



INTERNATIONAL CUMHURİYET
ARTIFICIAL INTELLIGENCE APPLICATIONS
CONFERENCE 2022

| 8th-9th | ONLINE |
DECEMBER

<http://caiac.cumhuriyet.edu.tr>



CONFERENCE PROCEEDINGS



CONFERENCE PROCEEDINGS

ISBN: 978-605-7902-92-4

CAIAC'22

The Proceedings of The International Cumhuriyet Artificial
Intelligence Applications Conference
2022

Edited By

Prof. Serkan AKKOYUN

Dr. Emre DELİBAŞ

Dr. Abdulkadir ŞEKER

Published

Sivas Cumhuriyet University, December 2022.

caiac@cumhuriyet.edu.tr

WELCOME TO CAIAC'22

International Cumhuriyet Artificial Intelligence Applications Conference'22 (CAIAC'22) will provide an excellent international forum for sharing knowledge and results in theory, methodology and applications of Artificial Intelligence. The Conference looks for significant contributions to all major fields of the Artificial Intelligence, Soft Computing in theoretical and practical aspects. The aim of the Conference is to provide a platform to the researchers and practitioners from both academia as well as industry to meet and share cutting-edge development in the field.

Authors are solicited to contribute to the Conference by submitting articles that illustrate research results, projects, surveying works and industrial experiences that describe significant advances in the listed areas but are not limited to.

CAIAC is organized by Sivas Cumhuriyet University Artificial Intelligence and Data Science Applications and Research Center.

Asst. Prof. Abdulkadir ŞEKER
Co-Chairs of Conference

Prof. Serkan AKKOYUN
Co-Chairs of Conference

GENERAL CO-CHAIRS

Dr. Serkan AKKOYUN
Dr. Abdulkadir ŞEKER

(Sivas Cumhuriyet University)
(Sivas Cumhuriyet University)

ORGANIZATION COMMITTEE

Dr. Ahmet Gürkan YÜKSEK
Dr. Emre DELİBAŞ
Dr. Serkan AKKOYUN
Dr. Abdulkadir ŞEKER

(Sivas Cumhuriyet University)
(Sivas Cumhuriyet University)
(Sivas Cumhuriyet University)
(Sivas Cumhuriyet University)

SCIENTIFIC COMMITTEE

Dr. Alpaslan Fırlalı
Dr. Andrew Kusiak
Dr. Bahriye Akay
Dr. Banu Diri
Dr. Celal Öztürk
Dr. Çetin Elmas
Dr. Çiğdem Erol
Dr. Ecir Uğur Küçükşille
Dr. Emre Dandil
Dr. Emre Delibaş
Dr. Emre Ünsal
Dr. Eyüp Çalık
Dr. Ferdi Sönmez
Dr. Ferhat Sayım
Dr. Feriştah Dalkılıç
Dr. Fırat İsmailoğlu
Dr. Güzin Ulutaş
Dr. Haldun Akpınar
Dr. Harun Uğuz
Dr. Hidayet Takçı
Dr. İhsan Hakan Selvi
Dr. Konstantin P. Katin
Dr. Kali Gürkahraman
Dr. Manafəddin Namazov
Dr. Mehmet Ali Alan
Dr. Mehmet Göktürk
Dr. Metin Zontul
Dr. Metin Saygılı
Dr. Muhammed Kürşad UÇAR
Dr. Murat Şeker
Dr. Naveed Muhammad
Dr. Oğuz Kaynar
Dr. Osman Nuri Şahin
Dr. Özlem Polat
Dr. Rukiye Karakış
Dr. Selçuk Ökdem
Dr. Süleyman Eken
Dr. Şaban Gülcü
Dr. Şadi Evren Şeker
Dr. Vasıf Nabiyev

(Kocaeli University)
(The University of Iowa)
(Erciyes University)
(Yıldız Technical University)
(Erciyes University)
(Azerbaijan Technical University)
(Istanbul University)
(Süleyman Demirel University)
(Bilecik Seyh Edebali University)
(Sivas Cumhuriyet University)
(Sivas Cumhuriyet University)
(Yalova University)
(Fenerbahçe University)
(Yalova University)
(Ege University)
(Sivas Cumhuriyet University)
(Karadeniz Technical University)
(Marmara University)
(Konya Technical University)
(Sivas Cumhuriyet University)
(Sakarya University)
(National Research Nuclear University MEPhI)
(Sivas Cumhuriyet University)
(Baku Engineering University)
(Sivas Cumhuriyet University)
(Gebze Technical University)
(İstanbul Arel University)
(Sakarya University of Applied Sciences)
(Sakarya University)
(Gebze Technical University)
(University of Tartu)
(Sivas Cumhuriyet University)
(Alanya Alaaddin Keykubat University)
(Sivas Cumhuriyet University)
(Sivas Cumhuriyet University)
(Erciyes University)
(Kocaeli University)
(Necmettin Erbakan University)
(Antalya Bilim University)
(Karadeniz Technical University)

Dr. Veysel Yücesoy	(ASELSAN)
Dr. Volkan Göreke	(Sivas Cumhuriyet University)
Dr. Yasin Görmez	(Sivas Cumhuriyet University)
Dr. Yılmaz Atay	(Gazi University)
Dr. Yunus Doğan	(Ege University)
Dr. Yunus Torun	(Sivas Cumhuriyet University)
Dr. Yusuf Sinan Akgül	(Gebze Technical University)

KEYNOTE SPEAKERS

Betül Kübra Ekinci	(TRAI)
<i>“Türkiye’de Yapay Zeka Ekosistemi ve Ekosistem Oluşturmak”</i>	
Prof. Ayşegül Alaybeyoğlu	(İzmir Katip Çelebi University)
<i>“Tarımda Yapay Zeka”</i>	
Prof. Metin Zontul	(Sivas University of Science and Technology)
<i>“Metaverse Nereye Koşuyor?”</i>	
Osman Nuri Hömek	(Republic of Turkey Ministry of Justice)
<i>“Yapay Zeka Ne Değildir?”</i>	



INTERNATIONAL CUMHURİYET
ARTIFICIAL INTELLIGENCE APPLICATIONS
CONFERENCE 2022

| 8th-9th | ONLINE |
DECEMBER
<http://caiac.cumhuriyet.edu.tr>

Organized by



Sponsored by



PLATIN SPONSOR



GOLD SPONSORS

CONTENTS

Türkçe Faturaların Dijitalleştirilmesi Sürecinde Açık Kaynak Kodlu Optik Karakter Tanımlama Kütüphanelerinin Karşılaştırılması <i>Merve Sağlık, Mehmet Zahit Kaya, Yunus Emre Işık and Halil Arslan</i>	1-5
Yapay Zekâ Temelinde Etik Sorunsalı <i>Çağrı Yardımcı</i>	6-8
Turkish people's Opinions and Feelings Towards TOGG Cars <i>Numan Çelebi and Abdalrhman Alquaary</i>	9-13
Dijital Dönüşümlere Dayanan Katalog Sistemleri <i>Sercan Tomaç, Mustafa Temiz and Halil Arslan</i>	14-17
S-Factor Estimations at Low energies by Using Artifical Neural Network <i>Eda Paşayığıt, Serkan Akkoyun and Gökhan Koçak</i>	18-20
Recent Progresses of Heart Attack Prediction in Machine Learning <i>Burcu Bilgin and Nevcihan Duru</i>	21-25
A Performance Comparison of Deep Embedded Clustering Methods on IoT Time Series Data <i>Ezgi Zorarpacı</i>	26-30
İnsan Vücudu Termal Görüntülerinin U-Net ile Segmentasyonu <i>Mahmut Çevik, Melike Gökdemir, Ahmet Bayrak and Murat Ceylan</i>	31-34
Mermer Sınıflandırma Problemi İçin Güvenilir Veri Seti Oluşturulması <i>Burak Seçkin, Yunis Torun and Rukiye Karakış</i>	35-38
Derin Öğrenme Tabanlı Güç Yükselteç Modülü Kazanç Kalibrasyonu <i>Ahmet Buğra Uğur and Özgür Ergül</i>	39-43
Network Lifetime Maximization in Smart Farming by using an Improved Ant Colony Optimization Algorithm and Solar Energy Harvesting <i>Sara Khernane, Souheila Bouam and Chafik Arar</i>	44-46
Analysis of Flight Based Airport Passenger Arrival Patterns <i>Gözde M. Sayın and Mustafa Bolat</i>	47-50
Diagnosing Melanoma Cancer Using Deep Learning <i>Seda Büşra Bakır, Ali Kılıç and Sadettin Kapucu</i>	51-56
Classification Accuracy and Discrimination Performance of a Novel Abstract Vector Model for Face Recognition and Clustering <i>Mehmet Cemal Atlıoğlu and Gözde M. Sayın</i>	57-60
Categorical and Binary Brain Tumor Classification Using Transfer Learning Techniques <i>Ayşe Gül Eker, Gamze Korkmaz Erdem and Nevcihan Duru</i>	61-65
Malicious file detection based on textual analysis of Windows portable executable file header information <i>Hidayet Takçı and Rabia Doğan</i>	66-71
Deep learning-based super resolution applications on thermal images for different upscaling factors <i>Fatih Mehmet Senalp and Murat Ceylan</i>	72-75
Forecasting of Terminal Voltage of Li-FePO₄ Batteries in the Context of Dynamic Current Profile Using Machine Learning and Artificial Intelligence: Decision Tree Algorithm and Artificial Bee Colony Algorithm <i>Taner Çarkıt and Sümeyye Çarkıt</i>	76-80

Straights And Potential Threats Of Metaverse And Solution Suggestions <i>Olexandra Kalinska</i>	81-84
A New Lightweight Artificial Intelligence Approach: Detecting RPL Attacks in ANN and Blockchain Based Topology in Artillery <i>Ali Deveci</i>	85-89
Control of PMSG based variable speed wind energy conversion system connected to the grid with Nonlinear Backstepping Control <i>Mahgoun Mohamed Seddik</i>	90-96
Estimating a City's Electrical Load Demand with Long Short Term Memory <i>Gülay Yıldız Doğan and Nursel Öztürk</i>	97-99
Yapısal Tasarımda Yapay Sinir Ağları Yaklaşımı ile Analiz Tahminleri <i>Mustafa Kerem Özder, Emre İsa Albak and Ferruh Öztürk</i>	100-104
Kampüs İçi Kapalı Alanlarda Hava Kalitesinin Tahmin Edilmesi <i>Elif Cesur, Muhammet Raşit Cesur and Cemal Efe</i>	105-109
The Effects of Artificial Intelligence Studies in Health as a Biopolitics Tool <i>Azize Serap Tunçer</i>	110-112
Elektrik Dağıtım Şebekelerinde Arıza Tespitinde Yapay Zekâ Kullanımı <i>Eren Diler, Yunis Torun, Ahmet Uyaroğlu, İrem Şimşek and Tayfun Tural</i>	113-116
Gıda Üretim Alanlarında İnsanların Eldiven ve Maske Kullanımının Yapay Zekâ ile Tespiti <i>Aslı Sesli, Seda Arslan Tuncer and Serkan Karakuş</i>	117-120
Elektronik Kişilik: Hak vs Yükümlülük <i>Mustafa Kenan Ustahaliloğlu</i>	121-124
Anne Sağlık Durumu Riskinin Makine Öğrenmesi Yöntemleri ile Belirlenmesi <i>Mahmut Tokmak</i>	125-128
Location of Distributed Generation in DC Microgrids <i>Tuncay Altun</i>	129-130
DC Şebekelerin Optimizasyonun Hesaplama Sürelerinin Derin Öğrenme Metotları ile Azaltılması <i>Kadriye Başar, Kenan Altun and İdris Zorlutuna</i>	131-132
Yapay Zekânın Uluslararası İlişkilere Etkileri <i>Ranuna İklime Gün Altun</i>	133-136
Stock Trend Prediction and Portfolio Optimization <i>Deniz Pekşen and Okan Orsan Özener</i>	137
Estimation of fission barrier heights for even-even superheavy nuclei using random forest machine learning algorithm <i>Cafer Mert Yeşilkanat and Serkan Akkoyun</i>	138
Endüstriyel Tasarımlarda Yapay Zekanın Etkisi ve Geleceği <i>Münevver Yakut, Emine Bozkuş</i>	139

Türkçe Faturaların Dijitalleştirilmesi Sürecinde Açık Kaynak Kodlu Optik Karakter Tanımlama Kütüphanelerinin Karşılaştırılması

Merve SAĞLIK

Detay Teknoloji Yazılım Danışmanlık
Ve Bil. Hiz.Tic.San. A.Ş.
Sivas, Türkiye
merve.sakarya@detaysoft.com

Mehmet Zahit KAYA

Detay Teknoloji Yazılım Danışmanlık
Ve Bil. Hiz.Tic.San. A.Ş.
Sivas, Türkiye
zahit.kaya@detaysoft.com

Yunus Emre IŞIK

Yönetim Bilişim Sistemleri Bölümü
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
yeisik@cumhuriyet.edu.tr

Halil ARSLAN

Bilgisayar Mühendisliği Bölümü
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
harslan@cumhuriyet.edu.tr

Abstract— The spread of technological opportunities in recent years has enabled institutions and companies to digitize their processes. The electronic processing of invoices is one of these digitization processes. However, since some of the invoices could be in printed form, the invoice information must be transferred to the electronic environment in some way. This study includes some research on the text recognition sub-process, which is part of our end-to-end invoice digitization project. In order to transfer the text contained in invoices to the electronic environment as successfully as possible, 4 different optical character recognition libraries commonly used in the literature were comparatively applied to invoice images and it was shown how successfully the parts containing key information were predicted. In addition, an approach using XML and data augmentation techniques is proposed to generate synthetic invoices. As a result of the analysis, Tesseract OCR and Paddle OCR were determined to be the most successful libraries for digitizing alphabetic and numeric information, respectively. Furthermore, the analysis was performed on both the CPU and GPU to provide comparative runtimes of the algorithms. It is hoped that the results obtained will be useful to researchers working on digitizing documents such as invoices, etc.

Keywords—optical character recognition, invoice processing, data augmentation

Özet— Son yıllardaki teknolojik imkanların yayılması kurum ve firmaların da süreçlerinin dijitalleştirilmesine imkân tanımaktadır. Fatura süreçlerinin elektronik ortamda yürütülebilmesi de bu dijitalleştirme süreçlerindendir. Ancak faturaların bir kısmının matbu formda olması nedeniyle fatura bilgilerin bir şekilde elektronik ortama aktarılması ihtiyacı doğurmuştur. Çalışmamız bu ihtiyacı çözmeye yönelik olarak geliştirdiğimiz projenin metin dijitalleştirme süreciyle ilgili kısmına ait bazı analizleri içermektedir. Faturaların içerdiği metinlerin en başarılı şekilde elektronik ortama aktarılabilmesi için sektörde sık kullanılan 4 farklı optik karakter tanımlama kütüphanesi karşılaştırılmalı şekilde fatura resimleri üzerine uygulanarak, önemli bilgi içeren alanların ne derece başarılı tahmin edildiği ortaya koyulmuştur. Bununla beraber sentetik fatura üretilebilmesi için de XML ve veri çoğaltma tekniği kullanılarak bir yaklaşım önerilmiştir. Yapılan analizler sonucunda alfabetik bilgilerin dijitalleştirilmesinde en başarılı kütüphanenin Tesseract OCR, sayıların dijitalleştirilmesinde ise Paddle OCR olduğu ortaya çıkartılmıştır. Ayrıca hem

işlemci hem de grafik hızlandırıcı üzerinde yapılan analizlerle sonucunda çalışma süreleri de karşılaştırılmalı olarak paylaşılmıştır. Elde edilen sonuçların fatura vb. gibi doküman dijitalleştirme süreçlerinde çalışacak araştırmacılara faydalı olması umulmaktadır.

Anahtar kelimeler—optik karakter tanımlama, fatura okuma, veri çoğaltma

I. Giriş

Teknolojik gelişmeler hem kamu hem de özel sektörde dijitalleştirme süreçlerini hızlandırmaktadır [1]. İhtiyaçların çözümü, işlerin hızlandırılması ve maliyetlerin düşürülmesi açısından önerilen teknolojik çözüm ve dijitalleştirme süreçleri ortaya çıkan insan hatasını da en aza indirmektedir. Özellikle yapay zekâ temelli sistemlerin yaygınlaşarak var olan kurum uygulamalarına hızlıca entegre edilebilmesi kurum personellerinin birçok ihtiyacını kolaylaştırmaktadır. Bu ihtiyaçlardan birisi de elektronik olmayan faturaların kurum sistemlerine girilmesidir [2].

Faturalar genellikle benzer mali ve ödeme bilgilerini içeren ancak farklı görsel yapılar da sahip olabilecek dokümanlar olarak ifade edilebilir. Son kullanıcılar açısından bu belgeler çok fazla anlam ifade etmese de kurumlar adına kesilen faturalar finansal tutarlılık ve muhasebe süreçleri açısından önemlidir. Ancak her bir faturanın tek tek sisteme girilmesi de personel ve süre açısından maliyet doğurmaktadır. Bu ihtiyacın giderilmesi için fatura formatına uygun tarayıcı makineler ile bilgi çıkarımı yapılsa da formatta olabilecek ufak bir değişiklik bile sistemde arızaya neden olabilmektedir.

Diğer bir çözüm ise faturanın çeşitli yapay zekâ temelli yöntemler ile okunarak dijitalleştirilmesidir. Böylelikle herhangi bir insan müdahalesine gerek kalmadan fatura içerisinde yer alan metinler bilgisayar ortamına aktarılabilir. Bu sürecin ilk adımı ise faturaların optik karakter tanımlama yöntemleriyle içerdiği metnin dijital ortama aktarılmasıdır. Bu aşamada optik karakter tanımlama kütüphaneleri devreye girmektedir.

Literatür incelendiği zaman optik karakter tanımlama yöntemleri çok farklı alanlara uygulanarak süreçlerin dijitalleştirilmesine yardımcı olmuştur. Zhang vd., raylı

sistemlerde yer alan hat deęiřtirme operasyonlarının otomatik olarak yapılabilmesi için OCR temelli bir sistem önermişlerdir. Belirli bir yapıya sahip dokümandan sisteme elle eklenen bilgiler için önce optik karakter tanımlama, daha sonra konum belirleme yapılarak dijitalleştirme işlemi gerçekleştirilmiştir. Ayrıca çalışma içerisinde EasyOCR ve Paddle OCR kütüphaneleri karşılaştırılarak, Paddle OCR'in %83 tahmin performansı ile daha başarılı olduğu belirtilmiştir [3].

Lertsawatwicha vd. ise depoda yer alan ürünleri stok miktarlarının belirlenmesinde optik karakter tanımlama temelli bir sistem önermişlerdir. Sistem üretilen ürünlerin üzerine yapıştırılan parti numaralarını Tesseract OCR ile okumakta ve ürün stoęunu hesaplamaktadır. Yapılan testler sonucunda Tesseract OCR'in %91.82 oranında başarıyla stok numaralarını doğru tahmin edildięi belirtilmiştir [4]. Dięer bir çalışmada resim içerisinde yer alan yazının farklı dillere çevrilmesi için Tesseract OCR temelli bir web arayüzü önerilmiştir. Resmi çekilen resim önce Tesseract OCR ile okunmuş daha sonra Google servisleri kullanılarak farklı dillere çevrilmiştir [5].

Seokwoen vd., medikal dokümanda yer alan tablo şeklinde verileri optik karakter tanımlama ile okuyarak web arayüzünde kullanıcılara sunmuşlardır. Geliştirilen sistem hastalar hakkında not alınmasını kolaylaştırması yanı sıra takip işlemlerini de hızlandırmıştır [6].

