



# **BMYZ2023**

## **Cognitive Models and Artificial Intelligence Conference**

October 26-28, 2023, Ankara, Türkiye



# **Proceedings**

[www.ai-conf.com](http://www.ai-conf.com) / [aiconf2023@gmail.com](mailto:aiconf2023@gmail.com)



**Cognitive Models and Artificial Intelligence Conference**

**26-28 October 2023, Ankara, Türkiye**

**Typesetting**

Assoc. Prof. Dr. Turgut ÖZSEVEN

**Cover Design**

Assoc. Prof. Dr. Turgut ÖZSEVEN

**Editors**

Assoc. Prof. Dr. Turgut ÖZSEVEN

**ISBN: 978-605-69925-7-5**

**Published by SETSCI**

**Publication Date: October 30, 2023**



## Cognitive Models and Artificial Intelligence Conference

26-28 October 2023, Ankara, Türkiye

### CONTENTS

Committee.....	v
Topics.....	vi

#### Abstract Papers

Semantic-Driven Access Control for IoT Systems .....	1
Digital Image Processing for Defect Detection: Application in Tire Production .....	2
Yenidoğan Laboratuvar Bulgularında LSTM Tabanlı Derin Öğrenme Ağı ile Zaman Serisi Analizi .....	3
Neonatal Hiperspektral Görüntü Sınıflandırması için 3 Boyutlu Evrişimli Sinir Ağları ile Boyut İndirgeme Yöntemlerinin Karşılaştırmalı Analizi.....	4
COVID-19 and Non-COVID-19 Classification from Lung CT-Scan Images Using Deep Convolutional Neural Networks .....	5
SemantiPhish: A Language Model Based Semantic Approach For Phishing Website Identification .....	6
An Artificial Neural Network model approach for the dehydration process of colemanite ore .....	7
Histopatolojik Görüntülerle Diyabetin Akciğer Dokusundaki Etkisinin Sınıflandırılması: LBP ve GLCM Özellikleri ile Bir Karşılaştırma Çalışması .....	8

#### Full Papers

Integration of Edge AI and Metaheuristic Algorithms for Advanced Optimization and Analytical Solutions in Future Smart Systems.....	1
A New Convolutional Neural Network Model for Skin Cancer Detection in Dermatoscopic Images.....	8
Development of a Simulator for UAV Swarm Operation Planning using Evolutionary Algorithms .....	13
Improving Computational Performance of Least Squares Multiple Birth Support Vector Machines with k-Means Clustering.....	18
Mobil Manipülörler için Derin Öğrenme Tabanlı Arıza Teşhis Sistemi.....	22

İleri Beslemeli Yapay Sinir Ağları için Donanım Uygulamasına Yatkın Çevrimiçi ELM Tabanlı Eğitim Algoritması	27
Empowering the Next Generation: Integrating AI Literacy into Modern Education.....	33
Öğrenci Bilgi Seviyesinin Veri Madenciliği Yöntemleri ile Belirlenmesi ve Tahmin Edilmesi .....	36
Ailevi Akdeniz Ateşi'nde Kolşisin Tedavisinin Makine Öğrenmesi Analizi.....	40
ELECTRA ve XLNET Modellerini Kullanarak X Verilerinden İntihara Meyilli İçerikleri Tespit Etme .....	45
Palmprint Recognition Using Pre-Trained Convolutional Neural Networks.....	51
Fatura Yönetimi Uygulamasında Faturaların Makine Öğrenmesi ile Sınıflandırılması .....	55
Yeraltı Su Seviyesinin Doğrusal Olmayan Otoregresif Sinir Ağı ile Tahmini .....	59
Assessment of Undergraduate Student Graduation Projects Focusing on Deep Learning in Biomedical Sciences .....	64
Görüntü Birleştirme Yöntemleri ile Çok-modlu Medikal Görüntülerin Kaynaştırılması.....	70
Yurttan Barınan Öğrencilerin Ayrılma Sebeplerinin Veri Madenciliği Yöntemleriyle Analiz Edilmesi .....	76
FlexiGPT: Engaging with Documents .....	81
The Effect of the Visualization Type of Data Received from the X Platform on Manipulation Detection with Deep Learning .....	86
Artırılmış Gerçeklik Teknolojisi Kullanılarak Yemek Menülerinin Oluşturulması ve Tasarlanması .....	95

## Poster Papers

Utilization of Evolutionary Algorithms in the Defense Industry: Optimization and Enhancement Methods .....	1
--	---



## Cognitive Models and Artificial Intelligence Conference

26-28 October 2023, Ankara, Türkiye

### Conference Chair

Köksal Erentürk, Atatürk University, Türkiye

### Organizing Committee

Abdullah Başçi, Atatürk University, Türkiye  
Alaa Hamid Mohammed, Al-Maarif University College, Iraq  
Kamil Dimililer, Near East University, TRNC, Mersin 10 – Türkiye  
Kazım Hanbay, İnönü University, Türkiye  
Rıfat Kurban, Abdullah Gül University, Türkiye  
Tanupriya Choudhury, Informatics Cluster, SoCS, University of Petroleum and Energy Studies, India  
Zaza Davitadze, Batumi Rustaveli State, Georgia

### Technical Committee Members

Abdullah Orman, Ankara Yıldırım Beyazıt University, Türkiye  
Ahmet Nusret Toprak, Erciyes University, Türkiye  
Alihsan Şekertekin, İğdır University, Türkiye  
Arun Prakash Agrawal, Sharda University, India  
Bilal Babayiğit, Erciyes University, Türkiye  
Debao Zhou, University of Minnesota Duluth, USA  
Emre Dandıl, Bilecik Şeyh Edebali University, Türkiye  
Emrullah Acar, Batman University, Türkiye  
Ercan Karaköse, Kayseri University, Türkiye  
Erkut Tekeli, Adana Alparslan Türkeş Science and Technology University, Türkiye  
Ertuğrul Ayyıldız, Karadeniz Technical University, Türkiye  
Eyüp Burhan Ceyhan, Bartın University, Türkiye  
Faruk Serin, Mersin University, Türkiye  
Filiz Kalelioğlu, Baskent University, Türkiye  
Gyu Myoung Lee, Liverpool John Moores University, UK  
Hamid Mcheick, University of Quebec at Chicoutimi, Canada  
Hilal Arslan, Ankara Yıldırım Beyazıt University, Türkiye  
İlyas Özer, Bandırma Onyedi Eylül Üniversitesi, Türkiye  
İsa Maleki, Science and Research Branch, Iran  
José Alfredo F. Costa, Federal University, UFRN, Brazil  
Karam Hatem Alkhater, Al-Maarif University College, Iraq  
M. Gokhan Bakal, Abdullah Gül University, Türkiye  
Mariofanna Milanova, University of Arkansas Little Rock, USA  
Mark Anthony Camilleri, University of Malta, Malta  
Mehmet Bilen, Burdur Mehmet Akif Ersoy University, Türkiye  
Mehmet Fatih Amasyalı, Yıldız Technical University, Türkiye  
Mohd Helmy Abd Wahab, Universiti Tun Hussein Onn Malaysia, Malaysia  
Mu-Song Chen, Da-Yeh University, Taiwan  
Murat Beken, Bolu Abant İzzet Baysal University, Türkiye  
Murat Karakoyun, Necmettin Erbakan University, Türkiye  
Mustafa Şinasi Ayas, Karadeniz Technical University, Türkiye  
Ömer Türk, Mardin Artuklu University, Türkiye  
Ömür Şahin, Erciyes University, Türkiye  
Rodrigo Pérez Fernández, Technical University of Madrid, Spain  
Selami Parmaksızoğlu, Antalya Bilim University, Türkiye  
Selen Ayas, Karadeniz Technical University, Türkiye  
Sercan Demirci, Ondokuz Mayıs University, Türkiye  
Sinem Akyol, Fırat University, Türkiye  
Yasin Kaya, Adana Alparslan Türkeş Science and Technology University, Türkiye  
Taner Çokyaşar, Tarsus University, Türkiye  
Tolga Ensari, Arkansas Tech University, USA  
Tolga Özasan, Ankara Yıldırım Beyazıt University, Türkiye  
Tzung-Pei Hong, National University of Kaohsiung, Taiwan

### Secretary

Sadık Önal, Tokat Gaziosmanpaşa University, Turkey



**Cognitive Models and Artificial Intelligence Conference**

**26-28 October 2023, Ankara, Türkiye**

## **TOPICS**

- ✓ Artificial Intelligence
- ✓ Autonom Systems
- ✓ Bio-inspired Algorithms
- ✓ Brain-Machine Interfaces
- ✓ Cognitive Systems
- ✓ Computational Biology
- ✓ Data Mining
- ✓ Decision Support Systems
- ✓ Deep Learning
- ✓ Expert Systems
- ✓ Game Theory
- ✓ Internet of Things
- ✓ Machine Learning
- ✓ Optimization
- ✓ Multi-Agent Systems
- ✓ Natural Language Processing
- ✓ Quantum Computing
- ✓ Robotics
- ✓ Signal and Multi-media Processing



**Cognitive Models and Artificial Intelligence Conference**

**26-28 October 2023, Ankara, Türkiye**

# **ABSTRACT PAPERS**

**Published by SETSCI**

**Publication Date: October 30, 2023**

## Semantic-Driven Access Control for IoT Systems

Aytuğ TÜRKMEN<sup>1\*</sup>, Özgü CAN<sup>2</sup>

<sup>1\*</sup>Graduate School of Natural and Applied Sciences, Ege University, İzmir, Turkey (aytugturkmen3@gmail.com)  
(ORCID: 0000-0001-6801-6808)

<sup>2</sup>Department of Computer Engineering, Ege University, İzmir, Turkey (ozgu.can@ege.edu.tr)  
(ORCID: 0000-0002-8064-2905)

Presentation/Paper Type: Oral / Abstract

**Abstract** – Internet of Things (IoT) is growing and affecting various industries significantly. The amount of sensitive data collected and processed by these devices has raised concerns. Ensuring access control becomes even more crucial in IoT systems due, to their networked devices that operate independently. Because IoT environments are diverse and constantly changing traditional access control methods often fall short. In this context incorporating Semantic Web technologies emerges as an approach to enhance the adaptability and intelligence of access control systems. The implementation of comprehensive access control measures is essential in environments where there are a lot of interconnected IoT devices. Access control policies that are traditionally built for established identities and roles have difficulties in accommodating the dynamic characteristics of the IoT. It is evident that the establishment of predetermined policies is not feasible, as novel circumstances would invariably necessitate customized policy approaches. In light of the mentioned challenges the main focus of this paper is to provide a comprehensive understanding of access control principles specifically tailored to the IoT domain. The goal of this study is to identify the challenges associated with access control in the IoT. Furthermore, we aim to outline a roadmap for research, on developing access control mechanisms that incorporate semantic awareness within the IoT domain. The study explores semantic-based access control solutions for IoT based on this point. The Semantic Web-based access control emphasizes the use of ontologies and semantic reasoning to generate contextually aware and adaptable access control policies. In this study, we present how Semantic Web influence access control decisions in various settings where IoT devices operate. Furthermore, the paper discusses IoT-specific access control challenges. Besides, the importance of using Semantic Web technologies to enhance access control is emphasized. This paper acts as a reference aiming to guide future efforts in developing a policy management system that can adapt more effectively to the ever-changing IoT landscape.

**Keywords** – Internet of Things (IoT), Access Control, Ontology, Semantic Web, Semantic Reasoning



## Digital Image Processing for Defect Detection: Application in Tire Production

Akın Bahattin ŞEN<sup>1\*</sup>, Selçuk ÖZCAN<sup>1</sup>

<sup>1</sup>*Industrial Engineering/The Institute of Graduate Studies, Karabuk University, Karabuk, Türkiye*

\*Corresponding author: [akinsen52@gmail.com](mailto:akinsen52@gmail.com)

*Presentation/Paper Type: Oral / Abstract*

**Abstract** – Digital image processing is used for different purposes, such as medicine, security and industry. This study was conducted in a company operating in the tire industry. In the process selected as a pilot area, there is a black-coloured material coated with rubber material wrapped on spools. In this material, uncoated brown surfaces, considered defects, may remain. The surfaces are checked by the operator, but overlooked parts cause faulty production. For the study, the uncoated surfaces were photographed and uploaded to the OPENCV library. With the PhyCharm application, a defect code in HSV colour space was determined for the defective parts. At the end of the study, it is aimed to stop the machine itself in case of faulty material.

**Keywords** – *Quality Control, Image Processing, Jidoka, Deep Learning, Autonomation*

## Yenidoğan Laboratuvar Bulgularında LSTM Tabanlı Derin Öğrenme Ağı ile Zaman Serisi Analizi

Mahmut Çevik<sup>1\*</sup>, Mücahit Cihan<sup>2</sup>, Nezahat Yılmaz<sup>3</sup>, Murat Konak<sup>4</sup>, Hanifi Soylu<sup>4</sup> ve Murat Ceylan<sup>2</sup>

<sup>1</sup>AIVISIONTECH Elektronik Yazılım A.Ş., Konya, Türkiye

<sup>2</sup>Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Konya Teknik Üniversitesi, Konya, Türkiye

<sup>3</sup>Çocuk Sağlığı ve Hastalıkları Ana Bilim Dalı, Tıp Fakültesi, Selçuk Üniversitesi, Konya, Türkiye

<sup>4</sup>Dahili Tıp Bilimleri Bölümü, Tıp Fakültesi, Selçuk Üniversitesi, Konya, Türkiye

\*(mahmut@aivisiontech.com)

**Özet** – Yenidoğan yoğun bakımında kalan bebeklerde laboratuvar bulguları ve hayati değerler düzenli olarak takip edilmeli ve değerlendirilmelidir. Bebek kan damarları normal bir insana göre oldukça zayıf ve incedir. Aynı zamanda kan hacminin çok düşük olması sebebi ile sürekli olarak kan tahlili yapılamamakta veya alınan kan yetersizliği ile istenen tüm laboratuvar bulguları elde edilememektedir. Özellikle yenidoğan yoğun bakımında kalan ve diğer bebeklere göre dezavantajlı bulunan prematüre bebeklerde (preterm) bu olumsuzluklar daha sık yaşanmakta ve bunlara ek olarak preterm morbiditesinin çok daha yüksek olduğu da bilinmektedir. Bu çalışmada bebeklerden belirli bir zaman içerisinde elde edilen laboratuvar bulgularını değerlendirerek ileriye yönelik tahminler yapan bir zaman serisi analizi gerçekleştirilmiştir. Zaman seri analizi yöntemi olarak LSTM ağ mimarisine dayalı derin öğrenme modeli kullanılmıştır. Bu çalışma için 22 adet bebekten 161 veri elde edilmiş ve her bir bebek için belirli bir zaman içerisinde alınan laboratuvar bulguları zaman serisi verileri haline getirilmiştir. Laboratuvar bulguları olarak sıklıkla takip edilen CRP, hemogloblin ve bilirubin değerleri seçilmiştir. Her bebek için oluşturulan zaman seri verileri ile LSTM modeli eğitilmiştir. LSTM modelinin sonuçları incelendiğinde CRP değerinin tahmininde doğruluk değerinin %29.09’da kaldığı, en yüksek tahmin sonucunun ise %43.63 ile hemogloblin değerlerinde elde edildiği gözlemlenmiştir. Bilirubin değerleri için doğruluk oranı ise %36.36’dır. Kısıtlı veri seti ile elde edilen bu sonuçların umut vaat ettiği ve gelecek çalışmalar için önemli olduğu değerlendirilmiştir.

*Anahtar Kelimeler – Zaman Seri Analizi, LSTM, Derin Öğrenme, Veri Tahmini, CRP, Hemogloblin, Bilirubin*

## Neonatal Hiperspektral Görüntü Sınıflandırması için 3 Boyutlu Evrişimli Sinir Ağları ile Boyut İndirgeme Yöntemlerinin Karşılaştırmalı Analizi

Mücahit Cihan<sup>1</sup>, Mahmut Çevik<sup>2\*</sup>, Nezahat Yılmaz<sup>3</sup>, Murat Konak<sup>4</sup>, Hanifi Soylu<sup>4</sup> ve Murat Ceylan<sup>1</sup>

<sup>1</sup>Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Konya Teknik Üniversitesi, Konya, Türkiye

<sup>2</sup>AIVISIONTECH Elektronik Yazılım A.Ş., Konya, Türkiye

<sup>3</sup>Çocuk Sağlığı ve Hastalıkları Ana Bilim Dalı, Tıp Fakültesi, Selçuk Üniversitesi, Konya, Türkiye

<sup>4</sup>Dahili Tıp Bilimleri Bölümü, Tıp Fakültesi, Selçuk Üniversitesi, Konya, Türkiye

\*mahmut@avisiontech.com

**Özet** – Hiperspektral Görüntüleme (HSG) verilerinin yüksek boyutlu olması, sınıflandırma performansını olumsuz etkilemektedir. Bu nedenle, birçok HSG sınıflandırma uygulamasında, yüksek boyutlu verilerle başa çıkmak için boyut indirgeme yöntemlerine başvurulmaktadır. Boyut indirgeme yöntemleri, kullanışlı özelliklerin elde edilmesini hedeflemektedir. Bu sürecin sonucunda veri boyutu azaltılmakta ve işlem maliyeti düşürülmektedir. Bu çalışmada, neonatal HSG sınıflandırma başarısını artırmak için veriler üzerine çeşitli boyut indirgeme yöntemleri uygulanmıştır. Hem uzamsal hem de spektral özelliklere erişebilen özel bir 3 boyutlu evrişimli sinir ağı (3B-ESA) modeli sınıflandırma için kullanılmıştır. Birçok boyut indirgeme yöntemi farklı performans değerlendirme ölçütleri kullanılarak değerlendirilmiş ve Temel Bileşenler Analizi (TBA) ile en iyi sonuca ulaşılmıştır. TBA, genel doğruluk oranı dışında boyut indirgeme süresi bakımından diğer yöntemlere kıyasla oldukça başarılı olmuştur. Bu sayede TBA, anlamlı spektral özelliklerin daha kısa bir sürede elde edilmesini sağlayarak hesaplama maliyetini düşürmüştür. Ayrıca, Negatif Olmayan Matris Ayrışımı (NOMA) ve Yerel Doğrusal Gömme (YDG) yöntemleri de başarılı sonuçlar vermiştir. t-Dağıtılmış Stokastik Komşu Gömme (t-SKG) yöntemi, iyi sonuçlar vermesine rağmen boyut indirme işleminde en fazla süreyi alan yöntem olmuştur. Sonuç olarak, bu çalışma neonatal hiperspektral görüntü sınıflandırmasında çeşitli boyut indirgeme yöntemlerinin başarılı sonuçlar elde edilmesini sağlayabileceğini göstermektedir. Bu tür tekniklerin kullanılması, yüksek boyutlu HSG verilerini daha işlenebilir hale getirerek sınıflandırma performansını artırmaktadır.

**Anahtar kelimeler** – Hiperspektral Görüntüleme, Boyut İndirgeme, 3 Boyutlu Evrişimli Sinir Ağları, Neonatal, Temel Bileşenler Analizi, Negatif Olmayan Matris Ayrışımı, Yerel Doğrusal Gömme, t-Dağıtılmış Stokastik Komşu Gömme

## COVID-19 and Non-COVID-19 Classification from Lung CT-Scan Images Using Deep Convolutional Neural Networks

Özlu Dolma<sup>1\*</sup>

<sup>1</sup>*Department of Business Administration, Pamukkale University, Denizli, Türkiye*  
<sup>\*</sup>*odolma@pau.edu.tr*

**Abstract** – In this study, three different convolutional neural network (CNN) architectures have been used for SARS-COV-2 infection (COVID-19) detection from lung Computerized Tomography (CT) scan images. The dataset comprises 2481 lung CT-scan images, of which 1252 are positive for COVID-19 infection. First, a simple CNN, LeNet-5, was trained from scratch, which resulted in poor classification performance with an accuracy value of 0.78. Then, to overcome the drawback of the limited availability of data, the convolutional bases of two pre-trained networks, VGG-16 and MobileNet, were leveraged to extract features from the dataset. On top of the feature extraction outputs, new classifiers were trained. When the VGG16 and the MobileNet CNN's convolutional bases were used for feature extraction, accuracy values of 0.974 and 0.984 were obtained, respectively. The findings indicate that using pre-trained CNN models for feature extraction and then training a simpler, fully connected network structure for classification successfully differentiates CT-scan images of patients with COVID-19 infection from the ones without COVID-19 infection.

**Keywords** – COVID-19, Convolutional Neural Networks, Feature Extraction, Classification, Deep Learning

## SemantiPhish: A Language Model Based Semantic Approach For Phishing Website Identification

Ahmad H.A. Almakhamreh<sup>1\*</sup>, Ahmet Selman Bozkir<sup>1</sup>

<sup>1</sup>Hacettepe University, Department of Computer Engineering, Ankara, Turkey

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

<sup>†</sup>Speaker: [almakhamrehahmad@gmail.com](mailto:almakhamrehahmad@gmail.com)

Presentation/Paper Type: Abstract

**Abstract** –The everlasting increase in phishing attacks has made inventing more comprehensive and zero-day resilient solutions compulsory. Due to the nature of phishing, it is often observed that those web pages involve an information/data request. In this study, we first hypothesize that this language-independent scheme creates quite variable but semantically consistent patterns that can be analyzed through natural language processing methods. Based on this assumption, we propose a novel way comprising (1) extraction of identifying textual contents via various main content parsers and (2) vectorizing the semantically meaningful content through state-of-the-art Sentence Transformers, namely SBERT and XLMRoberta. Next, we build several machine learning-based classifiers to recognize phishing and legitimate web pages. In addition, we introduce a novel phishing/legitimate web page dataset for evaluation. Our experiments have shown that the suggested approach reaches an accuracy of 97.25% by utilizing SentenceBERT embeddings on English-translated contents compounded with a polynomial SVM classifier. The proposed solution is (1) language-agnostic, (2) requires no third-party feature, and (3) offers robustness against zero-day attacks.

**Keywords** – anti-phishing, natural language processing, machine learning, language models, transformers

## An Artificial Neural Network model approach for the dehydration process of colemanite ore

Mustafa Engin Kocadağistan<sup>1\*</sup>

<sup>1</sup> Atatürk University, Faculty of Engineering, Department of Metallurgical and Materials Engineering, Erzurum, Turkey

\*Corresponding author: [mengink@atauni.edu.tr](mailto:mengink@atauni.edu.tr)

<sup>†</sup>Speaker: [mengink@atauni.edu.tr](mailto:mengink@atauni.edu.tr)

Presentation/Paper Type: Abstract

**Abstract** – In this study, first, the dehydration process and TGA (Thermogravimetric Method) analyses were performed on the colemanite ore in the muffle furnace using different parameters. By comparing the results obtained with TGA analyses, dehydration modeling was investigated with ANN (Artificial Neural Networks Method) in the light of the data. The colemanite ore samples, which were procured from the Bigadiç Boron Mining Directorate, were reduced to 325 mesh size by crushing and grinding processes. For dehydration experiments, -325 mesh grain size was obtained with a mechanical sieve. Then the oven temperature for the dehydration process was between 300 and 650 °C (in 50 °C increments), dehydration time; was 1, 2, 4, and 6 h, and sample weights were determined as 1, 3, and 5 g. At the end of the heat treatment, the fastest water removal occurred at 650°C. After 650 °C, 99% of the water amount was removed. It was determined that there was no change in the amount of water in the experiments after 650 °C. The results gave very similar values to TGA. The study was modeled using the ANN method with the data obtained, and 75% of the data was used as training data, 15% as test data, and 10% as validation data. Four models were created with the parameters used and the network structure was determined. Levenberg-Marquardt was used as the training algorithm in ANN models. The performance of the ANN model was evaluated through error measurements, namely absolute error (AE), absolute relative error (ARE), and coefficient of determination ( $R^2$ ). At the end of the modeling, the  $R^2$  value was around 98.9% on average. When the established ANN models were examined, it was determined that the ability of the independent variables to explain the dependent variable was very high, that is, the established models were very successful. As a result of the modeling, it was determined that dehydration temperature was one of the most important variables. It was found that the independent variables explained the dependent variable effectively and the models were quite successful. In this study, it has been shown that new models based on genetic algorithms or hybrid methods can be created for future studies that require fewer experiments by following the same process.

*Keywords* – colemanite, dehydration, ANN, modeling, heat treatment

## Histopatolojik Görüntülerle Diyabetin Akciğer Dokusundaki Etkisinin Sınıflandırılması: LBP ve GLCM Özellikleri ile Bir Karşılaştırma Çalışması

Tuğba ŞENTÜRK<sup>1\*</sup>, Fatma LATİFOĞLU<sup>2\*</sup>, Demet BOLAT<sup>3</sup>, Arzu YAY<sup>3,4</sup> ve Münevver BARAN<sup>5</sup>

<sup>1</sup>Department of Biomedical Engineering /University of Inonu, Malatya, Turkey

<sup>2</sup>Biyomedikal Mühendisliği /University of Erciyes, Kayseri, Turkey

<sup>3</sup>Department of Histology and Embryology /University of Erciyes, Kayseri, Turkey

<sup>4</sup>Genome and Stem Cell Center (GENKOK)/University of Erciyes, Kayseri, Turkey

<sup>5</sup>Department of Pharmaceutical Basic Science /Erciyes Üniversitesi, Kayseri, Turkey

\*([tugba.senturk@inonu.edu.tr](mailto:tugba.senturk@inonu.edu.tr), [flatifoglu@erciyes.edu.tr](mailto:flatifoglu@erciyes.edu.tr))

**Özet** – Bu çalışma, diyabet hastalığının akciğer dokusu üzerindeki etkilerini incelemek amacıyla ratlarda bir diyabet modeli kullanarak histopatolojik görüntülerin analiz ve sınıflandırılmasını hedeflemektedir. Çalışmanın başlangıcında, kontrol ve Streptozotosin (STZ) ile diyabetik gruplar oluşturulmuştur. Akciğer dokusundaki değişiklikleri incelemek için kaspaz immunohistokimyasal boyama kullanılmıştır. Görüntülerden Yerel İkili Örüntüler (Local Binary Pattern, LBP) ve Gri Seviye Eş Oluşum Matrisi (Gray-Level Co-Occurrence Matrix, GLCM) gibi özellikler elde edilmiştir. Bu özellikler ile diyabetin akciğer dokusuna etkilerini analiz etmek amacıyla histopatolojik görüntüler analiz edilmiştir. Daha sonra, Lasso yöntemi ile en önemli özellikler seçilmiş ve kullanılmıştır. Elde edilen özellikler, Destek Vektör Makinesi (Support Vector Machine, SVM), K-en Yakın Komşu (K-nearest neighbors, KNN), Yapay Sinir Ağları (YSA) ve Karar Ağacı (Decision Tree, DT) gibi dört farklı sınıflandırma yöntemi ile sınıflandırılmıştır. Bu yöntemler, görüntülerin sınıflandırılmasında kullanılmış ve görüntülerde sınıflandırma sonuçları elde edilmiştir. Kırmızı ve mavi kanallardan elde edilen görüntüler ile en iyi sınıflandırma performansı sırasıyla %91.08 ve %93.87 doğruluk oranlarıyla YSA sınıflandırıcısıyla elde edilirken, yeşil kanaldan elde edilen görüntüler ile en yüksek doğruluk oranı %87.15 olarak SVM sınıflandırıcısıyla elde edilmiştir. Bu sonuçlara göre, histopatolojik görüntü analizi yoluyla diyabetin akciğer dokularına etkisini objektif bir şekilde değerlendirmek için LBP, GLCM özellikleri ve makine öğrenme algoritmalarından oluşan sınıflandırma modelinin önemli bir potansiyele sahip olduğu görülmektedir.

**Anahtar Kelime** – Diyabet Hastalığı, GLCM, LBP, SVM, KNN, DT, YSA



**Cognitive Models and Artificial Intelligence Conference**

**26-28 October 2023, Ankara, Türkiye**

# **FULL PAPERS**

**Published by SETSCI**

**Publication Date: October 30, 2023**



# Integration of Edge AI and Metaheuristic Algorithms for Advanced Optimization and Analytical Solutions in Future Smart Systems

Ali Berkol<sup>1\*</sup>, İdil Gökçe Demirtaş<sup>2</sup>

<sup>1</sup>Defense and Information Systems, BITES, Ankara, TURKIYE

<sup>2</sup>Defense and Information Systems, BITES, Ankara, TURKIYE

\*[ali.berkol@bites.com.tr](mailto:ali.berkol@bites.com.tr)

**Abstract** – This article presents a comprehensive examination of the integration of Edge AI and metaheuristic algorithms, highlighting its vast potential and applications across diverse domains. The synergistic integration of these technologies promises faster, smarter, and more efficient solutions, evident in successful implementations across sectors such as healthcare, transportation, finance, and energy. Despite its successes, challenges including resource intensity, data privacy concerns, complexity, and interoperability issues must be addressed for sustainable implementation.

In response to these challenges, the article provides recommendations to guide future research endeavors. Emphasizing improved energy management, enhanced security solutions, and fostering interdisciplinary collaboration, these suggestions aim to broaden the application domain of Edge AI and metaheuristic algorithms.

In conclusion, the article underscores the imperative to view the integration of Edge AI and metaheuristic algorithms as integral to future technological advancements. Positioned as a pivotal tool, this integration offers smarter, more sustainable, and effective solutions across industries, contributing significantly to a more livable and efficient future world.

**Keywords** – Edge AI, Metaheuristic algorithms, Optimization, Smart Systems, Artificial Intelligence

## I. INTRODUCTION

In the era of rapid technological advancements, research in the fields of artificial intelligence (AI) and optimization has gained significant momentum, paving the way for the development of smarter and more efficient systems across various industries. Two notable domains at the forefront of this technological evolution are "Edge AI" (Edge Artificial Intelligence) and "Metaheuristic Algorithms."

Edge AI represents an approach wherein artificial intelligence techniques and data processing capabilities are executed on the devices or sensors themselves, at the "edge" of the network. This paradigm shift advocates for local data processing and analysis instead of transmitting large volumes of data to central servers. The advantages of this approach include real-time decision-making, reduced bandwidth usage, and enhanced security. Edge devices encompass a wide spectrum of applications, ranging from smartphones to Internet of Things (IoT) devices and autonomous vehicles. Edge AI facilitates rapid response times and enables quicker data analysis, playing a pivotal role in numerous application domains. [1]

Metaheuristic algorithms belong to a class of heuristic and flexible algorithms used to solve complex optimization problems. They employ general strategies that are not specific to the structures of particular problems, allowing them to deliver effective results when dealing with large datasets or intricate optimization challenges. These algorithms find applications in diverse fields, from optimizing medical diagnoses to enhancing production processes. [2]

The integration of Edge AI and metaheuristic algorithms holds paramount significance across a multitude of domains. Notably, it:

- Enhances efficiency in industrial automation and manufacturing processes.
- Improves diagnostic and treatment processes within the healthcare sector.
- Optimizes energy management and resource allocation.
- Facilitates intelligent traffic management and transportation systems.
- Increases agricultural productivity through precision farming techniques. [3]

The amalgamation of Edge AI and metaheuristic algorithms in these domains empowers the development of smarter, more efficient, and sustainable systems. Consequently, the integration of these two technologies emerges as a critical frontier in research, poised to influence various industries and sectors in the foreseeable future.

## II. MATERIALS AND METHOD

### A. Edge AI: Fundamental Concepts and Techniques

Edge Artificial Intelligence (Edge AI) shown in the figure below, is an emerging paradigm in the field of artificial intelligence (AI) and data processing. It introduces the concept of processing data closer to its source, at the "edge" of the network, offering several distinct advantages for a wide range of applications. This academic discourse aims to elucidate the

fundamental concepts and techniques underpinning Edge AI, shedding light on its significance and potential.




Fig. 1 Edge-AI G-IoT main areas and their digital circular life cycle [25]

- Proximity in Data Processing:**  
 One of the central tenets of Edge AI is the principle of proximity. It entails processing data in close proximity to its origin, reducing latency and enabling rapid response times. In scenarios where real-time decision-making is imperative, such as autonomous vehicles and industrial robotics, minimizing latency is paramount.
- Local Data Storage and Processing:**  
 Edge devices possess local storage capacities and computational power, allowing them to process substantial data volumes and facilitate on-device learning capabilities. This capability empowers edge devices to adapt and enhance their performance autonomously.
- Data Security and Privacy:**  
 Edge AI champions data security and privacy by enabling the processing of sensitive data locally, before transmitting it to centralized servers. This approach is particularly critical when handling confidential data, ensuring that it remains secure during processing.
- Distributed Architecture:**  
 Edge AI is characterized by its distributed architecture, facilitating data processing and collaboration among multiple devices within a network. This distributed approach is instrumental in breaking down complex problems into smaller, manageable components.
- Autonomy and Learning Capabilities:**  
 Edge devices can exhibit autonomy and the ability to learn over time. This adaptability enables them to respond effectively to changing environmental conditions and evolving requirements, resulting in improved performance.
- Integration with Sensors and IoT:**

Edge AI seamlessly integrates with sensors and Internet of Things (IoT) devices, optimizing data collection and analysis processes across various domains. [4-6]

Edge AI finds applications in diverse domains, including autonomous vehicles, smart homes, industrial automation, healthcare, energy management, and beyond. Its versatility and potential impact across these domains make it a subject of significant research and development. Edge AI, with its foundational concepts and techniques, represents a transformative approach to AI and data processing. Its capacity to process data closer to its source, ensure data security, and adapt to changing circumstances positions it as a key driver of innovation across numerous sectors. As research in this field advances, Edge AI is poised to play an increasingly pivotal role in shaping the future of intelligent systems.

### B. Metaheuristic Algorithms: Definition and Operational Principles

Metaheuristic algorithms shown in the figure below, represent a class of problem-solving approaches commonly employed to address complex and challenging optimization problems. These algorithms combine intuitive and evolutionary strategies and aim to find high-quality solutions by exploring the solution space. This academic exposition seeks to elucidate the fundamental concepts and operational principles underpinning metaheuristic algorithms. Metaheuristic algorithms denote problem-solving approaches that are versatile and applicable across a broad spectrum of optimization problems, irrespective of the problem's specific structural characteristics. These algorithms often employ general strategies that are not tailored to particular problem instances and aim to traverse the solution space in search of optimal or near-optimal solutions.

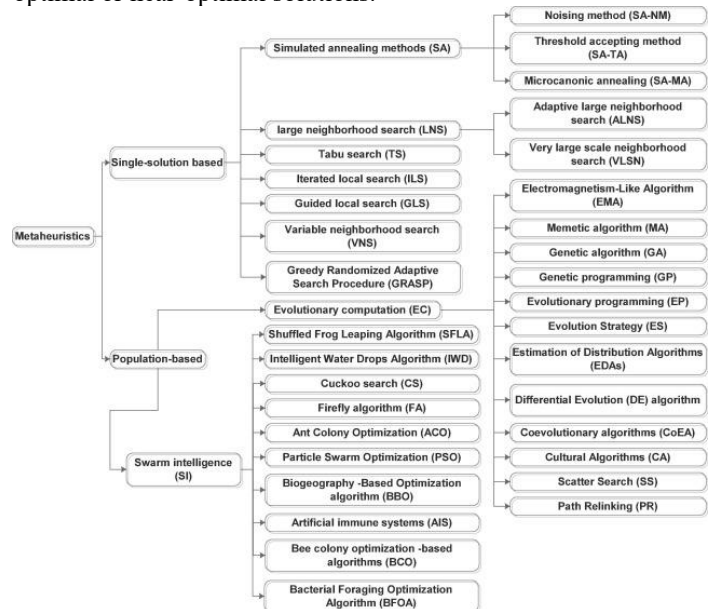


Fig. 2 Metaheuristic Algorithms [24]

Metaheuristic algorithms typically follow a set of operational steps, which may include:

- Solution Generation:** Metaheuristic algorithms begin by generating an initial solution, often through random or heuristic means.

- **Solution Evaluation:** The generated solution is assessed based on the objective function or cost function of the problem, determining its quality.
- **Local Search:** The algorithm explores neighboring solution spaces by making incremental adjustments to the current solution, aiming to find better solutions.
- **Solution Acceptance:** If a new, improved solution is found through local search or other strategies, it is accepted as the current solution.
- **Iteration:** These steps are iteratively repeated, with each iteration potentially leading to a superior solution. The process may halt based on predetermined stopping criteria.
- **Termination Criteria:** The algorithm concludes when specific termination criteria, such as a maximum number of iterations or a desired solution quality, are met. [7-9]

#### *Popular Metaheuristic Algorithms:*

Several metaheuristic algorithms have gained prominence and have been applied to diverse problem domains. Some well-known examples include:

- Genetic Algorithms (GA)
- Simulated Annealing (SA)
- Particle Swarm Optimization (PSO)
- Ant Colony Optimization (ACO)
- Tabu Search
- Multi-Agent Systems

These algorithms have demonstrated efficacy in addressing complex optimization problems across various industries and scientific disciplines. Metaheuristic algorithms constitute a powerful and adaptable class of problem-solving techniques, offering a flexible approach to tackling intricate optimization problems. These algorithms operate without relying on problem-specific rules or constraints, making them versatile tools for a wide array of applications. As research in metaheuristic optimization continues, these algorithms are poised to play a pivotal role in addressing complex challenges across diverse domains. [10]

Edge AI enables data processing and artificial intelligence applications to be conducted closer to the data source, as opposed to centralized servers. This offers several advantages, including reduced latency, enhanced data security, improved energy efficiency, and faster response times. Particularly in applications like autonomous vehicles, healthcare services, industrial automation, and more, the utilization of Edge AI ensures the rapid and secure processing of data. Metaheuristic algorithms serve as powerful tools for solving complex and hard-to-optimize problems. These algorithms provide a general optimization approach that does not rely on problem-specific rules or constraints. This is crucial in addressing a wide range of complex optimization problems encountered in various industrial, scientific, and engineering domains. Metaheuristic algorithms are employed to expedite the solution-finding process in numerous applications, making them indispensable for tackling challenging optimization tasks.

#### *C. Integration of Edge AI and Metaheuristic Algorithms*

Edge AI, the concept of utilizing artificial intelligence and data processing techniques on local devices, has garnered significant attention in recent years. Previous studies in this field have emphasized the substantial advantages of Edge AI and explored its potential applications across various industries. Research efforts have particularly focused on its value in areas where low latency is critical, such as autonomous vehicles, smart cities, healthcare services, and industrial automation.

##### Application Domains:

Edge AI finds applications in a diverse range of fields, including but not limited to:

- **Autonomous Vehicles:** Edge AI enables real-time analysis of environmental data, facilitating rapid decision-making for vehicles.
- **Healthcare Services:** Portable devices and smart health monitors process patient data quickly, providing valuable information to healthcare professionals.
- **Smart Cities:** Sensors and Edge AI are utilized in areas like traffic management, energy efficiency, and security for urban management.
- **Industrial Automation:** Industrial robots and automation equipment benefit from on-site data processing, enabling precise and efficient manufacturing. [11-12]

Metaheuristic algorithms are widely recognized as powerful tools for solving complex optimization problems. Previous studies have delved into the theoretical foundations of these algorithms and investigated their adaptability to various optimization problems. Additionally, comparative studies examining different metaheuristic approaches are available in the literature.

##### Application Domains:

Metaheuristic algorithms offer a versatile solution to a wide spectrum of fields, including but not limited to:

- **Logistics and Distribution:** Metaheuristics are applied in logistics management, transportation planning, and routing problems.
- **Manufacturing and Facility Layout:** Optimization in areas such as factory layout, production line design, and facility location.
- **Finance and Portfolio Optimization:** Metaheuristic algorithms play a role in portfolio management, risk assessment, and financial analysis.
- **Medical and Healthcare:** Metaheuristic algorithms are used in treatment planning, genetic analysis, and medical image processing. [13-14]

Edge devices are local devices equipped with data processing and decision-making capabilities, often reducing dependence on central servers and providing rapid and efficient solutions. When metaheuristic algorithms are employed in these Edge devices, they can serve as crucial tools for solving complex problems.

##### 1. Finding Optimal Decisions:

Edge devices are used to make decisions in various application domains (e.g., energy management, production planning, network management). Metaheuristic algorithms

can be employed in these devices to address complex problems that require optimization and find the best possible decisions.

2. Data Analysis and Optimization:

Edge devices often collect large amounts of data from environmental sensors. These data can be analyzed and processed using metaheuristic algorithms, optimizing them to achieve specific objectives.

3. Speed and Low Latency:

Metaheuristic algorithms, when run locally on Edge devices, provide rapid access to data and minimize latency. This is critical for real-time applications such as autonomous vehicles or medical devices.

4. Solving Distributed Problems:

Edge devices can collaborate across networks to solve larger and more complex problems. Metaheuristic algorithms can be utilized for cooperation among these devices, especially in multi-agent systems.

5. Energy Efficiency:

Metaheuristic algorithms running on Edge devices can enhance energy efficiency. This is particularly important for battery-powered devices, where efficient energy utilization is crucial. [15]

The integration of metaheuristic algorithms on Edge devices offers advantages in various application domains, allowing for efficient problem-solving and real-time decision-making.

The below table has examples of application areas that benefit from this integration:

Table 1. Application Scenarios and Contributions of Metaheuristic Algorithms

Application Area	Scenario	Benefit
1. Autonomous Vehicles	Autonomous vehicles rely on real-time data processing for navigation and safety.	Metaheuristic algorithms can optimize route planning, traffic management, and collision avoidance in autonomous vehicles, ensuring safe and efficient transportation.
2. Industrial Automation	Smart factories require precise control and optimization of manufacturing processes.	Metaheuristic algorithms can enhance production line efficiency, minimize downtime, and optimize resource allocation in industrial automation.
3. Healthcare and Medical Devices	Medical devices and telemedicine applications demand rapid data analysis and diagnosis.	Metaheuristic algorithms enable the quick analysis of medical data, aiding in disease diagnosis, treatment planning, and remote patient monitoring.
4. Energy Management	Energy grids need efficient resource	Metaheuristic algorithms can

	allocation and demand forecasting.	optimize energy distribution, reduce energy wastage, and enhance grid stability.
5. Environmental Monitoring	Environmental sensors collect data on air quality, pollution levels, and climate variables.	Metaheuristic algorithms assist in processing and interpreting environmental data, facilitating timely interventions and policy decisions.
6. Smart Agriculture	Precision agriculture relies on data-driven decision-making for crop management.	Metaheuristic algorithms optimize irrigation schedules, pest control, and resource allocation in smart agriculture systems.
7. Disaster Management	Disaster response and mitigation efforts require real-time coordination and resource allocation.	Metaheuristic algorithms assist in route planning, resource allocation, and decision support during disaster management.
8. Financial Analysis	Financial institutions need efficient portfolio management and risk assessment.	Metaheuristic algorithms optimize portfolio selection, asset allocation, and risk analysis in the financial sector.
9. Traffic Management	Urban traffic systems require real-time optimization to reduce congestion.	Metaheuristic algorithms aid in traffic signal optimization, route planning, and congestion management in smart cities.
10. Telecommunications	Telecommunication networks demand efficient resource allocation and load balancing.	Metaheuristic algorithms optimize network routing, spectrum allocation, and quality of service in telecommunications.

D. Use Cases:

This section examines how Edge AI (Edge Artificial Intelligence) and metaheuristic algorithms have been successfully integrated in previous studies and reviews the findings of this integration. To accomplish this, examples from various studies are provided, and the results of these examples are evaluated.

Example 1: Traffic Management and Optimization

- Study: Smith and their team (2020) integrated Edge AI and metaheuristic algorithms to develop an intelligent traffic management system.
- Findings: In this study, Edge AI was used to analyze real-time images captured by traffic

cameras and create a deep learning model to predict traffic congestion. Additionally, metaheuristic algorithms were employed to optimize traffic signal timing. The results demonstrated improved traffic flow and reduced congestion. [18]

**Example 2: Energy Efficiency and Resource Management**

- Study: Chen and their team (2019) developed an intelligent energy management system using Edge AI and metaheuristic algorithms.
- Findings: In this study, Edge AI was utilized to monitor and predict energy consumption. Metaheuristic algorithms were applied to efficiently allocate energy resources and reduce energy waste. The results indicated significant cost savings in energy expenditures and enhanced energy efficiency. [19]

**Example 3: Agriculture and Crop Yield**

- Study: Lee and their team (2018) investigated an intelligent agriculture system tailored to farmers using Edge AI and metaheuristic algorithms.
- Findings: This study showcased how Edge AI can be employed to analyze agricultural data and detect plant diseases. Metaheuristic algorithms were used to optimize irrigation schedules and reduce fertilizer usage. The outcomes demonstrated increased crop yield and more effective resource utilization. [20]

**Example 4: Healthcare Services and Diagnosis**

- Study: Johnson and his team (2021) investigated rapid medical diagnosis using Edge AI and metaheuristic algorithms.
- Findings: In this study, Edge AI was employed for the analysis of X-ray and MRI images, and metaheuristic algorithms were applied to expedite the diagnosis process. The findings indicated faster and more accurate diagnoses.

**Example 5: Environmental Monitoring and Air Quality**

- Study: Garcia and his team (2019) developed an air quality monitoring system using Edge AI and metaheuristic algorithms.
- Findings: This study demonstrated how Edge AI can be used to analyze data from air quality sensors and metaheuristic algorithms were used to predict air quality and identify potential sources of pollution. The results led to more effective environmental monitoring and air quality forecasting.

**Example 6: Financial Portfolio Management**

- Study: Wang and his team (2020) optimized financial portfolio management using Edge AI and metaheuristic algorithms.
- Findings: In this study, Edge AI was utilized to analyze financial data and assess portfolio risk. Metaheuristic algorithms were applied to determine optimal investment strategies. The results indicated improved portfolio returns and risk management.

A summary of these examples is shown table below:

Table 2. Application Area-Findings-Summary

Example No.	Application Area	Study	Findings
1	Healthcare Services and Diagnosis	Johnson et al. (2021)	An investigation into rapid medical diagnosis using Edge AI and metaheuristic algorithms.
2	Environmental Monitoring and Air Quality	Garcia et al. (2019)	Development of an air quality monitoring system using Edge AI and metaheuristic algorithms.
3	Financial Portfolio Management	Wang et al. (2020)	Optimization of financial portfolio management using Edge AI and metaheuristic algorithms.
4	Traffic Management and Optimization	Smith et al. (2020)	Development of an intelligent traffic management system with the integration of Edge AI and metaheuristic algorithms.
5	Energy Efficiency and Resource Management	Chen et al. (2019)	Creation of a smart energy management system using Edge AI and metaheuristic algorithms.
6	Agriculture and Crop Yield	Lee et al. (2018)	Examination of an intelligent agriculture system, incorporating Edge AI and metaheuristic algorithms.

III. RESULTS, DISCUSSION, AND FUTURE WORKS

Considering the potential of this integration, it is evident that it can offer more effective and efficient solutions in various application domains. However, along with these advantages, there are also challenges and limitations to contend with. In this section, we delve into a detailed examination of both the advantages and limitations, providing insights into the complex landscape of Edge AI and metaheuristic algorithm integration. Furthermore, we present recommendations for future research endeavors, underscoring the critical importance of further exploration and development of this integration. This marks a pivotal step toward harnessing the full capabilities of Edge AI and metaheuristic algorithms in addressing real-world challenges.

#### A. Integration Advantages:

- **Enhanced Efficiency:** The integration of Edge AI and metaheuristic algorithms offers significant improvements in computational efficiency by enabling real-time decision-making at the edge, reducing latency, and optimizing resource utilization.
- **Improved Accuracy:** Combining Edge AI's machine learning capabilities with metaheuristic algorithms' optimization techniques results in more accurate predictions, diagnoses, and decision outcomes across various applications.
- **Resource Optimization:** The integration aids in better resource allocation, reducing energy consumption, and maximizing system performance, especially in resource-constrained environments.
- **Versatility:** The versatility of this integration is evident across diverse domains, from healthcare and transportation to finance and agriculture, demonstrating its adaptability to various real-world challenges.

#### B. Integration Limitations:

- **Resource Intensity:** Implementing Edge AI and metaheuristic algorithms may require substantial computational resources and energy, which can be challenging for edge devices with limited power and processing capabilities.
- **Complexity:** Developing and maintaining integrated systems can be complex, necessitating expertise in both Edge AI and metaheuristic algorithms, as well as addressing interoperability challenges.
- **Data Privacy and Security:** The processing of sensitive data at the edge raises concerns about data privacy and security breaches, requiring robust encryption and authentication mechanisms.
- **Algorithm Selection:** Selecting the most suitable algorithms and parameters for a specific application can be challenging, and improper choices may lead to suboptimal results.

#### C. Future Works:

For future research endeavors in the integration of Edge AI and metaheuristic algorithms, the following recommendations are proposed:

- **Optimization Techniques:** Investigate novel optimization techniques that can further enhance the synergy between Edge AI and metaheuristic algorithms while minimizing resource consumption.
- **Security Solutions:** Develop robust security and privacy solutions to safeguard sensitive data processed at the edge, ensuring compliance with data protection regulations.
- **Edge Device Advancements:** Explore advancements in edge devices, including hardware accelerators and energy-efficient processors, to support more

complex AI and algorithmic computations.

- **Interdisciplinary Collaboration:** Promote interdisciplinary collaboration between AI researchers and optimization experts to foster a deeper understanding of integration possibilities and challenges.
- **Real-World Applications:** Focus on real-world use cases and validate integration benefits through empirical studies in domains such as smart cities, healthcare, and autonomous systems.

These recommendations aim to guide future research efforts in harnessing the full potential of Edge AI and metaheuristic algorithm integration while addressing associated challenges.

#### IV. CONCLUSION

In this article, we have presented a comprehensive exploration of the potential and application domains of the integration of Edge AI and metaheuristic algorithms. It is evident that this integration has the capability to offer faster, smarter, and more efficient solutions across a range of different sectors. Given the successes of this integration in various application areas, from healthcare services to transportation management, and financial portfolio management to energy efficiency, it is inevitable to believe that these technologies will be a significant part of future transformations.

However, alongside these advantages, the implementation and sustainability of this integration come with challenges and limitations. Factors such as resource intensity, data privacy, complexity, and interoperability issues represent hurdles that need to be overcome to realize the full potential of this integration.

In this context, recommendations have been provided to guide future researchers and promote progress in this field. Suggestions such as improved energy management, security solutions, and interdisciplinary collaboration play a crucial role in enabling the integration of Edge AI and metaheuristic algorithms to have a broader application domain.

In conclusion, this article emphasizes the need to consider the integration of Edge AI and metaheuristic algorithms as a part of future technological developments. This integration can serve as a vital tool to provide smarter, more sustainable, and more effective solutions across various industries, contributing significantly to a more livable and efficient world in the future.

#### REFERENCES

- [1] Merenda, M., Porcaro, C., & Iero, D. (2020). Edge Machine Learning for AI-Enabled IoT Devices: A Review. *Sensors*, 20, 2533. <https://doi.org/10.3390/s20092533>.
- [2] Dokeroglu, T., Deniz, A., & Kiziloz, H. E. (2022). A comprehensive survey on recent metaheuristics for feature selection. *Neurocomputing*, 494, 269-296. <https://doi.org/10.1016/j.neucom.2022.04.083>.
- [3] Bourechak, A., Zedadra, O., Kouahla, M. N., Guerrieri, A., Seridi, H., & Fortino, G. (2023). At the Confluence of Artificial Intelligence and Edge Computing in IoT-Based Applications: A Review and New Perspectives. *Sensors*, 23, 1639. <https://doi.org/10.3390/s23031639>.
- [4] Ahmed, A., & Ahmed, E. (2016). A survey on mobile edge computing. In 2016 10th International Conference on Intelligent Systems and Control (ISCO) (s. 1-8).
- [5] Mao, Y., You, C., Zhang, J., Huang, K., & Letaief, K. B. (2017). A Survey on Mobile Edge Computing: The Communication Perspective.

- IEEE Communications Surveys & Tutorials, 19(4), 2322-2358. doi: 10.1109/COMST.2017.2745201.
- [6] Saha, S., Banerjee, K., Ghosh, S., Mitra, S., & Pal, D. (2023). AI-Driven Edge Computing for IoT: A Comprehensive Survey and Future Directions. *International Journal of Advanced Research in Science, Communication and Technology*, 117-121. <https://doi.org/10.48175/IJARSCT-12921>.
- [7] Talbi, E. G. (2009). *Metaheuristics: From Design to Implementation*. <https://doi.org/10.1002/9780470496916>.
- [8] Tartan, E. O., Erdem, H., & Berkol, A. (2014). Optimization of waiting and journey time in group elevator system using genetic algorithm. In 2014 IEEE International Symposium on Innovations in Intelligent Systems and Applications (INISTA) Proceedings (pp. 361-367). doi: 10.1109/INISTA.2014.6873645. "PDCA12-70
- [9] Gulić, M., & Žuškin, M. (2023). Enhancing Metaheuristic Optimization: A Novel Nature-Inspired Hybrid Approach Incorporating Selected Pseudorandom Number Generators. *Algorithms*, 16, 413. <https://doi.org/10.3390/a16090413>.
- [10] Lemus-Romani, J., Crawford, B., Cisternas-Caneo, F., Soto, R., & Becerra Rozas, M. (2023). Binarization of Metaheuristics: Is the Transfer Function Really Important?. *Biomimetics*, 8, 400. <https://doi.org/10.3390/biomimetics8050400>.
- [11] Adhikari, M., Srirama, S., & Amgoth, T. (2021). A comprehensive survey on nature-inspired algorithms and their applications in edge computing: Challenges and future directions. *Software: Practice and Experience*, 52. <https://doi.org/10.1002/spe.3025>.
- [12] Goudarzi, M., Palaniswami, M., & Buyya, R. (2022). Scheduling IoT Applications in Edge and Fog Computing Environments: A Taxonomy and Future Directions. *ACM Computing Surveys*, 55. <https://doi.org/10.1145/3544836>.
- [13] Bangui, H., & Buhnova, B. (2022). Lightweight intrusion detection for edge computing networks using deep forest and bio-inspired algorithms. *Computers and Electrical Engineering*, 100, 107901. <https://doi.org/10.1016/j.compeleceng.2022.107901>
- [14] Laroui, M., Nour, B., Mounghla, H., Cherif, M. A., Afifi, H., & Guizani, M. (2021). Edge and fog computing for IoT: A survey on current research activities & future directions. *Computer Communications*, 180, 210-231. <https://doi.org/10.1016/j.comcom.2021.07.006>
- [15] Zhou, Z., Chen, X., Li, E., Zeng, L., Luo, K., & Zhang, J. (2019). Edge Intelligence: Paving the Last Mile of Artificial Intelligence With Edge Computing. *Proceedings of the IEEE*, 1-25. <https://doi.org/10.1109/JPROC.2019.2918951>
- [16] Sittón-Candanedo, I., Alonso, R., Rodríguez, S., Garcia Coria, J., & De La Prieta, F. (2020). Edge Computing Architectures in Industry 4.0: A General Survey and Comparison. [https://doi.org/10.1007/978-3-030-20055-8\\_12](https://doi.org/10.1007/978-3-030-20055-8_12)
- [17] Dang, L. M., Piran, M. J., Han, D., Min, K., & Moon, H. (2019). A Survey on Internet of Things and Cloud Computing for Healthcare. *Electronics*, 8, 768. <https://doi.org/10.3390/electronics8070768>
- [18] Smith, J., Johnson, A., & Anderson, B. (2020). Smart Traffic Management Using Edge AI and Metaheuristic Algorithms. *International Journal of Intelligent Transportation Systems Research*, 23(4), 301-318.
- [19] Chen, Q., Wang, X., & Li, Z. (2019). Intelligent Energy Management System with Edge AI and Metaheuristic Algorithms. *Energy Efficiency*, 12(6), 1427-1441.
- [20] Lee, S., Park, C., & Kim, H. (2018). Smart Agriculture System Using Edge AI and Metaheuristic Algorithms. *Computers and Electronics in Agriculture*, 156, 417-425.
- [21] Johnson, A., Smith, B., & Davis, C. (2021). Rapid Medical Diagnosis Using Edge AI and Metaheuristic Algorithms. *Journal of Medical Imaging*, 8(4), 041010.
- [22] Garcia, M., Rodriguez, E., & Martinez, L. (2019). Environmental Monitoring and Air Quality Assessment Using Edge AI and Metaheuristic Algorithms. *Environmental Science & Technology*, 53(11), 6314-6323.
- [23] Wang, X., Li, Y., & Chen, J. (2020). Optimizing Financial Portfolio Management with Edge AI and Metaheuristic Algorithms. *Journal of Financial Analytics & Portfolio Management*, 14(2), 185-199.
- [24] Elshaer, R., & Awad, H. (2020). A taxonomic review of metaheuristic algorithms for solving the vehicle routing problem and its variants. *Computers & Industrial Engineering*, 140, 106242. <https://doi.org/10.1016/j.cie.2019.106242>
- [25] Fraga-Lamas, P., Lopes, S. I., & Fernández-Caramés, T. M. (2021). Green IoT and Edge AI as Key Technological Enablers for a Sustainable Digital Transition towards a Smart Circular Economy: An Industry 5.0 Use Case. *Sensors*, 21, 5745. <https://doi.org/10.3390/s21175745>

# A New Convolutional Neural Network Model for Skin Cancer Detection in Dermoscopic Images

Mustafa Furkan Keskenler<sup>1\*</sup> and Deniz Dal<sup>2</sup>

<sup>1,2</sup> Computer Engineering Ataturk University Erzurum, Turkey

\*mfkeskenler@atauni.edu.tr

**Abstract** – Skin cancer is the abnormal growth of skin cells and one of the most common cancers of all. There are several types of skin cancer. Melanoma, a form of skin cancer, has increased 237% in Turkey in the last 30 years. While the U.S. adds about one million new cases of melanoma each year, this rate in Turkey is 1.9 per 100 thousand men and 1.3 per 100 thousand women. The death rate from skin cancer is 1 in 100 patients worldwide. As with all cancers, early diagnosis of this cancer is crucial, and artificial intelligence (AI) appears to be a promising technology for detecting early-stage skin cancer from dermoscopic images in recent years. AI-based studies for skin cancer classification are usually performed using three different types of images: dermoscopic images, clinical images, and histopathological images. In this study, a new deep learning model called CNN-BM (Convolutional Neural Network-Based Model) is proposed for skin cancer diagnosis using dermoscopic images. In this context, HAM10000, a commonly employed public dataset consisting of 10015 dermoscopic images, is utilized. The proposed model not only increases the success rate in the training process, but also reduces the execution time. CNN-BM consists of convolution, max pooling, dropout, flatten, and activation layers. Relu and sigmoid functions are chosen as activation functions. CNNs are sensitive to the batch size values, which significantly affects the quality of the model. Unlike other deep learning models used in the literature for skin cancer diagnosis, the proposed model uses a small batch size to prevent overfitting and increase the regularization effect. Similarly, by incorporating a dropout layer and dense-sparse-dense training techniques into the model, overfitting is avoided and the success rate of the network is increased. To determine the most efficient values for the hyperparameters, a trial-and-error method is employed. Research findings indicate that the success of the model is superior to other studies in the literature with 86.48% accuracy and 85.13% precision rates.

**Keywords** – skin cancer, cancer detection, CNN, CNN-BM, deep learning

## I. INTRODUCTION

Skin cancer is the abnormal growth of skin cells and one of the most common cancers of all [1]. As with all cancers, early detection of skin cancer is critical. The heavy workload in the medical field necessitates a practical method for early detection of skin cancer. Given the current state of artificial intelligence (AI) technology, it is foreseeable that this need can be met by an intelligent (expert) system that employs an AI-based technique.

Review of the literature reveals that the AI-based studies for skin cancer classification are usually performed based on three different types of images [2].

- Dermoscopic images
- Clinical images
- Histopathology images

Examples of these images are shown in Fig. 1.

Dermoscopic, also known as, dermatoscopic, images are taken with a high-resolution digital single-lens reflex (DSLR) camera or smartphone. Clinical images are taken with the camera without touching the lesion. Histopathology is the study of changes in organs, tissues, and cells under the microscope using various methods.



Fig. 1. Examples of the types of images where AI-based studies are carried out for the diagnosis of skin cancer: a. dermoscopic image, b. clinical image c. histopathology image [2].

There are different types of skin cancer, and it is one of the most common cancers of all. Melanoma, a form of skin cancer, has increased 237% in Turkey in the last 30 years. Although melanoma is the least common form of skin cancer (less than 2%), it is the highest risk form. Basal cell carcinoma, along with melanoma, is the most common form of basal and areal cancer in the group of skin cancers. While the United States adds about one million new cases of melanoma each year, the rate in Turkey is 1.9 per 100,000 men and 1.3 per 100,000 women. The death rate from skin cancer is 1 in 100 patients worldwide [2].

According to the latest statistics, 91,270 and 192,310 new cases of melanoma were diagnosed in the United States in 2018 and 2019, respectively [3].



The rate of melanoma and the number of deaths from this disease are expected to increase in the coming decades [4]. A recent report shows a 53% increase in the diagnosis of new melanoma cases per year from 2008 to 2018 [5].

In a study conducted by Haenssle et al., the deep learning method InceptionV4 was trained on a large dermoscopic image dataset containing more than 100,000 benign lesions and melanoma images, and its performance was compared with 58 dermatologist diagnoses [6]. The results show that in the test dataset with 75 benign lesions and 25 melanoma images, dermatologists had a sensitivity of 86.6% and a specificity of 71.3%, while the deep-learning method achieved a sensitivity of 95% and a specificity of 63.8%.

In a study by Tschandl et al., popular deep-learning architectures known as InceptionV3 and ResNet50 were applied to a combined dataset of 7895 dermoscopic and 5829 close-up lesion images for the diagnosis of non-pigmented skin cancers [7]. Performance was compared with 95 dermatologists who were divided into three groups based on their experience. In the study, deep learning algorithms were found to achieve the same accuracy as human experts and were found to outperform the accuracy rate of the dermatologist groups for early stage and intermediate cancer cases.

Codella et al. developed a method consisting of deep-learning algorithms in the ISIC-2016 dataset and compared the performance of this method with 8 dermatologists to classify 100 skin lesions as benign or malignant. It was highlighted that the corresponding method with 76% accuracy and 62% specificity outperformed the success of dermatologists who had 70.5% accuracy and 59% specificity [8].

The rest of this paper is organized as follows. Section 2 provides information about the dataset used in the study and explains the proposed methodology. The experimental results are analyzed in Section 3. Finally, Section 4 concludes the paper and highlights some possibilities for future work.

## II. MATERIAL AND METHOD

### A. Dataset

The HAM10000, a commonly used public dataset consisting of 10015 dermoscopic images, was utilized in this work since it is reported in the literature as a reference database for academic machine-learning studies [9].

HAM10000 was created by Stanford University by collecting data obtained from various patients at the Research Hospital [10].

The disease types and sample numbers in the dataset are as follows:

- Mel - 1113 patterns (Melanoma),
- NV - 6705 patterns (Melanocytic nevi),
- BCC - 514 patterns (Basal cell carcinoma),
- AKIEC - 327 patterns (Intraepithelial carcinoma & Actinic keratoses),
- BKL - 1099 patterns (Benign keratosis),
- DF - 115 patterns (Dermatofibroma),
- VASC - 142 patterns (Vascular lesions).

The cancer risk of the diseases included in the dataset is given in Fig. 2. In addition, sample images of disease types are presented in Fig. 3.




Fig. 2. Classification of disease types in the HAM10000 dataset




Fig. 3. Images of disease types in the HAM10000 dataset. a. Melanoma cancer, b. Basal cell carcinoma, c. Actinic Keratoses (Solar Keratoses) d. Intraepithelial Carcinoma (Bowen's disease) e. Benign keratosis, f. Dermatofibroma, g. Melanocytic nevi, h. Vascular lesions

In this dataset, which consists of 10015 dermoscopic images with a size of 450×600 and includes 7 diagnostic categories, information on patient age, sex, and diagnostic region can also be found.

### B. Proposed Deep-Learning Architecture

Deep learning is a subfield of machine-learning that is essentially a neural network with three or more layers. These neural networks attempt to simulate the behavior of the human brain and perform the learning process from a large amount of data. While a single-layer neural network can still make approximate predictions, additional hidden layers can help optimize and improve accuracy. Deep learning is the foundation for many AI applications and services that improve automation by performing analytical and physical tasks without human intervention. A key concept that has gained attention in recent years is the dense-sparse-dense paradigm, which has further improved the capabilities and efficiency of deep neural networks.

Deep learning focuses on artificial neural networks inspired by the interconnected structure of neurons in the human brain. Traditionally, neural networks were designed with densely connected layers, where each neuron in one layer is connected to each neuron in the subsequent layer. While this approach offered good modeling capabilities, it also presented problems in terms of computational resources and overfitting.

The dense-sparse-dense paradigm attempts to address these issues by introducing sparsity into neural network architectures. Sparsity means that only a subset of the connections is active, while the rest are set to zero. This sparsity can be achieved by various techniques, such as pruning, which removes connections with small weights, or structured sparsity, which imposes patterns on the connectivity of the network.

The introduction of sparsity reduces the overall size of the network, resulting in significant computational savings in

training and inference. In addition, sparsity promotes a more efficient representation of data by forcing the network to focus on relevant features and discard redundant or less informative connections. This not only improves generalization, but also reduces overfitting, leading to better performance on unseen data.

However, sparse networks alone may have limited informative power due to the smaller number of connections. To overcome this limitation, the dense-sparse-dense paradigm combines the advantages of both dense and sparse connectivity. The first dense layers capture complex patterns and enable rich representations, while subsequent thin layers selectively highlight important connections and promote efficiency.

The key to effectively implementing the dense-sparse-dense paradigm lies in learning algorithms and optimization techniques. Iterative methods such as the Alternating Direction Method of Multipliers (ADMM) are widely used to train sparse networks by iteratively enforcing sparsity constraints and updating network parameters. These methods strike a balance between accuracy and efficiency and enable the successful integration of sparse layers into deep neural networks.

The introduction of the dense-sparse-dense paradigm has led to significant benefits in several application areas. In computer vision, sparse convolutional neural networks have shown excellent performance in tasks such as image classification, object recognition, and semantic segmentation. In natural language processing, the incorporation of sparsity into recurrent neural networks has improved language modeling and machine translation tasks.

In summary, the dense-sparse-dense paradigm represents a significant advance in the field of deep learning and addresses the challenges of computational complexity and overfitting. By introducing sparsity into neural network architectures, it enables more efficient and effective representation of data. The combination of dense and sparse layers enables a balance between expressiveness and computational efficiency. As deep learning continues to evolve, the dense-sparse-dense paradigm holds promise for further enhancing the capabilities of neural networks and driving advancements in AI applications across diverse fields. In this study, a new CNN-based deep-learning model (CNN-BM) was developed for diagnosing skin cancer on dermoscopic images. Fig. 4 shows the architecture of the proposed deep-learning model.




Fig. 4. Architecture of CNN-BM

The CNN-BM consists of 15 layers in total, including input and output layers. The model was implemented using the *Python* language and the *Keras* library. *Relu* functions in Convolution layers and *Sigmoid* functions in *Dense* layers were used as activation functions. Images were given as input to the network with the size of 256x256 and a *batch size* of 8 was utilized. *binary\_crossentropy* was selected as the Loss function while *adam* was used as the Optimizer function.

Each filter takes a subset of the input data at a time and are applied to the entire input. There is a total of 5 convolution layers in CNN-BM. A pooling layer effectively downsamples the output of the previous layer, thus the number of operations required for subsequent layers are reduced. There are 4 *MaxPooling* layers in CNN-BM. *Dropout* layer was used to forget some neurons to avoid overfitting during training. The operations were divided into *dense-sparse-dense* layers to prevent overfitting. In the output layer, there are 2 classes, namely skin cancer and not skin cancer.

### III. EXPERIMENTAL RESULTS

The experiments performed resulted in an accuracy of 86.48% and a precision of 85.13%, as shown in Table 1. The

experimental success rates were obtained by averaging the results from five runs of the developed model.

