler modelin doğruluğu üzerinde büyük etkiye sahiptir. Katmanları içerisinde evrişim işlemi kullanan CNN yapısı sıklıkla kullanılan bir derin öğrenme yöntemidir. Görüntü, zaman serisi, ses, sinyal gibi farklı veri çeşitlerinde yüksek başarıma sahip olmasından dolayı literatürde CNN kullanımına sıklıkla rastlanılmaktadır. Bir CNN mimarisi her biri verinin farklı özelliklerini öğrenmeyi amaçlayan birden fazla katmana sahiptir. Katmanlar boyunca evrişim işleminden geçirilerek ilerleyen veri, her katmanda aranılan çıktıya daha da yaklaşmaktadır. Her katmanda farklı özellikler ile kısmen tanımlanan veri bir sonraki katmanın girişi olmaktadır. En sonda bulunan tam bağlantılı katman ile de CNN temsil ettiği sınıflandırma işlemi gerçekleştirilmiş olur. CNN mimarisi içerisinde evrişim katmanı, havuzlama katmanı ve tam bağlantı katmanı içermektedir. İşlemlerin büyük çoğunluğu evrişim katmanında kullanılan filtreler aracılığıyla gerçekleştirilir. Çalışma kapsamında evrişim ve tam bağlantı katmanı sayısı ile evrişim katmanı filtre sayısının AMC işlemi başarımlarını incelenmiştir.



Şekil 2. Evrişimsel Sinir Ağlarının (CNN) temel yapısı

Tablo 1: Çalışmada kullanılan senaryo özellikleri

Senaryo	Katman Özellikleri	Filtre Sayısı
1	Conv2D	32
2	Conv2D	64
3	Conv2D	128
4	Conv2D	128
	Conv2D	64
5	Conv2D	128
	Conv2D	64
	Conv2D	32
6	Conv2D	256
	Conv2D	64
7	Conv2D	256
	Conv2D	64
	Dense	256


3. Deneysel Sonuçlar

Çalışma kapsamında RadioML 2016.10a Modulation veri seti kullanılmıştır (O'Shea, Corgan ve Clancy, 2016). Bu veri seti içerisinde BPSK, QPSK, CPFSK, GFSK, 4-PAM, AM-DSB, QAM64 olmak üzere etiketlenmiş veri vektörleri halinde 7 tane modülasyon formatı bulunmaktadır. Veri vektörleri \mathbf{x}_k , 1MS/s örnekleme oranı ile $N = 128$ örnekleme yığını içinde toplanmışlardır. Her modülasyon formatı -20 db ve +18 db SNR oranına sahip olacak şekilde rastgele gürültü ile bozulmuşlardır. Veri seti toplamda 140000 veri vektörü $\mathbf{x}_k \in \mathbb{R}^{2 \times 128}$ olacak şekilde, I ve Q ifadesine sahiptir. Her SNR değerinde her modülasyon formatı için 1000 tane örnek bulunmaktadır. 7 modülasyon sınıf etiketini oluşturmak için ikili kodlama kullanılmıştır, sonuç olarak modülasyon tanıma 7 kategoriyi sınıflandırma problemine dönüşmüştür.

Çalışmada benzetimler Python programlama diliyle Keras kütüphanesi kullanılarak gerçekleştirilmiştir.

Çalışma kapsamında Tablo 1'de gösterildiği üzere yedi farklı senaryo oluşturulmuş olup, senaryolarda birbirinden farklı katman özellikleri ve filtre sayıları kullanılmıştır. Bu senaryolar kapsamında AMC başarımlarını incelenmiştir.


Şekil 3'te Senaryo 1, 2, 3, 4 ve 5 karşılaştırılmıştır. Senaryo 1, 2 ve 3'te olduğu gibi bir tane evrişim katmanı kullanıldığında %60 seviyelerinde doğruluk oranı elde edilmiştir. Senaryo 3'ün başarımlarını filtre sayısının daha büyük olmasından dolayı Senaryo 1 ve 2'ye kıyasla daha yüksektir. Tablo 1'de Senaryo 4 ve 5'in doğruluğu incelendiğinde diğer senaryolardan oldukça yüksek başarımlar elde edildiği gözlemlenmektedir. Senaryo 5'te üçüncü bir evrişim katmanı kullanımı başarımlarını daha da artırmıştır.



Şekil 3: Farklı filtre sayıları ve CNN ağ derinliği için başarımların incelenmesi

Şekil 4'te farklı filtre büyüklükleri ve tam bağlantı katmanı sayısı açısından Senaryo 4, 6 ve 7 incelenmiştir. Senaryo 4 ve 6 incelendiğinde filtre sayısının artışının başarımlarını olumlu yönde

etkilendiği gözlemlenmektedir. Senaryo 6 ve 7 karşılaştırıldığında ise aynı yapıya fazladan bir tam bağlantı katmanı eklenmesinin başarımı bir miktar daha artırdığı gözlemlenmiştir.



Şekil 4. Farklı filtre sayıları ve tam bağlantılı ağ derinliği için başarımların incelenmesi

4. Sonuçlar

Çalışmada derin öğrenme tabanlı farklı özelliklere sahip CNN yöntemleri kullanılarak modülasyon verisi tanıma ve sınıflandırma başarımı incelenmiştir. Sonuçlar incelendiğinde SNR seviyesinin başarımla ilgili doğrudan ilişkisi olduğu gözlemlenmiştir, SNR seviyesi arttıkça başarımlar yükselmiştir. Ayrıca filtre sayısı ve ağ derinliğinin doğruluk üzerindeki etkisi araştırılmıştır. Hem filtre sayısının hem de ağ derinliğinin artırılması doğruluk düzeyini yükseltici bir etki yapmıştır.