Bu çalışmamız ise farklı optik karakter tanımlama kütüphanelerinin özellikle Türkçe faturalar üzerinde ne derece doğru tahmin başarısı elde ettięini karşılařtırmalı olarak sunmaktadır. Kullanılan kütüphanelerin fatura içerisindeki 6 farklı alanda ne kadar başarılı tahmin yaptığı ayrı ayrı hesaplanarak raporlanmıştır. Kütüphaneler sadece gerçek veriler üzerinde deęil, herhangi bir gürültü içermeyen temiz ve sentetik gürültü eklenmiş fatura resimleri üzerine de uygulanarak farklı durumlarda başarımın ne kadar deęiřtięi ortaya çıkartılmıştır. Bunun yanı sıra kütüphanelerin hem işlemci hem de grafik hızlandırıcı üzerindeki çalışma süreleri de karşılaştırılarak her açıdan optimum algoritma belirlenmeye çalışılmıştır.

II. OPTİK KARAKTER TANIMLAMA KÜTÜPHANELERİ

A. Tesseract OCR

İlk olarak 1984-1994 arasında HP tarafından geliştirilen ve 2005 yılında açık kaynak kodlu olarak yayınlanmıştır. Daha sonra Google tarafından desteklenen kütüphane 100'den fazla farklı dil ve birçok yazı tipini desteklemektedir. İçerisinde yerleşim analizi ve bağlantılı bileşen analizi gibi modüller içeren kütüphane, yalnızca yatay deęil dikey olarak hizalanmış resimlerde yer alan metinleri de çıkartabilmektedir. 4. nesin sürümüyle beraber doğruluęu arttırmak için uzun-kısa süreli bellek (Long-short Term Memory, LSTM) temelli mimariye geçilmiş ve uzun metinlerin tahmin başarısı oldukça artırılmıştır. Bunların yanı sıra eldeki verilerle eğitim ve yeni karakter ekleme gibi özellikler de kullanıcılara sunulmaktadır[7].

B. EasyOCR

Easy OCR resim içerisinde metin bulan ve bulunan metni dijitalleřtiren dięer bir uçtan uca optik karakter tanımlama kütüphanesidir [8]. Mimari olarak metin tanımlama da derin öğrenme tabanlı CRAFT [9] yapısının kullanıldığı kütüphane, CRNN ve LSTM yaklaşımının kullanıldığı bir karakter

tanımlama yapısıyla birlikte çalışmaktadır. Tesseract OCR sistemine benzer şekilde Türkçe dahil olmak üzere birçok dil için hazır eğitilmiş modellerin sağlanmasına rağmen, Türkçe modelinin dięerlerine göre başarımının düşük olduęu söylenebilir.

C. Paddle OCR

Paddle OCR içerisinde metin alanı algılama, metin tanımlama, tablo tanımlama, anahtar bilgi çıkarımı ve düzen analizi gibi belge analizinde ihtiyaç duyulabilecek birçok modül içeren gelişmiş bir optik karakter tanımlama kütüphanesidir [10]. Kütüphane varsayılan olarak öncelikle doküman içerisindeki metinleri segmentasyon bazlı algoritmayla belirlemekte ve adaptif olarak segmentler içerisinde yer alan metinleri CRNN algoritmasıyla dijitalleřtirmektedir. Ek olarak EAST, DB gibi doküman içinde metin belirleme ve SRN, ABINet gibi farklı optik karakter tanımlama algoritmaları da parametrik olarak seçilebilmektedir. Kütüphane çoklu dil desteęi sağlamasına rağmen, her bir dil için özel eğitilmiş modelleri sunmamaktadır. Ancak buna rağmen Türkçeye özel karakterler hariç tahmin başarısı oldukça yüksektir.

D. DocTR

DocTR, Paddle OCR'a benzer şekilde literatürde yer alan farklı derin öğrenme tabanlı optik karakter tanımlama algoritmalarının tek bir paket halinde sunulduęu dięer bir kütüphane. Dahili metin belirleme kütüphanesi sayesinde öncelikle doküman içerisindeki metnin yeri belirlenmekte ve daha sonra seçilen optik karakter tanımlama algoritmasıyla metin dijitalleřtirilmektedir. Hem Tensorflow hem de Torch motorlarıyla çalışabilen kütüphane farklı diller için eğitilmiş özel modelleri içermemektedir [11].

III. VERİ SETİ

A. Sentetik Veri Oluřturma

Resim üzerinde yapay zekâ bazlı sistemler ile analizlerin başarısını etkileyen önemli faktörlerden birisi veri çeřitlilięidir. Veri çeřitlilięi arttıkça tahmin modellerinin canlı veri analizlerinde nasıl tepki vereceęi ya da başka bir deyişle ne kadar dayanıklı algoritma (robust) olduęu daha iyi ölçülebilmektedir. Çalışmamız içerisinde de birçok farklı elde edilmiş (resim, tarama ve dijital) gerçek fatura örneğine yer verilmiştir. Ancak optik karakter tanımlama algoritmalarının her duruma karşı nasıl sonuç verdięinin daha iyi anlaşılabilmesi için gerçek verilerin yanı sıra sentetik faturalar da üretilmiştir.

Sentetik faturalar gerçeęe benzer fakat rastgele üretilen deęerlerle oluřturulan veriler olarak tanımlanabilir. Örneęin fatura numarası G ile bařlayan ve devamında 16 hane sayı içeren bir alandır. Dolayısıyla bu alanı rastgele sayılar kullanarak üretmek kolaydır. Üretim için öncelikle hangi alanların deęiřtirileceęi belirlenmiştir. Çalışmamız içerisinde farklı optik karakter tanımlama algoritmalarının başarıları sırasıyla fatura sahibi, vergi kimlik numarası, fatura numarası, belgeye ait eşsiz numara (ETTN), toplam tutar ve tarih olmak üzere 6 farklı alanın ne derecede doğru tahmin edildięiyle ölçülmüştür. Bu sebeple sentetik veri üretme esnasında bu alanlar internetten indirilen açık veriler kullanılarak rastgele doldurulmuştur.

Metin halinde oluşturulan sentetik verilerin fatura görünümüne dönüştürülebilmesi için ise XML temelli bir yaklaşım önerilmiştir. Python LXML [12] kütüphanesi kullanılarak metin veriler daha önceden belirlenmiş bir XML formatındaki fatura şablonu içerisinde doldurulmuştur. Daha sonra XML veri sırasıyla önce HTML ve daha sonra da resim formatına dönüştürülmüştür. Bu şekilde istenildiği kadar sentetik fatura elde edilebilmektedir. Fakat sentetik olarak elde edilen resimler herhangi bir gürültü (tuz-biber gürültüsü, yamukluk, parlaklık vs.) içermediği için optik karakter tanımlama algoritmalarının yüksek başarı vermesi normal olacaktır.

TABLE I. IMG AUG KÜTÜPHANESİ İLE EKLENEN GÜRÜLTÜLER VE EKLEME İHTİMLERİ

Gürültü Türü	İhtimal	Gürültü Türleri
Bulanıklaştırma	%60	Gauss, Sıkıştırma, Ortalama
Piksel Bozma	%30	Tuz-Biber, Dürtü
Contrast Değiştirme	%30	Gamma, Karıştırma, Parlaklık
Kırpa	%15	Resmin Rastgele kırılması
Dönüştürme	%40	İlgin dönüştürme, Genişletme, Ölçeklendirme
Yamultma	%13	Perspektif değişimi
Döndürme	%20	Eksen etrafında döndürme

Algoritmaların gürültülü faturalar üzerindeki başarımının incelenmesi için ise veri çoğaltma tekniklerinden yararlanılmıştır. Python ImgAug [13] resimler üzerine çok çeşitli gürültü ekleyerek veri çoğaltmaya imkân tanıyan kütüphanelerdendir. Çalışmamızda sentetik olarak oluşturulan faturalara bu kütüphane kullanılarak gürültü eklenmiş ve gürültülü halleri kayıt altına alınmıştır. Eklenen gürültülere ait bilgileri tablo 1’te paylaşılmıştır.




Fig. 1. Sentetik olarak oluşturulmuş Gürültüsüz / Gürültülü Fatura Örnekleri

Sentetik veri üretme işlemiyle beraber 150 tanesi gürültülü, 150 tanesi ise gürültüsüz olmak üzere 300 adet fatura üretilerek işaretlenmiştir. Üretilen faturalara ait örnekler figür 1’de gösterildiği gibidir. Görüldüğü gibi imgAug ile veri üzerine gürültü eklenmesi, faturaya gerçek bir fotoğraftan çekilmiş gibi tesir etmiştir.

B. Gerçek Fatura Verileri

Çalışmamızda sentetik verilerin dışında Detaysoft firmasının müşterilerinden toplanan faturalarda kullanılmıştır. Bu faturalar genellikle taranmış resimlerden oluşsa da bazıları telefonla çekilmiş resim formatındadır.

Ayrıca gerçek faturalar içerisinde kaşe, imza veya boş kısımlara yazılmış ufak tefek notlarda bulunmaktadır. Farklı firmalardan toplam 131 fatura toplanarak analizler için hazır hale getirilmiştir. Her bir fatura LabelImg [14] uygulaması kullanılarak elle tek tek işaretlenmiştir ve etiket bilgileri saklanmıştır.

IV. UYGULAMA

Çalışmamız temel olarak uçtan uca fatura dijitalleştirme içeren projemizin optik karakter tanımlama süreçleriyle ilgili bir kısmını içerir. Hangi optik karakter tanımlama kütüphanesinin özellikle Türkçe faturalar üzerinde daha iyi sonuç verdiğini belirlemek, sistemin genel başarısı açısından da önemli olacaktır. Bu sebeple hem gerçek hem de sentetik olarak üretilen faturalar üzerinde farklı optik karakter tanımlama kütüphanelerinin ne kadar başarılı olduğunu karşılaştırılmalı olarak ortaya çıkarılmıştır. Test süreçlerinde 4 farklı algorithmadan yararlanılmıştır. Bunlar Paddle OCR, Easy OCR, DocTR ve Tesseract OCR kütüphaneleridir. Bunların dışında her ne kadar AWS Cloud OCR [15] ve Google Cloud OCR [16] gibi çözümler bulunsada bu ürünler hem ücretli hem de KVKK kurallarına aykırı olması nedeniyle çalışmamızda yer almamaktadır.




Fig. 2. Sistem Genel Mimarisi

Figür 2 çalışmamıza ait genel iş akış mimarisini göstermektedir. Müşterilerden toplanan ve bölüm 3a’da anlatıldığı gibi XML bir yapı kullanılarak oluşturulan sentetik veriler 4 farklı optik karakter tanımlama kütüphanesiyle dijitalleştirilmiştir. Daha sonra dijitalleştirilen metinler içerisinde faturalar için önem arz eden 6 farklı alanın doğru olup olmadığı kontrol edilmiştir. Bu alanlar sırasıyla fatura sahibi, vergi kimlik numarası, fatura numarası, belgeye ait eşsiz numara (ETTN), toplam tutar ve fatura tarihidir. Fatura sahibi ve ETTN numarası alfabetik karakterler içerirken diğer alanlar sadece sayılardan oluşmaktadır. Eğer ilgili alan dijitalleştirilen fatura metni içerisinde geçiyorsa kütüphanenin ilgili alanı doğru tahmin ettiği kabul edilmiştir.

Ancak ilgili kütüphanelerden tam anlamıyla Türkçe karakter desteği sadece Tesseract OCR kütüphanesinde bulunmaktadır. Diğer kütüphaneler ise “latin-1” dil ailesine destek vermesin rağmen bazı Türkçeye özgü karakterleri

(“Ğ” gibi) tanımlayamamaktadır. Buna rağmen tüm algoritmaların teknik temeli derin öğrenme modellerine bağlı olduğu için, Türkçe karakterleri bulamaması bile bu karakterleri en benzer karakter olarak tahmin etmektedirler. Örneğin “Ğ” karakteri “G”, “İ” karakteri “I” olarak dijitalleştirilmektedir.

Bu nedenle algoritmaların eşit bir şekilde karşılaştırılabilmesi için Türkçe karakterlerin İngilizceye çevrildiği (örneğin “Ğ” = “G”) verilerin başarıları raporlanarak tablolarda verilmiştir.

Diğer taraftan kütüphanelerin kullanışlılığını gösteren bir diğer önemli hususta çalışma süreleridir. Algoritmanın çok yüksek başarı vermesinin yanı sıra hızlı bir şekilde çalışıp sonuç üretmesi hem maliyet hem de zaman kazanımı açısından elzemdir. Her algoritmanın ortalama olarak bir faturayı kaç saniyede işlediği de kayıt altına alınarak paylaşılmıştır. Ayrıca derin öğrenme modellerinin CUDA desteğiyle çok daha hızlı çalıştığı da bilinmektedir. Kullandığımız kütüphanelerden Easy OCR ve Paddle OCR’in CUDA desteği bulunduğu için, bu kütüphanelerin testleri ayrıyeten grafik hızlandırıcı ile de denenerek raporlanmıştır. Uygulama sırasında yapılan deneylerin tamamı 16gb RAM, i7-7700k işlemci ve GTX 1050 Ti ekran kartlı donanıma sahip, Ubuntu işletim sistemli bilgisayar üzerinde gerçekleştirilmiştir.

V. SONUÇLAR

Test işlemleri sonucunda her kütüphanenin farklı alanlar için aldığı başarımlar sonuçları tablo 2’de gösterildiği gibidir. “Firma Adı” alanının hem Türkçe karakter hem de İngilizceye dönüştürülmüş karakterlerinden elde edilen sonuçları ayrı ayrı paylaşılmaktadır. Diğer alanlarda Türkçe karakter olmadığı için herhangi bir değişiklik gözlemlenmemiştir.

TABLE II. TEST SONUÇLARINA AIT BAŞARIM DEĞERLERİ

Model	Veri	Firma Adı		ETTN	Fatura Nu.	Toplam Tutar	Tarih	VKN
		TR	EN					
Tesseract OCR	Sen.	0,71	0,73	0,01	0,00	0,04	0,39	0,65
	Gür.	0,27	0,27	0,02	0,00	0,02	0,14	0,35
	Ger.	0,53	0,53	0,44	0,15	0,33	0,71	0,89
DocTR	Sen.	0,04	0,74	0,26	0,82	1,00	0,96	0,64
	Gür.	0,03	0,03	0,02	0,50	0,76	0,76	0,65
	Ger.	0,03	0,43	0,00	0,90	0,95	0,96	0,89
Paddle OCR	Sen.	0,05	0,66	0,96	1,00	1,00	0,94	0,76
	Gür.	0,05	0,27	0,67	0,60	0,71	0,77	0,70
	Ger.	0,02	0,34	0,86	0,85	0,87	0,98	0,98
Easy OCR	Sen.	0,19	0,54	0,25	1,00	0,56	0,94	0,76
	Gür.	0,05	0,18	0,05	0,17	0,19	0,35	0,38
	Ger.	0,17	0,28	0,40	0,62	0,88	0,86	0,95

Sonuçlara detaylı bakıldığında zaman ilk göze çarpan durum alfabetik karakter içeren alanların genellikle çok düşük başarımla tahmin edilmesidir. Örneğin Easy OCR kütüphanesi, sentetik veriler içerisinde Firma adını %19’luk bir başarıyla doğru tahmin edebilmiştir. Türkçe karakterler

dönüştürüldüğü zaman ise bu başarımlar %54’e yükselmiştir. Benzer durum hem Paddle OCR hem de DocTR için söz konusudur. Ortaya çıkan değişimin ana sebebi daha önceden de belirtildiği gibi bu kütüphanelerin Türkçe karakterleri doğru tahmin edememesidir. Öte yandan Türkçe karakter modeli sağlayan Tesseract OCR ise “Firma Adı” alanında yüksek başarımlar elde etmiştir.

Hem sayı hem de alfabetik karakter içeren “ETTN” numarası için Paddle OCR kütüphanesinin oldukça yüksek bir başarımla söz konusudur. Benzer başarı “Tutar”, “Tarih”, “VKN” alanları içinde geçerlidir. Kütüphanelerin varsayılan modellerinde sayı tahmin başarısının yüksek olduğu sonucuna varılabilir.

Analizler sonucunda elde edilen diğer bir bulgu ise sentetik veri çoğaltma algoritmalarının gerçeğe yakın bir üretim yapmadığıdır. Görüldüğü üzere alanların neredeyse tamamında gerçek faturalar, veri çoğaltma teknikleri kullanılarak bozulan faturalardan çok daha yüksek başarımlarda tahmin edilebilmiştir. Dolayısıyla faturalarda sentetik gürültülerin, gerçek gürültüler yerine kullanılamayacağı yorumu yapılabilir.

Tablo 3’de her bir kütüphanenin hem işlemci hem de grafik hızlandırıcı üzerindeki çalışma sürelerini saniye cinsinden gösterilmektedir.

TABLE III. ALGORİTMALARA AIT ÇALIŞMA SÜRELERİ

MODEL	Gerçek		Sentetik		S. Gürültülü	
	CUDA	CPU	CUDA	CPU	CUDA	CPU
Tesseract OCR	-	4.47	-	3.78	-	2.41
DocTR	-	18.14	-	22.95	-	24.58
Paddle OCR	1.77	12.50	2.98	20.50	2.15	19.66
Easy OCR	14.48	59.15	4.96	21.76	5.61	22.51

İşlemci üzerinde çalışan kütüphaneler karşılaştırıldığı zaman Tesseract OCR’in açık ara çok daha hızlı sonuç ürettiği belirgindir. Öte yandan en yavaş kütüphane ise Easy OCR kütüphanesidir. Ancak grafik hızlandırıcılar devreye girdiği zaman Paddle OCR kütüphanesinin neredeyse 10 kat daha hızlı çalıştığı söylenebilir. Özellikle canlı sistem uygulamalarında sistemin zaman aşımına düşmemesi açısından Paddle OCR ve Tesseract OCR kütüphanelerinin kullanılması daha mantıklı olacaktır. Elde edilen sonuçların fatura vb. gibi doküman dijitalleştirme süreçlerinde çalışacak araştırmacılara faydalı olması umulmaktadır.

İleriki çalışmalar hem başarımlar hem de çalışma süresi açısından en iyi model olan Paddle OCR kütüphanesinin gerçek verilerle eğitilerek model başarımlarının daha da artırılmasını ve uçtan uca bir sistem içerisinde servis olarak nasıl çalıştırılabileceğinin üzerine olacaktır.

VI. TEŞEKKÜR

Bu çalışma, Detaysoft Ar-Ge Merkez bünyesinde yürütülen çalışmaların sonucudur. Desteklerinden dolayı Detaysoft Ar-Ge Merkezine teşekkür ederiz. Bu çalışmada rapor edilen sayısal hesaplamaların bir kısmı TÜBİTAK ULAKBİM Yüksek Başarımlı ve Grid Hesaplama Merkezi (TRUBA)’da gerçekleştirilmiştir.