Table 1. Success rates of the algorithms

Reference Study	Classifier	Accuracy (%)	Precision (%)
[12]	DenseNet 201	81.27	-
	ResNet 50	79.95	-
	Inception v3	77.04	-
	InceptionResNet v2	81.79	-
[13]	Dermatologist 1	65,6	-
	Dermatologist 2	66,0	-
	CNN	69,4	-
[11]	CNN-PA	72,1	-
	CNN		<b>85.73</b>
	MobileNetV2		84.98
	<b>CNN-BM (Proposed Method)</b>	<b>86.48</b>	<b>85.13</b>

Examining the studies performed with deep-learning models on dermoscopic images, it can be seen that the proposed CNN-BM achieves the highest accuracy value of 86.48%, as listed in Table 1. In terms of precision values, it can be seen that the CNN model in the study by Kousis et al.

[11] has a rate of 85.73% and the CNN-BM has a rate of 85.13%.

In order to achieve higher success rates, previously applied performance enhancement techniques in the field of deep learning were utilized in this study. Some of these methods are discussed in this paragraph. By using the dropout layer, an attempt is made to break the bonds in the fully-connected layers. In this way, the nodes have less information about each other, and consequently, the nodes are less affected by weight changes of the other nodes. We believe that more consistent models can be created using the dropout method. In 2016, the dense-sparse-dense method was first presented in the article *DSD: Regularizing Deep Neural Networks with Dense-Sparse-Dense Training Flow* [14]. In this method, the operations performed in a single fully-connected layer are divided into three layers in the form of dense-sparse-dense. In this way, the effect of the weights on each other is first reduced, and then new information is learned by reconnecting them. In this case, the problem of overfitting caused by detailed learning is avoided. As a result of the reduced overfitting, the success on the test data is increased.

#### IV. CONCLUSION

The integration of deep learning and the dense-sparse-dense paradigm has shown promise for skin cancer diagnosis. Skin cancer is a common and potentially life-threatening disease, and accurate and timely diagnosis is critical for effective treatment.

Deep learning techniques, with their ability to learn complex patterns and representations from large data sets, have shown remarkable potential for automated skin cancer diagnosis. Using deep neural networks, these techniques can analyze skin images and detect subtle signs of malignancy with high accuracy.

The dense-sparse-dense paradigm complements deep learning by optimizing the efficiency and interpretability of skin cancer diagnostic models. By incorporating sparsity into neural network architectures, the paradigm reduces computational complexity and improves generalization performance. It allows the network to focus on relevant features while discarding redundant or less informative links, resulting in more efficient and accurate skin cancer diagnosis.

Implementing the dense-sparse-dense paradigm in skin cancer diagnosis requires sophisticated learning algorithms and optimization techniques. By iteratively enforcing sparsity constraints and updating network parameters, these techniques strike a balance between accuracy and efficiency. This integration provides clinicians with powerful diagnostic tools that can aid in early detection, provide second opinions, and improve overall patient care.

In addition, advances in deep learning and the dense-sparse-dense paradigm have the potential to address challenges in skin cancer diagnosis, such as limited access to dermatologists, variability in human expertise, and increasing caseloads. By using automated systems, healthcare providers can improve their diagnostic capabilities, reach underserved populations, and reduce the burden on healthcare systems.

In summary, the integration of deep learning and the dense-sparse-dense paradigm holds great potential for improving skin

cancer diagnosis. By harnessing the power of neural networks and optimizing their efficiency, these approaches offer the opportunity to improve accuracy, efficiency, and accessibility in skin cancer detection. Continued research, development, and collaboration between medical professionals and AI experts are essential to unlock the full potential of this technology and ultimately improve patient outcomes in skin cancer diagnosis and treatment.

In this study, a deep-learning model for skin cancer detection is developed to take advantage of artificial intelligence technology. The proposed model not only increases the success rate in the training process, but also reduces the execution time since the execution time varies in direct proportion to the number of layers [15] and the proposed model contains fewer layers than other architectures. If the batch size is chosen to be small, overfitting that may occur on the entire data is prevented because the data is processed in small chunks [16]. By choosing a small batch size in the model, overfitting was avoided and the regularization effect was increased. In addition, the inclusion of a dropout layer and dense-sparse-dense training techniques in the model avoids overfitting and increases the success rate of the network. The experimental results of the study show that the success rates of 86.48% accuracy and 85.13% precision were achieved thanks to the proposed method.

Increasing the number of samples in the dataset and analyzing the impact of this on the success rates of the developed model could be a research topic for the future studies.

#### ACKNOWLEDGMENT

This work was supported by The Scientific and Technological Research Council of Turkey (TÜBİTAK) 2211-A program.

#### REFERENCES

- [1] Koçak, Y. (2021), Cilt (Deri) Kanseri Belirtileri, Tedavisi ve Korunma Yöntemleri, Memorial, 1-1.
- [2] Goyal, M., et al. (2020), Artificial Intelligence-based Image Classification Methods for Diagnosis of Skin Cancer: Challenges and Opportunities, *Computers in Biology and Medicine*, 127, 104065.
- [3] Society, A.C. (2018), *Cancer Facts & Figures 2018*, American Cancer Society, 1-1.
- [4] Nikolaou, V. and A.J.B.j.o.d. Stratigos (2014), Emerging Trends in the Epidemiology of Melanoma, *Journal of Emerging Technologies and Innovative Research*, 170(1), 11-19.
- [5] Society, A.C. (2008), *Cancer Facts & Figures 2008*, American Cancer Society, 1-1.
- [6] Haenssle, H.A., et al. (2018), Man Against Machine: Diagnostic Performance of a Deep Learning Convolutional Neural Network for Dermoscopic Melanoma Recognition in Comparison to 58 Dermatologists, *Annals of oncology*, 29(8), 1836-1842.
- [7] Tschandl, P., et al. (2019), Expert-level Diagnosis of Nonpigmented Skin Cancer by Combined Convolutional Neural Networks, *JAMA dermatology*, 155(1), 58-65.
- [8] Codella, N.C., et al. (2017), Deep Learning Ensembles for Melanoma Recognition in Dermoscopy Images, *IBM Journal of Research and Development*, 61(4/5), 1-5.
- [9] Codella, N., et al. (2018), *Skin Lesion Analysis Toward Melanoma Detection 2018: A Challenge Hosted by the International Skin Imaging Collaboration, ISIC*, 1-1.
- [10] Tschandl, P., C. Rosendahl, and H. Kittler (2018), The HAM10000 Dataset, a Large Collection of Multi-Source Dermatoscopic Images of Common Pigmented Skin Lesions, *Scientific Data*, 5(1), 180161.

- [11] Kousis, I.; Perikos, I.; Hatzilygeroudis, I.; Virvou, M. (2022), Deep Learning Methods for Accurate Skin Cancer Recognition and Mobile Application, *Electronics*, 11, 1294.
- [12] Al-Masni MA, Kim DH, Kim TS. (2020), Multiple Skin Lesions Diagnostics via Integrated Deep Convolutional Networks for Segmentation and Classification, *Comput Methods Programs Biomed*, 1-1.
- [13] Esteva, A., Kuprel, B., Novoa, R. et al. (2017), Dermatologist-level Classification of Skin Cancer with Deep Neural Networks, *Nature*, 542, 115–118.
- [14] Han, Song & Pool, Jeff & Narang, Sharan & Mao, Huizi & Tang, Shijian & Elsen, Erich & Catanzaro, Bryan & Tran, John & Dally, William (2016), DSD: Regularizing Deep Neural Networks with Dense-Sparse-Dense Training Flow, 1-1.
- [15] Al-Bander, Baidaa; Yas, Qahtan M.; Mahdi, Hussain; and Al-Hamd, Rwayda KH. S. (2021) "Benchmarking of deep learning algorithms for skin cancer detection based on a hybrid framework of entropy and VIKOR techniques," *Turkish Journal of Electrical Engineering and Computer Sciences*: Vol. 29: No. 8, Article 4.
- [16] Kandel, I., & Castelli, M. (2020). The effect of batch size on the generalizability of the convolutional neural networks on a histopathology dataset. *ICT Express*, 6(4), 312–315.

## Development of a Simulator for UAV Swarm Operation Planning using Evolutionary Algorithms

Metehan Aydın, Gazi Erkan Bostancı, Mehmet Serdar Güzel and Koray Açıcı

Department of Computer Engineering/Engineering Faculty, Ankara University, Ankara, Turkey

Department of Artificial Intelligence and Data Engineering/Engineering Faculty, Ankara University, Ankara, Turkey  
[eng.metehan.aydin@gmail.com](mailto:eng.metehan.aydin@gmail.com), [ebostanci@ankara.edu.tr](mailto:ebostanci@ankara.edu.tr), [mguzel@ankara.edu.tr](mailto:mguzel@ankara.edu.tr), [kacici@ankara.edu.tr](mailto:kacici@ankara.edu.tr)

**Abstract** – In latest years, UAVs are widely used in many areas. Their advantages attracts researches all around the world. When UAVs are wanted to be used effectively, swarm systems offer better and more advantageous solutions. Using a UAV swarm has some advantages over a single agent UAV but operation planning must be considered carefully. There are lots of operation planning algorithms in literature. If these algorithms are evaluated for their effectiveness, evolutionary algorithms comes to the fore. Operation planning algorithms and UAV swarms are generally tested in simulation environments. There are lots of simulation environments and tools. They can handle simulations in many areas ranging from aviation to automobile. However, they do not offer any features dedicated for UAV swarms. In this work, a simulation software is designed for UAV swarms. The designed simulation software can plan an operation for an UAV swarm using evolutionary algorithms and simulate them. In this paper, the designed software and its architecture is explained in details.

**Keywords** – UAV swarm, simulation, operation planning, evolutionary algorithms, genetic algorithms

### I. INTRODUCTION

An unmanned aerial vehicle (UAV) is a vehicle which can fly without a pilot or a crew member on it. UAVs are being widely used in these days. The main reasons behind their growing usages are the advantages [1] they offer. The main advantages of UAVs are safety and their prices. UAVs are very capable vehicles. However, there are some cases where they are wanted to be more capable. In such cases, UAV swarms are used.

Swarm systems is a field in multi-agent systems and deal with the coordination of multiple agents [2]. Its purpose is that instead of using a complex agent, coordinating relatively simple agents to complete a task. The behaviors of the social insects are taken to model the coordination of the agents in the swarm and these behaviors give some abilities to swarm systems. [3]. These abilities are robustness, flexibility and scalability. Thanks to robustness, swarm systems can complete a task despite of failures on an environment or agents. Swarm systems can generate effective solutions for a range of problems with flexibility. Scalability gives the ability of increasing or decreasing number of agents in a swarm. When an UAV swarm is formed, these abilities can be beneficial and make UAVs more operational [4]. However, in order to complete an operation successfully, operation planning must be considered carefully [5]. When the latest developments in the literature are examined, it can be seen that evolutionary computational based operation planning systems are widely used for their efficiency and flexibility advantages.

Evolutionary computation solves problems by mimicking evolution steps in nature [6] [7]. Mimicking a natural process gives some abilities [8][9] to evolutionary computation. These abilities are as follows.

- Flexibility: Evolutionary computation algorithms can be applied to different kinds of problems.

- Dynamic: Evolutionary computation algorithms can be used for dynamic problems.
- Distributed: Evolutionary computation algorithms can be operated without being dependent on a central authority or decision maker.
- Autonomous: Evolutionary computation algorithms can work without human interaction.

An evolutionary computation algorithm generally consists of four steps [10] [11]. These steps are initialization, selection, genetic operation and termination. Genetic operation is composed of two steps; crossover and mutation. The order of these steps is shown in Figure 1.

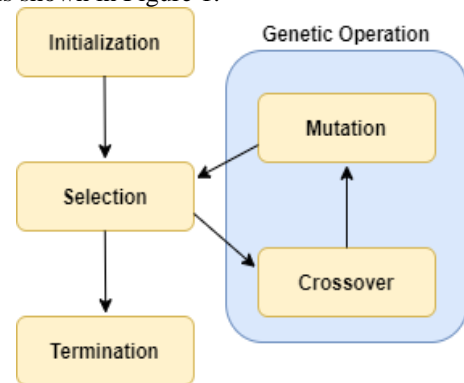


Fig. 1 Order of steps in an evolutionary computation algorithm

The algorithm starts with initialization step. In initialization, a solution set called population is created. Each solution in population is called chromosome. Then, the algorithm passes to selection step. In selection step, there is a function called fitness. The function evaluates the population and chooses the best chromosomes. Then, crossover step is started. In this step, two chromosomes are combined into one chromosome. After crossover step, the algorithm passes to mutation step. In mutation step, some chromosome values are altered. Then, the algorithm passes to selection state again. The cycle for

selection, mutation and crossover is repeated until a desired solution is obtained [12] [13].

When a swarm system is established, it is hard to realize its algorithms in real life [14]. Because, there are many agents in a swarm system. Establishing a swarm then testing its algorithms in real life is a challenging task. For these reasons, swarm system researchers most of the time work with simulators. They simulate a swarm system and its algorithms in a simulation environment.

Swarm systems are generally simulated in tools [15] like MATLAB [16] or SCADE Suit [17]. These kind of tools are good for simulation. They have very advanced simulation capabilities. But, they are developed for multi-purpose usages. Almost anything can be simulated using these kind of tools. However; in the case of simulating a swarm system, they do not offer any dedicated features or abilities. Thus, it is tedious to set up a swarm system simulation using these kind of platforms. There are also some tools which are dedicated for swarm system simulation but they are not for UAV swarms. Besides them, most of the simulation tools are depended on a single operating system. This situation restricts the area of use for the tools. In addition, the situation also makes it difficult to install these tools.

In this work, a simulation tool dedicated for UAV swarms are designed. The purpose of the tool is planning and simulating swarm operations. The designed tool can work in different operating system. The supported operation systems are Linux, Windows and MacOS. In this paper, we explain how the simulation tool is designed in details. The rest of the paper is structured as follows. In section 2, materials and method of the work is addressed. Section 3 presents some experiments and their results and the conclusion of the work is given in Section 4.

## II. MATERIALS AND METHOD

The software is developed using C++ Programming Language and Object Oriented Programming paradigm. Abilities of the software are as follows.

- Operation planning of a single UAV.
- Operation planning of a UAV swarm.
- Adding a new UAV model.
- Defining a UAV swarm that has homogenous architecture.
- Defining a UAV swarm that has heterogeneous architecture.
- Adding a new threat type.
- Defining an operation that has one type of threat.
- Defining an operation that has multiple types of threats.
- Adding a map to simulation.
- Applying different kind of evolutionary computation algorithms for operation planning.

The developed software has graphical user interface for easy use. Users can set up simulation environments, swarm systems and operations using the graphical interface. Qt Framework [18] is used in order implement the graphical interface and some of the abilities mentioned above.

Qt Framework is an application development framework that offers developers to design cross-platform applications with graphical user interfaces. Qt has lots of libraries for C++ programming languages ranging from 2D rendering to

networking and more. These features allow developers to create robust applications for various areas.

The architecture of the developed software has four main infrastructures. These infrastructures are as follows.

- Graphical user interface
- Software manager
- Object creation infrastructure
- Operation planning infrastructure
- Simulation infrastructure

Figure 2 shows relations of these infrastructures.

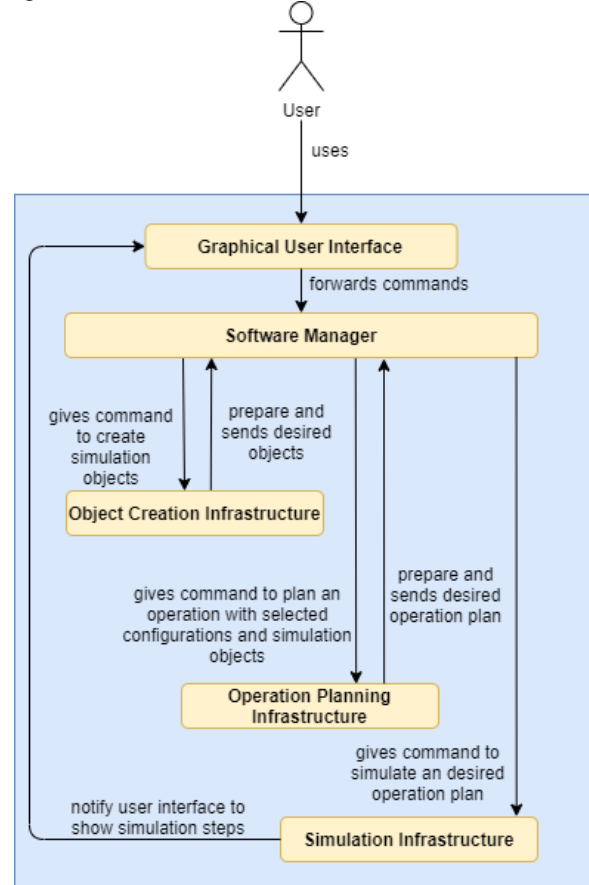


Fig. 2 Relationships among the infrastructures of designed simulation software

As it can be seen in the figure, a user can manage all his processes via graphical user interface. The graphical user interface forwards all the commands to software manager. Users can control the software using buttons on the user interface.

Software manager controls the infrastructures and provides collaboration among them. It handles all the functionality the software has and contains all the software data including UAVs, threats and maps. All the buttons in graphical user interface triggers a process in software manager. These processes manage desired commands to help preparing a simulation environment and simulate an operation. Thanks to software manager, modifications to the tool can be done easily and new features can be added without any changes to existing codes. Thus, software manager makes the tool flexible and robust.

Objects creation infrastructure gets commands from simulation manager. It is responsible for creating UAV, threat and map instances. When user wants to create these objects, he orders them via graphical user interface. Graphical user interface notifies object creation infrastructure via software

manager. Classes are defined for representing UAVs, threats and map. These classes implements prototype design pattern. Object creation infrastructure uses prototype design pattern embedded in each classes to create objects. When the objects are created, they are sent to software manager to store. Object creation infrastructure can create all kind of objects. In case of adding creating new types of objects, its implementation can be added easily.

When an operation wanted to be planned, operation planning infrastructure is executed. Its purpose is planning desired operations using desired algorithms. It takes an operation definition as input from software manager and create an operation plan as output to software manager. An operation definition includes properties of UAV swarm, properties of threats, properties of operation and the map. Properties of UAV swarm defines there are how many agents in the swarm and models of each agents. Operation planning infrastructure is designed to plan operation for any size of swarm. So, number of agents in the swarm can be 1 or N. Properties of threats addresses how many threats are there in the operation and what is the type of each threats. Operation planning infrastructure can handle any number and any types of threats. There can be 0 or N number of threats in the operation. Properties of an operation describes operation location and kind of operation. Operations can be located anywhere in the map. Operation kinds can be surveillance and reconnaissance. The map is set using graphical user interface and stored in software manager. In case of planning an operation, a map is also needed. Operation planning infrastructure is designed to handle any maps. Operation definition is processed to create an operation plan. The process is managed by the algorithm applied. Thanks to modular design of operation planning infrastructure, any kind of operation planning algorithm can be implemented or any kind of 3<sup>rd</sup> party libraries can be added. Operation planning infrastructure can also be moved to another software. In this work, an evolutionary computation algorithm is implemented in the tool. The algorithm outputs a planned operation. The planned operation is taken by operation planning infrastructure and sent to software manager.

Simulation infrastructure manages simulations. When user starts or stop simulation via graphical user interface, the commands are forwarded to simulation manager. Simulation manger executes simulation infrastructure. There is an interface named SimItem in the software. All the objects which can be simulated must implement SimItem interface. The interface provides simulation capabilities. Simulation infrastructure uses SimItem interface to simulate objects. The behaviours of objects are defined in functions provided by the interface. The objects are changed during simulation with respect to these functions. Simulation is executed step by step. In each step, simulated objects are changed and changes are reflected to screen by notifying graphical user interface. Thanks to simulation infrastructure's modular design, new simulation capabilities can be added or existing ones can be modified easily.

The infrastructures of the software provides all the functionalities for the software. Their designs allow new functionalities to be added with ease. Following figure has a use case diagram which shows the functionalities of the software.




Fig. 3 Functionalities of the software

When a user wants to add a map, there is a class whose name is Map. A map is represented with Map class. An instance of Map class is created via object creation infrastructure. The instance is used for representing the selected map in the software.

A new UAV model is added to software with entering a model name and a color. Color is used to represent a UAV in the map. There is a class in the software whose name is UAV. The class inherits SimItem and represents an UAV. When the user enters a UAV model and a color, an UAV class instance is created via object creation infrastructure and stored in software manager.

Type, color, width and height must be entered when a new threat type is wanted to be added. Type field stores type of a threat. Color field is for representing a threat in the map. Width and height fields define size of a threat. A threat is represented in the software with a class whose name is Threat. Threat class also inherits with SimItem class. When the user enters the fields, a Threat class instance is created via object creation infrastructure and stored in software manager.

Manage swarm functionality is provided to determine number of UAVs for each UAV model and number of threats for each threat types. When the user enters desired number of threats and UAVs, object creation infrastructure creates the instances and sends them to software manager to store.

In the software, operation properties are managed via a class whose name is Operation. Operation class represents an operation. There is an Operation class instance which is created default. Properties of an operation are type, width and height. Type property indicates type of the operation. There are two types of operation in the software. These are surveillance and reconnaissance. One of them can be selected. Width and height properties define the size of the operation. When user wants to manage an operation, he modifies the instance.

Plan operation functionality is triggered to plan an operation. Software manager creates an operation definition and sends it to operation planning infrastructure. Operation

planning infrastructure plans the operation and sends it to again software manager to store. The stored operation can be simulated any time.

In order to manage simulation functionalities, commands are forwarded to software manager. Software manager controls simulation manager to start or stop the simulation.

Figure 4 shows a planned operation.

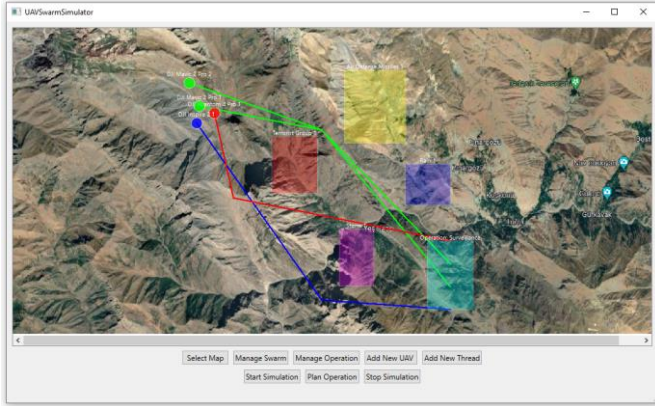


Fig. 4 A planned operation

### III. RESULTS

Two experiments are done to prove that our software design can work effectively with different algorithms. The algorithms used are NSGA-2 [19] and MOEA/D [20].

Experiments are executed for two agents and two objectives. The objectives are shortest path and safest path. Thus, the operations are planned for the path which is safest and shortest. Fitness functions of algorithms are same and as follows.

Let D be distance between source and destination points.

$$D = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (1)$$

Let P be penalty value.

$$P = \begin{cases} 0, & \text{if the path doesn't have a threat} \\ 100, & \text{if the path has a threat} \end{cases} \quad (2)$$

Let F be fitness function.

$$F = D + P \quad (3)$$

Both of the algorithms are run with following configurations. Bit-flip mutation is selected as mutation method. Binary random sampling is used as sampling method. Two-point crossover is chosen for crossover method. Figure 5 shows test case for the experiments.

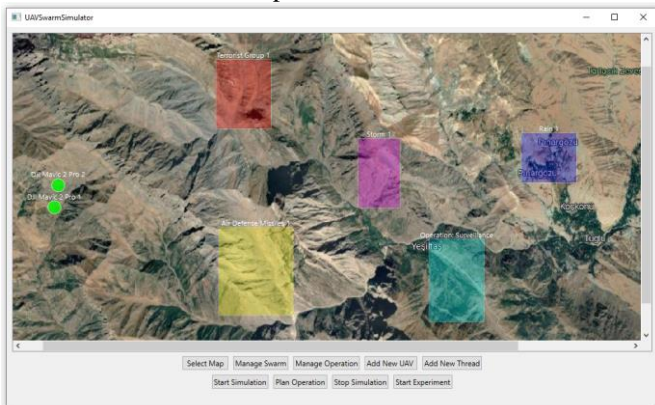


Fig. 5 Test case for the experiments

First, MOEA/D algorithm is tested. The test is completed in 7430ms. Figure 6 shows best and average fitness/generation graph for first and second agents.

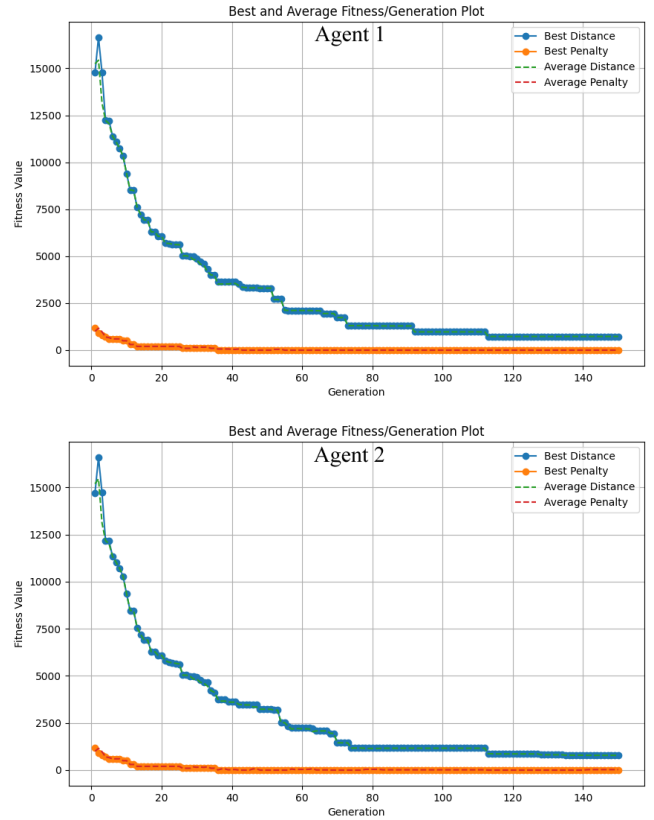


Fig. 6 Fitness plots for agents using MOEA/D

Then, NSGA-2 algorithm is tested. The test takes 13955ms. Figure 7 shows best and average fitness/generation graph for first and second agents.

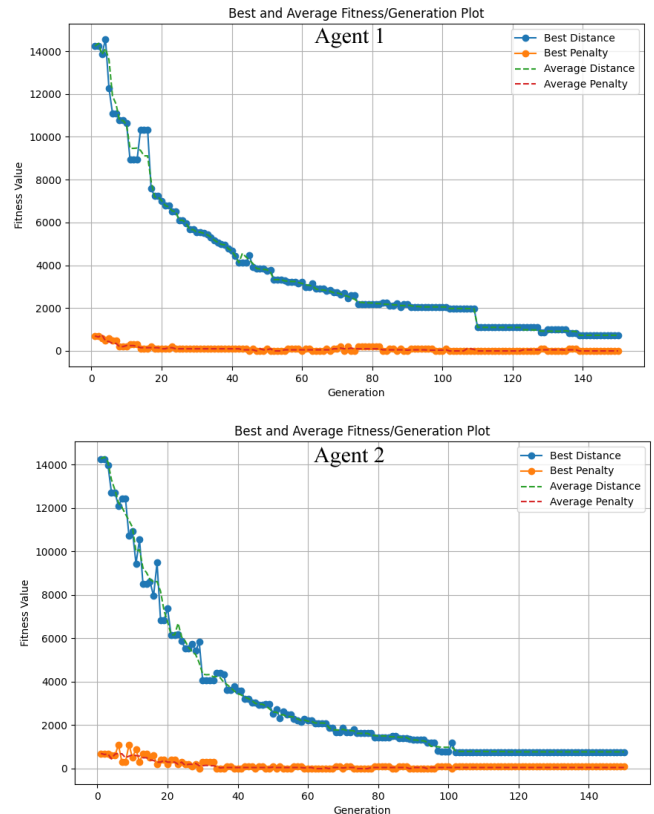


Fig. 7 Fitness plots for agents using NSGA-2



As it can be seen in plots, when both of the algorithms were executed, their solutions initially were not effective. The path distances were too long and their penalty values were too high. However, as the algorithms proceed, distances are getting shorter and penalty values are getting lower. Both of the algorithms give optimal solutions at the end of the execution. Whereas NSGA-2 gives the optimum result after 100<sup>th</sup> generations, MOED gives the optimum result after 140<sup>th</sup> generations. Although MOEA/D completes the task earlier than NSGA-2, NSGA-2 reaches the optimal solutions quicker.

#### IV. CONCLUSION

UAVs are used in many areas. Increasing popularities of UAVs result for new researches. According to latest development in literature, UAV swarms can be a better way to use UAVs effectively. Using a swarm can be effective if operation planning algorithm is well designed. According to latest developments, evolutionary algorithms can be a good choice for UAV swarms.

Swarm researches test their algorithms mostly in simulators. There are lots of simulation tools but most of them offers multi-purpose solutions. In this work, a simulation tool is designed which can work with evolutionary algorithms. Architecture of the tool is presented and two experiments are made. Each of the experiments is made with same parameters. MOEA/D and NSGA-2 algorithms are selected for operation planning algorithm. Results of the experiments show that the developed tool can work with different algorithms effectively.

#### REFERENCES

- [1] Baballe, M. A., Bello, M. I., Alkali, A. U., Abdulkadir, Z., Muhammad, A. S., & Muhammad, F. (2022). The Unmanned Aerial Vehicle (UAV): Its Impact and Challenges. Journal homepage: <https://gjrpublication.com/gjrecs>, 2(03).
- [2] Iñaki Navarro and Fernando Matía, "An Introduction to Swarm Robotics," ISRN Robotics, vol. 2013, Article ID 608164, 10 pages, 2013.
- [3] E. Şahin, "Swarm robotics: from sources of inspiration to domains of application," in Swarm Robotics Workshop: State-of-the-Art Survey, E Şahin and W. Spears, Eds., Lecture Notes in Computer Science, no. 3342, pp. 10–20, Berlin, Germany, 2005.
- [4] Cheraghi, Ahmad Reza, Sahdia Shahzad, and Kalman Graffi. "Past, present, and future of swarm robotics." Intelligent Systems and Applications: Proceedings of the 2021 Intelligent Systems Conference (IntelliSys) Volume 3. Springer International Publishing, 2022.
- [5] Sampedro, C., Bavle, H., Sanchez-Lopez, J. L., Fernández, R. A. S., Rodríguez-Ramos, A., Molina, M., & Campoy, P. (2016, June). A flexible and dynamic mission planning architecture for uav swarm coordination. In *2016 International Conference on Unmanned Aircraft Systems (ICUAS)* (pp. 355-363). IEEE.
- [6] Whitley, Darrell. "An overview of evolutionary algorithms: practical issues and common pitfalls." Information and software technology 43.14 (2001): 817-831.
- [7] Spears, William M., et al. "An overview of evolutionary computation." European conference on machine learning. Berlin, Heidelberg: Springer Berlin Heidelberg, 1993.
- [8] Fogel, David B. "The Advantages of Evolutionary Computation." *Bcec* (1997): 1-11.
- [9] Back, Thomas, Ulrich Hammel, and H-P. Schwefel. "Evolutionary computation: Comments on the history and current state." *IEEE transactions on Evolutionary Computation* 1.1 (1997): 3-17.
- [10] Mitchell, Melanie, and Charles E. Taylor. "Evolutionary computation: an overview." *Annual Review of Ecology and Systematics* 30.1 (1999): 593-616.
- [11] Pena-Reyes, Carlos Andrés, and Moshe Sipper. "Evolutionary computation in medicine: an overview." *Artificial Intelligence in Medicine* 19.1 (2000): 1-23.
- [12] Jones, Gareth. "Genetic and evolutionary algorithms." *Encyclopedia of Computational Chemistry* 2.1127-1136 (1998): 40.
- [13] Tian, Ye, et al. "Evolutionary large-scale multi-objective optimization: A survey." *ACM Computing Surveys (CSUR)* 54.8 (2021): 1-34.
- [14] Soria, Enrica, Fabrizio Schiano, and Dario Floreano. "SwarmLab: A MATLAB drone swarm simulator." 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2020.
- [15] Calderón-Arce, Cindy, Juan Carlos Brenes-Torres, and Rebeca Solís-Ortega. "Swarm robotics: Simulators, platforms and applications review." *Computation* 10.6 (2022): 80.
- [16] (2023) MATLAB website [Online]. Available: <https://www.mathworks.com/products/matlab.html>
- [17] (2023) SCADE Suit website [Online]. Available: <https://www.ansys.com/products/embedded-software/ansys-scade-suite>
- [18] (2023) Qt Framework website [Online]. Available: <https://www.qt.io/>
- [19] Deb, Kalyanmoy, et al. "A fast and elitist multiobjective genetic algorithm: NSGA-II." *IEEE transactions on evolutionary computation* 6.2 (2002): 182-197
- [20] Zhang, Qingfu, and Hui Li. "MOEA/D: A multiobjective evolutionary algorithm based on decomposition." *IEEE Transactions on evolutionary computation* 11.6 (2007): 712-731.

# Improving Computational Performance of Least Squares Multiple Birth Support Vector Machines with $k$ -Means Clustering

Güvenç Arslan<sup>1\*</sup> and Nisa Nur Bülbül<sup>2</sup>

<sup>1</sup>Department of Statistics, Kırıkkale University, Kırıkkale, Turkey

<sup>2</sup>Graduate School of Natural and Applied Sciences, Kırıkkale University, Kırıkkale, Turkey

\*([guvenc.arslan@kku.edu.tr](mailto:guvenc.arslan@kku.edu.tr))

**Abstract** – Multiple Birth Support Vector Machines (MB-SVM) were introduced as a powerful extension of SVM. Although the basic idea is like SVM, optimal non-parallel hyperplanes are used for each class category. One may find different implementations of this approach in the literature. One of these is the Least Squares MB-SVM. An appealing property of this implementation is that an analytical solution is obtained that is used for classification. On the other hand, this solution involves matrix computations of sizes depending on the number of attributes and the size of the data set. In this study, we propose to use the  $k$ -means clustering algorithm before applying the Least Squares MB-SVM algorithm to improve the computational performance of MB-SVM. The preliminary results with the Iris data set indicate that by using only a small number of examples obtained from the  $k$ -means clusters, comparable performance can be obtained with the LS-MB-SVM method.

**Keywords** – support vector machine, multiple birth,  $k$ -means

## I. INTRODUCTION

Support vector machines (SVM) are one of the supervised learning algorithms used with success in various applications. They were introduced in the framework of statistical learning by Vapnik and Chervonenkis [1]. The basic idea in SVM classification is to obtain the optimal hyperplane for classification by finding the maximum margin between examples at the boundaries of the examples in each class (..).

In recent years one may find various extensions and variations of the basic idea used in SVMs [2]. One of these variations is the Twin Support – SVM (Twin-SVM) introduced by Jayadeva et al. [3]. In contrast to standard SVMs, non-parallel hyperplanes are used in Twin-SVMs. Multiple Birth – SVM introduced by Yang et al. [4] may be considered as an extension of the basic idea in Twin-SVM to multiple classes.

MB-SVMs have lower computational complexity with improved classification accuracy [4]. On the other hand, there are various implementations of the MB-SVM approach. One of these is the Least Squares - MB-SVM (LS-MB-SVM) introduced by [5]. One advantage of this approach is that the solution for the optimal hyperplane is expressed analytically. On the other hand, this solution involves basic matrix computations and inverses of matrices whose dimensions depend on the dimensions of the data set. This may result in some computational problems especially for moderately large data sets.

The main goal of this study is to reduce the computational complexity of the LS-MB-SVM while keeping classification performance. As noted before, the solution in LS-MB-SVM is expressed by using large matrix products and inverses of matrices, which may result in some computational problems. Thus, it is expected that applying the  $k$ -means clustering

algorithm before using LS-MB-SVM will considerably reduce the computational complexity of this algorithm.

## II. MATERIALS AND METHOD

Assuming that there are  $t$  class categories in the classification problem, the set of class categories will be denoted by  $\mathcal{C}_t = \{k_1, k_2, \dots, k_t\}$ . Thus, the data set for a classification problem can be expressed as

$$\mathcal{D} = \{(\mathbf{x}_j, y_j) : \mathbf{x}_j \in \mathbb{R}^n, y_j \in \mathcal{C}_t ; j = 1, 2, \dots, m\}, \quad (1)$$

where  $m$  denotes the number of examples. Since in the MB-SVM approach there is an optimization problem for each class category it is more convenient to express this data set with respect to each class separately. Therefore, for  $i = 1, 2, \dots, t$  the examples corresponding to the class category  $k_i$  can be described as

$$\mathcal{D}_i = \{(\mathbf{x}_j^{(i)}, k_i) : \mathbf{x}_j^{(i)} \in \mathbb{R}^n \text{ ve } j = 1, 2, \dots, m_i\}, \quad (2)$$

where  $m_i$  denotes the number of examples in class  $k_i$ . With this notation it follows that

$$\mathcal{D} = \mathcal{D}_1 \cup \mathcal{D}_2 \cup \dots \cup \mathcal{D}_t, \quad (3)$$

where  $m = m_1 + m_2 + \dots + m_t$ .

Although there are different implementations of the MB-SVM approach we used the approach introduced in [5]. In this approach the solution is obtained by using the least squares method yielding an analytical solution of the classification problem.

### A. Least Squares Multiple Birth Support Vector Machines

MB-SVMs were introduced by Yang et al. [4], which may be considered as a generalization of Twin-SVM introduced by Jayadeva et al. [3]. An important property of MB-SVM is that one optimization problem is expressed for each class to find the corresponding optimum hyperplane. On the other hand, in contrast to standard SVMs, examples are classified with these non-parallel hyperplanes in MB-SVMs.

Although there are different implementations of the MB-SVM approach we used the approach in [5]. In this approach the optimization problem for classifying examples in class  $k_i$  is expressed as

$$\min_{\mathbf{w}_i, b_i, \xi_i} \frac{1}{2} \|B_i \mathbf{w}_i + \mathbf{e}_i b_i\|_2^2 + \frac{c_i}{2} \xi_i^T \xi_i + \frac{v_i}{2} (\|\mathbf{w}_i\|^2 + b_i^2) \quad (4)$$

$s.t. (A_i \mathbf{w}_i + \mathbf{e}_i' b_i) + \xi_i = \mathbf{e}_i', \xi_i \geq 0$

Here,  $A_i$  represents the matrix of the examples in class  $k_i$  without the class label. Similarly, matrix  $B_i$  represents all examples (without any class label) in the data set except examples belonging to class  $k_i$ .

Using the least squares method, the solution for the optimal hyperplane parameters is obtained as

$$\mathbf{u}_i = \begin{bmatrix} \mathbf{w}_i \\ b_i \end{bmatrix} = c_i [H_i^T H_i + v_i I_i + c_i G_i^T G_i]^{-1} G_i^T \mathbf{e}_i', \quad (5)$$

where  $H_i = [B_i \ \mathbf{e}_i]$  and  $G_i = [A_i \ \mathbf{e}_i']$ . A new example  $\mathbf{x}_0$  is classified by using

$$j = \arg \max_{i=1,2,\dots,t} \frac{|\mathbf{w}_i^T \mathbf{x}_0 + b_i|}{\|\mathbf{w}_i\|}, \quad (6)$$

and assigning it to class  $k_j$ .

It should be noted that in the setting above it is assumed that the examples are almost linearly separable. If not, appropriate kernels can be used to transform the data set into a higher dimensional space to improve classification performance. In this case, the classification of a new example  $\mathbf{x}_0$  is determined by

$$j = \arg \max_{i=1,2,\dots,t} \frac{|K(\mathbf{x}_0, C^T) \tilde{\mathbf{w}}_i + b_i|}{\sqrt{\tilde{\mathbf{w}}_i^T K(C^T, C^T) \tilde{\mathbf{w}}_i}}, \quad (7)$$

where  $K(\cdot, \cdot)$  represents the kernel function to be used. For more details about the optimization problem and its solution the reader is referred to [5].

### B. Least Squares Multiple Birth Support Vector Machines with $k$ -Means

In Yang et al. [4] it is noted that the construction of different optimization problems for each class results in lower computational complexity and that it is expected to be faster than existing multi-class SVMs. On the other hand, as can be seen from equations (5) - (7) in LS-MB-SVM the solution involves computation of matrix multiplications depending on the size of the data set. For moderately large data sets and the increased number of parameters to be selected for high classification performance in LS-MB-SVM, this can negatively affect the training time and performance of the algorithm. Therefore, it is expected that using the  $k$ -means clustering algorithm before applying LS-MB-SVM, as introduced by Wang et al. [6] for SVMs, will reduce computational complexity and reduce training time.

The basic idea in MB-SVM is to find the optimal hyperplane in a particular class that is farthest to the examples in the remaining classes. It is expected that only little information is lost, when using centers of clusters after  $k$ -means clustering, to construct the optimal hyperplane. This approach will be denoted by  $k$ -LS-MB-SVM. The basic steps of the proposed algorithm are as follows:

1. Determine the number of clusters ( $k$ ), the parameters ( $c_1, \dots, c_t, v_1, \dots, v_t$ ) and appropriate kernel function  $K(\cdot, \cdot)$  for LS-MB-SVM.
2. Apply  $k$ -means clustering to the training set.
3. Construct the reduced training set consisting of cluster centers and its corresponding class labels.

4. Apply LS-MB-SVM to the reduced training set to obtain the classifier.

Figure 1 shows how the training data set is reduced by  $k$ -means from 14 examples to 5 examples (denoted by the larger red points) for a small data set. The line represents the optimal hyperplane obtained by the reduced data set for examples in the class at the top left corner. The size of reduction depends on the number of clusters chosen. In this example, the training data set is reduced with a ratio of  $14/5=2.8$ .

Different strategies may be applied to use the information about classes in each cluster. In this study, we have used a simple strategy: assign the majority class label as the class label for each cluster center.




Fig. 1 Example for clustering with  $k$ -means

## III. RESULTS

The proposed approach was applied to the IRIS data set [7] to demonstrate how it reduces the training data set while preserving comparable classification performance. The data set is split into training and test sets with %30 as the test data set. This is repeated 5 times to take into consideration the variations of the splitting. Since for each run of the  $k$ -means algorithm different clusters may be obtained  $k$ -means clustering is applied to each of these training data sets 10 times for each value of  $k$ .

The implementation of the proposed algorithm was done by using the R Software [8]. For SVM calculations the e1071 package [9] was used whereas for the LS-MB-SVM calculations we developed our own implementation in R with the linear and radial basis kernels.

Figure 2 shows how the test accuracies change with respect to the number of clusters for  $k=3,5,7,11,13$  ( $a=3, b=5, \dots, f=13$ ). The results clearly indicate that for the radial basis kernel ( $k2$ ) better classification results are obtained than for the linear kernel ( $k1$ ).




Fig. 2 Accuracies for test set with  $k$  values of 3,5,7,9,11,13

Figure 3 shows the average test accuracies for 10 trials with each  $k$  value for one test data set. These calculations are repeated for each different partition of train and test sets. The resulting average accuracies for each partition are compared with SVM and MB-SVM accuracies in Figure 4.




Fig. 3 Average test accuracies for  $k$  values of 3,5,7,9,11,13

Figure 4 shows how the test accuracies vary according to three different implementations of the SVM approach: SVM, MB-SVM,  $k$ -LS-MB-SVM. The accuracies for the  $k$ -LS-MB-SVM method are obtained by taking the average of 10 repeated calculations with  $k=11$ .




Fig. 4 Average test accuracies for three different SVM implementations

From Figure 4 it is clear that the best performance for this data set is obtained with the MB-SVM method. The accuracies

for the SVM method are slightly smaller than the accuracies for the MB-SVM method. We note that the training data size for both methods is 105 whereas for the  $k$ -LS-MB-SVM method it consists only of 11 examples. Therefore, the  $k$ -LS-MB-SVM method yields comparable accuracies with only a small number of examples obtained from the clusters.

#### IV. DISCUSSION

Although  $k$ -means clustering has been applied with SVM in several studies, (see for example [6]) to the best of our knowledge there is no study in the literature that uses the same approach with MB-SVMs.

The preliminary findings of this study indicate that using  $k$ -means with the LS-MB-SVM method indeed helps to improve the computational performance of this method. In this study, we selected a fixed value for each train/test splitting. The results indicated that overall, the best choice (with respect to test accuracies) for the considered  $k$ -values was 11. We note here that in general increasing the  $k$  value also increases classification accuracies up to some threshold value. Therefore, using larger  $k$  values even higher classification accuracies for the  $k$ -LS-MB-SVM approach can be expected than the results given in Figure 4.

In this study, we only used a limited number of  $k$ -values because of time constraints. An alternative could be to choose a wider range of  $k$  values and selecting different  $k$  values for different training data sets. The results demonstrate that by using only a small number of examples obtained from the  $k$ -means clustering, comparable performance can be obtained. In addition, the time needed for classification is also considerable reduced with the introduced approach.

Another advantage of the proposed approach is that fine-tuning of the additional parameters resulting from the LS-MB-SVM approach can be addressed more effectively. We only used a fixed set of values for these parameters ( $c_1 = c_2 = c_t = 0.5$ ,  $v_1 = v_2 = v_3 = 1.0$ ). Fine-tuning of these and kernel function parameters may further improve classification accuracies.

#### V. CONCLUSION

The main objective of this study was to investigate the use of  $k$ -means clustering algorithm before applying LS-MB-SVM, as introduced by Wang et al. [6] for SVMs. The preliminary findings indicate that with appropriately chosen  $k$  values and cluster representatives as training examples the computational complexity of LS-MB-SVM can be reduced with comparable classification performance. Although the results of this study need to be verified with other data sets our preliminary findings show that the proposed approach is promising in improving the computational performance of the LS-MB-SVM method.

#### REFERENCES

- [1] V. Vapnik and A. Chervonenkis, *Theory of Pattern Recognition*, Nauka, Moscow, 1974.
- [2] G. Arslan, U. Madran, and D. Soyoğlu. "An Algebraic Approach to Clustering and Classification with Support Vector Machines," *Mathematics*, 10.1: 128, Jan. 2022.
- [3] Jayadeva, R. Khemchandani, and S. Chandra, "Twin Support Vector Machines for Pattern Classification", *IEEE Transactions on Pattern Analysis and Machine Intelligence.*, vol. 29 (5), pp. 905–910, May 2007.

- [4] Z.-X. Yang, Y.-H. Shao, and X.-S. Zhang, "Multiple birth support vector machine for multi-class classification" *Neural Comput & Applic*, 22 (Suppl 1), 153-161, 2013. doi: 10.1007/s00521-012-1108-x
- [5] S.-G. Chen and X.-J. Wu, "Multiple birth least squares support vector machine for multi-class classification" *Int. J. Mach. Learn. & Cyber.* 8, 1731-1742, 2017. doi: 10.1007/s13042-016-0554-7
- [6] J. Wang, X. Wu, and C. Zhang, "Support vector machines based on K-means clustering for real-time business intelligence systems", *International Journal of Business Intelligence and Data Mining*, 1(1), 54-64, 2005.
- [7] R. A. Fisher (1988) Iris. UCI Machine Learning Repository. <https://doi.org/10.24432/C56C76>.
- [8] R Core Team (2020). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>
- [9] Dimitriadou, E.; Hornik, K.; Leisch, F.; Chang, C.-C.; Lin, C.-C. Package 'e1071'. R Software Package. Available online: <https://cran.r-project.org/web/packages/e1071> (accessed on 14 August 2021).

# Mobil Manipulatörler için Derin Öğrenme Tabanlı Arıza Teşhis Sistemi

Zekican YILMAZ<sup>1\*</sup>, Tolga YÜKSEL<sup>1+</sup>

<sup>1</sup>Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi Elektrik Elektronik Mühendisliği

\*İlgili Yazar: zekican.yilmaz@tedu.edu.tr

\*Konuşmacı: zekican.yilmaz@tedu.edu.tr

+ tolga.yuksel@bilecik.edu.tr

**Özetçe** - Mobil manipulatörler, çeşitli endüstrilerde önemli bir rol oynamakta olup, üretim ve lojistikten sağlık hizmetleri ve felaket müdahalesine kadar birçok göreve katkı sağlamaktadır. Bu nedenle dünya genelinde çeşitli endüstriler büyüdükçe mobil manipulatörlerin de büyümesi gerekmektedir ve bu da güvenilir çalışmalarının büyük bir öneme sahip olmasını gerektirmektedir. Bu makale, mobil manipulatörler için derin öğrenme tekniklerini kullanarak arıza teşhis sisteminin geliştirilmesine yönelik yeni bir yaklaşım sunmaktadır. Geleneksel arıza teşhis yöntemleri, karmaşık kurallara dayalı bir sistem ve uzman bilgisi gerektirir ki bu da sürdürme ve geliştirme açısından zorlayıcı olabilir. Bu çalışmada robot mobil manipulatörün her bir eklemi modellenerek, modellenen eklemlere belirli hareketler yaptırılmıştır ve veriler kayda alınmıştır. Sonrasında elde edilen verilere belli oranlarda eklem arızası verilmiştir ve eklem arızaları her bir eklem için aynı zamanda verilmiştir. Arıza verilen eklemlerde derin öğrenme yöntemi kullanılarak, gerçeğe en yakın sonuç elde edilmeye çalışılmıştır, önerilen sistemde, özellikle evrimsel sinir ağları gibi derin öğrenme algoritmalarından yararlanarak, eklemlerine dayalı olarak arızaları otomatik olarak öğrenmiştir ve Kuka Youbot'un dinamikleri arıza teşhisi için kullanılmıştır. Arıza, eklemlerinden elde edilen verilerden tespit edilmiştir ve bu veriler, Yapay Sinir Ağı (YSA) kullanılarak bir karar yapısı aracılığıyla işlenerek karar verilmiştir.

**Abstract** – Mobile manipulators play a significant role in various industries, contributing to a wide range of tasks from production and logistics to health care and disaster response. As various industries grow globally, there's a corresponding need for the growth of mobile manipulators, emphasizing the importance of their reliable operation. This paper presents a novel approach to developing a fault diagnosis system for mobile manipulators using deep learning techniques. Traditional fault diagnosis methods rely on a complex rule-based system and expert knowledge, which can be challenging to maintain and develop. In this study, each joint of the robotic mobile manipulator was modeled, subjected to specific movements, and the data were recorded. Subsequently, joint failures were introduced to the collected data at certain ratios, and these failures were simultaneously applied for each joint. Using deep learning techniques on the joints with induced faults, efforts were made to obtain results closest to reality. The proposed system, deep learning algorithms like convolutional neural networks, automatically learns faults based on their joints. The dynamics of the Kuka Youbot were used for fault diagnosis. Faults were detected from the data obtained from its joints, and this data was processed through a decision structure using Artificial Neural Networks (ANN) to make a determination.

**Keywords** – hata teşhisi; yapay sinir ağı; mobil manipulatör

## I. GİRİŞ

Mobil manipulatörler, mobil platformların hareketliliğini kullanarak robot kol ile birleşmiş robotik sistemlerdir. İmalat uygulamaları bulunan büyük endüstrilerde çalışma alanına sahiptirler. Mobil manipulatörlerin yetenekleri olan, navigasyon ve hareketlilik kullanarak karmaşık görevleri yerine getirme özellikleri olduğu kabul edilmiştir, bu nedenle güvenli ve verimli işlem için hareket planlama tekniklerine ihtiyaç duyarlar. Birçok araştırmacı, bu teknikler için birçok yaklaşım bulmuşlardır ve bu tekniklerden bazıları şunlardır: mobil manipulatörün tüm eklemleri için ters kinematik öğrenme çerçevesi, bu teknikte fazla veri sorununu çözmek için, kolun ve mobilin her ikisinin de eklem açılarını bulmak gereklidir; bu, son hareketinin istenilen bir son yolunu takip etmesini sağlayacaktır [1], fakat veriler arttıkça yani hareket arttıkça mobil robotun önceki hareketi bulması ve açıları takip etmesi zorlaşacaktır. Bir diğer yöntem ise; Hareket Eden Bir Manipulatör için Kendi Kendine Çarpışma Önleme, kendi kendine çarpışma tespitini, proprioseptif veya eksteroseptif sensörler kullanarak algılaması ve reaktif olarak sensör tabanlı kaçınma hareketi üretmesi [2], fakat bu yöntemde de dikkat

çeken konu ise maliyet olacaktır, çünkü sensör maliyeti mobil robotun maliyetini arttıracaktır, öteki taraftan ise sensörlerde arıza meydana geldiğinde veya dış etmen kaynaklı problem görüldüğünde ekstra bakım gerektirmektedir. "İstatistiksel modelleme, makine öğrenimi ve hibrit gradyan artırma kullanarak robot kollarında arıza tespiti" çalışmasında belirtilen, Algoritma modelleme kültürü, genellikle en öngörücü modeli bulmaya odaklanmaktadır. Burada "kara kutu model" olarak adlandırılan bu model, karmaşık bir yapıya sahip olabilir ve birçok değişkeni kullanabilir. [3] tüm makine öğrenimini otomatikleştirmeyi amaçlar, özel gereksinimler eklendikçe Otomatik Makine Öğrenimi'ni zorlaştırır. Bu, ağı tahmin edilen çıkışları ile istenen çıkışlar arasındaki hata miktarını en aza indirmeyi amaçlayan tekrarlı bir algoritmadır [4]. Bu yaklaşım, çeşitli dizi-diziyi dönüştürme görevlerine uygulanabilen sinir ağları kullanarak dizi öğrenme için genel bir yaklaşım sunar. Bu yaklaşım, dizinin yapısı hakkında minimal varsayımlar yapılacak şekilde tasarlanmıştır. Günümüzde popüler olan ve uygulanan ise derin öğrenme tekniğidir, sistem davranışını inceleyerek hatayı erken tespit edebilir, maliyet bakımından da ekstra bakım gerektirmez,

aynı zamanda derin öğrenme yeni hata örgülerini tespit edebilir.

Veri analizi yapılırken, teknik bazlı model seçimi çalışma için önemlidir, bir durum bilgisinin sağlanması için Kalman filtresi kullanılır, Kalman filtresi giriş-çıkış bilgisine dayanan gerçek çıkış ve tahmini çıkışı karşılayıp durum bilgisi sağlar ve bu şekilde yorum yapılabilecek duruma gelinmiş olunur.

Bu çalışmada Kuka Youbot'un dinamikleri arıza teşhisi için kullanılmıştır. Kuka Youbot 5 serbestlik derecesinde ekleme sahiptir ve 4 adet mecanum tekerleği 45 derecelik açıyla hareket etmesine sağlar. Denavit Hartenberg parametreleri Kuka Youbot'un Matlab üzerinden modellenmesini sağlamaktadır.

Bu çalışmada, Kuka Youbot 5 serbestlik derecesine sahip eksenli mobil robot sisteminin veriye dayalı arıza teşhisi için LTSM ve NNT Levenberg-Marquardt algoritması arıza teşhis sistemi için kullanılmıştır.

İzleyen bölümde, 5 Eksenli mobil manipulatör modeli açıklanmaktadır, sonrasında modellenen mobil manipulatörün Bölüm B'de YSA ve Derin Öğrenme Kullanılarak Arıza Teşhisi'nin nasıl olacağı açıklanmaktadır. III. Bölüm'de sonuçlar, IV. Bölümde tartışma ve son olarak da V. Bölüm'de Özet bulunmaktadır.


## II. 5 EKSENLİ MOBİL MANİPÜLATÖR MODELİ

Bu çalışmada model olarak MATLAB'ta Denavit Hartenberg (DH) İleri (Forwards) ve Ters (Inverse) kinematik denklemleri kullanılarak Kuka Youtbot 5 eksenli mobil robot manipulatör modeli kullanılmıştır. Bu model 5 ekleme sahipken aynı zamanda 4 adet mecanum tekerleğe sahiptir, bu da modele hareketlilikte çeşitliliği sağlar. Bu modelde 5 eksenin ve 4 tekerleğin hareketleri ayrı ayrı dinamikleri ve çevresel etkileri de incelenebilir. Modelde 5 eklem ve 4 tekerlek, farklı durumlarda konumlandırılmış ve konumlandırılma esnasında yaptığı hareketlerden iki konfigürasyon arasındaki ortak uzay yörüngesi hesaplanmıştır. Yapılan çalışmada her bir eklem için PID kontrolcüsü kullanılmıştır. Şekil 1'de Kuka Youbot görünümü, Şekil 2'de ise koordinat yerleşimleri gösterilmiştir


Mobil robota dair DH parametreleri Tablo 1'de verilmiştir;

Tablo. 1 Kuka Youbot DH parametreleri

Eklem	$a$ (mm)	$\alpha$ (rad)	$d$ (mm)	$\theta$ (rad)
1	33	$\frac{\pi}{2}$	147	$\theta_1$
2	155	0	0	$\theta_2$
3	135	0	0	$\theta_3$
4	0	$\frac{\pi}{2}$	0	$\theta_4$
5	0	0	217,5	$\theta_5$



Şekil 1. Kuka Youbot Görünümü



Şekil 2. Koordinat Yerleşimi

Daha sonra da aşağıda gösterilen (1), (2), (3), (4) ve (5) DH tablosu kullanılarak, manipulatörün kinematik modeli bulunur.

$${}^0T_1(\theta_1) = \begin{bmatrix} \cos(\theta_1) & 0 & \sin(\theta_1) & 0.033\cos(\theta_1) \\ \sin(\theta_1) & 0 & -\cos(\theta_1) & 0.33(\sin(\theta_1)) \\ 0 & 1 & 0 & 0.147 \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (1)$$

$${}^1T_2(\theta_2) = \begin{bmatrix} \cos(\theta_2) & -\sin(\theta_2) & 0 & 0.155\cos(\theta_2) \\ \sin(\theta_2) & \cos(\theta_2) & 0 & 0.155(\sin(\theta_2)) \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (2)$$

$${}^2T_3(\theta_3) = \begin{bmatrix} \cos(\theta_3) & -\sin(\theta_3) & 0 & 0.135\cos(\theta_3) \\ \sin(\theta_3) & \cos(\theta_3) & 0 & 0.135(\sin(\theta_3)) \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (3)$$

$${}^3T_4(\theta_4) = \begin{bmatrix} \cos(\theta_4) & 0 & \sin(\theta_4) & 0 \\ \sin(\theta_4) & 0 & -\cos(\theta_4) & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4)$$

$${}^4T_5(\theta_5) = \begin{bmatrix} \cos(\theta_5) & -\sin(\theta_5) & 0 & 0 \\ \sin(\theta_5) & \cos(\theta_5) & 0 & 0 \\ 0 & 0 & 1 & 0.2175 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (5)$$

${}^mT_e$  aşağıdaki (6) şekilde tanımlanır:

$${}^mT_e = {}^0T_1(\theta_1) {}^1T_2(\theta_2) {}^2T_3(\theta_3) {}^3T_4(\theta_4) {}^4T_5(\theta_5) \quad (6)$$

Robot değişkeni  $q$  mobil manipülatörler için (7) şeklindedir:

$$q = [x_b \ y_b \ \theta_b \ \theta_1 \ \theta_2 \ \theta_3 \ \theta_4 \ \theta_5]^T \quad (7)$$

Eklem  $\theta_1$ - $\theta_5$  değerleri, manipülatörün eklem konfigürasyonudur,  $x_b \ y_b \ \theta_b$  mobil platformun sırasıyla konum ve yönelim değişkenleridir,


Bu denklem robotun anlık koordinatlarını verir ve robot eklem hareket yolları robotun her bir eklem için zaman içinde izlediği yolu tanımlamaktadır. Robot eklem hareket yollarının matematiksel ifade edilmesi için kuadratik polinom fonksiyonları kullanılmaktadır. Diğer çalışmalarda şu şekilde açıklanabilir; Endüstriyel robotun her eklem yörüngesi genellikle ikinci dereceden bir polinom fonksiyonu ile ifade edilecektir, dolayısıyla bu optimizasyon probleminde eklem sarsıntısı kısıtlaması dikkate alınacaktır [5]. Kuadratik polinom fonksiyonlarının kullanılıp robotun A noktasından B noktasına gittiği hareketin zamana bağlı değişimini verir ve endüstriyel robotların verimle ve güvenli bir biçimde çalışmasını sağlar, fakat bu çalışmada kuadratik polinom fonksiyonu veri almak amacıyla kullanılmıştır. Hareketin zamana bağlı değişimi kuadratik polinom ile (8)'deki şekilde ifade edilir:

$$P(x) = ax^2 + bx + c \quad (8)$$

Bu fonksiyon, robotun hareket edebileceği yolu temsil eder. Bu fonksiyonda  $x$  ile temsil edilen zaman veya başka bağımsız değişken olabilir, ama bu çalışmada  $P(x)$  robotun hızını ve konumunu temsil eder.

#### A. Manipülatör Eklemelerinin SIMULINK'te Modellenmesi ve Arıza Verisi Toplama

Modellenen manipülatör eklemelerinin Simulink gösterilimi Şekil 3'te verilmiştir,



Şekil 3. Simulink Eklem Modeli

Hazırlanan PID modelinde, PID kullanılarak mevcut hata oranıyla üretilen çıkışları geri besleme yaparak sisteme tekrardan gönderir ve integral ve türevinden faydalanarak biriken hataların zaman içindeki değişim oranına bağlı olarak sonraki gelecek hatayı tahmin eder bu sayede sistemde süreklilik sağlanır. Sürekliliğin sağlanmasında transfer fonksiyonda kullanılan  $J$  ve  $B$  verilerinin önemi büyüktür, modelleme esnasında mekanik terimleri temsil eder.  $J$  eylemsizlik momenti yani yapılan dönme hareketine karşı gösterilen dirençtir, bu direnç cismin kütleğine ve malzemesine bağlı olarak değişir, sistemin başlaması veya durması için ne kadar tork gerektiğinin hesabı yapılır.  $B$  ise viskoz sönüm katsayısıdır, bu da dönme hareketinin hızıyla birlikte olan enerji kaybını temsil eder.  $J$  ve  $B$  değeri modellenen sistemin gerçek tepkisinin nasıl olacağını tahmini için önemlidir. Aşağıdaki Tablo 2'de bu sistem için kullanılan her eklem için  $J$  ve  $B$  değerleri gösterilmiştir

Tablo 2. kullanılan sistemdeki eklem için  $J$  ve  $B$  değerleri


Eklem Adı	J Değeri	B Değeri
1. Eklem	0.006	40
2. Eklem	0.006	40
3. Eklem	0.006	20
4. Eklem	0.0814	8
5. Eklem	0.0734	20
6. Eklem (Sol ön tekerlek)	0.006	40
7. Eklem (Sol arka tekerlek)	0.006	40
8. Eklem (Sağ ön tekerlek)	0.006	40
9. Eklem (Sağ arka tekerlek)	0.006	40

PID kontrolü, manuel üretime ve PID'siz sistemlere kıyasla üretim hızını önemli ölçüde artırır. PID kontroller için tuning (ayarlar), kontrolcünün performansı açısından çok önemlidir. MATLAB tuning ayarını kendi fonksiyonu ile en iyi değeri otomatik olarak ayarlar. PID Tuning ile ayarlanmış eklemeler için PID katsayıları Tablo 3'te verilmiştir;

Tablo 3. Eklemelerin PID katsayıları

Eklem Adı	P Katsayısı	I Katsayısı	D Katsayısı
1. Eklem	53.503	712947.324	-0.00029
2. Eklem	53.503	712947.324	-0.00029
3. Eklem	26.751	178236.831	-0.00029
4. Eklem	10.700	2102.05599	-0.00395
5. Eklem	26.751	14569.768	-0.00356
6. Eklem (Sol ön tekerlek)	53.503	712947.324	-0.00029
7. Eklem (Sol arka tekerlek)	53.503	712947.324	-0.00029
8. Eklem (Sağ ön tekerlek)	53.503	712947.324	-0.00029
9. Eklem (Sağ arka tekerlek)	53.503	712947.324	-0.00029

Örnek; beşinci eklem için PID tuning sonrası grafiği Şekil 4'te gösterilmiştir;



Şekil 4. Beşinci eklem için Tuning sonrası basamak cevabı

PID parametreleri uygulandıktan sonra, her bir eklem için %30, %40, %50, %60 ve %70 oranında  $T=0.5$  anında arıza verilmiştir. Bu sayede arıza teşhis sisteminin test edilmesi için gereken temel hazırlanmıştır. Arızalar verildikten sonra, simulink'teki elde edilen veriler tek bir matris üzerinde oluşturulur ve oluşturulan matris şunları içerir; ilk satırda eklemdeki hareketin zamana bağlı değişimi, ikinci satırda PID sonrası tuning edilmiş veriler, üçüncü satırda transfer fonksiyonu bloğunun çıkışındaki veriler, dördüncü satırda  $1/s$  integratörü eklenir integratör, eklem dinamik hareketini (konumunu, hızını ve ivmesini) simüle etmek için



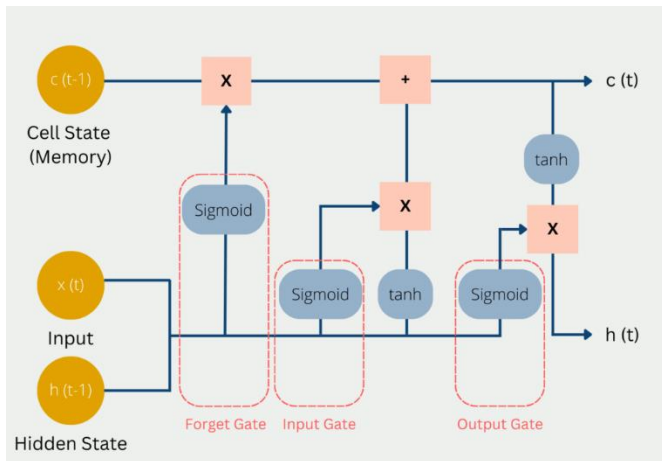
gereklidir ve son olarak 5. Satırda zaman bulunmaktadır. Böylece her bir eklem için  $5 \times 7379$  boyutlu veriler elde edilmiş ve uygulanmıştır.

### III. BENZETİM ÇALIŞMALARI

Bu çalışmada arıza teşhisi için neural network (NN) ve Long Short-Term Memory (LSTM) kullanılmıştır. Giriş verisi olarak PID çıkışlarından elde edilen  $5 \times 7379$  veriler her bir eklem için verilmiştir, çıkış olarak ise olması beklenen  $T=0.5$  anında arıza verilmeyen hareket verilmiştir, verilen giriş bilgileriyle doğru çıkışın tahmin edilmesi ve gerçek veriler ile arasındaki uyumun ölçülmesi buradaki amaç olarak tanımlanır. Özetle, amaç sistemin normal çalışma koşullarını öğrenerek ardından arızaları tespit veya tahmin etmek için LSTM veya NN modeli oluşturmak ve kullanmaktır. Daha sonra arızalı verilerin girişi modele verilir ve çıkış olarak tahminler üretilir. İlgili çalışmada da belirtildiği gibi; Burada arıza tespiti bir zaman serisi tahmin problemi olarak ele alınır [6]. Öğrenme algoritmalarının dikkatli seçilmesi için arızalı ve eğitilmiş eklem çıkışı başka eklemelerin çıkışına verilir benzerlik de tespit edilmiş olunur bu şekilde hem model genişlemiş olur hem de algoritma seçimi önem kazanmış olur.

Araç olarak, NN kullanılmıştır. YSA'da 3 katmanlı eğitim metodu olan Levenberh-Marguardt çalışılmıştır, aktivasyon fonksiyon tipi TANSIG olarak alınmıştır, nöron sayıları ilk iki katmanda 10 olarak seçilmiştir, bu da 10 adet giriş değişkeni olduğunu belirtir, ikinci katman ise gizli katmandır ağız öğrenme yeteneğini destekler bu katmanda da 10 nöron bulunur. Üçüncü katman ise ağız çıkış veren katmandır.