Kaynakça

- Avcı, E. (2008). Sayısal Modülasyon Tanıma Sistemleri İçin Bayes Karar Kuralları Sınıflandırıcısının Kullanımı. *Engineering Sciences*,3(1),<https://dergipark.org.tr/tr/pub/nwsaeng/issue/19871/212968>.
- Dobre, O. A., Abdi, A., Bar-Ness, Y., & Su, W. (2007). Survey of automatic modulation classification techniques : classical approaches and new trends. *IET Communications*, 1(2), 137–156. <https://doi.org/10.1049/iet-com:20050176>
- Çukur, H. & Serbes, A. (2019). A Survey of Automatic Modulation Classification Algorithms for Cognitive Radio Applications. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi* , vol.25, no.4, pp.1-15.
- Zhang, D., Ding, D., Zhang, B., Xie, C., Li, H. & Han, J. (2018). Automatic Modulation Classification Based on Deep Learning for Unmanned Aerial Vehicles. *Sensors (Basel)*, (3):924. doi: 10.3390/s18030924. PMID: 29558434; PMCID: PMC5876703.
- Rajendran, S., Meert, W., Giustiniano, D., Lenders, V. & Pollin, S. (2018). Deep Learning Models for Wireless Signal Classification With Distributed Low-Cost Spectrum Sensors. *IEEE Transactions on Cognitive Communications and e-ISSN: 2148-2683*

- Networking, vol. 4, no. 3, pp. 433-445, doi:10.1109/TCCN.2018.2835460.
- Xu, J. L., Su, W. & Zhou, M. (2011). Likelihood-Ratio Approaches to Automatic Modulation Classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 41, no. 4, pp. 455-469, July 2011, doi: 10.1109/TSMCC.2010.2076347.
- Karahan, S. N. & Kalaycıoğlu, A. (2020). Deep Learning Based Automatic Modulation Classification With Long-Short Term Memory Networks. *2020 28th Signal Processing and Communications Applications Conference (SIU)*, pp. 1-4, doi: 10.1109/SIU49456.2020.9302280.
- O'Shea, T. J., Roy, T. & Clancy, T. C. (2018). Over-the-Air Deep Learning Based Radio Signal Classification. *IEEE Journal of Selected Topics in Signal Processing*, vol. 12, no. 1, pp. 168-179, doi: 10.1109/JSTSP.2018.2797022.
- Çalışır, B. (2022). Radyo Haberleşmesinde Evrişimli Sinir Ağı Kullanılarak Yapılan Modülasyon Sınıflandırması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*,34 (2) , 867-877 . DOI: 10.35234/fumbd.1141515
- O'Shea, T. J., Corgan, J. & Clancy, T. C. (2016). Convolutional Radio Modulation Recognition Networks. *Proc. Int. Conf. Eng. Appl. Neural Netw.*, pp. 213226.
- Selim, A., Paisana, F., Arokkiyam, J. A., Zhang, Y., Doyle, L. & DaSilva, L. A. (2017). Spectrum Monitoring For Radar Bands Using Deep Convolutional Neural Networks. Available: <https://arxiv.org/abs/1705.00462>. 2017.
- Akeret, J., Chang, C., Lucchi, A., & Réfrégier, A. (2017). Radio frequency interference mitigation using deep convolutional neural networks. *Astron. Comput.*, 18, 35-39.
- Meng, F., Chen, P., Wu, L. & Wang, X. (2018). Automatic Modulation Classification: A Deep Learning Enabled Approach. *IEEE Transactions on Vehicular Technology*, vol. 67, no. 11, pp. 10760-10772, doi: 10.1109/TVT.2018.2868698.
- Kumar, Y., Sheoran, M., Jajoo, G. & Yadav, S. K. (2020). Automatic Modulation Classification Based on Constellation Density Using Deep Learning. *IEEE Communications Letters*, vol. 24, no. 6, pp. 1275-1278, doi: 10.1109/LCOMM.2020.2980840.
- Huang, S., Jiang, Y., Gao, Y., Feng, Z. & Zhang, P. (2019). Automatic Modulation Classification Using Contrastive Fully Convolutional Network. *IEEE Wireless Communications Letters*, vol. 8, no. 4, pp. 1044-1047, doi: 10.1109/LWC.2019.2904956.



Developing a Guided Tactile Feedback System for Visually Impaired People

Rıza İlhan^{1*}, Fahmeed Ali²

^{1*} Istanbul Aydın University, Faculty of Engineering, Department of Mechanical Engineering, İstanbul, Turkey, (ORCID: 0000-0001-8975-9942),
gilkhansarkandi@aydin.edu.tr

² Istanbul Aydın University, Faculty of Engineering, Department of Mechanical Engineering, İstanbul, Turkey, (ORCID: 0000-0001-9124-5115),
fahmeedali@stu.aydin.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1225030)

ATIF/REFERENCE: İlhan, R. & Ali, F. (2022). Developing a Guided Tactile Feedback System for Visually Impaired People. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 97-103.

Abstract

Haptic interfaces and assistive technologies are improving for visually impaired individuals. In line with these efforts, this paper describes the design, working and implementation of a wearable haptic feedback glove incorporated with a robotic arm to guide the user's hand in the court. The glove is lightweight, inexpensive and includes coin vibration motors that give vibratory feedback, which describes the direction of the ball. The system was tested on five participants. The participants gave positive feedback regarding the design and the overall experience was good. They recommended the system because it is easy-to-use.

Keywords: Haptics, Robotics, Visually impaired individuals.

Görme Engelliler için Rehberli Dokunsal Geri Bildirim Sistemi Geliştirme

Öz

Görme engelli bireyler için dokunsal arayüzler ve yardımcı teknolojiler gelişiyor. Bu çabalar doğrultusunda, bu makale, kullanıcının elini sahada yönlendirmek için robotik bir kolla birleştirilmiş giyilebilir bir dokunsal geribildirim eldiveninin tasarımını, çalışmasını ve uygulamasını açıklamaktadır. Eldiven hafiftir, ucuzdur ve topun yönünü tanımlayan titreşimli geri bildirim sağlayan titreşim motorları içerir. Sistem beş katılımcı üzerinde test edildi. Katılımcılar sistemle ilgili olumlu geri bildirimler verdiler ve genel deneyim iyiydi. Sistemi kullanımı kolay olduğu için tavsiye ettiler.