REFERENCES

- [1] G. Telli vd., *Dijital dönüşüm*. TC Maltepe Üniversitesi, 2020.
- [2] B. Koch, *Implementing e-invoicing on a broad scale*. Billentis, 2015.
- [3] B. Zhang vd., “Method of railway shunting operation sheet information extraction guided by table header”, *IET Intell. Transp. Syst.*, 2022.
- [4] P. Lertsawatwicha, P. Phathong, N. Tantasane, K. Sarawutthinun, ve T. Siriborvornratanakul, “A novel stock counting system for detecting lot numbers using Tesseract OCR”, *Int. J. Inf. Technol.*, ss. 1-6, 2022.
- [5] S. Thakare, A. Kamble, V. Thengne, ve U. R. Kamble, “Document Segmentation and Language Translation Using Tesseract-OCR”, içinde *2018 IEEE 13th International Conference on Industrial and Information Systems (ICIIS)*, 2018, ss. 148-151.
- [6] S. Jung, K. Choe, S. Park, H.-K. Ko, Y. Kim, ve J. Seo, “Mixed-Initiative Approach to Extract Data from Pictures of Medical Invoice”, içinde *2021 IEEE 14th Pacific Visualization Symposium (PacificVis)*, 2021, ss. 111-115.
- [7] A. Kay, “Tesseract: an open-source optical character recognition engine”, *Linux J.*, c. 2007, sy 159, s. 2, 2007.
- [8] V. Burkpalli, A. Joshi, A. B. Warad, ve A. Patil, “AUTOMATIC NUMBER PLATE RECOGNITION USING TENSORFLOW AND EASYOCR”.
- [9] Y. Baek, B. Lee, D. Han, S. Yun, ve H. Lee, “Character region awareness for text detection”, içinde *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, ss. 9365-9374.
- [10] Y. Du vd., “PP-OCR: A Practical Ultra Lightweight OCR System”. arXiv, 15 Ekim 2020. doi: 10.48550/arXiv.2009.09941.
- [11] “docTR documentation”. <https://mindee.github.io/doctr/> (erişim 24 Kasım 2022).
- [12] B. Faassen, Stefan, Martijn, Bicking, ve Ian, “lxml: XML and HTML with Python”. lxml, 2005. Erişim: 24 Kasım 2022. [Çevrimiçi]. Erişim adresi: <https://lxml.de/>
- [13] A. Jung, “Imgaug documentation”, *Readthedocs Io Jun*, c. 25, 2019.
- [14] Tzutalin, “LabelImg”. 2015. [Çevrimiçi]. Erişim adresi: <https://github.com/tzutalin/labelImg>
- [15] W. Ughetta ve B. W. Kernighan, “The Old Bailey and OCR: Benchmarking AWS, Azure, and GCP with 180,000 Page Images”, içinde *Proceedings of the ACM Symposium on Document Engineering 2020*, New York, NY, USA, Eyl. 2020, ss. 1-4. doi: 10.1145/3395027.3419595.
- [16] D. Mulfari, A. Celesti, M. Fazio, M. Villari, ve A. Puliafito, “Using Google Cloud Vision in assistive technology scenarios”, içinde *2016 IEEE Symposium on Computers and Communication (ISCC)*, Haz. 2016, ss. 214-219. doi: 10.1109/ISCC.2016.7543742.

Yapay Zeka Temelinde Etik Sorunsalı

Çağrı YARDIMCI
Bilgi İşlem Daire Başkanlığı
Uşak Üniversitesi
Uşak, Türkiye
cagri.yardimci@usak.edu.tr
<https://orcid.org/0000-0002-0752-0987>

Özet—Yapay zeka (YZ) sistemleri giderek yaygınlaştıkça, YZ'nin sınırları, neler yapabileceği, etik karar mekanizmaları, yönetimi ve kontrolü toplumda fazlaca tartışılır bir konu haline gelmiştir. Bu çalışmada konunun psikolojik, sosyal, felsefi ve yasal taraflarına odaklanılarak son gelişmelerin analizinin yapılması hedeflenmektedir. Bu çalışmada genel anlamda üç ana başlık üzerinde durulmuştur; bireysel etik karar mekanizmaları, toplumsal etik karar mekanizmaları ve insan ve YZ etkileşimleri. Her başlıkta kullanılan yöntemler ve temel teknikler vurgulanarak, etik YZ sistemlerinin insan temelli toplumlara başarılı bir şekilde entegrasyonuna yönelik araştırmalar tartışılacaktır.

Anahtar Sözcükler—yapay zeka, felsefe, etik, karar, mekanizma

I. GİRİŞ

YZ teknolojileri birçok alana girerken YZ için uzun süredir büyük bir zorluk olan etik karar verme sorunu, gündelik yaşamın birçok alanında kamuoyunun dikkatini çekmektedir [1]. YZ hakkında aşırı tepki verme eğiliminde olan önemli bir kamuoyu bloğu oluşarak, insan yetenekleriyle eşleşen ve günün sonunda insan zekasını aşan YZ geliştirmeyi amaçlayan genel YZ araştırmalarıyla yakinen ilgilenmektedir [2]. İnsanüstü yeteneklere sahip, kendi kendini tanıyan bir YZ, birçok kişi tarafından varoluşsal bir risk kaynağı olarak algılanmaktadır [3]. Bu seviye bir YZ'den hala onlarca yıl uzakta olunmasına rağmen, mevcut otonom sistemler (Ör. otonom araçlar) için, YZ araştırmacılarının etik hususları dahil etme konusunda ciddi bir eğilim oluşmaya başlamıştır [4].

Etik, bireyin başkalarına karşı nasıl davranması gerektiğine dair normatif bir pratik felsefi disiplindir ve üç boyutta incelenmektedir [5]:

A. Sonuçsal Etik

Bir birey, ancak ve ancak her seçimin sonuçlarını tartıyorsa ve en ahlaki sonuçları olan seçeneği seçerse etikdir. Elde edilen kararlar genellikle en iyi toplu sonuçları üretmeyi amaçladığından faydacı etik olarak da bilinmektedir.

B. Deontolojik Etik

Bir birey, ancak ve ancak belirli durumlarla ilgili yükümlülüklerle, görevlere ve haklara saygı duyuyorsa bu etik

adını almaktadır. Deontolojik etiğe sahip bireyler (Ör. görev etiği) yerel sosyal normlara göre hareket etmektedir.

C. Erdem Etiği

Bir birey, ancak ve ancak bazı ahlaki değerlere (Ör. cesaret, adalet vb.) göre hareket ediyor ve düşünüyorsa bu etikdir. Erdem etiğine sahip bireyler, başkaları tarafından olumlu algılanmak için içsel bir dürtü sergilemelidirler.

YZ araştırmacılarının perspektifinden, otonom sistemlerin insanlarla etkileşime girmesine izin verildiği ölçüde makine etiğinin belirleyici bir faktör olduğu anlaşılmaktadır [6]. Bu nedenle, bu sistemlerin insan haklarına saygı duymasını ve sadece kabul edilebilir etik ilkelere uygun eylemler gerçekleştirmesini sağlamak için teknik yaklaşımlara odaklanan araştırma çalışmaları ortaya çıkmıştır [7]. Bu konu birçok YZ geliştiricisi için yabancı kalmaktadır ve derinlemesine bir incelemeye ihtiyaç duyulmaktadır. Bununla birlikte, YZ yönetimi konusundaki mevcut çalışmalar çoğunlukla olayların psikolojik, sosyal ve yasal yönlerine odaklanmaktadır [8]. Bu çalışmada, bu boşluğu kapatmak için etiği yapay zekaya dahil etme tekniklerindeki son gelişmeler araştırılmaktadır.

II. BİREYSEL ETİK KARAR MEKANİZMALARI

YZ sistemlerinde etik karar verme söz konusu olduğunda, yapay zeka araştırmacıları, geçici kurallar yerine genel çerçevelerin tercih edilmesi hususunda büyük ölçüde hemfikirlerdir. Etik sınırların bağlamsal olabileceği ve zamansal anlamda tanımlanması zor olabileceğinden, etik kullanımı teşvik etmek ve etik olmayan kullanımı önlemek için temel normların yapay zekaya esnek bir şekilde dahil edilmesi gerekmektedir [9]. Bununla birlikte, güncellemeler kişiler tarafından sağlanıyorsa, kötüye kullanımı önlemek için bazı kontrol mekanizmaları devreye alınmalıdır [10]. İnsanlar tarafından ahlaki karar vermenin sadece faydalı etkilerini değil, aynı zamanda ahlaki kuralları da içerdiği gözlemlenmiştir. Bu tür kurallar genellikle, sonuçları ne olursa olsun belirli eylemlerin taahhüt edilmesi, ahlaki olarak korunması (Ör. kutsal değerler) ve yasaklanması (Ör. öldürmeye teşebbüs) gibi değerler içermektedir [11].

Yapılan çalışmada, bireylerin kendi ve diğer bireylerin eylemlerinin etiği hakkında yargıda bulunmalarını sağlayan bir çerçeve önermektedir [5]. İyi ve doğru teorilerine dayalı etik temsillerini, farkındalık ve değerlendirmeye dayalı etik yargı süreçlerini içermektedir. Önerilen etik yargı süreci, İnanç-Arzu-

Niyet (BDI) zihinsel modeline dayanmaktadır [12]. Bir bireyin kendi eylemlerinin etiğini yargılamak için, farkındalık süreci, bireyin karşı karşıya olduğu mevcut durumu ve bireyin hedeflerini tanımlayan inançları oluşturmaktadır. İnançlara ve hedeflere dayalı olarak, değerlendirme süreci, olası ve arzu edilen eylemler listesini kapsamaktadır. İyilik süreci daha sonra bireyin inançlarına, arzularına, eylemlerine ve ahlaki değer kurallarına dayalı etik eylemler listesini yaratmaktadır [13].

III. TOPLUMSAL ETİK KARAR MEKANİZMALARI

Toplum temsilcilerinin, toplumdaki diğer bireylerin eylemlerinin etik olup olmadığını yargılayarak, insan refahı ile koordineli hareket eden ve uyumlu bireylerden oluşan bir toplum yaratmak birçok açıdan yeterli olmayabilir. Toplumsal normları yönetenler, birincil kuralların gerekliliğini savunurken, zaman ilerledikçe ikincil kuralların, birincil kurallarla yaratılmasına, değiştirilmesine ve bastırılmasına izin vermektedirler [14].

Literatürde, özerk varlıkların (YZ veya insanların) davranışlarını yönetmek için sosyal normları kullanan bir mekanizma önermektedir. Böyle bir yaklaşım, merkezi bir otoriteye dayanmak yerine doğası gereği dağıtıcıdır. Bireyler, kendi karar mekanizmalarını yürüterek özerkliklerini sürdürürler, ancak roller aracılığıyla kolektif toplum tarafından tanımlanan sosyal normlara tabidirler (bireylerin nitelikleri sonucu onlara ayrıcalıklar veren fakat bu ayrıcalıklar sonucu yanlış davranırlarsa ceza veren kurallar bütünü). Sosyal normlar, taahhüt, yetki, yasak ve yaptırımları içeren bir şablon aracılığıyla tanımlanmaktadır. Bireyler daha sonra dinamik etkileşimler yoluyla kolektif kendi kendine yönetim elde etmek için itibar modelleme tekniklerine dayalı bir güven ağı oluştururlar [15].

Bireysel etik karar verme mekanizmaları, belirli bir senaryoda eylem seçimlerini ahlaki düşüncelerle değerlendirirken, toplumdaki farklı bir birey, farklı roller üstlenebilir. Örneğin, bazı bireyler deontolojik etiği değerlendirebilir. Diğerleri sonuçsal etik veya erdem etiğini değerlendirebilir [16]. Bir dizi başlangıç etik kuralına dayalı olarak, öğrenme yoluyla daha karmaşık kurallar kademeli olarak edinilebilir. Tercihler şeklinde tezahür eden ve nicel kısıtlamalar ile sınırlandırılan değerlendirmeler, tercih toplama ve çoktan seçmeli oylama yöntemleriyle toplu bir karara varmak için bir araya getirilebilir [17].

IV. İNSAN VE YZ ETKİLEŞİMLERİ

İnsanların davranışlarını etkilemeye çalışan yapay zeka uygulamalarında, davranış bilimleri için Belmont Raporu [18] tarafından oluşturulan ilkelerin, etiğin sağlanması için bir başlangıç noktası olduğu öne sürülmektedir [19]. Bu ilkeler üç temel gereksinimi içermektedir :

- a) İnsanların kişisel özerkliği ihlal edilmemelidir (teknoloji ile etkileşime girerken özgür iradelerini koruyabilmelidirler).
- b) Teknolojinin getirdiği faydalar risklerden daha ağır basmalıdır.
- c) Faydalar ve riskler kullanıcılar arasında adil bir şekilde dağıtılmalıdır.

Etik olarak uyumlu tasarım yönergelerine rağmen, uygulama tasarımcıları için faydaları ve riskleri ölçmenin zorluğu gereği yönergeleri Elektrik ve Elektronik Mühendisleri Enstitüsü (IEEE)'nden almak yararlı bir başlangıç noktası olabilir [20]. İnsan merkezli değerlerin (Ör. toplu refah ve iş-yaşam dengesi) hesaplamalı formülasyonları önerilmiş ve toplu kaynak kullanımında son zamanlardaki YZ destekli algoritmik yönetim yaklaşımlarına dahil edilmiştir [21].

Duygusal çekicilik, etik ikilemler altında etkili bir ikna edici strateji olmasa da, bireylerden gelen etik açıdan uygun duygusal tepkiler, insan-yapay zeka etkileşimini artırabilmektedir [22]. Bireylerin verilen duruma ilişkin değerlendirmeyi değiştirerek güçlü olumsuz duygularla başa çıkmalarına izin veren Başa Çıkma Teorisi'ne dayalı bir yaklaşım önerilmiştir. Birey, kendi eylemlerinin ve diğer bireylerin eylemlerinin etik etkilerini değerlendirmektedir. Kendi eylemi belirli bir ahlaki değeri ihlal ederse, verilen eyleme devam etme önceliğini düşürmeye yarayan utanç duygusu tetiklenir. Diğer bir bireyin eylemi belirli bir ahlaki değeri ihlal ederse, gözlemleyen kişide sitem duygusu tetiklenir ve bu, ilgili bireyle sosyal mesafeyi artırmaya hizmet etmektedir (Ör. güveni azaltmak) [23].

SONUÇLAR

YZ yönetim tekniklerindeki son gelişmelere dayanarak, çoğu çalışmanın, etik ikilemleri çözmek için kural tabanlı ve örnek tabanlı yaklaşımları birleştiren bireysel etik karar çerçevelerinde genelleştirilebilir geliştirmeye odaklandığı görülmektedir. İnsanlar tarafından etik karar verme örneklerinden uygun kuralları öğrenmek için, farklı kültürel geçmişe sahip insanlardan çeşitli etik ikilemler hakkında veri toplama konusunda daha fazla çalışmaya ihtiyaç bulunmaktadır. Çok etmenli oylamaya dayalı toplu etik karar verme üzerine çalışmalar ortaya çıkmasına karşın bireylerin etik tercihlerini temsil edecek mekanizmaları tasarlamak için hala çok araştırmaya ihtiyaç vardır. Ayrıca YZ mühendislerinin etik ve karar verme araştırmaları üzerinde daha fazla yoğunlaşmaları gerekmektedir [24].

REFERANSLAR

- [1] H. Yu, Z. Shen, C. Miao, C. Leung, V. R. Lesser, and Q. Yang, "Building ethics into artificial intelligence," *arXiv preprint arXiv:1812.02953*, 2018.
- [2] W. Wallach, C. Allen, and S. Franklin, "Consciousness and ethics: artificially conscious moral agents," *International Journal of Machine Consciousness*, vol. 3, pp. 177-192, 2011.
- [3] J. J. Bryson and P. P. Kime, "Just an artifact: Why machines are perceived as moral agents," in *Twenty-second international joint conference on artificial intelligence*, 2011.
- [4] S. Dehaene, H. Lau, and S. Kouider, "What is consciousness, and could machines have it?," *Robotics, AI, and Humanity*, pp. 43-56, 2021.
- [5] N. Cointe, G. Bonnet, and O. Boissier, "Ethical Judgment of Agents' Behaviors in Multi-Agent Systems," in *AAMAS*, 2016, pp. 1106-1114.

- [6] R. C. Arkin, "Ethics and autonomous systems: Perils and promises [point of view]," *Proceedings of the IEEE*, vol. 104, pp. 1779-1781, 2016.
- [7] A. Etzioni and O. Etzioni, "Incorporating ethics into artificial intelligence," *The Journal of Ethics*, vol. 21, pp. 403-418, 2017.
- [8] K. Kirkpatrick, "The moral challenges of driverless cars," *Communications of the ACM*, vol. 58, pp. 19-20, 2015.
- [9] B. M. McLaren, "Computational models of ethical reasoning: Challenges, initial steps, and future directions," *IEEE intelligent systems*, vol. 21, pp. 29-37, 2006.
- [10] J. A. Blass and K. D. Forbus, "Moral decision-making by analogy: Generalizations versus exemplars," in *Twenty-Ninth AAAI conference on artificial intelligence*, 2015.
- [11] M. Dehghani, E. Tomai, K. D. Forbus, and M. Klenk, "An Integrated Reasoning Approach to Moral Decision-Making," in *AAAI*, 2008, pp. 1280-1286.
- [12] A. S. Rao and M. P. Georgeff, "BDI agents: from theory to practice," in *Icmas*, 1995, pp. 312-319.
- [13] A. Loreggia, N. Mattei, F. Rossi, and K. B. Venable, "Preferences and ethical principles in decision making," in *Proceedings of the 2018 AAAI/ACM Conference on AI, Ethics, and Society*, 2018, pp. 222-222.
- [14] U. Pagallo, "Even Angels Need the Rules: AI, Roboethics, and the Law," in *ECAI*, 2016, pp. 209-215.
- [15] M. P. Singh, "Norms as a basis for governing sociotechnical systems," *ACM Transactions on Intelligent Systems and Technology (TIST)*, vol. 5, pp. 1-23, 2014.
- [16] H. Yu, Z. Shen, C. Miao, C. Leung, and D. Niyato, "A survey of trust and reputation management systems in wireless communications," *Proceedings of the IEEE*, vol. 98, pp. 1755-1772, 2010.
- [17] J. Greene, F. Rossi, J. Tasioulas, K. B. Venable, and B. Williams, "Embedding ethical principles in collective decision support systems," in *Thirtieth AAAI conference on artificial intelligence*, 2016.
- [18] U. S. N. C. f. t. P. o. H. S. o. Biomedical and B. Research, *The Belmont report: ethical principles and guidelines for the protection of human subjects of research* vol. 2: Department of Health, Education, and Welfare, National Commission for the ..., 1978.
- [19] R. Luckin, "Towards artificial intelligence-based assessment systems," *Nature Human Behaviour*, vol. 1, pp. 1-3, 2017.
- [20] J. P. How, "Ethically aligned design [From the Editor]," *IEEE Control Systems Magazine*, vol. 38, pp. 3-4, 2018.
- [21] H. Yu, Z. Shen, S. Fauvel, and L. Cui, "Efficient scheduling in crowdsourcing based on workers' mood," in *2017 IEEE International Conference on Agents (ICA)*, 2017, pp. 121-126.
- [22] C. Battaglino and R. Damiano, "Coping with moral emotions," in *14th International Conference on Autonomous Agents and Multiagent Systems, AAMAS 2015*, 2015, pp. 1669-1670.
- [23] S. Marsella and J. Gratch, "Modeling coping behavior in virtual humans: don't worry, be happy," in *Proceedings of the second international joint conference on Autonomous agents and multiagent systems*, 2003, pp. 313-320.
- [24] O. J. Erdélyi and J. Goldsmith, "Regulating artificial intelligence: Proposal for a global solution," in *Proceedings of the 2018 AAAI/ACM Conference on AI, Ethics, and Society*, 2018, pp. 95-101.