LSTM, YSA'da öğrenme zorluklarını aşmak için kullanılır, içinde ise tam bağlantılı katman ve regresyon katmanlarından oluşmuştur, Bu kapama birimlerinin tanıtılması, tüm zincir boyunca kolay bilgi akışını mümkün kılar, bu nedenle gradyanın kaybolma sorunu ortadan kaldırılabilir ve uzun süreli bağımlılıkları öğrenme yeteneğine sahip olabilir [7]. Giriş kapısı, yeni bilgiyi hafızaya almayacağını kararını verir, unutmaya kapısı; hafızada bulunan eski verilerden hangilerinin unutulacağına karar verir ve son olarak da çıkış kapısı hafızanın mevcut durumunu değerlendirerek hangi bilginin üretileceğine karar verir. Bir karar mekanizması olması gürültünün azaltılmasında da etki gösterir. Şekil 5'te LSTM yapısı basit olarak gösterilmiştir;




Şekil 5. LSTM Yapısı

Bu ağların eğitim sonucunda elde edilen MSE değerleri Tablo 4'te verilmiştir:


Tablo 4. MSE Değerleri

Eklem No:	NN MSE Değeri	LSTM MSE Değeri
1.Eklem	0.0078	0.0081
2.Eklem	0.0065	0.0112
3.Eklem	0.0075	0.0073
4.Eklem	0.0063	0.0784
5.Eklem	0.0069	0.0066
6.Eklem	0.0034	0.0021
7.Eklem	0.0092	0.0016
8.Eklem	0.0038	0.0021
9.Eklem	0.0057	0.0023


Arıza durumuna göre YSA veya LSTM kullanımı MSE değerlerinin yanında eğitim başarımı deneme yanılma ile de belirlenmiştir. Özellikle her iterasyonda ya da epoch'ta elde edilen MSE değerlerinin yakınsamasına da bakılmaktadır. Eğer MSE değeri her iterasyonda azalıyor, bu modelin eğitim verisine yakınsadığını gösterir. NN ile yakınsama örnekleri Şekil 6'da gösterilmiştir, grafikteki mavi çizgi gerçek durumu, kırmızı ise yakınsamayı göstermektedir;




Şekil 6.a. 1. Eklem yakınsama örneği




Şekil 6.a. 2. Eklem yakınsama örneği




Şekil 6.a. 3. Eklem yakınsama örneği




Şekil 6.a. 4. Eklem yakınsama örneği




Şekil 6.a. 5. Eklem yakınsama örneği




Şekil 6.a. 6. Eklem yakınsama örneği



Şekil 6.a. 7. Eklem yakınsama örneği



Şekil 6.a. 8. Eklem yakınsama örneği



Şekil 6.a. 9. Eklem yakınsama örneği

Önerilen arıza tespit sisteminin nasıl çalıştığını göstermek için robotun her bir eklemine 5 farklı hareket ve %70, %60, %50, %40 ve %30 oranında arıza verilmiştir aynı zamanda tekerleklerine de verilmiştir. Bu arızalar  $T=0.5$  anında verilmiştir, bu da 0.5 anında tekabül ettiği yerde bozulmaya başlamıştır.

#### IV. SONUÇ VE GELECEK ÇALIŞMALAR

Bu çalışmada Mobil Manipülâtörler için Derin Öğrenme Tabanlı Arıza Teşhis Sistemi üzerine odaklanılmıştır. Önerilen yöntem, modellenen mobil manipülâtörün hareket verilerini derinlemesine analiz ederek arıza teşhisini gerçekleştirmektedir. Bu analiz süreci, manipülâtörün eklemlerinde oluşan bozulmalara odaklanarak,  $T=0.5$  saniyede farklı oranlarda (%30, %40, %50, %60 ve %70) bozulma gösteren durumları kapsamaktadır. Bu çalışmada, toplamda 9 eklem için bu oranlardaki bozulmalar ayrı ayrı ele alınmıştır. Elde edilen veriler, derin öğrenme algoritmalarından olan NN ve LSTM ile işlenmiş, bu yöntemlerin manipülâtör eklemlerinde oluşan arızaları teşhis etmedeki başarısı değerlendirilmiştir. Sağlıklı kabul edilen veriler ile arızalı veri setleri karşılaştırıldığında, NN ve LSTM'nin eğitim süreçleri sonucunda belirli bir eşik değeri üzerinden arıza teşhisinde bulunduğu gözlemlenmiştir.

Sonuç olarak, bu çalışma mobil manipülâtörlerin arıza teşhis süreçlerinde derin öğrenme yöntemlerinin potansiyelini ortaya koymaktadır. Gelecekte, bu alandaki çalışmaların daha geniş veri setleri ve farklı derin öğrenme modelleri ile genişletilmesi, arıza teşhis süreçlerinin daha da optimize edilmesine katkıda bulunabilir.

#### KAYNAKLAR

- [1] R. Raja, A. Dutta, & B. DasGupta, "Learning framework for inverse kinematics of a highly redundant mobile manipulator", *Robotics and Autonomous Systems*, vol. 120, p. 103245, 2019
- [2] K. Jang, S. Kim, & J. Park, "Reactive self-collision avoidance for a differentially driven mobile manipulator", *Sensors*, vol. 21, no. 3, p. 890, 2021
- [3] Costa, M. A., Wullt, B., Norrlöf, M., & Gunnarsson, S., "Failure detection in robotic arms using statistical modeling, machine learning and hybrid gradient boosting.", *Measurement*, 146, 425-436, 2019.
- [4] I. Sutskever, O. Vinyals, Q. Le, "Sequence to sequence learning with neural networks", In *Proceedings of NIPS*, pages 3104–3112, 2014.
- [5] G. Xiaoqing, W. Jidong, "Trajectory planning theory and method of industrial robot," 2011 3rd International Conference on Computer Research and Development, Shanghai, China, pp. 340-343, 2011
- [6] T. Wang, L. Zhang and X. Wang, "Fault Detection for Motor Drive Control System of Industrial Robots Using CNN-LSTM-based Observers," in *CES Transactions on Electrical Machines and Systems*, vol. 7, no. 2, pp. 144-152, June 2023.
- [7] Han, P., Ellefsen, A. L., Li, G., Holmeset, F. T., & Zhang, H.. Fault detection with LSTM-based variational autoencoder for maritime components. *IEEE Sensors Journal*, 21(19), 21903-21912, 2021

# İleri Beslemeli Yapay Sinir Ağları için Donanım Uygulamasına Yatkın Çevrimiçi ELM Tabanlı Eğitim Algoritması

Önder Polat<sup>1\*</sup>, Sema Koç Kayhan<sup>1</sup>

<sup>1</sup>Elektrik-Elektronik Mühendisliği, Gaziantep Üniversitesi, Gaziantep, Türkiye  
\*(onderp@gantep.edu.tr)

**Özet** – Bu bildiri, ileri beslemeli tek gizli katmanlı yapay sinir ağları için donanım uygulamasına uyumlu olan ve seyrek düzenlenmiş bir aşırı öğrenme makinası (ELM) algoritması sunulmaktadır. Önerilen algoritma, düzenleme için geliştirilmiş minimaks konkav (GMC) ceza fonksiyonuna dayanmakta ve matris tersi alma veya norm hesaplaması gibi donanım mimarisi için karmaşıklığı arttıracak matematiksel işlemleri içermemektedir. Önerilen algoritma, çevrimiçi sıralı ELM (OS-ELM) algoritmasına benzer olarak, çevrimiçi öğrenmeyi destekleyecek şekilde değiştirilmiştir. Önerilen algoritma, UCI makine öğrenmesi veri deposundan alınan veri kümeleri ile test edilmiş ve genel olarak daha yüksek seyreklik seviyelerine ulaşmıştır. OS-ELM algoritmasına göre genellikle daha iyi sonuçlar vermiştir. Ek olarak, düzenleme ile artan seyreklik seviyeleri sayesinde, önerilen algoritma yapay sinir ağından gereksiz değişkenleri elemekte ve test verileri için tahmin doğruluğunu artırmaktadır.

**Anahtar Kelimeler** – Yapay Sinir Ağı, Çevrimiçi makine öğrenmesi, ELM, Donanım uygulaması

## I. GİRİŞ

Tek gizli katmanlı ileri beslemeli ağlar (SLFN'ler), kompakt yapıları ve iyi tahmin yetenekleri nedeniyle literatürde geniş bir şekilde incelenmiştir. İleri beslemeli yapay sinir ağları (FNN'ler) genellikle geriye yayılım (BP) yöntemleri kullanılarak eğitilmektedir. Ancak, bu yöntemler eğitim için gereken geriye yayılım adımı nedeniyle daha yavaş olma eğilimindedir. Aşırı Öğrenme Makinası (ELM), analitik olarak SLFN eğitimi için kullanılan çok hızlı bir algoritmadır [1], [2]. ELM algoritmasının hızlı eğitim özelliği, ağırlık ve sapma değerlerinin rastgele başlatılmasından kaynaklanır ve çıkış katmanı için analitik olarak çözümlenerek, gerekli ağırlık ve sapma değerleri bulunur. ELM algoritması ile bu rastgele atanan değerlerin geriye yayılım gibi tekrarlayan işlemlere ihtiyaç duyulmadan ağı eğitmek için kullanılabilirliği kanıtlanmıştır [3]. ELM literatürdeki benzer öğrenme algoritmaları ile de kıyaslanabilir bir performans sergilemektedir [3].

Pratik uygulamalara bakıldığında, yapay sinir ağına ekstra yük getiren ve performansını düşüren gereksiz değişkenler içeren veri setleri görülmektedir. Bu yapay sinir ağı için gereksiz karmaşıklığa neden olabilmekte ve eğitilen ağda aşırı öğrenme oluşabilmektedir. Ek olarak, genelleme performansını kötüleştirilebileceğinden ve tahmin hızını düşüreceğinden, eğitilen model aşırı derecede karmaşık da olmamalıdır. Bu sorunu aşmak için literatürde birçok çalışma önerilmiştir. Bu yöntemler genel olarak 2 ana gruba ayrılabilir: 1) Bilgi Kriterleri (IC) temelli budama, ve 2) Düzenleme temelli yöntemler. Budama temelli yöntemler, önceden belirlenmiş belirli bir IC'ye dayanarak gizli katman nöronlarının bazılarını kaldırmaktadır. Düzenleme temelli yöntemler, zarar fonksiyonuna bir ceza fonksiyonu tanıtarak bu problemi bir optimizasyon problemi olarak formüle etmeye ve optimizasyon yöntemlerini kullanarak çözmeye dayanır.

Bunlar, ağırlıkları normalleştirerek ve aşırı öğrenmeden kaçınmak için ağırlıkları düzenleyerek çıkış parametrelerini düzenleyen bir dizi tekniktir. Ceza fonksiyonun türüne bağlı olarak çıkış ağırlık parametrelerinin çoğu sıfır değerini alabilir ve seyrek bir yapıya ulaşabilir.

Geleneksel ELM, eğitim süreci başlamadan önce tüm eğitim verilerinin mevcut olduğunu varsaymaktadır. Ancak, bazı pratik uygulamalarda eğitim verileri sıralı olarak gelebilmektedir. Bu durumda tüm veriler önceden toplu olarak hazır bulunmayabilir. Bu durum, yapay sinir ağına her yeni veri örneği için ek kaynaklar (örneğin bellek, hesaplama gücü vb.) kullanmadan eğiten çevrimiçi makine öğrenme algoritmalarını gerektirmektedir. Ayrıca, bu algoritmaların bu dinamik eğitim sürecini etkili bir şekilde yönetmesi ve ilgili uygulamanın gerçek zamanlı gereksinimlerini karşılaması gerekmektedir. Bu tür sistemlerin avantajı; kaynak kullanımının eğitim başlamadan önce bilinmesi ve sabit olması, ayrıca sisteme yeni bir veri örneği geldiğinde, ağı eğitmeye devam ederken sınıflandırma sonuçlarını da sunabilmesidir. Böyle bir sistemin hesaplama gereksinimi yüksek olacağından, özelleştirilmiş donanım geliştirilmesi ve paralel hesaplama yapılması gibi konular bir gereksinim haline gelmektedir.

Bu nedenle, bu bildiri kapsamında; donanım uygulamasına da yatkın olan bir çevrimiçi makine öğrenme algoritması geliştirilmesi hedeflenmiştir. Bu amaçla, ELM algoritması tabanlı bir seyrek çevrimiçi öğrenme algoritması önerilmiştir. Önerilen algoritma, konveks olmayan bir ceza fonksiyonu ile optimizasyon yaparak, çıkış katmanındaki ağırlıkları düzenlemekte ve seyrekleştirmektedir. Ayrıca algoritma modifiye edilerek sıralı verilerle çevrimiçi öğrenmeye uygun hale getirilmiştir. Önerilen algoritma, yalnız gizli katman matrisini ve etiket vektörünü kullanmakta ve donanım

uygulamasına çok uygun olmayan matris tersi alma işlemi gibi işlemler içermemektedir. Bu özellikleriyle de donanım uygulamasına yatkın bir algoritmadır. Önerilen algoritmanın test verileri için doğruluk oranları da incelenmiş ve klasik ELM algoritmalarına göre yeterli seviyede sonuç verdiği görülmüştür.

Bildirinin geri kalanı aşağıdaki şekilde düzenlenmiştir: Bölüm 2’de mevcut literatürde bulunan önemli çalışmalar açıklanmıştır. Bölüm 3’te, önerilen seyrek ELM algoritması sunulmuştur. Bölüm 4’te önerilen algoritmanın çeşitli veri kümeleri üzerindeki performansı değerlendirilmiştir. Bildiri, Bölüm 5’te sonuçlanmaktadır.

## II. MEVCUT LİTERATÜR

Bu bölümde, literatürde mevcut önemli çalışmalar sunulacaktır. ELM algoritmasının regresyon ve sınıflandırma için önerilen çeşitli uzantıları bulunmaktadır. Bu bildiri kapsamında, ELM ağının düzenlenmesi ve budanması ile ilgili çalışmalar ana odak noktası olmuştur. ELM algoritması gizli katmanı rastgele oluşturduğu için geleneksel sinir ağlarına göre daha fazla gizli nöron gerektirmektedir. Artan gizli katman nöron sayısı performansı kısıtlamakta, aşırı öğrenmeye sebebiyet vermekte ve sınıflandırma süresi uzamaktadır. Bu nedenle, ağın karmaşıklığını azaltma konusu mevcut literatürde büyük ilgi çekmektedir.

### A. Budama temelli yöntemler

[4]’te sunulan çalışma, optimize edilmiş budama ELM (OP-ELM) olarak adlandırılmıştır. OP-ELM, mevcut gizli nöronları en küçük açılı regresyonu (LARS) algoritması temel alarak sıralamaktadır. LARS,  $l_1$  düzenleme yapan bir algoritmadır [5]. Sıralama işleminden sonra nöronlar çapraz doğrulama (CV) ile budanmaktadır. Özellikle büyük veri kümeleri için çapraz doğrulama (CV) süreci zaman alıcı olduğundan, [4]’ün yazarları, her veri örneği için CV olarak tanımlanabilecek LOO-CV’nin kapalı form bir sürümünü kullanmakta ve buna tahmin karelerin toplamı (PRESS) demektelerdir. Her nöronu LOO-CV sürecine dahil ederek, en düşük hataya sahip sayıyı seçerek bunu en iyi gizli nöron sayısı olarak kullanmaktadırlar. Sunulan yöntem küçük veri kümeleri için etkilidir, ancak LOO-CV adımı nedeniyle büyük veri kümeleri için eğitim süresi çok yavaştır. Başka bir budama tabanlı ELM de [6]’da önerilmiştir. Burada gizli nöronlar üç farklı IC’ye dayalı olarak budanmaktadır; Ki-kare, bilgi kazancı (IG) ve Akaike Bilgi Kriteri (AIC). İlk olarak, gizli katman matrisi  $H$  rastgele ağırlıklar ve eğitim verileri ile oluşturularak, temel ELM yapısı elde edilmektedir. Daha sonra, her gizli düğümün istatistiksel ilişkisi IC'lere dayalı olarak hesaplanmaktadır. Kullanıcı tarafından verilen bir ilişki eşiği, ağdaki önemli nöronları tanımlamak için kullanılmaktadır. Son adımda, aynı zamanda minimum AIC değerine sahip nöronları bulmak için doğrulama kullanılmaktadır. Son olarak, seçilen nöronlar ağı son kez eğitmek için kullanılmaktadır. P-ELM test verileri için iyi isabet oranlarına ulaşmaktadır, ancak diğer ELM uzantılarına göre ağın eğitim süresi hala yavaştır. [7]’deki çalışmada yine PRESS formülü kullanılmıştır. Yazarlar LOO-CV hesaplaması için sıralı bir yöntem önermişlerdir. Her gizli nöron ağı sırayla eklenmekte ve LOO-CV formülü sırayla güncellenmektedir. En iyi nöron sayısı, yazarlar tarafından önerilen bir erken durdurma kriterini kullanarak belirlenir. Veri kümeleri için daha iyi olan verimli LOO-CV tabanlı ELM

(ELOO-ELM), OP-ELM ve P-ELM algoritmalarından daha iyi sonuç vermektedir, ancak büyük veri kümeleri için hala yavaştır.

Yukarıda bahsedilen ve temelde CV tabanlı olan bu yöntemler, hem norm hesaplamaları için karmaşık işlemler içermeleri hem de CV nedeniyle bütün veri setinin baştan hazır olmasını istediklerinden, çevrimiçi uygulamalara ve donanım uygulamasına yatkın değildir.

### B. Düzenlemeye dayalı yöntemler

Seyrek yapay sinir ağı elde etmek için, optimizasyonda kullanılan farklı normlar arasında, en yaygın uygulanan seyrek düzenleme yöntemleri şunlardır:  $l_0$ -norm ile seyrek düzenleme,  $l_1$ -norm ile seyrek düzenleme,  $l_2$ -norm ile seyrek düzenleme ve karışık norm minimizasyonu ( $l_{2,1}$ ). Bir lineer denklemler sistemi ( $y = Ax$ ), optimizasyon kullanılarak seyrek bir şekilde çözülebilir. Genellikle, düzenlenmiş en küçük kareler maliyet fonksiyonu, şu şekilde bir ceza fonksiyonu ile minimize edilmektedir:

$$\arg \min_x f(x) = \|y - Ax\|_2^2 + \lambda \psi(x) \quad \lambda > 0 \quad (1)$$

$l_1$ -norm, genellikle makine öğrenimi sorunlarını çözmek için düzenleme yapmak için yaygın olarak kullanılmaktadır.  $l_1$ -norm, genellikle aşağıdaki optimizasyon problemi tanımlanarak kullanılmaktadır:

$$\arg \min_x f(x) = \|y - Ax\|_2^2 + \lambda \|x\|_1 \quad \lambda > 0 \quad (2)$$

Başka bir olası yaklaşım ise Tikhonov düzenlemesi (veya ridge regresyon) olarak adlandırılan yöntemi kullanmaktır. Bu yöntemde, aşağıdaki formülasyon kullanılarak  $l_2$ -norm minimizasyonu yapılmaktadır:

$$\arg \min_x f(x) = \|y - Ax\|_2^2 + \lambda \|x\|_2^2 \quad \lambda > 0 \quad (3)$$

$l_2$ -norm minimizasyonu, katsayıları küçültür ve ağın karmaşıklığını azaltır, ancak seyreklik özellikleri,  $l_1$ -norm minimizasyonuna göre zayıftır.  $l_1$ -norma göre daha iyi sonuçlar vermektedir.  $l_2$ -norm, verideki aykırı değerlere karşı hassastır, çünkü ridge regresyon, artık değişkeninde biriken hataların karesini almaktadır. Öte yandan,  $l_1$ -norm, bu hata değerlerinin sadece mutlak değerini alır, bu nedenle bu tür aykırı değerlere karşı dayanıklıdır.

[8]’de sunulan çalışmada, OP-ELM algoritmasına dayanan  $l_2$ -norm temelli bir düzenleme önerilmiştir. OP-ELM’deki  $l_1$ -norm sıralama adımının yanı sıra, Tikhonov düzenlemeli OP-ELM (TROP-ELM) algoritması,  $l_2$ -norm kullanarak çıkış ağırlıklarını düzenlemekte ve hızlı matris hesaplaması için PRESS istatistiğinin değiştirilmiş bir versiyonunu kullanmaktadır. Yazarlar, regresyon veri kümeleri için karşılaştırmalı sonuçlarını sunmuştur. Hata oranları OP-ELM’den daha iyidir, ancak eğitim süreleri OP-ELM’den daha yavaştır. Ayrıca, sonuçlar yalnızca regresyon durumu için sunulmuş olup sınıflandırma görevi için herhangi bir bilgi verilmemiştir.

Literatürde çevrimiçi çalışan ve düzenleme kullanan birçok algoritma da önerilmiştir[9]–[12]. Düzenleme kullanan birçok çalışma olmasına karşın, çevrimiçi olanlar da dahil, donanım uygulamasına yatkın değildir. Matris tersi işlemi, norm hesaplaması, karekök vb. işlemler içeren bu algoritmalar, olası bir donanım tasarımı sürecinde donanımın karmaşıklığını oldukça arttıracak ve hesaplama performansını düşürecektir. Bu nedenle, donanıma yatkın algoritmalara ihtiyaç duyulmaktadır.

### III. ÖNERİLEN ÇEVİRİMİÇİ ELM ALGORİTMASI

ELM algoritmasında,  $T = H\beta$  şeklindeki sistemde çıkış ağırlık vektörü  $\beta$ , gizli katman matrisi  $H$ 'nin yalancı-ters matrisi ile etiket matrisi  $T$  birlikte kullanılarak şu şekilde hesaplanmaktadır:

$$\beta = (H^T H)^{-1} H^T T \quad (4)$$

Gizli katman matrisi  $H$ , aktivasyon fonksiyonu  $G(w, x, b)$  kullanılarak şu şekilde tanımlanabilir:

$$H(x) = \begin{bmatrix} G(w_1 \cdot x_1 + b_1) & \dots & G(w_L \cdot x_1 + b_L) \\ \vdots & & \vdots \\ G(w_1 \cdot x_N + b_1) & \dots & G(w_L \cdot x_N + b_L) \end{bmatrix}_{N \times L} \quad (5)$$

ELM'deki gizli katman nöronları, eğitim verileri yapay sinir ağına sunulmadan önce rastgele oluşturulmaktadır. Temel ELM algoritması, eğitim sürecinden önce tüm eğitim verilerinin hemen kullanılabilir olduğunu varsayar. Bazı pratik uygulamalarda ise eğitim verileri sıralı olarak sunulmaktadır ve önceden mevcut değildir. Ayrıca, sıralı olarak gelecek verinin örnek sayısı olarak büyüklüğü bilinmemektedir. Bu nedenle, yapay sinir ağı mimarisi hem algoritma kısmında teorik olarak hem de donanım kısmında pratik olarak bu koşulu desteklemelidir. Bu amaçla, ELM algoritmasının çevrimiçi sürümü olan OS-ELM, [16]'da önerilmiştir. OS-ELM, eğitim verilerini birer birer veya gruplar halinde öğrenebilmektedir ve öğrenme işleminden sonra verileri atmaktadır. OS-ELM algoritmasının, sisteme kaç eğitim örneğinin gireceğini önceden bilmesine gerek yoktur. OS-ELM algoritması, orijinal ELM algoritmasına dayanmaktadır ve onun özinelemeli hesaplamayı destekleyen versiyonudur. Özetlemek gerekirse, OS-ELM sıralı şekilde gelen her veri grubu için aşağıdaki işlemleri yapar:

$$K_0 = H_0^T H_0 \quad (6)$$

$$\beta_0 = (H_0^T H_0)^{-1} H_0^T T_0 \quad (7)$$

$$K_{k+1} = K_k + H_{k+1}^T H_{k+1} \quad (8)$$

$$\beta_{k+1} = \beta_k + K_{k+1}^{-1} H_{k+1}^T (T_{k+1} - H_{k+1} \beta_k) \quad (9)$$


#### A. Önerilen seyrek düzenlenmiş çevrimiçi ELM algoritması

$l_1$ -norm kullanılarak  $T = H\beta$  doğrusal sistemi için seyrek yaklaşık bir çözüm bulunabilir.  $l_1$ -norm, en seyrek çözümü sağladığı için genellikle düzenleme için ilk tercih edilen seçenektir. Ancak,  $l_1$ -norm yüksek genlikli bileşenleri daha fazla baskıladığı için bu bileşenlerin sisteme katkılarını sınırlayabilmektedir [13].  $l_1$ -norm'un sınırlamalarını aşmanın yollarından biri, düzenleme için konveks olmayan ceza fonksiyonlarını kullanmaktır [14]. Bu tür bir fonksiyon, minimaks konkav (MC) ceza fonksiyonudur[15]:

$$\psi(x) = \begin{cases} |x| - \frac{1}{2}x^2, & |x| \leq 1 \\ \frac{1}{2}, & |x| \geq 1 \end{cases} \quad (10)$$

$l_1$ -norm,  $l_2$ -norm ve MC ceza fonksiyonlarını Şekil 1'de gösterilmektedir. MC ceza fonksiyonunun genelleştirilmiş hali olan (GMC), Huber fonksiyonu kullanılarak [16] nolu çalışmada önerilmiştir.  $b$  ölçeklendirme parametresi olmak üzere, ölçekli Huber fonksiyonu aşağıdaki gibidir:


$$s_b(x) = \begin{cases} |x| - \frac{1}{2b^2}x^2, & |x| \geq 1/b^2 \\ \frac{1}{2}b^2x^2, & |x| \leq 1/b^2 \end{cases} \quad (11)$$



Şekil 1: MC, L1 ve L2 ceza fonksiyonları

GMC ise şu şekilde tanımlanmaktadır:

$$\psi_B(x) = \|x\|_1 - s_B(x) \quad (12)$$



Şekil 2: Farklı ölçek değerleri için GMC ceza fonksiyonu

Bu nedenle, GMC,  $x$ 'in mutlak değerinden ( $l_1$ -norm) genelleştirilmiş Huber fonksiyonunu çıkartarak elde edilir. GMC ceza fonksiyonu,  $l_1$ -norm'un konveks özelliğini korurken seyrekliği güçlü bir şekilde teşvik etmektedir. GMC

ceza fonksiyonunun ölçekli versiyonu Şekil 2'de görselleştirilmiştir. Şekil 2'de GMC ceza fonksiyonunun küçük değerleri büyük değerlerden daha az baskılandığı gözlenmektedir, ancak bu baskılama  $l_1$ -norm kadar şiddetli değildir.

GMC ceza fonksiyonuyla ELM algoritması için optimizasyon problemi şu şekilde ifade edilebilir:

$$\arg \min_{\beta} g(\beta) = \|T - H\beta\|_2^2 + \lambda \psi_B(\beta) \quad (13)$$

Burada  $\lambda$ , düzenleme parametresidir.  $g(\beta)$  maliyet fonksiyonu olmak üzere, bu optimizasyon problemi ileri-geri yer değiştirme algoritması (FBS) kullanılarak çözülebilmektedir. FBS kullanarak çözebilmek için, optimizasyon problemi eyer noktası problemi olarak şu şekilde tanımlanmaktadır[16], [17]:

$$\arg \min_{x, \sigma} g(\beta, \sigma) = \|T - H\beta\|_2^2 + \lambda \|\beta\|_1 - \lambda \|\sigma\|_1 - \frac{\gamma}{2} \|H(\beta - \sigma)\| \quad (14)$$

#### Algoritma 1 FBS Algoritması

**Girdi:**

$\rho: \max\{1, \gamma/(1 - \gamma)\} \|A^T A\|_2$   
 $\mu: 0 \leq \mu \leq 2/\rho$   
 $\gamma: 0 \leq \gamma \leq 1$   
 $\lambda: \lambda > 0$   
 $K$ : Maksimum yineleme sayısı.  
 $A: A \in R^{M \times N}$   
 $y: y \in R^M$

**Çıktı:**

$x: x \in R^N$   
1:  $x$  ve  $v$  için başlangıç değerlerini sıfır yap.  
2: **for**  $i = 1$  to  $K$  **do**  
3:  $w_i = x_i - \mu A^T (A(x_i + \gamma(v_i - x_i)) - y)$   
4:  $u_i = v_i - \mu \gamma A^T A(v_i - x_i)$   
5:  $x_{i+1} = \text{soft}(w_i, \mu\lambda)$   
6:  $v_{i+1} = \text{soft}(u_i, \mu\lambda)$   
7: **end for**

FBS algoritması yalnızca yumuşak eşikleme operatörünü ve  $A^T A$  ve  $A^T y$  matrislerinin çarpımını içermektedir. Parametreler  $\lambda$  ve  $\gamma$  kontrol edilerek, (14) denklemi içindeki optimizasyon problemi için seyrek bir çözüme ulaşılabilir. GMC ceza fonksiyonunu kullanan FBS algoritması, ELM algoritması için çıkış ağırlık vektörü  $\beta$ 'yi düzenlemek için kullanılabilir. Yalnızca matrisler  $A$ ,  $A^T$  ve  $y$ 'nin çarpımını içerdiğinden ve matris tersi işlemi gerektirmediğinden, donanım uygulaması için oldukça uygun iyi bir algoritmadır.

FBS algoritmasını çevrimiçi öğrenmeyi destekleyecek şekilde modifiye etmek için, matrisler  $H^T H$  ve  $H^T T$ 'nin özyinelemeli formleri türetilmiştir. Başlangıç veri örnekleriyle, gizli katman matrisinin  $H_0$  ve hedef matrisinin  $T_0$  olduğu varsayılırsa, yeni bir eğitim veri örneği  $(x_1, t_1)$  geldiğinde, yeni gizli katman matrisi  $H_1$  şu şekilde tanımlanır:

$$H_1 = \begin{bmatrix} H_0 \\ h_1 \end{bmatrix} \quad (15)$$

$$C = [H_0^T h_1^T] \begin{bmatrix} H_0 \\ h_1 \end{bmatrix} = [H_0^T H_0 + h_1^T h_1] \quad (16)$$

$$D = [H_0^T h_1^T] \begin{bmatrix} T_0 \\ t_1 \end{bmatrix} = [H_0^T T_0 + h_1^T t_1] \quad (17)$$

Yeni bir veri örneği  $(x_i, t_i)$  geldiğinde, matrisler  $C_1$  ve  $D_1$  için özyinelemeli formler aşağıdaki gibi tanımlanabilir:

$$C_1 = C_0 + h_1^T h_1 \\ D_1 = D_0 + h_1^T t_1$$

Bu özyinelemeli formleri kullanarak önerilen, seyrek düzenlenmiş çevrimiçi ELM algoritması (SDÇ-ELM), Algoritma 2'de verilmiştir.

#### Algoritma 2 SDÇ-ELM Algoritması

**Girdi:**

**Parametreler:**  $\gamma, \lambda, 0 \leq \mu \leq 2/\rho$ , and  $L$ .  
 $T_0$ :  $N_0 \times m$  boyutlu başlangıç etiket matrisi.  
 $H_0$ :  $N_0 \times L$  boyutlu başlangıç gizli katman matrisi.  
 $R$ : Maksimum yineleme sayısı.

**Çıktı:**

$\beta$ :  $L \times m$  boyutlu çıkış ağırlık matrisi  
 $\beta$  ve  $\sigma$  için başlangıç değerlerini sıfır yap.  
**Başlangıç Aşaması:**  
1:  $H_0$  matrisini başlangıç veri örneği sayısı  $N_0$  için hesapla.  
2: **for**  $i = 1$  to  $R$  **do**  
3:  $\delta_i = \beta_{i-1}^{(0)} - \mu H_0^T (H_0(\beta_{i-1}^{(0)} + \gamma(\sigma_{i-1} - \beta_{i-1}^{(0)})) - T_0)$   
4:  $\eta_i = \sigma_{i-1} - \mu \gamma H_0^T H_0(\sigma_{i-1} - \beta_{i-1}^{(0)})$   
5:  $\beta_i^{(0)} = \text{soft}(\delta_i, \mu\lambda)$   
6:  $\sigma_i = \text{soft}(\eta_i, \mu\lambda)$   
7: **end for**  
**Sıralı Öğrenme Aşaması:**  
8: **for**  $k = 1, 2, 3, \dots$  **do**  
9:  $C_k = C_{k-1} + h_k^T h_k$   
10:  $D_k = D_{k-1} + h_k^T t_k$   
11:  $\delta_k = \beta_{k-1} - \mu (C_k(\beta_{k-1} + \gamma(\sigma_{k-1} - \beta_{k-1})) - D_k)$   
12:  $\eta_k = \sigma_{k-1} - \mu \gamma C_k(\sigma_{k-1} - \beta_{k-1})$   
13:  $\beta_k = \text{soft}(\delta_k, \mu\lambda)$   
14:  $\sigma_k = \text{soft}(\eta_k, \mu\lambda)$   
15: **end for**  
16: **return**  $\beta_k$

#### IV. DENEYSEL SONUÇLAR

Önerilen algoritmanın performansı, literatürde genellikle kıyaslama amacıyla kullanılan veri kümeleri ile test edilmiştir. Sınıflandırma problemleri için doğruluk oranı ve regresyon problemleri için kök ortalama kare hata (RMSE) ölçütleri baz alınmış ve UCI makine öğrenmesi veri deposundan sekiz veri seti kullanılmıştır[18]. Kullanılan veri kümeleri Tablo 2'de verilmiştir. Bu çalışmada amaç donanım mimarisine uygun bir algoritma önermek olduğundan, önerilen algoritma klasik ELM algoritmaları ile karşılaştırılarak yeterli performans verip vermediği ve seyreklik özelliği incelenmiştir.

Deneylerde tüm veri kümeleri için maksimum gizli nöron sayısı 100 olarak ayarlanmıştır. SDÇ-ELM için düzenleme parametreleri manuel olarak ayarlanmış ve en

iyi parametreler seçilmiştir. OS-ELM ve SDC-ELM için sıralı eğitim adımında her yineleme için örnek kümesi büyüklüğü veri setinin yüzde 10'u olarak alınmıştır. Her veri kümesi için

Tablo 1. ELM, OS-ELM ve SDC-ELM için RMSE, doğruluk oranı ve eğitim süresi karşılaştırması

Veri Seti	Algoritma	Eğitim Süresi (s)	RMSE/Doğruluk Oranı	Nöron Sayısı
Breast Cancer	ELM	0.0040	0.9412	100
	OS-ELM	0.0085	0.9344	100
	SDC-ELM	0.0423	0.9373	74
Diabetes	ELM	0.0044	0.7359	100
	OS-ELM	0.0082	0.5379	100
	SDC-ELM	0.0443	0.7407	87
Iris	ELM	0.0029	0.5911	100
	OS-ELM	0.0056	0.4822	100
	SDC-ELM	0.0306	0.9244	40
Segments	ELM	0.0082	0.8960	100
	OS-ELM	0.0154	0.7831	100
	SDC-ELM	0.0872	0.8955	81
Abalone	ELM	0.0125	0.2658	100
	OS-ELM	0.0363	0.1006	100
	SDC-ELM	0.2466	0.1344	100
Body-fat	ELM	0.0023	0.0053	100
	OS-ELM	0.0054	0.0039	100
	SDC-ELM	0.2209	0.0046	45
Auto P.	ELM	0.0023	0.0529	100
	OS-ELM	0.0056	0.0104	100
	SDC-ELM	0.1347	0.0448	60
Boston H.	ELM	0.0039	0.0360	100
	OS-ELM	0.0075	0.0201	100
	SDC-ELM	0.1076	0.0289	64

50 deneme yapılmış ve 5 katlı CV için ortalama değerler rapor edilmiştir. Çevrimiçi algoritmalar için başlangıç örnek boyutu 100 örnek olarak ayarlanmıştır. Her denemede başlangıç ağırlık değerleri rastgele olarak belirlendiğinden, sabit bir tohum değeri belirlenerek her algoritma için aynı değerlerin kullanılması sağlanmıştır. Tablo 1'de eğitim süresi, test seti için tahmin performansı (doğruluk oranı ve RMSE) ve kullanılan nöron sayısı (seyreklik) sonuçları sunulmuştur. Tablo 1'den görüleceği üzere, önerilen SDC-ELM algoritması OS-ELM'ye göre genellikle daha iyi doğruluk oranlarına ulaşmıştır. Özellikle sınıflandırma veri setleri için daha yüksek sonuçlar sergilemiştir. Genel olarak değerlendirildiğinde ELM ve OS-ELM'ye yakın veya daha iyi performans vermiştir. ELM ve OS-ELM'nin performansı bazı veri setlerinde düşerken, önerilen algoritma her veri seti için stabil sonuçlar sunmuştur. Bunun en önemli nedeni düzenleme yapma kabiliyetine sahip olmasıdır. SDC-ELM'nin eğitim süreleri, düzenleme adımları nedeniyle daha uzun süre de donanım mimarisine uygun bir algoritma olduğu için, olası bir donanım uygulamasında klasik ELM algoritmalarına göre daha hızlı çalışacaktır. Böyle bir donanım mimarisi matris ters alma işlemi gibi işlemler de içermeyeceğinden daha sade bir mimari elde edilecektir. Seyreklik bakımından incelendiğinde ise, SDC-ELM'nin daha seyrek yapıda bir yapay sinir ağı oluşturduğu görülmektedir.

## V. SONUÇ

Sonuç olarak, önerilen çevrimiçi ELM algoritması donanım uygulamaları için uygun ve seyrek düzenleme kabiliyetine sahip bir algoritmadır. Yapılan deneyler,

önerilen algoritmanın test veri kümeleri üzerinde daha yüksek seyreklik seviyeleri ve genellikle daha iyi performans sağladığını göstermektedir. Seyreklik seviyelerinin artırılması, yapay sinir ağlarının gereksiz değişkenlerden arındırılmasına ve test verileri için tahmin doğruluğunun artırılmasına olanak tanımaktadır. Gelecekte, önerilen algoritmanın daha fazla veri kümesi ile ayrıntılı performans analizleri yapılabilir. Ayrıca, önerilen algoritmanın programlanabilir donanımlar üzerinde donanım mimarisi olarak gerçekleştirilmesi de muhtemel çalışmalarındadır.

Tablo 2.Çalışmada kullanılan veri setleri

Veri Seti	Öznitelikler	Örnek Sayısı	Tür
Breast Cancer	10	683	İkili Sınıflandırma
Abalone	8	4177	Regresyon
Segments	20	3000	Çoklu Sınıflandırma
Iris	5	150	Çoklu Sınıflandırma
Diabetes	9	768	İkili Sınıflandırma
Body Fat	15	252	Regresyon
Auto Price	16	160	Regresyon
Boston Housing	14	506	Regresyon

#### KAYNAKLAR

- [1] G. B. Huang, H. Zhou, X. Ding, ve R. Zhang, “Extreme Learning Machine for Regression and Multiclass Classification”, *IEEE Trans. Syst. Man Cybern. Part B Cybern.*, c. 42, sy 2, ss. 513-529, Nis. 2012, doi: 10.1109/TSMCB.2011.2168604.
- [2] G.-B. Huang, D. H. Wang, ve Y. Lan, “Extreme learning machines: a survey”, *Int. J. Mach. Learn. Cybern.*, c. 2, sy 2, ss. 107-122, Haz. 2011, doi: 10.1007/s13042-011-0019-y.
- [3] G.-B. Huang, Q.-Y. Zhu, ve C.-K. Siew, “Extreme learning machine: Theory and applications”, *Neurocomputing*, c. 70, sy 1, ss. 489-501, Ara. 2006, doi: 10.1016/j.neucom.2005.12.126.
- [4] Yoan Miche, A. Sorjamaa, P. Bas, O. Simula, C. Jutten, ve A. Lendasse, “OP-ELM: Optimally Pruned Extreme Learning Machine”, *IEEE Trans. Neural Netw.*, c. 21, sy 1, ss. 158-162, Oca. 2010, doi: 10.1109/TNN.2009.2036259.
- [5] B. Efron, T. Hastie, I. Johnstone, ve R. Tibshirani, “Least angle regression”, *Ann. Stat.*, c. 32, sy 2, ss. 407-499, Nis. 2004, doi: 10.1214/009053604000000067.
- [6] H.-J. Rong, Y.-S. Ong, A.-H. Tan, ve Z. Zhu, “A fast pruned-extreme learning machine for classification problem”, *Neurocomputing*, c. 72, sy 1-3, ss. 359-366, Ara. 2008, doi: 10.1016/j.neucom.2008.01.005.
- [7] Z. Shao, M. J. Er, ve N. Wang, “An Efficient Leave-One-Out Cross-Validation-Based Extreme Learning Machine (ELOO-ELM) With Minimal User Intervention”, *IEEE Trans. Cybern.*, c. 46, sy 8, ss. 1939-1951, Ağu. 2016, doi: 10.1109/TCYB.2015.2458177.
- [8] Y. Miche, M. van Heeswijk, P. Bas, O. Simula, ve A. Lendasse, “TROP-ELM: A double-regularized ELM using LARS and Tikhonov regularization”, *Neurocomputing*, c. 74, sy 16, ss. 2413-2421, Eyl. 2011, doi: 10.1016/j.neucom.2010.12.042.
- [9] Ö. Polat ve S. K. Kayhan, “GPU-accelerated and mixed norm regularized online extreme learning machine”, *Concurr. Comput. Pract. Exp.*, c. 34, sy 15, s. e6967, 2022, doi: 10.1002/cpe.6967.
- [10] H. T. Huynh ve Y. Won, “Regularized online sequential learning algorithm for single-hidden layer feedforward neural networks”, *Pattern Recognit. Lett.*, c. 32, sy 14, ss. 1930-1935, Eki. 2011, doi: 10.1016/j.patrec.2011.07.016.
- [11] Z. Shao ve M. J. Er, “An online sequential learning algorithm for regularized Extreme Learning Machine”, *Neurocomputing*, c. 173, ss. 778-788, Oca. 2016, doi: 10.1016/j.neucom.2015.08.029.
- [12] T. Song, D. Li, Z. Liu, ve W. Yang, “Online ADMM-Based Extreme Learning Machine for Sparse Supervised Learning”, *IEEE Access*, c. 7, ss. 64533-64544, 2019, doi: 10.1109/ACCESS.2019.2915970.
- [13] C.-H. Zhang ve J. Huang, “The sparsity and bias of the Lasso selection in high-dimensional linear regression”, *Ann. Stat.*, c. 36, sy 4, ss. 1567-1594, Ağu. 2008, doi: 10.1214/07-AOS520.
- [14] “A Survey on Nonconvex Regularization-Based Sparse and Low-Rank Recovery in Signal Processing, Statistics, and Machine Learning | IEEE Journals & Magazine | IEEE Xplore”. Erişim: 11 Ekim 2023. [Çevrimiçi]. Erişim adresi: <https://ieeexplore.ieee.org/document/8531588>
- [15] C.-H. Zhang, “Nearly unbiased variable selection under minimax concave penalty”, *Ann. Stat.*, c. 38, sy 2, ss. 894-942, Nis. 2010, doi: 10.1214/09-AOS729.
- [16] I. Selesnick, “Sparse Regularization via Convex Analysis”, *IEEE Trans. Signal Process.*, c. 65, sy 17, ss. 4481-4494, Eyl. 2017, doi: 10.1109/TSP.2017.2711501.
- [17] H. H. Bauschke ve P. L. Combettes, *Convex Analysis and Monotone Operator Theory in Hilbert Spaces*. içinde CMS Books in Mathematics. New York, NY: Springer, 2011. doi: 10.1007/978-1-4419-9467-7.
- [18] “Citation - UCI Machine Learning Repository”. Erişim: 11 Ekim 2023. [Çevrimiçi]. Erişim adresi: <https://archive-beta.ics.uci.edu/citation>



# Empowering the Next Generation: Integrating AI Literacy into Modern Education

Hamdi Erkunt<sup>1\*</sup>

<sup>1</sup>Department of Computer Education and Educational Technology, Bogazici University, Istanbul, Turkey  
(\*erkunt@boun.edu.tr)

**Abstract** – Today's students frequently engage with AI daily, yet many still need to learn the underlying principles. With AI becoming an integral part of modern society, the importance of AI literacy in schools is ever-increasing. This paper discusses the essence of AI literacy, emphasizing the understanding of algorithms, data processing, and machine learning while considering their ethical implications. Schools should integrate AI concepts across various subjects to foster AI literacy and utilize platforms that offer practical AI experience. Istanbul Metropolitan Municipality's weekend technology workshop serves as a case study, shedding light on its curriculum and pedagogical approach toward AI literacy. Feedback from trainers and students offers insights into the program's effectiveness and areas of improvement. The curriculum's adaptability, combining theory with hands-on application, promotes a deeper understanding of AI among students. In conclusion, as AI reshapes society, comprehensive AI education becomes essential in equipping students to become informed contributors in an AI-driven world.

**Keywords** – AI literacy, Curriculum integration, Pedagogical approach, Hands-on AI experience, Practical versus theoretical AI education

## I. INTRODUCTION

When today's students ask Siri a question or receive movie recommendations on Netflix, they already engage with AI. However, how many understand the principles behind these technologies? In an era where AI is no longer a futuristic speculation but a tangible part of our everyday lives, the pressing need for AI literacy in schools has never been more apparent.

McKinsey Global Institute [5] indicated an unsettling forecast: By 2030, automation might displace up to 800 million global workers. The demand for AI knowledge will permeate numerous professions, emphasizing that all professionals must have at least a foundational understanding of AI. Moreover, with AI's increasing influence on both public and private sectors, as illustrated by Brynjolfsson and McAfee [2], citizens need a clear grasp of AI's intricacies to participate meaningfully in democratic processes shaped by AI's influence. Zhou and Lin [10] further emphasized the pervasive nature of AI in our daily lives, from movie recommendations to banking algorithms, underscoring its role in everyday interactions.

## II. AI LITERACY

Nevertheless, what does AI literacy entail? At its core, AI literacy involves understanding fundamental AI concepts like algorithms, data processing, and, as some might not know, machine learning. It also means using and interacting with AI tools and systems while fully aware of AI's ethical, societal, and economic ramifications.

Schools are the starting point. Introducing AI literacy into school curriculums is about more than just preparing students for AI-dominated professions. It is about ensuring they understand the AI-driven world around them. From interacting with personal assistants on smartphones to navigating

recommendation systems on streaming platforms, understanding AI equips students to use these tools effectively and responsibly.

## III. SCHOOL INTEGRATION

One strategy incorporates AI concepts into existing subjects like math, science, and computer science, drawing from frameworks like the Computer Science Teachers Association's standards [4]. Students might learn about algorithms within their math lessons or explore machine learning in science.

Dedicated AI courses can also be beneficial, complemented by platforms like Scratch, which can enhance understanding and foster creativity [7]. Platforms like Teachable Machine and Machine Learning for Kids can also bridge the gap between theory and practical application.

Ethical discussions surrounding AI, as posited by Mittelstadt et al. [6], ensure students not only grasp the "how" but also understand the "should." With educators at the frontline of this initiative, their ongoing professional development, as Webb et al. [9] indicate, becomes crucial to impart AI concepts effectively.

## IV. INSIGHTS FROM AN AI PROGRAM

Istanbul Metropolitan Municipality introduced a detailed weekend technology workshop for students from the 4th to 10th academic grades beginning in the fall of 2021. Within this program, 6th- to 10th-grade students engage in a 36-hour module dedicated to Artificial Intelligence (AI). This module highlights AI's role in daily life and offers hands-on experience through platforms such as Teachable Machine and Machine Learning for Kids. Moreover, students delve into fundamental AI constructs like neural networks and deep learning methodologies.

A critical aspect of the program's design is the role and expectations set for the trainers. These trainers, often senior or

graduate students from computer science disciplines, are not just expected to instruct; they also have a mandate to spark rich academic dialogues among the students. The intention is to facilitate a more profound comprehension of AI concepts, such as machine learning, neural networks, and deep learning. This pedagogical approach aims to solidify students' foundational understanding of AI mechanisms through collaborative discourse.

Regrettably, these expectations have fallen short. While the curriculum prescribes a dynamic, discussion-led learning mode, feedback indicates a potential gap between this ideal and the current implementation. A pressing concern is the students' perception of these workshops. Instead of viewing them as interactive workshops, many students feel they are extensions of their regular school classes. This perception, unfortunately, influences their behavior, making them approach the workshops with the same mindset they have in their typical school setting. When students and trainers maintain their daily schooling, achieving this dynamic, discussion-led learning mode becomes challenging.

The following feedback emanates from the trainers who oversaw the 2022-2023 AI module, explicitly conducted for grades 6-7 and 9-10. The activities at the workshop generally found favor among students, particularly the hands-on tasks that utilized platforms like Machine Learning for Kids and Teachable Machine. However, there was a clear need for content depth and engagement adjustments. Activities needed to be age-appropriate; at the time, some seemed too rudimentary for high schoolers, while others were too advanced for younger students. Trainers preferred practical tasks over sessions to trigger a dialog. Lastly, introducing more AI sample applications for grades 9-10, especially those focusing on algorithms and coding, would have been beneficial. While the curriculum's foundation was robust, it demanded strategic enhancements for optimal student engagement and enrichment.

Student feedback on the AI activities showed overwhelming appreciation, with the Teachable Machine platform standing out as a favorite. They expressed enthusiasm for various applications, particularly the AI of Spotify, YouTube, and the Scratch Pokemon activity. These tangible outcomes and hands-on AI experiences overshadowed discussion-based sessions, underscoring a preference for interactive, application-focused learning. However, while the overall sentiment was positive, the lean toward practical tasks was evident.

In delivering the module, trainers confronted challenges, from articulating complex AI concepts and engaging students in discussions to catering to non-English speaking students with automatically subtitled videos. These challenges, however, served as invaluable learning experiences in understanding practical teaching nuances. To combat these challenges, trainers leaned into verbal explanations, used relatable real-life examples, and introduced debating activities to enrich discussions. Recommendations for future modules include integrating advanced platforms such as Python and diversifying the curriculum to balance hands-on and theoretical content, ensuring a richer learning experience for students.

Based on the feedback, it was evident that AI content needed differentiation to cater to varying grade levels. Specifically, the curriculum should have been neither too rudimentary for grades 9-10 nor overly advanced for grades 6-7. While trainers

appreciated platforms like Teachable Machine and Machine Learning for Kids, incorporating more sophisticated platforms like Python for older students could have provided more profound insights into AI. A clear student preference leaned towards practical, hands-on tasks; thus, curating activities with tangible outcomes became essential. However, this did not diminish the importance of engaging in discussions or structured debates. Incorporating real-world AI applications also boosted engagement, highlighting real-world relevance. While the emphasis was on hands-on tasks, a balanced theoretical foundation remained pivotal. Lastly, establishing a robust feedback mechanism could help the curriculum remain adaptive.

The current curriculum provides comprehensive lesson plans, enabling trainers to tailor the pace to meet the unique needs of their classes while emphasizing specific areas of interest. This approach ensures that trainers are equipped with foundational AI concepts and engaging hands-on activities. By blending theory with practical application, the curriculum fosters a deeper understanding and a more interactive learning experience for students.

## V. CONCLUSION

Bostrom [1] emphasized that AI does not merely represent another technology; it actively transforms every aspect of society. Decision-makers actively shape the future, and it becomes essential, not just progressive, to equip the next generation to navigate, lead, and excel in an AI-dominated world. In conclusion, the pervasiveness of AI in today's society mandates a profound understanding of it. As students today actively engage with AI-driven technologies, schools must ensure that these students use and deeply understand these tools. The feedback from trainers and students on the Greater Istanbul Municipality's AI module actively reflects both the curriculum's strengths and areas for enhancement. Striking a balance between solid theoretical foundations and practical, real-world applications becomes crucial. In preparing students for an AI-intertwined world, providing them with the appropriate knowledge, skills, and ethical insights is pivotal, turning them into informed participants and contributors to our AI-centric future. The path to AI literacy demands an ongoing adaptation of curricula, but this proactive approach is essential to mold informed citizens and professionals for our future.

## REFERENCES

- [1] S. M. Metev and V. P. Veiko, *Laser Assisted Microtechnology*, 2nd [1] N. Bostrom, *Superintelligence: Paths, Dangers, Strategies*. Oxford: Oxford University Press, 2014.
- [2] E. Brynjolfsson and A. McAfee, *The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies*. W. W. Norton & Company, 2014.
- [3] A. Bundy, "Automating the professions: Utopian pipe dream or dystopian nightmare?" *Lecture Notes in Computer Science*, vol. 10642, pp. 1–10, 2017.
- [4] Computer Science Teachers Association (CSTA), "K-12 Computer Science Standards," 2017.
- [5] McKinsey Global Institute, "Jobs lost, jobs gained: What the future of work will mean for jobs, skills, and wages," 2017.
- [6] B. D. Mittelstadt, P. Allo, M. Taddeo, S. Wachter, and L. Floridi, "The ethics of algorithms: Mapping the debate," *Big Data & Society*, vol. 3, no. 2, pp. 1-21, 2016.
- [7] M. Resnick et al., "Scratch: Programming for all," *Communications of the ACM*, vol. 52, no. 11, pp. 60-67, 2009.
- [8] S. J. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*. Malaysia: Pearson Education Limited, 2010.

- [9] M. Webb et al., "Computer science in K-12 school curricula of the 21st century: Why, what and when?" *Education and Information Technologies*, vol. 22, no. 2, pp. 445–468, 2017.
- [10] L. Zhou and T. W. Lin, "Artificial Intelligence in Education: Challenges and Opportunities for Teachers," *Computers in Human Behavior*, p. 107, 106275, 2020.

## Öğrenci Bilgi Seviyesinin Veri Madenciliği Yöntemleri ile Belirlenmesi ve Tahmin Edilmesi

Sezer Seven<sup>1\*</sup>, Tolga AYDIN<sup>2</sup> and Güler KARAMAN<sup>3</sup>

<sup>1</sup>Atatürk Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Erzurum, Türkiye

<sup>2</sup>Atatürk Üniversitesi Mühendislik Fakültesi, Erzurum, Türkiye

<sup>3</sup>Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi, Ankara, Türkiye

\*(sezerseven@atauni.edu.tr)

**Özet** – Öğretmenler açısından öğrencilerin herhangi bir konuda bilgi düzeylerinin bilinmesi oldukça önemlidir. Bu doğrultuda öğrencilerin bilgi düzeylerinin ölçülmesi veya belirlenmesine yönelik olarak çalışmalar literatürde mevcuttur. Yapılan çalışmalara genel olarak bakıldığında öğrenci bilgi düzeyinin belirlenebilmesi için nicel veya nitel araştırma yöntemlerinin kullanıldığı görülmüştür. Bu makalede gerçekleştirilen çalışmada ise öğrenci bilgi seviyesinin veri madenciliği yöntemleri kullanılarak tespit edilebilmesi amaçlanmıştır. Bilgi seviyelerinin oluşturulması işlemi için bölümleyici yöntemler arasında en çok kullanılan k-ortalamlar yöntemi kullanılmıştır. Çalışmadaki veri seti için, bilgi seviyelerinin optimum olarak 4 gruba ayrılması gerektiği görülmektedir. Bilgi seviyesinin tahmini için ise regresyon analizi tercih edilmiştir. Bu çalışma için sınıflandırma temelli olan lojistik regresyon modeli, sınıflandırma ve regresyon ağaçları modeli ve son olarak destek vektör regresyon modelleri kullanılmıştır. Sonuç olarak lojistik regresyon modeli %87, sınıflandırma ve regresyon ağaçları modeli %84.38 ve son olarak destek vektör regresyon modeli %82.66 oranında başarılı bir şekilde tahmin gerçekleştirmiştir.

**Anahtar Kelimeler** – Bilgi Seviyesi; Regresyon Modeli; Veri Madenciliği; K-Ortalamlar; Sınıflandırma

### I. GİRİŞ

Öğretmenler açısından öğrencilerin herhangi bir konuda bilgi düzeylerinin bilinmesi oldukça önemlidir. Bu doğrultuda öğrencilerin bilgi düzeylerinin ölçülmesine veya belirlenmesine yönelik olarak çalışmalar gerçekleştirilmiştir. Bu çalışmalara genel olarak bakıldığında öğrenci bilgi düzeyinin belirlenebilmesi için nicel veya nitel araştırma yöntemleri kullanılmıştır. Örneğin; Gökdere ve Ayvaci (2004) yapmış oldukları sınıf öğretmenlerinin üstün yeteneklilik kavramı hakkındaki bilgi düzeylerini belirlemeyi amaçladığı çalışmada başarı testi ve mülakat yöntemi kullanılmıştır. Karamustafaoglu ve Yalnız'ın (2016) yapmış oldukları 8. sınıf öğrencilerinin genel kültür düzeylerinin belirlenmesini amaçladığı çalışmada ise nicel araştırma yöntemi olan betimsel alan taraması kullanılmıştır. Son olarak; İncekara ve Tuna'nın (2010) yapmış ortaöğretim seviyesinde öğrenim gören öğrencilerin çevre ile ilgili olgular hakkındaki bilgi seviyelerinin belirlenmesini amaçlayan çalışmada nicel araştırma yöntemi olan ölçek yöntemi kullanılmıştır.

Bu motivasyondan yola çıkılarak yapılan bu çalışmada öğrenci bilgi seviyesinin veri madenciliği yöntemleri kullanılarak tespit edilebilmesi amaçlanmıştır. Bu doğrultuda yapılan alanyazın taraması neticesinde benzer bir çalışmaya rastlanılmamıştır. Öncelikle bilgi seviyelerinin oluşturulması için benzer özellik gösteren öğrenci gruplarının oluşturulması fikri üzerinde çalışmalar gerçekleştirilmiştir. Öğrencileri bilgi seviyelerine göre ayırmak, benzer bilgi düzeyi özelliği gösteren öğrencilerin bir araya toplanarak gruplandırılması demektir. Bu durumdan ötürü grupların oluşturulma işlemi için bölümleyici yöntemlerin arasında en çok kullanılan k-ortalamlar yöntemi (Cebeci ve ark., 2015) kullanılmıştır. K-

ortalamlar yöntemi algoritmik yapısı gereği k yani küme sayısının dışarıdan girilmesini istemektedir. Bu çalışmada küme sayısı belli olmadığından ötürü dirsek yöntemi kullanılmıştır. Dirsek yöntemi ile optimum k sayısı bulunabilmektedir (Okumuş ve ark., 2017).

Öğrenciler bilgi düzeylerine göre gruplandırıldıktan sonra veri setine yeni dahil olacak öğrenciler için bilgi düzeylerinin tahmin edilmesi aşamasına geçilmiştir. Tahminleme için yaygın olarak kullanılan bir makine öğrenmesi modeli olan regresyon modeli tercih edilmiştir. Makine öğrenmesi algoritmalarında bir çok regresyon modeli kullanılmaktadır. Bu çalışmada ise üç farklı regresyon modeli kullanılmıştır. Bunlar; lojistik regresyon modeli, sınıflandırma ve regresyon ağaçları modeli ve son olarak destek vektör regresyon modelidir. Kullanılan regresyon modelleri sınıflandırma temelli olduğu ve yüksek tahmin doğruluğu gerçekleştirdiği için tercih edilmiştir (Awad ve Khanna, 2015; Işığışık, 2003; akt. Girginer ve Cankuş, 2008; Timofeev, 2004). Kullanılan üç regresyon modelinin başarı oranı birbirleri ile kıyaslanarak en yüksek başarı oranına sahip olan regresyon modeli belirlenmiştir.

### K-Ortalamlar Yöntemi

K-ortalamlar yöntemi bölümleyici yöntemlerin arasında en çok kullanılan yöntemdir. Yöntemin isminden de anlaşılacağı üzere veri setini k adet kümeye bölümlemek için başlangıç olarak rastgele şekilde k adet küme merkezi seçilmektedir. Her bir veri noktasının küme merkezleri ile arasındaki uzaklıklar hesaplanmaktadır. Veri noktasının uzaklığı hangi kümeye yakın olursa ilgili kümeye dâhil edilmektedir. Veri noktalarının artık küme değiştirme durumu gözlemlenmiyorsa kümeleme işlemi sona erdirilir, gözlemleniyor ise bir sonraki

adımda işlem tekrarlanmaktadır (Cebeci ve ark., 2015). K-Ortalamalar yöntemi algoritmik yapısı gereği k sayısının dışarıdan girilmesini istemektedir. Küme sayısı belli olan veri setleri dışında belli olmayan veri setleri de mevcuttur. Dirsek yöntemi ile optimum k sayısı bulunabilmektedir. Yöntemde veri setindeki karesel hata oranları grafik eğrisi şeklinde değerlendirilmektedir. Eğride dirseğe benzemekte olan keskin bir kırılmanın yaşandığı nokta tespit edilmektedir. Bu nokta veri setinin optimum küme sayısını vermektedir (Okumuş ve ark., 2017).

#### Destek Vektör Regresyon Modeli

Destek Vektör Regresyon modeli, sınıflandırma problemlerinde kullanılan, doğrusal veya doğrusal olmayan bir fonksiyonun kullanılmasıyla sınıflandırma işlemini gerçekleştirmektedir (Özkan, 2020). Destek Vektör Regresyon modelinin, gerçek değer fonksiyonu tahmininde etkili bir araç olduğu kanıtlanmıştır. Ana avantajlarından biri, yüksek tahmin doğruluğu ile mükemmel genelleme yeteneğine sahip olmasıdır (Awad ve Khanna, 2015).

#### Lojistik Regresyon Modeli

Lojistik regresyon analizinin temel odağı, bireylerin hangi grubun üyesi olduğunu kestirmede bir regresyon denklemi oluşturmaktır (Çokluk, 2010). Lojistik regresyon analizinin iki amacı bulunmaktadır. Bu amaçlardan birincisi sınıflandırma, ikincisi ise bağımlı ve bağımsız değişkenler arasındaki ilişkileri araştırmaktır (Işığışık, 2003; akt. Girginer ve Cankuş, 2008).

#### Sınıflandırma ve Regresyon Ağaçları (CART) Modeli

Sınıflandırma ve Regresyon Ağaçları, bir ağaç gibi kökünden başlayarak baş aşağı büyürken gösterilmektedir. Bu algoritmada ikili dallanmalar söz konusudur yani bir düğümde seçme işlemi yapıldığında sadece iki dala ayrılabilir. Bir düğüme belirli bir kriter uygulanarak bölünme işlemi gerçekleştirilmektedir ve bu bölünmeler üzerinde seçme işlemi gerçekleştirilmektedir (Özkan, 2020). Sınıflandırma ve Regresyon Ağaçları, verileri sınıflandırmak için kullanılmaktadır. Bu algoritmayı kullanabilmek için sınıf sayısını önceden bilmemiz gerekmektedir (Timofeev, 2004).

## II. MATERYAL VE YÖNTEM

Öğrenci bilgi seviyesinin belirlenmesi ve tahmin edilmesini amaçlayan bu çalışmada, mobil öğrenme ortamlarından elde edilen metriklerden yola çıkılarak öğrencilerin bilgi seviyelerinin veri madenciliği yöntemleri ile tahmin edilebileceği düşünülmüştür. Yapılan alanyazın taraması sonrasında 18 adet metrik elde edilmiştir. Bilgi seviyesi tespiti için metriklerin belirlenmesi aşamasından sonra bu metriklerin referans değerlerinin belirlenmesi aşamasına geçilmiştir. Bu aşamada nitel araştırma yöntemlerinden doküman inceleme yöntemi kullanılmıştır.

Doküman inceleme yöntemi, araştırılması hedeflenen olgular hakkında bilgi içeren yazılı materyallerin analizini kapsamaktadır. Nitel araştırmalarda kullanılması gereken önemli bilgi kaynaklarıdır. Araştırmacının gözlem ve görüşme yapmadan ihtiyacı olan veriyi elde edebilmesini sağlamaktadır. Veri toplama yöntemleriyle birlikte kullanıldığında verinin çeşitlendirilmesinde ve araştırmanın geçerliliğinin artırılmasında etkili olmaktadır. Eğitim ile ilgili yapılan araştırmalarda öğrenci kayıtları ve tutanakları, öğrenci ödevleri ve sınavları, öğretmen dosyaları doküman ve veri

kaynağı olarak kullanılabilir (Yıldırım & Şimşek, 1999).

Doküman inceleme yönteminden yola çıkılarak çalışmada kullanılan metriklere ait verilerin kişilerle herhangi bir görüşme sağlanmadan ya da anket uygulamadan elde edilebileceği görülmüştür. Böylelikle yapılan çalışmada, gözlem veya görüşme yapılmaksızın verilerin elde edilebilmesini sağlayabileceği ve eğitim araştırmalarında kullanılan önemli yöntemlerden biri olduğundan ötürü doküman inceleme yöntemi tercih edilmiştir.

Metriklerin oluşturulabileceği veri noktalarına yönelik olarak öğrencilerin mobil öğrenme ortamlarındaki faaliyetleri ile öğretmen tarafından öğrencilerle ilgili olarak düzenli bir şekilde tutulan kitap okuma sıklığı, çözülen soru sayısı, doğru veya yanlış sayısı gibi verileri barındıran dokümanlar incelenmiştir. Dokümanların incelenmesi sonucunda metriklerin taban ve tavan değerleri belirlenmiştir. Taban ve tavan değerler referans alınarak her bir öğrenci için simülasyon veriler oluşturulmuştur.

Sonuç olarak öğrencilerin önce k-ortalamalar yöntemine göre bilgi seviyesi ölçülerek, bilgi seviyesine göre gruplandırma işlemi gerçekleştirilmiştir. Sonrasında ise öğrencilerin bilgi seviyeleri sınıflandırma temelli üç regresyon modeli ile tahmin edilmeye çalışılmıştır. Yöntem kısmında yapılacak olan bu iki önemli işlem, veri bilimi başta olmak üzere diğer alanlarda da sıklıkla kullanılan Python programlama dili kullanılarak gerçekleştirilmiştir.

#### Araştırmanın Evren ve Örneklemi

Araştırmanın evrenini, 2021-2022 eğitim-öğretim yılı birinci döneminde, Erzurum iline bağlı tüm ilçelerdeki devlet okullarında ilköğretim kademesinde eğitim gören 7. Sınıf öğrencileri oluşturmaktadır. Bu örneklemin tercih edilme sebebi benzer özellik gösteren öğrenci gruplarının bölümleyici yöntemler ile gruplara daha sağlıklı bir şekilde ayrıştırılmasını sağlamaktır. Evrendeki öğrenci sayısı toplamda 12307 kişi olarak tespit edilmiştir. Araştırmanın örneklemini yaş aralığı 12 ila 13 arasında değişen 200'ü erkek, 172'si kız olmak üzere toplam 372 katılımcı oluşturmaktadır. Örneklem sayısının belirlenmesine yönelik olarak aşağıda belirtilen basit seçkisiz örnekleme formülü kullanılmıştır (Nacar, 2019). Formüle göre %95 güven aralığı ve 0,05 hata payına sahip olmak üzere, evren büyüklüğü 12307 olan araştırmalarda örneklem sayısının en az 372 olması gerekmektedir. Örneklemin hesaplanmasında kullanılan formül aşağıda belirtilmiştir (Karasar, 2014).

n: Örneklem büyüklüğü

N: Evren büyüklüğü

t: Belirli bir anlamlılık düzeyinde t tablosuna göre bulunan teorik değer

p: İncelenen olayın gerçekleşme olasılığı

q: İncelenen olayın gerçekleşmeme olasılığı

d: Hata payı

$$n = \frac{Nt^2pq}{d^2(N-1) + t^2pq}$$

$$= \frac{12307 \times 1,96^2 \times 0,5 \times 0,5}{0,05^2 \times (12307 - 1) + 1,96^2 \times 0,5 \times 0,5} = 372$$

### Bilgi Seviyesi Metriklerinin Referans Değerlerinin Belirlenmesi

Aşağıdaki bahsi geçen metriklerin referans değerleri mobil öğrenme ortamlarından elde edilen veriler ve öğrencilerin performansları ile ilgili verilerin düzenli olarak tutulduğu dokümanlar yardımı ile belirlenmiştir. Referans değerleri hesaplanırken veriler haftalık olarak belirlenmiştir.