Anahtar Kelimeler: Haptik, Robotik, Görme engelli bireyler.

* Corresponding Author: gilkhansarkandi@aydin.edu.tr

1. Introduction

It has been estimated that there are around 49.1 million visually impaired people of the total 7.79 billion population in the world (Bourne RRA, Adelson J, Seth Flaxman S, Briant P, Bottone M 2020). Researchers have been working hard to develop assistive technologies for such individuals to make the graphical user interface (GUI) and computer interface more accessible and easy to use. In this regard, haptic technology plays an important role. Haptic technology is the science of generating a sense of virtual touch by implying different phenomena such as vibration. It transforms an electronic device into a bilateral one that gets input and outputs sensational awareness. Utilizing haptic feedback enhances device usability and increases realism by enabling a combination of touch, vision, and sound (MacLean 2009), (Hayward and Astley 1996), (Hatzfeld 2014).

A well-known attempt in this field is developing a braille tactile display (Yang et al. 2021). Since the current braille systems are bulky and expensive to use, researchers are trying to make the system cost-effective, simple, and accessible (Frediani, Busfield, and Carpi 2018; Zarate et al. 2017), (Yobas et al. 2003). Another common problem for these individuals is the absence of surface information such as texture, shape, and graphical items while they are touching a display like a smartphone. Several attempts have been done to tackle this issue. Knowing this, Israr et al. (Xu et al. 2011) developed a system to feel the 2D shapes on the display. They were using electrovibration (Bau et al. 2010), (Ilkhani, Aziziaghdam, and Samur 2017) method to create tactile information. In another study, thermal information was included in the haptic system (Hribar and Pawluk 2011). A thermal feedback was adopted to map the warm-cold spectrum of colors.

Some other studies focused on wearable devices such as a glove. Krishna et al. (Krishna et al. 2010) developed VibroGlove to let blind people see the facial expressions of people. With this technology, a blind person can see by the patterns of vibration. In a study, scientists developed a haptic glove system named FeelX for web browsing. They conducted an experiment on 20 blind participants and asked different questions regarding experiencing the system such as identifying various objects of different shapes. They concluded that FeelX was not the ultimate solution but blind people were interested in using a haptic glove to ease their problem (Soviak et al. 2016).

Navigation in another typical problem for these people. Current society is becoming more and more crowded and complicated such that even normal people have to use assistive technologies to avoid obstacles and find the ways. ActiveBelt is one of those technologies that was developed in this field by Tsukada et al. (Tsukada and Yasumura 2004). The vibration motors were integrated in a belt and by adjusting the vibration people can find their ways. Using haptic as a guidance options, Ogrinc et al. (Ogrinc et al. 2018) utilized a tactile feedback system for deaf-blind people while riding horse. Using tactile cues, which were sent by the instructor, riders experienced an enjoyable and independent horse riding.

Relevant to sports, blind disabled people have hardness watching and doing sports. Especially deaf-blind ones need a company to describe the game to them by hand motions.

Scientists have rarely addressed this area. In the most relevant study, Footbraille was developed which allows blind disabled people to watch football. Footbraille works by allowing users to place their hands on a carpeted device that mimics a soccer field. During gameplay, a miniature ball moves in sync with the game, allowing fans to easily track game stats (Al-Mohannadi 2022). In another application, a haptic glove was developed to watch a football match. Fifteen visually impaired individuals were selected with severe visual impairment to perform the test using haptic glove. The Haptic glove allows for receiving signals and generating vibrations in the hand, informing about what happens in a scene. The answers to the questions asked to the participants revealed that they liked the system (Villamarín and Menéndez 2021). Lee et al. (Lee et al. 2005) developed a vibrotactile display to provide events happening in the game. The system was composed of a 7×10 tactile array that was attached to the forearm. They claimed that 80% of subjects could judge the correct ball path. Rehman et al. (Ur Réhman et al. 2008) carried this experience to a mobile phone trying to render a football match using vibration. A user could feel the dynamic position of the ball and attack direction in this device. The main contribution of the paper was declared to be the application of vibration in game rendering.

There are other studies that address the application of haptic in multimedia. For example, Kim et al. (Kim et al. 2010) developed a haptic glove synchronized with the media to feel the content of the movie such that in a horror movie you can feel a ghost brush against your hand. In another application, a 4D multimedia player that stimulates further senses such as haptics was presented. It was the combination of conventional 3D content with sensory effects which allows to further enhance the viewing experience of the users (Waltl et al. 2013). Mazzoni et al. introduced Mood Glove to enhance mood music. The glove was also usable by hearing impaired people. Using vibration motors and adjusting intensity and frequency of the vibration haptic sensation were created (Mazzoni and Bryan-Kinns 2016).

In the present study, Volleyball game was chosen to design the desired interactive system for the blind people. Unlike the other studies a sense of touch was combined with the sense of location, using a haptic glove and a robotic arm, which demonstrate that wearable haptic glove, has the potential to become an indispensable tool for enhancing the sensing experience for visually impaired people while watching Volleyball game. Besides the proposed system could be extended to render other games too.

2. Volleyball game

In 1895, William G. Morgan, a physical director of Young Men's Christian Association (YMCA), invented the game of Volleyball. It was initially termed Mintonette (Murat 2000). It is estimated that approximately 200 million individuals play Volleyball globally. A 9 m (30 ft) wide and 18 m (60 ft) long court is designed to play Volleyball by two teams. A net of 2.43 m for men and in the case of women, a 2.24 m high equally divides the court over a black margin drawn on the floor in the center. The game is played by two teams and each team has six members. Initially, one player of any team tosses the ball from the boundary of the court and hit it by the hand or arm over the net. The opponent team should not allow the ball to hit the ground. The players should avoid touching the ball more than three times to hit it back to the other side, where it is not allowed

to touch the ball two times in a row by any individual team member. Typically, a team needs 25 points to win in the first four games (referred to as ‘sets’) and 15 in the fifth one.