Turkish people's Opinions and Feelings Towards TOGG Cars

Numan Çelebi
Information Systems Engineering
Sakarya University
Sakarya, Türkiye
ncelebi@sakarya.edu.tr

Abdallrhman Alquaary
Information Systems Engineering
Sakarya University
Sakarya, Türkiye
apoalquaary@gmail.com

Abstract— The study aimed to collect data on the Twitter platform related to the hashtag (#TOGG) and analyze people's feelings and opinions. TOGG 2022 cars were officially announced to identify the user tweets' positive and negative feelings. We tried to see the extent of the impact of people's feelings and opinions after making these domestic cars. These results may help predict the winner in the next Turkish elections that will be held by 2023. The study examined issues that dominated Twitter tweets related to hashtag (#TOGG), and it reached many results. Most of the tweeters had positive feelings at a rate of (85.16%), negative feelings at a rate of (13.46%), and neutral feelings at a rate of (1.38%). We showed the relationship between hashtags related to hashtag (#TOGG). We found that (#RecepTayyipErdogan) was one of the most frequently repeated hashtags mentioned in 425 tweets. Of these, 380 were positive, as it observed that the ruling party was mentioned frequently and positively. Some tweets mocked the opposition parties. There was the hashtag (#BOGG), the only hashtag whose negative tweets outweighed the positive ones, as it was observed that it mocks or downplays the importance of the TOGG car industry with some attack on the ruling party.

Keywords— TOGG, TOGG2022, BOGG, Sentiment Analysis, Election in Türkiye

I. INTRODUCTION (HEADING 1)

The Turkish presidential election is considered one of the most important events that will happen in 2023, and all Turkish people and other countries are looking forward to knowing who is going to win. The elections of 2023 will happen in different circumstances than the previous times, as there is great resentment of the Turkish people towards their government (ruling party) because of the inflation that occurred in Türkiye in recent years. Fortunately, Türkiye officially announced the readiness of its electric cars, which it called TOGG, and held a celebration for that on 29/10/2022, as this announcement may lead to the return of some confidence to the people towards the current government. In order to understand the situation more clearly, we decided to use the Twitter platform as a primary source of information, as Twitter is the most used platform globally to discuss many matters, especially economic and political, by all segments of society. We used the hashtag (#TOGG), as it is the most prominent hashtag, coinciding with the official announcement of Togg electric cars on the Twitter platform and collecting almost all tweets from 06/08/2022 until 02/11/2022.

II. RELATED WORK AND BACKGROUND

Reference [1] says that few researchers have examined the impact of government policies toward social media on individuals' attitudes to social media use, particularly when

these policies aim to denounce and control social media platforms, as was the case in Turkey in 2013-2016.

More recently, on the technical side, data scientists have created a new concept in natural language processing (NLP) called attention [2] which gave them the ability to computers to understand texts more efficiently. It was published in 2017 for the first time. One year later, Google published a new language representation model called BERT, which stands for Bidirectional Encoder Representations from Transformers. Unlike recent language representation models [3]. BERT is designed to pre-train deep bidirectional representations from an unlabeled text by jointly conditioning on both the left and right context in all layers. As a result, the pre-trained BERT model can be fine-tuned with just one additional output layer to create state-of-the-art models for a wide range of tasks, such as question answering and language inference, without substantial task-specific architecture modifications.

III. METHODOLOGY

In recent decades, the continuous growth of social networking sites has attracted significant research interests from various disciplines and fields, especially since they are open spaces that allow their users to express their opinions freely, which has made them one of the most popular and used sites. It also can reflect the political scene in particular, which helped the growth in their use during the elections by political candidates and users. Looking at social networking sites, we will find a huge volume of data, and a large amount of useful information about users, their opinions, attitudes, ideas, and interactions on various issues, in contrast to the limited number of respondents to opinion polls and traditional interviews. With the advent of big data and its increasing popularity in the current century, research has increased in analyzing the feelings of social networking sites and extensive data analysis. Researchers have begun to integrate social networking data, led by the Twitter platform, as an aid in predicting various issues such as election results, so if the majority of feelings are positive towards a candidate, they expect this candidate to win the election.

Our study focused on the feelings, opinions, and thoughts of users from inside and outside Türkiye after the Turkish TOGG cars were announced to see if they affected people's thinking regarding politics or economics. Fig. 1 shows our methodology Framework.




Fig. 1 Our Model Framework

A. Collecting Data

Although a so-called Twitter API is given to developers, it gives only a limited number of tweets that do not exceed 3,200 thousand tweets per week. The other solution, which is the most difficult, was to use web scraping techniques to collect data from Twitter using the hashtag (#TOGG). The data was collected from 06-08-2022, i.e., when talking about Togg cars on social media began, until 11-02-2022, i.e. four days after the Turkish Togg car show ceremony. Four days were waited after the ceremony to see Twitter users' feedback on this topic. This process was done using Python to collect data related to each tweet. 56,040 thousand tweets were collected at different times of the day, and then this data was stored in an Excel file. It was noted that some accompanying hashtags indicated a political presence with the hashtag (#TOGG) in Fig. 2

Fig. 2 Collected Data Excel File

B. Cleaning Data

Data mining across the Twitter platform is a difficult task, because an opinion boils down to a few words and any error in sentiment analysis of any word will lead to the wrong classification of tweets; For this reason, accuracy in processing the text of tweets is very important, as raw tweets have many problems or so-called text noise that may affect the accuracy of the results, so data purification and preparation is done through preliminary processing of data analysis using natural language processing technology through the computer. And the use of the Python programming language, through which this noise was removed and the data was cleaned from characters of no value such as punctuation marks, prepositions, numbers, text emojis, emails, URLs, modification of signs and hashtags, deletion of duplicate characters such as "Hiiiiii" and removal of starting characters ("@", "#") and others with the help of the stop words dictionary as shown in Table 1, so that the valid data is

converted into an analyzable data format, which does not lead to distortion of the exploration results, then the text is converted to lowercase letters, and thus the extensive data that It was collected to extract what was helpful for meaningful analysis after which the data was stored in a new file.

Table 1 Example of Cleaning Data

Before Cleaning	After Cleaning
@zafersahin06 İçeriği göremedik , yani fabrikanın içini, tavuk mu yumurtladı, leylekler mi getirdi? #TOGG #YeterArtıkSıvadinız #EmeklilikteYasaTakılan Iar #GeceyeNotum https://t.co/COsB2Nwvzi	İçeriği göremedik , yani fabrikanın içini, tavuk mu yumurtladı, leylekler mi getirdi TOGG YeterArtıkSıvadinız EmeklilikteYasaTakılan Iar GeceyeNotum

C. Sentiment Analysis

We used Bert Sentiment Analysis Model to analyze our cleaned tweets and interpreted them using descriptive statistics and network graphs.

At the same time, we made two undirected graph data sets, one of the relationships between the most frequent hashtags. Vertex (V) represents a hashtag, and edge (E) represents the existence of both hashtags in the same tweet. We should mention that edge thickness indicates the frequency of words together. We used the same technique to make a network graph for the most frequented words and emojis.

Undirected Graph = $G(V, E_{\{ \text{the existence of both nodes in the same tweet} \}})$ (1)

IV. STUDY RESULTS

In this section the results of study are explained as below

First: sentiment analysis of the tweets in the hashtag TOGG

Table 2 shows the total percentages of tweet sentiment according to the hashtag TOGG during the period 08-06-2022 and 11-02-2022, where 56,040 tweets were collected. Sentiments of the tweets fluctuate between positive, negative, and neutral from the table. The highest percentage of tweets tended to be positive (85.16%), followed by negative feelings with a rate of (13.46%) and finally, neutral feelings with a percentage of (1.38%). For simplicity, the researcher removed the tweets related to neutral feelings from consideration so that only tweets with positive and negative feelings are dealt with in the following tables.

Table 2 Sentiment Analysis of TOGG Hashtag Tweets

Sentiment Type	TOGG Tweets	
	Frequency	Percentage
Positive	47723	85.16%
Negative	7543	13.46%
Neutral	774	1.38%
Total	56040	100%

It is worth noting that there is a vast difference between positive and negative feelings, as positive feelings are clearly overshadowed by the fact that there is great joy and on the part of the tweeters. This result is not surprising, as everyone knows that the Turkish people rejoiced greatly on this occasion. It is worth noting that it was noticed that the most cheerful and those with positive tweets were praising the ruling party. In contrast, most negative tweets were critical of the ruling party as shown in Fig. 3.




Fig. 3 Graph of Sentiment Analysis of TOGG Hashtag Tweets

Second: Sentiment Analysis Timeline

We can see from the following table the number of tweets per month from the percentage of the total number of tweets. As we can see, the number of positive tweets in August was 3439, as the percentage of the total tweets in August was 88.32%. As for the negative tweets, the number was 455 tweets or 11.68% of the total tweets for the month of August. In September 1649 positive tweets were published, where we noticed a decrease in the number of tweets, which was 89.14%, while the negative tweets were repeated 201 times, and the rate was 10.86%. As for October, it was the peak of publishing the hashtag (#TOGG), as the TOGG car was officially announced to the market on 10-29, and most of these tweets were the last days of October, when 41,545 positive tweets were published, which was 86.15%, while the negative tweets were 6,679. Tweet rate of 13.85%. As for the eleventh month, we only took the first two days from it, and the number of positive tweets was 1090, or 83.98%. As for the negative tweets, the number was 208, or 16.02% in Table 3.

Table 3 Sentiment Analysis Based on Months

Sentiment Type	Positive		Negative	
	Frequency	%	Percentage	%
8	3439	88.32	455	11.68
9	1649	89.14	201	10.86
10	41545	86.15	6679	13.85
11	1090	83.98	208	16.02

We also note that the positive side was constantly superior to the negative side in the hashtag (#TOGG) Fig. 4. These feelings indicate joy, happiness, and confidence, which may lead to a change in the political thinking of the Turkish street toward its government. As a result of this research, the

researchers expect that the announcement of these electric cars may affect the upcoming Turkish elections that will be held in 2023.




Fig. 4 Sentiment Analysis Based on Months

Third: Examples of Tweets

Analysts observed that the political aspect was strongly present in the minds of the tweeters, as most of the tweets contained political content. Tweets were either positive, negative, or neutral, as most of the positive tweets were praising the ruling party and President of Türkiye Recep Tayyip Erdoğan Fig. 5. Negative tweets were mostly criticizing the ruling party or the Turkish president Fig. 6. Neutral tweets were independent Fig. 7. as we can see from the below examples.

a) Positive Tweets



Fig. 5 Positive Tweet

b) Negative Tweets




Fig. 6 Negative Tweet

c) Neutral Tweets



Fig. 7 Neutral Tweet

Forth: Clouds and Network Graphs

A network graph refers to a structure representing a group of objects/words/hashtags/emojis and the relationships between them. It is also known as a graph in mathematics. A network structure consists of nodes and edges. Here, nodes represent objects(hashtags/words/emojis) we will analyze, while edges represent the relationships between those objects. (Green node is a positive node, Red Node is a negative Node, the Green edge means both nodes are positive, the Red edge means one of the two nodes is negative, and the thickness of an edge means the more substantial relation)

As we can see in Fig. 8, there are many relationships between hashtags, most of which were positive, except (#BOGG) hashtag. We can notice from the graph that there was some political existence.

As we can see in Fig. 9, there are fewer relationships between words and most of them were positive, except (#BOGG) hashtag. We can notice from the graph that there were some national feelings existing.

As we can see in Fig. 10, there are many relationships between emojis, all of which are positive. We can notice the support Twitter users had for TOGG.




Fig. 8 Network Graph for Most frequented 20 hashtags and their relationships




Fig. 9 Network Graph for Most frequented 25 words and their relationships




Fig. 10 Network Graph for Most frequented 25 emojis and their relationships

CONCLUSION

In this paper, we analyzed one of the hottest topics in Türkiye in 2022. We investigated how this topic would affect other aspects of life, primarily politics. 2023 is the most crucial year in Türkiye's history because it has two important events: presidential election and The centenary of the founding of Türkiye. Researchers assumed Togg cars announcement would affect those two events from the political side, which is why it is a considerable subject. This study concluded that the announcement of the Togg cars this year has impacted the Turkish people's political decisions, positively and negatively, as shown in the tables above. However, at the same time, there is opposition and resentment, especially with the economic situation and high prices.

REFERENCES

- [1] M. Zagidullin, N. Aziz, and S. Kozhakhmet. "Government policies and attitudes to social media use among users in Turkey: The role of awareness of policies, political involvement, online trust, and party identification," *Technology in Society* Volume 67, November 2021, 101708.
- [2] A. Vaswani, N. Shazeer, N. Parmar, and at all. "Attention Is All You Need," 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA.
- [3] J. Devlin, M. Chang, K. Lee, and K. Toutanova. "BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding," arXiv:1810.04805v2 [cs.CL] 24 May 2019.

Dijital Dönüşümlere Dayanan Katalog Sistemleri

Sercan Tomaç
Detay Danışmanlık Bil. Hiz. San. ve
Dış Tic. A. Ş.
İstanbul, Türkiye
sercan.tomac@detaysoft.com

Mustafa Temiz
Yönetim Bilişim Sistemleri Bölümü
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
temizmustafa@cumhuriyet.edu.tr

Halil Arslan
Bilgisayar Mühendisliği Bölümü
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
harslan@cumhuriyet.edu.tr

Özet— Katalog sistemleri ürün tanıtımlarında bilgi vermek amaçlı kullanılan kullanışlı ve etkili bir tanıtım mekanizmasıdır. Teknolojinin gelişimi ile ürün tanıtımlarında kullanılan kâğıt baskı katalog sistemleri yerini dijital kaynaklara bırakmaktadır. Bünyesinde çok sayıda alt organizasyon içeren büyük işletmeler, geleneksel yöntemler ile her alt organizasyonu için özel katalog üretme noktasında hem maliyet hem de kullanılabilirlik açısından farklı problemler ile karşılaşmaktadırlar. Dijital katalog sistemleri, ön taraf (frontend), arka taraf (backend), veri tabanı ve bulut mimari teknolojilerinin sunmuş olduğu güncel ve etkili mimariler yardımıyla bu problemlere çözüm üretmekte ve son kullanıcı için hem mobil uygulama hem de web platformları üzerinden kullanışlı bir ürün sunmaktadır. Yenilikçi teknolojik yaklaşımların kullanıldığı bu çalışma, kâğıt baskı kataloglar yerine dijital platformlar kullanılarak performanslı ve etkili bir ürün tanıtım işlemi gerçekleştiren dijital katalog tasarlama çalışmasıdır. Bu platform üzerinden katalogları görüntüleyen kullanıcıların konum, zaman, odaklanılan ürün (ısı haritaları) gibi bilgileri alınmakta ve bu bilgiler üzerinden katalogta sunulan içeriğin analitikleri gerçekleştirilmektedir. Bu analitikler arasında, öne çıkan ürünler/sayfalar, bölgelere/shirlere göre odaklanılan ürünler/sayfalar gibi analizler elde edilebilmektedir. Ayrıca sonraki çalışmalarda, kullanıcıya özgü tavsiye sistemi, katalog içeriğinin kullanım istatistiklerine göre yeniden düzenlenmesi, konum tabanlı olarak anlık kampanyalar üretilerek kullanıcının en yakın mağazaya yönlendirilmesi gibi yapay zekâ destekli modeller geliştirilecektir.

Anahtar Kelimeler—*Dijital Dönüşüm, Online Katalog, Yapay Zekâ, Makine Öğrenmesi, Öneri Sistemleri*

I. GİRİŞ


Kataloglar, üretici veya satış operasyonu gerçekleştiren firmalar tarafından ürün bilgisi vermek için kullanılan etkili bir tanıtım aracıdır. İçerisinde çok sayıda ürün görseli ve bu ürünlere ait çeşitli bilgiler içeren kataloglar hem mağaza çalışanları hem de müşteriler için ürünlere erişim noktasında kolaylık sağlamaktadır. 21. yüzyıl gelişen teknoloji ile gerçekleşen gelişmeler tüketici istek ve beklentilerini de şekillendirmektedir. Bu istek ve beklentiler, kısa zaman dilimlerinde daha fazla ve gerçekçi ürün incelemek ve gözlemlemek üzerine kurulmaktadır. İşletmeler, geleneksel olarak kullanılan kağıt baskılı kataloglar üzerinden ürün yönetimi (ürün bilgi, depo vb.) için çevre şubeler ile iletişim kanallarını kullanarak etkileşim kurmaktadır. İşletmeler için prestij ve zaman kaybı ile sonuçlanan bu yöntem gelişen teknoloji ile yerini dijital kaynaklara bırakmaktadır. Ürün kararını verecek müşteriler, dijital kaynaklar üzerinden ürün mevcut durumu ve benzer modelleri de inceleme isteği gibi önem arz eden isteklere de çözüm olmaktadır. Satış ve pazarlamada kullanılan geleneksel kâğıt baskılı kataloglar teknolojik gelişmeler ile yerini dijital katalog sistemlerine bırakmaktadır [1].

Dijital kataloglar ihtiyaçları karşılamak için çok sayıda kaynağı online platformlar kullanarak daha etkili bir şekilde

sunmak amacıyla kullanılan araçlardır. Mobilya, elektronik ve sarf malzeme gibi çeşitli pazarlama sektörlerinde dijital katalog sistemleri etkili bir şekilde kullanılmaktadır. Öncelikle, dijital katalog kullanan işletmeler personel yardımı olmadan ve daha hızlı bir şekilde ilgili ürünlere erişme imkanına sahiptir. Ayrıca dijital platformlar, ürünlere daha etkili erişimin yanında sistemin sunacağı öneriler sayesinde müşteriler için fikir oluşturmaktadır. Dijital kataloglar görselleri ile çok fazla bilgi içermesinden dolayı arayüzlerin tasarlaması karmaşık bir işlemdir. Dijital kataloglar alıcı ve satıcı için kullanımı açık, anlaşılır ve kolay olmalıdır. Arama filtreleri tercihi, biçimleri ve temsil etme şekli başta olmak üzere kullanıcı merkezli dijital kataloglar kullanım kolaylığı sağlamaktadır.

Kullanıcı merkezli dijital katalog tasarımların da gerçekleştirilen önceki çalışmalar genellikle kütüphane otomasyon sistemleri ve oyun öğrenme alanlarına yoğunlaşmaktadır. Kataloglama, kütüphanelerde kaynakların tanımını içeren önemli bir tanıtım aracıdır [2]. İçerisinde çok sayıda kitap bulunmasından dolayı istenildiğinde ilgili dökümanlara geleneksel kataloglar üzerinden erişim çok sayıda problemi beraberinde getirmektedir. Kütüphanelerde geleneksel kataloglar yerine filtreleme tekniğine sahip dijital kataloglar kullanılmaya başlanmaktadır. Monyela (2020) çalışmasında kütüphanelerde kullanılan kataloglama ve dijital kataloglamaya geçiş çalışmalarına yer vermektedir [3]. Oyun tanıtım dijital kataloglarında dijital platformların filtreleme özelliği ön plana çıkmaktadır. Leavitt vd. Mobygames oyun tanıtım kataloğu platforma, oyunun yılına, kullanım alanına ve oyun derecelendirmesine bağlı çeşitli filtreler sunduğunu ifade etmektedir [4]. Djaouti vd. SeriousGamesClassification dijital kataloğunun yaş grubu, oyun türü ve amacı gibi önemli etkenlerini ön planda tutan ve oyun bulmayı daha etkili bir şekilde kullanıcıya sunan dijital kataloglarda filtreleme tekniği sunulduğunu vurgulamaktadır [5].