- **Favori ders:** Milli Eğitim Bakanlığı 7. Sınıf ders listesinden faydalanılarak zorunlu olan 16 ders, referans değeri olarak belirlenmiştir.
- **Okul not ortalaması:** 45 ila 100 arasında referans değeri belirlenmiştir.
- **Ders not ortalaması:** 15 ila 100 arasında referans değeri belirlenmiştir.
- **Oturum süresi:** 16 hafta boyunca mobil öğrenme ortamında geçirilen toplam süre olarak dakika cinsinden hesaplanmıştır. Her hafta için taban değer öğrencinin toplam etkileşim süresi (video, okuma ve soru materyalinde geçirilen toplam süre); tavan değer ise 840 dakika olarak belirlenmiştir.
- **Ders süresince atılan mesaj sayısı:** 16 hafta boyunca mobil öğrenme ortamında atılan toplam mesaj sayısı olarak hesaplanmıştır. Her hafta için taban değer 0, tavan değer ise 50 adet olarak belirlenmiştir.
- **Ders süresince izlenen video süresi:** 16 hafta boyunca mobil öğrenme ortamında izlenen toplam video süresi olarak dakika cinsinden hesaplanmıştır. Ortalama bir video 15 dakika olmak üzere her hafta için maksimum izlenebilecek video sayısı 4 olarak belirlenmiştir. Bundan ötürü her hafta için taban değer 0, tavan değer ise 60 dakika olarak belirlenmiştir.
- **Soru başına ortalama ayırdığı süre:** 16 hafta boyunca mobil öğrenme ortamında çözülen toplam soru sayısı ve sorulara ayrılan dakika cinsinden toplam süre hesaplanmıştır. Daha sonra ise toplam süre, toplam soru sayısına bölünmüştür.
- **Toplam etkileşim süresi:** 16 hafta boyunca mobil öğrenme ortamında video, okuma ve soru materyalinde geçirilen dakika cinsinden toplam süre olarak hesaplanmıştır.
- **Günlük çözülen ortalama soru sayısı:** 16 hafta boyunca mobil öğrenme ortamında çözülen toplam soru sayısının 112'ye bölünmesi ile hesaplanmıştır.
- **Tekrarlayan okumalar:** 16 hafta boyunca mobil öğrenme ortamında en çok okunan materyalin yineleme sayısı olarak hesaplanmıştır.
- **Okuma için ayırdığı ortalama süre:** 16 hafta boyunca mobil öğrenme ortamında okuma materyali için ayrılan dakika cinsinden toplam sürenin ortalaması alınarak hesaplanmıştır.
- **Konu başına tamamlanan okuma sayısı:** 16 hafta boyunca mobil öğrenme ortamında yapılan toplam okuma sayısının konu sayısına(16) bölünmesi ile hesaplanmıştır.
- **Konu başına tamamlanan video sayısı:** 16 hafta boyunca mobil öğrenme ortamında izlenen toplam video sayısının konu sayısına(16) bölünmesi ile hesaplanmıştır.
- **Konu başına tamamlanan soru sayısı:** 16 hafta boyunca mobil öğrenme ortamında çözülen toplam

soru sayısının konu sayısına (16) bölünmesi ile hesaplanmıştır.

- **Konu başına doğru sayısı:** 16 hafta boyunca mobil öğrenme ortamında çözülen sorulardan elden edilen toplam doğru sayısının konu sayısına (16) bölünmesi ile hesaplanmıştır.
- **Konu başına yapılan yorum sayısı:** 16 hafta boyunca mobil öğrenme ortamında yapılan toplam yorum sayısının konu sayısına (16) bölünmesi ile hesaplanmıştır.
- **Görev tamamlama zamanı:** 16 hafta boyunca mobil öğrenme ortamında tamamlanan toplam görev sayısının konu sayısına (16) bölünmesi ile hesaplanmıştır.

### Bilgi Seviyelerinin Oluşturulması ve Tahmin Edilmesi

Bilgi seviyelerinin oluşturulması için öncelikle benzer özellik gösteren öğrenci grupları bölümleyici yöntemler arasında en çok kullanılan k-ortalama yöntemini kullanılarak, Python programlama dili ve Python programlama diline ait pandas ve sklearn.cluster kütüphanelerinden yararlanılmıştır. Yöntemin isminden de anlaşılacağı üzere veri setini k adet kümeye bölümlenmek için başlangıç olarak rastgele şekilde k adet küme merkezi seçilmektedir. Her bir veri noktasının küme merkezleri ile arasındaki uzaklıklar hesaplanmaktadır. Veri noktasının uzaklığı hangi kümeye yakın olursa ilgili kümeye dâhil edilmektedir. Veri noktalarının artık küme değiştirme durumu gözlemlenmiyorsa kümeleme işlemi sona erdirilir, gözlemleniyor ise bir sonraki adımda işlem tekrarlanmaktadır (Cebeci ve ark., 2015).

K-Ortalama yöntemini ilgili yoğun bir şekilde merak edilen konulardan birisi ise optimum k sayısının bulunması işlemidir. K-Ortalama yöntemini algoritmik yapısı gereği k sayısının dışarıdan girilmesini istemektedir. Küme sayısı belli olan veri setleri dışında belli olmayan veri setleri de mevcuttur. Bu durumda devreye dirsek(elbow) yöntemi girmektedir. Dirsek yöntemi ile optimum k sayısı bulunabilmektedir. Yöntemde veri setindeki karesel hata oranları grafik eğrisi şeklinde değerlendirilmektedir. Eğride dirseğe benzemekte olan keskin bir kırılmanın yaşandığı nokta tespit edilmektedir. Bu nokta veri setinin optimum küme sayısını vermektedir (Okumuş ve ark., 2017).


Bilgi seviyelerinin tahmin edilmesi işlemi için sınıflandırma temelli olan üç ayrı regresyon modeli kullanılmıştır. Bunlar; lojistik regresyon modeli, sınıflandırma ve regresyon ağaçları modeli ve son olarak destek vektör regresyon modelidir. Veriler, regresyon analizine tabi tutulmadan önce min-max normalizasyon işlemi uygulanmıştır. Regresyon analizleri Python programlama dili kullanılarak sklearn kütüphanesi yardımıyla gerçekleştirilmiştir. Modellerin başarı oranına R<sup>2</sup> skoruna bakılarak karar verilmiştir. Her bir modelin başarı oranı birbiri ile kıyaslanmıştır.

### III. BULGULAR

Çalışmanın bu bölümünde öğrenci bilgi seviyesinin belirlenmesi ve tahmin edilmesine yönelik olarak bulgular sunulmuştur.


### Öğrenci Bilgi Seviyelerinin Belirlenmesi

Yapılan bu çalışmada kullanılan veri setinin optimum küme sayısı Python programlama dili kütüphanelerinden matplotlib kütüphanesi vasıtası ile dirsek yöntemi kullanılarak elde edilen grafik eğrisi sayesinde tespit edilmiştir. Aşağıda Şekil 1.1’de görüldüğü üzere optimum k sayısı 4 olarak gösterilmektedir.



Şekil. 1.1. Dirsek Yöntemi ile Optimum K Değeri Grafliği

Grafik eğrisi ile optimum k sayısının tespit edilememesi durumunda yine Python programlama dili kütüphanelerinden klibowvisualizer kütüphanesi vasıtası ile dirsek yönteminin görselleştirilmiş versiyonu kullanılabilir. Aşağıda Şekil 1.2’de görüldüğü üzere dirsek yönteminin görselleştirilmiş versiyonu kullanılarak optimum k sayısı tekrardan 4 olarak tespit edilmiştir.



Şekil. 1.2. Görselleştirilmiş Optimum K Değeri Grafliği

### Öğrenci Bilgi Seviyelerinin Tahmin Edilmesi

Bilgi seviyelerinin tahmin edilebilmesi için üç ayrı regresyon modeli olan “Lojistik regresyon”, “Destek Vektör Regresyon” ve “Sınıflandırma ve Regresyon Ağaçları” kullanılmıştır. Yapılan regresyon analizleri sonucunda modellerin başarı puanı olarak  $R^2$  skorlarına bakılmıştır. Tablo 1’de regresyon modellerinin başarı puanları sıralanmaktadır.

Table 1. Regresyon Modelleri Başarı Puanı Sıralaması

S.N.	Model Adı	Başarı Puanı ( $R^2$ )
1	Lojistik Regresyon Modeli	0.86992
2	Sınıflandırma ve Regresyon Ağaçları	0.84379
3	Destek Vektör Regresyon Modeli	0.82653

### IV. SONUÇ

Çalışmanın bu bölümünde bulgulara ait sonuçlar tartışılmaktadır. Ayrıca gelecek çalışmalara ışık tutacak öneriler sunulmaktadır.

Elde edilen bulgulara bakıldığında çalışmada kullanılan veri setindeki öğrencilerin bilgi seviyelerinin optimum olarak 4 gruba ayrılması gerektiği Şekil 1.1. ve Şekil 1.2.’de görülmektedir. Gelecekte başka veri setleriyle yapılacak olan diğer çalışmalarda da optimum bilgi seviyesi sayısının dirsek yöntemi kullanılarak belirlenebileceği görülmüştür.

Öte yandan bilgi seviyesi tahmini ile ilgili olarak lojistik regresyon modeli yaklaşık %87, sınıflandırma ve regresyon ağaçları modeli yaklaşık %84.38 ve son olarak destek vektör regresyon modeli de yaklaşık %82.66 oranında başarılı bir şekilde öğrenci bilgi seviyelerini tahmin işlemi gerçekleştirmiştir. Böylelikle veri setine yeni dahil olan bir öğrencinin bilgi düzeyi lojistik regresyon modeli kullanılarak yüksek doğruluk oranı ile tahmin edilebilecektir.

Gelecekte yapılacak olan çalışmalarda elde edilecek veri çeşitliliği ile grupların daha kesin bir şekilde tahmin edilmesi sağlanabilir. Ayrıca veriler kısa süreli periyotlarla güncellenerek grupların dağılımı anlık olarak güncellenebilir.

### KAYNAKLAR

- [1] Çokluk, Ö. (2010). Lojistik regresyon analizi: Kavram ve uygulama. Kuram ve uygulamada eğitim bilimleri, 10(3), 1357-1407.
- [2] Timofeev, R. (2004). Classification and regression trees (CART) theory and applications. Humboldt University, Berlin, 54.
- [3] Gökdere, M., & Ayvaci, H. Ş. (2004). Sınıf öğretmenlerinin üstün yetenekli çocuklar ve özellikleri ile ilgili bilgi seviyelerinin belirlenmesi. Ondokuz Mayıs Üniversitesi Eğitim Fakültesi Dergisi, (18), 17-26.
- [4] Karamustafaoglu, S., & Yalnız, S. (2016). 8. Sınıf öğrencilerinin genel kültür seviyelerinin belirlenmesi.
- [5] İncekara, S., & Tuna, F. (2010). Ortaöğretim Öğrencilerinin Çevresel Konularla İlgili Bilgi Düzeylerinin Ölçülmesi: Çankırı İli Örneği. Marmara Coğrafya Dergisi, (22), 168-182.
- [6] Timofeev, R. (2004). Classification and regression trees (CART) theory and applications. Humboldt University, Berlin, 54.
- [7] Özkan, Y. (2020). Veri madenciliği yöntemleri. Papatya Yayıncılık Eğitim.
- [8] Girginer, N., & Cankuş, B. (2008). Tramvay yolcu memnuniyetinin lojistik regresyon analiziyle ölçülmesi: Etram örneği. Yönetim ve Ekonomi Dergisi, 15(1), 181-193.
- [9] Işığışık, E. (2003). Bebeklerin doğum ağırlıklarını ve boylarını etkileyen faktörlerin lojistik regresyon analizi ile araştırılması. IV. Ulusal Ekonometri ve İstatistik Sempozyumu, 3.
- [10] Awad, M., & Khanna, R. (2015). Support vector regression. In Efficient learning machines (pp. 67-80). Apress, Berkeley, CA.
- [11] Cebeci, Z., Yıldız, F., & Kayaalp, G. T. (2015). K-ortalamlar kümelemesinde optimum K değeri seçilmesi. 2. Ulusal Yönetim Bilişim Sistemleri Kongresi. Erzurum, 8-10.
- [12] Pınar, M., Okumuş, O., Turgut, U. O., Kalıpsız, O., & Aktaş, M. S. (2017). Büyük veri içeren öneri sistemleri için hiperparametre optimizasyonu. Ulusal Yazılım Mühendisliği Sempozyumu, 22-272.
- [13] Yıldırım, A., & Simsek, H. (1999). Sosyal Bilimlerde Nitel Araştırma Yöntemleri (12. baskı: 1999-2021).
- [14] Nacar, A. (2019). Öğretmenlerin Eğitime İnanma Düzeyleri ile İşe Bağlılık Düzeyleri Arasındaki İlişki: Kahramanmaraş İli Örneği. (Yüksek Lisans Tezi). Kahramanmaraş: Sütçü İmam Üniversitesi Sosyal Bilimler Enstitüsü.
- [15] Karasar, N. (2014). Bilimsel Araştırma Yöntemi: Kavramlar, İlkeler, Teknikler. 26. bs. Ankara: Nobel Yayın Dağıtım

## Ailevi Akdeniz Ateşi'nde Kolşisin Tedavisinin Makine Öğrenmesi Analizi

Muhammet İkbal YILDIZ\*, Salim CEYHAN<sup>2</sup>

<sup>1</sup>LEE, Computer Engineering, Bilecik Seyh Edebali University, Bilecik, Turkey

<sup>2</sup>Computer Engineering, Bilecik Seyh Edebali University, Bilecik, Turkey

\*(muh.ikbalyizildiz@gmail.com) Email of the corresponding author

**Özet** – Bu çalışma, Ailevi Akdeniz Ateşi (AAA) hastalığına özgü bir veri setini analiz etmek için K-means kümeleme ve Kruskal-Wallis istatistiksel testini kullanan kapsamlı bir araştırmadır. Çalışmanın ana hedefi, AAA hastalarının kolşisin tedavi yanıtlarını etkileyen klinik ve demografik özellikleri belirlemektir. Toplamda 144 hasta kaydı içeren veri seti, demografik bilgiler, klinik semptomlar ve genetik varyantlar gibi 15 farklı özelliği barındırmaktadır. Özellik seçimi için ANOVA F-değerini temel alan SelectKBest algoritması kullanılmış ve "atak süresi", "ateş" ve "TİT protein" en fazla bilgi taşıyan üç özellik olarak seçilmiştir. Bu özellikler üzerinde K-means kümeleme algoritması uygulanmış ve yaklaşık olarak %70.14 doğruluk oranı elde edilmiştir. Ayrıca, Kruskal-Wallis testi ile de bu özelliklerin kolşisin tedavi yanıtları açısından istatistiksel olarak anlamlı farklılıklar gösterdiği tespit edilmiştir. Çalışma, klinisyenlere AAA hastalarına daha etkili ve kişiselleştirilmiş tedavi protokolleri önerme olanağı sağlama potansiyeli ile dikkat çekmektedir. Bu araştırma, daha geniş kapsamlı çalışmalar için önemli bir temel oluşturmaktadır.

**Anahtar Kelimeler** – Makine Öğrenmesi, K-means Kümeleme, Ailevi Akdeniz Ateşi, Kolşisin Tedavisi, Sağlıkta Veri Madenciliği

### I. GİRİŞ

Ailevi Akdeniz Ateşi (AAA), özellikle Doğu Akdeniz bölgesinde sıkça rastlanan genetik bir inflamasyon (iltihaplanma) hastalığıdır [1]. Bu durum, yüksek ateş, karın ağrısı ve akciğer zarı iltihabı gibi belirtilerle kendini gösterir [2]. 1970'lerden bu yana, kolşisin adlı ilaç, AAA'nın tedavisinde oldukça etkili bir yöntem olarak kabul görmektedir [3]. Ancak, bu ilaca yanıt vermeyen hastaların varlığı, tedavi yönergelerinin ve uygulamalarının daha da iyileştirilmesi gerektiğini göstermektedir [4,5,6].

Bu akademik çalışma, Türkiye'nin farklı bölgelerinde doğmuş ve Uludağ Üniversitesi Tıp Fakültesi'nde tedavi görmekte olan 144 AAA hastasının demografik ve klinik verilerini analiz etmek için makine öğrenmesi ve veri analizi tekniklerini kullanmaktadır. Makine öğrenmesi ve veri analizi teknikleri, hastalığın daha derinlemesine anlaşılmasına yardımcı olabilir [7]. Örneğin, hastaların demografik bilgilerini (yaş, cinsiyet, etnik köken vb.) ve klinik bilgilerini (semptomlar, tedavi tarihçesi vb.) içermektedir. Özellik seçimi yöntemleri kullanılarak, modelin genelleştirme kabiliyeti artırılmış ve hastalık üzerindeki çeşitli faktörlerin etkisi detaylı bir şekilde incelenmiştir.

Dikkat çekici bir şekilde, bu çalışmada kolşisin tedavisine yanıt vermeyen 22 hastanın detaylı analizi yapılmıştır. Bu grup, toplam hasta sayısının yaklaşık %15.28'ini oluşturmaktadır. Bu oran, daha önce yapılan çalışmalarda bildirilen %5-10'luk oranından daha yüksektir [8], bu durumun dirençli hastaların daha yüksek oranda üniversite hastanesinde takip edilmesinden kaynaklandığı düşünülmektedir.

Bu çalışmanın amacı, makine öğrenmesi teknikleri ve özellik seçimi kullanarak AAA hastalarının hangi özelliklerinin tedaviye yanıtı etkilediğini anlamak ve özellikle kolşisin tedavisine yanıt vermeyen hastaların özelliklerini daha iyi kavramaktır. Özellik seçimi sonrası, "atak süresi" "ateş" ve "TİT protein" en fazla bilgi taşıyan üç özellik olarak

belirlenmiştir. Elde edilen bilgilerin, hastalığın daha etkin bir şekilde yönetilmesine ve tedavi yönergelerinin geliştirilmesine katkı sağlayacağı düşünülmektedir.

Ailevi Akdeniz Ateşi (AAA) hakkında yapılan önceki çalışmalar, hastalığın ne kadar sık görüldüğü, nasıl tedavi edildiği ve hangi topluluklarda daha yaygın olduğu gibi konulara farklı bakış açıları getirmektedir. Örneğin, Türkiye'deki bir araştırma, hastalığı etkileyen genetik ve çevresel etkenleri incelemiş ve bu konuda önemli bilgiler sunmuştur [1]. Kontrollü, çift-kör bir çalışmada, Ailevi Akdeniz Ateşi (AAA) hastaları üzerinde kolşisin tedavisinin etkinliği incelenmiştir. Çalışmada, kolşisin atak sayısını önemli ölçüde azalttığı ve bu sonuçların istatistiksel olarak anlamlı olduğu belirlenmiştir ( $p < 0.002$ ) [5]. Kolşisin tedavisine yanıt vermeyen Ailevi Akdeniz Ateşi (AAA) hastaları için alternatif bir tedavi yaklaşımı olarak Anakinra'nın etkinliğini incelemiştir. Çalışmada, Anakinra'nın Interlökin-1 (IL-1) reseptör antagonisti olarak rol alarak inflamasyonu kontrol edebileceği ve kolşisin tedavisine yanıt vermeyen hastalarda etkili bir alternatif olabileceği belirtilmiştir [6]. İlaç tedavisine yeterli yanıt alınamayan hastalar için farklı tedavi yöntemlerinin etkinliği, çeşitli yerlerde yapılan bir genel değerlendirme (meta-analiz) ile incelenmiştir [5]. Özgöçmen ve Akgül'ün çalışması, Ailevi Akdeniz Ateşi (AAA) hastalarında anti-TNF ajanlarının (infliximab, adalimumab gibi) etkinliğini gözlemlemiştir. Özellikle spondilitis ve amiloidoz gibi komplikasyonlarla seyreden AAA hastalarında anti-TNF ajanlarının etkili bir tedavi yöntemi olabileceğini göstermişlerdir [9]. Sarı, Birlik ve Kaşifoğlu'nun gözden geçirme makalesi, Ailevi Akdeniz Ateşi'nin (AAA) tedavisinde kolşisin'in yerinin tartışmasız olduğunu, fakat kolşisin'e dirençli ya da tedaviye duyarlı olmayan hastalar için alternatif tedavi seçeneklerinin geliştirilmesi gerektiğini belirtiyor. Özellikle IL-1 ve TNF inhibitörleri gibi biyolojik ajanlar, bu tür hastalarda olumlu sonuçlar gösterebilecek potansiyele sahiptir [10]. Ailesel Akdeniz ateşi



(AAA) hastalığı ile ilişkili MEFV gen varyantlarının etnik ve coğrafi kökenini belirlemek için makine öğrenimi yaklaşımlarını kullanır. Sonuçlar, belirli MEFV varyantlarının Kuzey Afrika, Avrupa ve Batı Asya gibi farklı coğrafi bölgelerle güçlü bir şekilde ilişkilendirildiğini, bu da AAA'nin etiolojisi ve tedavisi için yeni yolların keşfi açısından önemli olabileceğini göstermektedir [7].

## II. MATERYAL VE METHOD

Bu çalışmada, Ailevi Akdeniz Ateşi (AAA) hastalığına ait bir veri seti üzerinde özellik seçimi ve K-means kümeleme yöntemleri kullanılarak kapsamlı bir analiz gerçekleştirilmiştir. Kolşisin tedavi yanıtını belirlemede önemli faktörler olan özellikler belirlenmiştir. Bu değişkenlerin kolşisin tedavi yanıtları açısından istatistiksel olarak anlamlı farklılıklar gösterip göstermediği Kruskal-Wallis istatistiksel testi ile gösterilmiştir.

### A. Veri Seti ve Ön İşleme

Bu çalışma, Tel-Hashomer Tanı Kriterleri ile tanı konulmuş toplamda 155 Ailevi Akdeniz Ateşi (AAA) hastasının klinik, demografik ve genetik verilerini incelemektedir. İlgili veri seti, Uludağ Üniversitesi Tıp Fakültesi Dahili Bilimler Bölümü, İç Hastalıkları Anabilim Dalı Romatoloji Bilim Dalı Başkanı Prof. Dr. Yavuz Pehlivan tarafından sağlanmıştır. İlk ham veri seti, 21 farklı değişken içermekte ve bu değişkenler demografik, klinik ve genetik olmak üzere üç ana kategoride sınıflandırılmıştır. İncelenen veri seti, hem sayısal hem de kategorik değişkenlerden oluşmaktadır.

Ön analiz sürecinde, belirli değişkenlerin yüksek oranda eksik veri içerdiği ve bazı değişkenler arasında yüksek korelasyon olduğu tespit edilmiştir. Yüksek korelasyon, değişkenlerin birbirini tekrar eden bilgi sunduğunu göstermektedir. Bu sebeplerle, eksik veya yüksek korelasyonlu değişkenler analizden çıkarılarak diğer değişkenlerin model üzerindeki etkisinin daha net anlaşılabilir olması sağlanmıştır. Sonuçta elde edilen rafine edilmiş veri seti, 3 demografik, 8 klinik ve 4 genetik özellik içermektedir. Detaylı özellikler ve dağılımları, Tablo 1'de sunulmuştur.

Tablo 1. Kullanılan veri setinin kategorik özellikleri, açıklamaları, aldığı değerler ve oranları.

Sütun Adı	Açıklama	Değer-Oranlar
cinsiyet	Hastanın Cinsiyeti	Erkek %55.56 / Kadın %44.44
dyer	Doğum Yeri	Marmara %59.03 / Karadeniz %40.97
ailefmf	Aile AAA Öyküsü	Var %61.81/Yok %38.19
krnagrsatk	Karın Ağrısı Atak	Var %95.83/Yok %4.17
ateş	Ateş	Var %85.42/Yok %14.58
kolsisinynt	Kolşisin Yanıtı	Var %84.72/Yok %15.28
ebe	Deri Lezyonu	Var %96.53/Yok %3.47
atkaktfazyk	Başka bir nedene bağlanmayan AA amiloidoz	Var %86.11/Yok %13.89
titrpteinvar	TİT'de protein varlığı	Var %16.67/Yok %83.33
yygnmutvar	MEFV mutasyon varlığı	Var %69.44/Yok %30.56
MEFV	MEFV geninin mutasyonları	Homozigot %41.0 / Heterozigot %59.0


Sayısal değişkenlere ait tanımlayıcı istatistikler Tablo 2'de verilmiştir.

Tablo 2: Veri setindeki sayısal değişkenlere ait tanımlayıcı istatistikler

	smptmyas	atksur	atksklg
<b>Ortalama</b>	18.92	2.94	61.28
<b>Standart Sapma</b>	10.44	1.21	42.43
<b>Medyan</b>	17.0	3.0	60.0
<b>IQR</b>	16.0	2.0	50.0
<b>Min</b>	2.0	1.0	1.0
<b>Max</b>	45.0	7.0	180.0
<b>*Shapiro-Wilk p-değeri</b>	0.000451	0.0	0.0

\* Shapiro-Wilk p-değeri sayısal verilerin normal dağılıma sahip olup olmadığını belirler.

Shapiro-Wilk p-değerlerinden görüldüğü gibi veri setindeki sayısal veriler normal dağılımlı değildir. Veri setindeki eksik veriler Şekil 1'de yüzde olarak gösterilmiştir ve Tablo 3'te eksik veri değerleri ve ortalama / mod değerleri verilmiştir.



Şekil 1 Veri setindeki eksik verilerin yüzdelik değerleri.

Tablo 3: Eksik veri sayıları, yüzdeleri ve ortalama/mod değerleri

Özellik	Eksik Veri Sayısı	Eksik Veri Yüzdesi	Ortalama/Mod
MEFV	46	29.6774	heterozigot
ailefmf	43	27.7419	var
ates	0	0.0000	var
atkaktfazyk	0	0.0000	Var
atksklg	21	13.5484	79.85
atksur	31	20.0000	3.56
cinsiyet	0	0.0000	k
dyer	0	0.0000	marmara
ebe	12	7.7419	yok
gogagrs	6	3.8710	Yok
klcdzykblkagrs	5	3.2258	Yok
kolsisinynt	0	0.0000	Var
krnagrsatk	0	0.0000	Var
smptmyas	0	0.0000	18.92
titrpteinvar	1	0.6452	yok
yygnmutvar	0	0.0000	var

### B. Eksik Verilerin Doldurulması ve Aykırı Değerlerin Ele Alınması

Veri ön işleme aşamasında eksik veri ve aykırı değerlerin yönetimi için bir dizi teknik uygulanmıştır. Özellikle, 'atksur' ve 'atksklg' gibi korelasyonlu sayısal değişkenlerde gözlenen eksik veriler, K-En Yakın Komşu İmputasyon (KNNImputer) algoritması kullanılarak doldurulmuştur. Bu yaklaşım, eksik verinin doğal yapısını ve değişkenler arası ilişkileri korumayı amaçlamaktadır.


Ayrıca, 'atksur' ve 'atksklg' değişkenlerinde tespit edilen aykırı değerler, modelin performansını olumsuz etkileyeceği gerekçesiyle veri setinden çıkarılmıştır. Bu, modelin genelleştirme kabiliyetini artırmayı ve aşırı uyumu önlemeyi amaçlamaktadır.

Kategorik değişkenler arasındaki ilişkiler, karşılıklı sayım grafikleri kullanılarak analiz edilmiştir. Bu analizler sonucunda belirlenen ilişkili kategorik değişkenlerdeki eksik veriler, gruplama ve mod işlemleri ile doldurulmuştur. Bu strateji, eksik verinin rastgelelik olmaksızın, değişkenler arasındaki doğal ilişkileri yansıtan bir şekilde doldurulmasını sağlamıştır.

### III. SONUÇLAR

#### A. Seçilen Kriterler Altında Kolşisin Yanıtı

Bu bölümde, eksik veri içermeyen toplam 144 hasta verisi seçilen kriterler ("ateş", "karın ağrısı atağı", "atak akut faz yüksekliği" semptomları var) temelinde değerlendirildiği bir çalışma sunulmaktadır. Kriterlere uyan ve "kolşisin yanıtı" var olmayan hasta sayısı 22, bu da toplam hasta popülasyonunun yaklaşık %15.28'sini oluşturmaktadır (Şekil 2). Diğer yandan, belirlenen kriterlere uyan veya uymayan ve kolşisin tedavisine olumlu yanıt veren toplam 122 hasta bulunmaktadır. Şekil 2'nin incelemesi, en az bir kriterin 'yok' değerini aldığı durumlarda kolşisin tedavisine hastaların olumlu yanıt verdikleri görülmektedir.



Şekil 2 Kolşisin yanıtını ateş, karın ağrısı atağı ve atak akut faz yüksekliği semptomlarının varlığı ve yokluğuna göre sayısal dağılımları

#### B. Demografik ve Klinik Karakteristikler: Kolşisin Tedavisine Yanıtız Hastaların Analizi

Bu çalışmada ele alınan toplam 144 Ailevi Akdeniz Ateşi (AAA) hastası popülasyonu içerisinde, ateş, karın ağrısı ve atak akut faz yüksekliği semptomlarına sahip, fakat kolşisin tedavisine yanıt vermeyen 22 hasta tespit edilmiştir. Bu alt grup, toplam popülasyonunun %15.28'ini oluşturmaktadır.

##### Demografik ve Coğrafi Özellikler

**Cinsiyet Dağılımı:** Alt grubu oluşturan hastaların 12'si erkek, 10'u kadındır.

**Coğrafi Dağılım:** Bu hastalardan 14'ü Marmara grubundan, 8'i ise Karadeniz grubundandır.

**Yaş:** Semptomların başlangıç yaşı ortalaması 19.09, standart sapması ise 10.91'dir.

##### Klinik Özellikler

**Atak süresi:** Atak süresi ortalaması 3.50 gün, standart sapması 1.54 gün olarak hesaplanmıştır.

**Atak sıklığı:** Atak sıklığı ortalaması 45.45 gün, standart sapması 33.70 gün'dür.

**Deri Lezyonu (Ebe):** Tüm hastalarda var olarak gözlemlenmiştir.

**Eklem Ağrıları:** Kalça, diz ve ayak bileği ağrısı 17 hastada yok, 5 hastada var olarak kaydedilmiştir.

##### Aile Öyküsü ve Genetik Faktörler

**Aile öyküsü:** 17 hastanın ailesinde AAA öyküsü olduğu, 5 hastanın ise ailesinde AAA öyküsü olmadığı tespit edilmiştir.

**Tit Protein Varlığı:** 14 hastada var, 8 hastada yoktur.

**Yaygın mutasyon:** 12 hastada var, 10 hastada yoktur.

**Genetik Mutasyonlar:** MEFV geninin heterozigot ve homozigot sayısı eşittir.

Bu bulgular, kolşisin tedavisine yanıtız hastaların özelliklerinin çok yönlü bir şekilde incelenmesi gerektiğini göstermektedir. Özellikle demografik faktörlerin, yanı sıra klinik ve genetik varyasyonların bu yanıtızlıkta rol oynayabileceği anlaşılmaktadır.

#### C. K-means Kümeleme ile Kolşisin Yanıtlarının Analizi

Bu çalışma, Ailevi Akdeniz Ateşi (AAA) hastalığı için spesifik bir veri setinin detaylı analizini sunmaktadır. Analizde, özellik seçimi, K-means kümeleme ve Kruskal-Wallis testi gibi çok yönlü istatistiksel ve makine öğrenimi teknikleri kullanılmıştır. Veri seti toplamda 144 hasta kaydı içermekte ve 15 farklı özelliği barındırmaktadır. Bu özellikler demografik bilgiler, klinik semptomlar ve genetik varyantlar gibi değişkenleri içermektedir. Hedef değişken olarak "kolsisinint" (kolşisin tedavi yanıtı) seçilmiş ve bu yanıtın var/yok durumu iki kategoriye ayrılmıştır.

##### Özellik Seçimi ve K-means Kümeleme

Özellik seçimi, modelin genelleştirme kabiliyetini artırmak ve daha anlamlı yorumlar yapabilmek için kritik bir öneme sahiptir [11]. Bu çalışmada, kategorik değişkenler One-Hot Encoding yöntemi ile sayısal formata dönüştürülmüş ve ardından ANOVA F-Değerini temel alan SelectKBest algoritması kullanılmıştır. "Atksur" (atak süresi), "ates" (ateş) ve "titprteinvar" (TİT protein) en anlamlı üç özellik olarak belirlenmiştir. K-means kümeleme algoritması bu özellikler üzerinde uygulanmış ve orijinal hedef değişken "kolsisinint" ile doğruluk oranı yaklaşık olarak %70.14 olarak hesaplanmıştır.

Şekil 3, AAA hastalarının, 'kolsisinint' değişkenine göre 'ates' (Var/Yok), 'titprteinvar' (Var/Yok), ve 'atksur' (Gün) değişkenlerinin dağılımını göstermektedir. Bu grafiklerden çıkarılan sonuçlar aşağıda verilmiştir:


**1. Ateşin Var/Yok Dağılımı:** Grafik, kolşisin tedavisine yanıt veren ve vermeyen gruplar arasında ateşin varlığı veya yokluğu açısından önemli farklar göstermektedir. Kolşisin tedavisine yanıt veren hastaların büyük çoğunluğunda ateş varken, yanıt vermeyenlerde bu oran daha düşüktür. Bu, kolşisinin ateşli semptomlar üzerinde etkili olabileceğini düşündürülebilir. Ayrıca ateşin olmadığı durumlarda kolşisin tedavisine kesin yanıt alındığı görülmektedir.

**2. TİT Protein Var/Yok Dağılımı:** TİT proteininin yokluğu, kolşisin tedavisine yanıt veren hastalarda daha yüksek görünmektedir. Bu, TİT proteininin kolşisin tedavisine yanıtın bir göstergesi olabileceğini işaret edebilir.

**3. Atak Süresi Dağılımı:** Histogram, atak süresinin kolşisin tedavisine yanıt veren ve vermeyen gruplar arasında farklı olduğunu göstermektedir. Yanıt veren grup daha kısa atak sürelerine sahipken, yanıt vermeyen grup daha uzun atak sürelerine sahiptir.

**4. Atak Süresi Değişimi:** Boxplot, kolşisin tedavisine yanıt vermeyen hastalarda atak süresinin daha yüksek varyansa sahip olduğunu göstermektedir. Bu, yanıt vermeyen hastaların atak sürelerinin daha değişken olduğunu ve tedaviye farklı şekillerde yanıt verebileceklerini göstermektedir.

Bu gözlemler, kolşisin tedavisinin etkinliğini değerlendirmede kullanılacak potansiyel biyolojik ve klinik belirteçlerin yanı sıra, tedaviye yanıt etkileyebilecek faktörler hakkında önemli bilgiler sunmaktadır.



Şekil 3 Kolşisin yanıtına göre Atak Süresi, TİT Protein ve Ateş değişkenlerinin dağılımları

### İstatistiksel Analizler: Kruskal-Wallis Testi

Kruskal-Wallis testi, çeşitli klinik ve demografik özelliklerin AAA hastalarının kolşisin tedavisine yanıtı ile ilişkisini derinlemesine incelemek amacıyla kullanılmıştır [12, 13]. Özellikle, 'titprteinvar', 'atksur' ve 'ates' değişkenleri istatistiksel olarak anlamlı farklılıklar göstermektedir.

#### Anlamlılığı Yorumlama

**1. Titprteinvar:** Bu değişken, inflamasyon modülasyonu ile ilgili proteinlerin varlığı veya yokluğunu belirtir. İstatistiksel olarak anlamlı bir p-değeri ( $p=0.007$ ) ile bu değişkenin kolşisin anti-inflamatuar etkileri üzerinde önemli bir rol oynayabileceği belirlenmiştir.

**2. Atksur:** Bu değişken, AAA hastalarının atak süresine ilişkin bilgiler sunmaktadır. İstatistiksel olarak anlamlı p-değeri ( $p=0.035$ ) ile kolşisin tedavisine yanıtını etkileyebileceği anlaşılmaktadır.

**3. Ates:** Bu değişken, hastanın ateş semptomlarının varlığı veya yokluğunu göstermektedir. İstatistiksel olarak anlamlı bir p-değeri ( $p=0.036$ ) ile kolşisin inflamatuvar süreçlerini düzenleyebileceği veya kontrol altına alabileceği ifade edilmektedir.

Bu çok yönlü analiz, mevcut veri seti üzerinden elde edilmiş olup, daha geniş kapsamlı araştırmalar için bir temel oluşturmaktadır. Özellikle, bu tür analizler, klinik pratiğe uygulama potansiyeli yüksek, kişiselleştirilmiş tedavi protokollerinin geliştirilmesine önemli bir zemin hazırlamaktadır. Hem teorik hem de uygulamalı çalışmalar

için yol gösterici olabilecek bu sonuçlar, ilerleyen araştırmalarda daha kapsamlı bir anlayışa kavuşturulabilir.

### Gelecekteki Araştırmalar İçin Öneriler

**1. Daha Geniş Veri Setleri:** Bu çalışma, sınırlı bir veri seti üzerinde gerçekleştirilmiştir. Daha geniş ve çeşitli demografik özelliklere sahip bir veri seti ile analizlerin tekrarlanması, modelin genelleştirme yeteneği artırabilir.

**2. Farklı Algoritmaların Kullanımı:** K-means dışında farklı kümeleme algoritmaları veya sınıflandırma yöntemleri kullanılarak, sonuçların güçlülüğü test edilebilir.

**3. Klinik Değerlendirme:** Seçilen özelliklerin klinik önemi, geleceğe yönelik çalışmalar veya tedavi alan ve almayan gruplar arasında rastgele atama ile yapılacak deneyler aracılığıyla değerlendirilebilir.

**4. Moleküler Analiz:** "TİT protein" gibi biyolojik göstergelerin moleküler mekanizmalarının incelenmesi, tedaviye yanıt anlamada derinlemesine bilgiler sağlayabilir.

**5. Tedavi Protokolleri:** Bu tür bir makine öğrenmesi analizi, AAA hastaları için kişiselleştirilmiş tedavi protokolleri geliştirilmesine yardımcı olabilir. Bu protokollerin klinik deneylerle test edilmesi önerilir.

## IV. SONUÇ

Bu çalışmada, Ailevi Akdeniz Ateşi (AAA) hastalığına ait bir veri seti üzerinde özellik seçimi ve K-means kümeleme yöntemleri kullanılarak kapsamlı bir analiz gerçekleştirilmiştir. Özellik seçimi ile belirlenen "atak süresi," "ates" ve "TİT protein" değişkenleri, kolşisin tedavi yanıtını belirlemede önemli faktörler olarak ortaya çıkmıştır. Kruskal-Wallis istatistiksel testi, bu değişkenlerin kolşisin tedavi yanıtı açısından istatistiksel olarak anlamlı farklılıklar gösterdiğini teyit etmiştir.

K-means kümeleme algoritması ile oluşturulan kümelerin, orijinal hedef değişken "kolşisinylnt" ile yüksek bir doğruluk oranı (%70.14) göstermesi, analizin klinik pratiğe uygulanabilirliğini desteklemektedir. Bu sonuçlar, AAA hastalarına daha etkili ve kişiselleştirilmiş tedavi protokolleri önerilebileceğini göstermektedir.

### BİLGİLENDİRME

Bu çalışma, Bilecik Şeyh Edebali Üniversitesi Etik Kurulu'nun 31.10.2022 tarihli 6 sayılı kararıyla etik yönden uygun bulunmuştur. Veri seti hastaların kimliklerini ifşa etmeyecek şekilde anonimleştirilmiştir. Bu çalışma Bilecik Şeyh Edebali Üniversitesi LEE Bilgisayar Mühendisliği Anabilim Dalı öğrencisi Muhammet İkbâl YILDIZ'ın "Makine Öğrenmesi Yöntemleri ile Ailevi Akdeniz Ateşi (FMF) Hastalığı Tespiti" başlıklı yüksek lisans tezinden üretilmiştir.

### REFERENCES

- [1] M. Tunca, Familial Mediterranean Fever (FMF) in Turkey: Results of a Nationwide Multicenter Study, *Medicine*, 84(1): p 1-11, 2005.
- [2] P. Mansueto, A. Seidita, M. Chiavetta, D. Genoves, A. Giuliano, W. Priano, A. Carroccio, A. Casuccio, E. Amodio, Familial Mediterranean Fever and Diet: A Narrative Review of the Scientific Literature, *Nutrients*, 14, 3216, 2022.

- [3] S. Üstebay, D. Ü. Üstebay, Y. Yılmaz, Ailevi Akdeniz Ateşi. Journal of Academic research in medicine, 2015.
- [4] D. Zemer, A. Livneh, Y. L. Danon, M. Pras, E. Sohar, Long-term colchicine treatment in children with familial Mediterranean fever, *Arthritis Rheum*, 34: 973-7, 1991.
- [5] R. C. Goldstein, A.D. Schwabe, Prophylactic colchicine therapy in familial Mediterranean fever. A controlled, double-blind study, *Ann Intern Med*, 81: 792-4, 1974.
- [6] V. J. Parvaneh, R. Shiari, Treatment of Colchicine-Resistant Familial Mediterranean Fever With Anakinra. *Arch Pediatr Infect Dis*, 3(3): e21664, 2015.
- [7] O. Adato, R. Brenner, A. Levy et al, Determining the origin of different variants associated with familial mediterranean fever by machine-learning, *Sci Rep*, 12, 15206 (2022).
- [8] E. Sohar, J. Gafni, M. Pras, H. Heller, Familial Mediterranean fever. A survey of 470 cases and review of the literature, *Am J Med*, 43:227-53. doi:10.1016/0002-9343(67)90167-2, 1967.
- [9] S. Ozgocmen, O. Akgul, Anti-TNF agents in familial Mediterranean fever: report of three cases and review of the literature. *Mod Rheumatol* 2011; 21: 684-90.
- [10] İ. Sarı, M. Birlık, T. Kaşifoğlu, Familial Mediterranean fever: An updated review, *Eur. J. Rheumatol*, 1: 21-33, 2014.
- [11] I. Guyon, A. Elisseeff, An Introduction to Variable and Feature Selection, *Journal of Machine Learning Research*. 3 1157-1182, 2003.
- [12] W. H. Kruskal, W. A. Wallis, Use of ranks in one-criterion variance analysis. *Journal of the American Statistical Association*, 47(260), 583-621, 1952.
- [13] M. Hollander, D.A A. Wolfe, E. Chicken, Nonparametric statistical methods. John Wiley & Sons, 2013.

# ELECTRA ve XLNET Modellerini Kullanarak X Verilerinden İntihara Meyilli İçerikleri Tespit Etme

Tolga Aydın<sup>1</sup>, Muhammed Coşkun Irmak<sup>2\*</sup>

<sup>1</sup>Bilgisayar Mühendisliği Bölümü, Atatürk Üniversitesi, Erzurum, Türkiye

<sup>2</sup>Bilgisayar Mühendisliği Bölümü, Van Yüzüncü Yıl Üniversitesi, Van, Türkiye

\*[coskunirmak@yyu.edu.tr](mailto:coskunirmak@yyu.edu.tr)

**Özet** – İntihar konusu, birçok farklı disiplin tarafından incelenen ve tarihin her döneminde karşılaşılan bir konu olmuştur. Teknolojinin gelişimi ve akıllı telefonların her yerde bulunması sebebiyle, kullanıcılar, özellikle çevrimiçi sosyal platformlar aracılığıyla duygu ve düşüncelerini rahatlıkla ifade edebilmişlerdir. Paylaşılan bu düşüncelerden biri de intihar düşüncesidir. İntiharın önlenmesi ve genç popülasyonda artan intihar oranlarının kontrol altına alınabilmesi için son zamanlarda sosyal medyada paylaşılan intihar düşüncelerinin tespiti üzerine yapılan araştırmaların sayısı her geçen gün artmaktadır. Bu çalışmada, en popüler sosyal medya platformlarından birisi olan X'te paylaşılan gönderilerden hazırlanan bir veri seti üzerinde makine öğrenmesi ve doğal dil işleme teknikleri kullanılarak bu paylaşımı yapan kişilerin intihara meyilli olup olmadığının tespitinin yapılmasına odaklanılmıştır. Önceden eğitilmiş transformatör yöntemlerinin klasik makine öğrenmesi yöntemleri ile karşılaştırmalı bir analizi sunulmuştur. Tüm modeller içerisinde en yüksek doğruluk oranı, ELECTRA modeli ile %96.61 olarak elde edilmiştir. Bu bulgular, intihara meyilli tweetlerin tespitinde transformatör modellerinin potansiyelinin yüksek olduğunu göstermekte ve özellikle ELECTRA'nın bu alanda etkili bir araç olabileceğini ortaya koymaktadır.

**Anahtar Kelimeler** – İntihar tespiti, Doğal dil işleme, ELECTRA, XLNET, Transformatör model

## I. GİRİŞ

Günümüzde, sosyal medya platformları, milyonlarca insanın düşüncelerini, duygularını ve deneyimlerini paylaştığı güçlü bir iletişim aracı haline gelmiştir. Ancak bu dijital platformlar, sadece pozitif deneyimleri değil, aynı zamanda zihinsel sağlık sorunlarının da izlerini taşımaktadır. İnternetin derinliklerinde, insanların kendilerini ifade etmek için kullandıkları bu alanlarda, intihar düşünceleri gibi ciddi zihinsel sağlık sorunlarının da izleri bulunmaktadır.

İntihar, toplumun karşı karşıya olduğu en ciddi sağlık sorunlarından biri haline gelmiştir. Özellikle genç ve orta yaşlılar arasında intihar düşünceleri ve eylemleri endişe verici bir artış göstermektedir. Dünya Sağlık Örgütü (World Health Organization – WHO) istatistiklerine göre, her yıl yaklaşık bir milyon kişi intihar nedeniyle hayatını kaybetmektedir ve ortalama olarak her 40 saniyede bir intihar gerçekleşmektedir [1]. WHO, intiharın gençler arasında ölümün ana nedeni ve yetişkinler arasında altıncı önde gelen neden olduğunu belirtmektedir. Amerikan İntiharı Önleme Vakfı (American Foundation for Suicide Prevention – AFSP) intiharla ilişkilendirilen çeşitli risk faktörlerini tanımlamıştır [1]. Bu faktörler arasında umutsuzluk, zararlı madde kullanımı, anksiyete, şizofreni gibi kişisel sorunlar; toplumdaki izolasyon, sevdiklerinin kaybı, işsizlik, zorbalık veya kötü muamele gibi sosyal faktörler; ya da hastalık, duygusal bozukluklar ve önceki intihar girişimleri gibi olumsuz olaylarla ilgili faktörler yer almaktadır. İntihar düşünceleri, sıkça zorlu yaşam koşulları, psikolojik sıkıntılar ve duygusal çalkantılarla ilişkilendirilirken, bu düşüncelerin erken teşhisi ve yardım sağlanması hayati önem taşımaktadır [1, 2]. Bu olumsuzluklara rağmen, teknoloji, bu soruna dikkat çekme ve

potansiyel intihar eylemlerini önceden belirleme konusunda umut verici bir rol oynamaktadır.

Yapılan çalışmalarda, Makine Öğrenimi (Machine Learning – ML) ve Doğal Dil İşleme (Natural Language Processing – NLP) tekniklerinin, sosyal medya verilerini analiz ederek intihar düşüncelerini tespit edebileceği gösterilmiştir [1-10]. Özellikle Derin Öğrenme (Deep Learning – DL) yapıları, bu konuda oldukça başarılı sonuçlar elde etmekte ve bu alandaki potansiyelini ortaya koymaktadır [2-4, 9, 10]. Ancak bu tekniklerin başarısını garantilemek için doğru veri setlerini oluşturmak ve etiketlemek büyük önem taşımaktadır. Bu noktada, sosyal medya platformları, intihar düşüncelerini ve risklerini belirlemek için bir veri seti oluşturmada güçlü bir kaynak olmaktadır. Kullanıcılar, bu dijital alanlarda duygularını ve düşüncelerini serbestçe ifade etmektedir, ancak bu ifadeler sıkça gözden kaçmakta veya görmezden gelinmektedir [5, 6].

Bu makale, günümüzde en çok kullanılan sosyal medya platformlarından birisi olan X (Twitter)'te paylaşılan içerikleri analiz ederek intihar düşüncelerini tespit etmeye odaklanan bir araştırmanın sonuçlarını sunmaktadır. Bu çalışmada, kullanılan makine öğrenme ve veri madenciliği teknikleri sayesinde, intihar riski taşıyan içeriklerin belirlenmesi ve erken müdahale imkânı sağlanmaktadır. Ayrıca, bu çalışma, zihinsel sağlık sorunlarını daha iyi anlamak ve önlemek için sosyal medya platformlarının potansiyelini keşfetmeye yönelik bir adım olarak da görülmektedir.

Bu çalışmada, intihara meyilli tweetleri tespit etmede, güçlü transformatör tabanlı makine öğrenme yöntemlerinden ELECTRA ve XLNET'in, klasik makine öğrenmesi yöntemleri ile karşılaştırmalı bir performans analizine yer

verilmiştir. ELECTRA, var olan metinleri daha iyi anlamak ve anlam değişimlerini yakalamak için tasarlanmış yenilikçi bir modeldir. XLNET ise dil modellemesi konusundaki sınırlamaları aşarak daha iyi sonuçlar elde etmek için kendinden önceki modellerden farklı bir yaklaşım benimsemiştir.

Çalışmanın geri kalan kısmı şu şekilde organize edilmiştir: Bölüm 2'de, literatürdeki intihara meyilli tweetlerin tespiti alanında yapılan çalışmalar sunulmuştur. Bölüm 3'te çalışmada kullanılan veri seti ve metodoloji detaylı bir şekilde anlatılmıştır. Bölüm 4'te deneysel sonuçlar verilmiş, ardından bu sonuçlar tartışılmıştır.

## II. LİTERATÜR İNCELEMESİ

Bu bölümde, intihara meyilli paylaşımların tespiti üzerine literatürde yer alan güncel çalışmalara yer verilmiştir.

Haque ve ark. (2022) çalışmalarında, sosyal medya platformlarından biri olan twitter verilerini kullanarak intihar düşüncelerinin erkenden tespiti için makine öğrenmesi (Random Forest – RF, Support Vector Machine – SVM, Stochastic Gradient Descent, Logistic Regression – LR ve Naive Bayes) ve derin öğrenme modellerinin (Long Short-Term Memory – LSTM, Bidirectional LSTM - BiLSTM, Gated Recurrent Unit – GRU, Bidirectional GRU ve Convolutional Neural Network – CNN ve LSTM'in birleştirilmiş modelleri) karşılaştırmalı analizini sunmuşlardır. Çalışmada, intihar düşüncesinin yüksek doğrulukla ve erkenden tespit edilebilmesi için önceki araştırma çalışmalarındaki sonuçlardan daha iyi bir performans değeri elde edilebilmesi amaçlanmıştır. Özellikle metin ön işleme ve öznitelik çıkarma aşamalarına odaklanılmıştır. On sekiz anahtar kelime dikkate alınarak intihar niteliğinde olan ve olmayan toplamda 49178 örneği içeren bir veri kümesi üzerinde deneysel çalışmalar yapılmıştır. Yapılan çalışmalarda en yüksek sınıflandırma performansına %93 doğruluk değeri ile RF modeli kullanılarak ulaşılmıştır. Ayrıca, derin öğrenme modellerinin kelime yerleştirme ile eğitilmesi sonucunda BiLSTM modelinin %93.6 doğruluğa ulaştığı görülmüştür [2].

Baghdadi ve ark. (2022) çalışmalarında, Arapça olarak paylaşılan tweetlerden oluşan bir veri seti hazırlamışlardır. Hazırlanan bu veri setinde 1074 normal ve 956 intihara meyilli olmak üzere toplamda 2030 tweet yer almaktadır. Ayrıca çalışmada, Arapça tweetlerin ön işleminin gerçekleştirilmesi için yeni bir algoritma önerilmiştir. Model eğitiminde ise yaygın olarak kullanılan transformatör yöntemlerinden olan Bidirectional Encoder Representations from Transformers – BERT ve Universal Sentence Encoder – USE kullanılmıştır. Eğitilen modeller dengeli doğruluk, özgüllük, F1 puanı, IoU, ROC, Youden İndeksi, NPV ve ağırlıklı toplam ölçüt (weighted sum metric – WSM) performans metriklerine göre karşılaştırılmıştır. USE modelleri için, en iyi WSM değeri %80.2 iken BERT modelleri ile en iyi WSM değeri %95.26 olarak bulunmuştur [3].

Abdulsalam ve ark. (2022) çalışmalarında, Arapça tweetlerden intihar düşüncelerini tespit edebilmek için, Ağustos 2021 – Nisan 2022 tarihleri arasında atılan toplam 5719 tweeti toplayarak yeni bir Arapça intihar tweetleri veri kümesi geliştirmişlerdir. Model eğitimlerinde NB, SVM, K-En Yakın Komşu (k-Nearest Neighbors – KNN), RF ve XGBoost makine öğrenimi modellerini ve AraBERT, AraELECTRA ve AraGPT2 önceden eğitilmiş derin öğrenme modellerini kullanmışlardır. Sonuçlar, karakter n-gram özelliklerinde eğitilen SVM ve RF modellerinin, makine

öğrenimi modelleri arasında %86 doğruluk ve %79 F1 puanı ile en iyi performansı sağladığını göstermektedir. Derin öğrenme modellerinin sonuçları, AraBERT modelinin diğer makine ve derin öğrenme modellerini geride bıraktığını, Arapça tweetler veri kümesinde intihar düşüncelerinin tespitini önemli ölçüde geliştirerek %91 doğruluk ve %88 F1 puanı elde ettiğini göstermektedir [4].

Chatterjee ve ark. (2022) çalışmasında, Reddit ve Twitter'da intihar düşünceleri olan iyi etiketlenmiş bir veri kümesi oluşturulması amaçlanmıştır. Sadece klinik intihar belirtileri değil, aynı zamanda sosyal medyada çevrimiçi davranışları da içeren altı özellik grubu tanımlanmıştır. Bu özellik gruplarını kullanarak sosyal medyada intihar düşüncelerini tanımlamak için çok modlu bir model önerilmiştir. Önerilen modeller içerisinde en yüksek doğruluk değeri %87 olarak LR ile elde edilmiştir [7].


Sabri ve Mohamad (2022) çalışmasında, intihar düşüncesi olan tweetleri tespit etmek için Naive Bayes algoritmasının yeteneği araştırılmıştır. Twitter verileri, Mayıs 2021'deki Malezya'nın pandemi kilitlenmesi sırasında "stres", "anksiyete", "depresyon" ve "intihar" anahtar kelimeleri temel alınarak Tweepy kütüphanesi kullanılarak çekilmiştir. Değerlendirme sonuçları, algoritmanın intihar içerikli tweetleri tespit etmede %80.39 doğrulukla başarılı ve kabul edilebilir bir performans gösterdiğini ortaya koymuştur [8].

Deepa ve ark. (2023) çalışmasında, tweet verisini değerlendirerek twitter kullanıcı profillerindeki intihar derecesini otomatik olarak erken tespit etmeyi amaçlamışlardır. 26 Aralık 2022 – 10 Ocak 2023 tarihleri arasında atılan tweetleri, intiharla ilgili bir dizi ifade ve terimler ile izlemişlerdir. Kriterlere uyan tweetler tespit edildiğinde, bu kullanıcıların zaman çizelgesinden diğer tweetleri de toplamışlardır. Bu süre zarfında 529 kullanıcıdan 16820 tweet toplanmıştır. Bu tweetlerin %40'ı rastgele seçilip ve manuel olarak '1' intihar içeren ve '0' intihar içermeyen tweetler olarak etiketlenmiştir, geri kalanı modeli test etmek için kullanılmıştır. Veri üzerinde bir LSTM modeli uygulanmış ve intihar içeren tweetleri intihar içermeyen tweetlerden ayırmada %90.8 doğruluk elde edilmiştir. Ayrıca bu tweetler üzerine bir makine öğrenimi modeli daha uygulanmış ve 'Derinlemesine Rahatsız Edici', 'Muhtemelen Rahatsız Edici' ve 'Göz Ardı Edilebilir' olmak üzere üç derece verilmiştir [9].

Priyamvada ve ark. (2023) çalışmasında ise intihara meyilli tweetlerin tespiti için makine öğrenmesi ve derin öğrenme mimarilerinden faydalanılmıştır. Stacked CNN – 2 katmanlı LSTM modelini kullanmışlardır. Stacked CNN – 2 katmanlı LSTM mimarisi kelime gömme teknikleriyle önceki CNN – LSTM yaklaşımlarına kıyasla %93.92 sınıflandırma doğruluğu elde etmiştir [10].

## III. MATERYAL AND METOT

Bu başlıkta, çalışmada kullanılan veri setinin içeriği ve yapılan ön işleme çalışmalarına değinilmiştir. Ayrıca model eğitiminde kullanılan makine öğrenmesi ve transformatör yöntemler hakkında detaylı bilgi verilmiştir. Çalışmanın akış şeması Şekil 1'de gösterilmiştir.



Şekil 1 İntihara meyilli tweet tespitinin genel akış diyagramı

### A. Veri Seti

Bu çalışmada, intihara meyilli tweetlerin tespiti için, Syeda Aunanya Mahmud tarafından X sosyal medya platformu kullanılarak hazırlanan ve Kaggle üzerinde açık erişimli paylaşılan Suicidal Tweet Detection Dataset (STDD) olarak adlandırılan veri seti kullanılmıştır. Bu veri seti 2 sınıf etiketi (not suicide post ve Potential suicide post) ve 1787 etiketli tweetten oluşmaktadır [11]. Veri setinin güncel tweetleri içermesi ve tweet sayısının literatürdeki diğer çalışmalarda kullanılan veri setlerinden daha az olması çalışmada bu veri setinin kullanılmasının sebeplerindedir. Literatürdeki çalışmalar incelendiğinde çok sayıda veri ile doğruluk değerinin iyileştirilmesine odaklandığı görülmüştür. Bu çalışmada ELECTRA ve XLNET modellerinin az sayıda veri üzerindeki yüksek başarılarını göstermek amaçlanmaktadır.

### B. Veri Ön İşleme

Yapılan ön işlemler;

-URL'lerin silinmesi: Paylaşımlarda yer alan yönlendirme linkleri temizlenmiştir.

-Etiketlerin silinmesi: Sosyal medya platformlarında belli konuları sınıflandırmak, bir araya toplamak, öne çıkarmak gibi farklı amaçlarla kullanılan etiketleme (Hashtag) işlemi vardır. Bu amaçla kullanılan # işareti veri setinden kaldırılmıştır.

-Bahsetmelerin silinmesi: Sosyal medya platformlarında yapılan paylaşımları, özellikle görmesi istenilen kişilere ulaştırmak amacıyla bu kişilerin kullanıcı isimlerinin paylaşımlara eklenmesi işlemine bahsetme (Mention) denir. Bu amaçla kullanılan @ işareti yardımıyla veri setinde yer alan bütün bahsetmeler kaldırılmıştır.

-Noktalama işaretlerinin kaldırılması: Python dilinde tanımlı noktalama işaretleri (!"#%&'()\*+,-./:;<=>?@[\\]^\_`{|}~) model doğruluğunu etkilememesi açısından paylaşımlardan kaldırılmıştır.


-Etkisiz kelimelerin silinmesi: İngilizce dilinde etkisiz olan ve bütün paylaşımlarda yer aldığı için model eğitimini olumsuz yönde etkileyecek bazı kelimeler (stopwords) vardır. Bu kelimeler Python dilinde farklı diller için önceden belirlenerek bir kütüphane içerisine eklenmiştir. Paylaşımlarda yer alan bu etkisiz kelimeler temizlenmiştir.

-Dil bilgisi düzeltme: Yine Python dilinde tanımlı language\_tool\_python kütüphanesi ile İngilizce dilinde yazılan herhangi bir metnin dil bilgisi (grammar) uygunluğunu kontrol etmek mümkündür. Tüm paylaşımlar bu düzeltme işleminden geçirilmiştir.

-Büyük – küçük harf düzeltmesi: Paylaşımları belli bir forma sokmak amacıyla bütün alfabetik karakterler küçük harfe çevrilmiştir.

-Emojilerin silinmesi: Gönderilerden emoji, ifade (emoticons), bayrak vb. kaldırılmıştır.

Ön işleme adımlarının tamamlanmasının ardından bazı tweetler tamamen yok olmuştur ve tweet sayısı 1787'den 1771'e düşmüştür. Veri setinde en sık kullanılan kelimeler tespit edilerek Şekil 2'de verilen kelime bulutu ile gösterilmiştir.



Şekil 2 Ön işleme yapılmış veri setinin kelime bulutu

### C. Sınıflandırma

Veri temizleme işlemlerinin tamamlanmasının ardından sınıflandırma işlemine geçilmiştir. Sınıflandırma işleminin yapılabilmesi için verilerin sayısal değerlere dönüştürülmesi gerekmektedir. Bu amaçla, veriler üzerinde önce Count Vectorizer işlemi uygulanmıştır. Count Vectorizer işlemi bir kelimenin metin içerisinde kaç kere geçtiğini sayar ve bu değeri ağırlık olarak kullanır. Bu işlemin ardından metin içerisinde geçen kelimelerin buldukları metni ne kadar temsil ettiklerini ölçmek amacıyla Terim Sıklığı – Ters Doküman Sıklığı (Term Frequency – Inverse Document

Frequency – TF-IDF) işlemi yapılmıştır. Buradaki parametreler ise şunlardır;

TF (Term Frequency – Terim Sıklığı): İlgili kelimenin dokümandaki sıklığıdır. Kelimenin dokümanda geçme sayısını, dokümandaki toplam kelime sayısına bölerek elde edilir (Eşitlik 1).

$$tf(t, d) = \frac{f_d(t)}{\max_{w \in d} f_d(w)} \quad (1)$$

DF (Document Frequency – Doküman Sıklığı): TF ile benzetilmektedir ama bu kez diğer dokümanlara odaklanır. Doküman sayısının ilgili kelimenin geçtiği doküman sayısına bölünmesi ile hesaplanır (Eşitlik 2).

$$df(t, D) = \frac{|D|}{|\{d \in D : t \in d\}|} \quad (2)$$

IDF (Inverse Document Frequency – Ters Doküman Sıklığı): DF değerinin logaritması alınarak hesaplanır (Eşitlik 3).

$$idf(t, D) = \ln \left( \frac{|D|}{|\{d \in D : t \in d\}|} \right) \quad (3)$$

TF-IDF (Term Frequency-Inverse Document Frequency): Terim sıklığı ve ters doküman sıklığının çarpılması ile elde edilir (Eşitlik 4).

$$tfidf(t, d, D) = tf(t, d) * idf(t, D) \quad (4)$$

#### Transformatör Modeller

**XLNET:** Otokodlama yöntemlerinin avantajlarını birleştirmek için bir permütasyon dili modellemesini kullanan genelleştirilmiş bir otoregresif ön eğitim yöntemidir (Yang et al., 2019; Fodeh et al., 2021). Permütasyon dili modelleme, sağdan sola veya soldan sağa yerine bir cümledeki tüm olası kelime permütasyonları üzerinde çalışılmasını sağlamaktadır (Naveen et al., 2021). XLNET ve BERT modeli arasındaki temel fark, XLNET yaklaşımının Permütasyon dil modeli sayesinde, BERT yaklaşımındaki gibi belirteçlerin %15'ini maskeleyerek kalmadan modeli çift yönlü bağlamda eğitmesine izin vermesidir. Ayrıca, XLNET, LSTM gibi dizi modellerinin tekrarlama fonksiyonu ile BERT'in aynı anda terimlerle ilgilenme avantajlarını harmanlamaktadır. Bu sayede, BERT'ten farklı olarak XLNET'in cümle uzunluğu sınırlaması yoktur. Herhangi bir uzunluktaki cümleleri parçalar olarak ele alarak işler ve durumu parçalar arasında taşır. Model, bir diziyi başka bir diziyeye çevirmek için bir diziyi diğerine eşleyerek bir kodlayıcı-kod çözücü modeli aracılığıyla tüm cümleden seçici olarak bilgi çıkarır. Modelin kod çözücü kısmı, kodlayıcının gizli durumlarının her birini ağırlıklandırarak ilgili gizli durumları bulmak için kodlayıcının tüm gizli durumlarını kullanır ve bu ağırlıklar basit bir ileri beslemeli sinir ağı tarafından belirlenir [12].

**ELECTRA:** BERT gibi dil modelleme ön eğitim yöntemleri, bazı belirteçleri [MASK] ile değiştirerek girdiyi bozar ve ardından orijinal belirteçleri yeniden oluşturmak için bir model eğitir. NLP görevlerine aktarıldıklarında iyi sonuçlar vermelerine rağmen, genellikle etkili olmaları için büyük miktarda bilgi işlem gerektirirler. Ancak ELECTRA, ön eğitim için değiştirilmiş bir belirteç algılama görevi kullanır. Bir üreticiden örnek alarak bazı belirteçleri değiştirerek girdiyi bozar, ardından her bir belirtecin orijinal mi yoksa yedek mi

olduğunu tahmin etmek için bir ayrımcı eğitilir. Ayrımcının önemli bir avantajı, modelin yalnızca küçük maskelenmiş alt kümesi yerine tüm girdi belirteçlerinden öğrenmesi ve bu da onu hesaplama açısından daha verimli hale getirmesidir. BERT, küçük bir maskelenmiş alt kümeden (genellikle %15) öğrenirken, ELECTRA hesaplama açısından daha verimli olan tüm girdi belirteçlerinden öğrenilebilir [13].

#### Makine öğrenmesi modelleri

**SVM:** Vapnik tarafından 1999 yılında önerilen ve son yıllarda sınıflandırma-regresyon problemlerinde sıklıkla kullanılan bir makine öğrenmesi tekniğidir. SVM'nin temel amacı, tüm destek vektörleri arasında en büyük geometrik aralığa sahip olan ve yeni verileri sınıflandırmak için kullanılan ayırma hiperdüzlemini hesaplama yoluyla bulmaktır [14]. Bu hiperdüzlemler, ML modellerinin karar sınırları olarak adlandırılır. Destek vektörleri, hiperdüzlemin konumunu ve yönünü belirlemek için kullanılan SVM hiperdüzlemine en yakın veri noktalarıdır.

**Linear SVM:** Linear destek vektör sınıflandırıcısı, büyük veri setlerinde çalışabilme avantajına sahip çok sınıflı sınıflandırma görevi gören bir algoritmadır.

**LR:** Lojistik regresyon, esas olarak tahminler için kullanılan denetimli bir sınıflandırma algoritmasıdır. Cevap değişkenin ikili (binary) olarak gözlemlendiği durumlarda bağımlı ve bağımsız değişkenler arasındaki ilişkiyi belirlemede kullanılır. Her bir veri noktasının sınıfını tahmin etmek için kullanılan olasılık değerlerini elde ederken aktivasyon fonksiyonu olarak sigmoid fonksiyonunu kullanır [15].

**DT:** Karar ağaçları, düğüm, dal ve yapraklardan oluşmaktadır. Öznitelikler düğümler ile temsil edilir. Eğitim verilerine ait öznitelik bilgilerine göre ağaç yapısı oluşturulur ve karar sorularına verilen cevaplara göre karar kuralları oluşturulur. Oluşturulan ağacın yeni bir veri seti için genelleme kabiliyetinin belirlenmesi için test verisi kullanılır. Yeni gelen bir test verisi, ağacın kökünden başlar ve karar kuralına göre bir yaprağa gidene kadar devam eder. Her bir yaprak düğümü sadece bir sınıfa ait gözlem değerleri içerene kadar karar kuralı işletilir. Bu şekilde veriler sınıflandırılır. Karar ağaçlarında en önemli adım ağaçtaki dallanmanın hangi kritere göre yapılacağı veya hangi öznitelik değerlerine göre ağaç yapısının oluşturulacağıdır [16].

**RF:** Rastgele orman, öğrenme aşamasında eğitim veri örneklerinden rastgele bir seçimle oluşturulan birçok karar ağacını kullanır. Rastgele orman aynı zamanda bir veri örneğine ilişkin tüm karar ağaçlarının tahminlerini birbiriyle karşılaştırdığı için bir topluluk yöntemidir.