3. Methodology

3.1. Design of the Court

The court was assumed as a rectangle region with 90 cm height and 180 cm width. It was divided into two halves from the middle. This line represents the location of the net. The players were grouped into two teams. The teams were named team A and team B. Typically, there are six players in Volleyball but in this study, it was assumed four players in each team in which one player is dedicated for the services. Positions and angles of players were set arbitrarily.




Figure 1: The court was assumed to be 90 cm × 180 cm rectangle region. Each team composed of four players who are located arbitrarily in the region.

3.2. Robotic Arm

In this study, the robotic arm was used to direct the user’s hand according to the ball position. The two-link arm was made of two Aluminum plate with 70 mm × 50 mm × 2 mm dimensions as links. Two MG996R servomotors with metal gears and maximum stall torque of 11 kg/cm located at two joints. The system was connected to the base using screws firmly. As is seen in Figure 2, the arm involves two rotatory joints and it is a linear chain. L1 and L2 are the length of both links respectively, whereas angle θ_1 and angle θ_2 are the angles of joint rotations of the two joints, accordingly. The arm was initially designed on Solidwork software. For all events happening during the game angles information were obtained using Solidwork. However, an autonomic system could be developed using following information.




Figure 2: The robotic arm consists of two Aluminum links and two servomotors.

3.2.1. Forward Kinematic

Forward kinematics can be defined as the calculation of the end-effector’s position and orientation as joint variables. Using

the link’s length and angles, the end effectors position can be written as follows:

$$P_x = L_1 \cos \theta_1 + L_2 \cos(\theta_1 + \theta_2) \quad (1)$$

$$p_y = L_1 \sin \theta_1 + L_2 \sin(\theta_1 + \theta_2)$$

For robot kinematics, Denavit-Hartenberg (D-H) method is also used commonly. This method involves four parameters; θ_i joint angle, α_i link twist, a_i link length and d_i joint distance. According to these parameters the D-H parameters can be written in Table 1. (Corke 2007). According to these parameters, the transformation matrix relating position and orientation of the end-effector to the reference coordinate system can be written as Equation 3.

Table 1 D-H Parameters of two-link manipulator

Link	a_i	α_i	d_i	θ_i
1	L1	0	0	θ_1
2	L2	0	0	θ_2

$$T_i^{i+1} = \begin{bmatrix} \cos \theta_i & -\sin \theta_i \cos \alpha_i & \sin \theta_i \sin \alpha_i & L_i \cos \theta_i \\ \sin \theta_i & \cos \theta_i \cos \alpha_i & -\cos \theta_i \sin \alpha_i & L_i \sin \theta_i \\ 0 & \sin \alpha_i & \cos \alpha_i & d_i \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (2)$$

$$T_2^0 = T_1^0 T_2^1 \quad (3)$$

3.2.2. Inverse Kinematic

The manipulators work in Cartesian space (including orientation matrix and position vector), on the other hand, actuators in joint space (represented by joint angles). The position and orientation of the manipulator end-effector converts from Cartesian space to joint space. This is called inverse kinematics problem. The solution to this problem is the use of geometric, analytical, numerical and intelligent algorithm approaches. The angles θ_1 and θ_2 can be found using Equations 4 and 5.

$$\theta_2 = \cos^{-1} \left(\frac{p_x^2 + p_y^2 - L_1^2 - L_2^2}{2L_1L_2} \right) \quad (4)$$

$$\theta_1 = \tan^{-1} \frac{p_y}{p_x} - \tan^{-1} \frac{a_2 \sin \theta_2}{a_1 + a_2 \cos \theta_2} \quad (5)$$

3.3. Haptic Glove

The glove is made of a fabric that can be adjusted to fit different hand sizes by adjusting the length of all finger appendages to resemble a real hand. The wires and haptic motors are on the glove’s internal pair. Nine low-power, small-size coin vibration motors were used to provide tactile feedback. Where TA1, TA2, TA3 and TA5 represent team A, the second group TB1, TB2, TB3 and TB5 represent team B. The last one was located on the back of the hand for the auxiliary purposes. Its initial working prototype was produced for the right hand. The whole system was controlled using an Arduino UNO.




Figure 3: Shows the position of motors incorporated in haptic glove.

3.3.1. Haptic Glove Working Algorithm

As stated earlier the Volleyball game involves rules and events such as fouls, time-out, service etc. In order to create all effective events following algorithm was considered. The time interval was set before every event so that the participant had enough time to be engaged and understand.

- The match starts with a 5 sec delay for preparation.
- The game starts with a service. For a service, V5 is vibrated. Each vibration motor turns on for 1 sec.
- For scoring a goal, V5 - Goal is vibrated for 1 sec.
- In attacking and defending goal situation, mutual motors TB1-TA1, TB2-TA2, and TB3-TA3 are vibrated simultaneously. If a team scores a point, the Goal function is activated. If none of the teams scores a point, the normal game continues.
- If a foul happens (i.e. touching the net), the referee stops the game. For this case V1, V3, V5 are vibrated simultaneously for 0.5 sec two times. Then the Goal function is activated.
- If one team service hit the net, V5 is vibrated for 2 sec two times. Then, the opposite team's Goal function is activated.
- For timeout, both V5 are vibrated for 2 sec.
- If one team misses the ball (i.e. ball hits a region outside the court) V1, V2, and V3 are vibrated simultaneously. Then, the opposite team's Goal function is activated.
- If a team wins a set V1, V2, V3, and V5 are vibrated for 0.5 sec two times.

Where V is the general term used for any player of both team.