Bu çalışmada geleneksel kataloglama yöntemlerinin yerine dijital platformlar kullanılarak daha hızlı ve etkili bir dijital katalog üretim ve dağıtım mimarisi Şekil 1'de gösterilmektedir. Öncelikle yönetici olarak yönetim paneline giriş yapılmakta ve üretilecek kataloğa ait tanımlama verileri (katalog adı, firma bilgisi, hedef platform, aktiflik süresi, kataloglar arası yerleşim sırası vb.) sisteme girilmektedir. İnteraktif tasarlayıcı aşamasında PDF formatında yüklenen içerik resim formatına dönüştürülmekte ve istenilen her sayfa için farklı interaktif öğe (video, ses, resim slaytı, web



Şekil 1. Dijital katalog sistemi iş akışı

bağlantısı, harita vb.) ile içerik zenginleştirilebilmektedir. Ardından içerik dağıtım aşamasında mobil ve web kanalları üzerinden tasarlanan ürün katalogları dağıtılacak ve kullanıma sunulacaktır. Yazılım ürünleri ile tasarlanan sistem gereksinimleri bulut tabanlı mimari (SaaS) de tutulmaktadır. Son kullanıcıların erişimine mobil uygulama ve web portalları kullanarak bulut mimari üzerinden erişim imkânı sunulmaktadır. Güncel teknolojilerin kullanıldığı bu çalışmada tüketiciler katalogları gerçekçi ve ayrıntılı bir şekilde gözlemlemiş olacaktır.

Ayrıca geliştirilen platform ile dijital katalogları görüntüleyen kullanıcıların, bu katalogları incelediği konum bilgisi, zaman bilgisi (saat, mevsim olarak) ve kullanıcıların odaklanmış oldukları ürün bilgileri incelenmekte ve bunları içeren çeşitli istatistiksel veriler elde edilmektedir. Bu istatistiksel veriler işlenerek kullanıcılar için öne çıkan ürün/sayfalar, bölge/şehirler ve odaklanılan ürün/sayfalar gibi kullanıcı için yararlı bilgiler oluşturulabilmektedir. Gelecek çalışmalarda bu veriler kullanılarak kullanıcıya özgü ürün tavsiye sistemleri, katalog içeriğinin kullanıcı işlem hareketlerine göre yeniden tasarlanması, zaman ve konum tabanlı analizleri dikkate alarak anlık kullanıcıya özgü kampanyalar üretilmesi gibi yapay zekâ destekli modeller geliştirilecektir.

Çalışmanın kalan kısmı şu şekilde özetlenmektedir. Bölüm 2’de çalışmada kullanmış olduğumuz materyal ve metotlara yer verilmiş, Bölüm 3’te gerçekleştirmiş olduğumuz uygulama tanıtılmış ve Bölüm 4’te elde ettiğimiz sonuçlar ifade edilerek çalışma tamamlanmaktadır.

II. MATERYAL VE YÖNTEM

Bu bölümde geliştirilen dijital katalog uygulaması için kullanılan teknolojiler ve mimariler hakkında bilgiler verilmektedir. Dijital katalog uygulaması için arka plan (backend) tarafında geliştirilen kodlar PHP Laravel ile gerçekleştirilmektedir. Görsel olarak son kullanıcıya sunulacak yapının ön taraf (frontend) kodları ise Next.js (React) ile geliştirilmektedir. Tasarlanan uygulamada ürünlere ve satışlara ait kayıtlar MySQL veri tabanında tutulmaktadır. Geliştirilen yazılım ve veriler bulut tabanlı mimaride barındırılmakta ve ilgili kullanıcılar için dağıtım, bulut mimari üzerinden hizmet olarak yazılım (Software as a Service-SaaS) modelinde sunulmaktadır.

Katalog metaverileri veya PDF dosyaları öncelikle resim formatına dönüştürüldükten sonra interaktif tasarımcılara

aktarılmaktadır. İnteraktif tasarımcıyla her bir sayfaya video, ses, slayt geçişi, web bağlantısı gibi bileşenleri de içerisinde bulunduran 10 farklı interaktif bileşen entegre edilebilmektedir. Bileşenler görsellere entegre edildikten sonra katalog yeniden PDF formatına dönüştürülmektedir. Son aşamada yetkili kullanıcının ilgili kataloğu görüntülenmesi ve onaylaması için ön görüntü sunulmaktadır. Katalog üretim aşaması tamamlanan ürün istenilen platformlar için dağıtım onayına sunulmaktadır. Daha sonra üretilen içerik farklı dağıtım kanallarında (iOS, Android ve Web Sayfası olarak) yer alan içerik görüntüleyici yazılım üzerinden görüntülenebilmektedir. Gerçekleştirilen sistem bulut mimari yaklaşımları ile mobil uygulama veya web portalları üzerinden kullanıcıların hizmetine sunulmaktadır. Son kullanıcılar gerek mobil uygulamalar gerekse web portalları üzerinden kataloglara erişim sağlamak ve dijital platformlar yardımı ile ürün incelemesini gerçekleştirmektedir.

A. Laravel

Web sitesi tasarımların da geleneksel yaklaşımlar ile ortaya bir site çıkarmak uzun süreli işlemler ve çok sayıda satırdan oluşan kodlamalar gerektirmektedir. Bu işlemler zaman kaybı ile sonuçlanmaktadır. PHP çerçeveleri önceden hazırlanan pratik ve kullanışlı yapılar ile web tasarımı yapmak için hazır bir mimari sağlamaktadır. Bu yapıyı problemlerimize göre uyarlayarak daha hızlı bir şekilde web uygulamaları oluşturulmaktadır. Laravel en sık kullanılan PHP tabanlı web çerçevelerinden biridir [6]. Laravel açık kaynak kodlu üst düzey güvenli web uygulamaları oluşturmayı sağlayan PHP tabanlı web çerçevesidir ve web uygulamaları gerçekleştirmek için oldukça kullanışlı bir çerçevedir. Model-view-controller (MVC) mimari modelini uygulayan bu yapı, proje kurmak ve çalıştırmak için PHP composer kullanımını sağlamaktadır. Ayrıca çeşitli modeller, kontroller ve servisler oluşturmak için yoğun bir şekilde uygulanmaktadır [7]. Laravel dosya işleme bileşeni diğer PHP çerçeveleri ile karşılaştırıldığında en iyi performansı gösterdiği vurgulanmaktadır [6].

B. Next.js (React)

Bir react çerçevesi olan Next.js web uygulamaları geliştirirken bir ön-taraf (frontend) yapısını oluşturmak için kullanılmaktadır. Bir web uygulamasının performanslı ve güvenilir bir şekilde çalışması için uygun yapıları içermektedir. Strapi dahil olmak üzere içerik yönetim

sistemleri ile uyumlu bir şekilde çalışmaktadır. Next.js ön tarafta üçüncü parti uygulamaları kullanmadan basit bir form gönderme mantığının uygulanmasına izin vermektedir [8]. Next.js web uygulamaları geliştirmek için önemli özelliklere sahiptir.


Değiştirilmiş dosyaları tanımlama ve bu dosyaların anında yeniden yükleme becerisini içeren aktif kod yeniden yükleme özelliği bu mimariyi ön plana çıkaran özelliklerden biridir. Yönlendirme için URL'leri ayarlama ihtiyacını ortadan kaldırması ile gerçekleşen otomatik yönlendirme özelliği bir diğer dikkat çekici özelliklerinden biridir. Bir başka özelliği ise sunucuda önceden oluşturulmuş olarak gelen ve istemci tarafında yüklemeleri daha hızlı ve etkili hale getiren sunucu tarafı oluşturmalarıdır. JavaScript modüllerini ve React.js bileşenlerini dinamik olarak yüklemek ise bir başka özelliğidir. Yaygın olarak kullanımını sağlayan bir diğer özellik Typescript desteği ve statik siteleri dışa aktarabilmesidir [9].

C. MySQL

MySQL, SQL (Structured Query Language) dilini kullanan, veri alımını otomatikleştirmeye yardımcı olan ve PHP tabanlı web uygulamaları geliştirmede önemli kolaylıklar sağlayan açık kaynak ilişkisel bir veri tabanıdır [10]. Kullanıcı yönetme, ağ erişimi sunma, veri tabanı bütünlüğünü kontrol etme ve veri tabanının yedeğini oluşturma sürecini basitleştirme yeteneği gibi özellikleri içermektedir. Ayrıca SQL ifadeleri kullanılarak ilişkisel veri tabanlarından bilgi oluşturabilir, değiştirebilir ve kurtarabilir olması kullanıcıların veri tabanlarına nasıl eriştiğini kontrol etmelerini sağlamaktadır [11].

D. Saas (Hizmet olarak yazılım)


Hizmet olarak Yazılım, uygulamaların bir satıcı veya hizmet sağlayıcı tarafından barındırıldığı ve müşterilere bir ağ, genellikle İnternet üzerinden sunulduğu bir yazılım dağıtım modelidir. SaaS, web hizmetlerini ve hizmet odaklı mimariyi destekleyen temel teknolojiler olgunlaştıkça ve yeni gelişimsel yaklaşımlar popüler hale geldikçe, giderek yaygınlaşan bir dağıtım modeli haline gelmektedir. Bu modelin en önemli avantajlarından biri kullandıkça öde modeli ile kullanıcıların kullanımına bağlı olarak ücretlendirme modelidir. SaaS uygulamaları aynı zamanda, farklı platformlardaki diğer verilerle ve diğer uygulamalarla da etkileşime girerek kullanıcılar için kullanım çeşitliliği sağlamaktadır. Aynı zamanda tanımlanan farklı hizmet sunum modelleriyle yakından ilişkili bir şekilde hizmet vermektedir. Çoğunlukla kurumsal müşterilere düşük maliyetle iş yazılımı işlevselliği sağlamak için uygulanan bu sistem, müşterilerin ticari olarak lisanslanmış, dahili olarak çalıştırılan yazılımın aynı faydalarını kurulum, yönetim, destek, lisanslama ve yüksek başlangıç maliyeti ile ilişkili karmaşıklık olmadan elde etmelerini sağlamaktadır. Katalog tasarlama ve dağıtım mimarisi Şekil 2’te gösterilmektedir.



Şekil 2. Uygulama dağıtım modeli

III. UYGULAMA

Geliştirilen sisteme Şekil 3’te gösterilen kullanıcı paneli üzerinden giriş yapılmaktadır. Geniş ölçekli işletmeler bünyesinde çok sayıda farklı sektöre hizmet eden alt organizasyonlar içerebilmektedir. Geliştirilen uygulamada kullanıcı paneline giriş yapılmasının hemen ardından ilgili organizasyonun katalogu seçilerek dijital platform kaynaklarına kataloglar aktarılmaktadır.



Şekil 3. Kullanıcı paneline giriş ekranı


Şekil 4’te katalogların listelendiği ekran gösterilmektedir. Alt organizasyonlar içerisinde ilgili organizasyon seçilerek etkili ve hızlı bir şekilde ürün görselleri yüklenmektedir.



Şekil 4. Katalogların listelenmesi

İlgili katalog seçildikten sonra bu kataloğa ait tanımlama bilgileri verilmekte ve kullanıcının katalogu düzenleyebilmesine olanak sağlanmaktadır. Katalog geliştirmesi tamamlandıktan sonra mobil ve web platformlarında etkili bir dağıtım ve kullanım sunulabilmesi için uygulama SaaS içerik görüntüleyicilere aktarılmakta ve son kullanıcı ya da paydaşlarla kataloglar paylaşılmaktadır.

Tasarlanan katalogların indirilme sayıları, sayfa bazlı görüntülenme oranları, ısı haritaları dönemsel ve bölgesel (bölge, şehir, ilçe vb.) bazlı yöneticiye sunulmakta ve oluşturulan katalog ilgi derecesi takip edilmektedir. İçerik takip sistem ekranları Şekil 5'te gösterilmiştir.



Şekil 5. Yönetici istatistik ekranları

IV. SONUÇ

Bu çalışma da ürün bilgisi içeren ve alışlagelmiş baskı sistemine dayanan kataloglar yerine mobil cihazlar ve web portalları üzerinden katalog bilgisine erişilen bir sistem geliştirilmiştir. Bu sistem sayesinde basılı kataloglarda yaşanan, güncel olmayan ürün verileri, katalog dağıtım zorlukları, katalogların hedef kitleye ulaşp/ulaşmadığı gibi önemli problemlerin giderilmesi sağlanmıştır. Ayrıca katalog sahibi firmaya, katalog indirme/görüntülenme/odaklanma gibi kayıtlar kullanılarak elde edilen verilerden üretim, lojistik ve pazarlama için faydalı geri dönüşler yapılmaktadır. Bu çalışmada SaaS tabanlı olarak geliştirilen uygulamamızın bakım ve onarımını da çok kolay bir şekilde sürdürülebilmektedir. Geleneksel baskı kataloglar yerine dijital platformların kullanılır olması ise baskı ve dağıtım maliyetlerini ortadan kaldırmaktadır. Gelecek çalışmalarda geliştirilen uygulamadan toplanan veriler çeşitli makine öğrenmesi yöntemleri ile analiz edilecek ve tüketiciler

arasında yaygın olarak tercih edilen ürünler (konum ve zaman tabanlı olarak) değerlendirilerek müşterilere geri dönüşlerin sunulması planlanmaktadır. Ayrıca katalogu görüntüleyen kullanıcılara gerçek zamanlı olarak bildirimler (push notification) sunularak anlık kampanyaların oluşturulması ve kişiye özgü kampanyalar üretilmesi sağlanacaktır.

TEŞEKKÜR

Bu çalışma, Detaysoft Ar-Ge Merkezi bünyesinde yürütülen çalışmaların sonucudur. Desteklerinden dolayı Detaysoft Ar-Ge Merkezine teşekkür ederiz.

KAYNAKÇA

- [1] G. F. Toprak, "BİLİŞİM TEKNOLOJİSİNDE KATALOGLA PAZARLAMININ ÖNEMİ VE MOBİLYA SEKTÖRÜNDE BİR UYGULAMA," Yüksek Lisans Tezi, İSTANBUL ESENYURT ÜNİVERSİTESİ, İstanbul, 2020.
- [2] B. Dobreski, "Anglo-American library cataloging," 2020. <https://www.isko.org/cyclo/cataloging> (accessed Jul. 19, 2022).
- [3] M. Monyela, "In the evolving digital environment: is cataloging lagging behind?," Library Hi Tech News, vol. ahead-of-print, no. ahead-of-print, Jan. 2022, doi: 10.1108/LHTN-11-2020-0105.
- [4] M. O. Leavitt and B. Shneiderman, Based web design & usability guidelines. Health and Human Services Department, 2006.
- [5] D. Djaouti, J. Alvarez, and J.-P. Jessel, "Classifying Serious Games: The G/P/S Model," Handbook of Research on Improving Learning and Motivation through Educational Games: Multidisciplinary Approaches, 2011. <https://www.igi-global.com/chapter/classifying-serious-games/www.igi-global.com/chapter/classifying-serious-games/52492> (accessed Jul. 19, 2022).
- [6] N. Yadav, D. S. Rajpoot, and S. K. Dhakad, "LARAVEL: A PHP Framework for E-Commerce Website," in 2019 Fifth International Conference on Image Information Processing (ICIIP), Nov. 2019, pp. 503–508. doi: 10.1109/ICIIP47207.2019.8985771.
- [7] K. I. Bagwan and S. Ghule, "A Modern Review on Laravel- PHP Framework," vol. 2, no. 12, p. 3, 2019.
- [8] N. Pinnis, "MODERN WEBSITE DEVELOPMENT WITH STRAPI AND NEXT.JS," p. 44.
- [9] Z. Dinku, "React.js vs. Next.js," p. 36.
- [10] A. T. Joseph Kurien, S. A. Mathew, and S. C. Mana, "Development of PHP and MySQL based Digital Asset Management System for Secure Organizations," in 2022 6th International Conference on Trends in Electronics and Informatics (ICOEI), Apr. 2022, pp. 1859–1863. doi: 10.1109/ICOEI53556.2022.9776698.
- [11] D. Johari, S. Samaddar, and S. Kumar, "AI based WebApp development using Application Programming Interface (API)," in 2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE), Apr. 2022, pp. 474–479. doi: 10.1109/ICACITE53722.2022.9823524.

S-Factor Estimations at Low energies by Using Artificial Neural Network

Eda Pasayigit
Department of Physics
Erciyes University
Kayseri
e.orkunpasayigit@gmail.com

Serkan Akkoyun
Department of Physics
Cumhuriyet University
Sivas
sakkoyun@cumhuriyet.edu.tr

Gokhan Kocak
Department of Physics
Erciyes University
Kayseri
gkokak@erciyes.edu.tr

Abstract— The first-order distorted wave born approximation and artificial neural network are used to examine the astrophysical S-factor and total cross-section of the $^3\text{He}(\alpha, \gamma)^7\text{Be}$ radiative capture reaction. Our findings demonstrate that the artificial neural network model is a strong candidate as an extrapolation model to estimate the observable S-factor at astrophysical energy.

Keywords—Artificial neural network, radiative capture reaction, astrophysical S-factor.

I. INTRODUCTION

At nuclear astrophysical low energies, the S-factor is of great importance. It allows to make predictions due to its structure that goes to zero and changes smoothly in places where there is no experimental data. In this study, S-factor for $^3\text{He}(\alpha, \gamma)^7\text{Be}$ reaction obtained by using Distorted wave born (DWBA) approximation.

In this study, as a new approximation in this area, we have used artificial neural network model to estimation S-Factor. In recent years, this technique has grown significantly in importance for data analysis in disciplines like nuclear physics, high energy physics, astronomy, biology, chemistry, meteorology, and geophysics. A great amount of work is being done in nuclear physics with the aid of the ANN model.

The ANN approach was chosen for these investigations because, unlike other extrapolation models, it does not require any equations or mathematical linkages between the input and output data, which is its primary benefit over other methods.

In this study, we have obtained the S-factor for the $^3\text{He}(\alpha, \gamma)^7\text{Be}$ system by using DWBA and ANN. We have compared the results at energies going to zero. Also, the reliability of ANN has been investigated.

II. MODEL

A. DWBA Model

In this investigation, the total cross section and S-factor for the $^3\text{He}(\alpha, \gamma)^7\text{Be}$ radiative capture processes were calculated using the nuclear potential model.

In this model, the cross section is given by,

$$\frac{d\sigma}{d\Omega} \propto |T_{fi}|^2 \quad (1)$$

We can define transition amplitude T_{fi} as,

$$T_{fi}(k_f, k_i) = \int dr \chi_f^{(-)}(k_f, r) \langle \Phi_f | U(r, \beta) | \Phi_i \rangle \chi_i^{(+)}(k_f, r) \quad (2)$$

where k_i and k_f are wave numbers of entrance and exit channels, respectively. The distorted waves $\chi_i^{(+)}(k_i, r)$ and $\chi_f^{(-)}(k_f, r)$ give the relative motion between the interacting nuclei. $U(r, \beta)$ and the β defines internal coordinates of the excited states.

At astrophysically low energies, either there aren't any open excited channels, or they aren't strong enough to support nuclear reactions. In order to choose the optimal potential model to obtain the reaction observables for a specific system, We calculated the reaction total cross section for the $^3\text{He}(\alpha, \gamma)^7\text{Be}$ system using this potential and first-order DWBA calculations. While non-elastic contributions can be handled perturbatively, the DWBA implicitly assumes that elastic scattering is prevalent.

B. ANN Model

Artificial neural network (ANN) is a mathematical model that simulates how the human nervous system and brain work [1]. The neurons in a nerve cell and the connections that link them make up the model's structure. Neurons serve as the model's functional units. In three separate layers, groupings of neurons are arranged. The input, hidden, and output layers are those layers. This kind of ANN is referred to as a layered ANN because of its layered construction. Neurons in the input layer serve as representations for the problem's independent variables. Each variable relates to a different neuron. The problem's desired outcome, or the dependent variables, occurs in the output layer.