**GB:** Gradyan Arttırma, Friedman tarafından 2001 yılında tanımlanan güçlü bir makine öğrenme tekniğidir. Sırayla çok sayıda zayıf öğreniciyi inşa etmek ve onları karmaşık bir modele dahil etmeyi amaçlamaktadır [17].

**XGBoost:** Temeli GB ve DT algoritmalarına dayanan bir makine öğrenme tekniğidir. XGBoost, genel performansı iyileştiren ve aşırı uyum ya da aşırı öğrenmeyi azaltan bir dizi düzenleme içerir. Bu sayede, ağaçların karmaşıklığını kontrol ederek daha iyi bir performans elde etmeyi başarmaktadır [17].

**KNN:** Etiketsiz bir test verisi verildiğinde eğitim veri setindeki en yakın k noktayı bulur ve bu veriye en uygun olan etiketi atar. Modeldeki tek ayarlanabilir parametre olan k, sınıf üyeliği tahminine dahil edilecek en yakın komşuların sayısını göstermektedir.



#### IV. ARAŞTIRMA BULGULARI

DeneySEL çalışmalarında, Python dilinde kodları çalıştırmak için Google tarafından geliştirilen ve uç noktada yüksek GPU'lara erişim izni vererek model eğitimlerinin daha hızlı gerçekleşmesine olanak tanıyan Colaboratory ortamı kullanılmıştır. Sınıflandırma aşamasında tüm veri seti %70 eğitim (1239), %15 (266) doğrulama ve %15 (266) test verisi olacak şekilde ayrılmıştır. Çalışmada kullanılan bütün modeller doğruluk, kesinlik, duyarlılık ve F1 skor performans metriklerine göre karşılaştırılmıştır. Bu değerler Eşitlik 5-8 ile hesaplanır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (6)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (7)$$

$$\text{F1 Skor} = \frac{2 \cdot \text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (8)$$

Çalışmanın ilk aşamasında klasik makine öğrenmesi yöntemleri eğitilmiş ve performans değerleri karşılaştırılmıştır. Bu aşamada elde edilen sonuçlar Tablo 1'de verilmiştir.

Tablo 1. Klasik makine öğrenmesi yöntemlerinin performans metriklerinin karşılaştırılması

Metrikler	Modeller (%)							
	LSVM	SVM	RF	XGB	GB	LR	DT	KNN
Doğruluk	90.6	89.1	89.1	89.1	88.7	87.2	85.0	83.4
Kesinlik	90.9	95.3	97.5	94.2	98.7	93.9	86.7	79.8
Duyarlılık	84.9	76.4	74.5	77.3	72.6	72.6	73.6	78.3
F1-Skor	87.8	84.8	84.5	85.0	83.7	81.9	79.6	79.0



Makine öğrenmesi yöntemlerinde en yüksek doğruluk değeri LSVM ile %90.6 olarak elde edilmiştir. Çalışmanın ikinci aşamasında ise Transformatör yöntemlerinden ELECTRA ve XLNET'in performans değerleri incelenmiştir. Eğitilen modellerin hiperparametreleri şu şekildedir: Devir (epoch) 50, yığın boyutu (batch size) 32 ve öğrenme oranı (learning rate) 0.00005. Elde edilen sonuçlar Tablo 2'de verilmiştir.

Tablo 2. Transformatör yöntemlerinin performans metriklerinin karşılaştırılması


Metrikler	Modeller (%)	
	ELECTRA	XLNET
Doğruluk	96.61	95.11
Kesinlik	96.19	89.07
Duyarlılık	95.28	100
F1-Skor	95.73	94.22

Transformatör yöntemleri ile elde edilen sonuçlar incelendiğinde son yıllarda geliştirilen ELECTRA ve XLNET yöntemlerinin az sayıda veri üzerinde bile yüksek başarılarla ulaştığı görülmektedir. Bu modellere ait karmaşıklık matrisleri Şekil 3'te verilmiştir.

Şekil 3 incelendiğinde ELECTRA yöntemi ile 160 intihara meyilli olmayan tweetten 156'sı doğru bulunurken, 106 intihara meyilli tweetten sadece 5'i hatalı olarak bulunmuştur. XLNET modelinde ise intihara meyilli tweetlerin tamamı doğru sınıflandırılırken intihara meyilli olmayan 13 tweet intihara meyilli olarak yanlış etiketlenmiştir. Çalışmada kullanılan tüm modellerin ROC AUC grafikleri ise Şekil 4'te verilmiştir.



Şekil 3. Transformatör yöntemlerine ait karmaşıklık matrisleri (a) ELECTRA (b) XLNET



Şekil 4. Çalışmada kullanılan modellerin ROC-AUC grafiklerinin karşılaştırılması

#### V. SONUÇ VE TARTIŞMA

Bu çalışmada intihara meyilli olarak atılan tweetlerin otomatik olarak tespiti amaçlanmıştır. Bu doğrultuda, çeşitli makine öğrenmesi yöntemleri ve transformatör modelleri kullanılarak analizler gerçekleştirilmiştir. Makine öğrenmesi yöntemlerinden LSVM, SVM, LR, RF, KNN, GB, XGBoost ve DT modelleri ele alınmıştır. Bununla birlikte transformatör yöntemleri olarak ELECTRA ve XLNET modelleri kullanılmıştır. Tüm bu modeller arasında en yüksek doğruluk değerine ELECTRA yöntemi ile ulaşılmıştır. Bu model ile elde edilen değerler şu şekildedir: doğruluk (%96.61), kesinlik (%96.19), duyarlılık (%95.28) ve F1 skoru (%95.73). Bu sonuçlar, intihara meyilli tweetlerin otomatik olarak tespitinde ELECTRA'nın etkili bir model olduğunu göstermektedir.

Literatürde yer alan çalışmalar incelendiğinde doğruluk değerini artırmak için veri artırma yöntemlerine odaklanıldığı görülmüştür. Buna rağmen elde edilen doğruluk değerleri düşük kalmaktadır. Bu çalışmada az sayıda veri ile literatürdeki sonuçlardan daha yüksek bir doğruluk değeri elde edilmiştir. Bu durum ELECTRA yönteminin doğal dil işleme çalışmalarında başarılı bir şekilde kullanılabileceğini göstermektedir.

#### REFERANSLAR

- [1] Rabani, S. T., Khan, Q. R., and Khanday, A. M. U. D. "Detection of suicidal ideation on Twitter using machine learning & ensemble approaches". *Baghdad science journal*, 17(4), 1328-1328, 2020.
- [2] Haque, R., Islam, N., Islam, M., and Ahsan, M. M. "A comparative analysis on suicidal ideation detection using NLP, machine, and deep learning." *Technologies*, 10(3), 57,2022.
- [3] Baghdadi, N. A., Malki, A., Balaha, H. M., AbdulAzeem, Y., Badawy, M., and Elhosseini, M. "An optimized deep learning approach for suicide detection through Arabic tweets." *PeerJ Computer Science*, 8, e1070, 2022.
- [4] Abdulsalam, A., Alhothali, A., and Al-Ghamdi, S. "Detecting Suicidality in Arabic Tweets Using Machine Learning and Deep Learning Techniques." *arXiv preprint arXiv:2309.00246*, 2023.
- [5] Abdulsalam, A., and Alhothali, A. "Suicidal ideation detection on social media: A review of machine learning methods." *arXiv preprint arXiv:2201.10515*, 2022.
- [6] Ramírez-Cifuentes, D., Freire, A., Baeza-Yates, R., Puntí, J., Medina-Bravo, P., Velazquez, D. A., ... and González, J. "Detection of suicidal ideation on social media: multimodal, relational, and behavioral analysis." *Journal of medical internet research*, 22(7), e17758, 2020.
- [7] Chatterjee, M., Kumar, P., Samanta, P., and Sarkar, D. "Suicide ideation detection from online social media: A multi-modal feature based technique." *International Journal of Information Management Data Insights*, 2(2), 100103, 2022.
- [8] Sabri, N. M., and Mohamad, N. A. "Detection of Suicidal Tweets Based On Naïve Bayes Algorithm." *International Journal of Advanced Research in Technology and Innovation*, 4(3), 47-59, 2022.
- [9] Deepa, J., Shriraman, S., Shruti, V. V., and Vasanth, G. "Detecting and Determining Degree of Suicidal Ideation on Tweets Using LSTM and Machine Learning Models." *Journal of Survey in Fisheries Sciences*, 10(2S), 3217-3224, 2023.
- [10] Priyamvada, B., Singhal, S., Nayyar, A., Jain, R., Goel, P., Rani, M., and Srivastava, M. "Stacked CNN-LSTM approach for prediction of suicidal ideation on social media." *Multimedia Tools and Applications*, 1-22, 2023.
- [11] Mahmud, S. A., *Suicidal Tweet Detection Dataset*, (Son Erişim Tarihi: 30.09.2023), <https://www.kaggle.com/datasets/aunanya875/suicidal-tweet-detection-dataset>
- [12] Naveen, S., Kiran, M. S. R., Indupriya, M., Manikanta, T. V., and Sudeep, P. V. "Transformer models for enhancing AttnGAN based text to image generation." *Image and Vision Computing*, 115, 104284, 2021.
- [13] Clark, K., Luong, M. T., Le, Q. V., and Manning, C. D. "Electra: Pre-training text encoders as discriminators rather than generators." *arXiv preprint arXiv:2003.10555*, 2020.
- [14] Li, X., Li, L., Ma, W., & Wang, W. "Two-phase flow patterns identification in porous media using feature extraction and SVM." *International Journal of Multiphase Flow*, 104222, 2022.
- [15] Singh, N., Jena, S., and Panigrahi, C. K. "A novel application of Decision Tree classifier in solar irradiance prediction." *Materials Today: Proceedings*, 58, 316-323, 2022.
- [16] Kavzoğlu, T., and Çölkese, İ. "Karar ağaçları ile uydu görüntülerinin sınıflandırılması." *Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-45, 2010.
- [17] Yangın, G. "XGBoost ve Karar Ağacı Tabanlı Algoritmaların Diyabet Veri Setleri Üzerine Uygulaması" Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalı, İstanbul, 2019.

# Palmprint Recognition Using Pre-Trained Convolutional Neural Networks

Nader Ebrahimpour<sup>1\*</sup> and Faruk Baturalp Günay<sup>2</sup>

<sup>1</sup>*Papilon Savunma, Ankara, Turkey*

<sup>2</sup>*Department of Computer Engineering, Atatürk University, Erzurum, Turkey*

*\*(nebrahimpour@ktu.edu.tr) Email of the corresponding author*

**Abstract** –Palmprint recognition (PR) has garnered significant interest due to its distinctive characteristics and potential applications as a robust and secure biometric authentication (BA) method across various domains. This paper introduces a novel approach to enhance PR using pre-trained Convolutional Neural Network (CNN) models. The proposed method harnesses the capabilities of Deep Learning (DL) and Transfer Learning (TL) to improve palmprint recognition by leveraging state-of-the-art CNN architectures for feature extraction and classification. This proposed method begins by exploring the potential of pre-trained CNN architectures, including ShuffleNet, EfficientNet, and MobileNet, as feature extractors for palmprints. In the next step, extracted feature vectors are compared using the Cosine Similarity (CS) method. The proposed method is thoroughly evaluated through comprehensive experiments. Results of evaluations demonstrate that pre-trained CNN models excel at recognizing palmprints for biometric authentication, establishing their proficiency in this domain. Consequently, this paper illuminates the inherent capabilities of pre-trained CNN models as a potent tool for advancing PR, introducing an innovative facet to BA methodologies.

**Keywords** – *Palmprint Recognition, Convolutional Neural Networks, Biometric Authentication*

## I. INTRODUCTION

BA, which involves identifying individuals through their distinct physical or behavioral characteristics, has now assumed a pivotal role in contemporary security systems. In an era dominated by the need for foolproof access control methods, verification of payments and identity validation, biometric technologies have emerged as indispensable instruments that guarantee privacy and protect sensitive data [1]. PR is an attractive and effective means of authentication among the various forms of BA that have garnered attention [2].

The palmprint, the impression of the palm's unique ridges and valleys, offers a compelling biometric modality due to its several advantageous characteristics [3]. Palmprints present a broader range of applications, including access control to secured facilities, user verification for mobile devices, and forensic analysis. Palmprints are also known for their stability and durability, making them well-suited for long-term BR [4].

The extraordinary development of DL techniques, notably CNNs, is one of the key causes influencing the revival of palmprint recognition. CNNs are highly adept in computer vision tasks like object detection, facial recognition, and picture categorization. These networks are excellent at feature extraction, enabling them to learn discriminative characteristics from raw data [5] automatically. Palmprint Recognition with CNNs promises to be more accurate, robust, and flexible authentication [6].

This paper discusses using pre-trained CNN models already trained on enormous datasets for general object recognition tasks for PR. By utilizing TF, the potential of these pre-trained models as feature extractors for palmprint images is investigated, thereby utilizing their capacity to capture complex patterns and representations. The main goal of this study is to determine whether it is feasible to use pre-trained

CNNs for PR and to evaluate how well they perform compared to conventional techniques.

The remainder of this paper is structured as follows: Section 2 presents an overview of the related work in the PR field. Section 3 delves into the detailed explanation of the proposed method. Section 4 is dedicated to presenting the results and discussing the findings. Finally, Section 5 encapsulates the paper with a comprehensive conclusion.

## II. RELATED WORKS

PR has undergone significant advancements over the years as a branch of BA. This section reviews relevant literature and highlights critical contributions in PR, focusing on approaches utilizing CNNs.

In [7], Matkowski et al. stated that soft biometric characteristics such as gender, ethnicity, or age may provide helpful information for biometric and forensic applications. Researchers used, for example, face, gait, iris, hand, etc., to classify such features. Even though palms have been widely studied for biometric identification, relatively less attention has been paid to palm soft biometrics. In this work, several deep learning models are set and evaluated in gender and ethnic classification scenarios based on palms. The results show that for sex and ethnicity classification in an uncontrolled environment, full-hand images are more suitable than fingerprint images.

In [8], Aberni et al. stated that among the various biometric features that can be extracted from the hand, the palm vein structure is a reliable and reliable source to identify or verify a person's identity. Several methods have been presented in different research based on this fact. To further improve the performance of these methods, this paper presents a new palm vein identification method for personal authentication and identification based on a competitive coding program using a multi-scale local binary pattern with ant colony optimization.

The results obtained in the PolyU-MS database show that the proposed method offers acceptable performance for palm recognition.

Jung et al. [9] have highlighted the expanding role of automatic BA systems in various domains, encompassing applications such as automated identity verification, information capture, security checks, and protection against identity fraud. As biotechnology advances, the market witnesses the emergence of biometric-based identification systems that demand precision and user-friendliness. Among these biometric modalities, palm vein identification stands out, characterized by its ability to analyze the unique features of palm veins. Palm vein recognition, due to its exceptional accuracy, has garnered substantial attention when compared to alternative biometric attributes. This research introduces an innovative non-contact detection system, leveraging a high-performance adaptive background filter to capture palm vein images within the region of interest. The approach utilizes a modified CNN to establish an optimal identification model through rigorous training and testing. Notably, the implemented system operates seamlessly on a resource-constrained Raspberry Pi embedded platform while harnessing the capabilities of cloud computing technology. The experimental outcomes reveal an impressive accuracy rate of 96.54%, underscoring the system's high performance and suitability for real-world applications.

In reference [10], Stanuch et al. introduced a novel approach that employs infrared wavelengths to capture palm images. This innovative method utilizes infrared (IR) and ultraviolet (UV) wavelengths, followed by deep CNN image processing. The network aims to extract distinctive biometric features and perform user authentication. In [11], Jemaa et al. have proposed a method for identity recognition by combining two biometrics from each hand. Biometrics have been selected at two levels: palm and fingerprint. Combining these two models is possible without any restrictions for identity recognition. Additionally, using a new hybrid scheme based on aggregating rank levels leads to achieving acceptable results. In [12], Morales et al. have measured features of the ridge pattern in the palm area that are useful for BA. This review divides the desired area for biometric identification in the palm into three regions. In this work, three feature extraction methods are reviewed, and suitable features for identification are suggested. In [13], Betancourt et al. have segmented the hand's image and identified whether the hand is right or left in video images. In this work, challenges such as blocking of hands or proximity of hands have been examined.

In summary, using CNN models for biometric recognition represents a significant advancement in the field, offering promising results and opportunities for further research. This paper contributes to this work by presenting an in-depth exploration of pre-trained CNN models' efficacy in palmprint recognition and their comparative performance analysis.

### III. PROPOSED METHOD

This section outlines the proposed method for PR using pre-trained CNNs. The proposed approach aims to maximize the accuracy and effectiveness of PR by utilizing pre-trained CNN architectures and the power of TL.

#### A. Pre-trained CNN Models

CNNs already trained on large-scale picture datasets like ImageNet are known as pre-trained CNNs. Edges, shapes, and

textures are just a few examples of the essential features that these models have learned to identify and extract from photos. Utilizing pre-trained CNNs can be highly beneficial for various computer vision applications, such as semantic segmentation, object recognition, and image classification [5, 14-16]. The following provides a summary of several pre-trained models utilized in this paper.

ShuffleNet is a highly effective CNN architecture that creatively uses bottleneck blocks, group convolution, and channel shuffling. With its competitive performance and significant reduction in computational costs, this design is an excellent option for resource-constrained applications like edge computing and real-time object detection on mobile devices [17].

Model size, accuracy, and computing efficiency are all factors that EfficientNet aims to balance. It uses a compound scaling technique that gradually increases network depth, width, and resolution to improve model performance. EfficientNet uses fewer processing resources than other models while producing cutting-edge outcomes on various computer vision tasks. It helps applications with low computational requirements [18].

MobileNet is designed for embedded and mobile vision applications. The typical convolution is divided into depthwise and pointwise convolutions using depthwise separable convolutions. While maintaining comparable accuracy, this method lowers the number of parameters and computational expense. For real-time image processing on devices with limited resources, MobileNet is appropriate [19].

#### B. Cosine Similarity

CS is a measure based on calculating the cosine of the angle between two vectors. If the two vectors match (in this criterion, the sign of complete similarity) and the angle between the two vectors is zero, its value will be equal to 1. At the lowest degree of similarity between the two vectors, that is, if the angle between the two vectors is 180 degrees, the result of this criterion will be -1. This criterion is one of the most widely used in image and text processing. The equation for CS of two vectors,  $A$  and  $B$ , is as follows:

$$CS(A, B) = (A \cdot B) / (||A|| * ||B||)$$

where:

- $(A \cdot B)$  is the dot product of two vectors.
- $||A||$  is the Euclidean norm of vector A.
- $||B||$  is the Euclidean norm of vector B.

The CS formula calculates the cosine of the angle between two vectors, which indicates their similarity [20].

#### C. Problem-Solving

PR aims to recognize people from the distinctive features and patterns in their palmprints, which are stable and consistent over time. As a biometric authentication method, PR takes distinctive patterns and features from a person's palm to confirm their identity. The proposed approach is intended to complete this task precisely and successfully using pre-trained CNN models. Figure 1 provides a visual representation of the proposed method, elucidating the sequential stages of the process. So, in the following, a concise overview of the key steps involved in this method is explained.




Fig. 1 The architecture of the proposed method.

Taking a high-resolution picture of the palm is the first step in the process. The use of specialized palmprint scanners or imaging equipment guarantees the high quality and clarity of the palmprint representation in this image. The acquired palmprint image is subjected to several preprocessing steps during the preprocessing phase. First, Detecting the image's palmprint region is necessary to isolate the relevant features. The RobustPalmRoi technique is used for palmprint detection [21]. The photo is then cropped so that the palmprint area is the only thing in focus. The palmprint image is finally resized to a standard size of 224x224 pixels. These preprocessing procedures improve the consistency and suitability of palmprint images for additional analysis.

Feature extraction is a critical phase where the significant and distinctive attributes from the palmprint image are extracted. The proposed method utilizes the capabilities of pre-trained CNN models featuring cutting-edge architectures like MobileNet, ShuffleNet, and EfficientNet for feature extraction. These models have been pre-trained on vast datasets and are adept at learning hierarchical and abstract features. From these models, feature vectors with a dimensionality of 512 are extracted. These feature vectors capture the distinct traits of palmprints, facilitating a robust means of distinguishing individuals effectively.

The palmprint image comparison is based on the extracted feature vectors. The suggested technique measures how similar two palmprint images' feature vectors are by using the CS method. CS method is a reliable and understandable similarity metric. This method calculates the cosine of the angle between two feature vectors.

Making decisions based on the CS result is the final step. This step involves setting a threshold value. If the CS value between two images surpasses this threshold, the images are considered matched; conversely, if the CS result falls below the threshold, the system concludes that it is not a match, indicating different individuals.

The proposed method comprises two fundamental steps: registration and authentication. In the registration phase, the feature vector extracted from the input data is stored within the database for future reference. In the subsequent authentication step, the acquired feature vector is compared to the existing feature vectors in the database using CS. The authentication process is completed when the match score surpasses a predefined threshold. This two-step procedure forms the core of the proposed methodology, facilitating reliable and secure user verification.

The suggested PR method combines image preprocessing, deep feature extraction using pre-trained CNN models, and CS comparison to authenticate people based on their distinctive palmprint patterns. This approach provides a strong and trustworthy way to confirm identity, making it appropriate for various applications, from biometric authentication to secure access control.

## IV. RESULT AND DISCUSSION

This section presents the simulation results of the palmprint recognition system utilizing pre-trained CNNs. An inclusive evaluation was conducted to assess the system's performance in terms of accuracy and efficiency.

### A. Dataset

Tongji Contactless Palmprint Dataset [22] has been used to evaluate the proposed method. This dataset established a large-scale contactless palmprint image dataset. This dataset includes images collected from 300 volunteers, including 192 males and 108 females. Among them, 235 subjects were 20~30 years old, and the others were 30~50 years old. Samples are collected in two separate sessions. Each session asked the subject to provide ten images for each palm. Therefore, 40 images from 2 palms were collected from each subject. In total, the database contains 12,000 images captured from 600 different palms. The average time interval between the first and the second sessions was about 61 days. The maximum and minimum time intervals were 106 and 21 days, respectively [22]. Figure 2 visually represents a dataset sample, showcasing palmprints from both the left and right hands. Within the scope of this study, exclusively images of the left hand were utilized to train the models used in the proposed method.




Fig. 2 Palmprints from both the left and right hands.

### B. Implementation and Results

For the implementation of the proposed method, the PyTorch library as a foundational tool is used [23]. The models' development occurs on a computing system equipped with an eight-core Intel i7 processor, 32 GB of RAM, a 1 TB SSD hard drive, and an NVIDIA GeForce GTX 3070 Ti graphics card. The dataset is partitioned into two categories: training and evaluation, facilitating the model implementation process. In this simulation, the models mentioned above undergo training under consistent conditions. The optimization method employed is Adam's optimization algorithm [24], with an initial learning rate of 0.001. The model training procedure undergoes 15 iterations in total.

In the assessment of the proposed method, involved an examination of parameters associated with model training, encompassing the analysis of training duration, validation accuracy, and model size. Validation accuracy is a fundamental metric that reflects the model's ability to accurately identify palmprints within a given dataset. A higher validation accuracy indicates a more dependable model for palmprint recognition, a crucial aspect in authentication and security applications. The result presented in Table 1 illustrates that utilizing pre-trained CNNs substantially improves validation accuracy, establishing the proposed method as a compelling option for palmprint recognition tasks.

Table 1 Assessing Three Pre-Trained Models with the Proposed Method

	Val-Accuracy	Val-Loss	Training Duration	Model Size
<b>MobileNetV2</b>	0.9955	0.0173	28M+ 37S	13.3 MB
<b>ShuffleNetV2</b>	0.9941	0.0946	28M + 2S	4.8 MB
<b>EfficientNetB0</b>	0.9947	0.0115	29M + 1S	20.5 MB

Training time is another essential factor in evaluating the model's practicality. Efficient training is crucial for deploying a model in real-world scenarios. By using almost lightweight CNN models, the proposed method reduces the time required for training, making the model more time-efficient. This feature is precious for applications with critical rapid response and real-time performance. The results in Table 1 highlight ShuffleNet as having the shortest training time among the models examined.

Model size is also a critical consideration, especially in resource-constrained environments. A smaller model size can be advantageous regarding storage, memory, and deployment. The study outlines that lightweight CNN models lead to a more compact model size while preserving high PR performance. This makes the proposed method suitable for deployment on devices with limited storage and computational resources.

In summary, a close examination of the data presented in Table 1 concludes that ShuffleNet emerges as a pragmatic choice for real-time applications characterized by limited computational resources. This selection proves favorable because it delivers satisfactory accuracy while maintaining a compact model size and minimizing the required training time.

## V. CONCLUSION

This paper has investigated the PR field and proposed a new approach to improve its capabilities by incorporating pre-trained CNN models. PR is gaining attention because of its unique features and potential applications as a robust and secure method of BA in various industries. The proposed approach combines the power of DL and TL to enhance PR by leveraging state-of-the-art CNN architectures to extract features from PR data and classify them to identify trends. It uses the CS method for the comparison of feature vectors. This study has shown that pre-trained CNN models can improve PR systems, introducing a new approach for BA systems. These models could make PR systems more accurate, reliable, and secure. This study evaluated the performance of three pre-trained CNN models for palmprint recognition: ShuffleNet, EfficientNet, and MobileNet. The models were fine-tuned on the Tongji Contactless Palmprint dataset to improve their accuracy on palmprint data. The results showed that all three models achieved high accuracy, with MobileNet performing the best. The findings suggest that pre-trained CNN models are a promising approach for PA in BA applications. Considering all three evaluation criteria, the superior performance of ShuffleNet becomes evident. It excels by delivering a compact model size and shorter training duration, all while retaining a commendable level of accuracy.

## REFERENCES

- [1] S.-Y. Jeon and M.-K. Lee, "Acceleration of inner-pairing product operation for secure biometric verification," *Sensors*, vol. 21, no. 8, p. 2859, 2021.
- [2] S. Zhao and B. Zhang, "Learning salient and discriminative descriptor for palmprint feature extraction and identification," *IEEE transactions on neural networks and learning systems*, vol. 31, no. 12, pp. 5219-5230, 2020.
- [3] Y. Fan, J. Li, S. Song, H. Zhang, S. Wang, and G. Zhai, "Palmprint Phenotype Feature Extraction and Classification Based on Deep Learning," *Phenomics*, vol. 2, no. 4, pp. 219-229, 2022.
- [4] J. Dai and J. Zhou, "Multifeature-based high-resolution palmprint recognition," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 33, no. 5, pp. 945-957, 2010.
- [5] N. Ebrahimpour, "Handwritten Signatures Forgery Detection Using Pre-Trained Deep Learning Methods," presented at the International Congress of New Horizons in Sciences, Istanbul/Türkiye, 2023, 224-229.
- [6] L. Zhang, Z. Cheng, Y. Shen, and D. Wang, "Palmprint and palmvein recognition based on DCNN and a new large-scale contactless palmvein dataset," *Symmetry*, vol. 10, no. 4, p. 78, 2018.
- [7] W. M. Matkowski and A. W. K. Kong, "Gender and ethnicity classification based on palmprint and palmar hand images from uncontrolled environment," in 2020 IEEE International Joint Conference on Biometrics (IJCB), 2020: IEEE, pp. 1-7.
- [8] Y. Aberni, L. Boubchir, and B. Daachi, "Palm vein recognition based on competitive coding scheme using multi-scale local binary pattern with ant colony optimization," *Pattern Recognition Letters*, vol. 136, pp. 101-110, 2020.
- [9] S.-Y. Zhong et al., "An automated biometric identification system using CNN-based palm vein recognition," in 2020 international conference on advanced robotics and intelligent systems (ARIS), 2020: IEEE, pp. 1-6.
- [10] M. Stanuch, M. Wodzinski, and A. Skalski, "Contact-free multispectral identity verification system using palm veins and deep neural network," *Sensors*, vol. 20, no. 19, p. 5695, 2020.
- [11] S. B. Jemaa and M. Hammami, "Human Identification Based on the Palmar Surface of the Hand," in 2016 13th International Conference on Computer Graphics, Imaging and Visualization (CGiV), 2016: IEEE, pp. 51-56.
- [12] A. Morales, A. Kumar, and M. A. Ferrer, "Interdigital palm region for biometric identification," *Computer Vision and Image Understanding*, vol. 142, pp. 125-133, 2016.
- [13] A. Betancourt, P. Morerio, E. Barakova, L. Marcenaro, M. Rauterberg, and C. Regazzoni, "Left/right hand segmentation in egocentric videos," *Computer Vision and Image Understanding*, vol. 154, pp. 73-81, 2017.
- [14] N. Ebrahimpour, M. A. Ayden, and B. Altay, "Liveness control in face recognition with deep learning methods," *The European Journal of Research and Development*, vol. 2, no. 2, pp. 92-101, 2022.
- [15] N. Ebrahimpour, "Iris Recognition Using Mobilenet For Biometric Authentication," presented at the 9th INTERNATIONAL ZEUGMA CONFERENCE ON SCIENTIFIC RESEARCH, Gaziantep, Turkey, 2023.
- [16] H. Chen et al., "Pre-trained image processing transformer," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2021, pp. 12299-12310.
- [17] X. Zhang, X. Zhou, M. Lin, and J. Sun, "Shufflenet: An extremely efficient convolutional neural network for mobile devices," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 6848-6856.
- [18] M. Tan and Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," in *International conference on machine learning*, 2019: PMLR, pp. 6105-6114.
- [19] A. G. Howard et al., "Mobilenets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861*, 2017.
- [20] A. R. Lahitani, A. E. Permasari, and N. A. Setiawan, "Cosine similarity to determine similarity measure: Study case in online essay assessment," in 2016 4th International Conference on Cyber and IT Service Management, 2016: IEEE, pp. 1-6.
- [21] Leosocy, "A robust algorithm for extracting ROI from palm image taken by mobile phone." <https://github.com/leosocy/RobustPalmRoi> (accessed).
- [22] L. Zhang, L. Li, A. Yang, Y. Shen, and M. Yang, "Towards contactless palmprint recognition: A novel device, a new benchmark, and a collaborative representation based identification approach," *Pattern Recognition*, vol. 69, pp. 199-212, 2017.
- [23] E. Stevens, L. Antiga, and T. Viehmann, *Deep learning with PyTorch*. Manning Publications, 2020.
- [24] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.

## Fatura Yönetimi Uygulamasında Faturaların Makine Öğrenmesi ile Sınıflandırılması

Bilgehan AVCI<sup>1\*</sup>, Can AYDIN<sup>2</sup>

<sup>1</sup>Dokuz Eylül Üniversitesi, Yönetim Bilişim Sistemleri Bölümü, İzmir, Türkiye

<sup>2</sup>Dokuz Eylül Üniversitesi, Yönetim Bilişim Sistemleri Bölümü, DEÜ-KALMER, İzmir, Türkiye

\*[ba.bilgehanavci@gmail.com](mailto:ba.bilgehanavci@gmail.com)) Email of the corresponding author

**Öz** – Dijitalleşmenin yaygınlaşmasıyla birlikte işletmelerin muhasebe ve finans gibi yoğun ve rutin hesaplama ağırlıklı iş yükü olan departmanlarındaki iş ve işlemler dijital muhasebe uygulamaları, robotik süreç otomasyonları gibi farklı bilgi teknolojilerinden yararlanılarak gerçekleştirilmeye başlamıştır.

Bu çalışmada; aktif olarak kullanılmakta olan ve çok sayıda kullanıcısı olan bir muhasebe uygulamasında kullanıcılar tarafından gerçekleştirilmekte olan faturaların sınıflandırılması işlemi otomatik hale getirecek bir karar destek sistemi geliştirilmesi amaçlanmıştır. Mevcut durumda sisteme yüklenen faturalar ilk olarak sınıflandırmadan sorumlu kullanıcılar tarafından incelenerek hangi sınıfa ait olduğu belirlenmektedir. Daha sonra belirlenen sınıfın kullanıcılarına iletilmektedir. Bu sınıflandırma işleminin kullanıcılar tarafından yapılması hem iş gücü kaybına hem de özellikle iş yoğunluğunun yüksek olduğu dönemlerde gecikmelere yol açmaktadır. Bu doğrultuda uygulamanın veri tabanında kayıtlı yaklaşık 450 bin adet faturanın verileri düzenlenerek makine öğrenmesi teknikleri ile bir model eğitilmiştir.

**Anahtar kelimeler:** Makine Öğrenmesi, Sınıflandırma, Karar Destek Sistemi, Fatura Yönetimi.

## Classification of Invoices with Machine Learning in Invoice Management Application

**Abstract** – With the widespread adoption of digitization, businesses have started to carry out tasks and processes in departments with heavy and routine calculation-based workloads, such as accounting and finance, by utilizing various information technologies such as digital accounting applications and robotic process automations.

In this study; it is aimed to develop a decision support system that will automate the classification process of invoices carried out by users in an accounting application that is actively used and has many users. In the current situation, the invoices uploaded to the system are first examined by the users responsible for classification and the class they belong to is determined. It is then forwarded to the users of the specified class. Performing this classification process by users causes both labor loss and delays, especially during periods of high workload. In this direction, a model was trained with machine learning techniques by editing the data of approximately 450 thousand invoices registered in the application's database.

**Keywords:** Machine Learning, Classification, Decision Support System, Invoice Management.

### I. GİRİŞ

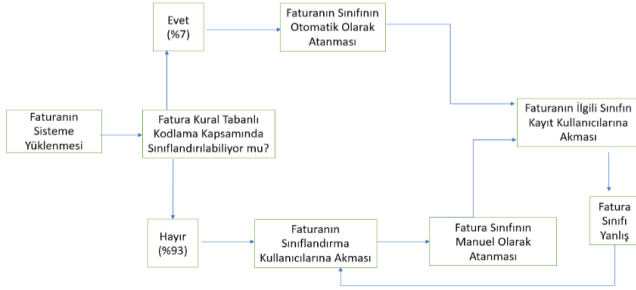
Günümüzde iş dünyası sistematik zorluklarla doludur. İş bölümleri kapsamlı ve birbiriyle bağlantılı birçok boyuttan oluşmaktadır. Pek çok araştırma karmaşıklaşan iş modellerinin hızla gelişen ve değişen iş dünyasında verimlilik ve başarının sürdürülmesinin önündeki büyük bir engel olduğunu göstermektedir. İş modelinde verimlilik tekrarlanabilir, sistematik ve düzenli süreçlerle sağlanabilir. Bu doğrultuda iş modelinin değişen şartlara göre güncellenmesi, ihtiyaca göre veya belli periyotlarla etkin bir şekilde denetimi ve iyileştirilmesi işletmeler açısından oldukça önemlidir (Sebetçi ve diğerleri, 2018).

İşletmeler bilgisayar ve internetle birlikte dijital muhasebe uygulamalarına geçmiş ve pek çok alanda olduğu gibi muhasebe departmanlarında da bilgi teknolojilerinin kullanılarak çeşitli yazılım uygulamalarından yararlanılması durumu giderek artmıştır (Tektüfekçi, 2012).

Şirketler çalışma şekillerine, büyüklüklerine ve evrak yoğunluklarına göre çok sayıda muhasebe personeli istihdam edebilmektedirler. Yine çalışma şekillerine bağlı olarak muhasebe departmanlarında iş bölümü ve görev paylaşımı yapılmaktadır.

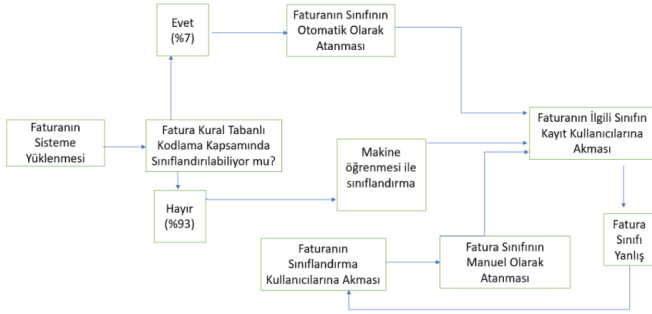
Bu çalışmada kapsamında ele alınan uygulama; kurumsal bir şirketin muhasebe departmanında aktif olarak kullanılmakta olan ve 100'ün üzerinde kullanıcısı olan bir fatura yönetimi uygulamasıdır. Uygulamadaki iş sürecinde sisteme yüklenen faturalar ilk olarak sınıflandırma işleminden sorumlu olan kullanıcıların görev ekranına düşmektedir. Sınıflandırma kullanıcıları tarafından faturanın hangi sınıfa ait olduğu manuel olarak belirlendikten sonra faturalar belirlenen sınıfın kullanıcılarının görevlerine iletilmektedir. Bu sınıflandırma işleminin manuel olarak gerçekleştirilmesi iş sürecini yavaşlatmakta ve departman verimliliğini olumsuz yönde etkilemektedir. Faturaların sınıflandırılma işlemi tamamlanana kadar kayıt aşamasına geçilememesi özellikle iş

yoğunluğunun yüksek olduğu dönemlerde kayıtlarda ve ödemelerde gecikmelere sebebiyet verebilmektedir. Ödemelerdeki gecikmeler tedarikçilerle ilişkileri olumsuz yönde etkilemekte ve vade farkı / gecikme faizi gibi ekstra maliyetlere de yol açabilmektedir.



Şekil 1. Uygulamanın geliştirme öncesi iş akış şeması.

Şekil 1'de yer alan şemada uygulamanın mevcut işleyişindeki iş akış aşamaları detaylı olarak yer almaktadır. İş akış şemasından da anlaşılacağı üzere sınıflandırma işlemi için kural tabanlı kodlama yöntemi uygulanmış olup bu yöntemin başarı oranı %7'dir. Bu yöntemde başarı oranının artırılması çok sayıda kullanıcı tarafından yeni kuralların tespit edilmesi ve tespit edilen yeni kuralların sisteme dahil edilmesi ile mümkündür. Bu çalışmada ise; uygulama veri tabanında yer alan sınıflandırılmış fatura verileri kullanılarak sınıflandırma işleminin makine öğrenmesi algoritmaları ile gerçekleştirilmesi amaçlanmıştır.



Şekil 2. Uygulama için önerilen geliştirme sonrası iş akış şeması.

Şekil 2'de yer alan şemada ise makine öğrenmesi modelinin, mevcut uygulama yaşam döngüsünün hangi aşamasında uygulamaya dahil edilebileceğinin gösterimi yer almaktadır. Mevcut sistemde kural tabanlı kodlama ile sınıflandırılmayan faturalar direkt olarak sınıflandırma kullanıcılarına iletilirken, şekil 2'de yer alan yeni yaşam döngüsünde bu aşamaya makine öğrenmesi modelinin dahil edilmesi önerilmektedir. Modelin hatalı sınıflandırdığı faturalar ise mevcut sistemde olduğu gibi; kayıt kullanıcıları tarafından, yeniden sınıflandırılmak üzere sınıflandırma kullanıcılarına iletmeye devam edilecektir.

Faturaların makine öğrenmesi algoritmaları ile sınıflandırılması kapsamında, makine öğrenmesi yöntemi ile yapılan sınıflandırma çalışmaları araştırıldığında çok sayıda ve farklı konularda çalışmaya rastlanmıştır. 2021 yılında Yangın vd. tarafından yapılan çalışmada ABD'de 130 farklı hastanenin kayıtlarında yer alan 1999-2008 yılları arasında karşılaşılmış toplam 70 bin sağlık vakası kayıtlarından elde ettikleri veri setini kullanarak hastaların diyabet rahatsızlıklarını sınıflandırmışlardır (Yangın vd. 2021). Bu çalışmada sınıflandırma işlemi için veri setini Karar Ağaçları, K-En

Yakın Komşu, Lojistik Regresyon, Naive Bayes ve Rassal Orman algoritmaları olmak üzere 5 farklı sınıflandırma algoritması ile eğittiklerinde en iyi ve en doğru sınıflandırma başarısını Rassal Orman algoritması ile elde etmişlerdir. Bağımsız 22 değişkenin yer aldığı veri setinin kullanıldığı çalışmada bireylerin diyabet rahatsızlığı olma olasılıklarını %84,78 doğruluk oranı ile tahmin edilebileceği sonucuna ulaşmışlardır. Bardelli vd. 2020 yılında gerçekleştirdikleri çalışmalarında elektronik faturalarda yer alan bilgileri kullanarak muhasebecilerin işini basitleştirecek akıllı bir sistem geliştirmeyi amaçlamışlardır. Çalışmada, muhasebe işlemleri yapılırken özel kodlar halinde sınıflandırılan faturaların hesap ve vergi kodlarının tahmin edilebilmesini sağlayacak çok sınıflı bir sınıflandırma algoritması önerilmiştir (Bardelli vd. 2020). Farklı sınıflandırma algoritmalarının başarı oranlarının karşılaştırıldığı çalışmada en yüksek sınıflandırma başarı oranının Rassal Orman algoritması ile elde edildiği gözlemlenmiştir. Kazan vd. 2019'daki çalışmalarında bir e-ticaret sitesinden elde ettikleri, ürün bilgileri etiketlenerek oluşturulmuş veri setini eğiterek ürünleri 9 farklı sınıfa ayırarak şekilde tahminleme yapmayı amaçlamışlardır (Kazan vd. 2019). Çalışmada veri seti farklı makine öğrenmesi algoritmaları ile eğitilerek algoritmaların ürünlerin kategorilerini doğru tahminleme başarıları karşılaştırılmıştır. Eğitim aşamasında denedikleri makine öğrenmesi algoritmaları Karar Ağacı, Random Forest, Multinomial Naive Bayes (Multinomial NB): Lojistik Regresyon, Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM) algoritmalarıdır. Çalışma sonunda ürünler 6 kategoride sınıflandırılmış ve sonuçların başarı oranları birbirleriyle karşılaştırılmıştır. Birbirine yakın özellikleri taşıyan veri setlerinde elde edilen başarı oranlarına göre daha düşük çıktığı gözlemlenmiştir. Çalışmada kullanılan sınıflandırma algoritmalarının ortalama başarıları karşılaştırıldığında Destek Vektör Makineleri (DVM) ve Yapay Sinir Ağları (YSA) ((Multi-Layer Perceptron (MLP) (aktivasyon='logistic sigmoid')) algoritmalarının yaklaşık olarak %97 başarı oranları ile diğer yöntemlere göre daha yüksek sonuçlar verdiği görülmüştür.

Çalışmanın algoritma seçimi aşamasında literatür taramasının kapsamında incelenen çalışmalarda sıklıkla uygulanan ve yüksek doğruluk oranı elde edilen algoritmalar tercih edilmiştir.

## II. YÖNTEM

### II.1 Verilerin Toplanması

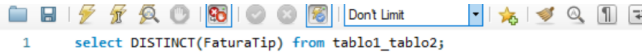
Bu aşamada uygulama verilerinin yer aldığı MySQL veri tabanı tabloları incelenmiş ve veri setine dahil edilebilecek olan fatura verileri ve fatura sınıfı bilgisi verilerinin 3 farklı tabloda yer aldığı tespit edilmiştir. Ayrıca veri tespiti aşamasında uygulama kullanıcıları ile toplantılar gerçekleştirilerek uzman görüşüne de başvurulmuştur. Veri setine dahil edilecek veriler belirlenirken; ilerleyen süreçte geliştirilen modelin sisteme dahil edilmesinde durumunda anlamlı bir şekilde modelden faydalanılabilesi için verilerin herhangi bir işlem yapılmamış, faturaların uygulamaya yüklendikleri ilk aşamada veri tabanına otomatik olarak kayıtları gerçekleşen verilerden oluşmasına özen gösterilmiştir. Bu tablolardan birinde kayıtların birden fazla sayıda tutulabildiği anlaşılmış ve bu tablodaki fazla veriler temizlenmiştir. Sql sorguları ile uygulamada faturaların kaç farklı sınıfa ayrıldığı ve hangi



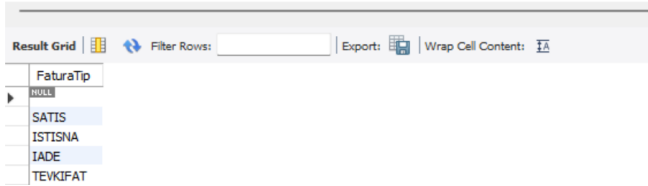
sınıftan kaç tane fatura bulunduğu bilgileri elde edilmiştir. Faturaların 7 farklı sınıfa ayrıldığı ve ulaşım ve reklam sınıflarına dahil faturaların toplam faturaların yaklaşık olarak %2'sini oluşturduğu tespit edilmiştir. Bu sınıflara ait verilerin veri setinden çıkarılmasına karar verilmiştir. Sonrasında tablolar veri bütünlüğü korunacak şekilde birleştirilmiş ve Excel formatında lokal bilgisayara aktarılmıştır.

## II.II. Veri Ön İşleme Aşaması

Veri ön işleme aşamasında Excel formatına aktarılan veriler tekrar incelenerek veri temizleme işlemine devam edilmiştir. Sayısal olmayan verilerin kaç farklı tipte yer alabildikleri SQL sorguları ile tespit edilmiş ve bu değerler numerik hale getirilmiştir.



```
1 select DISTINCT(FaturaTip) from tablo1_tablo2;
```



FaturaTip
NULL
SATIS
ISTISNA
IADE
TEVKIFAT

Şekil 3. Farklı fatura tipi değerlerinin tespit edildiği SQL sorgusu.

Şekil 2'de veri setine dahil edilmiş olan fatura tipi değerlerinin farklı olarak hangi isimlerle yer alabildiklerinin elde edildiği SQL sorgusu örneği yer almaktadır. Bu bilgiler elde edilirken, veri setine dahil edilen veri başlıkları için ayrı ayrı hangi veri tipinden kaç adet sonuç döndüğü de farklı SQL sorguları ile incelenmiş ve hatalı kayıtlardan veya yazım yanlışları gibi hatalardan kaynaklı olarak çok az sayıda yer alan değerler veri setinden çıkarılmıştır.

## II.III. Algoritma Seçimi

Eğitim işlemleri makine öğrenmesi algoritmalarından Lojistik Regresyon, Naive Bayes, Rassel Orman, Destek Vektör Makineleri ve K- En Yakın Komşu Algoritması (K-NN) algoritmaları ile ayrı ayrı gerçekleştirilmiş ve başarı sonuçları kontrol edilerek karşılaştırılmıştır. Çalışmada veri seti %90 eğitim kümesi ve %10 test kümesi olacak şekilde belirlenmiş, verilerin %90'lık kısmı ile eğitim çalışmaları gerçekleştirilirken eğitim kümesinde kullanılmayan %10'luk kısmı ile de oluşturulan modellerin başarılarının test edilmesi amaçlanmıştır.

**Lojistik Regresyon:** Lojistik regresyon, ikili veya kategorik sonuçları tahmin etmek için kullanılan istatistiksel bir makine öğrenmesi algoritmasıdır. Bağımlı ve bağımsız değişkenler arasındaki ilişkiyi açıklamak için kullanılmaktadır. Lojistik regresyonda amaç, bağımsız değişkenlerin değerlerine dayalı olarak ortaya çıkan sonucun olasılığını tahmin etmektir.

Lojistik regresyonun sıralı lojistik regresyon, multinominal lojistik regresyon ve ikili lojistik regresyon olmak üzere üç farklı türü vardır. Bunlardan sıralı lojistik regresyon kategoriye göre sınıflandırmada belli periyotlarla sıralı tahminler veren çalışmalarda kullanılmaktayken multinominal lojistik regresyon belli bir sırası olmayan en az üç veya daha fazla kategorik tahminin olduğu durumlarda kullanılmaktadır. Lojistik regresyonun bir diğer türü olan ikili lojistik regresyon

ise kategorik olarak sadece iki farklı sonucun olduğu durumlarda kullanılmaktadır (Aydın,2020).

**Naive Bayes:** Sınıflandırma işlemi, sınıflarda yer alan değişkenlerin farklı özelliklere sahip olduğu varsayımından hareketle yapan ve verideki farklı sınıfların yapılarını öğrenip yeni bir veri eklendiğinde bu yeni verinin hangi sınıfa ait olduğunu öğrenmiş olduğu sınıf yapılarına göre tespit eden basit ve etkili bir yöntemdir (Silahtaroglu,2013). Verilerin eğitilmesi işleminin hızlı gerçekleşmesi ve tahminlemedeki başarı oranının yüksek olması Naive Bayes algoritmalarının avantajlı tarafları olarak kabul edilmekle birlikte, dezavantaj olarak ise sınıflandırma problemlerindeki karmaşıklığın yüksek olduğu durumlarda bu algoritmanın yetersiz kaldığı karşımıza çıkmaktadır (Uzun, 2007).

**Rassel Orman:** Denetimli makine öğrenmesi yöntemlerinden birisidir. Boyut sayısının çok yüksek olduğu verilerin eğitiminde kullanılır. Karar ağaçlarında sık rastlanan problemlerden birisi olan aşırı öğrenme probleminin aşılmasında çözüm olarak bu yöntem kullanılabilir. Birbirinden bağımsız karar ağaçlarının eğitim ve test verilerindeki girdileri örneklemeye dayanmaktadır. Sınıflandırma çalışmalarında kullanıldığında bağımsız karar ağaçlarından birer tane sınıf oyu olarak oy çokluğuna göre sınıflandırma işlemi yapmaktadır. Regresyon problemlerinde ise tahmin ortalamalarına göre işlem yapmaktadır (Dangeti, 2017). Rassel Orman yönteminde veri kümesi de değişken kümesi de rastgele kullanılarak ağaçlar oluşturulur. Rastgele veri ve değişkenlerde oluşan bu rastgele ağaçlar bir araya geldiğinde rastgele bir ormanı tanımlar. Bu yöntemde sonuç iki farklı inanca dayanır. Bunlardan birincisi her bir ağacın verinin bir bölümü için doğru tahminde bulunmasıdır. İkincisi ise değişik yerlerde hatalarla karşılaşıldığıdır. Bu şekilde karar, karar ağaçları arasındaki oylama sonucuna göre verilmektedir (Gollapudi ve Laxmikanth 2016).

**Destek Vektör Makineleri:** Yaygın olarak sınıflandırma problemlerinde kullanılır. Gözetimli öğrenme yöntemlerinden birisidir. Bir düzlem üzerindeki farklı sınıflara ait olan noktaları, bu noktalara maksimum uzaklıktaki bir çizgi ile bölmeyi amaçlar. Karmaşık ama veri miktarının fazla büyük olmadığı çalışmalar için uygun yöntemlerden birisidir. Genellikle makine öğrenimi yöntemi olarak adlandırılan karar destek sistemleri, belirli durumlarda açıkça tanımlanamayan işlemler için, verilen girdilere karşılık gelen çıktının, mevcut bilgi ve deneyimlerin yardımıyla tahmin edildiği bir işlemdir (Alpaydın, 2004).

**K- En Yakın Komşu Algoritması (K-NN):** Verilerin sınıfını tespit etmek amacıyla regresyon ve sınıflandırma çalışmalarında kullanılan denetimli öğrenme yöntemlerden birisidir. Sınıflandırma işlemi, bir düzlem üzerindeki noktaların birbirine olan mesafelerini baz alarak yapmaktadır (Özkan, 2008). K-NN, bir öğrenme aşaması bulunmayan, tembel (lazy) bir öğrenme yöntemidir. Eğitim verilerini öğrenme yöntemiyle değil veri setini ezberleme yöntemiyle çalışır. Bir verinin sınıfı bu yöntemle tahmin edilmeye çalışıldığında, sınıfı tahmin edilmeye çalışılan verinin veri setinin tamamındaki komşularına bakarak tahmin sonucu vermektedir (Karadağ ve diğerleri, 2020).

## II.IV. Veri Setinin Eğitilmesi

Verilerin eğitilmesi işlemi Python programlama dili ile gerçekleştirilmiştir. Bu işlemde Python'da yer alan numpy, pandas ve sklearn kütüphanelerinden faydalanılmıştır.

Çalışmada veri seti %90 eğitim kümesi ve %10 test kümesi olacak şekilde belirlenmiş, verilerin %90'lık kısmı ile eğitim çalışmaları gerçekleştirilirken eğitim kümesinde kullanılmayan %10'luk kısmı ile de oluşturulan modellerin başarılarının test edilmesi amaçlanmıştır.

### III.SONUÇ

Makine öğrenmesi algoritmaları ile veri seti eğitildiğinde en yüksek başarı oranı %88 doğrulukla Karar Ağacı ve Rassal Orman algoritmaları ile elde edilmiştir. Bu algoritmalar yeni veriler girilerek test edildiğinde Karar Ağacı algoritmasında aşırı öğrenme sorunuyla karşılaşılırken, Rassal Orman algoritmasında bu soruna rastlanmadığı gözlemlenmiştir. Bu sonuç ulaşım ve reklam sınıflarına ait olanlar dışındaki faturaların makine öğrenmesi yöntemi ile %88 oranında doğru sınıflandırılabileceğini göstermiştir. Eğitim verisinde dahil edilmeyen faturaların, toplam fatura sayısının yaklaşık olarak %2'sini oluşturduğu bilinmektedir. Eğitim verisine ulaşım ve reklam sınıflarına ait faturaların verilerinin dahil edilmediği dolayısıyla bu sınıflara ait faturaların model tarafından doğru sınıflandırılmayacakları göz önünde bulundurulduğunda bütün fatura sınıfları için modelin kullanılması durumunda yaklaşık olarak %2 düzeyinde bir kayıpla %86 seviyesinde bir başarı oranının elde edilebileceği anlaşılmaktadır. Gelecek çalışmalarda derin öğrenme yöntemleri ile daha başarılı sonuçlar elde edilebilir.

### REFERENCES

- [1] SEBETCİ, Ö., GÜNAY, M. B., & SEBETCİ, E. (2018). İş Süreç Yönetimi (Bpm) ve İş Akış Yönetimi (Wfm) Kavramlarına Yaklaşım. AJIT-e: Academic Journal of Information Technology, 9(33), 115-126.
- [2] Tektüfekçi, F. (2012). BİLGİ TEKNOLOJİLERİNİN MUHASEBE UYGULAMALARINA ENTEGRASYONU VE BÜTÜNLEŞİK SİSTEMLERLE OLAN ETKİLEŞİM. Organizasyon ve Yönetim Bilimleri Dergisi, 4(2), 51-59.
- [3] BAŞER, B. Ö., YANGIN, M., & SARIDAŞ, E. S. (2021). Makine öğrenmesi teknikleriyle diyabet hastalığının sınıflandırılması. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 25(1), 112-120.
- [4] Bardelli, C., Rondinelli, A., Vecchio, R., & Figini, S. (2020). Automatic electronic invoice classification using machine learning models. Machine Learning and Knowledge Extraction, 2(4), 617-629.
- [5] Kazan, S., & Karakoca, H. (2019). Makine öğrenmesi ile ürün kategorisi sınıflandırma. Sakarya University Journal of Computer and Information Sciences, 2(1), 18-27.
- [6] Aydın, K.E. (2020). Web İçerik Sınıflandırması İçin Makine Öğrenmesi (Yayınlanmamış Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi, İstanbul.
- [7] Silahtaroglu, G. (2013). Veri Madenciliği Kavram ve Algoritmaları (3. Basım). Papatya Bilim Yayıncılık.
- [8] Uzun, E. (2007). İnternet tabanlı bilgi erişimi destekli bir otomatik öğrenme sistemi.
- [9] Dangeti, P. (2017). Statistics for machine learning. Packt Publishing Ltd.
- [10] Gollapudi, S. Ve Laxmikanth, V. (2016). Practical Machine Learning. Birmingham,UK: Packt Publishing.
- [11] Alpaydın, E. (2004). Introduction To Machine Learning. United States Of America: MIT Press.
- [12] Özkan, Y. (2008). Veri Madenciliği Yöntemler (3.Baskı). İstanbul: Papatya Yayıncılık.
- [13] Karadağ, B., Bölükbaş, O. ve Ünal, M. A. (2020). Makine Öğrenmesi İle Bireysel Müşteriler İçin Finansman Ürün Önerilmesi. Academic Perspective Procedia, 3(1), 438-444.

## Yeraltı Su Seviyesinin Doğrusal Olmayan Otoregresif Sinir Ağı ile Tahmini

Ramazan Şentürk<sup>1,3\*</sup>, Rifat Kurban<sup>2,3</sup>, Fatma Çakıroğlu<sup>4</sup>

<sup>1</sup>Kayseri Üniversitesi, Lisansüstü Eğitim Enstitüsü, Hesaplamalı Bilimler ve Mühendislik Anabilim Dalı, Kayseri, Türkiye

<sup>2</sup>Abdullah Gül Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kayseri, Türkiye

<sup>3</sup>Envest Enerji ve Su Teknolojileri, Kayseri, Türkiye

<sup>4</sup> Kayseri Üniversitesi, Elektrik Elektronik Mühendisliği, Lisansüstü Eğitim Enstitüsü, Kayseri, Türkiye

\*(ramazan.senturk@envest.com.tr)

**Özet** – Yeraltı su seviyelerinin izlenmesi ve tahmini, su kaynakları yönetimi için kritik bir öneme sahiptir. İklim değişikliği, nüfus artışı ve aşırı su çıkarma gibi etkenler, yeraltı suyu rezervlerine baskı oluşturabilir. Bu nedenle, yeraltı su seviyelerinin izlenmesi, akiferlerin sağlığının değerlendirilmesine, sorunların tespit edilmesine ve su yönetimi için bilinçli kararlar alınmasına yardımcı olacaktır. Yeraltı su seviyelerinin izlenmesi yeraltı su rezervlerinin kapasitesi, hassas tarım, yağmur suyu yönetimi ve karstik ortamlar gibi özel durumlar için önemlidir. Yapay sinir ağları (YSA) yeraltı suyu seviyesi tahmininde büyük ilgi görmüştür. Bu modeller, geçmiş verileri ve ilgili parametreleri kullanarak gelecekteki su seviyelerini tahmin etmek için kullanılmıştır ve yüksek başarı sağlamaktadır. Bu çalışmada, doğrusal olmayan otoregresif sinir ağı (NAR-NN) yaklaşımı ile AquiferAuser veri setindeki LT2 kuyusu için yeraltı su seviyesinin tahmini gerçekleştirilmiştir.

**Anahtar kelimeler** – yeraltı su seviyesi tahmini, yapay sinir ağı, doğrusal olmayan otoregresif sinir ağı

### I. GİRİŞ

Yeraltı su seviyelerinin izlenmesi, su kaynakları yönetimi ve çevresel izlemenin önemli bir yönüdür. Kuyulardaki, akiferlerdeki ve diğer yeraltı su kaynaklarındaki yeraltı suyu seviyelerinin ölçülmesini ve analizini içerir. Bu bilgiler, yeraltı suyu kaynaklarının mevcudiyetini, kalitesini ve sürdürülebilirliğini anlamak için gereklidir [1].

Yeraltı suyu, içme suyu temini, sulama ve endüstriyel kullanım dahil olmak üzere çeşitli amaçlar için hayati bir öneme sahiptir. Ancak iklim değişikliği, nüfus artışı ve bilinçsiz tarımsal sulama gibi faktörler yeraltı suyu rezervleri üzerinde baskı oluşturmaktadır. Yeraltı suyu seviyelerinin izlenmesi, akiferlerin genel sağlığının değerlendirilmesine, su tahsisi ve yönetimi ile ilgili bilinçli kararlar alınmasına yardımcı olur [1].

Yeraltı su seviyelerini izlemek için çeşitli teknikler ve teknolojiler kullanılmaktadır. Bunlar arasında basınç transdüserleri veya su seviyesi kaydediciler gibi aletlerle donatılmış izleme kuyularının kullanımı yer almaktadır [1]. Uydu görüntüleri ve hava araştırmaları gibi uzaktan algılama teknolojileri de yeraltı suyu depolaması ve geniş alanlarda su mevcudiyetindeki değişiklikler hakkında önemli veriler sağlayabilmektedir [2]. Ayrıca, Sonlu Hacim Nokta Seyreltme Yöntemi (FVPDM) gibi yenilikçi yöntemler, yeraltı suyu akışlarının sürekli izlenmesi için umut vaat etmektedir [3]. Yeraltı su seviyelerinin izlenmesi, hassas tarım [1], yağmur suyu ve sıhhi kanalizasyon yönetimi [4] ve karstik ortamlar [5] gibi belirli bağlamlarda önemlidir.

Yeraltı su seviyelerinin tahmini, su kaynakları yönetimi ve planlamasının önemli bir adımdır. Yeraltı suyu seviyelerinin doğru tahmin edilmesi, bu hayati kaynağın mevcudiyeti ve

sürdürülebilirliği hakkında değerli bilgiler sağlamaktadır. Yeraltı su seviyelerine yönelik tahmin modelleri geliştirmek için yapay zekâ (YZ) ve veri odaklı modeller de dahil olmak üzere çeşitli teknikler kullanılmıştır [6-8].

Yapay sinir ağları (YSA) ve uyarlanabilir nöro-bulanık çıkarım sistemleri (ANFIS) gibi yapay zekâ yaklaşımlarını kullanan yeraltı suyu seviyesi tahmini son yıllarda büyük ilgi görmektedir [6]. Bu modeller, gelecekteki su seviyelerini tahmin etmek için diğer ilgili parametrelerle birlikte geçmiş yeraltı suyu seviyesi verilerini kullanmaktadır. YSA'lar ve ANFIS kullanılarak yapılan çalışmaların sonuçları, yeraltı suyu seviyelerini tahmin etmede umut verici doğruluk göstermektedir [9].

Bu amaçla kullanılan yaklaşımlardan biri doğrusal olmayan otoregresif sinir ağıdır (NAR-NN). NAR-NN, yalnızca bir serinin söz konusu olduğu zaman serisi tahmini için çok uygun olan dinamik bir sinir ağı modelidir [10]. Bu model, güneş radyasyonu tahmini [11], enerji tüketimi tahmini [12], rüzgâr hızı tahmini [13] ve yeraltı suyu seviyesi tahmini [10] gibi çeşitli alanlarda başarıyla uygulamaktadır. NAR-NN modeli, geçmiş yeraltı suyu seviyesi verilerini kullanarak ve potansiyel olarak çevresel girdileri dahil ederek gelecekteki yeraltı suyu seviyelerine ilişkin doğru tahminler sağlamıştır. Bu tahminler, etkili su kaynakları yönetimi, konjonktürel kullanım planlaması ve yeraltı suyu kaynaklarının sürdürülebilir kullanımı için gereklidir [14, 15].

Bu çalışmada, AquiferAuser veri setindeki LT2 kuyusu için yeraltı suyu seviyesinin tahmini NAR-NN modeli kullanılarak gerçekleştirilmiştir. Çalışmalarda, gizli katmanda farklı nöron sayıları ve farklı eğitim algoritmaları kıyaslanmıştır.

## II. MATERYAL VE YÖNTEM

Bu bölümde kullanılan veri seti, klasik yapay sinir ağı modeli ve doğrusal olmayan otoregresif sinir ağı modeli kısaca tanıtmıştır.

### A. Veri Seti

Kaggle'dan elde edilen AquiferAuser veri setinden Depth\_to\_Groundwater\_LT2 veri olarak üzerinde simülasyon çalışmaları gerçekleştirilmiştir [16].

Bu su kütlesi KUZEY ve GÜNEY adı verilen iki alt sistemden oluşur; birincisi, ikincisinin davranışını kısmen etkiler etkilemektedir. Gerçekte, kuzey alt sistemi bir su tablası (veya sınırlanmamış) akiferi iken, güney alt sistemi bir artezyen (veya sınırlanmış) yeraltı su seviyesini temsil etmektedir. GÜNEY sektörün seviyeleri LT2 kuyusu tarafından temsil edilmiştir.

Test ve eğitim için kullanılacak olan verilerin ayrıştırılmasında ön işlem olarak eksik veriler bulunmuş ve bu veriler en yakın komşular ile enterpolasyon işlemi yapılmıştır. Enterpolasyon sonucunda oluşan datadan boş olan veriler ayıklanarak deneyde kullanılacak olan veri seti oluşturulmuştur.

### B. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), son yılların en önemli teknolojik gelişmelerinden biri olarak kabul edilen derin öğrenme alanının temelini oluşturan güçlü bir matematiksel modeldir. Bu yapay zekâ yöntemi, biyolojik sinir sistemlerinden ilham alarak tasarlanmıştır ve karmaşık bilgi işleme görevlerini gerçekleştirmek için kullanılmıştır. Temelde nöronları taklit eden yapay sinir hücreleri, katmanlar halinde düzenlenmiş ve bu katmanlar arasındaki bağlantılar ağırlıklarla temsil edilmiştir. Eğitim sırasında, bu ağırlıklar, veri setine uygun hale getirilmiş ve ağ, verileri analiz edip desenleri öğrenerek görevlerini yerine getirmiştir.

Yapay Sinir Ağlarının en büyük avantajlarından biri, çok çeşitli uygulama alanlarında kullanılabilirliğidir. Görüntü ve ses tanıma, doğal dil işleme, oyunlar, finansal analiz, tıbbi teşhis, otomasyon ve daha birçok alanda bu teknoloji etkili bir şekilde kullanılmaktadır. Ayrıca, derin öğrenme yöntemleri ile büyük veri setlerinin işlenmesi ve örüntülerin tespit edilmesi gibi karmaşık görevlerde insan performansını aşabilme potansiyeline sahiptirler.

Ancak, yapay sinir ağları, büyük hesaplama kaynaklarına ve veri setlerine ihtiyaç duyan karmaşık yapılar olduğu için eğitimleri ve kullanımları bazen zorlu olmaktadır. Ayrıca, ağların iç işleyişi karmaşıktır ve sonuçlarını yorumlamak genellikle zorlu olmaktadır. Bu nedenle, yapay sinir ağlarının doğru bir şekilde tasarlanması, eğitilmesi ve uygulanması için uzmanlık gerektirmektedir. Yapay sinir ağları, gelecekte birçok alanda daha fazla yenilik ve ilerleme sağlama potansiyeli taşıdığı için bu alandaki araştırmalar ve geliştirmeler hızla devam etmektedir.

Doğrusal olmayan oto-regresif sinir ağı (Nonlinear Autoregressive Neural Network), kısaca NAR-NN olarak isimlendirilmiş bir derin öğrenme modelidir. Bu model, özellikle zaman serileri analizi ve tahmini gibi uygulamalarda

kullanılabilen bir tür yapay sinir ağıdır. Temel amacı, önceki zaman adımlarındaki girdilere dayalı olarak gelecekteki değerleri tahmin etmektir.

NAR-NN, geleneksel Autoregressive (AR) modellerinden farklı olarak, karmaşık ve doğrusal olmayan ilişkileri öğrenmek için derin öğrenme tekniklerini kullanılmıştır. Geleneksel AR modelleri, geçmiş zaman adımlarındaki veriler arasındaki doğrusal ilişkileri yakalamaya odaklanırken, NAR-NN, daha karmaşık ve esnek ilişkileri ifade etmektedir. Bu, zaman serilerinin karmaşıklığına ve dinamizmine daha iyi uyum sağlayabilmektedir.

Doğrusal olmayan otoregresif sinir ağı, özellikle finansal tahminler, doğal dil işleme ve çeşitli mühendislik uygulamaları gibi alanlarda başarılı bir şekilde kullanılmaktadır. Bu model, veri analitiği, tahmin ve kontrol sistemleri gibi birçok alanda önemli bir araç haline gelmektedir.

Klasik ileri beslemeli yapay sinir ağı (Feedforward NN) ile doğrusal olmayan otoregresif sinir ağı (NAR-NN) arasındaki temel farklardan biri bağlantı yapısıdır. Klasik ileri beslemeli yapay sinir ağı, bilgi akışının yalnızca bir yönde olduğu bir yapıya sahiptir. Girdiler, gizli katmanlar ve çıkışlar arasında doğrusal olmayan aktivasyon fonksiyonlarıyla birleştirilmiştir, NAR-NN, zaman serileri analizi için tasarlanmıştır ve geçmiş zaman adımlarındaki verilere dayalı olarak gelecekteki değerleri tahmin etmek amacıyla özel olarak tasarlanmıştır. Bu nedenle, NAR-NN'nin bir otoregresif (kendini geri besleyen) yapısı vardır, yani her çıkış, önceki çıkışları veya girdileri geri beslemesi mümkün olmaktadır.