3.3. Experimental Evaluation

A user study was performed to evaluate the performance of the proposed system. Four male and one female volunteer (Mean age = 25 years, age range 20-30 years) participated in the study after signing a written informed consent. All volunteers had no prior experience of testing such a system. Istanbul Aydin University approved the procedure. To test the system, a sample Volleyball match between Japan and France (Men's Volleyball World Grand Champions Cup 2017) was selected.






Figure 4: The developed system is seen on the right. The subject puts his hand on the robotic arm. It guides the user's hand to the desired position.

All the events in the first three minutes were extracted and programmed according to the algorithm stated earlier. A total of 26 events were extracted including scores, fouls, time outs, etc. Five events were selected randomly and played for each user while they were hearing the game played on the computer. Later they were asked to comment if they could feel the corresponding event. Figure 4 shows the conducted experiment. The user puts his hand on the arm and the arm guides the user's hand according to the ball position. A sample event is presented in Figure 5. The game starts with service from TA5. TB1 receives the first ball and then passes it to the second player TB3. Finally, TB2 spikes the ball. Simultaneously TA3 is trying to defend. As a result, team B scored 1 point, which means TB5 - Goal, were activated.







Figure 5: A sample experiment and schematic representation of the arm movement.

4. Results and Discussion

The participants answered some questions related to the experience throughout the game. They were required to answer each question in on a Likert scale from 1-7. One represents the lowest score and seven is the highest. The results are presented in Table 2. As is seen in Table 2 most of the participants were satisfied with the experiment and found it interesting to try. However, intensity and type of vibration got the lowest score which means they must be improved. In addition, training is required to remember the entire event. Some users stated that they need some time before each event, which might be because of memorizing and interpretation. Overall, they were satisfied with the experiment and enjoyed the game with this new invention.


5. Conclusion

The idea of this study was to build a cost-effective, light-weighted, portable, and patient-friendly system. The arm was initially designed on Solidwork software and all the motion information was obtained. The standard dimensions of the pitch were 90 cm by 180 cm. Positions and angles of players were set. A sample game was chosen and the entire events in the game were extracted and coded according to the algorithm. The performance of the system was evaluated using a psychophysical experiment. According to the findings, the participants significantly improved their abilities related to the usage of the haptic glove and their active participation in the game. Some of the participants also suggested that the system could be improved by adding more features such as multiple directional sound effects to create an enthusiastic environment. Whereas some of them were satisfied with the current system. They also gave feedback that the proposed system is cost-effective but it needs to be easily available in markets.

5. Future Work

Many scientists have worked on assistive technologies for visually impaired individuals in order to make them feel joyful in spite of their disabilities, yet more studies are ongoing. The technology is getting advanced and more options can be integrated into the systems. The present proposed design was satisfactory and easy-to-use for the participants. It was observed that the integration of camera and providing virtual environment in the system would make the participants feel more enjoyable.

Table 2 Showing scores of Questionnaire-based survey



This study is an on-going project and will build a system in which a participant can choose other games of their interest, which requires automatic ball position recognition, and faster system compatible with the game's dynamics.

References

- Al-Mohannadi, Al-Dana. 2022. "Innovative ICT Accessibility Solutions in Stadiums and Fan Zones for Persons with Visual Impairment and Blindness." *Nafath* 7(19): 28–33.
- Bau, O., I. Poupyrev, A. Israr, and C. Harrison. 2010. "TeslaTouch." In *Proceedings of the 23rd Annual ACM Symposium on User Interface Software and Technology - UIST '10*, New York, New York, USA: ACM Press, 283.
- Bourne RRA, Adelson J, Seth Flaxman S, Briant P, Bottone M, Vos T et al. 2020. "Global Prevalence of Blindness and Distance and Near Vision Impairment in 2020: Progress towards the Vision 2020 Targets and What the Future Holds." *Investigative Ophthalmology & Visual Science* 61(7): 2317.
- Corke, Peter I. 2007. "A Simple and Systematic Approach to Assigning Denavit-Hartenberg Parameters." *IEEE Transactions on Robotics* 23(3): 590–94.
- Frediani, Gabriele, James Busfield, and Federico Carpi. 2018. "Enabling Portable Multiple-Line Refreshable Braille Displays with Electroactive Elastomers." *Medical Engineering and Physics* 60: 86–93. <https://doi.org/10.1016/j.medengphy.2018.07.012>.
- Hatzfeld, Christian. 2014. "Haptics as an Interaction Modality." In , 29–100.
- Hayward, Vincent, and Oliver R. Astley. 1996. "Performance Measures for Haptic Interfaces." *Robotics Research* (December): 195–206.
- Hribar, Victoria E., and Dianne T.V. Pawluk. 2011. "A Tactile-Thermal Display for Haptic Exploration of Virtual Paintings." *ASSETS'11: Proceedings of the 13th International ACM SIGACCESS Conference on Computers and Accessibility*: 221–22.
- Ilkhani, Gholamreza, Mohammad Aziziaghdam, and Evren Samur. 2017. "Data-Driven Texture Rendering on an Electrostatic Tactile Display." *International Journal of Human-Computer Interaction* 00(00): 1–15.
- Kim, Yeongmi, Jongeun Cha, Jeha Ryu, and Ian Oakley. 2010. "A Tactile Glove Design and Authoring System for Immersive Multimedia." *IEEE Multimedia* 17(3): 34–44.
- Krishna, Sreekar et al. 2010. "VibroGlove: An Assistive Technology Aid for Conveying Facial Expressions." *Conference on Human Factors in Computing Systems - Proceedings*: 3637–42.
- Lee, Beom Chan et al. 2005. "Immersive Live Sports Experience with Vibrotactile Sensation." *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 3585 LNCS: 1042–45.
- MacLean, Karon E. 2009. "Putting Haptics into the Ambience." *IEEE Transactions on Haptics* 2(3): 123–35.
- Mazzoni, Antonella, and Nick Bryan-Kinns. 2016. "Mood Glove: A Haptic Wearable Prototype System to Enhance Mood Music in Film." *Entertainment Computing* 17: 9–17.
- Murat, M, Volleyball Tech. 2000. Ankara: Bağırgan.
- Ogrinc, Matjaž, Ildar Farkhatdinov, Rich Walker, and Etienne Burdet. 2018. "Horseback Riding Therapy for a Deafblind Individual Enabled by a Haptic Interface." *Assistive Technology* 30(3): 143–50.
- Soviak, Andrii et al. 2016. "Tactile Accessibility: Does Anyone Need a Haptic Glove?" *ASSETS 2016 - Proceedings of the 18th International ACM SIGACCESS Conference on Computers and Accessibility (October)*: 101–9.
- Tsukada, Koji, and Michiaki Yasumura. 2004. "ActiveBelt: Belt-Type Wearable Tactile Display for Directional Navigation." *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 3205: 384–99.