III. RESULTS

In this study, we have used three different experimental data [2-4] for $^3\text{He}(\alpha, \gamma)^7\text{Be}$ system. The experimental energy ranges changes between $E_{\text{cm}}=0-2$ MeV.

First of all, we have applied the DWBA model to obtain S-factor data. In our calculations, we have used Gaussian potential for the nuclear part of total potential with the parameters $V_0=300$ MeV, $r_0=1.02$ fm. and $a_0=2.0$ fm.




Fig. 1. The S-factor results of ${}^3\text{He}(\alpha,\gamma){}^7\text{Be}$ reaction with comparison our results and experimental data. The experimental data is obtained from Ref. [2].




Fig. 2. The S-factor results of ${}^3\text{He}(\alpha,\gamma){}^7\text{Be}$ reaction with comparison our results and experimental data. The experimental data is obtained from Ref. [3].

As it can be seen in all figures, our potential model explanation very reasonable. But, it fails to reproduces pahse and magnituse in some points. This reactions very sensitive to potential parameters. Because of this reason, It is not possible to obtain precise results.

In a second stage, we have applied ANN model to get reaction observables. As it given from figures, ANN gives very good results. This study aims to estimate the S-factor using nuclear reaction data and ANN. Old style experimental data were used to generate S-factor values. The S-factor values corresponding to the Energy value were estimated using ANN and used as input data to create the ANN model. There was just one input, one output, and one hidden layer with four hidden layer neurons. The artificial intelligence technique known as the Multilayer Perceptron was adopted. Theoretically, hidden neurons activation functions may be

nonlinear. In our analysis, we have found reasonable $S_{34}(0)$ values for the energies going to zero except Constantini's data. Our results very compatible with literature values. In future, we will search the ANN behavior for Constantini's data.

IV. CONCLUSION

In this study, we have analized the astrophysical S-factor and total cross-section of ${}^3\text{He}(\alpha,\gamma){}^7\text{Be}$ reaction by using the nuclear potential model and artificial neural network. Our results proves that, our ANN findings accurately forecast the reaction observable and replicate the oscillatory structure of the S-factor and total cross-section data with the proper amplitudes and phases. Additionally, the $S_{34}(0)$ ANN prediction at energies going to zero is quite consistent with the other data.

Our primary goal in doing this work is to compare the nuclear potential model to the ANN results for the estimation of $S_{34}(0)$ and reaction variables. Our findings indicate that the ANN model is a very effective extrapolation technique at astrophysical energy. It might be an effective tool for estimating a region out of experimental data.




Fig. 3. The S-factor results of ${}^3\text{He}(\alpha,\gamma){}^7\text{Be}$ reaction with comparison our results and experimental data. The experimental data is obtained from Ref. [4].

ACKNOWLEDGMENT

This work was supported by the Erciyes University Scientific Research Projects Unit. Project Number: FBA-2022-11957.

REFERENCES

- [1] S. Haykin, "Neural Networks: A Comprehensive Foundation". 2nd Edition, Prentice-Hall, Englewood Cliffs, NJ. 1999.
- [2] J. L. Osborne, C. A. Barnes, R. W. Kavanagh, R. M. Kremer, G. J. Mathews, J. L. Zyskind, P. D. Parker and A. J. Howard, "Low-energy Behavior of the ${}^3\text{He}(\alpha,\gamma){}^7\text{Be}$ Cross-section," Nucl. Phys. A 419, 1984, 115-132.
- [3] H. Costantini, D. Bemmerer, F. Confortola, A. Formicola, G. Gyurky, P. Bezzon, R. Bonetti, C. Brogini, P. Corvisiero and Z. Elekes, et. al., "The He-3(α,γ)Be-7 S-factor at solar energies: The Prompt gamma experiment at LUNA," Nucl. Phys. A 814, 2008, 144-158.
- [4] P. D. Parker and R. W. Kavanagh, "He-3 (α, γ) Be-7 Reaction," Phys. Rev. 131, 1963, 2578-2582.

Recent Progresses of Heart Attack Prediction in Machine Learning

1st Burcu Bilgin
Computer Engineering
Kocaeli University
Kocaeli, Turkey
burcubilgin2020@gmail.com

2nd Nevcihan Duru
Faculty of Engineering and Natural
Sciences
Kocaeli Health and Technology
University
Kocaeli, Turkey
nevcihan.duru@kocaelisaglik.edu.tr

Abstract—The prediction of heart attack is one of the serious causes of morbidity in the world population. Because of its vital importance, heart attack prediction is a challenging problem that has attracted the attention of both healthcare professionals and computer scientists. In order to create an effective prediction model, obtaining smart information from electronic health data and the use of smart learning models with developing technology have gained momentum in recent years and expanded the solution boundaries. Our motivation for this study is to shed light on researchers in the field by examining studies on machine learning and deep learning models for heart attack prediction.

Keywords—Heart Attack, Myocardial Infarction (MI), Acute Myocardial Infarction (AMI), Prediction, Machine Learning.

I. INTRODUCTION

The heart, which is the main organ of the human body, plays the most important role in the circulatory system by pumping blood throughout the body through the vessels in the circulatory system. The circulatory system is the most important part of our body, as it is responsible for the transport of blood, which carries food, oxygen, water, minerals and other important substances to our entire body. If the heart's work is impaired for any reason and not working properly, it can lead to serious health problems such as death.

The World Health Organization (WHO) states that heart disease is the #1 cause of death worldwide. Worldwide, approximately 17.9 million people die from heart disease each year, representing 32% of global deaths. 85% of these deaths occur due to heart attack and stroke [1].

According to the data of the Turkish Statistical Institute (TUIK), the leading cause of death in Turkey is circulatory system diseases. Circulatory system diseases 39.8% in 2009, 37.9% in 2012, 39.6% in 2013, 40.0% in 2014, 40.1% in 2015, 39.5% in 2016, with 39.5% in 2017, 37.8% in 2018 and 36.8% in 2019, it is at the top of all causes of death. According to 2019 statistics, 39.1% of deaths due to circulatory system diseases are caused by ischemic heart disease, 25.7% by other heart diseases, 22.2% by cerebrovascular disease and 7.9% by hypertensive diseases [2].

A heart attack, called myocardial infarction (MI) or Acute myocardial infarction (AMI), is one of the most serious diseases in the cardiovascular disease segment. The heart muscle needs oxygen to survive. A heart attack occurs when the blood flow that carries oxygen to the heart muscle is severely reduced or cut off completely. This disease is preventable at the initial stage, but it can lead to serious

health problems and in the worst case, even death, as it prevents rapid and early treatment.

Symptoms vary between people and gender; As in men, the most common heart attack symptoms in women are chest pain (angina) or discomfort. However, women are slightly more likely than men to experience other common symptoms, particularly shortness of breath, nausea/vomiting, and back or jaw pain. In addition, there are a few other symptoms to watch out for, such as pain in the chest or arms that may radiate to the neck, nausea, abdominal pain, cold sweat, fatigue, dizziness or sudden pain [3].

Risk factors can be categorized by environmental, lifestyle, or genetic predisposition. The most common risk factors include age and gender (men aged 45 and over and women aged 55 and over), smoking, excessive use of alcohol or caffeine, substance abuse, stress, diabetes, obesity, high blood pressure, family history of heart attack (if your family has had an early heart attack - up to age 55 for men and age 65 for women) and lack of physical activity may be noted [3].

Our focus in our study is to contribute to the roadmaps of researchers by examining the studies directed by artificial intelligence on heart attack prediction in recent years.

II. BACKGROUND

Today, many healthcare organizations use information systems to collect patient data and manage diseases. These systems generate large amounts of data. Transforming this data into intelligent medical diagnoses and clinical decisions is invaluable. Supporting field knowledge of healthcare professionals can significantly increase the quality and speed of clinical decisions. The use of Artificial Intelligence, Machine Learning and Deep Learning technologies, which have an important role and advantage with the increasing momentum in the health sector, can lead in this field.

A. Machine Learning and Deep Learning

Artificial intelligence can be called the ability of a computer program to imitate the human brain by developing intelligence. It gives computers the ability to think, which makes them smarter. The idea of creating an artificial machine is as old as the invention of the computer. In the early 1950s, Alan Turing proposed the Turing test, designed to assess whether a machine can be described as intelligent. Artificial Intelligence is based on the principle that the machine tries to imitate and execute tasks from the simplest to the more complex ones using human intelligence [4].

Machine Learning can be called a subdivision of Artificial Intelligence where the program learns through data or input. It is a highly reliable tool for processing complex data as well as providing simple user-friendly analysis. It also ensures that ambiguities are minimized in the context of classifying large numbers of complex and interrelated data. According to one estimate, machine learning could be an important tool in 38.12% of heart disease-related processes by the end of 2023 [4].

Deep learning is the ability of deep learning to process and analyze large amounts of unstructured data makes it a promising mechanism for predicting diseases in the healthcare industry. It is a much better method than its counterparts for the separation and analysis of large volumes of data. The deep learning method is based on supervised learning, and this learning process cannot be used on third category data that are not familiar with the system.

B. Applying Machine Learning in Health Sector

In the health sector, simple statistics such as "What is the gender distribution of patients with myocardial infarction?", "What are the highest risk factors for myocardial infarction?", "What is the average age for myocardial infarction" can be produced using decision support systems. Clinical decision-making is often based on the experience of healthcare professionals, which can lead to undesirable bias, errors and high medical costs, which can directly affect the quality of their care [5].

It is very important to improve this process, especially in time-critical diseases such as heart attacks, which can result in death. Significant advantages that can be achieved by incorporating machine learning and deep learning methods into the process:

- Prediction and optimization of disease using machine learning,
- Obtaining high-accuracy results with data by obtaining real-time data over sensors with wearable technologies that are a part of our daily life,
- Saving time and cost by offering deep learning methods and semantic approaches in clinical decisions made by field experts,
- Developing knowledge about the field by combining with decision support systems for analysis in disease research and treatment stages.

III. OVERVIEW

A. Search Strategy

46 resources were collected in line with the criteria set in Google Scholar. Search criteria:

- Keywords: Heart attack prediction, machine learning in heart attack prediction, deep learning in heart attack prediction, etc.
- Language: Turkish and English
- Period: 01.01.2020 - 31.10.2022

B. Related Works

The general information of the reviewed studies is listed in Table 1. More detailed explanations about some of the studies are given below.

[5] presents a method to investigate the factors affecting heart attacks by using the recurrent group model of the data processing neural network (Recurrent GMDH Neural Network) over two separate data sets. The results of the

proposed algorithm are compared with PNN, RBF, GRU and LSTM methods on two data sets. The results show that the proposed method outperforms the other four methods with 99% accuracy.

In [16], a novel feature selection and trait sequencing approach is proposed to filter out high-preference traits that help in early detection of heart attack. Since the contribution capacity of different features varies proportionally, a variable feature combination (VCF) algorithm is proposed and probabilistic principal component analysis (PPCA) is applied to improve feature extraction. The predicted feature vectors are analyzed according to their covariance and the vectors with the highest covariance are determined by PPCA. Thus, VCF and PPCA reduce the dimensionality of the data set by overcoming the dimensionality problem. Selected salient features are subjected to multiple linear regression (MLR) and tightly related combinations are identified. They are also passed through radial basis function (RBF) based support vector machines (SVM) for classification. The two classes created by SVM include patients with and without MI. The clinical tests of the patients are taken as a data set for analysis and the performance of the system is measured. Predicted patients and mortality are correlated to measure system performance. The combination of these machine learning algorithms with selected symptoms defines myocardial predictions. The results show that the planned framework is suitable for estimating MIs.

In [28], feature extraction approaches for heart disease prediction and classification using ensemble deep learning are proposed. First, preprocessing was performed using image resizing and contrast enhancement. Afterwards, segmentation was performed using Mask Zone-Based Convolutional Neural Network (RCNN). Segmented result, extracted features using SIFT and ALEXNET. Hybrid Classification was performed with a combination of Random forest and Gaussian Navy Bayes to detect heart attack. In ALEXANET feature extraction method, Gaussian NB produced the most successful result with 91.99%.

In [38], a Highly Random Tree (Extra-Tree) algorithm was applied to identify important attributes and compared different base classifiers and Bagging and Amplification ensemble-based machine learning techniques for early prediction of myocardial infarction. The study shows that, using the relevant features, the Bagging Method with Random Forest base classifier achieves a prediction accuracy of 96.50%, significantly outperforming the result of other ensemble methods.

Table 1: Related Works

	Algorithm(s)	Model Success	Data set(s)	Evaluation Metric(s)
[5]	Proposed model: * Recurrent GMDH neural network	99 %	Custom	Accuracy, Computational time, Precision, Recall,
[6]	Logistic Regression, Naive Bayes, Support Vector Machine, * XGBoost	92 %	UCI Heart Disease	Accuracy, AUC, F1-Score, Precision, Recall, ROC
[7]	* Neural Additive Models, Decision Tree, Logistic Regression, XGBoost, SCORE	87 %	Custom	Accuracy, F-Score

[8]	Artificial Neural Network, * Convolution Neural Network	98 %	UCI Heart Disease	Accuracy, F-Score, Precision
[9]	Decision Tree, * Random Forest	95 %	UCI Heart Disease	Accuracy
[10]	Logistic Regression, Random Forest	-	-	-
[11]	Recurrent Neural Network	92 %	-	-
[12]	Decision Tree, K-Nearest Neighbor, Linear Regression, Naive Bayes, Random Forest	83 %	Custom	-
[13]	-	-	-	-
[14]	Gradient Boosting, * Naive Bayes, K-Nearest Neighbor	94,28 %	UCI Heart Disease	Accuracy, AUC
[15]	* Logistic Regression	87 %	UCI Heart Disease	Accuracy, F1-Score, Precision, Recall
[16]	* Support Vector Machine	94,98 %	Custom	Accuracy
[17]	Artificial Neural Network, Decision Tree, K-Nearest Neighbor, Logistic Regression, Naive Bayes, Random Forest, * Support Vector Machine	85,56 %	UCI Heart Disease	Accuracy, AUC, F-Score, Precision, Sensitivity, Specificity
[18]	Proposed model: *IGS: Integrated genetic algorithm and support vector machine		Custom	Accuracy, AUC, Sensitivity, Specificity, ROC
[19]	* K Nearest Neighbor	72,37 %	Kaggle-Cardiovascular Disease	Accuracy, F1-Score, Precision, Recall
[20]	* Artificial Neural Network, Ensemble learning - AdaBoost, Ensemble learning-baggingvote, K-Nearest Neighbor, Logistic Regression, Naive Bayes, Support Vector Machine	96 %	UCI Heart Disease	Accuracy, F1-Score, Precision, Recall, ROC, Computational time
[21]	Gaussian Naive Bayes, K-Nearest Neighbor, Simple Linear Regression, * RBF Support Vector Machine	80 %	Custom (sensors)	Accuracy
[22]	Multiple Regression Analysis	41,9 %	Kaggle	-

[23]	Delta-Bar-Delta Learning, Levenberg Marquardt Algorithm, * Neural Network - Backpropagation, Quickprop	99,3 %	UCI Heart Disease	Accuracy, Mean Square Error
[24]	* K-Nearest Neighbour, Random Forest	91,8 %	Kaggle-Cardiovascular Disease	Accuracy
[25]	Decision Tree, Logistic Regression, Random Forest, * Gradient Boosting	85,5 %	NIH - Framingham, UCI - Statlog	Accuracy
[26]	Proposed model: * HRFLM (hybrid random forest linear model)	88,7 %	UCI Heart Disease	Accuracy, F1-Score, Precision
[27]	Proposed model: * StackingCVClassifier, Decision Tree, Extreme Gradient Boost, Logistic Regression, Naive Bayes, Random Forest, K-Nearest Neighbour, Support Vector Machine	91 %	-	Accuracy, F1-Score, Precision, Recall
[28]	* Gaussian Naive Bayes, Random Forest	91,99 %	MS COCO, EchoNet Dynamic	Accuracy, F1-Score, Precision, Recall
[29]	Decision Tree, Logistic Regression, * Random Forest, * K-Nearest Neighbour	90 %	UCI Heart Disease	Accuracy
[30]	* Support Vector Machine	83 %	UCI Heart Disease	Accuracy
[31]	Artificial Neural Network, KNN, Decision Tree, * Random Forest, Support Vector Machine, Naive Bayes	98,05 %	UCI Heart Disease	Accuracy, Computational time
[32]	K-Nearest Neighbour, Multilayer Perceptron, * Random forest	-	Custom	ROC, AUC
[33]	K-Nearest Neighbors, Decision Tree, Gaussian Naive Bayes, K-Nearest Neighbors, Logistic Regression, * Random Forest, Support Vector Machine	96 %	Kaggle - Stroke Prediction	Accuracy, AUROC, F1-Score, Precision, Recall

[34]	* Proposed model: Super Learner (Decision Tree + CatBoost), Logistic Regression is a meta learner	98,8 %	UCI Heart Disease, Mendeley - Cardiovascular Disease, Custom	Accuracy, F1-Score, Precision, Recall
[35]	* Decision Tree, Gaussian Naive Bayes, K-Nearest Neighbors, Logistic Regression, Random Forest, Support Vector Machine	90,79 %	UCI Heart Disease	Accuracy
[36]	* Random Forest	80 %	Custom (sensors)	Accuracy
[37]	-	-	Custom (sensors)	Largest average error
[38]	Decision Tree, K-Nearest Neighbor, Naive Bayes, * Random Forest, Support Vector Machine	96,5 %	Custom	Accuracy, Cohen's kappa statistics, F1-Score, Precision, Recall, ROC
[39]	Decision Tree, K-Nearest Neighbors, Logistic Regression, Random Forest, Support Vector Machine	76 %	Custom	Accuracy, F-Score, G-Score, Precision
[40]	* Convolutional Neural Network	75 %	Custom	Accuracy, F1 Score, Sensitivity, Specificity
[41]	-	-	-	-
[42]	* Bagging Trees, Extreme Learning Machines, K-Nearest Neighbors, Logistic Regression, Support Vector Machine	98,89 %	UCI Heart Disease	Accuracy, Sensitivity, Specificity
[43]	* Rule-based decision making	93,33 %	Custom (sensors)	Accuracy, Sensitivity, Specificity
[44]	* Artificial Neural Network	88.51 %	UCI Heart Disease	Accuracy
[45]	* Artificial Neural Network, Decision Tree, Logistic Regression, Random Forest, Support Vector Machine	93,81 %	The PhysioNet - Classification of Heart Sound Recordings, Kaggle - Cardiovascular Disease	Accuracy

Identify applicable funding agency here. If none, delete this text box.

[46]	* Proposed model: Convolutional Neural Network + Long-Short Term Memory	94 %	PTB Diagnostic ECG Database	AUROC, Precision, Sensitivity, Specificity
[47]	* Proposed model: Firefly Algorithm + Convolutional Neural Network	84,84 %	PTB Diagnostic ECG Database	Accuracy, F-Measure, Precision, Recall, Specificity, Sensitivity
[48]	Decision Tree, K-Nearest Neighbor, Naive Bayes	97 %	Custom	Accuracy, Precision, Recall
[49]	* Proposed model: Lasso regression, Multiple Linear Regression, Ridge Regression		Custom	Root Mean Square Error (RMSE)
[50]	Proposed model: Ensemble Driven Neural Network	95,4 %	UCI Heart Disease	Specificity

IV. CONCLUSION

Heart attack is an important cause of illness and death in the world, so diagnosis of this disease is vital. Although significant advances have been made in the diagnosis and treatment of heart attack, more research is needed. Machine learning and deep learning methods can be used to extract useful information from large amounts of data in the healthcare industry.