Bir diğer önemli fark, bu modellerin kullanım alanlarındadır. Klasik ileri beslemeli yapay sinir ağı, genellikle statik verilerin işlenmesi ve sınıflandırma veya regresyon gibi görevler için kullanılmaktayken, NAR-NN özellikle zaman serilerinin analizi ve tahmini için tasarlanmaktadır. Geçmiş zaman adımlarındaki verilere dayalı olarak gelecekteki değerleri tahmin etme yeteneği ile öne çıkmaktadır.

Aktivasyon fonksiyonları açısından, klasik ileri beslemeli yapay sinir ağı doğrusal olmayan aktivasyon fonksiyonları (ReLU, Sigmoid, vb.) kullanılmaktadır, ancak bu fonksiyonlar önceden belirlenmekte ve sabit kalmaktadır. Doğrusal olmayan otoregresif sinir ağı ise genellikle geleneksel RNN (Recurrent Neural Network) hücrelerini kullanmakta ve bu hücreler daha esnek ve zaman serilerine uygun aktivasyon fonksiyonlarını öğrenme yeteneği sağlamaktadır.

$$y = f(b + \sum_i w_i x_i) \quad (1)$$

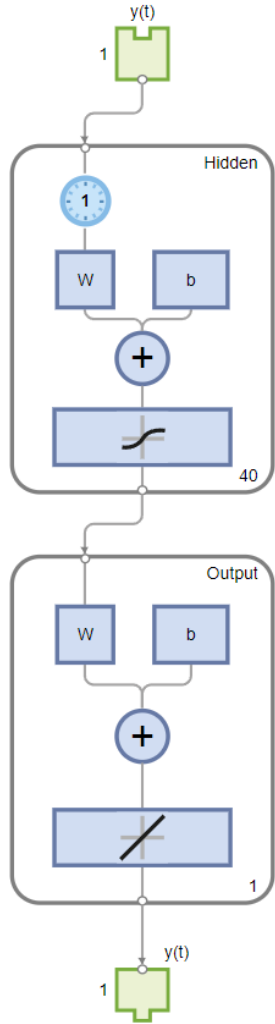
burada  $b$  nöron için bias değerini,  $f$  aktivasyon fonksiyonunu,  $w$  ağırlık katsayılarını,  $x$  giriş verisini ve  $y$  ise nöron çıkışını ifade etmektedir [16].

$$\hat{y}(t) = f(y(t-1) + y(t-2) + \dots + y(t-d)) \quad (2)$$

burada  $f$  doğrusal olmayan fonksiyon,  $d$  çıkış sinyalinin önceki değerlerini ifade etmektedir.  $\hat{y}$  ise tahmin edilen çıkışı ifade etmektedir [17].

### C. Önerilen Model

Deneylerde kullanılan NAR-NN modeli Şekil 1'de verilmiştir. Modelde  $y(t)$  girişine 1 adım gecikme uygulanmıştır. Gizli katmanda sırasıyla 2, 10 ve 40 nöron bulunan modeller ile farklı yapılar oluşturularak sonraki bölümde kıyaslamalar yapılmıştır. Gizli katmanda tanjant-sigmoid ve çıkış katmanında ise doğrusal transfer fonksiyonu kullanılmıştır.



Şekil 1 Deneylerde kullanılan NAR-NN modeli.

### III. DENEYSEL BULGULAR

Simülasyon çalışmaları Intel Core i7 işlemci ile güçlendirilmiş, 16GB RAM'e sahip bir bilgisayarda ve MATLAB 2022B versiyonunda gerçekleştirilmiştir.

Deneylerde Levenberg-Marquardt geri yayılım (backpropagation) (trainlm) ve Bayesian Regularization geri yayılım (trainbr) yapay sinir ağları eğitim algoritmaları kullanılmıştır. Ayrıca her bir eğitim fonksiyonu (trainlm ve trainbr) için farklı katman boyutları (2, 10 ve 40) kullanılarak deneyler gerçekleştirilmiştir.

Levenberg-Marquardt, yapay sinir ağları ve özellikle ağırlık güncellemesi için kullanılan bir optimizasyon algoritmasıdır. Bu algoritma, ağırlık eğitim verilerine uyum sağlamasını hedefleyerek ağırlıkları güncellemektedir. Levenberg-Marquardt, özellikle regresyon problemleri gibi ağırlık öğrenmesi gereken karmaşık işlevleri içeren problemlerde etkili olmuştur. Bu yöntem, geleneksel geri yayılım algoritmasının yanı sıra Hesaplanan Gradyan ve Gauss-Newton algoritmalarının bir kombinasyonunu kullanmaktadır. Ağırlık güncellemelerini, hatanın küçülmesini hedeflerken aynı zamanda aşırı uyarlamayı (overfitting) önlemek için düzenleme (regularization) sağlamaktadır. Levenberg-Marquardt, karmaşık ve yüksek boyutlu veri setleriyle başarılı bir şekilde çalışabilen bir optimizasyon algoritmasıdır ve özellikle doğrusal olmayan işlevlerin yakınlştırılmasında kullanılmaktadır.

Bayesian Regularization, yapay sinir ağı eğitiminde kullanılan bir optimizasyon yöntemi ve düzenleme tekniğidir. Bu yöntem, ağırlık öğrenme sürecinde ağırlıkları güncellemek için Bayes teorisine dayalı bir yaklaşım kullanmaktadır. Bayesian Regularization, ağırlıkların belirsizliklerini modellemek ve bu belirsizlikleri ağırlık eğitimi sırasında düzenlemek için bir Bayes çerçevesi içinde çalışmaktadır. Bu sayede, ağırlık aşırı uyarlamayı (overfitting) önlemesine ve daha genelleyici sonuçlar üretmesine yardımcı olmaktadır. Bu yöntem, veri seti karmaşıklığının ve boyutunun arttığı durumlarda özellikle etkili olabilir ve ağırlık güvenilir tahminler yapmasını sağlamak için belirsizlikleri dikkate almaktadır. Bayesian Regularization, ağırlık güncellemeleri sırasında hem veriye dayalı bilgiyi hem de ağırlıkların dağılımı hakkındaki bilgiyi dengeli bir şekilde kullanarak ağırlık performansını iyileştirmektedir.

Root Mean Square Error (RMSE), bir tahmin modelinin veya algoritmanın gerçek değerlerle ne kadar uygunluk gösterdiğini ölçmek için kullanılan istatistiksel bir metriktir. RMSE, özellikle regresyon analizi gibi problemlerde yaygın olarak kullanılır kullanılmaktadır. Bu metrik, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerini alır alıp, bu farkların ortalamasını alır alıp ve son olarak bu değerlerin karekökünü alarak hesaplanır hesaplanmaktadır. RMSE, daha düşük değerlere sahip olduğunda modelin daha iyi tahminler yaptığını, yani gerçek değerlerle daha yakın uyum sağladığını gösterir göstermektedir. Dolayısıyla, bir tahmin modelinin doğruluğunu ve başarısını değerlendirmek için kullanılan önemli bir ölçüttür.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (3)$$

Deneyde 5294 adet veri bulunan veri seti kullanılmıştır. Bu verinin %70'i yapay sinir ağlarının eğitimde ve kalan %30'u ise test verisi olarak kullanılmıştır.

Deneyler 30 kez tekrarlanmış ve bu tekrarlarının ortalaması ile standart sapmaları hesaplanmıştır.

Tablo 1. 30 tekrara ait RMSE değerlerinin ortalama değerleri

	Katman 2	Katman 10	Katman 40
Levenberg-Marquardt	0,0717	0,0345	0,0348
Bayesian Regularization	0,0350	0,0344	0,0346


Tablo 1'deki sonuçlar incelendiğinde katman sayısı 10 olduğunda daha iyi sonuçlar elde edildiği, en iyi sonucun Bayesian Regularization eğitim algoritması ile katman boyutu 10 seçildiğinde elde edildiği ve Bayesian Regularization eğitim algoritmasının tüm katman boyutları dikkate alındığında Levenberg-Marquardt eğitim algoritmasından daha iyi olduğu gözlemlenmiştir.

Tablo 2. 30 tekrara ait RMSE değerlerinin standart sapmaları.


	Katman 2	Katman 10	Katman 40
Levenberg-Marquardt	2,01E-01	1,27E-05	1,03E-05
Bayesian Regularization	2,20E-03	1,79E-05	3,66E-05

Tablo 2'deki sonuçlar incelendiğinde en düşük standart sapmanın Levenberg-Marquardt eğitim algoritması ve katman boyutu 40 olduğunda gözlemlenmiştir.


Şekil 2-4 de Levenberg-Marquardt eğitim algoritmaları ve Şekil 5-7 da Bayesian Regularization eğitim algoritmaları için farklı katman boyutlarıyla elde edilen test ve yapay sinir ağı sonuçlarının değerlerini gösteren grafikler bulunmaktadır. Grafikler, her eğitim fonksiyonunun katman boyutlarına göre performansını daha açık bir şekilde göstermektedir.




Şekil 2 Levenberg-Marquardt Backpropagation Katman 2




Şekil 3 Levenberg-Marquardt Backpropagation Katman 10




Şekil 4 Levenberg-Marquardt Backpropagation Katman 40



Şekil 5 Bayesian Regularization Backpropagation Katman 2



Şekil 6 Bayesian Regularization Backpropagation Katman 10



Şekil 7 Bayesian Regularization Backpropagation Katman 40

#### IV. SONUÇ VE TARTIŞMA

Bu çalışmada doğrusal olmayan otoregresif sinir ağı (NAR-NN) ile AquiferAuser veri setindeki LT2 kuyusu için yeraltı suyu seviyesinin tahmini gerçekleştirilmiştir. Deneylerde NAR gizli katmanında bulunan nöron sayısı, sırasıyla, 2, 10 ve 40 olarak belirlenmiştir. Ayrıca, eğitim algoritması olarak Levenberg-Marquardt eğitim algoritması ve Bayesian Regularization eğitim algoritması kullanılmıştır. Tüm deneyler sinir ağlarının rastgele yapısından dolayı 30'ar kez tekrar edilmiştir. Simülasyon sonuçlarına göre ortalama RMSE değeri için en iyi sonuç 0,0344 olarak gizli katmanda 10 nöron ve Bayesian Regularization eğitim algoritması ile

elde edilmiştir. İleriki çalışmalarda, literatürdeki farklı veri setleri de dahil edilerek NAR-NN yanı sıra uzun-kısa süreli bellek (LSTM) modeli ile kıyaslama yapılması planlanmıştır.

#### TEŞEKKÜR

Bu çalışmayı 2210-D Sanayiye Yönelik Yurtiçi Yüksek Lisans Burs Programı kapsamında destekleyen TÜBİTAK'a ve Envest Enerji ve Su Teknolojileri Ltd. Şti.'ne teşekkür ederiz.

#### REFERANSLAR

- [1] Vuran, M., Salam, A., Wong, R., & Irmak, S. (2018). Internet of underground things in precision agriculture: architecture and technology aspects. *Ad Hoc Networks*, 81, 160-173. <https://doi.org/10.1016/j.adhoc.2018.07.017>
- [2] Masood, A., Tariq, M. A. U. R., Hashmi, M. Z. u. R., Waseem, M., Sarwar, M. K., Ali, W., ... & Ng, A. W. M. (2022). An overview of groundwater monitoring through point-to satellite-based techniques. *Water*, 14(4), 565. <https://doi.org/10.3390/w14040565>
- [3] Jamin, P. and Brouyère, S. (2018). Monitoring transient groundwater fluxes using the finite volume point dilution method. *Journal of Contaminant Hydrology*, 218, 10-18. <https://doi.org/10.1016/j.jconhyd.2018.07.005>
- [4] Raza, U. and Salam, A. (2020). Wireless underground communications in sewer and stormwater overflow monitoring: radio waves through soil and asphalt medium. *Information*, 11(2), 98. <https://doi.org/10.3390/info11020098>
- [5] Wu, J., Chen, S., Zheng, K., Tian, L., Tai, S., Huang, Y., ... & Ye, J. (2023). Monitoring methodology study of a reservoir built on the karst depression: a large scale laboratory simulation test. *ACS Omega*, 8(16), 14520-14530. <https://doi.org/10.1021/acsomega.3c00072>
- [6] Rajae, T., Ebrahimi, H., & Nourani, V. (2019). A review of the artificial intelligence methods in groundwater level modeling. *Journal of Hydrology*, 572, 336-351. <https://doi.org/10.1016/j.jhydrol.2018.12.037>
- [7] Sureshkumar, V., Rajasomashekar, S., & Sarala, B. (2022). An efficient underground water prediction using optimal deep neural network. *Concurrency and Computation: Practice and Experience*, 35(1). <https://doi.org/10.1002/cpe.7421>
- [8] Najafabadipour, A., Kamali, G., & Nezamabadi-pour, H. (2022). Application of artificial intelligence techniques for the determination of groundwater level using spatio-temporal parameters. *ACS Omega*, 7(12), 10751-10764. <https://doi.org/10.1021/acsomega.2c00536>
- [9] Samani, S., Vadiati, M., Azizi, F., Zamani, E., & Kişi, Ö. (2022). Groundwater level simulation using soft computing methods with emphasis on major meteorological components. *Water Resources Management*, 36(10), 3627-3647. <https://doi.org/10.1007/s11269-022-03217-x>
- [10] Wünsch, A., Liesch, T., & Broda, S. (2018). Forecasting groundwater levels using nonlinear autoregressive networks with exogenous input (narx). *Journal of Hydrology*, 567, 743-758. <https://doi.org/10.1016/j.jhydrol.2018.01.045>
- [11] Boussaada, Z., Curea, O., Remaci, A., Camblong, H., & Bellaaj, N. M. (2018). A nonlinear autoregressive exogenous (narx) neural network model for the prediction of the daily direct solar radiation. *Energies*, 11(3), 620. <https://doi.org/10.3390/en11030620>
- [12] Ruiz, L. G. B., Cuéllar, M. P., Calvo-Flores, M. D., & Pegalajar, M. (2016). An application of non-linear autoregressive neural networks to predict energy consumption in public buildings. *Energies*, 9(9), 684. <https://doi.org/10.3390/en9090684>
- [13] Blanchard, T. and Samanta, B. (2019). Wind speed forecasting using neural networks. *Wind Engineering*, 44(1), 33-48. <https://doi.org/10.1177/0309524x19849846>
- [14] Mohanty, S., Jha, M. K., Kumar, A., & Sudheer, K. P. (2009). Artificial neural network modeling for groundwater level forecasting in a river island of eastern india. *Water Resources Management*, 24(9), 1845-1865. <https://doi.org/10.1007/s11269-009-9527-x>
- [15] Kurban, R. (2023). Su Temin ve Dağıtım Sistemlerinin Otomasyonunda Endüstri 4.0, Nesnelerin İnterneti, Bulut Bilişim, Makine Öğrenimi ve Optimizasyon Uygulamaları, Mühendislikte Araştırma ve Değerlendirmeler - II, 49-70, Gece Kitaplığı.
- [16] Acea Smart Water Analytics (2023, October), <https://www.kaggle.com/competitions/acea-water-prediction/data>
- [17] Benmouiza, K., & Cheknane, A. (2013). Forecasting hourly global solar radiation using hybrid k-means and nonlinear autoregressive neural network models. *Energy Conversion and Management*, 75, 561-569.

# Assessment of Undergraduate Student Graduation Projects Focusing on Deep Learning in Biomedical Sciences

Uğur Baysal

Department of Electrical and Electronics Engineering, Hacettepe University, Ankara-TÜRKİYE  
(ubaysal@ee.hacettepe.edu.tr)

**Abstract** – Biomedical Sciences are the technological disciplines that aim to explore methods to obtain, produce, reveal or produce information related to understand, model, monitor, diagnose, combat problems in human and/or animal bodies. Machine learning in biomedical technology is relatively new field of scientific research area and engineering technology application field, its growing rate is so fast that it is put into lower education levels than graduate level. In this work, educational contributions of senior year electrical and electronics engineering student projects will be discussed. After supervising four undergraduate student graduation projects, done by total of six students, it is concluded that the undergraduate electrical and electronics engineering average student is ready to apply deep learning techniques to biomedical sciences with restricted budget conditions, internet resources, available computational infrastructure and credit-hour load from the other courses leading graduation. Moreover, a student is already aware of and is ready to fully consider his professional work obligations health, safety, manufacturability, sustainability, economy direct or indirect effects to society, ethics, and environment.

**Keywords** – Biomeical Engineering, Deep Learning, Artificial Intelligence, ECG, ACS, Biology

## I. INTRODUCTION

The concepts that come into our lives with artificial intelligence are machine learning and deep learning. While machine learning can be defined as a subgroup of artificial intelligence, deep learning is also a subgroup of machine learning.

Deep Learning in artificial intelligence is an emerging working area to aid classification and decision making to human efforts by means of computer hardware and software. It can help clinicians diagnose disease, identify cancer sites, identify drug effects for each patient, understand the relationship between genotypes and phenotypes, explore new phenotypes, and predict infectious disease outbreaks with high accuracy.

Deep learning is a subset of machine learning, which is essentially a neural network with three or more layers. These neural networks attempt to simulate the behavior of the human brain from large amounts of data. Deep learning drives many artificial intelligence (AI) applications and services that improve automation, performing analytical and physical tasks without human intervention.

Biomedical Sciences are the technological disciplines that aim to explore methods to obtain, produce, reveal or produce information related to understand, model, monitor, diagnose, combat problems in human and/or animal bodies. The researchers are working for living systems from the cell scale to human beings, to explore and analyse its systematic (normal) behaviours, any problematic (pathological) case diagnosis as well as designing and substituting parts of the body by using therapeutic or prosthetic devices.

Although the idea of artificial intelligence emerged at the end of the 1950s, it has gained a lot of popularity in recent years and its usage areas have become quite widespread. After utilisation in automated industrial application, the artificial intelligence is now in many fields of biomedical science both to aid human experts to lessen cumbersome routine biomedical activities, as well as reach out a few critical conditions to act like an expert, such as remote medical diagnosis and therapy systems in not so comfortable or even hazardous environments for the experienced medical expert. All these systems imitate human brain in computer environment, by means of computational models of human brain nerve cells, i.e. neurons. Interconnection of these neurons in computational domain is representation of neural networks in human nervous system by means of computational representation pieces in software application codes.

Neural Networks (NN) use the architecture of human neurons which have multiple inputs, a processing unit, and single/multiple outputs. There are weights associated with each connection of neurons. By adjusting these weights, a neural network arrives at an equation which is used for predicting outputs on new unseen data. This process is done by backpropagation and updating of the weights.

Even though, machine learning in biomedical technology is relatively new field of scientific research area and engineering technology application field, its growing rate is so fast that it is put into lower education levels than graduate level. In this work, educational contributions of senior year electrical and electronics engineering student projects will be discussed.



## II. MATERIALS AND METHOD

The higher educational institute is internationally accredited University having Faculty of Medicine, Faculty of Engineering, Faculty of Education, Faculty of Arts and others, such as literature, social sciences. The students participated in this study is senior level students attempting to get B.Sc. Degree in Electrical and Electronics Engineering. In the senior level of their four-year education, a two-term project course is offered and the registered student is expected to compile existing information (techniques, articles, patents if applicable etc) about the topic of the project, then analyse the information, select the appropriate ones for the project. Then comes the implementation stage in which the student (or student group) is supposed to design the solution, construct the first prototype (hardware, software or hybrid), test its performance with respect to project constraints announced and agreed in the beginning. According to this first test, preliminary results are obtained, documented in interim reports and weekly progress reports. Followingly, second and further prototypes are developed, tested in more rigorous constraints, documented in the end of the year by term report, poster, descriptive video clip in internet environment and besides the project is defended against other lecturers and students in a common gathering in project exhibition format.

This work samples four of these projects offered in the last year to give some experience in deep learning experience in biomedical classification. The projects are briefly described followingly, where detailed information can be found in their project term reports as cited.

### A. Project 1 : Application of Deep Learning Algorithms to Classify Electrocardiography (ECG) Signals obtained from Acute Coronary Syndrome (ACS) [1].

This project aims to use deep learning algorithm to classify some heart signals obtained from electrocardiogram (ECG) device. In addition, it is aimed to detect patients with "Acute Coronary Syndrome (ACS)" by means of this algorithm. ECG is a very important method used to observe the electrical impulses produced by the heart and to detect heart diseases. In addition, the EKG is very practical and is life-saving in many situations.

Electrocardiogram (ECG) is a widely used reliable, non-invasive approach for cardiovascular disease diagnosis. With the rapid growth of ECG examinations and the insufficiency of cardiologists, accurate and automatic diagnosis of ECG signals has become a hot research topic. Deep learning methods have demonstrated promising results in predictive healthcare tasks.

It was developed a deep learning algorithm to classify in 12-lead Electrocardiography (ECG) Signals obtained from Acute Coronary Syndrome (ACS). Acute coronary syndrome is a term for a group of conditions that suddenly stop or severely reduce blood from flowing to the heart muscle. When blood cannot flow to the heart muscle, the heart muscle can become damaged. Heart attack and unstable angina are both acute coronary syndromes (ACS). Acute coronary Syndrome is divided into classes in itself. The aim in this project is to detect ACS from ECG signals and to identify the ACS class of the existing disease.

There are three different classes of ACS :

i) Unstable angina is a change in the pattern of angina symptoms (chest discomfort), including prolonged or worsening angina and new onset of severe angina symptoms. People who have unstable angina do not have signs of heart attack on their ECG or blood tests.

ii) Non-ST-segment elevation MI (NSTEMI) is a heart attack that identified by blood tests but that does not produce typical changes (ST-segment elevation) on an ECG.

iii) ST-segment elevation MI (STEMI) is a heart attack that doctors identified by blood tests and also produces typical changes on an ECG (ST-segment elevation).

The method involves compiling biomedical heart signal (ECG) data from reliable datasets in internet. The ECG signal is first preprocessed to remove noise and identify clean beats, then segmented to delineate the various waveforms comprising each beat. The ST segments are then isolated and a mathematical transformation is applied to extract the coefficients describing the morphology of the segment, which are then applied as input to the model.

In this project, computer vision will be one of our most basic applications, as ACS classification will be made by using ECG signal images. The most appropriate tool for this project was found to be OpenCV(Open Source Computer Vision) , which is an image processing library with its teaching/training sites as well as many useful codes to construct the desired deep learning architecture.

There are more than 2500 algorithms for image processing and machine learning within the OpenCV library. With these algorithms, operations such as face recognition, distinguishing objects, detecting human movements, object classification, license plate recognition, processing on three-dimensional images, image comparison, optical character identification OCR (Optical Character Recognition) can be easily performed.

The data set was retrieved from internet resources. It is PTB-XL ECG dataset, which is a large dataset of 21837 clinical 12-lead ECGs from 18885 patients of 10 second length. The raw waveform data was annotated by up to two cardiologists, who assigned potentially multiple ECG statements to each record. The in total 71 different ECG statements conform to the SCP-ECG standard and cover diagnostic, form, and rhythm statements.

To ensure comparability of machine learning algorithms trained on the dataset, it was added to provide recommended splits into training and test sets. In combination with the extensive annotation, this turns the dataset into a rich resource for the training and the evaluation of automatic ECG interpretation algorithms. The dataset is complemented by extensive metadata on demographics, infarction characteristics, likelihoods for diagnostic ECG statements as well as annotated signal properties.

The statistics of the data in the dataset are given as follows: The patient gender information is, %52 Male, %48 Female; age range is 0-95 (Median=62).

The technical specification of the computer hardware used in the project is as follows : Dell Inspiron 15 7000 Gaming(2.8 GHz Intel i7 processor, 16GB RAM, GTX 1050 Ti 12GB Graphics card) and ASUS(Intel Core i5 processor,8GB RAM, NVIDIA GeForce GT 620 graphics card).

The most appropriate algorithm for this classifier was decided to be the Convolutional Neural Network (CNN) algorithm, which is one of the deep learning techniques.

CNN model started with the input layer. There are 8 layers after which the convolution process is performed. Afterwards, the average pooling was performed, taking the average value of the outputs. With the dropout layer, the number of outputs is reduced and a triple classification has been made by using the dense layer, which provides the transition of neurons or nodes between the layers.




Fig. 1 Convolutional Neural Network (CNN) general

### B. Project 2 : Processing and Classification of Microscope Images [2]

This project is related to cell scale, and involves microscopic imaging processing techniques. In the first phase, literature and dataset research was accomplished through available internet resources. The project time plan was constructed and steps to be taken were discussed.

According to data uniformity, blood cell datasets have been chosen. This data set was considered, data were investigated, and classified by using CNN (Convolutional Neural Network) (Fig. 1).

The dataset contains 12,500 augmented images of blood cells (JPEG) with accompanying cell type labels (CSV). There are approximately 3,000 images for each of 4 different cell types grouped into 4 different folders (according to cell type). The cell types are Eosinophil, Lymphocyte, Monocyte, and Neutrophil. This dataset is accompanied by an additional dataset containing the original 410 images (pre-augmentation) as well as two additional subtype labels (WBC vs WBC) and also bounding boxes for each cell in each of these 410 images (JPEG + XML metadata). More specifically, the folder 'dataset-master' contains 410 images of blood cells with subtype labels and bounding boxes (JPEG + XML), while the folder 'dataset2-master' contains 2,500 augmented images as well as 4 additional subtype labels (JPEG + CSV). There are approximately 3,000 augmented images for each class of the 4 classes as compared to 88, 33, 21, and 207 images of each in folder 'dataset-master'.

'Blood Cell Images' dataset from 'Kaggle.com'. This dataset contains 12,500 augmented images of blood cells (JPEG) with accompanying cell type labels (CSV). There are approximately 3000 images for each of 4 different cell types grouped into 4 different folders (according to cell type). The cell types are Eosinophil, Lymphocyte, Monocyte, and Neutrophil. This dataset is accompanied by an additional dataset containing the original 410 images (pre-augmentation) as well as two additional subtype labels (WBC vs WBC) and also bounding boxes for each cell in each of

these 410 images (JPEG + XML metadata). More specifically, the folder 'dataset-master' contains 410 images of blood cells with subtype labels and bounding boxes (JPEG + XML), while the folder 'dataset2-master' contains 2,500 augmented images as well as 4 additional subtype labels (JPEG + CSV). There are approximately 3,000 augmented images for each class of the 4 classes as compared to 88, 33, 21, and 207 images of each in folder 'dataset-master'.

The accuracy value for this model was calculated as approximately 0.783. This indicates that approximately 78.3% of all samples were correctly classified. The model accurately predicts most of the data.

In the second stage of the project, experimental works have been done to test the method in actual cell images obtained from inexpensive microscope. This microscope was a non-professional one, that a limited budget student can afford.

Various vegetable surfaces (watermelon, peach, hazelnut, tomato, etc.), blood, hair strands, flour items were imaged. These are the samples that can be found in every home and every student can access.

Following this experimental phase, a small classification group was created using onion varieties. The onion cells were chosen because their availability and repeatability were the most compared to other samples. Normal onions, green onions and red onions were also included in the selected group of images to in order to increase onion cell image variations.

The cell samples have been examined and photographed different magnifications of at x100, x400 and x1200 zoom factors. The images have been classified these various onion images photographed with CNN, a deep learning method.

Recall shows how many of the real samples belonging to a given class are accurately predicted. In particular, the "NEUTROPHIL" class has a high recall value (0.88), indicating the model's ability to accurately predict this class. There are similarly high recall values for other classes.

In particular, a high precision value (0.96) was obtained for the class "EOSINOPHIL", indicating that the predictions of the model for this class have high accuracy if it really belongs to this class. There are reasonable precision values for other classes as well.

F1-score is a balanced measure of performance, combining precision and sensitivity. This shows the balance between precision and recall. Generally, the F1-score is a useful metric if the data is unstable. Separate F1-score values are calculated for each class and these values range from 0 to 1.

### C. Project 3 : Implementation of medical decision support software library for classifying heart bioelectric signals [3]

Electrocardiogram (ECG) feature extraction is a process in signal processing and data analysis where relevant information is extracted from the ECG signal for further analysis or diagnosis. ECG is a graphical representation of the electrical activity of the heart over time, and it contains valuable information about the heart's rhythm and function. Feature extraction helps in quantifying and characterising specific aspects of the ECG waveform, which can be used for

various medical applications, such as arrhythmia detection, heart disease diagnosis, and heart rate variability analysis.

The Adaptive Noise Cancellation (ANC) filter consists of the filter and adaptive algorithm, which updates the filter coefficients according to the reference signal. This method is based on the principle of the interference simulation as the reference input signal, which has to be associated with this interference. The estimated noise is subtracted from the raw measured signal to obtain the filtered one. The method can be used for the purpose of eliminating the PLI, baseline wander or motion artifacts.

Wavelet Transform (WT) is one of the most powerful time-frequency analysis means, which distributes continuous time signals into different scale components.

After the signal reconstruction using the wavelet decomposition structure, the signal that was non-stationary and non-periodic can become a smooth signal. The WT-based approaches are widely used due to their low complexity and high performance. They allow signal denoising with its lossless compression, R peaks detection or automated diagnosis determination of some diseases.

Here are the steps involved in ECG feature extraction and some commonly extracted features:

**Data Acquisition:** ECG data is typically acquired using electrodes attached to the skin, which record the electrical signals generated by the heart. This data is usually represented as a time-series waveform.

**Preprocessing:** Before feature extraction, it's essential to preprocess the ECG signal to remove noise and artifacts. Common preprocessing steps include baseline correction, filtering (e.g., bandpass or notch filtering), and artifact removal.

**R-Peak Detection:** The R-peaks correspond to the highest points in the ECG waveform, representing ventricular depolarization (contraction). Locating R-peaks is a crucial step in ECG feature extraction, as many features are calculated based on the R-R intervals.

**Segmentation:** The ECG signal is divided into smaller segments, typically around the R-peaks. Segmentation helps in analyzing specific sections of the ECG waveform, such as the P-wave, QRS complex and T wave.

**Feature Extraction:** Various features can be extracted from the segmented ECG signal. Here are some common features:

- Heart Rate: The heart rate can be calculated by measuring the time between successive R-peaks (RR intervals).

- RR Intervals: These are the time intervals between consecutive R-peaks and are used for heart rate variability analysis.

- Amplitude and Duration of Waves: Characteristics of the P-wave, QRS complex, and T-wave, such as amplitude and duration, can be important for diagnosing specific cardiac conditions.

- ST-Segment Analysis: Changes in the ST-segment can indicate myocardial ischemia or injury.

- Frequency Domain Features: Transforming the ECG signal into the frequency domain using techniques like the Fast Fourier Transform (FFT) can reveal frequency-related information.

- Nonlinear Features: Measures of signal complexity, such as entropy or fractal dimensions, can provide insights into cardiac dynamics.

**Classification or Analysis:** Once the relevant features are extracted, they can be used for various purposes, such as detecting arrhythmias (abnormal heart rhythms), diagnosing heart diseases, or assessing heart rate variability for stress or autonomic nervous system analysis.

**Visualization:** Visualizing the extracted features and the original ECG signal can help healthcare professionals in making diagnostic decisions.

The method used in this work is adopting Matlab (TM) library and construct required architecture to classify data. Matlab provides a deep learning framework called Deep Learning Toolbox that supports a variety of pre-trained Convolutional Neural Networks (CNNs) for various tasks. Alexnet is a popular CNN architecture designed for image classification tasks. It consists of multiple convolutional and fully connected layers.

**Input Layer :** AlexNet takes an input image of size 227x227 pixels with three color channels (RGB). The input image is preprocessed, which includes mean subtraction and resizing to meet the network's requirements.

**Convolutional Layers (Conv Layers) :** These layers are responsible for feature extraction. Each convolutional layer uses a set of learnable filters or kernels to perform convolution operations on the input image.

**Rectified Linear Unit :** ReLU activation functions are applied after each convolution to introduce non-linearity.

**Max-Pooling Layers (Pooling Layers):** After each pair of convolutional layers, there is a max-pooling. Max-pooling reduces the spatial dimensions of the feature maps and helps in creating translation-invariant representation.

**Local Response Normalization (LRN):** LRN is applied after the first two convolutional layers. It enhances the contrast of the features and provides local competition among neurons

**Fully Connected Layers (FC Layers):** After the convolutional and pooling layers, there are three fully connected layers. These layers perform high-level feature extraction and classification. Dropout is applied to reduce overfitting during training.

**Output Layer:** The final fully connected layer has 1000 neurons, representing 1000 different classes in the ImageNet dataset. A softmax activation function is applied to compute class probabilities. The class with the highest probability is the predicted label for the input image.

**Training:** AlexNet is typically trained using the stochastic gradient descent (SGD) optimization algorithm. The network is trained on a large labeled dataset (e.g., ImageNet) to learn discriminative features and minimize the classification error.

The results of this project can be summarised in three basic conclusion :

If speed and simplicity are important, then KNN may be a good choice. If accuracy and robustness are important, then CNNs may be a better choice. If computational resources are limited, then PNNs may be a good option.

#### *D. Project 4 : Development of Convolutional Neural Network for ECG Beat Classification to Detect and Categorize Myocardial Infarction [4]*

This project is based on a convolutional neural network construction to classify ECG signals on the different categories of myocardium infarction (MI) disease (i.e. heart

attack). In earlier phase, support vector machine (SVM), k-Nearest neighbour (KNN) and probabilistic neural network (PNN) structures were inspected and how successful they were with different classification tasks, up to 6 classes.

After a careful revision, it was decided to define 11 classes will be categorized by the CNN architecture (Fig 1). AI is created in MATLAB environment with neural network layers that makes up a convolutional neural network (CNN), with 11 outputs that matches the 11 beat types which needs to be classified. These classes are as follows; anterior (A), anterior lateral (AL), anterior septal (AS), inferior (I), inferior lateral (IL), inferior posterior (IP), inferior posterior lateral (IPL), lateral (L), posterior (P) and posterior lateral (PL), alongside with the healthy (H) class.

The heart signal data have been obtained from PhysioNet database and it was pre-processed to get rid of noise and remove baseline wander, alongside some other improvements with proper filters applied. Later on, these data are inspected with a MATLAB tool called ECGDeli, for R-peak detection. This detection is necessary to divide the raw, long ECG recordings into beats that could be given to a neural network for training and testing.

After the R-peak detection, the beats are segmented and kept on cells with their corresponding class types. Following this, 80% of the data is divided into training data, 10% as validation data and 10% as testing data. Neural network is created with 19 layers, 4 1D-convolution layers, 2 1D-maxpooling layers and the rest being mostly ReLU activation layers and dropout layers.

### III. RESULTS

All of the projects work have been presented to include classification assessment results in Receivers Operating Curves (ROC) and various classification accuracy metrics such as accuracy, sensitivity, specificity, F1 score and similar. One sampla figure of confusion matrix is given for Project 4, Lead 5 in Fig. 2.

True Class \ Predicted Class	1	2	3	4	5	6	7	8	9	10	11
1	688	173	2		3	4					
2	1	839	9								
3			1166	12	83	30		115			
4				1250	2				7		
5				59	1298	186		8	4	74	
6					76	932					
7							800				
8								800			
9									800		
10										800	
11											800

Fig. 2 Confusion matrix for Project 4 work for Lead 5 data

It was found that, the best average sensitivity was obtained in “iteration 2” as 97.81%, on lead 10 results. There are some weaknesses and strengths of the methods adopted:

Iteration 2 should be preferred when we want to inspect classes that didn’t have much training data when we were training our neural network. Because by increasing their data number via Gaussian white noise addition and data recreation, we also decreased the chances of misclassification happening upon these classes from other classes that were overtrained, due to class imbalance and them having more training data. Yet fixing the class imbalance issue caused another problem, which was misclassification on other classes continuing to happen between each other and lowering the overall accuracy of the classifier. So, in overall sense, iteration 1 could be preferable. It has the highest accuracy rates on different leads, lead 10 being more preferable in MI-subclassification. It can also better distinguish healthy cases from other cases, compared to iteration 2.

### IV. DISCUSSION

Artificial intelligence (AI) aims to mimic human cognitive functions. Deep learning in AI can be applied to numerous types of biomedical data. These data can be structured (classical support vector machine and neural network), and unstructured (like natural language processing). for areas of early detection and diagnosis, treatment, as well as outcome prediction and prognosis evaluation. [5-6]

In the beginning of their engineering career, the undergraduate students will most probably face to analyse or design deep learning codes. Their undergraduate graduation projects are aimed to prepare the student to professional engineering environment.

Besides reaching out the golas of their technical aspects of their projects, it is also aimed to comply with applicable engineering standards exist to govern the rules of technical aspects and ethical aspects. Some standards can be itemised as;

ISO/TR 22100-5:2021: (Safety of Machinery-Relationship with ISO-Implications of artificial intelligence and machine learning. This document addresses how artificial intelligence and machine learning can impact the safety of machinery and machinery systems.)

ISO/IEC 2382-31:1997 (This document represents the detailed terminology about the artificial intelligence and machine learning.)

ISO/IEC 18039:2019 (Computer graphics, image processing and environmental data representation This document defines the scope and key concepts of mixed and augmented reality, the relevant terms and their definitions and a generalised system architecture based on image processing)

IEEE Standard 830 - Recommended Practice for Software Requirements Specifications: This standard provides guidelines for developing software requirements specifications. The project should satisfy this standard by ensuring that the software requirements specifications adhere to the guidelines set forth in IEEE Standard 830.

ISO 13485 - Medical devices -- Quality management systems -- Requirements for regulatory purposes: This international standard outlines the requirements for a quality management system for medical devices. Although none of the project yield a new biomedical device, it is still related to

medical diagnostics and could benefit from following this standard to ensure that the system is safe, reliable, and effective. The project will satisfy this standard by adhering to the guidelines set forth in ISO 13485.

ANSI/ASQ Z1.4 - Sampling Procedures and Tables for Inspection by Attributes: This standard provides guidelines for sampling inspection procedures for attributes. In some projects, the sampling inspection procedures could be used to test the accuracy of the system's classifications by comparing them to manual classifications performed by experts. The project will satisfy this standard by following the guidelines set forth in ANSI/ASQ Z1.4.

ASTM E2817-18 - Standard Guide for Design and Development of Controlled Image Analysis Systems: This standard provides a guide for designing and developing image processing systems. This standard could be used as a guide to ensure that the project follows best practices for designing and developing the image processing and machine learning techniques used in the system. At least one project will satisfy this standard by following the guidelines set forth in ASTM E2817-18.

ISO/IEC 25010 - Systems and software engineering -- Systems and software Quality Requirements and Evaluation (SQuaRE) -- System and software quality models: This standard outlines the quality requirements for software products and systems. The standard provides guidelines for evaluating software quality characteristics, such as functionality, reliability, usability, and performance. This standard could be used to evaluate the quality of the system and ensure that it meets the necessary requirements.

ISO/IEC 14882:2011 (C++ Programming Language), that is general purpose programming language that was standardized, ratified and published by ISO in 2011. Because Python and MATLAB uses the same derived language with some additions and changes, our entire project will be based on this standard generally.

## V. CONCLUSION

After supervising these four projects, done by total of six students, it is concluded that the undergraduate electrical and electronics engineering average student is ready to apply deep learning techniques to biomedical sciences with restricted budget conditions, internet resources, available computational infrastructure and credit-hour load from the other courses leading graduation.

Moreover, a student is already aware of and is ready to fully consider his professional work obligations health, safety, manufacturability, sustainability, economy direct or indirect effects to society, ethics, and environment.

The Sustainable Development Goals (SDGs), also known as the Global Goals, were adopted by all United Nations Member States in 2015 as a universal call to action to end poverty, protect the planet and ensure that all people enjoy peace and prosperity by 2030.

As an example, there are 17 SDGs and Project 1 agrees with two of them as mentioned below.

Goal 3: Good Health and Well-being

Goal 8: Decent work and economic growth

Goal 17: Partnerships on the Goals.

The other projects are also satisfy at least three of them from that requirement list.

## ACKNOWLEDGMENT

This study was partially supported by Hacettepe University Scientific Project Coordination Office (BAP), Türkiye, Projects No: FYL-2018-17610, FYL-2018-17626, and FYL-2018-17469.

## REFERENCES

- [1] T.A. Bozkurtlar, E. Kaya, Application of Deep Learning Algorithms to Classify Electrocardiography (ECG) Signals obtained from Acute Coronary Syndrome (ACS), Hacettepe University Dept. Electrical and Electronics Engineering, ELE402 Graduation Project II Course Final Report, 22.01.2023.
- [2] B.Aldemir, İ.Aksoy, Processing and Classification of Microscope Images, Hacettepe University Dept. Electrical and Electronics Engineering, ELE402 Graduation Project II Course Final Report, 02.09.2023.
- [3] F.K.Terzi, Implementation of medical decision support software library for classifying heart bioelectric signals, Hacettepe University Dept. Electrical and Electronics Engineering, ELE402 Graduation Project II Course Final Report, 03.09.2023.
- [4] F.Ramiz, .Development of Convolutional Neural Network for ECG Beat Classification to Detect and Categorize Myocardial Infarction, Hacettepe University Dept. Electrical and Electronics Engineering, ELE402 Graduation Project II Course Final Report ,12.01.2023.
- [5] Shubham Mittal & Yasha Hasija, Applications of Deep Learning in Healthcare and Biomedicine chapter in "Deep Learning Techniques for Biomedical and Health Informatics" (Part of the Studies in Big Data book series (SBD,volume 68), 15 November 2019.
- [6] F Jiang, Y Jiang, H Zhi, Y Dong, H Li, S Ma, Y Wang, Q Dong, H Shen, Y Wang, Artificial intelligence in healthcare: past, present and future, Stroke and vascular neurology, 2017.

## Görüntü Birleştirme Yöntemleri ile Çok-modlu Medikal Görüntülerin Kaynaştırılması

Fatma Çakıroğlu<sup>1</sup>, Rifat Kurban<sup>\*2</sup>, Ali Durmuş<sup>3</sup>, Ercan Karaköse<sup>4</sup>

<sup>1</sup> Kayseri Üniversitesi, Elektrik Elektronik Mühendisliği, Lisansüstü Eğitim Enstitüsü, Kayseri, Türkiye

<sup>2</sup> Abdullah Gül Üniversitesi, Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Kayseri, Türkiye

<sup>3</sup> Kayseri Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Mühendislik Mimarlık ve Tasarım Fakültesi, Kayseri, Türkiye

<sup>4</sup> Kayseri Üniversitesi, Mühendislik Temel Bilimleri Bölümü, Mühendislik Mimarlık ve Tasarım Fakültesi, Kayseri, Türkiye

<sup>\*</sup>(rifat.kurban@agu.edu.tr)

**Özet** –Çok-modlu medikal görüntü birleştirme, görüntü kalitesini artırmak için iki ya da daha fazla medikal görüntünün birleştirilmesidir. Tıbbi görüntüleme sağlık alanında teşhis, araştırma ve tedavide önemli bir rolü üstlenmektedir. Tanı ve tedavide daha doğru klinik bilgiler için farklı modlarda görüntüler kullanılır. Tıbbi görüntüleme kullanılan Tek Foton Emisyonlu Bilgisayarlı Tomografi (SPECT), Pozitron Emisyon Tomografisi (PET), Bilgisayarlı Tomografi (CT), Manyetik Rezonans Görüntüleme (MRI), gibi görüntüleme teknikleri hekimlere hastaların vücudundaki sert ve yumuşak dokular hakkında bilgi sağlarlar. Her bir görüntüleme tekniği farklı özellikleri korur ve buna bağlı olarak aynı parçanın farklı görüntüleme bilgisini elde ederler. Farklı modlardaki görüntülerin birleştirilmesindeki amaç klinik tanının doğruluğunu artırmak için daha iyi bir kontrast ve füzyon kalitesi sağlamaktır. Bu doğrultuda farklı modaliteler birleştirilir ve bu sayede lezyonların anlaşılabilirliği artırılır. İyi bir füzyon görüntüsü, kaynak görüntülerdeki yararlı bilgileri korumalı ve herhangi bir yapay olgu içermemelidir. Bu çalışma da sekiz farklı CT ve MRI görüntü çifti üzerinde literatürde iyi bilinen klasik birleştirme yöntemleri kıyaslanmıştır. Birleştirme performansları görsel ve sayısal sonuçlara göre değerlendirilmiştir. Ayrıca buna ek olarak yöntemlerin CPU zaman tüketimleri arasında da karşılaştırma yapılmıştır.

**Anahtar Kelimeler** – Çok modlu görüntü birleştirme, MRI, CT, medikal görüntü kaynaştırma

### I. GİRİŞ

Çok modlu görüntü füzyonu, birden fazla farklı modalitelerdeki medikal görüntülerin birleştirilmesidir. Buradaki amaç hekimlerin lezyonları daha iyi anlayabilmesidir. Tanı, tedavi ve sağlık alanındaki araştırmaların kalitesini artırmak için bu yöneme başvurulur. Örneğin CT ile sert ve yumuşak dokularda üç boyutlu bilgi sağlanırken, kemik bilgisini desteklemeyen MRI görüntüsü yumuşak doku bilgisi sağlar. Tek bir görüntü klinisyenlerin istediği bilgiyi tam olarak sağlamayabilir. Bu durumda çok modlu görüntü birleştirmeye ihtiyaç duyulur [1].

Tıbbi görüntüleme kullanılan Tek Foton Emisyonlu Bilgisayarlı Tomografi (SPECT), Bilgisayarlı Tomografi (CT), Pozitron Emisyon Tomografisi (PET), Manyetik Rezonans Görüntüleme (MRI) yöntemlerinin görüntü elde etme sınırları farklıdır. MRI yumuşak doku görüntüleme kullanılır. CT dokuların üç boyutlu bilgisini verir. PET doku ve organlarda meydana gelen fonksiyonel değişikliği gösteren bir görüntüleme tekniğidir. SPECT ise farklı açılarda alınan iki boyutlu görüntüleri iç boyutlu tomografik görüntüye dönüştüren bir sistemdir. Genel olarak bakıldığında her bir görüntüleme sistemi farklı işlev için kullanılmaktadır. Farklı modalitelerde çekilmiş tıbbi görüntüler herhangi bir yapay olgu eklenmeden ve kaynak görüntülerdeki yararlı bilgiler kullanılarak birleştirilir [2].

Çok modlu tıbbi görüntü birleştirme genel olarak MRI-CT, MRI-PET ve MRI-SPECT görüntüleri arasında yapılmaktadır [3].

Görüntü birleştirme yöntemleri uzamsal alan, dönüşüm alanı, hibrit ve derin öğrenmeye dayalı yöntemler olarak sınıflandırılır [4]. Uzamsal alan yöntemleri direkt kaynak görüntünün piksellerine uygulanır. Kendi içinde blok, bölge ve piksel tabanlı yöntemler olarak sınıflandırılır. Aslantaş ve arkadaşları çok odaklı görüntü birleştirme için bölge bazlı bulanık yöntem önermişlerdir [5]. Chen, beyin MRI ve PET görüntü füzyonu için log-Gabor yöntemine dayalı bir füzyon tekniği önermiştir [6]. Aslantaş ve arkadaşları çok odaklı ve çok sensörlü görüntü birleştirme için web tabanlı bir uygulama sunmuşlardır [7]. Dönüşüm alanı yöntemleri karşılık gelen dönüşüm katsayılarını birleştirir ve ters dönüşüm uygulayarak birleşik görüntüyü elde eder. Dönüşüm alanı tabanlı yöntemlerden ayrık dalgacık dönüşümü (DWT) [8], ayrık kosinüs dönüşümü (DCT) [9], alt örneklenmiş konturlet dönüşümü (NSCT) [10] yöntemleri çok modlu tıbbi görüntülerin birleştirilmesinde kullanılmaktadır. Ayrık dalgacık dönüşümü yöntemi genelde MRI - PET görüntü görüntüleri [11] ve CT - MRI görüntüleri için uygulanmıştır [12]. Cunha ve arkadaşları alt örneklenmiş konturlet yönteminden daha iyi performans gösteren çok ölçekli bir ayrıştırma yöntemi önermişlerdir [13]. Yin ve arkadaşları alt örneklenmemiş Shearlet Dönüşüm alanında parametre uyarlamalı darbe eşleşmiş sinir ağı ile tıbbi görüntü füzyonu önermiştir [14]. Derin öğrenmeye dayalı yöntemlerden evrişimli sinir ağı (CNN) yöntemi, çok modlu tıbbi görüntülerin birleştirilmesi için kullanılan derin öğrenme modelidir. Görüntü birleştirmede CNN modeli Liu ve arkadaşları tarafından uygulanmıştır [15]. Yu ve arkadaşları

CNN'e dayalı görüntü birleştirme yöntemi önermişlerdir [16]. Çok modlu görüntü füzyonu farklı modlarda çekilen tıbbi görüntülerin avantajlarını birleştirmeyi amaçlar. MRI vücutta yumuşak doku yapısı hakkında bilgi verir. Kemikte proton yoğunluğu az olduğu için MRI'da kemik görüntüsü net değildir. CT'de X-ışınları insan vücudunu taramak için kullanılır. X-ışınları yumuşak dokuda daha az geçirgenliğe sahiptir. Bu sebeple CT kemik doku hakkında daha fazla bilgi içermektedir. Na ve arkadaşları kılavuzlu filtrelemeye (GF) dayalı MRI ve CT görüntü füzyon yöntemi önermişlerdir [17].

## II. MATERYAL VE METOD

### A. Çalışmada Karşılaştırılan Görüntü Birleştirme Yöntemleri

DWT, düşük frekans ve yüksek frekans katsayılarını birleştirmek için farklı füzyon kuralları belirlenerek geliştirilmiştir [18]. Sabit dalgacık dönüşümü (SWT) yöntemi, DWT'ye benzer bir yöntemdir, tek alt örnekleme işlemi ile bastırılır [19]. Dönüşüm tabanlı yöntemlerden Ayrık kosinüs dönüşümü (DCT), görüntüler NxN boyutunda bloklara ayrılır ve her blok için ayrık kosinüs dönüşüm katsayıları hesaplanır. Füzyon kuralına uygun bloklar seçilir ve birleşik katsayı değerleri oluşturulur. Birleşik katsayı değerlerine ters ayrık kosinüs dönüşümü uygulanır [20]. Ayrık kosinüs harmonik dalgacık dönüşümü (DCHWT), azaltılmış hesaplamalarla birleştirilmiş görüntünün görsel kalitesini ve performansını korumak için geliştirilmiş bir yöntemdir [21]. CNN, eğitilebilir denetimli öğrenmeye sahip çok aşamalı ileri beslemeli bir yapay sinir ağıdır. Evrişim işlemi çok boyutludur. Evrişimli bir ağda, ilk parametreye genellikle giriş, ikinci parametreye çekirdek işlevi ve çıkışa da özellik haritası adı verilir [22].

### B. Performans Analizi İçin Kullanılan Kalite Metrikleri

#### B.1. Kenar Tabanlı Kalite Metriği (Edge Based Quality Metric - $Q_p^{AB/F}$ )

Kenar Tabanlı Kalite metriği, kaynak görüntülerden birleşik görüntüyü oluşturmak için taşınan kenar bilgilerini kullanarak görüntü kalitesini ölçer [23].

$$Q_p^{AB/F} = \frac{\sum_{n=1}^N \sum_{m=1}^M Q^{AF}(n,m)w^A(n,m) + Q^{BF}(n,m)w^B(n,m)}{\sum_{i=1}^N \sum_{j=1}^M (w^A(i,j) + w^B(i,j))} \quad (1)$$

#### B.2. Chen-Blum Kalite Metriği (Chen-Blum metric- $Q_{cb}$ )

İnsan algısından ilham alarak geliştirilen referanssız görüntü kalite metriğidir [24]. Chen-Blum Kalite metriği değeri global kalite haritasının ortalama değeri hesaplanarak elde edilir:

$$Q_{cb}(x,y) = \lambda_A(x,y) Q_{AF}(x,y) + \lambda_B(x,y) Q_{BF}(x,y) \quad (2)$$

#### B.3. Uzamsal Frekans (Spatial Frequency- $Q_{sf}$ )

RF ve CF, bitişik piksellerin birinci dereceden türevleriyle hesaplanan birleşik görüntünün satır ve sütun frekanslarıdır [25].

$$SF = \sqrt{RF^2 + CF^2} \quad (3)$$

$$RF = \left[ \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (F(i,j) - F(i,j-1))^2 \right]^{1/2} \quad (4)$$

$$CF = \left[ \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (F(i,j) - F(i-1,j))^2 \right]^{1/2} \quad (5)$$

#### B.4. Standart Sapma (Standard Deviation - $Q_{std}$ )

Birleştirilmiş görüntünün boyutu M ve N, burada  $\bar{F}$  birleştirilmiş görüntünün ortalaması ve F birleştirilmiş görüntü olmak üzere standart sapma hesaplanır [26].


$$STD = \left[ \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (F(i,j) - \bar{F})^2 \right]^{1/2} \quad (6)$$

#### B.5. Uzamsal Alan Referanssız Görüntü Kalite Değerlendiricisi (Blind Referenceless Image Spatial Quality Evaluator, $Q_{brq}$ )


Uzamsal alan referanssız görüntü kalite değerlendiricisi (Blind Referenceless Image Spatial Quality Evaluator, BRISQUE), uzamsal alanda görüntü kalitesi değerlendirmek için kullanılan referanssız bir görüntü kalite metriğidir. Kıyaslamalarda sayısal değeri küçük olan birleşik görüntünün, birleştirme performansı daha iyi kabul edilir [27].

### C. Deneylerde Kullanılan Çok Modlu Tıbbi Görüntü Çiftleri


Deneylerde sekiz çift CT ve MRI görüntüsü kullanılmıştır [16]. Bu görüntüler [www.med.harvard.edu/aanlib/home.html](http://www.med.harvard.edu/aanlib/home.html) adresinden elde edilmiştir (erişim tarihi, Ekim 2023). Kullanılan görüntüler Şekil 1-8'de verilmiştir.




Şekil 1 Görüntü #1 CT ve MR görüntü çifti




Şekil 2 Görüntü #2 CT ve MR görüntü çifti




Şekil 3 Görüntü #3 CT ve MR görüntü çifti




Şekil 4 Görüntü #4 CT ve MR görüntü çifti




Şekil 5 Görüntü #5 CT ve MR görüntü çifti



Şekil 6 Görüntü #6 CT ve MR görüntü çifti



Şekil 7 Görüntü #7 CT ve MR görüntü çifti



Şekil 8 Görüntü #8 CT ve MR görüntü çifti

### III. GÖRSEL VE SAYISAL SONUÇLAR

Sekiz farklı CT ve MRI görüntü çiftlerine ait sayısal sonuçlar Tablo 1-8 de verilmiştir. Tablolarda  $Q_{P^{AB/F}}$ ,  $Q_{CB}$ ,  $Q_{SF}$  ve  $Q_{STD}$  kalite metrikleri için büyük sayısal değere sahip olan yöntemler daha başarılı iken  $Q_{BRQ}$  kalite metriği için küçük sayısal değere sahip kalite metriğine sahip olan yöntem daha başarılıdır. Her bir metrik için en iyi yöntem koyu renk ile işaretlenmiştir.

Tablo 1. Görüntü #1'e ait sayısal sonuçlar

Görüntü #1	$Q_{P^{AB/F}}$	$Q_{CB}$	$Q_{SF}$	$Q_{STD}$	$Q_{BRQ}$	işlem süresi (sn)
DCHWT	0,0004	<b>0,3862</b>	13,3888	41,9861	42,5714	2,0788
DCT	<b>0,0009</b>	0,3575	13,5490	54,8413	42,2915	<b>0,3258</b>
DWT	0,0005	0,3550	<b>19,1628</b>	<b>59,1874</b>	<b>39,6979</b>	1,8532
SWT DCT	0,0005	0,3579	19,1268	59,0766	41,5344	5,0177
SWT	0,0005	0,3479	10,6821	34,0097	43,4581	0,3558
CNN	0,0005	0,3313	17,6211	60,0385	35,9498	32,4145

Tablo 1.'de DWT yöntemi  $Q_{SF}$  ve  $Q_{STD}$  kalite metrikleri için başarılı, DCT yöntemi ise  $Q_{P^{AB/F}}$  kalite metriği için başarılı sonuç elde etmiştir. İşlem süresi açısından en hızlı DCT yöntemi olmuştur.

Tablo 2. incelendiğinde DWT ve DCT iki farklı kalite metriği için başarılı olurken işlem süresi açısından en hızlı yöntem SWT olmuştur.

Tablo 2. Görüntü #2' e ait sayısal sonuçlar

Görüntü #2	$Q_{P^{AB/F}}$	$Q_{CB}$	$Q_{SF}$	$Q_{STD}$	$Q_{BRQ}$	işlem süresi (sn)
DCHWT	0,0004	0,4866	16,4155	52,6410	<b>22,9268</b>	1,9428
DCT	<b>0,0011</b>	<b>0,6401</b>	19,8180	52,9173	29,7024	0,3012
DWT	0,0004	0,5024	<b>23,6053</b>	<b>61,8818</b>	23,7671	0,2786
SWT DCT	0,0004	0,4631	22,8848	61,3819	29,5032	4,0370
SWT	0,0004	0,3924	17,6492	52,1324	43,0848	<b>0,1264</b>
CNN	0,0005	0,3313	17,6211	60,0385	35,9498	32,4145

Tablo 3.'e göre DCT yöntemi,  $Q_{P^{AB/F}}$  ve  $Q_{CB}$  kalite metrikleri için başarılı sonuç vermiştir. DWT yöntemi,  $Q_{SF}$  ve  $Q_{STD}$  kalite metrikleri için başarılı olmuştur. En hızlı işlem süresine sahip yöntem SWT olmuştur.

Tablo 3. Görüntü #3' e ait sayısal sonuçlar

Görüntü #3	$Q_{P^{AB/F}}$	$Q_{CB}$	$Q_{SF}$	$Q_{STD}$	$Q_{BRQ}$	işlem süresi (sn)
DCHWT	0,0004	0,5755	22,4970	52,9506	39,4254	2,2161
DCT	<b>0,0005</b>	<b>0,7052</b>	25,6398	69,0078	34,6733	0,2755
DWT	0,0004	0,6188	<b>27,7428</b>	<b>69,2749</b>	37,5969	0,2997
SWT DCT	0,0004	0,6418	27,5243	69,1737	31,7574	4,0414
SWT	0,0004	0,5796	21,0058	46,2265	42,5719	<b>0,1124</b>
CNN	0,0004	0,5464	26,7860	63,8331	<b>12,4350</b>	31,8322

Tablo 4. 'te DCT yöntemi,  $Q_{P^{AB/F}}$  ve  $Q_{CB}$  kalite metrikleri için en başarılı sonuç vermiştir. En hızlı işlem süresine sahip yöntem SWT olmuştur.

Tablo 4. Görüntü #4' e ait sayısal sonuçlar

Görüntü #4	$Q_{P^{AB/F}}$	$Q_{CB}$	$Q_{SF}$	$Q_{STD}$	$Q_{BRQ}$	işlem süresi (sn)
DCHWT	0,0004	0,4916	19,8221	62,8558	<b>24,2284</b>	1,9874
DCT	<b>0,0028</b>	<b>0,8456</b>	17,9592	66,2654	40,0569	0,3142
DWT	0,0005	0,6647	<b>26,4666</b>	78,7427	34,2581	0,2045
SWT DCT	0,0004	0,6997	25,8905	<b>79,4042</b>	39,3654	4,2407
SWT	0,0004	0,6493	18,6744	61,2511	35,6527	<b>0,0906</b>
CNN	0,0004	0,6102	24,9930	74,1028	35,1284	30,6786

Tablo 5. Görüntü #5' e ait sayısal sonuçlar

Görüntü #5	$Q_{P^{AB/F}}$	$Q_{CB}$	$Q_{SF}$	$Q_{STD}$	$Q_{BRQ}$	işlem süresi (sn)
DCHWT	0,0003	0,4458	20,3290	57,5140	25,8195	1,9753
DCT	<b>0,0005</b>	<b>0,7302</b>	24,1391	72,3602	42,2672	0,2930
DWT	0,0003	0,5477	<b>28,0096</b>	<b>75,5129</b>	34,9107	0,2362
SWT DCT	0,0004	0,6076	27,8448	75,3431	33,9876	4,0332
SWT	0,0003	0,5247	19,5655	54,4592	<b>25,1008</b>	<b>0,0965</b>
CNN	0,0004	0,5415	25,8329	72,4638	27,9231	30,9938

Tablo 5.'te DWT ve DCT iki farklı kalite metriği için en başarılı sonucu verirken SWT en hızlı işlem süresine sahiptir.

Tablo 6.'da DCT yöntemi  $Q_{P^{AB/F}}$ ,  $Q_{CB}$  ve  $Q_{SF}$  kalite metrikleri için en iyi birleştirme başarımına sahip yöntemdir. İşlem süresi en hızlı olan ise SWT yöntemidir.



Tablo 6. Görüntü #6' ya ait sayısal sonuçlar

Görüntü #6	$Q_{P^{AB/F}}$	$Q_{CB}$	$Q_{SF}$	$Q_{STD}$	$Q_{BRQ}$	işlem süresi (sn)
DCHWT	0,0004	0,4409	16,1007	68,4648	43,0123	1,9521
DCT	<b>0,0006</b>	<b>0,7546</b>	<b>23,7577</b>	70,6008	36,9336	0,2923
DWT	0,0004	0,5538	20,5701	<b>101,1589</b>	34,3804	0,2000
SWT DCT	0,0004	0,6083	19,9187	100,8640	40,8541	4,0733
SWT	0,0004	0,5686	14,3743	65,6337	34,6288	<b>0,0879</b>
CNN	0,0005	0,4074	19,4666	101,1240	<b>33,9150</b>	30,7666

Tablo 7. Ve Tablo 8. 'de DCT ve DWT en başarılı olurken SWT en hızlı işlem süresine sahiptir.

Tablo 7. Görüntü #7' ye ait sayısal sonuçlar

Görüntü #7	$Q_{P^{AB/F}}$	$Q_{CB}$	$Q_{SF}$	$Q_{STD}$	$Q_{BRQ}$	işlem süresi (sn)
DCHWT	0,0004	0,5241	27,5323	70,9792	28,2884	1,9463
DCT	<b>0,0005</b>	<b>0,6816</b>	31,8021	80,2959	33,8509	0,2773
DWT	0,0004	0,5495	<b>37,0844</b>	<b>87,6538</b>	43,4484	0,1955
SWT DCT	0,0003	0,5438	36,0506	85,7006	<b>23,0151</b>	3,9645
SWT	0,0004	0,5015	28,0768	68,3895	33,9516	<b>0,1015</b>
CNN	0,0004	0,5778	34,5152	85,6531	43,4460	33,3111

Tablo 8. Görüntü #8' e ait sayısal sonuçlar


Görüntü #8	$Q_{P^{AB/F}}$	$Q_{CB}$	$Q_{SF}$	$Q_{STD}$	$Q_{BRQ}$	işlem süresi (sn)
DCHWT	0,0003	0,4842	17,0117	52,9441	<b>28,7967</b>	1,9455
DCT	<b>0,0005</b>	<b>0,6407</b>	21,5286	73,5822	33,3386	0,2838
DWT	0,0004	0,5917	<b>24,0640</b>	<b>74,0694</b>	37,4125	0,1972
SWT DCT	0,0004	0,6314	23,2530	73,8481	35,3368	4,0427
SWT	0,0004	0,5687	16,8453	47,7518	32,0470	<b>0,0851</b>
CNN	0,0004	0,5236	22,3081	69,5713	33,9963	31,6908

Şekil 9-16 arasında çalışmada kullanılan yöntemlere ait görsel birleştirme sonuçları verilmiştir.


Birleştirme başarısını değerlendirmek için sayısal sonuçlara ek olarak görsel sonuçlar da değerlendirilmiştir. Görsel sonuçlar Şekil 9-16 arasında gösterilmektedir.

DWT ve DCT yöntemlerinin görsel sonuçlarında kaynak görüntülerden birleşik görüntüye daha fazla bilgi aktarıldığı görülmektedir.


Şekil 9. Görüntü #1' e ait görsel sonuçlar



Şekil 10. Görüntü #2' e ait görsel sonuçlar

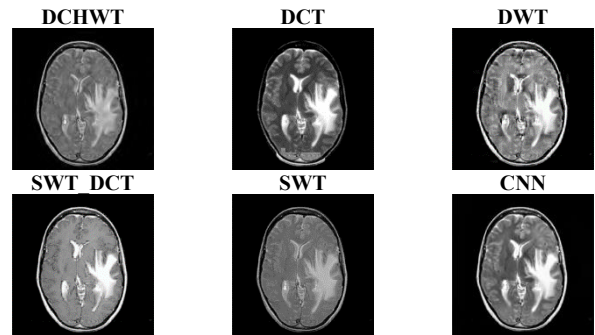


Şekil 11. Görüntü #3' e ait görsel sonuçlar




Şekil 10-11 de DWT yöntemi görsel olarak daha net ve anlaşılır sonuç elde etmiştir.

Şekil 12. Görüntü #4' e ait görsel sonuçlar




Şekil 12'de DCT yönteminin elde ettiği görsel sonuç daha anlaşılır görüntüye sahiptir.

Şekil 13. Görüntü #5' e ait görsel sonuçlar




Şekil 13,14 ve 15 de DCT yönteminin görsel sonuçları daha başarılıdır.

Şekil 14. Görüntü #6' ya ait görsel sonuçlar




Şekil 15. Görüntü #7' e ait görsel sonuçlar



Şekil 16.'da DCT, DWT ve SWT\_DCT yöntemlerinden elde edilen görsel sonuçlar daha başarılıdır.

Şekil 16. Görüntü #8' e ait görsel sonuçlar



#### IV. SONUÇ

Çok modlu tıbbi görüntü birleştirme uzamsal alan yöntemlerinden dönüşüm alanı yöntemlerine ve derin öğrenmeye kadar dayanır. Bilgisayar destekli klinik tanıya olan ihtiyacın fazla olmasından dolayı, çok modlu görüntü birleştirme çalışmaları da artmaktadır. Farklı araştırmacılar, farklı yöntemlerin avantajlarını ön plana çıkaran çalışmalar yapmaya devam etmektedir. Bu çalışmada DCHWT, DCT, DWT, SWT\_DCT, SWT ve CNN yöntemlerinin birleştirme performansları arasında sayısal ve görsel sonuçlara dayanarak karşılaştırma yapılmıştır. Birleşik görüntülerin performans analizi  $Q_P^{AB/F}$ ,  $Q_{CB}$ ,  $Q_{SF}$ ,  $Q_{STD}$  ve  $Q_{BRQ}$  kalite metrikleri ile yapılmıştır.  $Q_{BRQ}$  kalite metriği için sayısal olarak düşük değer daha başarılı olduğunu ifade etmektedir. Diğer dört kalite metriği için yüksek değer daha başarılıdır. Elde edilen sayısal ve görsel sonuçlar doğrultusunda en başarılı iki birleştirme

yöntemi DCT ve DWT yöntemleri olmuştur. İşlem süresi açısından en hızlı SWT yöntemidir.