- Ur Réhman, Shafiq, Jiong Sun, Li Liu, and Haibo Li. 2008. "Turn Your Mobile into the Ball: Rendering Live Football Game Using Vibration." *IEEE Transactions on Multimedia* 10(6): 1022–33.
- Villamarín, Diego, and José Manuel Menéndez. 2021. "Haptic Glove Tv Device for People with Visual Impairment." *Sensors* 21(7): 1–27.
- Waltl, Markus et al. 2013. "A 4D Multimedia Player Enabling Sensory Experience." 2013 5th International Workshop on Quality of Multimedia Experience, QoMEX 2013 - Proceedings: 126–27.
- Xu, Cheng et al. 2011. "Tactile Display for the Visually Impaired Using TeslaTouch." *Proc. CHI EA '11*: 317–322.
- Yang, Wenzhen et al. 2021. "A Survey on Tactile Displays for Visually Impaired People." *IEEE Transactions on Haptics* 14(4): 712–21.
- Yobas, Levent et al. 2003. "A Novel Integrable Microvalve for Refreshable Braille Display System." *Journal of Microelectromechanical Systems* 12(3): 252–63.
- Zarate, Juan Jose, Olexandr Gudozhnik, Anthony Sébastien Ruch, and Herbert Shea. 2017. "Keep in Touch: Portable Haptic Display with 192 High Speed Taxels." *Conference on Human Factors in Computing Systems - Proceedings Part F1276*: 349–52.



Violence Detection with Machine Learning: A Sociodemographic Approach

Tolga Ensari¹, Betül Ensari², Mustafa Dagtekin^{3*}

¹ Arkansas Tech University, College of STEM, Department of Engineering and Computing Sciences, Russellville, USA, (ORCID: 0000-0003-0896-3058), tensari@atu.edu

² Arkansas Tech University, Graduate College, Information Technology (MSc Program), Russellville, USA (ORCID: 0000-0003-0425-7252), bensari@atu.edu

^{3*} Istanbul University-Cerrahpasa, Faculty of Engineering, Department of Computer Engineering, Istanbul, Turkey, (ORCID: 0000-0002-0797-9392), dagtekin@iuc.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1225896)

ATIF/REFERENCE: Ensari T., Ensari B., & Dagtekin M., (2022). Violence Detection with Machine Learning: A Sociodemographic Approach. *European Journal of Science and Technology*, (44), 104-107.

Abstract

This study suggests that by implementing machine learning methods on a sociodemographic data set can be helpful in preventing domestic violence. This approach is important in predicting high-risk factors that an offender may cause and it offers treatment, and financial or mental health aids in order to prevent domestic violence. In this sense, this proposal is critical at a personal and social level in creating a secure and healthy environment as well as empowering an equal society. In our study, we use k-nearest neighbor (k-nn), support vector machine (SVM), decision tree (DT), and Gaussian Naive Bayes (GNB) machine learning algorithms for the prediction analysis. We provide the comparison of the classifiers with precision, recall, F1 score, and accuracy performance measures. According to our analysis, the decision tree (DT) performs the best performance in terms of accuracy.

Keywords: Violence detection, machine learning, sociodemographic, classification, prediction

Makine Öğrenmesi ile Şiddet Tespiti: Sosyodemografik Bir Yaklaşım

Öz

Bu çalışma, sosyodemografik bir veri seti üzerinde makine öğrenimi yöntemlerinin uygulanmasının aile içi şiddeti önlemede yardımcı olabileceğini önermektedir. Bu yaklaşım, failin neden olabileceği yüksek risk faktörlerini öngörmeye önemlidir ve aile içi şiddeti önlemek için tedavi, maddi veya manevi sağlık yardımları sunar. Bu anlamda bu öneri, güvenli ve sağlıklı bir çevre yaratmanın yanı sıra eşit bir toplumu güçlendirmede kişisel ve toplumsal düzeyde kritik öneme sahiptir. Çalışmamızda tahmin analizi için k-en yakın komşu (k-EYK), destek vektör makinesi (DVM), karar ağacı (KA) ve Gaussian Naive Bayes (GNB) makine öğrenmesi algoritmalarını kullanılmıştır. Kesinlik, F1 skoru ve doğruluk performans ölçütleri ile sınıflandırıcıların karşılaştırmasını sağlıyoruz. Analizlerimize göre, karar ağacı (KA) doğruluk açısından en iyi performansı sergilemektedir.

Anahtar Kelimeler: Şiddet tespiti, makine öğrenmesi, sosyodemografi, sınıflandırma, tahmin

* Corresponding Author: dagtekin@iuc.edu.tr, Dagtekin M., Istanbul University-Cerrahpasa, Computer Engineering, Istanbul, Turkey

1. Introduction

Domestic violence has been one of the most important health issues that raise concerns all over the world. According to data conducted by world health organization (WHO), approximately 1 in 3 women and 1 in 10 men 18 years of age or older experience domestic violence worldwide. In the United States, annually over 1500 deaths happen due to domestic violence [1-3].