V. FUTURE WORKS

In the study, the studies that were open to public access on Google Scholar between 2020 and 2022 were systematically examined and presented as main demonstrations to shed light on researchers in this field. In future studies, it is planned to contribute to the field by expanding and elaborating the scope of the study.

REFERENCES

1. [World Health Organization, Cardiovascular Diseases](#), September, 2022.
2. [Turkey Cardiovascular Diseases Prevention and Control Program 2021-2026](#), September, 2022.
3. [Heart Attack, Symptoms and Risk Factors](#), September, 2022.
4. J. A. Perez, F. Deligianni, D. Ravi, and G.-Z. Yang, "Artificial Intelligence and Robotics," pp. 1–56, 2018, [Online]. Available: <https://arxiv.org/ftp/arxiv/papers/1803/1803.10813.pdf>
5. Mehrankia, A., Mollakhalili Meybodi, M.R. and Mirzaie, K., 2022. Prediction of Heart Attacks Using Biological Signals Based on Recurrent GMDH Neural Network. *Neural Processing Letters*, 54(2), pp.987-1008.
6. Nandal, N., Goel, L. and TANWAR, R., 2022. Machine learning-based heart attack prediction: A symptomatic heart attack prediction method and exploratory analysis. *F1000Research*, 11(1126), p.1126.
7. Balabaeva, K. and Kovalchuk, S., 2022. Neural Additive Models for Explainable Heart Attack Prediction. In *International Conference on Computational Science* (pp. 113-121). Springer, Cham.
8. Kumar, A., Rathor, K., Vaddi, S., Patel, D., Vanjarapu, P. and Maddi, M., 2022, August. ECG Based Early Heart Attack Prediction Using Neural Networks. In *2022 3rd International Conference on*

- Electronics and Sustainable Communication Systems (ICESC) (pp. 1080-1083). IEEE.
9. Kumari, P.S. and Vinitha, S., 2022. Heart Attack Prediction in Machine Learning Environment.
10. Rubesh, S., Rajkumar, R., Shyry, S.P., Mayan, J.A. and Jinila, Y.B., 2022, August. Prediction of Heart attack using Supervised Machine Learning Technique. In 2022 3rd International Conference on Electronics and Sustainable Communication Systems (ICESC) (pp. 1516-1520). IEEE.
11. Nuthan, A.C. and Bhoomika, H.R., ANALYSIS OF HEART ATTACK PREDICTION USING VARIOUS PARAMETERS.
12. Kalse, P., Kumbhar, S., Desai, M. and Patil, P.R., Heart Attack Prediction System Using IoT and Machine Learning.
13. Sattaru, N.C., Baker, M.R., Umrao, D., Pandey, U.K., Tiwari, M. and Chakravarthi, M.K., 2022, April. Heart Attack Anxiety Disorder using Machine Learning and Artificial Neural Networks (ANN) Approaches. In 2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE) (pp. 680-683). IEEE.
14. Vyas, G.V.N.D., Pasupureddy, L., Bikkini, P.P., Kenguva, R. and Venkatesh, M.B., HEART ATTACK DETECTION USING MACHINE LEARNING.
15. Elescano-Avendaño, E.A., Huamán-Leon, F.E., Vasquez-Torres, G.A., Ysla-Espinoza, D., Huamán, E.L. and Delgado, A., 2022. Machine Learning Application for Predicting Heart Attacks in Patients from Europe. *International Journal of Advanced Computer Science and Applications*, 13(2).
16. Sulthana, A.R. and Jaithunbi, A.K., 2022. Varying combination of feature extraction and modified support vector machines based prediction of myocardial infarction. *Evolving Systems*, pp.1-18.
17. Πεταρούδας, Μ.Γ., 2022. Comparative analysis of machine learning techniques in predicting heart attacks (Doctoral dissertation, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης).
18. Wu, F.H., Lai, H.J., Lin, H.H., Chan, P.C., Tseng, C.M., Chang, K.M., Chen, Y.F. and Lin, C.S., 2022. Predictive models for detecting patients more likely to develop acute myocardial infarctions. *The Journal of Supercomputing*, 78(2), pp.2043-2071.
19. Bah, I., 2022. KNN Algorithm Used for Heart Attack Detection. *FES Journal of Engineering Sciences*, 11(1), pp.7-19.
20. Waqar, M., Dawood, H., Dawood, H., Majeed, N., Banjar, A. and Alharbey, R., 2021. An efficient SMOTE-based deep learning model for heart attack prediction. *Scientific Programming*, 2021.
21. Sahoo, S., Borthakur, P., Baruah, N. and Chutia, B.P., 2021, August. IoT and machine learning based health monitoring and heart attack prediction system. In *Journal of Physics: Conference Series* (Vol. 1950, No. 1, p. 012056). IOP Publishing.
22. ARSLANKAYA, S. and ÇELİK, M.T., 2021. Prediction of heart attack using fuzzy logic method and determination of factors affecting heart attacks. *International Journal of Computational and Experimental Science and Engineering*, 7(1), pp.1-8.
23. Antar, R.K., ALotaibi, S.T. and AlGhamdi, M., 2021. Heart Attack Prediction using Neural Network and Different Online Learning Methods. *International Journal of Computer Science & Network Security*, 21(6), pp.77-88.
24. Santhi, P., 2021. A survey on heart attack prediction using machine learning. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(2), pp.2303-2308.
25. Gupta, S.K., Shrivastava, A., Upadhyay, S.P. and Chaurasia, P.K., A Machine Learning Approach for Heart Attack Prediction.
26. Kathare, S. and Gaikwad, S., Practicability of Heart Attack Prediction using Machine Learning.
27. Sharma, R., Kumar, A. and Singh, T., HEART ATTACK PREDICTION BY USING MACHINE LEARNING MODELS.
28. Patil, P.B., 2021. Heart Attack Detection Based On Mask Region Based Convolutional Neural Network Instance Segmentation and Hybrid Classification Using Machine Learning Techniques. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(9), pp.2228-2244.
29. Nabeel, M., Awan, M.J., Raza, M., Muslih-Ud-Din, H. and Majeed, S., 2021, November. Heart Attack Disease Data Analytics and Machine Learning. In 2021 International Conference on Innovative Computing (ICIC) (pp. 1-6). IEEE.
30. Madhu, H.K. and Ramesh, D., 2021. Heart attack analysis and prediction using SVM. *International Journal of Computer Applications*, 975, p.8887.
31. Sumana, K.R., Phaneendra, H.D. and Kalpashree, K.S., 2021. Machine Learning and Deep Learning Techniques to Prognosticate Heart Attack in Due of Abnormal Sleep Style.
32. Yuan, P., 2021, September. Research on predicting heart attack through active learning. In 2021 2nd International Conference on Big Data & Artificial Intelligence & Software Engineering (ICBASE) (pp. 12-18). IEEE.
33. Akter, S., Amina, M. and Mansoor, N., Early Diagnosis and Comparative Analysis of Different Machine Learning Algorithms for Myocardial Infarction Prediction. In 2021 IEEE 9th Region 10 Humanitarian Technology Conference (R10-HTC) (pp. 01-06). IEEE.
34. David, V.K., SUPER LEARNER MODEL IN PREDICTION OF HEART ATTACK BASED ON CARDIAC BIOMARKERS.
35. Farooq, N., Nafis, M.T. and Rahman, N., 2021, July. Comparative Analysis of Heart Attack Readmission Using Machine Learning. In *Proceedings of the International Conference on Innovative Computing & Communication (ICICC)*.
36. Mihiranga, A., Shane, D., Indeewari, B., Udana, A., Nawinna, D. and Attanayaka, B., Digital Tool for Prevention, Identification and Emergency Handling of Heart Attacks. In 2021 IEEE 9th Region 10 Humanitarian Technology Conference (R10-HTC) (pp. 1-6). IEEE.
37. Zahra, I.F., Wisana, I.D.G.H., Nugraha, P.C. and Hassaballah, H.J., 2021. Design a Monitoring Device for Heart-Attack Early Detection Based on Respiration Rate and Body Temperature Parameters. *Indonesian Journal of Electronics, Electromedical Engineering, and Medical Informatics*, 3(3), pp.114-120.
38. Hakim, M.A., Jahan, N., Zerín, Z.A. and Farha, A.B., 2021, July. Performance Evaluation and Comparison of Ensemble Based Bagging and Boosting Machine Learning Methods for Automated Early Prediction of Myocardial Infarction. In 2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT) (pp. 1-6). IEEE.
39. Aghazadeh, T. and Bagheri, M., 2021. Investigating myocardial infarction and its effects in patients with urgent medical problems using advanced data mining tools. *arXiv preprint arXiv:2112.07890*.
40. Thanou, D., Senouf, O.Y., Raita, O., Abbé, E., Frossard, P., Aminfar, F., Auberson, D., Dayer, N., Meier, D., Pagnoni, M. and Muller, O., 2021. Predicting future myocardial infarction from angiographies with deep learning (No. CONF).
41. Janani, P., Rani, N.E., Subha, T.D. and Subash, T.D., 2021. Analysis of acute myocardial infarction diagnosis. *Materials Today: Proceedings*, 43, pp.3554-3561.
42. SAYGILI, A., 2020. A novel approach to heart attack prediction improvement via extreme learning machines classifier integrated with data resampling strategy. *Konya Mühendislik Bilimleri Dergisi*, 8(4), pp.853-865.
43. Patel, A., Sahani, P., Saxena, S., Goel, S. and Bhatnagar, V., Myocardial Infarction Detection using Multi Biomedical Sensors.
44. Zheng, S., Heart Attack Prediction with Artificial Neural Network.
45. Mineni, H., 2020. Second heart attack prediction using machine learning and deep learning (Doctoral dissertation, Dublin Business School).
46. Tadesse, G.A., Javed, H., Weldemariam, K. and Zhu, T., 2020, July. A spectral-longitudinal model for detection of heart attack from 12-lead electrocardiogram waveforms. In 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC) (pp. 6009-6012). IEEE.
47. Mamun, M.M.R.K. and Alouani, A., 2020. Diagnosis of STEMI and Non-STEMI Heart Attack using Nature-inspired Swarm Intelligence and Deep Learning Techniques. *Journal of Biomedical Engineering and Biosciences (JBEB)*, 6(1), pp.1-8.
48. Elkahoul, A.H., 2020. Prediction of Myocardial Infarction by Data Mining among Chronic Diseases Patients (UNRWA Clinics in Gaza Strip as A Case Study) عقوت.
49. Reddy, S.S., Sethi, N. and Rajender, R., 2020. Risk Assessment of Myocardial Infarction for Diabetics through Multi-Aspects Computing. *EAI Endorsed Transactions on Pervasive Health and Technology*, 6(24), pp.e3-e3.
50. Gayathri, M.K. and UmaMaheswari, N., A COMPARITIVE STUDY OF MYOCARDIAL INFARCTION PROGNOSIS USING NEURAL NETWORK TECHNIQUES. *European Journal of Molecular & Clinical Medicine*, 7(4), p.2020.

A Performance Comparison of Deep Embedded Clustering Methods on IoT Time Series Data

Ezgi Zorarpacı
Faculty of Aeronautics and
Astronautics
Iskenderun Technical University
Iskenderun, Hatay, Turkey
ezgi.zorarpaci@iste.edu.tr,
ezorarpaci@gmail.com

Abstract— The Internet of Things (IoT) enables the emergence of huge amounts of time series data. Hence, the classification/clustering of time series data is a hot research field in data mining. Deep embedded clustering (DEC) is a novel unsupervised learning algorithm that concurrently devises the feature representations and cluster assignments. In this study, the performance of DEC on IoT time series data is investigated. Therefore, two variants of DEC are considered for the performance assessment on IoT time series data. The first deep clustering algorithm is the original DEC which uses k-means in the clustering layer while the second deep clustering algorithm is DEC using the mean shift method in the clustering layer. In the experiments, nine datasets from the UCR time series classification archive are used. The experimental results reveal that DEC using the mean shift shows better clustering performance than DEC using k-means on IoT time series data when there are enough data samples in the dataset to set apart the clusters. Otherwise, DEC using k-means will be a better choice to perform clustering tasks on IoT time series data.

Keywords—deep clustering, iot, time series clustering, unsupervised learning

I. INTRODUCTION

The Internet of Things (IoT) systems denominate different applications activated and facilitated by sensors, actuators, instruments, and other devices, that are connected with each other [1].

Through the prevalence of IoT, time series have excessively emerged in many fields ranging from engineering, clinical medicine, and biology to climate research and social science. Various time series patterns have been generated and used in applications related to intelligent transportation, political science, population dynamics, banking, marketing, economy, audio and video signals, etc [2-5]. Time series data mining can discover useful patterns and characteristics. Therefore, the classification/clustering of time series data is a hot research field in data mining [5].

With data storage and computing power progress, the increasing interest in machine learning to analyze big data has been viewed [6, 7, 8]. Classification is a prominent research field in supervised machine learning. In classification, the correct class labels must be known to train the algorithms. Time series classification is an issue encountered by researchers from various domains such as physics, medicine, biology, and finance. However, the knowledge discovery in this field has been increasing continuously [6, 9].

As well to supervised machine learning, unsupervised machine learning is another important research field to investigate the data. Unsupervised methods depend merely on similarities in the data, and these methods do not require tagging the training data. Therefore, these techniques are considered when tagged training data or correct class labels are not possible and favorable to appoint [6]. Time series clustering that is an unsupervised machine learning technique aims at exploring groups within the data without utilizing the class labels [6].

Time series clustering has been studied over the past decades and many approaches have been asserted. Some time series clustering approaches [10, 11, 12, 13, 14] based on hierarchical, partitional, model-based, and density-based clustering methods have been proposed. And also, some multi-step methods that emphasize improving algorithms and submitting a new model (generally a hybrid method) to cluster time series data have been suggested [15-31].

According to the literature, most of the previous works of deep clustering methods have focused on vision-based data since the vision-based data are inexpensive and effortless to gather with respect to the sensor-based data [24]. On the other hand, Cisco [32] has predicted that there would be about 14.7 billion IoT devices by 2023, and each of them would produce its own data. As a result, IoT time series data are increasingly important to provide the accomplishment of data-driven applications.

Deep embedded clustering (DEC) [33] is a recent unsupervised algorithm based on a deep neural network (DNN) that concurrently discovers feature representations and cluster appointments. “DEC learns a mapping from the data space to a lower-dimensional feature space in which it iteratively optimizes a clustering objective” [33]. The experimental evaluations have been performed on image and text corpora, and the results show considerable amelioration over state-of-the-art methods that are k-means, local discriminant models and global integration (LDMGI), and spectral embedded clustering (SEC).

Relying on the aforementioned motivations, the clustering performance of DEC on IoT time series data is investigated in this paper. For the performance evaluation, two variants of DEC are considered. The first DEC is the original one which uses k-means clustering method in the clustering layer while the second DEC uses the mean shift clustering method in the clustering layer.

The rest of the paper is organized as follows: In the next section, the basic ideas underlying clustering and

optimization are given for DEC. A detailed description of the datasets and the experimental setup are presented in Section 3. In Section 4, the experimental results are delivered and discussed. At last, the paper is concluded in Section 5.

II. DEEP EMBEDDED CLUSTERING (DEC)

Contemplate the clustering problem of a set of n data points $\{x_i \in X\}_{i=1}^n$ into k clusters and each of cluster centroid which is indicated by $\mu_j, j = 1, 2, \dots, k$. Rather than clustering directly in the data space X , the data is transformed with a non-linear mapping $f_\theta: X \rightarrow Z$, where θ and Z stands for learnable parameters and latent feature space. The dimensionality of Z is smaller than X to refrain from the curse of dimensionality [33, 34]. In order to parameterize f_θ , DNNs are plausible to ensure function approximation and to learn features [33, 35, 36].

DEC performs data clustering by concurrently learning k cluster centroids $\{\mu_j \in Z\}_{j=1}^k$ in the latent feature space Z and the parameters θ mapping data points into the latent space. DEC consists of two stages: (1) parameter initialization with a deep auto-encoder [33, 37] and (2) parameter optimization, that is clustering. In the optimization stage, we compute the target distribution and minimize the Kullback–Leibler (KL) divergence iteratively [33]. The network structure of DEC is illustrated in Fig. 1.




Fig. 1. The network structure of DEC [33].

A. Clustering with KL Divergence

Designated an initial estimation of f_θ and the initial cluster centers $\{\mu_j \in Z\}_{j=1}^k$, the clustering is enhanced by employing an unsupervised algorithm which utilizes the two steps. A soft assignment is calculated between the embedded points and the cluster centers in the first step. The mapping f_θ is updated and the cluster centers are improved by learning from the existing high confidence assignments using additional target distribution in the second step. This operation is reiterated until a termination criterion is reached [33].

a) Soft Assignment: The Student's t-distribution is used as a kernel to specify the similarity between embedded point z_i and the cluster center μ_j . The probability of assigning data sample i to j^{th} cluster (q_{ij}) is formulated in Eq. (1).

$$q_{ij} = \frac{(1 + \|z_i - \mu_j\|^2 / \alpha)^{-\frac{(\alpha+1)}{2}}}{\sum_{j'} (1 + \|z_i - \mu_{j'}\|^2 / \alpha)^{-\frac{(\alpha+1)}{2}}} \quad (1)$$

where $z_i = f_\theta(x_i) \in Z$ and α are the degrees of freedom of the Student's t-distribution [34].

b) KL Divergence Minimization: In DEC, the objective is defined as KL divergence loss between the soft assignments q_i and the additional distribution p_i and formulated as follows:

$$L = KL(P||Q) = \sum_i \sum_j p_{ij} \log \frac{p_{ij}}{q_{ij}} \quad (2)$$

$$p_{ij} = \frac{q_{ij}^2 / f_j}{\sum_{j'} q_{ij'}^2 / f_{j'}} \quad (3)$$

where $f_j = \sum_i q_{ij}$ represents soft cluster frequency. The training strategy adopted in DEC is a variant of self-training [38]. According to the algorithm, an initial classifier and an unlabeled dataset are taken, then the dataset are labeled with the classifier to train by using these high confidence estimations. In each iteration, DEC makes progress by learning from the high confidence predictions, enabling it to ameliorate the low confidence ones.

c) Optimization: In DEC, the cluster centroids $\{\mu_j\}$ and DNN parameters θ are concurrently optimized by employing Stochastic Gradient Descent (SGD) with momentum. With respect to each embedded data point z_i and each cluster center μ_j , the gradients of the error are calculated as:

$$\frac{\partial L}{\partial z_i} = \frac{\alpha+1}{\alpha} \sum_j \left(1 + \frac{\|z_i - \mu_j\|^2}{\alpha}\right)^{-1} \times (p_{ij} - q_{ij}) (z_i - \mu_j) \quad (4)$$

$$\frac{\partial L}{\partial \mu_j} = -\frac{\alpha+1}{\alpha} \sum_i \left(1 + \frac{\|z_i - \mu_j\|^2}{\alpha}\right)^{-1} \times (p_{ij} - q_{ij}) (z_i - \mu_j) \quad (5)$$

The gradients of the embeddings are presented to the DNN and employed to compute the gradients of the DNN parameters θ , i.e. $\partial L / \partial \theta$, to perform standard backpropagation.