#### KAYNAKLAR

- [1] A. P. James and B. V. Dasarathy, "Medical image fusion: A survey of the state of the art," *Information fusion* vol. 19, pp. 4-19, 2014.
- [2] B. Meher, S. Agrawal, R. Panda, and A. Abraham, "A survey on region based image fusion methods," *Information Fusion* vol. 48, pp. 119-132, 2019.
- [3] J. Du, W. Li, K. Lu, and B. Xiao, "An overview of multi-modal medical image fusion," *Neurocomputing* vol. 215, pp. 3-20, 2016.
- [4] S. Bhat and D. Koundal, "Multi-focus image fusion techniques: a survey," *Artificial Intelligence Review* vol. 54, pp. 5735-5787, 2021.
- [5] V. Aslantaş, A. Bulatov, and R. Kurban, "Multi-focus image fusion using a fuzzy criterion function." 6th International Symposium on Intelligent And Manufacturing Systems, IMS 2008, Sakarya, Turkey, 2008, ss.1-5
- [6] C.-I. Chen, "Fusion of PET and MR brain images based on IHS and log-Gabor transforms," *IEEE Sensors Journal* vol. 17, no. 21, pp. 6995-7010, 2017.
- [7] V. Aslantas, R. Kurban, A.N. Toprak, E. Bendes, "A Novel Web Application for Image Fusion." ICIT 2015 The 7th International Conference on Information Technology , Amman, Jordan, 15 May 2015, ss.397-401s
- [8] S. Madanala and K. J. Rani, "PCA-DWT based medical image fusion using non sub-sampled contourlet transform," in *2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPEs)*, 2016, pp. 1089-1094: IEEE.
- [9] M. Amin-Naji and A. Aghagolzadeh, "Multi-focus image fusion in DCT domain using variance and energy of Laplacian and correlation coefficient for visual sensor networks," *Journal of AI Data Mining* vol. 6, no. 2, pp. 233-250, 2018.
- [10] M. N. Do and M. Vetterli, "The contourlet transform: an efficient directional multiresolution image representation," *IEEE Transactions on image processing* vol. 14, no. 12, pp. 2091-2106, 2005.
- [11] M. Haribabu, C. H. Bindu, and K. S. Prasad, "Multimodal medical image fusion of MRI-PET using wavelet transform," in *2012 International Conference on Advances in Mobile Network, Communication and Its Applications*, 2012, pp. 127-130: IEEE.
- [12] A. Wang, H. Sun, and Y. Guan, "The application of wavelet transform to multi-modality medical image fusion," in *2006 IEEE International Conference on*

- networking, sensing and control*, 2006, pp. 270-274: IEEE.
- [13] A. L. Da Cunha, J. Zhou, and M. N. Do, "The nonsubsampling contourlet transform: theory, design, and applications," *IEEE transactions on image processing* vol. 15, no. 10, pp. 3089-3101, 2006.
- [14] M. Yin, X. Liu, Y. Liu, and X. Chen, "Medical image fusion with parameter-adaptive pulse coupled neural network in nonsubsampling shearlet transform domain," *IEEE Transactions on Instrumentation Measurement* vol. 68, no. 1, pp. 49-64, 2018.
- [15] Y. Liu, X. Chen, H. Peng, and Z. Wang, "Multi-focus image fusion with a deep convolutional neural network," *Information Fusion* vol. 36, pp. 191-207, 2017.
- [16] Y. Liu, X. Chen, J. Cheng, and H. Peng, "A medical image fusion method based on convolutional neural networks," in *2017 20th international conference on information fusion (Fusion)*, 2017, pp. 1-7: IEEE.
- [17] Y. Na, L. Zhao, Y. Yang, and M. Ren, "Guided filter-based images fusion algorithm for CT and MRI medical images," *IET Image Processing* vol. 12, no. 1, pp. 138-148, 2018.
- [18] Y. Yang, "A novel DWT based multi-focus image fusion method," *Procedia engineering* vol. 24, pp. 177-181, 2011.
- [19] K. Kannan, S. A. Perumal, and K. Arulmozhi, "Area level fusion of multi-focused images using multi-stationary wavelet packet transform," *International Journal of Computer Applications* vol. 2, no. 1, pp. 88-95, 2010.
- [20] R. P. Desale and S. V. Verma, "Study and analysis of PCA, DCT & DWT based image fusion techniques," in *2013 international conference on signal processing, image processing & pattern recognition*, 2013, pp. 66-69: IEEE.
- [21] B. Shreyamsha Kumar, "Multifocus and multispectral image fusion based on pixel significance using discrete cosine harmonic wavelet transform," *Signal, Image Video Processing* vol. 7, pp. 1125-1143, 2013.
- [22] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, 2012.
- [23] C. S. Xydeas and V. Petrovic, "Objective image fusion performance measure," *Electronics letters* vol. 36, no. 4, pp. 308-309, 2000.
- [24] Y. Chen and R. S. Blum, "A new automated quality assessment algorithm for image fusion," *Image vision computing* vol. 27, no. 10, pp. 1421-1432, 2009.
- [25] A. M. Eskicioglu and P. S. Fisher, "Image quality measures and their performance," *IEEE Transactions on communications* vol. 43, no. 12, pp. 2959-2965, 1995.
- [26] Y. Liu, S. Liu, and Z. Wang, "A general framework for image fusion based on multi-scale transform and sparse representation," *Information fusion* vol. 24, pp. 147-164, 2015.
- [27] A. Mittal, A. K. Moorthy, and A. C. Bovik, "No-reference image quality assessment in the spatial domain," *IEEE Transactions on image processing* vol. 21, no. 12, pp. 4695-4708, 2012.

## Yurtta Barınan Öğrencilerin Ayrılma Sebeplerinin Veri Madenciliği Yöntemleriyle Analiz Edilmesi

Berrin Değirmenci\*, Oktay Yıldız<sup>2</sup>

<sup>1</sup>Bilgisayar Mühendisliği/Fen Bilimleri Enstitüsü, Gazi Üniversitesi, Ankara, Türkiye

<sup>2</sup>Bilgisayar Mühendisliği/Fen Bilimleri Enstitüsü, Gazi Üniversitesi, Ankara, Türkiye  
\*berrin.degirmenci@gazi.edu.tr

**Abstract** – Ülkemizde Üniversite öğrencilerinin büyük bir bölümü öğrenim hayatlarının bir döneminde devlet yurtlarında kalmaktadır. Bu çalışmanın amacı, Kredi ve Yurtlar Genel Müdürlüğü (KYGM)'nde barınan öğrencilerin; yurttan ayrılma sebeplerinin veri madenciliği yöntemleriyle analiz edilmesidir. Yapılan analizler sonucunda yurt şartlarının iyileştirilmesi veya sosyal ortamın düzenlenmesi için öneriler sunulması, ayrılma nedenleri ve barınan öğrencilerin çeşitli özellikleri analiz edilerek; ayrılması baştan öngörülen öğrencilerin yurt başvuru ve yerleştirme kriterlerinin yeniden gözden geçirilmesinin sağlanmasıdır. İlk olarak veri ön işleme ve öznitelik analizi gerçekleştirilmiştir. Öznitelik seçimi, bilgi kazancı ve korelasyon öznitelik sıralama filtresi kullanılarak yapılmıştır. Modellerin aşırı uyumunu önlemek için eğitim seti üzerinde k-katlı çapraz doğrulama kullanılarak, veri setine popüler tahmin modelleri olan; lojistik regresyon, naive bayes, destek vektör makinesi, karar ağaçları, KNN, ANN vb. uygulanmıştır. Önerilen kayıp tahmin modeli; doğruluk, kesinlik, hatırlama, f-ölçüsü ve karar verici etkinliği (ROC) alanı gibi metrikler kullanılarak değerlendirilmiştir. En başarılı sonuçları; Karar Tablosu (DecisionTable) algoritması %86,95 doğruluk ve %89 ROC alanı, Adaboost algoritması %86,93 doğruluk ve %89 ROC alanı ve Karar Kütüğü (Decision Stump) algoritmasının %86,93 doğruluk ve %85 ROC alanı ile göstermiştir.

**Keywords** – Yurt Memnuniyeti, Sınıflandırma, Kümeleme, Makine Öğrenmesi, Veri Madenciliği

### I. GİRİŞ

Yükseköğrenim öğrencileri barınma yerleri olarak; kamu/vakıf/dernek ve özel sektöre ait yurtları, apart evleri, özel pansiyonları, kiralık evleri ya da akrabalarının yanında kalmayı seçebilirler. Barınma yerlerinin seçiminde ise, öğrencinin kendisinin ve ailesinin sosyo-ekonomik durumu, güvenlik, kiralık, okula yakınlık ve ulaşım kolaylığı, üniversite öğreniminin sürdürüldüğü şehirdeki konutların kapasite ve durumları gibi birçok faktör etkili olmaktadır [1].

Yurtlarda barınarak üniversite öğrenimlerine devam eden öğrenciler, ailelerinden uzak yaşamlarına devam etmeleri sebebiyle barınma, beslenme, sağlık, ekonomik, sosyal gelişim vb. ile ilgili sorunlar yaşama riski ile karşı karşıya kalmaktadırlar. Ayrıca yurttan kalan öğrencilerin yeni bir yaşam tarzı ile tanışmaları ve toplu kalınan bir ortama girmeleri nedeniyle başka problemler ile de karşılaşabilmektedirler. Bu nedenlerden yurttan ayrıldıkları varsayılmaktadır.

KYGM amaçları incelendiğinde öğrencilerin yurtlardan memnun kalması, kaliteli hizmet alması ve öğrenim hayatları boyunca yurttan ayrılmamaları istenmektedir. Çalışmamız ile Kuruma yurttan ayrılması tahmin edilecek öğrenciler hakkında fikir verilebilir.

Yurt dışındaki çalışmalarda; üniversite öğrencilerinin yurttan barınmasının lokal ve öğrenim gördükleri üniversite kampüsü ile sınırlı olduğu görülmüştür, ülkemizdekine benzer yurt yerleştirme çalışmaları [2], [3] bulunmaktadır. Öğrenci

yurtlarının hizmet kalitesinin ölçüldüğü bir çalışma yapılmıştır [4]. Yükseköğrenimde yurt hizmetleri ve barınma hakkında bir araştırma yapılmıştır [1].

Yurttan ayrılma nedenlerinin analiz edilmesi ile ilgili ülkemizde çok fazla çalışma bulunmamaktadır; ancak konuya benzer müşteri kaybı araştırmaları mevcuttur. Literatürde makine öğrenmesi, veri madenciliği ve hibrit teknikler kullanılarak kayıp tahmini yapılmıştır. Bu teknikler, şirketlerin kayıp müşterileri belirlemesini, tahmin etmesini ve elde tutmasını sağlar.

Literatürdeki benzer çalışmalardan bazı örnekler aşağıda verilmiştir. Müşterileri sınıflandırmak için çeşitli algoritmaları kıyaslayan çalışmada en yüksek başarı %88,63 ile Rastgele Orman (RF)'dir [5]. Başka bir makalede Logit yaprak modeli (LLM) diye hibrit bir model önerilmiştir. Logistik regresyon ve karar ağacının birleşimi bir modeldir. Bileşenleriyle mukayese edildiğinde daha başarılıdır [6]. Bu çalışma; özellik oluşturma, yığınlama modeli (logistik regresyon, karar ağacı, naive bayes) ve yumuşak oylamadan oluşan yeni bir müşteri kaybı tahmin sistemi önermektedir, %96.12 başarı elde edilmiştir [7]. Diğer bir çalışma, müşteri kaybı ve kayıpsızlık ile ilgili önemli karar kurallarını çıkarmak için kaba küme teorisine (RST) dayanan akıllı bir kural tabanlı karar verme tekniği önermektedir. Kapsamlı simülasyon deneyleri, Kapsamlı Algoritma (EA), Genetik Algoritma (GA), Kapsama Algoritması (CA) ve LEM2 algoritması (LA) olmak üzere dört kural oluşturma mekanizması kullanılarak yapılmıştır en iyi performansı önerilen RST tabanlı CCP yaklaşımı göstermiştir

[8]. Önerilen çerçeve, müşteri kaybını daha iyi yönetmek için telekomünikasyon operatörlerine eksiksiz bir kayıp analizi sağlamak için kayıp tahmini ve müşteri segmentasyon sürecini birleştirir. Altı makine öğrenimi sınıflandırıcısı ile yapılan deneylerde üç veri seti kullanarak müşteri kayıp durumu tahmin edilir. AdaBoost'un %77,19 doğruluk ile veri kümesi 1'de; Random Forest, %93,6 doğruluk ve ile veri kümesi 2'de; Random Forest, doğruluk açısından %63,09 ile veri kümesi 3'te en iyi performansı göstermiştir [9]. Müşteri kayıp tahminini (CCP) için akıllı karar ormanı (DF) modelleri geliştirmişlerdir. Lojistik model ağacı (LMT), rastgele orman (RF) ve İşlevsel Ağaçlar (FT), DF modelleri ile karşılaştırılmış ve önerilen DF modellerinin telekom endüstrisinde üstün tahmin performansı gösterdiği görülmüştür [10]. Yapılan diğer bir çalışmada Telekom sektöründeki müşteri kaybının tahmini için çeşitli makine öğrenmesi teknikleri uygulamışlardır. Adaboost ve XGboost Sınıflandırıcının sırasıyla %81,71 ve %80,8 ile en yüksek doğruluğu verdiği tespit edilmiştir [11].


Yaptığımız çalışmada öğrencilerin yurttan ayrılma sebepleri veri madenciliği yöntemleri ile incelenmiş ve yurttan erken ayrılan öğrencilerin tespitine çalışılmıştır. Çalışmanın amacı, makine öğrenmesi ve veri madenciliğinde mevcut teknikleri araştırmak ve ayrılan öğrenci tahminleri için bir model önermek, ayrılma faktörlerini belirlemek ve elde tutma stratejileri sağlamaktır.

Bu makalede, çeşitli veri madenciliği algoritmaları kullanan ayrılan öğrenci tahmin modeli önerildi. Bir sınıflandırıcının performansı, mevcut veri setine bağlıdır. Veri seti olarak Kredi ve Yurtlar Genel Müdürlüğü'nün Ankara ilinde bulunan yurtlarında barınan öğrencilerinin 2016-2022 yılları arasındaki verileri kullanılmıştır. Önemli öznitelikler, bilgi kazancı ve korelasyon öznitelik sıralama filtresi gibi öznitelik seçme teknikleri kullanılarak seçilmiştir. Önerilen ayrılan öğrenci tahmin modeli, sınıflandırıcı doğrulama metrikleri kullanılarak değerlendirilmiştir. Doğruluk, TP oranı, FP oranı, Kesinlik, Hatırlama, F-ölçüsü ve ROC alanı kullanılarak modelin performansı ölçülür. Deneylerden, önerilen modelin yüksek doğruluk elde ederek, DecisionTable algoritmasının diğer makine öğrenmesi algoritmalarına göre daha iyi doğruluk ürettiği belirlenmiştir. Yapılan araştırmalar sonucunda, konu hakkında yurtiçinde pek fazla çalışma yapılmadığı görülmüştür. Çalışmanın yeni araştırmalar için öncü olacağı varsayılmaktadır.

## II. METARYALLER VE YÖNTEM

Ayrılan öğrenci tahmin modeli; öğrenci kaybını öngörmeyi ve uzun süreli barınacak öğrencileri elde tutmayı amaçlamaktadır. Öğrenci kaybının önlenmesi için uygun önlemlerin alınmasını sağlamaktır.

Bu, ayrılıp ayrılmayacakların tahmin edildiği ikili bir sınıflandırma problemidir. Bu sorunun üstesinden gelebilmek için; daha önce yapılan çalışmalara dayanarak oldukça etkili teknikler olan; doğrusal regresyon, destek vektör makinesi, naive bayes, karar ağacı, rastgele ormanı vb. içeren makine öğrenimi algoritmaları [9], [11], [12] kullanılır. Makine öğrenimi modellerinde, ön işleme sonrası özellik seçimi, sınıflandırma doğruluğunun iyileştirilmesinde önemli bir rol oynar.



Şekil 1. Ayrılan Öğrenci Analizi Çerçevesi

Şekil 1 Ayrılan Öğrenci Analizi çerçevesini göstermekte ve adımlarını açıklamaktadır. İlk adımda; gürültü giderme, veri filtreleme, dengesiz veri özellikleri kaldırma ve verilerin normalleştirilmesini içeren veri ön işleme yapılır. Önemli Özniteliklerin seçimi bilgi kazancı ve korelasyon öznitelik sıralama filtresi kullanılarak yapılmıştır. Sorunun çözümü için naive bayes, lojistik regresyon, geliştirme (boosting), torbalama, karar tablousu, karar kütüğü, karar ağacı, rastgele orman, destek vektör makinesi, , en yakın komşu, yapay sinir ağları (MLP), vb. makine öğrenmesi teknikleri kullanılmıştır. Tahminler yapılmış ve sınıflandırıcıların başarıları; doğruluk, kesinlik, hatırlama f-ölçüsü ve karar verici etkinliği (ROC) alanı gibi metrikler kullanılarak değerlendirilmiştir.

### A. Veri Ön İşleme

Veri ön işleme, veri madenciliği yöntemleri uygulanmadan önce veri seti üzerinde yapılan düzeltme, eksik veriyi tamamlama, tekrarlanan verileri kaldırma, dönüştürme, bütünleştirme, temizleme, normalleştirme, boyut indirgeme vb. işlemlerdir.

Yapılan çalışmada, Yurt Öğrenci veri seti içindeki binlerce öğrenci kaydından konuyla ilgili olanlar seçilmiştir, verilerin veri madenciliği yöntemleriyle analiz edilebilmesi için tarih ya da metin içeren özellikler sayısallaştırılmıştır. Bazı özellikler kategorik hale getirilmiştir. Verilerden yeni veriler üretilmiştir. Gürültülü veriler çıkarılmış ve eksik veriler tamamlanmıştır. Veri ön işleme tamamlandığında Tablo 1'de gösterilen 34 öznitelikli 8783 veri kaydı sınıflandırmaya hazır hale getirilmiştir.

Tablo 1. Seçim Yapılacak Öznitelikler

	Öznitelikler		Öznitelikler
1	CINSİYET	18	GELIR_PUAN
2	MEDENIDURUM	19	BASARI_PUAN
3	YURTTANAYRILDIGIYAS	20	OGRETIM_SEKLI
4	ADRES_IL_ID	21	PUAN_TURU
5	ENGEL_TURU_ID	22	VELAYET
6	ONCELIK_DURUM	23	BOLUM_OZEL_YETENEK
7	BASVURU_TURU	24	FAKULTE_GRUP
8	IL_DISI_UNI_KARDES	25	YURTLOKASYON
9	IL_ICI_UNI_KARDES	26	BAHCE
10	ANNE_VEFAT	27	MODELTIPI
11	BABA_VEFAT	28	YATAKTIPI
12	ANNE_BABA_AYRI	29	YATAK_SAYI
13	ANNE_SAG_OZURLU_BEYAN	30	UCRET_TIPI
14	BABA_SAG_OZURLU_BEYAN	31	YURT_BOLUMUZAKLIK_GRUP

15	VAKIF_TAM_BURS_DEGIL	32	YURT_KAPASITE_GRUP_1
16	MEB_KARDES_SAYI	33	BINAKAPASITE_GRUP_1
17	SOSYAL_DURUM_PUAN	34	KALDIGI_AY_1

### B. Öznitelik Seçimi

Öznitelik seçimi, çalışılan problem için en önemli ve en yararlı özellikleri seçerek veri setindeki özellik sayısının azaltılmasını amaçlamaktadır. Algoritma hızını artırır, ilgisi olmayan ya da ilgisi düşük olan veriyi ortadan kaldırır, veri kalitesini artırır, veri setini daha basit ve anlaşılabilir hale getirir, önerilen modelin başarısını artırır [13]. Bu nedenle öznitelik seçimi önemlidir. Literatürde öznitelik seçimi için bir takım teknikler [2], [14], [15], [16] mevcuttur.

Bilgi kazancı, bir veri kümesinin dönüşümünden kaynaklanan entropideki azalmayı hesaplar. Her değişken bilgi kazancını hedef değişken bağlamında değerlendirerek özellik seçimi için kullanılabilir. Korelasyon ise iki varlık arasındaki istatistiksel ilişki olarak tanımlanır. Makine öğreniminde korelasyon, iki veya daha fazla özelliğin birbirleriyle ne kadar ilişkili olduklarını kontrol etmek için kullanılır. İki özellikten herhangi biri yüksek düzeyde ilişkiliyse veya her ikisi de aynı bilgiyi taşıyorsa bu durumda bunlardan biri gereksizdir aralarından seçim yapılır.

Bu çalışmada öznitelik seçimi, Bilgi Kazancı ve Korelasyon Nitelikleri Sıralama Filtresi teknikleri WEKA araç setini kullanılarak yapıldı. Yurt Öğrenci veri setinde, her iki tekniğin Tablo 2’de gösterilen sonuçlarına göre yüksek sıralama değerlerine sahip olan toplam 34 özelliğten ilk 27’si seçildi. KALDIGI\_AY\_1 sınıflandırmayı direkt etkilediğinden çıkarılmıştır. Bu çalışmada kullanılan veri seti 26 öznitelik içermektedir. Böyle yüksek boyutlu bir veri setinde, bazı nitelikler performans ölçümünü iyileştirir ve karar verme süreci için faydalıdır, diğerleri ise daha az önemli niteliklerdir. Öznitelik seçiminde bu norm göz önüne alınmıştır.

Tablo 2. Bilgi Kazancı ve Korelasyon Öznitelik Seçim filtresi sıralama sonuçları

No	Öznitelik	Bilgi Kazancı Sıralaması	Korelasyon Sıralaması
34	KALDIGI_AY_1	0.64249692	0.726607
3	YURTTANAYRILDIGIYAS	0.49232142	0.670929
1	CINSIYET	0.04970366	0.261717
24	FAKULTE GRUP	0.04834594	0.079863
31	YURT_BOLUMUZAKLIK_GRUP	0.03705054	0.20598
26	BAHCE	0.02653318	0.191283
27	MODEL TIP	0.01884151	0.107257
28	YATAK TIPI	0.01873054	0.009715
16	MEB_KARDES_SAYI	0.01191664	0.127498
30	UCRET TIPI	0.00871423	0.089996
22	VELAYET	0.00671395	0.087683
12	ANNE_BABA_AYRI	0.00661807	0.09589
21	PUAN_TURU	0.00512664	0.031489
18	GELIR_PUAN	0.00503488	0.041905
4	ADRES_IL_ID	0.00409062	0.036573
17	SOSYAL_DURUM_PUAN	0.00389283	0.021928
15	VAKIF_TAM_BURS_DEGIL	0.00369065	0.069434
29	YATAK_SAYI	0.0036464	0.009715
33	BINAKAPASITE GRUP 1	0.00344194	0.063874
32	YURT_KAPASITE GRUP 1	0.00269516	0.05618
19	BASARI_PUAN	0.00165298	0.024623
11	BABA_VEFAT	0.00112052	0.039521

8	IL_DISI_UNI_KARDES	0.00084824	0.033667
23	BOLUM_OZEL_YETENEK	0.00065037	0.026218
10	ANNE_VEFAT	0.00026113	0.01908
13	ANNE_SAG_OZURLU_BE_YAN	0.00025486	0.01885
14	BABA_SAG_OZURLU_BE_YAN	0.00000212	0.001715
7	BASVURU_TURU	0	0.012634
2	MEDENIDURUM	0	0.000649
20	OGRETIM_SEKLI	0	0.009714
9	IL_ICI_UNI_KARDES	0	0.002055
5	ENGEL_TURU_ID	0	0.000454
6	ONCELIK_DURUM	0	0.009035
25	YURTLOKASYON	0	0.024252

### C. Sınıflandırma Algoritmaları

Sınıflandırma; tahmin edici bir yöntemdir, denetimli bir öğrenme algoritmasıdır. Sınıflandırıcılar bir veri setinin, içerdiği ortak özelliklerine göre belirli kategorilere ayrılmasını sağlamaktadır. Bu amaçla çeşitli algoritmalar geliştirilmiştir [17].

Yurt Öğrenci veri setinde iki tür öğrenci vardır. Birincisi, mezun öğrenciler; yurttan okulan mezun olana kadar kalırlar. İkinci tip ise yurttan kendi isteğiyle vaktinden önce ayrılan öğrencilerdir. Önerilen model, yurttan ayrılan öğrenciyi hedefliyor ve ayrılışın arkasındaki nedenleri tanımlıyor. Bu çalışmada, öğrenci verilerini sınıflandırmak için bir dizi makine öğrenme tekniği kullanılmıştır. Algoritmalarından hangisinin öğrencileri en iyi şekilde sınıflandırdığını değerlendirmektedir. 10-k çapraz doğrulama ile J48, Karar Kütüğü, Karar Tablosu, Adaboost, LogitBoost, Torbalama, Naive Bayes (NB), Rastgele Orman (RF), Çok Katmanlı Algılayıcı (MLP), Lojistik Regresyon (LR), SVM ve KNN kullanıldı. Sınıflandırma işlemi WEKA 3.8.6 araç takımı kullanılarak gerçekleştirilmiştir.

Aşağıda; güvenilirliği, verimliliği ve popülerliği dikkate alınarak, makine öğrenmesi için kullanılan altı köklü teknik sunulur [11], [12], [13], [18], [19].

Karar Ağaçları, belirli bir veri kümesi için sınıflandırma kuralları oluşturabilen karar kümelerini temsil eden ağaç şeklindeki yapılardır. Müşteri kaybı probleminde, yüksek doğruluğa sahiptir. Destek vektör makinesi, verileri çok boyutlu bir girdi alanına haritalayarak ve alanı homojen bölümlere ayıran optimal bir hiperdüzlem oluşturarak örüntü tanıma problemlerini çözmektedir [20]. Yeni örneklerin tahminleri daha sonra bu bölümlere göre sınıflandırılır. Yapay sinir ağları, insan özelliklerinden biri olan öğrenme ile yeni bilgiler türetme, oluşturma gibi yetenekleri gerçekleştiren bilgisayar sistemleridir. Bayes sınıflandırıcısı, Bayes teoremini güçlü (naive) bağımsızlık varsayımlarıyla uygulamaya dayanan basit bir olasılıksal sınıflandırıcıdır. Bu sınıflandırıcı, bir sınıftaki belirli bir özelliğin başka bir özellik ile doğrudan ilişkili olmadığını varsayar, ancak o sınıfın özellikleri kendi aralarında bağımlılık yaptırabilir [18]. Naive Bayes sınıflandırıcısının birçok uygulamada faydalı olduğu görülmektedir. Regresyon analizi değişkenler arasındaki ilişkiyi ölçmek için kullanılan istatistiksel bir süreçtir. Bir bağımlı değişkenin birden fazla bağımsız değişken arasındaki ilişkiye odaklanıldığında, çeşitli değişkenlerin modellenmesi ve analiz edilmesi için birçok teknik içerir. Topluluk öğrenme,

bir dizi temel sınıflandırıcı tarafından yapılan tahminleri birleştirir. Çoklu makine öğrenimi algoritmalarının kullanılması, bir sorun için bir dizi hipotez oluşturulmasına sağlar. Sınıflandırıcılar topluluğu, ortak bir sonuç üretmek için hipotezleri birleştirir [13]. Örneğin; rastgele orman, birden çok karar ağacının tahminlerini birleştiren topluluk sınıflandırıcılarından biridir. Topluluk öğrenmesinin popüler yöntemlerinden bazıları torbalama, güçlendirme, çoğunluk oylama ve istiflemedir.

#### D. Model Başarısının Değerlendirme Yöntemi

Sınıflandırıcıların, tahminindeki performansını uygun parametrelerle değerlendirmek amacıyla, Tablo 3'de gösterilen karışıklık matrisinin içeriğinden hesaplanan kesinlik, hatırlama, doğruluk ve F-ölçüsü ölçümlerini kullanıyoruz [11].

Tablo 3. Karışıklık Matrisi

	Ayrılanlar (Kendi İsteğiyle Yurttan Ayrılan Öğrenciler)	Ayrılmayanlar (Mezun olan Öğrenciler)
Ayrıldı	Tp	Fn
Ayrılmadı	Fp	Tn


Sınıflandırıcıların performansları karışıklık matrisi çıkarıldıktan sonra, farklı ölçütler ile kıyaslanmıştır. Bu ölçütler doğruluk oranı (Tp Rate), yanlışlık oranı (Fp Rate), başarı oranı(A), hatırlama(R), kesinlik (P), F-ölçüsü (F), AUC-ROC eğrileridir. Başarı oranı (A): Toplam veri içindeki doğru tahmin oranıdır, duyarlılık (R): Pozitif olarak tahmin edilmesi gerekenlerin, kaçının doğru tahmin edildiğini gösteren metriktir, kesinlik (P): Pozitif olarak tahmin edilen örneklerin kaçının doğru tahmin edildiğinin oranıdır, F-Ölçüsü (F): kesinlik ve duyarlılığın harmonik ortalamasıdır [18].

### III. SONUÇ VE TARTIŞMA

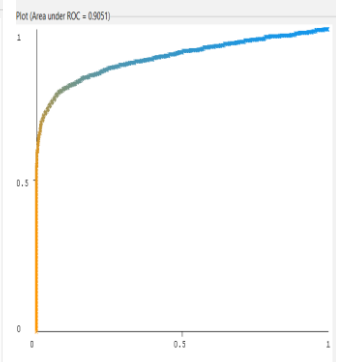
DeneySEL çalışmanın sonuçları, tablo 4'te gösterilmiştir. Doğru tahmin oranı, yanlış tahmin oranı, kesinlik, hatırlama, f-ölçüsü, ROC alanı değerlerine göre sınıflandırıcıların başarıları belirlenmiştir. Karar Tablosu (Decision Table) en yüksek doğruluk oranına sahiptir. ROC alanı değeri 1.0'e eşitse, bu mükemmel bir tahmindir.

Tablo 4. Sınıflandırıcıların Performansları


Classifier	Accurac y	TP Oran	FP Oranı	Precisi on	Recall	F-Measu re	ROC Area
Naive Bayes	82,9329	0,766	0,118	0,843	0,766	0,803	0,899
LogisticRegre syon	86,2689	0,79	0,077	0,894	0,79	0,839	0,905
AdaBoost	86,9293	0,751	0,032	0,951	0,751	0,839	0,895
Bagging	86,36	0,766	0,055	0,92	0,766	0,836	0,912
LogitBoost	86,8041	0,754	0,038	0,943	0,754	0,838	0,915
Decision Table	86,9521	0,753	0,034	0,949	0,753	0,839	0,89
Decision Stump	86,9293	0,751	0,032	0,951	0,751	0,839	0,851
J48	86,5536	0,778	0,062	0,912	0,778	0,84	0,868
RandomFores t	86,3031	0,783	0,071	0,902	0,783	0,838	0,916
SVM	86,4966	0,771	0,057	0,918	0,771	0,838	0,857
KNN	72,6176	0,663	0,221	0,713	0,663	0,687	0,72
ANN (Multiplayer Perceptron)	84,4131	0,792	0,112	0,854	0,792	0,822	0,898




Şekil 2 Naive Bayes ROC Alanı




Şekil 3 LogisticRegresyon ROC Alanı




Şekil 4 AdaBoost ROC Alanı




Şekil 5 Bagging ROC Alanı




Şekil 6 LogitBoost ROC Alanı




Şekil 7 Decision Table ROC Alanı




Şekil 8 Decision Stump ROC Alanı




Şekil 9 J48 ROC Alanı




Şekil 10 Random Forest ROC Alanı



Şekil 11 SVM ROC Alanı



Şekil 12 KNN ROC Alanı



Şekil 13 MLP ROC Alanı

Literatür taraması yapılmış yurttan ayrılma nedenlerinin analiz edilmesine benzer pek fazla çalışma olmadığı görülmüştür ancak bu probleme benzer müşteri kaybı analizleri yapılmıştır. Bu çalışmalar incelenmiştir, kullanılan yöntemlerin zayıf ve güçlü yönleri ele alınmıştır. Sorunun çözümüne uygun bir model önerilmiştir.

Yaptığımız deneysel çalışmalar neticesinde Tablo 4'te gösterildiği gibi topluluk öğrenimi algoritmalarının daha başarılı sonuçlar verdiği tespit edilmiştir. Karar Tablosu (DecisionTable) algoritmasının %86,95 doğruluk ve %89 ROC alanı, Adaboost algoritmasının %86,93 doğruluk ve %89 ROC alanı ve Karar Kütüğü (Decision Stump) algoritmasının %86,93 doğruluk ve %85 ROC alanı ile iyi performans gösterdiği görülmüştür. %91,6 ile en iyi ROC alanına sahip Random Forest %86,3 doğruluk oranı göstermiştir.

Çalışmasının sonucunda öğrencilerin özelliklerine göre yurttan ayrılma nedenleri tespit edilmiş, erken dönemde yurttan ayrılan öğrenciler başarılı şekilde bulunmuştur. Çıkan sonuçların değerlendirilmesi ile yurt koşullarının iyileştirilmesi ya da sosyal ortamın düzenlenmesi ve yurttan ayrılmanın asgari düzeye indirgenmesi hedeflenmektedir. İlk birkaç ayda yurttan ayrılması öngörülen öğrenci profilinin yurt başvuru ve yerleştirme kriterlerinin yeniden gözden geçirilmesi önerilecektir.

Gelecek çalışmalarda Ankara ilinde yurttan ayrılan ve dört yıl öğrenim gören öğrenciler için alınan verilerin diğer illere ve öğrencilere de yaygınlaştırılması, dezavantajlı grup için çalışmanın derinleştirilmesi planlanmaktadır.

## KAYNAKLAR

- [1] E. Kavuncu, "Türkiye'de Üniversitelerde Öğrenci-Yurt Hizmetleri ve Barınma Sorunu", *Eğitim-Öğretim ve Bilim Araştırma Dergisi*, sayı:30, pp. 48-50, 2014.
- [2] P. Frijters et al., "Heterogeneity in peer effects in random dormitory assignment in a developing country", *Journal of Economic Behavior and Organization*, 163, pp.117-134,2019.
- [3] N. Perach et al. "Stable matching of student-groups to dormitories", *European Journal of Operational Research*, 302 (1) , pp.50-61, 2022.
- [4] Ö. Kökalan et al., "Measurement of Service Quality in Public and Private/Foundation University Dormitories: Comparison of Turkish and Foreign Students", *Yüksek Öğretim Dergisi*, 9(3), pp.263-278, 2019
- [5] I. Ullah et al., "A Churn Prediction Model Using Random Forest: Analysis of Machine Learning Techniques for Churn Prediction and Factor Identification in Telecom Sector", *IEEE Access*, vol:7, pp: 60134 – 60149, 2019.
- [6] A. De Caigny et al., "A new hybrid classification algorithm for customer churn prediction based on logistic regression and decision trees", *European Journal of operational research*, vol:269 (2), pp.760-772,2018.
- [7] Tianpei Xu. et al., "Telecom Churn Prediction System Based on Ensemble Learning Using Feature Grouping", *Applied Sciences-Basel*, 11(11), doi: 10.3390/app11114742, 2021.
- [8] A. Amin et al., "Customer churn prediction in the telecommunication sector using a rough set approach", *Neurocomputing*, vol:237, pp.242-254, 2017.
- [9] S. Wu et al., "Integrated Churn Prediction and Customer Segmentation Framework for Telco Business", *IEEE ACCESS*, Vol. 9, 62118-62136, 2021.
- [10] F. Usman-Hamza et al., "Intelligent Decision Forest Models for Customer Churn Prediction", *Applied Sciences*, Vol. 12,8270, 2022.
- [11] P. Lalwani et al. "Customer churn prediction system: a machine learning approach", *Computing*, Vol. 104, No:2, pp.271-294,2021.
- [12] D. Al-Najjar et al., "Machine Learning to Develop Credit Card Customer Churn Prediction", *Journal of Theoretical and applied electronic commerce research*, Vol. 17, Issue:4,pp:1529-1542,2022
- [13] P. Mishra et al., "A Detailed Investigation and Analysis of Using Machine Learning Techniques for Intrusion Detection", *IEEE Communications Surveys & Tutorials*, vol.21(1), pp. 686-728,2019
- [14] H. Uğuz, "A two-stage feature selection method for text categorization by using information gain, principal component analysis and genetic algorithm", *Knowledge-Based Systems*, Vol:24, pp:1024-1032,2011
- [15] K. Niu et al., "A Developed Feature Selection Method for Classification Based on United Information Gain", 2017 IEEE Smartworld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computed, Scalable Computing & Communications, Cloud & Big Data Computing, Internet Of People And Smart City Innovation (Smartworld/Scalcom/Uic/Atc/Cbdcom/Iop/Sci),2017
- [16] AM. Kowshalya et al., "Correlation Based Feature Selection Algorithms for Varying Datasets of Different Dimensionality", *Wireless Personan Communications*, Vol.108, pp:1977-1993, 2019
- [17] A. Çınar, "Performance Evaluation Of Classification Algorithms In Data Mining And An Application With The R Language", *Marmara Üniversitesi Öneri Dergisi*, vol. 14(51), pp. 90-111,2019
- [18] S. Uddin et al. (2019), "Comparing different supervised machine learning algorithms for disease prediction", *BMC Medical Informatics and Decision Making*, 19(1), 2019
- [19] TM. Rausch et al., "Predicting online shopping cart abandonment with machine learning approaches", *International Journal of Market Research*, Vol:64, pp:89-112, 2022.
- [20] C. Cortes and V. Vapnik, *Support-Vector Networks. Machine Learning*, 20, 273-297. <http://dx.doi.org/10.1007/BF00994018>,1995



## FlexiGPT: Engaging with Documents

Abdalrhman Alquaary\*, Numan Çelebi <sup>2</sup>

<sup>1</sup>Information Systems Engineering, Sakarya University, Sakarya, Türkiye

<sup>2</sup>Information Systems Engineering, Sakarya University, Sakarya, Türkiye  
 \*(apoalquaary@gmail.com) Email of the corresponding author

**Abstract** – Leveraging the robust potential inherent in large language models, their profound and pervasive impact has transcended various domains in recent years, ushering in their widespread integration across diverse sectors. In resonance with this predominant trend, the current study introduces an innovative application that endows users with the capacity to actively engage in conversations with their digital files. This program integrates state-of-the-art large language models with the techniques of Retrieval Augmentation, thereby crafting an immersive and sophisticated experience that not only amplifies but fundamentally elevates user engagement to new heights of interactivity and responsiveness. Functioning as a pivotal nexus, Hugging Face, a renowned platform for machine learning models, assumes the role of the primary repository and catalyst for these transformative language models. Through the medium of this application, users can have interactive engagement, perfectly aligned with the continually evolving tapestry of linguistic technology and digital interaction. Significantly, users possess the freedom to choose from an extensive array of open-source large language models available on the Hugging Face platform, thereby, they also retain the option to seamlessly update to newer models as they become available, ensuring continuous access to the latest large language models and maintaining the applicability of the application in line with evolving user needs. Importantly, the operational viability of the program is extended to local execution, contingent upon the availability of sufficient hardware resources.

**Keywords** – LLM, Retrieval Augmentation, Hugging Face, Langchain, Local LLMs

### I. INTRODUCTION

The field of Natural Language Processing (NLP) has undergone a remarkable transformation in recent years, driven by the proliferation of Large Language Models (LLMs). These models, endowed with the ability to comprehend and generate human language, have transcended disciplinary boundaries, ushering in a new era of possibilities across various sectors. The impact of NLP advancements is palpable, extending from document analysis and summarization to chatbots and code analysis. It is within this dynamic landscape that we situate our project.

Central to our exploration is the LangChain framework, a remarkable open-source tool that simplifies the development of applications powered by LLMs [1]. Launched in October 2022 by Harrison Chase during his tenure at Robust Intelligence, LangChain offers developers a versatile solution. It streamlines the integration of LLMs into applications, effectively democratizing the capabilities of these models. Its core objective is to empower developers with the tools needed to create applications that harness the power of LLMs and connect seamlessly with data sources.

At the heart of our endeavor is the application we have developed, which leverages the LangChain framework to facilitate human-file interaction. This application represents a practical realization of the transformative potential of NLP advancements. Users can now engage in dynamic, interactive conversations with their digital files, transforming these repositories into responsive knowledge hubs. Notably, our application provides users with the flexibility to select LLM

models and embedding models from the Hugging Face platform, aligning their interactions with specific domains and preferences [2] [3].

In essence, this project introduces a user-centric and developer-friendly approach to harnessing the power of large language models (LLMs) in conjunction with retrieval augmentation for dynamic interactions with digital files. Our application streamlines the complex process of integrating LLMs into file-based interactions, offering developers a practical toolkit and end-users an intuitive platform. By democratizing access to LLMs and retrieval augmentation techniques, we empower both developers and users to engage in seamless, conversational exchanges with their files, thus bridging the gap between sophisticated NLP capabilities and practical utility. This contribution not only underscores the transformative potential of LLMs but also aligns with the ongoing evolution of NLP in enhancing human-file interaction. The application is available in github [4].

### II. RELATED WORKS

The field of natural language processing has witnessed remarkable advance-ments in recent years, driven by the development of increasingly sophisticat-ed Language Model Models (LLMs). This progress can be traced back to the idea "Attention is All You Need" [5], which introduced the Transformer archi-tecture. The Transformer marked a paradigm shift in the way we approach natural language understanding tasks, primarily through the incorporation of self-attention mechanisms that allowed models to consider global context de-pendencies efficiently.

In recent years, there has been a significant and ongoing enhancement in the performance of Large Language Models (LLMs), primarily attributed to the expansion of both high-quality data and model parameters. This evolution has heralded a genuine revolution in the domain of large-scale language model-ing. Notably, with the introduction of ChatGPT by OpenAI, the global interest in LLMs has surged, driven by their remarkable capacity to surpass the capabilities of traditional language models. Despite the formidable cost associated with training large language models, several forward-thinking organizations have undertaken the challenge, contributing to the open-source ecosystem by making these models publicly available. Leading the forefront of open-source LLMs is LLama-2, a prominent model accessible through the Hugging Face platform. This model exists in three iterations, distinguished by their parameter sizes: 7 billion, 13 billion, and an astounding 70 billion parameters. These publicly accessible models have ignited a plethora of innovative applications that harness the potential of LLMs, fundamentally reshaping the landscape of natural language understanding. The ubiquitous integration of LLMs into various applications underscores their transformative impact, solidifying their position as a foundational element in contemporary natural language processing and AI-driven systems. One notable application focuses on the evaluation of large language model (LLM)-based chat assistants. In a previous study, researchers delved into the utilization and inherent constraints of employing Large Language Models (LLMs) as judges. They presented innovative strategies to mitigate potential biases in LLM judgments and introduced two benchmarking mechanisms to gauge the alignment between LLM judgments and human preferences. The findings of this investigation highlighted the feasibility and interpretability of utilizing LLMs as evaluative proxies for approximating human preferences effectively [6].

The foundation of Retrieval Augmented Generation (RAG) lies in the evolution of text embeddings, a critical component in understanding and generating natural language text. The journey of text embeddings began with the advent of word vectors, which aimed to represent words as continuous, semantically meaningful vectors in a high-dimensional space. Word2Vec and GloVe were pioneering models in this regard, enabling the capture of word semantics and relationships [7], [8]. However, the field of embeddings rapidly evolved, spurred by the introduction of models like BERT (Bidirectional Encoder Representations from Transformers), GPT (Generative Pre-trained Transformers) and BGE (Bidirectional Generative Embeddings). BGE has achieved state-of-the-art results on several benchmarks, such as the TREC-COVID challenge. These state-of-the-art models revolutionized the way we represent text, offering contextual embeddings that could capture nuanced word meanings and their relationships within sentences and documents. This transition from traditional word vectors to context-aware embeddings marked a significant leap in natural language understanding. Harnessing these embeddings within the context of RAG has opened new frontiers in text generation and information retrieval, allowing systems to seamlessly blend the power of language models with the depth of semantic understanding.

### III. MATERIALS AND METHOD

In this study, we aim to create a system that allows users to interact with various document types, including PDFs, text files, and other document formats. The methodology consists of several interconnected steps designed to facilitate this interaction (Fig. 1).

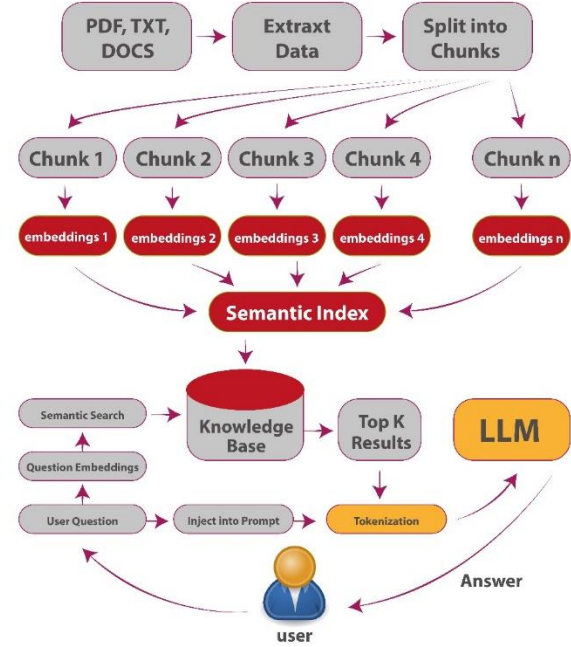


Fig. 1. The Process of the program

#### Data Collection and Preparation:

The initial step involves data collection and preparation. We assume that all data files are located in a single directory, which is by default named 'docs' and resides in the same folder – path – as the program. The program is responsible for extracting data from this directory, ensuring that the data is readily available for further analysis.

#### Data Chunking:

Once the data is extracted, it is transformed into manageable chunks. These chunks are created based on predefined criteria, which may include word count or paragraph boundaries. The purpose of this step is to break down the documents into smaller, digestible portions, making them easier to process.

#### Embedding Models:

A critical aspect of our methodology is the flexibility in choosing embedding models. Users have the option to select an embedding model from the Hugging Face Transformers library. The program is designed to dynamically download and apply the selected model to the data. It is important to note that the choice of the embedding model significantly influences subsequent stages of the process.

#### Semantic Index and Knowledge Base:

Following the embedding of data, a semantic index and knowledge base are created. These components serve as the

backbone of our system, allowing for efficient retrieval of relevant information. The semantic index is formed based on the embeddings, while the knowledge base stores critical information from the documents. This step plays a pivotal role in retrieving the most related chunks when we apply search similarity with the taken question from users.

**User Query Processing:**

In parallel with the above processes, the user interacts with the system by entering questions or queries. The user's question is embedded using the same selected embedding model. A semantic search is conducted to identify the most relevant document chunks in response to the user's query. Users also have the flexibility to specify how many relevant topics they want to retrieve, giving them control over the depth of information they receive.

**Engineered Prompt Generation:**

To further enhance the quality of responses from the large language model, the user's question is injected into an engineered prompt. This engineered prompt is carefully crafted to optimize the model's understanding of the user's query, thereby improving the relevance and accuracy of the generated answers.

**Model Input and Output:**

In the final step, we employ a technique called QLoRA to minimize the hardware requirements necessary to run Large Language Models (LLMs) [9], [10]. This innovative approach quantizes the weights of the model into 4 or 8 bits, reducing the computational demands significantly while preserving model performance.

Both the related document chunks and the engineered prompt are tokenized, and these tokenized inputs are then fed into the selected large language model with quantized weights. The model processes this input and generates an output, which is presented as the answer to the user's query, completing the user interaction loop. This efficient utilization of QLoRA empowers users to engage in an iterative process of querying the model within a while loop, providing a seamless and responsive experience while conserving hardware resources. Users have the flexibility to exit the program at their discretion, all while benefiting from the hardware-efficient capabilities of QLoRA.

Our methodology combines data extraction, chunking, embeddings, semantic indexing, user query processing, prompt engineering, and model interaction to enable users to seamlessly interact with document content using state-of-the-art language models and retrieval augmentation techniques.

**IV. RESULTS**

In the context of this study, the application that integrates state-of-the-art large language models with Retrieval Augmentation techniques was subject to comprehensive experimentation. The aim was to assess the effectiveness and

user experience of this innovative approach to digital interaction.

The experimental results indicated several noteworthy findings:

**Enhanced User Engagement:** In the early stages of testing the console-based application, it became evident that interaction with digital content experienced a significant enhancement. Conversations with digital files within the console interface exhibited a notable increase in immersion and sophistication, resulting in fundamental improvements in interactivity and responsiveness. These initial observations underscore the untapped potential of large language models in transforming user experiences across various domains through a console-based interface. This highlights the capacity of this approach to pioneer novel and groundbreaking digital interactions, even in the absence of specific user participants. In the following instances, the LLM lacked knowledge of "BERTopic." However, providing the LLM with the PDF article titled "BERTopic: Neural topic modeling with a class-based TF-IDF procedure" enabled the program to answer the question, "What is BERTopic?" This highlights our program's ability to access and provide relevant information from digital documents, even in cases where prior knowledge is limited (Fig.2) [12]. We can run the program using the command, selecting the LLM model 'meta-llama/Llama-2-7b-chat-hf' and the embedding model 'sentence-transformers/all-MiniLM-L6-v2':

```
> python flexiGPT.py --llm_model meta-llama/Llama-2-7b-chat-hf --embedding_model sentence-transformers/all-MiniLM-L6-v2 (1)
```

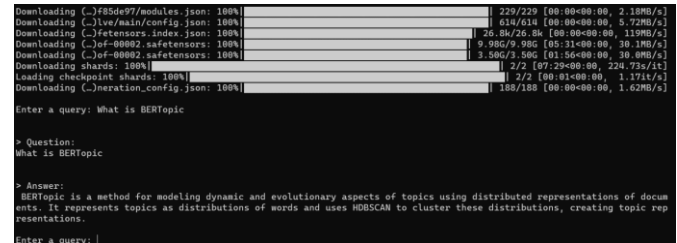


Fig. 2. Example of FlexiGPT output

In the second example, when we inquired about how BERTopic functions, the program provided a comprehensive and accurate response (Fig. 3).

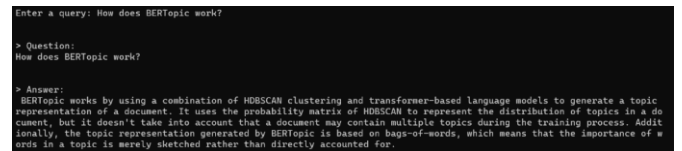


Fig. 3. Example 2 of FlexiGPT output

However, if we pose a question unrelated to the provided data, the program will respond by indicating that it lacks knowledge on the topic (Fig. 4).



Fig. 4. Example 3 of FlexiGPT output

**Diverse Model Selection for LLM Models:** In the context of this application, users had the flexibility to select from a

diverse range of open-source Large Language Models available on the Hugging Face platform. Notably, the default Large Language Model employed within the application was the highly capable Llama-2-7b-chat-hf. However, users also had the option to explore and choose from various other LLMs, each with its unique set of capabilities, enabling them to finely tailor their interactions to specific tasks and preferences (Table 1) [11]. This experimentation illuminated the critical role of LLM selection, showcasing that the choice of model significantly influenced the quality of conversational interactions and the depth of content understanding [2].

Table 1. Best Large Language Models in HF

Model Name	Average	Arc	HellaSwag	MMLU	TruthfulQA
uni-tianyan/Uni-TianYan	73.81	72.1	87.4	69.91	65.81
Riiid/sheep-duck-llama-2	73.69	72.35	87.78	70.82	63.8
fangloveskari/ORCA_LLaM	73.4	72.27	87.74	70.23	63.37
A_70B_QLoRA					
budecosystem/genz-70b	73.21	71.42	87.99	70.78	62.66
garage-bAInd/Platypus2-70B-instruct	73.13	71.84	87.94	70.48	62.26

**Diverse Model Selection for Embedding Models:** In addition to LLMs, users could also choose from a variety of embedding models, with the default being the BAAI/bge-base-en embedding model (Table 2). These embedding models played a pivotal role in enhancing the application's contextual understanding of digital files. The experimental results highlighted that the choice of embedding model significantly enriched the application's capacity to furnish users with comprehensive and contextually relevant information during their interactions. This dual-layered diversity in model selection, encompassing both LLMs and embedding models, offered users a powerful toolkit to tailor their digital interactions according to their unique requirements and preferences [3].

This dual-layered diversity in model selection not only enhanced user engagement but also showcased the adaptability of the application across different domains and use cases. It allowed users to harness the strengths of both LLMs and embedding models to optimize their digital interactions.

**Continuous Model Updates:** The ability to seamlessly update to newer models as they became available was a notable feature. This ensured that users had access to the latest advancements in large language models, keeping the application relevant and in line with evolving user requirements.

Table 2. Best Embedding Models in HF

Embedding Model Name	Size	Embedding Dimensions	Sequence Length
bge-large-en	1.34	1024	512
bge-base-en	0.44	768	512
gte-large	0.67	1024	512
gte-base	0.22	768	512
e5-large-v2	1.34	1024	512

**Local Execution:** The operational viability of the program, with the caveat of sufficient hardware resources, extended to local execution. This local execution option provides users with additional flexibility and control over their interactions.

The comprehensive analysis of the experimental results presented in this study serves as a compelling testament to the transformative power of harnessing large language models in conjunction with Retrieval Augmentation techniques to craft a

profoundly enriching user experience within the realm of digital interaction. The insights gleaned from this research strongly imply that these innovative applications possess not only the inherent potential but also the practical capability to redefine the very paradigms by which users engage with their digital files. By seamlessly blending the prowess of state-of-the-art language models and sophisticated retrieval augmentation strategies, this groundbreaking approach achieves a multifaceted augmentation of user interactions, encompassing heightened interactivity, unparalleled adaptability tailored to specific user needs, and an unobstructed conduit to the forefront of linguistic technology, where the latest advancements in large language models stand ready to amplify the digital experience. This study, thus, positions such applications at the forefront of digital innovation, poised to usher in an era where user engagement transcends prior boundaries, seamlessly integrating cutting-edge language technologies to create an immersive and responsive digital landscape that aligns seamlessly with evolving user expectations and preferences.

## V. DISCUSSION

The development and deployment of our application, designed to facilitate dynamic interactions with digital files using Large Language Models (LLMs) and Retrieval Augmentation, have provided us with valuable insights. In this discussion chapter, we delve into key factors that influence the quality of responses generated by our application. It is evident that the quality of responses is intimately tied to several critical elements, with the choice of LLMs, particularly their size and associated hardware requirements, standing out as a prominent factor.

### Model Size and Response Quality:

One of the fundamental factors that significantly impacts the effectiveness of our application is the choice of LLMs. Notably, the size of the LLM emerges as a decisive factor in determining the quality of responses. In the realm of LLMs, it's generally observed that larger models, characterized by a greater number of parameters, tend to produce higher-quality responses. The increased capacity of these larger models allows them to capture a broader spectrum of language nuances, leading to more nuanced, contextually aware, and coherent interactions with digital files.

Take, for example, the contrast between the Llama-2-7b model and its more massive counterpart, the Llama-2-70b model. While both are powerful in their own right, the Llama-2-70b model, with its expansive parameter count, consistently outperforms the Llama-2-7b model in terms of response quality. Users should be aware that opting for larger models often demands more substantial hardware resources. Thus, the choice of model size should align with both their quality expectations and their available computing infrastructure.

### Language, Tokens, and Datasets:

In addition to model size, the linguistic dimension continues to play a vital role in determining the quality of responses. LLMs are inherently dependent on the languages they were trained

on. The tokenization process and the datasets used for training contribute to the model's linguistic proficiency. For instance, LLMs trained on specific languages may exhibit limitations in comprehending or generating content in languages not adequately represented in their training data. Furthermore, the choice of tokens and datasets can influence how well the model understands and responds to specific queries. Models trained on a diverse range of tokens and datasets tend to exhibit greater language versatility and may offer more accurate responses, especially in multilingual contexts.

### **Future Studies**

Future studies for our project encompass two key areas of development. Firstly, the creation of multilingual Large Language Models (LLMs) tailored to a broader range of languages holds significant promise. Expanding language coverage will ensure that users from diverse linguistic backgrounds can engage with their digital files effectively. Secondly, the integration of a Graphical User Interface (GUI) is on the horizon to enhance accessibility and user-friendliness. A GUI interface will simplify the user experience, making it accessible to a broader audience and offering a more interactive and visually engaging platform for dynamic conversations with digital files. These advancements underscore our commitment to continuous improvement and the ever-evolving nature of Natural Language Processing (NLP) in reshaping human-file interaction.

### **REFERENCES**

1. Web Access: LangChain. [https://python.langchain.com/docs/get\\_started/introduction](https://python.langchain.com/docs/get_started/introduction).
2. Web Access: LLM Leaderboard. [https://huggingface.co/spaces/HuggingFaceH4/open\\_llm\\_leaderboard](https://huggingface.co/spaces/HuggingFaceH4/open_llm_leaderboard).
3. Web Access: Embedding Models LeaderBoard. <https://huggingface.co/spaces/mteb/leaderboard>.
4. Web Access: FlexiGPT. <https://github.com/apoalquaary/FlexiGPT>.
5. Vaswani, A., Shazeer, N., Parmar, N., and et al. 2017. Attention Is All You Need. NIPS. arXiv:1706.03762v5.
6. Zheng, L., Chiang, W.L., Sheng, Y., et al. 2023. Judging LLM-as-a-judge with MT-Bench and Chatbot Arena. arXiv:2306.05685v2.
7. Brochier, R., Guille, A., Velcin, J. 2019. Global Vectors for Node Representations. arXiv:1902.11004v1.
8. Mikolov, T., Chen, K., Corrado, G., et al., 2013. Efficient Estimation of Word Representations in Vector Space. arXiv:1301.3781v3.
9. Hu, E., Shen, Y., Wallis, P., et al. 2021. ORA: LOW-RANK ADAPTATION OF LARGE LANGUAGE MODELS. arXiv:2106.09685v2.
10. Dettmers, T., Pagnoni, A., Holtzman, A., et al. 2023. QLORA: Efficient Finetuning of Quantized LLMs. arXiv:2305.14314v1.
11. Touvron, H., Martin, L., Stone, K., et al. 2023. Llama 2: Open Foundation and Fine-Tuned Chat Models. arXiv:2307.09288v2.
12. Grootendorst, M. 2022. BERTopic: Neural topic modeling with a class-based TF-IDF procedure. arXiv:2203.05794v1.

# The Effect of the Visualization Type of Data Received from the X Platform on Manipulation Detection with Deep Learning

Hafzullah İş<sup>1\*</sup>

<sup>1</sup>Department of Computer Engineering, Batman University, Batman, Turkey

\*([hafzullah.is@batman.edu.tr](mailto:hafzullah.is@batman.edu.tr))

**Abstract** – Deep learning can provide successful results in detecting manipulations made with bot accounts on the X (Twitter) platform and preventing disinformation. As a method for applying deep learning algorithms, numerical values in the data set can be visualized and classified by making sense of them. The methodology used in the data visualization process and the structure of the shape created are critical for deep learning and classification performance. In this article, the effect of the format used to visualize the data in the dataset to be applied deep learning on the classification performance has been demonstrated with more than 400 experimental studies. From visualization methods; The effect of deep learning applied to images created with formats such as area graph, qrcode, spectrogram graph, color map, histogram and distribution on the classification performance with Convolutional Neural Network algorithms has been demonstrated comparatively. As a result of experimental studies, it was observed that while the highest performance was achieved with 98.67% depending on the visual and algorithm used, the performance decreased to 23.70% when different visuals and algorithms were used. In this regard, it has been determined that the methodology applied in revealing the profile confidence index, the effect of the variables that make up the data set and the algorithms used are very important, but the data visualization method used in creating the figure is important. has a critical impact on performance.

**Keywords** – X, Social Network Analysis, Deep Learning, Transfer Learning, Data Visualization, CNN.

## I. INTRODUCTION

In today's world, as a result of developments in information technologies, there is a transformation in people's interactions with each other. As a result of the internet being accessible all over the world and the increase in mobile phone usage, this transformation has begun to occur faster. While the subject of this transformation is humans, the intermediary object is social networks [1]. As Web 2.0 and the Internet pave the way for multifaceted interaction, people have found another medium to express themselves. The versatile interaction opportunities in this medium have been quite attractive. For this reason, diversity in social networks has begun to increase and the number of people using these networks has increased exponentially.

According to We Are Social's "Digital in 2020" report [1], digital, mobile and social media have become an indispensable part of daily life for people all over the world. Social media has become the source of digital culture. With digital culture, communication platforms, socialization areas and topics have changed. This change has caused very effective transformations in many areas, including economic, political and social. The opportunity to communicate and interact independently of geographical borders and without language, religion and culture limitations has made the social networks that the new generation grew up with an integral part of daily life. More than 4.5 billion people currently use the internet, while social media users have surpassed 3.8 billion.

However, the shadow of data misuse remains, with almost half of internet users using ad blockers[1]. Social networks'

user profile structures are important due to the size and diversity of the area that the intense user base affects politically, socially and economically. Social media manipulation by bot accounts makes social network analysis more important.

Figure 1 shows the closeness of bot account interaction to human interaction, which is critical in showing the destructiveness of manipulation in social networks.

Analyzing the profile structures of manipulated users in social networks is valuable in terms of determining their characters [3]. In this regard, understanding the categorical profile structures of users is valuable in preventing manipulation and disinformation in social networks [4]. There are many academic studies addressing the impact and destructiveness of manipulation in social networks. Ferrera's work predicting this danger in social networks has attracted a lot of attention in the literature [5]. In the "Manipulation Policy in Social Media-2020" report of the University of Amsterdam, it was stated that these destructive activities on social media have increased exponentially [6]. For this reason, determining the authenticity of social network user profiles as well as revealing their quality is valuable in preventing destructive manipulation activities.

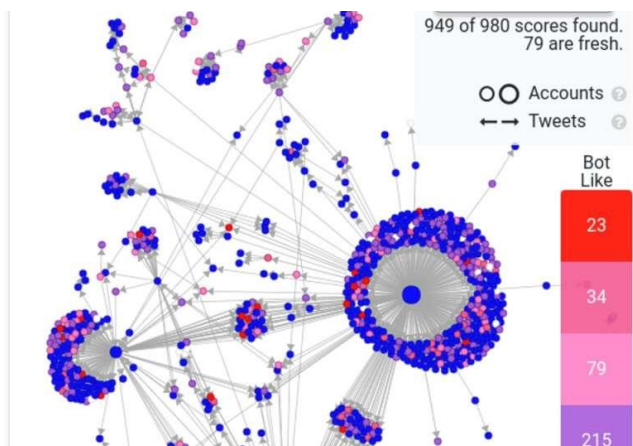


Fig. 1 Similarity Study of Bot Interaction in Social Networks to Human Interaction[2]

The article discusses the methodological approaches of the method, which was developed to detect and prevent the source of manipulation and disinformation in social media, specifically X (Twitter), and whose performance was tested on an up-to-date and comprehensive data set. In the applied methodology, deep learning performance was determined depending on the format of the images used. The data set consists of data that measures a user's interaction with static and dynamic aspects in multiple ways, using 10 different metrics. These metrics; It consists of modularity, reciprocity, centrality, diameter, density, likes, retweets, followers and follows, as well as the total number of tweets sent. The data consisting of all the specified metrics of the 3000 X (Twitter) users that make up the data set were visualized and the data set created from these visuals was added to the data set from Convolutional Neural Networks models; 6 different algorithms have been implemented, such as InceptionRN, MobilenetV2, Imagenet, Xception, Densenet201 and Resnet101. The effect of the structure of the visuals on performance was analyzed through experimental applications on visual types created in different structures.

## II. LITERATURE REVIEW

In this part of the article; Articles on the detection and classification of social network users have been examined, the methods adopted in solving the problems focused on in the relevant articles have been examined and their achievements have been presented. Social networks have been the subject of many studies in the literature due to their high number of users as well as their effects on political, social and economic areas. The main issues are the structure of user profiles, interaction styles and the quality of the accounts. Detection of malicious accounts such as spam, bots and identity fraud used in social network manipulation is an important area of work. There are several methods in the literature that have been used to detect malicious social network users, which are discussed in the experimental part of the article. Gannarapu and colleagues presented an automatic mechanism for detecting and removing bots on social media platforms [7]. Their research used bot detection technique based on machine learning algorithms. In the other article, active and passive users, as well as malicious accounts, were classified using machine learning, and a success rate of 96.81% was achieved [8]. In the study by Loyola-gonzález et al., a pattern-based classification

mechanism was used to detect social bots, especially for X (Twitter). A new feature model for bot detection has been introduced. Experimental results have shown that their mechanism outperforms other state-of-the-art classifiers, not based on patterns, and that feature models give better classification results than others reported in the literature [9]. In the vaccine bot detection study conducted by Yuan et al. in the United States, a retweet network about the MMR vaccine after the 2015 California Disneyland measles outbreak was examined and the communication patterns of anti-vaccine and pro-vaccine users and the role of bots on Twitter were investigated. Using supervised machine learning, users were classified into anti-vaccine, vaccine-neutral, and pro-vaccine groups.

It was discovered that pro and anti-vaccine users retweeted mainly from their own opinion groups. Additionally, bot analysis discovered that 1.45% of corpus users were identified as possible bots, accounting for 4.59% of all tweets in the dataset. In the study, it was determined that anti-vaccine social bots caused an environment that hindered the spread of vaccination [10]. In the study by Zago et al., a solution mix was proposed in the form of a proof-of-concept platform that combines the agility of artificial intelligence with the expertise of human analysts to detect and shield against the interference of social bots in detecting social robot activities [11].

In addition to machine learning applications used in bot detection, there are also deep learning applications. In our study, which detects the character of users in social networks and applies deep learning, the classification performance was higher than the machine learning application in the experimental studies conducted on the data set where convolutional neural networks were applied. In this regard, it has been determined that more effective results can be obtained by creating a data set from images with appropriate metrics and applying appropriate parameters and algorithms [12]. In the study by Cai et al., a behavior-enhanced deep model (BeDM) was proposed for bot detection. The proposed model views user content as temporal text data instead of plain text to extract latent temporal patterns. BeDM combines content knowledge and behavioral knowledge using the deep learning method. Experiments conducted on a real-world dataset collected from Twitter have also demonstrated the effectiveness of the proposed model [13].

In the study conducted by Ping et al.; A social bot detection model based on deep learning algorithm (DeBD) has been proposed [14]. The model basically includes three layers. The first layer is the collaborative content feature extraction layer, which focuses on feature extraction of tweet content and the relationship between them. The second layer is the tweet metadata temporal feature extraction layer, which considers tweet metadata as temporal information and uses this temporal information as the input of LSTM to extract the temporal feature of the user's social activity.

The third layer is the feature fusion layer, which combines extracted common content features with ad-hoc features to detect social bots. To evaluate the effectiveness of the DeBD model, experiments were conducted on three different types of new real-world social bot datasets. Experimental results have proven the success of the applied methodology. In the literature review, detailed information about machine learning and deep learning studies used in detecting malicious accounts is given, as well as examining the structure of user profiles in social networks. Since there are no precedent studies that used

a similar method to analyze the effect of the structure of the visuals on performance, it is not given. In this respect, the article has a unique structure.

The difference of this article from the literature and its contribution to the literature can be summarized as follows.

- In the article, an up-to-date and original data set was used in the profile analysis of social network users.
- It is a comprehensive data set because it addresses both the static profile structure and the dynamic interaction of the variables from which the data set is created.
- The originality of the article is the use of a visualization methodology applied on the numerical values in the data set and an alternative and more successful deep learning application method to machine learning.
- The article offers a new approach in terms of measuring the effect of the visualization format on the classification performance with deep learning applied on the data set.

### III. EXPERIMENTAL RESULTS

In this section, the process of creating the data set used in the thesis study and the applied methodology are explained. The metrics that make up the data set and the data cleaning, data integration, data reduction, data transformation and visualization processes covered by the applied data mining process are explained. Machine learning and deep learning algorithms used in the applied methodology, learning models, hyperparameters used, analysis and evaluation processes are discussed. Although there are many metrics used in the literature to analyze user profiles and detect bots, the use of an optimal number of but comprehensive metrics is the main criterion. In this sense, the data set of the experimental part of the article study was created from 10 metrics that can comprehensively scale a profile dynamically and statically. The data used was created by ourselves and obtained from current Twitter user data. In this article, those to be tagged are defined in 3 different groups in order to conduct behavioral analysis based on the physical interaction of the focal social media users. These groups are popular-active, observer-passive and spam-bot-malicious categories. These categories were created in accordance with the literature studies and experimental research and were revealed as the most appropriate combination in which social media users can be grouped in general terms.