There are many studies that aim to decrease violence through machine learning algorithms. Some of them analyze the messages sent by victims on online platforms such as facebook, tweeter in order to identify victims in critical need by using natural language processing and text mining. [4-6,7] Some studies look into videos to detect physical violence by using classification techniques such as traditional violence detection using machine learning, support vector machine (SVM) and deep Learning. Feature extraction and object detection techniques, k-nearest neighbors (k-nn), random forest classifier [8-14]. Another significant artificial intelligence method in violence detection is using machine learning algorithms in identifying stress, panic, and fear in speech through physiological sensory data, speech, and audio analysis [16].

Differently from the above mentioned methods, this study proposes to use social-demographic data set to pre-detect high risk factor in domestic violence. according to some research, domestic violence is triggered by some social and psychological reasons such as poverty, lack of education, cultural norms, post-traumatic stress disorder (PTSD), etc. [17]. The research signifies that by healing and treating offenders, domestic violence can be abolished. Considering the approach underlined by these researches, in this study, it is suggested that using a socio-demographic data set can be also helpful in preventing domestic violence [18-22]. Based on the data set, it can be predicted how high the rate at an intimate partner may cause a violent action. To demonstrate how our proposed method/system makes early predictions, a synthetic data set has been created. By identifying the rate of violence tendency in an intimate partner, this method/system aims to give early feedback to the decision-makers in social workers, law enforcement, and clinics where these individuals can be provided with education, financial aid, and medical care.




Fig. 1. The proposed method/system for domestic violence detection

We also illustrate the proposed system in Fig. 1. This platform can work with this architecture or can be improved adding new stakeholders into the design. Machine learning algorithms work as an automatic detector as an artificial intelligence engine.

2. Material and Method

2.1. Data Set

There is no data set in the literature for this kind detection system. Therefore, we created a new synthetic data set to use in the prediction and early detection analysis. This data set contains a sociodemographic information of the individuals. We use mental health, income, drug use, and education level in the data set. We rate mental health from 0 to 5, income from 0 to 5, drug use from 0 to 2, and education level from 1 to 5. Highest values show the best conditions for the individuals.

mental_health_0_5	income_0_5	drug_0_2	Educ_1_5	class
2	3	1	2	High-risk
4	0	2	3	High-risk
0	3	1	4	Low-risk
1	5	1	2	Low-risk
5	4	0	5	No-risk
5	4	0	5	No-risk

Fig. 2. The sample tuples (lines) from the data set

Sample tuples from the data set can be seen in Fig. 2. We categorize it with high risk, low risk, and no risk labels. There are 240 individuals in this synthetic data set. In real world, governmental facilities, health clinics, law enforcement units, counselors, family centers, educational institutes, and other official centres can collect and process this new data set in their systems. After collection of the real world data sets, they can be proceed with machine learning approaches to have their early warning/detection platform.

2.2. Machine Learning Methods

We use k-nearest neighbours (k-nn), support vector machines (SVM), decision tree (DT), and Gaussian Naive Bayes (GNB) algorithms as a classifier to predict the violence with our data set. We use Python programming language for the experimental analysis.

The k-nearest neighbour (k-nn) method is a non-parametric classification algorithm that groups data with neighbour distance measures. An unknown data point is assigned the majority of the class labels. The k value shows the number of the neighbour for that specific unknown data point. The support vector machine method is a supervised algorithm that uses borders (hyper planes) between the classes. The margins between hyperlanes are optimized to have a better classification result. Also, a kernel function can also be used for the SVM method. The decision tree algorithm is also another non-parametric method that has a tree structure with nodes and leaves. It is one of the supervised learning algorithms. The Gaussian Naive Bayes method is another supervised learning algorithm and it uses a Gaussian distribution for the classification and prediction tasks.

2.3. Results

We use k-NN, SVM, DT, and GNB supervised learning algorithms in our experiments. Our system finds the prediction results of the individuals (candidates) as the high risk, low risk, and no risk groups (labels). After the training and testing process, these algorithms have results for the proposed scenario. We use precision, recall, F1 score and accuracy metrics to measure performance of the classification methods. According to

the experiments, decision tree classifier performs the best result in terms of the accuracy. Also other performance metric values and accuracy values can be seen from Table 1 below. SVM gives the second best, GNB gives the third best, and k-nn gives the

worst accuracy values in our analysis. The algorithms/methods can also be classified in terms of the other metrics in Table 1.

Table 1. Prediction results of machine learning algorithms (classifiers) for the violence detection

Machine learning methods (algorithms)		Precision	Recall	F1 score	Accuracy (%)
k-nearest neighbours (k-nn)	High-risk	0.57	0.67	0.62	75.0
	Low-risk	0.75	0.75	0.75	
	No-risk	0.89	0.80	0.84	
Support vector machines (SVM)	High-risk	0.62	0.83	0.71	79.16
	Low-risk	0.75	0.75	0.75	
	No-risk	1.00	0.80	0.89	
Decision trees (DT)	High-risk	1.00	1.00	1.00	91.66
	Low-risk	0.80	1.00	0.89	
	No-risk	1.00	0.80	0.89	
Gaussian Naive Bayes (GNB)	High-risk	0.71	0.83	0.77	79.10
	Low-risk	0.71	0.62	0.67	
	No-risk	0.90	0.90	0.90	

We also illustrate the accuracy prediction performance in Fig. 2. The result values can be seen from this figure.




Fig. 2. Accuracy performance comparison of the machine learning algorithms

4. Conclusions and Recommendations

This study presented an approach to using machine learning methods on a sociodemographic data set to predict how high a risk factor an offender may pose to their family members or intimate partners. Our goal was to provide some help and healing to the offender in order to prevent domestic violence by collecting a socio demographic data to understand the sociological and psychological reasons that trigger violent actions. Based on the prediction value, the machine learning algorithms give feedbacks to social workers, law enforcement, and clinics. According to the feedback drawn from the data set, social workers, law enforcement, and clinics can provide the offender some help such as training, and financial or mental health aids. In this sense, this proposal is critical at personal and social level in creating a secure and healthy environment as well as empowering an equal society. In our study, we use k-nearest neighbour (k-nn), support vector machine (SVM), decision tree (DT), and Gaussian Naive Bayes machine learning algorithms for the prediction analysis. The performance comparison of the

classifiers has been given with precision, recall, F1 score, and accuracy performance measures. Decision tree (DT) performs the best performance in terms of accuracy.

References

- [1] Boserup, B., McKenney, M., & Elkbulli, A. (2020). Alarming trends in US domestic violence during the COVID-19 pandemic. *The American Journal of Emergency Medicine*, 38(12), 2753-2755.
- [2] Wahi A, Zaleski KL, Lampe J, Bevan P, Koski A. The Lived Experience of Child Marriage in the United States. *Soc Work Public Health*. 2019; 34(3):201-213.
- [3] Harland KK, Peek-Asa C, Saftlas AF. Intimate Partner Violence and Controlling Behaviors Experienced by Emergency Department Patients: Differences by Sexual Orientation and Gender Identification. *J Interpers Violence*. 2021 Jun; 36(11-12): NP6125-NP6143.
- [4] Subramani, S., Wang, H., Vu, H. Q., & Li, G. (2018). Domestic violence crisis identification from facebook posts based on deep learning. *IEEE Access*, 6, 54075-54085.
- [5] Subramani, S., Michalska, S., Wang, H., Du, J., Zhang, Y., & Shakeel, H. (2019). Deep learning for multi-class identification from domestic violence online posts. *IEEE Access*, 7, 46210-46224.
- [6] Le Glaz, A., Haralambous, Y., Kim-Dufor, D. H., Lenca, P., Billot, R., Ryan, T. C., and Lemey, C. (2021). Machine learning and natural language processing in mental health: systematic review. *Journal of Medical Internet Research*, 23(5).
- [7] Xue, J., Chen, J., and Gelles, R. (2017). Using Data Mining Techniques to Examine Domestic Violence Topics on Twitter. *Violence and Gender*, 6 (2), 105-114.
- [8] Siddique, M., Islam, M., Sinthy, R., Mohima, K., Kabir, M., Jibon, A. H., and Biswas, M. (2022). State-of-the-Art Violence Detection Techniques: A review. *Asian Journal of Research in Computer Science*, 29-42.
- [9] Ye, L., Wang, L., Wang, P., Ferdinando, H., Seppänen, T., Alasaarela, E. (2018). Physical Violence Detection with

- Movement Sensors. Machine Learning and Intelligent Communications. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, vol 251. Springer, Cham.
- [10] Vashistha, P., Singh, J.P., Khan, M.A. (2020). A Comparative Analysis of Different Violence Detection Algorithms from Videos. In: Kolhe, M., Tiwari, S., Trivedi, M., Mishra, K. (eds) Advances in Data and Information Sciences. Lecture Notes in Networks and Systems, vol 94.
- [11] Deepak, K., Vignesh, L. K. P., and Chandrakala, S. J. I. E. (2020). Autocorrelation of gradients based violence detection in surveillance videos. *ICT Express*, 6(3), pp 155-159.
- [12] S. Das, A. Sarker and T. Mahmud, "Violence Detection from Videos using HOG Features," *2019 4th International Conference on Electrical Information and Communication Technology*, 2019, pp. 1-5.
- [13] A. Jain and D. K. Vishwakarma, "State-of-the-arts Violence Detection using ConvNets," *2020 International Conference on Communication and Signal Processing*, 2020, pp. 0813-0817.
- [14] Chaudhary, D., Kumar, S., and Dhaka, V. S. (2022). Video based human crowd analysis using machine learning: a survey. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging and Visualization*, 10(2), 113-131.
- [15] Jiang Y, DeBare D, Colomer I, Wesley J, Seaberry J, Viner-Brown S. Characteristics of Victims and Suspects in Domestic Violence-Related Homicide- Rhode Island Violent Death Reporting System, 2004-2015. *R I Med J* (2013). 2018 Dec 03; 101(10):58-61.
- [16] Rituerto-González, E., Mínguez-Sánchez, A., Gallardo-Antolín, A., & Peláez-Moreno, C. (2019). Data augmentation for speaker identification under stress conditions to combat gender-based violence. *Applied Sciences*, 9(11), 2298.
- [17] Evans, S. (2005). Beyond gender: Class, poverty and domestic violence. *Australian Social Work*, 58(1), 36-43.
- [18] Wallach, H. S., and Sela, T. (2008). The importance of male batterers' attributions in understanding and preventing domestic violence. *Journal of Family Violence*, 23(7), 655-660.
- [19] Guerrero, A., Cárdenas, J. G., Romero, V., & Ayma, V. H. (2020). Comparison of Classifiers Models for Prediction of Intimate Partner Violence. In Proceedings of the Future Technologies Conference, pp. 469-488, Springer, Cham.
- [20] Abramsky, T., Watts, C. H., Garcia-Moreno, C., Devries, K., Kiss, L., Ellsberg, M., and Heise, L. (2011). What factors are associated with recent intimate partner violence, Findings from the WHO multi-country study on women's health and domestic violence. *BMC public health*, 11(1), 1-17.
- [21] Vyas, S., and Watts, C. (2009). How does economic empowerment affect women's risk of intimate partner violence in low and middle income countries. A systematic review of published evidence. *Journal of International Development: The Journal of the Development Studies Association*, 21(5), 577-602.
- [22] Leonard, K. E. (2005). Alcohol and intimate partner violence: when can we say that heavy drinking is a contributing cause of violence, *Addiction*, vol 100. no. 4, pp 422-425.