The following methodology was followed for experimental application in the article:

- a) An original data set consisting of current data and comprehensive variables has been created. The metric data to be used when creating the data set was captured with Twitter Rest API.
- b) By applying data structuring processes such as data cleaning, data integration, data reduction and data transformation on the captured data, the data set is made ready for work.
- c) After the data was filtered, time series were applied on the metric data, the missing parts of the data set were completed and reduced to a single dimension. Min-Max Optimization was applied to eliminate the variance difference between the data.
- d) Numerical values in the data set were converted to visuals. Visualization process was applied to the numerical values of the data set and the data set was brought into a format that can be used with deep learning algorithms.

e) Image classification was performed with Deep Learning algorithms on the data set consisting of images prepared in different formats and experimental results were obtained. Additional techniques have been applied to improve the achieved achievements.

In the article, using 10 different metrics in interaction analysis was deemed sufficient to analyze the dynamic and static structure of a profile. These metrics; tweets, account age, follower rank, average retweet, average likes, diameter, density, reciprocity, centrality, centrality, and modularity.

Descriptions of these metrics and their purposes for use are as follows.

- (a) Tweets: These are messages sent by users to communicate with others.
- (b) Account Age: It refers to the entire period of time an account has been open since its first opening.
- (c) Follower Rank: It refers to the ratio of the number of followed accounts in the accounts to the number of following accounts.
- (d) Average Forwarding: It refers to the situation where a user reshapes another user's message on his/her own profile.
- (e) Average Likes: It is a parameter that expresses how much a social media user likes the messages shared by others.
- (f) Density: It is the ratio of existing connections to the total number of possible connections in a network.
- (g) Centrality: Measures the average degree of centrality of all nodes within a network.
- (h) Reciprocity: Reciprocity is a proportion of ties that exhibit two-way communication (also called reciprocal coupling) in relation to the total number of ties present.
- (i) Diameter: calculates the longest distance between two network participants.
- (j) Modularity: Modularity helps determine whether the clusters found represent different communities in the network.

The data used to create the data set as in Figure 2 was collected from Twitter. The metric data that makes up the dataset was captured with the Twitter Rest API V1.1 search/tweets endpoint using Socialblade and Netlytic platforms.

Fig. 2 A cross-section of sample user data captured with Twitter REST API.

The data set was created from data collected in a total of 16 periods within a 1-year period. Data from 3000 users were used as training and testing data.



Table 1 A Section from Data Normalized with Min-Max (K: User, M: Metric)

A Section from a Reduced Data Set with Simple Time Series										
Users	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
K1	9192	104	1	1,78	12,82	20	0,002933	0,004575	0,290370	0,606270
K2	11342	84	123	422,095	1208,36	19	0,001229	0,000000	0,403700	0,354600
K3	179136	105	2,57	75	268	19	0,015034	0,227400	0,227400	0,817460
K4	17	129	398,50	33	29	0	0,000000	0,000000	0,000000	0,000000
K5	...	...	...	...	...	...	...	...	...	...
A Section of Normalized Data with Min-Max Optimization										
K1	0,000243	0,660526	0,0001428	0,000225	0,01055	0,121212	0,002933	0,004575	0,29037	0,60627
K2	0,000299	0,532051	0,1757142	0,053429	0,99046	0,115151	0,001229	0,000000	0,4037	0,35460
K3	0,004736	0,666666	0,0003672	0,009493	0,21967	0,115151	0,002432	0,015034	0,2274	0,81746
K4	0,00045	0,820512	0,0569278	0,004177	0,02377	0,000000	0,000000	0,000000	0,0000	0,00000
K5	...	...	...	...	...	...	...	...	...	...




Fig. 3 Methodology used in data visualization for classification with deep learning

The data preprocessing process applied to the data set is given in Figure 3. Preprocessing steps such as cleaning, reduction, transformation and balancing were applied on the data. Since the data set consists of 16 periods of data, time series were applied to obtain images in order to reduce them to a single dimension. The Simple Averages Algorithm of the time series used is given in Equation 1.

$$SMA = \frac{P_m + P_{m-1} + \dots + P_{m-(n-1)}}{n} \quad (1)$$

Min-Max Optimization algorithm was used to eliminate variance differences between metrics in the data set. Thus, the dominance of one metric over other metrics due to variance difference was eliminated. The Min-Max optimization algorithm used is shown in Equation 2.

$$X^* = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2)$$




Fig. 4 CNN architecture used in image classification

Table 2 Performance of Deep Learning Algorithms Applied on Images Created in Different Formats

Model	Qrcode	Scatter	Colormap	Histogram	Area Graphics
Xception	71.30	77.21	80.74	87.49	98.67
ResNet101	27.80	31.14	52.91	62.76	98.33
InceptionRN.	23.70	38.60	38.19	73.58	95.58
MobileNetV2	38.40	40.10	47.53	69.74	95.35
ImageNet	29.66	36.29	48.60	74.81	92.67
DenseNet201	34.15	35.43	42.96	65.15	96.67




Fig. 5 Visualization of data with time series applied (wma-sma-cma: time series applied, t: time period)

After eliminating the variance difference with Min-Max Optimization, all user data in the data set was visualized by applying the steps shown in Figure 4 in accordance with deep learning and image classification.




Fig. 6 Examples from the Deep Learning Applied Dataset

These visuals created in Excel look different because they consist of data obtained by applying different time series. Since the images created from the data obtained by simple motion average in the classification methods applied on these images can be better analyzed and classified with high performance rates, the images created using this method have been used in deep learning. Since the images obtained with cumulative motion averages were very similar to each other, they were completely excluded from evaluation.

As shown in Figure 5, the method of obtaining images suitable for the area graphics format applied as a result of the time series used in dimension reduction in order to determine the most suitable format in the visualization process is shown.

In the visualization, images of 3000 users were created in different formats and their classification performance was measured.

The data was reconstructed in visual format as shown in Figure 6 to be processed and classified by the image processing algorithms of deep learning Convolutional Neural Networks.

$$CMA = \frac{X_1 + \dots + X_n}{n} \quad (3)$$

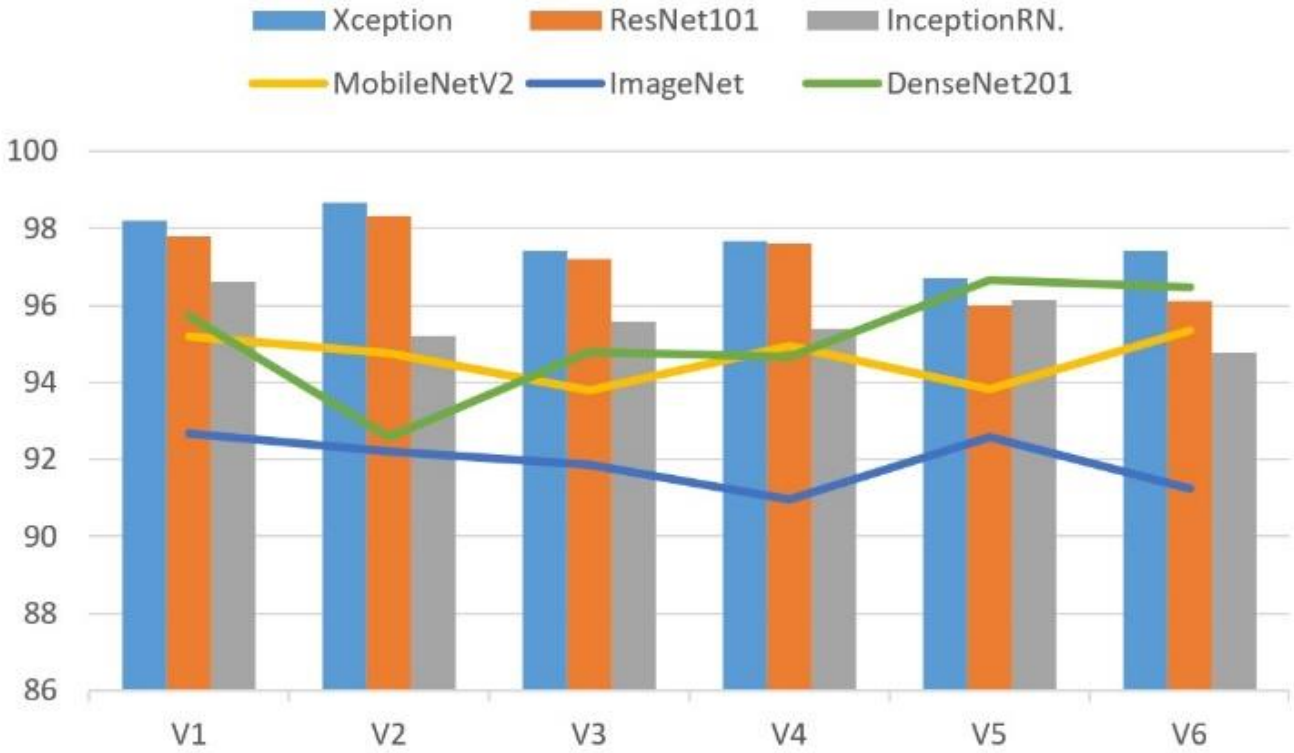
In Equation 3, the formula of the holistic motion average time series used in dimensionality reduction is given.

In visualization, visuals were prepared in formats such as area creation graph, spectrogram graph, colormap, histogram and scatter using Matlab visualization tools. Apart from these, 3000 images compiled from the holistic data set were used to overcome the problems of revealing the performance of the user with qrcode tools due to high resource needs and too much time required in image classification in deep learning.

Experimental applications were carried out on 6 sub-data sets by creating shapes with different structures in all formats for each user data in the data set.

Since hyperparameters such as the number of filters, filter size, activation function, optimization and image pre-processing that make up the convolutional neural networks structure can seriously affect the training success, as many ready-made convolutional neural network models as possible were loaded into the system with the transfer learning module and their performance was tested on the data set.

On the data set with Transfer Learning; Xception, ResNet18, ResNet50, ResNet101, InceptionResNetV2,



*Fig. 7 Graph of Performance Rates in Different Classification Studies Made by Applying Ready-made Convolutional Neural Network Models of Deep Learning (According to Area Graph)*

MobileNetV2, ImageNet, DenseNet201, NasnetLarge, InceptionV3, SqueezeNet, AlexNet, VGG16 and VGG19 deep learning architectures have been implemented.

In experimental studies conducted on the data set created from images structured in 5 different formats, results as shown in Table 2 and Figure 7 were obtained. It should be stated that the achievements here are not only due to the visual format, but also that the hyperparameters entered in the transfer learning application used when applying deep learning have a serious impact. But studies have shown that the format of the visuals affects performance at very high rates.

A total of more than 400 training sessions were carried out with these models, which were applied on data sets on multiple platforms with different hyperparameters, and the application results were analyzed.

The classification performance graphs of the Xception algorithm, which showed the highest performance in experimental studies conducted in the Matlab environment with the Dell Precision 7820 Tower workstation, on images of different structures are given below.

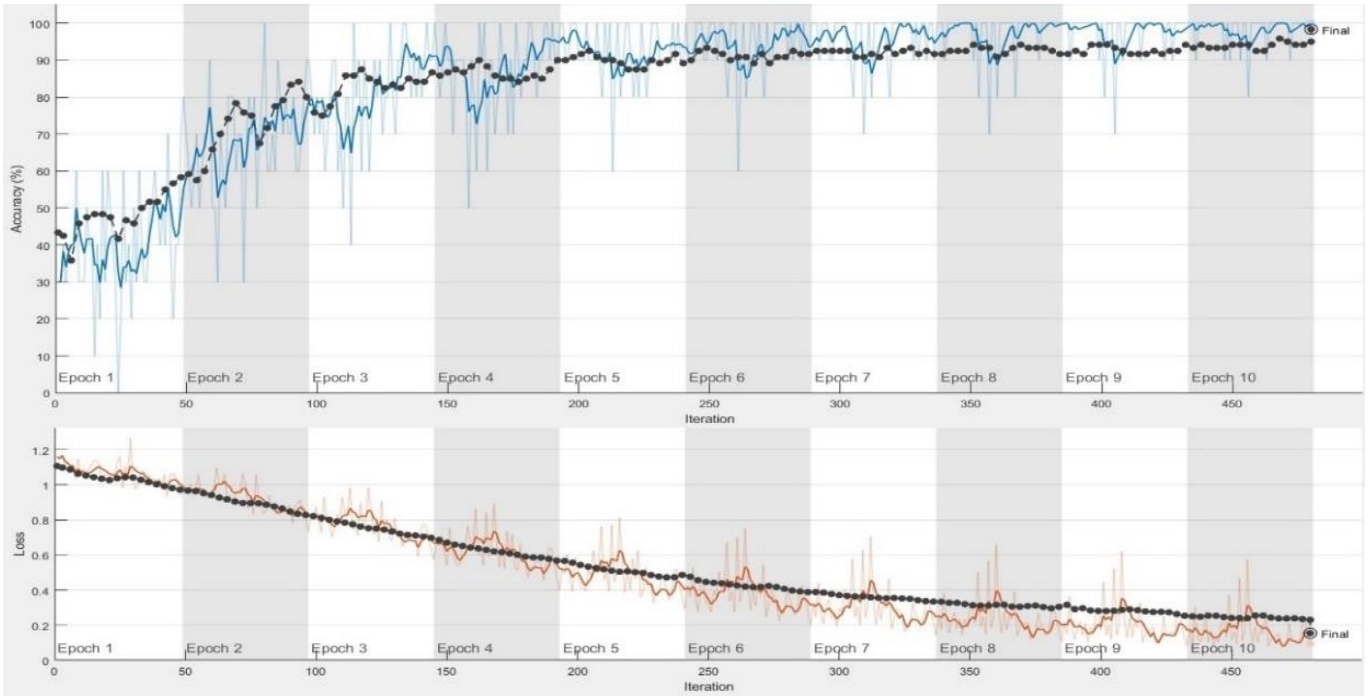


Fig. 8 Accuracy-Loss Graph of Xception Algorithm, Which Performs the Most Successful Classification on Area Graphs




Fig. 9 Data Set Accuracy Graph Created in Histogram Format Applied to Xception




Fig. 10 Data Set Accuracy Graph Created in Colormap Format Applied to Xception

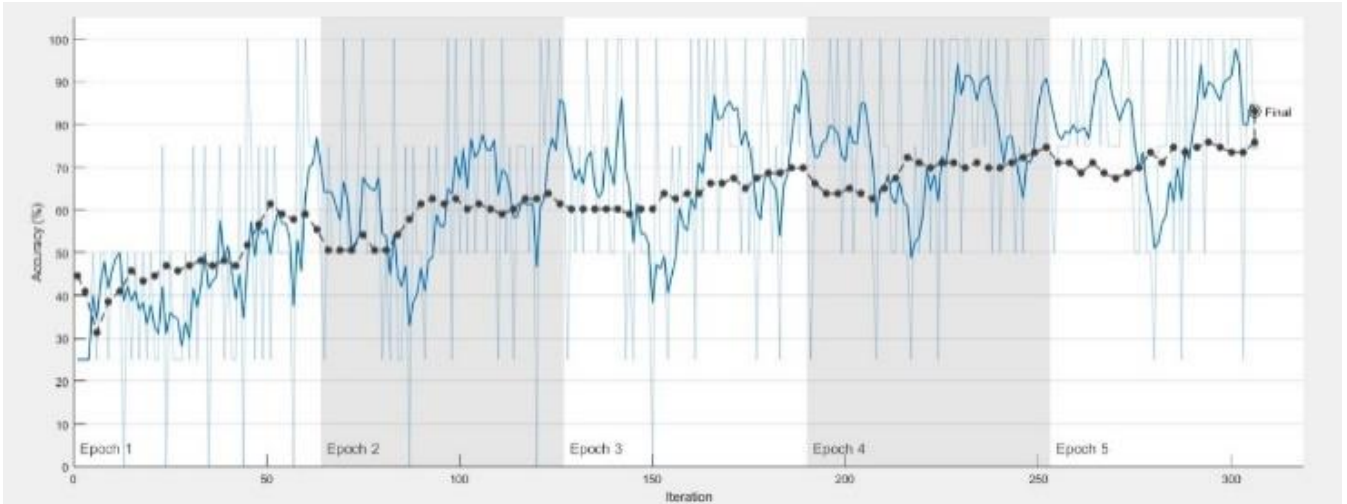


Fig. 11 Data Set Accuracy Graph Created in Scatter Format Applied to Xception




Fig. 12 Data Set Accuracy Graph Created in Applied Qrcode Format

In the experimental study, it was seen that the Xception algorithm gave the most successful classification results for images with all different structures. However, although the Xception algorithm successfully learned and classified area graphs and histogram graphs, it was observed that it interrupted the process after a maximum of 5 epochs because it could not learn from colormap, scatter and qrcode images and could not create a feature map. It has been determined that all other algorithms cannot produce feature maps of images created with different structures other than area and histogram graphics, and therefore cannot make a successful classification.

#### IV. DISCUSSION

In the article, it was tried to classify social network users as normal or malicious based on their interaction styles. The aim is to detect the source of manipulation in social networks through malicious account detection. Numerical values of the data set were visualized in order to apply deep learning on the data set. Since the desired level of performance could not be achieved in previous interaction analysis studies, this

methodology was developed as an alternative method [15], [16]. It has been observed that the performance in classification with machine learning is lower. As an alternative method, a visualization process was applied and classification was tried to be made with deep learning. In the developed methodology, high performances were achieved with the Xception algorithm used by applying Convolutional Neural Networks. However, as a result of approximately 400 experimental applications, it was determined that the performance depends on the hyperparameters used in the studies carried out with Transfer Learning, and that performing experiments on data sets containing images in a suitable format from which the algorithms can create feature maps affects the performance. It has been determined that in images such as histograms and area graphs, where the area corresponding to each metric is clear, the feature map can be created and thus the source of interaction can be revealed, but in formats where the metric values are melted into the image, the algorithms cannot decipher the structure of the visual and therefore cannot learn the feature map.

## V. CONCLUSION

Nowadays, due to their political, social and economic effects, the creation of trust indices of user profiles in social networks; Detecting malicious accounts is valuable in preventing manipulation and disinformation in social networks. In this article, a data set was created using effective and unique metrics that can measure dynamic and static interaction in the social network, and deep learning algorithms were applied on this data set. In the experimental studies carried out, it has been seen through experimental analysis that the creation method and structure of the visuals in the visualization study carried out in order to apply deep learning in the methodological approach applied are of critical importance in terms of deep learning algorithms being able to extract feature maps and make classification. It has been determined that classification studies performed on images that are not in the appropriate format are unsuccessful. However, when algorithms such as Xception were applied on images in appropriate formats, such as images consisting of area graphics suitable for creating feature maps, 98.67% performance could be achieved.

## REFERENCES

- [1] Simon Kemp, We Are Social "Digital in 2020" Report, <https://wearesocial.com/digital-2022> (2022).
- [2] Hoaxy-Indiana University, <https://hoaxy.osome.iu.edu/>, (2023).
- [3] H. İş, A. A. Müngen, T. Tuncer and M. Kaya, "Frequent pattern mining for community dedection in web logs group based habit dedection in community using network traces," 2017 International Artificial Intelligence and Data Processing Symposium (IDAP), 2017, pp. 1-7, doi: 10.1109/IDAP.2017.8090293.
- [4] [4]. H. İŞ and T. TUNCER, "Confidence Index Analysis of Twitter Users Timeline," 2018 International Conference on Artificial Intelligence and Data Processing (IDAP), 2018, pp. 1-8, doi: 10.1109/IDAP.2018.8620917.
- [5] [5]. E Ferrara, Manipulation and abuse on social media, arXiv:1503.03752, 2015.
- [6] [6]. R. Rogers, S. Niederer, The Politics of Social Media Manipulation, Amsterdam University Press, 2020.
- [7] [7]. S. Gannarapu, A. Dawoud, R. S. Ali and A. Alwan, "Bot Detection Using Machine Learning Algorithms on Social Media Platforms," 2020 5th International Conference on Innovative Technologies in Intelligent Systems and Industrial Applications (CITISIA), 2020, pp. 1-8, doi: 10.1109/CITISIA50690.2020.9371778.
- [8] [8]. İş, H.; Tuncer, T. Interaction-Based Behavioral Analysis of Twitter Social Network Accounts. Appl. Sci. 2019, 9, 4448. <https://doi.org/10.3390/app9204448>.
- [9] [9]. O. Loyola-Gonzalez, R. Monroy, J. Rodriguez, A. Lopez-Cuevas and J. I. Mata-Sanchez, "Contrast Pattern-Based Classification for Bot Detection on Twitter", IEEE Access, vol. 7, pp. 45800-45817, 2019.
- [10] [10]. X. Yuan, R. J. Schuchard and A. T. Crooks, "Examining Emergent Communities and Social Bots Within the Polarized Online Vaccination Debate in Twitter", Social Media + Society, vol. 5, pp. 205630511986546, 2019.
- [11] [11]. M. Zago, P. Nespoli, D. Papamartzivanos, M. G. Perez, F. G. Marmol, G. Kambourakis, et al., "Screening Out Social Bots Interference: Are There Any Silver Bullets?", IEEE Communications Magazine, vol. 57, pp. 98-104, 2019.
- [12] [12]. İş, H., Tuncer, T. (2021). A profile analysis of user interaction in social media using deep learning. Traitement du Signal, Vol. 38, No. 1, pp. 1-11. <https://doi.org/10.18280/ts.380101>
- [13] [13]. C. Cai, L. Li and D. Zengi, "Behavior enhanced deep bot detection in social media," 2017 IEEE International Conference on Intelligence and Security Informatics (ISI), 2017, pp. 128-130, doi: 10.1109/ISI.2017.8004887.
- [14] [14]. H. Ping and S. Qin, "A Social Bots Detection Model Based on Deep Learning Algorithm," 2018 IEEE 18th International Conference on Communication Technology (ICCT), 2018, pp. 1435-1439, doi: 10.1109/ICCT.2018.8600029.
- [15] [15]. İş, H , Tuncer, T . "Twitter Users' Emotion, Emoticons and Scaling Metrics Based Categorical Interaction Analysis". Journal of Engineering and Technology 2 (2018 ): 10-18
- [16] [16]. İş, H , Tuncer, T . "Kalite Ölçekleme Kriterleri ile Sosyal Ağ Hesaplarının Etkinliğinin Belirlenmesi". Fırat Üniversitesi Mühendislik Bilimleri Dergisi 31 (2019 ): 99-108

## Artırılmış Gerçeklik Teknolojisi Kullanılarak Yemek Menülerinin Oluşturulması ve Tasarlanması

Uğur İşçi<sup>1</sup>, Abdullah Orman<sup>2\*</sup>

<sup>1</sup>Ankara Yıldırım Beyazıt Üniversitesi, Ankara, Türkiye (ugurisci@gmail.com) (ORCID No: 0000-0002-2272-9105)

<sup>2\*</sup>Ankara Yıldırım Beyazıt Üniversitesi, Ankara, Türkiye (aorman@aybu.edu.tr) (ORCID No: 0000-0002-3495-1897)

**Özet** – Gelişen teknoloji birçok alanda alışkanlıklarımızı değiştirmekte etkili olmaktadır. Günümüzde restoranlar, yemek sektöründeki rekabetin artmasıyla birlikte müşterilerine farklı ve yaratıcı yemekler sunmak için çaba göstermektedirler. Bu nedenle, artırılmış gerçeklik teknolojisi bu amaç için kullanılabilir bir araçtır. Artırılmış gerçeklik (AG) teknolojilerinin, sanal ortam ile gerçek dünya arasında bir etkileşim sağlayarak restoranların yemek menülerinde olumlu anlamda hızlı bir dönüşümü sağlayacağı öngörülmektedir. Bu doğrultuda müşterilerin yemek seçimi yaparken artırılmış gerçeklik teknolojisi kullanılarak sunulan yemekleri daha iyi anlamaları ve seçim yapmaları amaçlanmaktadır.

Bu çalışmada, artırılmış gerçeklik teknolojisi kullanılarak yemek menüleri oluşturma ve tasarlama sürecinin nasıl gerçekleştirileceği ele alınacaktır. Örnek bir üç boyutlu çalışma hazırlanacak olup, bu çalışmanın ürünleri sergilemekte ne derece etkili olduğu, pazarlama, rekabet ve insanlarla etkileşim boyutları ele alınacaktır. Bu süreçte, yemeklerin üç boyutlu olarak sunumu, menü tasarımı ve müşterilerin menüyü görüntüleme deneyimi üzerinde durulacaktır.

**Anahtar Kelimeler** – Artırılmış Gerçeklik, Sanal Gerçeklik, Yemek Menüleri, QR Menü, Teknoloji.

## Using Augmented Reality Technology Creating and Designing Food Menus

**Abstract** – Developing technology is effective in changing our habits in many areas. Today, restaurants strive to offer different and creative dishes to their customers with the increasing competition in the food industry. Therefore, augmented reality technology is a tool that can be used for this purpose. It is predicted that augmented reality (AR) technologies will provide an interaction between the virtual environment and the real world, and will provide a positive rapid transformation in the food menus of restaurants. In this direction, it is aimed for customers to better understand and choose the dishes served using augmented reality technology while choosing their meals.

In this study, it will be discussed how to create and design food menus using augmented reality technology. An exemplary three-dimensional work will be prepared, and how effective this work is in displaying products, marketing, competition and interaction with people will be discussed. In this process, three-dimensional presentation of the dishes, menu design and the customers' experience of viewing the menu will be emphasized.

**Keywords** – Augmented Reality, Virtual Reality, Food Menus, QR Menu, Technology.

### I. GİRİŞ

Günümüzde hızla gelişen teknolojiler sonucunda insanlar bireysel zaman geçirme şekillerini değiştirebilmekte ve çevresiyle olan etkileşimini farklılaştırabilmektedir [7]. Artırılmış gerçeklik teknolojisi akıllı cihazlarla uyumlu yenilikçi bir teknolojidir. Bu doğrultuda pazarlama alanında tüketicilerin dokunma, işitsel ve görsel gibi başlıca duyularına hitap etmektedir. Aynı zamanda kullanıcılar, fiziksel ortamdan başka bir ortama geçmeden ürünü zengin içeriklerle görebilmekte ve deneyimleyebilmektedir [2]. Artırılmış gerçeklik teknolojisinin kullanıldığı alanlardan birisi mimarlıktır. Gerçek proje alanında dolaşabilme, sanal bir binayı görebilme gibi birçok özelliği beraberinde getiren AG teknolojisi, tasarımcılar ve müşteriler için oldukça zengin bir

deneyim olabilmektedir [5]. Doktor, hemşire ve sağlık çalışanlarının eğitimi büyük önem arz etmektedir. Bu doğrultuda meslek adaylarının öğrendiklerini sahada uygulama noktasında zorluklarla karşılaştıkları görülmektedir. Sağlık alanında AG teknolojisi bu sorunları gidermede önemli bir potansiyele sahiptir. Öğrenme üzerindeki kalıcılığı bu teknolojinin önemli özelliklerinden birisidir. AG teknolojisi sayesinde gerçeğe benzer sanal nesnelere oluşturularak eğitim verilebilmektedir. Hasta için bu durum daha az risk içermektedir. Öğrenen meslek adaylarının ise özgüveni daha da artmaktadır [8]. Müzeler ve sanatçılar AG teknolojisi sayesinde farklı ifade biçimleriyle sanatseverlere zengin bir deneyim sunabilmektedirler. Bu doğrultuda bir sanatçı, oluşturduğu eserin katmanlarını göstererek süreçteki aşamalarını sunabilirken, bir diğer sanatçı ise AG teknolojisi

ile oluşturulan kitabını dijital animasyonlu olarak daha zengin bir deneyimle gösterebilmektedir. Müzeler ise daha fazla ilgi çekmek için koleksiyonlarını AG teknolojileriyle tekrar canlandırabilmektedir [11]. Gerçek zamanlı olarak AG teknolojisi oyun ve eğlence sektöründe kullanılmaktadır. Bu doğrultuda oyundaki görsel ve işitsel içerikler kullanıcının ortamında yer alabilmektedir. Sanal gerçeklikten farklı olarak kullanıcı, özel bir konum ve ekipmana (kafaya takılan başlık) ihtiyaç duymadan, kendi ortamında bu deneyimi yaşayabilmektedir [7]. AG teknolojisi spor müsabakalarında canlı olarak oyun özelliklerini ve verilerini izleyiciler açısından etkileşimini artırmak için kullanılabilir [20].

Artırılmış gerçeklik (AR) teknolojisi son yıllarda hızla gelişmekte ve yemek sektöründe de kullanılmaktadır. Yemek deneyimleri giderek daha özgün ve görsel açıdan etkileyici hale gelirken, bu makale, artırılmış gerçeklik teknolojisinin yemek menülerinin estetik ve içerik açısından geliştirilmesindeki potansiyelini araştırmaktadır. Çalışmanın artırılmış gerçeklik destekli mobil yazılım geliştirme sürecini ayrıntılı olarak incelemesi ve uygulamayı deneyimleyen katılımcıların görüşlerini titizlikle analiz etmesi bağlamında literatüre olumlu katkıda bulunacağı düşünülmektedir. Bu çalışmanın daha sonra yapılacak çalışmalar için alt yapı oluşturması hedeflenmektedir.

## II. MATERYAL VE YÖNTEM

Bu çalışma, araştırma problemini kapsamlı bir şekilde anlamak, hipotezler oluşturmak ve daha ileri araştırmalar için potansiyel yolları belirlemek amacıyla konuyu derinlemesine incelemeyi amaçlayan, keşifsel araştırma tasarımıyla yürütülmüştür. Keşifsel çalışmalar belirli bir araştırma konusunun veya meselesinin araştırılmasının ilk aşamalarında, konuyla ilgili sınırlı ön bilgi veya önceki araştırma mevcut olduğunda kullanılan araştırma türlerindedir [12]. Bu tür çalışmaların birincil amacı, araştırma probleminin daha derinlemesine anlaşılmasını sağlamak, ilk hipotezleri oluşturmak ve daha kapsamlı araştırmalar için potansiyel araştırma sorularını belirlemektir. Bu çalışmalar, sonraki araştırma çabalarının yönünü ve odağını şekillendirmede temel bir rol oynamaktadır [21]. Bu araştırma, özellikle keşifsel çalışmalar için çok uygun olan nitel araştırma yaklaşımı kullanılarak gerçekleştirilmiştir [13]. Nitel araştırma deseni, karmaşık olguların daha derinlemesine anlaşılmasını sağlayan farklı ve zengin verileri yakalama özelliklerine sahiptir [14].

### VERİLERİN TOPLANMASI

Araştırma verileri, yanıtların zenginliğini ve derinliğini sağlamak için alandaki uzmanlar tarafından özenle tasarlanmış yarı yapılandırılmış görüşme formlarıyla toplanmıştır. Yarı yapılandırılmış görüşme soruları Yüksel'in tez çalışmasındaki sorulardan yararlanılarak çalışma için uygun hale getirilmiştir [22].

Görüşme formları, veri toplama sürecini standartlaştırmaya ve yapılandırmaya hizmet ederek araştırmalarda çok önemli bir rol oynar [18]. Bu formlar, tüm katılımcılar için tutarlı bir sorgulama hattı sağlayarak karşılaştırılabilirliği artırır ve veri analizini kolaylaştırır [23]. Standartlaştırılmış görüşme formlarının kullanımı, araştırmacıların yanıtları niceleştirmesini de sağlayarak araştırma boyunca nesnellığı teşvik etmektedir [16]. Ayrıca, araştırma sürecinin sistematik

bir şekilde belgelenmesini sağlar böylece tekrarlanabilirliği teşvik eder ve çalışmalar arası veya gruplar arası karşılaştırmaları kolaylaştırır [1].

### VERİ ANALİZİ

Toplanan veriler, kapsamlı bir kodlama kılavuzu tarafından yönlendirilen ve veri düzenleme yazılım araçlarıyla desteklenen titiz bir tematik içerik analizi sürecinden geçirilmiş, böylece bulguların geçerliliği ve güvenilirliği artırılmıştır [17].

Tematik içerik analizi, metinsel veya görsel verilerdeki örüntüleri veya temaları sistematik olarak tanımlamak, analiz etmek ve raporlamak için kullanılan nitel bir araştırma yöntemidir [9]. Bu yöntem, verileri ortak noktalara dayalı temalar veya örüntüler halinde kategorize ederek içeriğin altında yatan anlamları, fikirleri veya kavramları daha derinlemesine anlamak için uygulanmaktadır. Süreç veri tanıma, kodlama, tema oluşturma ve tema iyileştirmeyi içerir. Tematik içerik analizi yöntemi, araştırmacıların içgörülerini ortaya çıkarmasına, eğilimleri belirlemesine ve nitel verilerden teoriler üretmesine olanak tanıyarak karmaşık olguların daha zengin bir şekilde anlaşılmasına katkıda bulunduğundan sosyal bilimler, psikoloji ve sağlık araştırmaları da dahil olmak üzere çeşitli alanlarda yaygın olarak kullanılmaktadır [9].

### UYGULAMA

Uygulama APK formatında bir Android cihaza aktarıldıktan sonra katılımcılara sunulmuştur (Şekil 12). Katılımcılara uygulama hakkında bilgi verildikten sonra, deneyimleyebilmeleri için süre verilmiştir.

Uygulamayı deneyimleyen katılımcılara yarı yapılandırılmış görüşme soruları yüz yüze görüşme yöntemiyle sorulmuştur ve yanıtlar anlık olarak kaydedilmiştir. Katılımcıların özellikle bilgisayar teknolojileri ile alakalı meslekleri yapıyor olmaları çalışma için hazırlanan mobil uygulamanın geri dönüşleri için oldukça önemlidir.

## III. ARTIRILMIŞ GERÇEKLIK TEKNOLOJİSİNİN YEMEK MENÜLERİNDE UYGULANMASI

Teknolojinin hızla gelişmesi doğrultusunda artırılmış gerçeklik teknolojisi önemini giderek artırmaktadır. Gerçek dünya ile entegreli olan bu teknoloji, pazarlama alanında kendisine hızla bir şekilde yer bulmuştur. Tüketicilerin bu teknolojiye karşı tutumunun nasıl ve ne yönde olacağı sorusu önem kazanmıştır [6]. Özellikle restoranlarda gelişen teknoloji ve koşullara göre rekabet günden güne artmaktadır. Tüketiciler günümüzde daha çok deneyim odaklıdır. Fiyat ve ürün geri planda kalmakta, kişiye özel, diğerlerinden farklı ve nitelikli ürünler ön plana çıkmaktadır. Bu ürünlerde işletmelerin inovasyona gitmelerine neden olmaktadır [10].


### MOBİL YAZILIM GELİŞTİRME

Bu bölümde yiyecek ve içeceklerin artırılmış gerçeklik teknolojisi kullanılarak mobil uygulama haline getirilmesi süreçleri ele alınmıştır. Artırılmış gerçeklik tabanlı mobil uygulama yapım aşamaları Şekil 1'de özetlenmiştir.

Tüketicilerin restoranlarda en çok tercih ettiği ve tükettiği yiyecek ve içeceklerden on bir adet yiyecek ve iki adet içecek 3Dx Max programında tasarlanmıştır. Tasarlama aşamasında yiyeceklerin gerçeklik hissi uyandırması için titiz bir çalışma




yürütülmüştür. Hazırlanan üç boyutlu yemek ve içeceklerin mobil uygulama haline getirilebilmesi için birtakım programlara ve eklentilere ihtiyaç duyulmaktadır. Mobil uygulama yazılımları oluşturulmasında bilinen ve yaygın olarak kullanılan Unity3D programı bu çalışmada tercih edilmiştir. Unity3D programının güçlü bir oyun motoru olması ve program geliştirme aşamasında geliştiriciye kod yazma olanağı vermesi, rakiplerinden ayıran özellikler arasındadır.



Şekil 1. Artırılmış Gerçeklik Tabanlı Mobil Uygulama Yapım Aşamaları

Çalışmada Unity3D programı resmi web sitesinden 2023.1.0b1 sürümü indirilerek bilgisayara yüklenmiştir. UnityHUB arayüzü üzerinden 3D core hazır ayarları olan bir proje oluşturulmuştur.

Projede kamera hareketlerinde, işaretleyici vasıtasıyla nesnelerin konumlandırmasını sağlayan Vuforia eklentisi resmi web sitesinden (<https://developer.vuforia.com/downloads/sdk>) indirilmiş ve Unity3D programında projeye yüklenmiştir. Sahnedeki main camera sağ tıklanarak silinmiş ve onun yerine Vuforia Engine menüsü altında AR Camera sahneye dahil edilmiştir (Şekil2). Vuforia destekli AR Camera sahnemizde artırılmış gerçeklik destekli kamera hareketlerini sağlamak için kullanılmıştır.



Şekil 2. AR Kameranın Sahneye Eklennesi

AR Camera eklentisinin düzgün çalışabilmesi için web sitesinden lisans anahtarı edinilmiştir. Kullanıcı bilgileri girilerek Vuforia Engine Developer Portal'a üye olunmuştur. Licence manager sayfasından oluşturulan lisans anahtarı kopyalanmış ve Unity programında projeye eklenmiştir.

Yiyecek ve içeceklerin kamera ile görüntülenebilmesi için işaretleyiciye ihtiyaç duymaktadır. İşaretleyicinin temel prensibi yemek ve içeceklerin bu işaretleyici vasıtasıyla o konumda gösterilebilmesini sağlamaktır. Bu çalışmada QR

kodlu işaretleyici kullanılmıştır. QR kodları, hızlı yanıt için tasarlanmıştır ve bir akıllı telefon kamerası kullanılarak okunabilirler. İşaretleyici QR kodları, kullanıcılara bir web sitesine, ürün sayfasına, indirilebilir bir dosyaya veya diğer çevrimiçi kaynaklara yönlendirmek için kullanılabilir. QR kodlarının boyutu ve tasarımı oldukça önemlidir. QR kodlarının kolayca taranabilmesi için yeterli kontrast ve netlik sağlanmalıdır. Bu program için aşağıdaki işaretleyici özel olarak oluşturulmuştur (Şekil 3).



Şekil 3. Oluşturulan İşaretleyicinin Görüntüsü

Vuforia resmi web sitesinden develop menüsüne girilerek (<https://developer.vuforia.com/vui/develop/databases>) add database butonuna tıklanmıştır. Type menüsünden device seçeneği seçilmiş ve bir veritabanı ismi belirlenmiştir. Veritabanı oluşturulup, maksimum 2 megabayt boyutunda png ya da jpg formatında işaretleyici "Add target" butonuna basılarak yüklenmiştir. Oluşturulan işaretleyicinin puanının yüksek olması önem arz etmektedir. Çünkü bu puan, işaretleyicimizin diğer nesnelere ayırt edilebilmesini sağlamak ve kamera hareketlerinde kopmaları en aza indirmek önemli bir göstergedir. İşaretleyici oluşturulmuş ve "Download Database" butonuna tıklanarak Unity Editor programı seçilmiştir. Bu seçenek oluşturulan işaretleyicinin hangi platform için kullanılacağını göstermektedir. İndirilen işaretleyici Inspector menüsü altında Image Target ayarını from Database olarak seçilerek kullanılmıştır. Uygulamada içecek ve yiyeceklerin tek bir QR kod işaretleyici ile yansıtılabilmesinden kaynaklı sorunların önüne geçebilmek adına butonlar oluşturulmuştur. Sahnelerin birbirinden ayırt edilebilmesi ve ürünlerin çeşitliliğini simgelemesi bağlamında ana yemekler kırmızı, pasta çeşitleri mavi, içecekler ise sarı renkte oluşturulmuştur (Şekil 4).



Şekil 4. Ürünlerin farklı renklerde kategorize edilmesi

3Ds Max programında tasarlanan yiyecek ve içecek görselleri fbx formatında Unity programına tek tek aktarılmış ve sahnede işaretleyici katmanının altına yerleştirilmiştir. Game object menüsünden UI Legacy butonlar oluşturularak

isimlendirilmiştir. Oluşturulan bu butonların pozisyon ve boyut değerleri game menüsünden özileme yapılarak ayarlanmıştır. Hazırlanan sahneye C# ile oluşturulan script entegre edilerek butonların aktif olması sağlanmıştır ve basıldığında ürünleri sahneye getirmesi sağlanmıştır.

Uygulama dışı aktarılmadan önce farklı ebatlarda ikonlar Illustrator programı aracılığıyla oluşturulmuştur. Android, ios ve tablet cihazlarda bu ikonların görüntülenebilmesi için Unity3D programında Project Settings menüsü altından Player Settings'e girilerek ikonlar uygulamaya dahil edilmiştir. Uygulamayı dışı aktarmak için File menüsünden "Build Settings"e girerek dışı aktarmak istediğimiz platform olan Android seçilmiştir. Dışı aktarılan yazılımın uygulama içi görüntüsü Şekil 5'te gösterilmiştir.



Şekil 5. Uygulama İçi Görüntü

#### IV. BULGULAR

##### KATILIMCILARIN DEMOGRAFİK ÖZELLİKLERİ

Tablo 1. Katılımcıların Demografik Özellikleri

Kod	Cinsiyet	Yaş	Meslek	Eğitim Durumu	Süre (Dakika)
K1	Kadın	30	Grafik Tasarımcı	Lisans	36
K2	Kadın	34	Yazılımcı	Lisans	28
K3	Kadın	59	Dizgici	Önlisans	25
K4	Kadın	25	Sosyal Medya Uzmanı	Lisans	30
K5	Kadın	24	Grafik Tasarımcı	Lisans	33
K6	Erkek	44	Grafik Tasarımcı	Önlisans	36
K7	Erkek	54	Dizgici	Ortaokul	32
K8	Kadın	44	Yazılım Mühendisi	Lisans	27
K9	Erkek	35	Bilgi İşlem Uzmanı	Lisans	30
K10	Erkek	41	Bilgi İşlem Uzmanı	Lisans	32

İçlerinde grafik tasarımcı, yazılımcı, yazılım mühendisi, sosyal medya uzmanı, dizgici ve bilgi işlem uzmanı farklı

meslek gruplarından on kişiye yüz yüze mülakat yöntemi uygulanmıştır. Araştırmaya katılan katılımcıların demografik özellikleri Tablo 1'de verilmiştir. Araştırmaya katılan toplam 10 katılımcı K1, K2, K3, K4, K5, K6, K7, K8, K9, K10 şeklinde kodlanmıştır.

Tablo 1'de görüldüğü üzere, yaşları 24- 59 arasında değişen katılımcıların 6'sı kadın, 4'ü erkektir. Katılımcılar ortaokul, ön lisans ya da lisans mezunu olup, görüşmeyi 25 – 36 dakika arasında tamamlamışlardır.

##### KATILIMCILARIN AG İLE KARŞILAŞMA DURUMU

Tablo 2. Katılımcıların Artırılmış gerçekliğe sahip uygulamalarla daha önce karşılaşma ve yaygın olarak kullanılma durumu

Tema	f	Kod	f	Katılımcı Görüşleri
Karşılaşma Durumu	10	Karşılaşmış	5	Daha önce bu tarz üç boyutlu artırılmış gerçeklik destekli QR menü uygulaması ile karşılaşmış. (K-1, K-2, K-4, K-9, K-10)
		Karşılaşmamış	5	Daha önce bu tarz üç boyutlu artırılmış gerçeklik destekli QR menü uygulaması ile karşılaşmamış ve ilk defa deneyimliyor. (K-3, K-5, K-6, K-7, K-8)
Yaygınlık Durumu	10	Yaygınlık kazanmaya başladı	2	Bu ve benzeri uygulamalar birçok farklı sektörde yaygınlık kazanmaya, daha fazla insanın ilgisini çekmeye başladığını düşünüyor. (K-9, K-10)
		Yaygın değil	8	Bu ve benzeri tarzda hazırlanmış artırılmış gerçeklik uygulamalarının yaygın olarak kullanıldığını düşünmüyor. (K-1, K-2, K-3, K-4, K-5, K-6, K-7, K-8)

Farklı yaş, meslek ve eğitim düzeyine sahip katılımcılardan ilk olarak artırılmış gerçeklik uygulamalarıyla karşılaşmadıkları sorusuna yanıt vermeleri istenmiş ve yaygınlık durumu sorulmuştur. Katılımcıların %50'si daha önce bu tarz bir uygulama ile karşılaştığını, %50'si ise karşılaşmadığını belirtmiştir. Katılımcıların yarısı daha önce bu tarz üç boyutlu artırılmış gerçeklik destekli QR menü uygulaması ile karşılaşmıştır. Diğer yarısı ise daha önce bu tarz üç boyutlu artırılmış gerçeklik destekli QR menü uygulaması ile karşılaşmamış ve ilk defa deneyimlemektedir.

Katılımcıların %80'i bu tarz bir uygulamanın yaygın olmadığını, %20'si ise yaygınlık kazanmaya başladığını belirtmiştir (Tablo 2). Katılımcıların çoğunluğu bu ve benzeri tarzda hazırlanmış artırılmış gerçeklik uygulamalarının yaygın olarak kullanıldığını düşünmemektedir.

### UYGULAMANIN DEĞERLENDİRİLMESİ

Tablo 3. Katılımcıların deneyimlediği artırılmış gerçekliğe sahip uygulamayı değerlendirmesi

Tema	f	Kod	f	Katılımcı Görüşleri
Güzel/ Beğendim	9	Mutluluk verici	2	Sipariş vermeden önce ürünün görselini 3 boyutlu olarak görmenin kendisini mutlu ettiğini belirtiyor. (K-1, K-8)
		Fikir verdi	2	Ne yiyeceği konusunda fikir verici buldu. (K-4, K-7)
		Yenilikçi	1	Uygulamayı yenilikçi ve tarz buldu. (K-2)
		Kolay ve hızlı	2	Alışık olduğu klasik menülere bakmaktan daha kolay ve hızlı olduğunu düşünüyor. (K-5, K-9)
		Farklı bir deneyim	2	Uygulamanın kendisinde farklı bir deneyim oluşturduğunu belirtiyor. (K-3, K-10)
Kararsız	1	Anlamlandıramadım	1	Sektör için uygun bulmadığını belirtiyor. (K-6)

Katılımcıların, artırılmış gerçeklik uygulaması hakkında yaşadıkları deneyimi genel olarak değerlendirmeleri istenmiştir. Katılımcıların %90'ı bu uygulamayı beğendiğini söylemiş, %10'u ise kararsız kalmıştır (Tablo 3).

Uygulamayı beğenen katılımcılar uygulamanın mutluluk verici olduğunu (f=2), yiyecekleri hakkında fikir verdiğini (f=2), yenilikçi olduğunu (f=1), kolay ve hızlı olduğunu (f=2) ve farklı bir deneyim sunduğunu (f=2) düşünmektedir.

Öte yandan uygulama hakkında olumlu ya da olumsuz fikri olmayan katılımcılar, uygulamayı anlamlandıramadıklarını (f=1) belirtmiştir.

### SATIN ALMA KARARINA ETKİSİ

Tablo 4. Katılımcıların deneyimlediği artırılmış gerçekliğe sahip uygulamanın satın alma kararını nasıl ve ne yönde etkilediği durum

Tema	f	Kod	f	Katılımcı Görüşleri
Olumlu	9	Menüye dokunmayacak olmak	1	Pandemi sürecini değerlendirdiğimde uygulamanın satın alma kararımı olumlu yönde etkileyeceğini düşünüyorum. Şuan için de aynı şeyi düşünüyorum. (K-2)
		Ne yiyeceğimi görebiliyorum	6	Ne yiyeceğimi önceden gördüğüm için satın alma kararımı olumlu yönde etkiler. (K-1, K-3, K-4, K-7, K-8, K-10)
		QR Menü	2	QR Menü uygulamasını kullanan ve bunun entegrasyonunu sağlayan işletmelere gitme isteği uyandırdı. (K-5, K-9)
Kararsız	1	Sanal	1	Gözümle yemeği görmem gerekiyor, sanal olduğu için kararsızım. (K-6)

Katılımcılara yöneltilen bir diğer soru, katılımcıların deneyimlediği artırılmış gerçekliğe sahip uygulamanın satın alma kararını nasıl ve ne yönde etkilediğidir. Katılımcıların %90'ı olumlu anlamda bir satın alma kararı vereceğini belirtirken, %10'u ise kararsız kalmıştır (Tablo 4).

Katılımcılar menüye dokunmadan (f=1) içerik hakkında bilgi sahibi olmanın, ne yiyeceklerini önceden görmelerinin (f=6) ve QR menü (f=2) seçeneğinin satın alma konusundaki kararlarını olumlu etkilediğini vurgulamışlardır. Öte yandan içeriğin sanal (f=1) olması bazı katılımcıları olumsuz etkilemiştir fakat yine de kararsızdırlar.

### ÜRÜNE KARŞI OLAN TUTUM ÜZERİNE ETKİSİ

Katılımcılara yöneltilen bir diğer soru, deneyimledikleri uygulamanın ürüne karşı olan tutumlarını etkileyip etkilemediğini değerlendirmeleridir. Katılımcıların %70'i ürüne karşı olan tutumunu olumlu anlamda değiştirdiğini belirtirken, %20'si kararsız kalmış, %10'u ise olumsuz olacağını belirtmiştir (Tablo 5). Satın alacakları ürüne karşı tutumlarının olumlu yönde değişeceğini söyleyen katılımcılar, uygulamadaki ürünleri gerçekçi (f=7) buldukları için tutumlarını değiştirdiklerini söylemiştir. Tutumlarının

değişmeyeceğini söyleyen katılımcılar ise, bunun sadece görüntüden ibaret olmasını, ne yiyeceklerini bilmediklerini (f=2) gerekçe olarak sunmuşlardır. Tutumlarının olumsuz yönde etkilenmeyeceğini söyleyen katılımcılar ise buna gerekçe olarak porsiyonların gerçekçi olmamasını (f=1) sunmuşlardır.

Tablo 5. Katılımcıların deneyimlediği artırılmış gerçekliğe sahip uygulamanın ürüne karşı olan tutumlarını değiştirip değiştirmediği

Tema	f	Kod	f	Katılımcı Görüşleri
Olumlu	7	Gerçekçi	7	Birçok ürünü gerçekçi bulduğum için ürün bende satın alma istediği uyandırdı. (K-1, K-2, K-3, K-5, K-7, K-8, K-10)
Kararsız	2	Ne yiyeceğimi biliyorum	2	Restorana gitmeden önce ne yiyeceğimi önceden bildiğim için ürüne karşı olan tutumum değişmedi, sadece nasıl görüldüğüne baktım. (K-4, K-9)
Olumsuz	1	Porsiyon	1	Porsiyonlar gerçekçi olmadığı için ürüne karşı olan tutumum değişmedi. (K-6)

#### KATILIMCILARIN YAYGINLAŞTIRMA HAKKINDAKİ GÖRÜŞLERİ

Katılımcılara yöneltilen bir diğer soru ise, “Bu tip uygulamaların tüm restoranlarda olmasını ister miydiniz?” olmuştur. Katılımcıların %70’i tüm restoranlarda bu tarz uygulamaların olmasını isterken, %30’u istemediklerini belirtmiştir (Tablo 6).

Olumlu düşünen katılımcıların bazıları garsonların desteğinin de olmasını (f=1) istediklerini, bazıları bu yöntemin restorana daha titiz (f=1) olmaya teşvik edeceğini, bir kısmı görselle gelen ürün arasında karşılaştırma (f=2) yapma imkanının olacağını, ya da önceden ne yiyeceğini görme (f=2) avantajının olduğunu ve menülerin daha hızlı (f=1) güncellenebileceğini düşünmektedir.

Olumsuz düşünen katılımcılar ise her kafe ya da restoranda olmasına gerek olmadığını, bu tür çalışmalarda işlevselliğin (f=2) önemli olduğunu ya da ürünü görmelerine gerek olmadığını (f=1) belirtmişlerdir.

Tablo 6. Katılımcıların deneyimlediği artırılmış gerçekliğe sahip uygulamanın tüm kafe restoranlarda olmasını isteyip istememe durumu

Tema	f	Kod	f	Katılımcı Görüşleri
İsterim	7	Garsonlar bilgi verirse	1	Garsonların beni yönlendirmesi ve bilgilendirmesi noktasında desteği olursa tüm kafe ve restoranlarda bu tarz bir uygulamanın olmasını isterim. (K-3)
		Titizlik	1	Restoranların daha titiz ve özenli davranmalarına yol açacağını düşünüyorum. (K-8)
		Karşılaştırma	2	Görselle gelen ürün arasında karşılaştırma yapma olanağım olduğu için tüm restoranlarda bu tarz uygulama olmasını isterim. (K-1, K-4)
		Önceden ne yiyeceğimi görebiliyorum	2	Önceden ne yiyeceğimi görebildiğim için kafe ve restoranlarda olmasını isterim. (K-5, K-10)
		Hız	1	Menülerin bu uygulama ile daha hızlı bir şekilde güncellenebilmesi bakımından isterim. (K-2)
İstemem	3	İşlevsel	2	Her kafe ve restoranda olmasını istemem. İşe yarayacak yerlerde olmasını beklerim. Yapmak için yapılmamalı, işlevsel olmalı. (K-7, K-9)
		Ürünü görmeme gerek yok	1	Kafeye gittiğim için ürünü zaten tüketeceğim. Bu ürünü QR menüde görmeme gerek olmadığını düşünüyorum. (K-6)

### KATILIMCILARIN ESTETİK AÇIDAN GÖRÜŞLERİ

Tablo 7. Katılımcıların deneyimlediği artırılmış gerçekliğe sahip uygulamanın estetik açıdan değerlendirilmesi.

Tema	f	Kod	f	Katılımcı Görüşleri
İyi	4	Uygulama arayüzü	1	Uygulama arayüzünü estetik açıdan güzel buldum. (K-7)
		Kategorize renkler	1	Ürünlerin kategorize edilerek renklendirilmesi hoşuma gitti. (K-4)
		Gerçekçi	2	Ürünler gerçekçi görünüyor. (K-3, K-8)
Orta	6	Hız	2	Uygulama daha hızlı ve akıcı olmalı. Daha iyisi olabilir. (K-6, K-10)
		Gerçeklikten uzak	3	Bazı görseller çok gerçekçi ancak bazı görseller gerçeklikten uzak. (K-5, K-2, K-9)
		Boyut	1	Ürünün görselleri tabakta daha doğru boyutlandırılabilir. Uygulamada görülen porsiyon ile önümüze getirilecek porsiyon bire bir aynı olmalı. (K-1)

Katılımcılara yöneltilen bir diğer soru, deneyimledikleri uygulamayı estetik açıdan değerlendirmeleridir. Katılımcıların %40'si uygulamayı estetik açıdan iyi bulduğunu, uygulama arayüzü (f=1), kategorize renkleri (f=1) ve ürün görsellerinin gerçekçiliğini (f=2) beğenmiştir. Katılımcıların %60'ı ise uygulamayı estetik açıdan orta düzeyde olduğunu belirtmiştir. Daha hızlı ve akıcı olması gerektiğini (f=2), bazı görsellerin gerçeklikten uzak olduğunu (f=3) ve boyutlandırmaların daha doğru ayarlanması gerektiğini (f=1) belirtmişlerdir (Tablo 7).

### KATILIMCILARIN UYGULAMANIN EKSİKLİĞİ YÖNÜNDE GÖRÜŞLERİ

Katılımcılara yöneltilen bir diğer soru ise, deneyimledikleri artırılmış gerçekliğe sahip uygulamada eksik buldukları noktaların neler olduğudur. Katılımcıların %10'u uygulama üzerinden sipariş verilememesinin bir eksiklik olduğunu, %20'si görsellerin daha gerçekçi olması gerektiğini, %10'u arka plan görselinin daha kurumsal bir görsel olmasını, %20'si ürün çeşitliğinin az olduğunu; artması gerektiğini, %20'si yiyecek ve içecek çizimlerin gerçekçi olmadığını, %10'u ciddi sağlık problemlerine yol açmaması

için uygulama içerisinde alerjen uyarılarının olmasını gerektiğini, %10'u ise yemeklerde kullanılacak malzemelerin yazması gerektiğini belirtmiştir (Tablo 8).

Tablo 8. Katılımcıların deneyimlediği artırılmış gerçekliğe sahip uygulamada eksik buldukları noktalar

Tema	f	Katılımcı Görüşleri
Sipariş	1	Uygulama üzerinden sipariş verilebilir olmalı. (K-5)
Görseller zayıf	2	Görseller daha gerçekçi olmalı. (K-4, K-10)
Arkaplan sabit bir görsel olmalı	1	Ürünün konumlandığı yerde kafe amblemi ya da kurumsal bir görsel olmalı. (K-2)
Ürün çeşitliliği	2	Ürün çeşitliliği artırılabilir, farklı mutfaklardan yemekler sunulabilir. (K-1, K-3)
Çizimlerin iyi olmaması	2	Gelecek ürünle görseldeki çizimler birebir aynı olmalı. (K-6, K-9)
Alerjen uyarılar	1	Uygulamada yemeklerde kullanılacak malzemelere karşı insanlar uyarılabilir. Örneğin tavuğa alerjisi olan birisi o ürün içeriğini bilmeden sipariş verirse çok ciddi sağlık sorunlarıyla karşılaşabilir. (K-8)
Malzeme listesi	1	Uygulamada yemeklerde kullanılan malzemeler gösterebilir. (K-7)

### KATILIMCILARIN KULLANIM KOLAYLIĞI HAKKINDAKİ GÖRÜŞLERİ

Katılımcılara yöneltilen son soru, deneyimledikleri artırılmış gerçekliğe sahip uygulamanın kullanım kolaylığı değerlendirmeleri olmuştur. Katılımcıların hepsi mobil uygulamanın kullanımının kolay olduğunu belirtmişlerdir (Tablo 9). Katılımcılardan bazıları uygulamanın mobil (f=6) olmasını kullanışlı bulurken, bazıları arayüzünü (f=3) kullanışlı bulmuşlardır. Uygulamanın içeriğinin az olması

(f=1) da kullanımı kolaylaştıran nedenler arasında görülmüştür.

Tablo 9. Katılımcıların deneyimlediği artırılmış gerçekliğe sahip uygulamanın kullanım kolaylığı değerlendirilmesi

Tema	f	Kod	f	Katılımcı Görüşleri
Kullanımı Kolay	10	Mobil uygulama	6	Günümüzde hemen hemen herkesin akıllı telefonu olduğu için oluşturulan QR menü uygulamasını her yaştan herkes çok rahatlıkla kullanabilir. (K-1, K-3, K-4, K-6, K-7, K-8)
		Kullanıcı dostu arayüz	3	Arayüzü kullanıcı dostu modern bir görünüme sahip olduğu için herkes rahatlıkla kullanabilir. (K-2, K-9, K-10)
		İçerik az olduğundan	1	Ürün yelpazesi az olduğu için kullanımını kolay buldum. Ama ürün çeşitliliği artırıldığında ürünlerin butonlarının tüm ekranı kaplamaması için kayan menü tarzında bir tasarım düşünülebilir. (K-5)

## V. SONUÇ VE TARTIŞMA

Bu çalışmada, yemek menülerinin oluşturulması ve tasarlanmasında artırılmış gerçeklik (AG) teknolojisini kullanımlarını araştırdık. Nitel araştırma desenine sahip bu araştırmada yarı yapılandırılmış görüşme formlarıyla toplanan veriler tematik içerik analizi yöntemiyle çözümlenmiştir. Bulgular, AG teknolojisini hem müşteriler hem de işletmeler için potansiyel faydalar sağlayarak menü oluşturma ve tasarlama sürecini geliştirmede oynayabileceği önemli rolün altını çizmektedir [3]. AG teknolojisi, müşterilerin gıda tekliflerini daha iyi anlamalarını sağlamak için değerli bir araç görevi görüyor ve işletmelerin mutfak tekliflerini daha büyüleyici ve sürükleyici bir şekilde sunmalarını sağlıyor.

Araştırma ayrıca, bir artırılmış gerçeklik mobil uygulamasının tüketicilerin dikkatini ne ölçüde çektiğine ve

etkileşimi ne ölçüde teşvik ettiğine de ışık tutmuştur [15]. Teknolojik gelişmelerin ve artan pazar rekabetinin damgasını vurduğu bir çağda, işletmeler birden fazla duyuyu harekete geçirmek ve tüketicilerin ilgisini çekmek için ürünlerini yenilemek zorunda kalmaktadır [19]. Geleneksel kâğıt menülerin aksine artırılmış gerçeklik destekli mobil yazılımların entegre edilmesinin bu yönde önemli bir değişimi temsil ettiği açıktır. Uygulamayı kullanarak QR kodlarını taramak gibi basit bir işlem sayesinde kullanıcılar menü öğelerini canlı bir şekilde deneyimleyebilmekte ve gerçekçi görsel temsillere dayalı olarak daha bilinçli gıda seçimleri yapabilmektedir.

Ayrıca çalışma, artırılmış gerçeklik deneyiminin tüketicilerin karar verme süreçleri üzerinde olumlu bir etkisi olduğunu ve ürünlere yönelik tutumlarında kayda değer bir iyileşme olduğunu ortaya koymuştur [4]. Dikkat çekici bir şekilde, birçok katılımcı bu yenilikçi deneyimi arkadaşlarıyla paylaşma niyetlerini dile getirerek, istemeden de olsa işletmeler için ücretsiz ve olumlu pazarlama ve reklam çabalarına katkıda bulunmuştur. Bu tür ağızdan ağıza paylaşım, AR teknolojisini organik tanıtım faaliyetleri yaratma potansiyelinin altını çizmekte ve müşterileri yeni ve etkileşimli bir şekilde meşgul etmek isteyen işletmeler için cazibesini daha da artırmaktadır.

## KAYNAKÇA

- [1] Aguinis, H., & Solarino, A. M. (2019). Transparency and replicability in qualitative research: The case of interviews with elite informants. *Strategic Management Journal*, 40(8), 1291-1315.
- [2] Aytekin, P., Yakın, V., & Çelik, B. H. (2020). Artırılmış Gerçeklik Teknolojisinin Pazarlamadaki Yeri. *AJIT-E: Academic Journal Of Information Technology*, 10 (39), 87-117. <https://doi.org/10.5824/ajit-e.2019.4.004>.
- [3] Balasubramanian, K., & Konar, R. (2022). Moving forward with augmented reality menu: Changes in food consumption behaviour patterns. *Journal of Innovation in Hospitality and Tourism*, 11(3), 91-96.
- [4] Batat, W. (2021). How augmented reality (AR) is transforming the restaurant sector: Investigating the impact of "Le Petit Chef" on customers' dining experiences. *Technological Forecasting and Social Change*, 172, 121013.
- [5] Behzadan, A. H. (2008). ARVSCOPE: Georeferenced Visualization Of Dynamic Construction Processes in Three-Dimensional Outdoor Augmented Reality [Yayınlanmamış Doktora Tezi]. University Of Michigan.
- [6] Bilici, F., & Özdemir, E. (2019). Tüketicilerin Artırılmış Gerçeklik Teknolojilerini Kullanmaya Yönelik Tutum ve Niyeti Üzerine Bir Araştırma. *Business & Management Studies: An International Journal*, 7(5), 2011-2033. <https://doi.org/10.15295/bmij.v7i5.1252>.
- [7] Bingöl, B. (2018). Yeni Bir Yaşam Biçimi: Artırılmış Gerçeklik (AG). *Etkileşim*, (1), 44-55. <https://doi.org/10.32739/etkileşim.2018.1.8>.
- [8] Boz Yüksekdağ, B. (2021). Sağlık Profesyonellerinin Eğitiminde Artırılmış Gerçeklik Uygulamaları. *Açıköğretim Uygulamaları ve Araştırmaları Dergisi*, 7(2), 130-148. <https://doi.org/10.51948/auad.887267>.
- [9] Braun, V., & Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative research in psychology*, 3(2), 77-101.
- [10] Cankül, D., Doğan, A., & Sönmez, B. (2018). Yiyecek-İçecek İşletmelerinde İnovasyon ve Artırılmış Gerçeklik Uygulamaları. *İşletme Araştırmaları Dergisi*, 10(3), 576-591. <https://doi.org/10.20491/isarder.2018.488>.
- [11] Coşkun, C. (2017). Bir Sergileme Yöntemi Olarak Artırılmış Gerçeklik. *Sanat ve Tasarım Dergisi*, (20), 61-75. <https://doi.org/10.18603/sanatvetasarim.370723>.
- [12] Creswell, J. W., & Creswell, J. D. (2017). *Research design: Qualitative, quantitative, and mixed methods approaches*. SAGE Publications.
- [13] Creswell, J. W., & Poth, C. N. (2017). *Qualitative inquiry and research design: Choosing among five approaches*. SAGE Publications.
- [14] Denzin, N. K., & Lincoln, Y. S. (2018). *The Sage handbook of qualitative research*. SAGE Publications.

- [15] Dadwal, S. S., & Hassan, A. (2016). The augmented reality marketing: A merger of marketing and technology in tourism. In *Mobile computing and wireless networks: Concepts, methodologies, tools, and applications* (pp. 63-80). IGI Global.
- [16] Eisenberg, N., Guthrie, I. K., Cumberland, A., Murphy, B. C., Shepard, S. A., Zhou, Q., & Carlo, G. (2002). Prosocial development in early adulthood: a longitudinal study. *Journal of personality and social psychology*, 82(6), 993.
- [17] Hsieh, H. F., & Shannon, S. E. (2005). Three approaches to qualitative content analysis. *Qualitative Health Research*, 15(9), 1277-1288.
- [18] Khan, T. H., & MacEachen, E. (2022). An alternative method of interviewing: Critical reflections on videoconference interviews for qualitative data collection. *International Journal of Qualitative Methods*, 21, 16094069221090063.
- [19] Traitler, H., Coleman, B., & Hofmann, K. (2014). *Food industry design, technology and innovation*. John Wiley & Sons.
- [20] Van Krevelen, D. W. F., & Poelman, R. (2010). Augmented reality: Technologies, applications and limitations. *International Journal of Virtual Reality*, 9(2), 1-20. <https://doi.org/10.20870/ijvr.2010.9.2.2767>.
- [21] Yin, R. K. (2018). *Case study research and applications: Design and methods*. SAGE Publications.
- [22] Yüksel, D. (2017). Pazarlamada Artırılmış Gerçeklik Uygulamalarının İşlevi Üzerine Nitel Bir Araştırma, Sosyal Bilimler Enstitüsü. [Yüksek Lisans Tezi, Gazi Üniversitesi].
- [23] Willis, G. B., & Miller, K. (2011). Cross-cultural cognitive interviewing: Seeking comparability and enhancing understanding. *Field methods*, 23(4), 331-341.



**Cognitive Models and Artificial Intelligence Conference**

**26-28 October 2023, Ankara, Türkiye**

# **POSTER PAPERS**

**Published by SETSCI**

**Publication Date: October 30, 2023**



## Utilization of Evolutionary Algorithms in the Defense Industry: Optimization and Enhancement Methods

Ali Berkol<sup>\*+</sup>, İdil Gökçe Demirtaş<sup>2</sup>

<sup>1,2</sup> *Defense and Information Systems, Aselsan-Bites, Ankara, Turkey*

<sup>\*</sup> *Corresponding author: ali.berkol@yahoo.com*

<sup>+</sup> *Speaker: ali.berkol@yahoo.com*

*Presentation/Paper Type: Poster/Abstract*

**Abstract** – The defense industry stands as a critical sector with paramount importance in national security and strategic defense operations. Problems within this domain often entail multidimensional and large-scale optimization requirements. This study aims to examine the various application areas of evolutionary algorithms within the defense industry and assess how these algorithms can contribute to defense operations. Key areas of focus in this study include weapon and ammunition design, radar and sensor network optimization, logistics and resource management, cybersecurity, military simulations, and more. The utilization of evolutionary algorithms in these domains holds the potential to enhance optimization processes, reduce costs, improve efficiency, and augment the effectiveness of military operations. Furthermore, this study seeks to lay the groundwork for future research by discussing how collaboration between the defense industry and evolutionary algorithms can be strengthened and how defense operations can be better managed. The acknowledgment of evolutionary algorithms as a critical optimization tool within the defense industry suggests that this algorithmic approach may find broader applications in the future.

**Keywords** – *Evolutionary Algorithms, Defense Industry, Optimization, Military Applications, Cybersecurity*