B. Parameter Initialization

In this section, how the DNN parameters θ and the cluster centroids $\{\mu_j\}$ are initialized is described. DEC is started with a stacked auto-encoder (SAE) since the latest research has brought into the open that SAEs steadily generate semantically meaningful and discriminative representations of real-world data [33, 37-39]. Consequently, the feature representation learned by SAE inherently makes the learning of clustering representations possible through DEC [34]. Based on the algorithm DEC, SAE is initialized layer by layer and each layer is a denoising auto-encoder trained in order to rebuild the preceding layer's output following a random breakdown [33, 37]. A denoising auto-encoder is a two-layer neural network, and it is defined as:

$$\tilde{x} \sim \text{Dropout}(x) \quad (6)$$

$$h = g_1(W_1 \tilde{x} + b_1) \quad (7)$$

$$\tilde{h} \sim \text{Dropout}(h) \quad (8)$$

$$y = g_2(W_1 \tilde{h} + b_2) \quad (9)$$

where $Dropout(.)$ [40] is a random mapping, which adjusts a certain rate of its input dimensions as 0, g_1 and g_2 are activation functions for encoding and decoding layers, and the DNN parameters $\theta = \{W_1, W_2, b_1, b_2\}$. Training of the model is accomplished by minimizing the least-squares errors $\|x - y\|_2^2$. Following the training of a layer, its output h is used the input for the training of successor layer. In DEC, rectified linear units (ReLUs) [41] are employed in all encoder-decoder pairs except for g_2 of the first pair and g_1 of the last pair. For the first g_2 , it is required to rebuild input data that may have positive and negative values. For the last g_1 , the ultimate data embedding keeps all information. Following the greedy layer-based training, all encoder layers followed by all decoder layers are concatenated to constitute a deep auto-encoder and finetuned to minimize reconstruction error in reverse layer-based training order. As a result, what turns out is a multilayer deep auto-encoder that includes a central bottleneck coding layer. After that, the decoder layers are eliminated and the encoder layers are used for the initial mapping between the data space and the feature space.

For the initialization of the cluster centroids, the data is passed through the initialized DNN to obtain embedded data points, and then, the standard k-means clustering is implemented in the latent space Z to get the initial k centers $\{\mu_j\}_{j=1}^k$.

In this study, as a second DEC algorithm, the mean shift clustering method is used to set the initial cluster centroid instead of k-means clustering employed in original DEC [33]. The mean shift is widely used in real-world data analysis. Also, it's non-parametric and doesn't require any predefined shape of the clusters in the feature space. Therefore, in this paper, a performance comparison of DEC using the mean shift versus DEC using k-means for IoT time series data is presented.

III. EXPERIMENTAL SETUP AND DATASETS

In this study, the commonly used parameters for DNNs are used to avoid dataset specific tuning as much as possible. Therefore, the network dimensions are set to d -500-500-2000-10 for all datasets, where d represents the length of the time series instances in the dataset. In the network, all layers are densely (fully) connected. Each layer is pre-trained for 50000 iterations with a dropout rate of 20%. The entire deep auto-encoder is further fine-tuned for 100000 iterations without dropout. For both layer-wise pre-training and end-to-end fine-tuning of the auto-encoder the mini-batch size is set to 256, starting learning rate is set to 0.1, which is divided by 10 every 20000 iterations, and weight decay is set to 0. For the initialization of the cluster centroids, k-means algorithm is run 20 times and the best solution is used as the initial cluster centroids in the clustering layer [33]. To evaluate the performance of DEC based on the mean shift clustering algorithm, the initial clustering centroids are obtained from the mean shift method instead of k-means in the clustering layer. The implementation is performed using Keras API on Google Colab platform. The GPU dedicated by Google Colab System for the experiments is NVIDIA Tesla T4. The average run time for each dataset is around 2 hours.

TABLE I. DESCRIPTIONS OF THE DATASETS

Dataset	Length	# of Instances	# of Classes
StarLightCurve	1024	9236	3
ECG5000	140	5000	5
Wafer	152	7174	2
FordA	500	4921	2
FordB	500	4446	2
HandOutlines	2709	1370	2
SemgHandGenderCh2	1500	900	2
ProximalPhalanxOutlineAge	80	605	3
ProximalPhalanxOutlineCorrect	80	891	2

In the experiments, nine datasets from the UCR time series classification archive [42] are utilized to evaluate the performances of the deep clustering algorithms. The descriptions of the datasets are given in Table I. According to Table I, the lengths of the time series vary between 80 and 2709, and the numbers of time series instances change between 605 and 9236. At the same time, the numbers of classes of the time series datasets are 2, 3, and 5.

IV. RESULTS AND DISCUSSION

In this section, the clustering performances of the algorithms are given. For the performance comparison, the external clustering metric, i.e. accuracy, is used. In Table II, the clustering accuracies of DEC algorithms using the mean shift and k-means are presented.

TABLE II. PERFORMANCES OF THE DEEP CLUSTERING ALGORITHMS

Dataset	Accuracy (%)	
	DEC using Mean Shift	DEC using K-means
StarLightCurve	81.6%	74.6%
ECG5000	89.7%	71.2%
Wafer	100%	71.6%
FordA	100%	50%
FordB	100%	53.3%
HandOutlines	70%	79.5%
SemgHandGenderCh2	60%	60%
ProximalPhalanxOutlineAge	73%	79%
ProximalPhalanxOutlineCorrect	61.7%	61.5%

From the observed results in Table II, it can be found that DEC based on mean shift achieves better clustering results on IoT time series data than DEC based on k-means in general. DEC using the mean shift produces satisfactory clustering accuracies on the datasets that are Star Light Curve, ECG 5000, Wafer, Ford A, and Ford B.

On the other hand, DEC based on the mean shift can reach maximum clustering accuracies of 73% on the Hand Outlines, Semg Hand Gender Ch2, Proximal Phalanx Outline Age, and Proximal Phalanx Outline Correct datasets.

However, DEC using k-means can achieve maximum clustering accuracy of 79.5% for all datasets. Over the Ford A and Ford B datasets, DEC based on k-means produces unsatisfactory clustering accuracies that are 50% and 53.3% respectively.

On the Seng Hand Gender Ch2 and Proximal Phalanx Outline Correct datasets, DEC using k-means and DEC using the mean shift show the same performances. On the Hand Outlines and Proximal Phalanx Outline Age datasets, DEC using k-means performs better than DEC using the mean shift.

Looking at the descriptions of the datasets in Table I, it can be seen that the datasets Star Light Curve, ECG 5000, Wafer, Ford A, and Ford B contain adequate time series samples to separate the clusters. But, the datasets Hand Outlines, Seng Hand Gender Ch2, Proximal Phalanx Outline Age, and Proximal Phalanx Outline Correct do not include enough instances to set apart the clusters.

When an overall assessment is made based on the experimental results, it can be concluded that if there are enough data samples, DEC based on the mean shift can yield better clustering results compared to DEC using k-means. On the contrary, if the dataset does not have enough instances, DEC based on k-means is a better choice than DEC based on the mean shift for IoT time series data.

V. CONCLUSION

Through the prevalence of IoT, time series have been widely used in many fields ranging from engineering to social science. Time series data mining can discover useful patterns and characteristics. Therefore, the classification/clustering of time series data is a hot research field in data mining. Deep embedded clustering (DEC) is a recent unsupervised algorithm using a deep neural network that simultaneously explores the feature representations and cluster appointments. Motivated by this idea, the performance of DEC on IoT time series data is investigated in this paper. For the performance evaluation, two variants of DEC are considered. The first deep clustering method is the original DEC which is based on k-means, while the second DEC is based on the mean shift clustering algorithm. According to the experimental results, DEC using the mean shift shows better clustering performance than DEC using k-means in general. However, if the dataset does not have adequate samples, DEC based on k-means will be a better choice to perform the clustering tasks on IoT time series data.

REFERENCES

- [1] Y. Guo, T. Ji, Q. Wang, L. Yu, G. Min, and P. Li, "Unsupervised anomaly detection in IoT systems for smart cities," *IEEE Trans. Netw. Sci. Eng.*, vol. 7, no. 4, pp. 2231–2242, 2020.
- [2] M. Krawczak, and G. Szkatuła, "An approach to dimensionality reduction in time series," *Inf. Sci.*, vol. 260, pp. 15–36, 2014.
- [3] G. Yuan, P. Sun, J. Zhao, D. Li, and C. Wang, "A review of moving object trajectory clustering algorithms," *Artif. Intell. Rev.*, vol. 47, no. 1, pp. 123–144, 2017.
- [4] J. Soto, O. Castillo, P. Melin, and W. Pedrycz, "A new approach to multiple time series prediction using MIMO fuzzy aggregation models with modular neural networks," *Int. J. Fuzzy Syst.*, vol. 21, no. 5, pp. 1629–1648, 2019.
- [5] H. Li, J. Liu, Z. Yang, R. W. Liu, K. Wu, and Y. Wan, "Adaptively constrained dynamic time warping for time series classification and clustering," *Inf. Sci.*, vol. 534, pp. 97–116, 2020.
- [6] G. Bode, T. Schreiber, M. Baranski, and D. Müller, "A time series clustering approach for building automation and control systems," *Appl. Energy*, vol. 238, pp. 1337–1345, 2019.
- [7] R. Alfred, "The rise of machine learning for big data analytics," in 2016 2nd International Conference on Science in Information Technology (ICSITech), Balikpapan .
- [8] H. Bangui, M. Ge, and B. Buhnova, "Exploring Big Data Clustering Algorithms for Internet of Things Applications," in *IoTBDs* (pp. 269–276) .
- [9] J. Zakaria, A. Mueen, and E. Keogh, "Clustering time series using unsupervised-shapelets," in 2012 IEEE 12th International Conference on Data Mining (pp. 785–794).
- [10] T. Oates, M. D. Schmill, and P. R. Cohen, "A method for clustering the experiences of a mobile robot that accords with human judgments," in *AAAI/IAAI*, 2000, pp. 846–851.
- [11] J. Beringer, and E. Hüllermeier, "Online clustering of parallel data streams," *Data Knowl. Eng.*, vol. 58, no. 2, pp. 180–204, 2006.
- [12] D. Tran, and M. Wagner, "Fuzzy c-means clustering-based speaker verification," in *AFSS International Conference on Fuzzy Systems*, 2002, pp. 318–324.
- [13] A. Bagnall, and G. Janacek, "Clustering time series with clipped data," *Mach. Learn.*, vol. 58, no. 2, pp. 151–178, 2005.
- [14] S. Chandrakala, and C. C. Sekhar, "A density based method for multivariate time series clustering in kernel feature space," in 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence), pp. 1885–1890.
- [15] S. Aghabozorgi, A. S. Shirkhorshidi, & T. Y. Wah, "Time-series clustering—a decade review," *Inf. Syst.*, vol. 53, pp. 16–38, 2015.
- [16] C. P. Lai, Chung, and V. S. Tseng, "A novel two-level clustering method for time series data analysis," *Expert Syst. Appl.*, vol. 37, no. 9, pp. 6319–6326, 2010.
- [17] S. Aghabozorgi, and Y. W. Teh, "Stock market co-movement assessment using a three-phase clustering method," *Expert Syst. Appl.*, vol. 41, no. 4, pp. 1301–1314, 2014.
- [18] C. Pélat, G. Bouleux, and V. Cheutet, "Improved time series clustering based on new geometric frameworks," *Pattern Recognit.*, vol. 124, pp. 108423, 2022.
- [19] B. Cai, G. Huang, N. Samadiani, G. Li, and C. H. Chi, "Efficient time series clustering by minimizing dynamic time warping utilization," *IEEE Access*, vol. 124, pp. 46589–46599, 2021.
- [20] A. Li, S. Xiong, J. Li, S. Mallik, Y. Liu, R. Fei, ... and G. Liu, "AngClust: Angle feature-based clustering for short time series gene expression profiles," *IEEE/ACM Trans. Comput. Biol. Bioinform.*, 2022.
- [21] W. Hussain, J. M. Merigó, M. R. Raza, and H. Gao, "A new QoS prediction model using hybrid IOWA-ANFIS with fuzzy C-means, subtractive clustering and grid partitioning," *Inf. Sci.*, vol. 584, pp. 280–300, 2022.
- [22] S. Pasupathi, V. Shanmuganathan, K. Madasamy, H. R. Yesudhas, and M. Kim, "Trend analysis using agglomerative hierarchical clustering approach for time series big data," *J Supercomput.*, vol. 77, no. 7, pp. 6505–6524, 2021.
- [23] B. Lafabregue, J. Weber, P. Gançarski, and G. Forestier, "End-to-end deep representation learning for time series clustering: a comparative study," *Data Min. Knowl. Disc.*, vol. 36, no. 1, pp. 29–81, 2022.
- [24] L. M. Dang, K. Min, H. Wang, M. J. Piran, C. H. Lee, and H. Moon, "Sensor-based and vision-based human activity recognition: A comprehensive survey," *Pattern Recognit.*, vol. 108, pp. 107561, 2020.
- [25] Y. Djenouri, D. Djenouri, A. Belhadi, G. Srivastava, and J. C. W. Lin, "Emergent deep learning for anomaly detection in internet of everything," *IEEE Internet Things J.*, 2021.
- [26] A. C. Onal, O. B. Sezer, M. Ozbayoglu, & and E. Dogdu, "MIS-IoT: Modular intelligent server based internet of things framework with big data and machine learning," in 2018 IEEE International Conference on Big Data (Big Data), pp. 2270–2279.
- [27] Y. Tang, Y. Xie, X. Yang, J. Niu, and W. Zhang, "Tensor multi-elastic kernel self-paced learning for time series clustering," *IEEE Trans. Knowl. Data Eng.*, vol. 33, no. 3, pp. 1223–1237, 2019.

- [28] G. Anand, and R. Nayak, "DeLTa: Deep local pattern representation for time-series clustering and classification using visual perception," *Knowl Based Syst.*, vol. 212, pp. 106551, 2021.
- [29] Q. Wang, Y. Guo, L. Yu, X. Chen, and P. Li, "Deep Q-network-based feature selection for multisourced data cleaning," *IEEE Internet Things J.*, vol. 8. no. 21, pp. 16153-16164, 2020.
- [30] N. Tavakoli, S. Siami-Namini, M. Adl Khanghah, F. Mirza Soltani, and A. Siami Namin, "An autoencoder-based deep learning approach for clustering time series data," *SN Appl. Sci.*, vol. 2. no. 5, pp. 1-25, 2020.
- [31] H. Y. Teh, I. Kevin, K. Wang, and A. W. Kempa-Liehr, "Expect the unexpected: unsupervised feature selection for automated sensor anomaly detection," *IEEE Sens. J.*, vol. 21. no. 16, pp. 18033-18046, 2021.
- [32] Cisco, "Cisco annual Internet report (2018-2023)," Cisco Syst., San Jose, CA, USA, White Paper 11-741490, 2020. [Online]. Available: <https://www.cisco.com/c/en/us/solutions/collateral/executiveperspectives/annual-internet-report/white-paper-c11-741490.html>.
- [33] J. Xie, R. Girshick, and A. Farhadi, "Unsupervised deep embedding for clustering analysis," in *International Conference on Machine Learning*, pp. 478-487, 2016.
- [34] R. Bellman, *Adaptive Control Processes: A Guided Tour*. Princeton University Press, Princeton, New Jersey, 1961.
- [35] K. Hornik, "Approximation capabilities of multilayer feedforward networks," *Neural Netw.*, vol. 4. no. 2, pp. 251-257, 1991.
- [36] Y. Bengio, A. Courville, and P. Vincent, "Representation learning: A review and new perspectives," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 35. no. 8, pp. 1798-1828, 2013.
- [37] P. Vincent Pascalvincent, L. Laroché, and H. S. D. Autoencoders, "Learning Useful Representations in a Deep Network with a Local Denoising Criterion Pierre-Antoine Manzagol," *J. Mach. Learn. Res.*, vol. 11, pp. 3371-3408, 2010.
- [38] G. E. Hinton, and R. R. Salakhutdinov, "Reducing the dimensionality of data with neural networks," *Science*, vol. 313, no. 5786, pp. 504-507, 2006.
- [39] Q. V. Le, "Building high-level features using large scale unsupervised learning," in *2013 IEEE international conference on acoustics, speech and signal processing*, pp. 8595-8598.
- [40] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," *J. Mach. Learn. Res.*, vol. 15, no. 1, pp. 1929-1958, 2014.
- [41] V. Nair, and G. E. Hinton, "Rectified linear units improve restricted boltzmann machines," in *ICML*.
- [42] https://www.cs.ucr.edu/~eamonn/time_series_data/

İnsan Vücudu Termal Görüntülerinin U-Net ile Segmentasyonu

Mahmut ÇEVİK
aivisiontech A.Ş.
Konya, Türkiye
e218221002004@ktun.edu.tr
r

Melike GÖKDEMİR
aivisiontech A.Ş.
Konya, Türkiye
melikegokdemir@outlook.co
m

Ahmet BAYRAK
Selçuk Üniversitesi
Konya, Türkiye
Fztahmet@gmail.com

Murat CEYLAN
aivisiontech A.Ş.
Konya Teknik Üniversitesi
Konya, Türkiye
mceylan@ktun.edu.tr

Özet—Termal görüntüleme son yıllarda gelişen termal kamera teknolojileri ile beraber, birçok farklı sektörde kullanılmaya başlanan bir araçtır. İnsan vücut sıcaklıklarının gösterdiği asimetrik durumların enfeksiyon, enflamasyon gibi çeşitli rahatsızlıkların bir belirtici olduğu bilinmektedir. Bu asimetriklerin belirlenmesi için geliştirilen görüntü işleme yaklaşımlarında insan vücudunun doğru tespit edilmesi ve arka plandan ayırtılabilmesi oldukça önemlidir. Bu çalışmada insan alt ve üst ekstremiteler termal görüntülerinden oluşturulan veri setleri ile U-Net segmentasyon modelleri geliştirilmiştir. Geliştirilen segmentasyon modellerinde alt ekstremiteler için; %86 doğruluk, %93 dice katsayısı ve %72 birleşimlerin kesişimi (IoU), üst ekstremiteler için; %92 doğruluk, %98 dice katsayısı ve %91 birleşimlerin kesişimi (IoU) değerleri elde edilmiştir.

Anahtar kelimeler—termal görüntüleme, segmentasyon, derin öğrenme

I. GİRİŞ

Mutlak sıfır derecenin üzerindeki her cisim bir ısıya sahiptir ve bu ısı termal (infrared) enerji yaymaktadır [1]. Cisimlerin yaydığı bu ısı enerjisi insan gözünün görebileceği görünür bölgeden daha yüksek dalga boyuna sahiptir. İnfrared bölge elektromanyetik spektrumun 780nm – 1mm aralığındaki alan olarak tanımlanmaktadır.

Cisimlerin yaydığı ısı enerjisi ile cisimlerin sıcaklık değerleri doğru orantılı olarak artıp azalmaktadır. Bu ilkeye dayanarak geliştirilen termal görüntüleme/termografi; cisimlerin yaydığı kızılötesi radyasyonun toplanarak renkli görüntüler halinde dijitalleştirilmesi olarak tanımlanmaktadır.

Termografi otonom sürüşe sahip araçlar, tıp, savunma teknolojileri, gibi birçok farklı alanda kullanılmaktadır [2-4]. Termal görüntülerde segmentasyon uygulamaları, özellikle cisimlerin arka plan ile olan sıcaklık farklılıklarının yüksek olduğu durumlar için, en yaygın kullanım tekniklerinden biridir. Termografi ile elde edilen termal görüntülerin RGB görüntülere göre belirli avantajları ve dezavantajları mevcuttur. RGB görüntüler ışığa ve çevre koşullarına fazlasıyla duyarlı oldukları için ışısız ortamlarda ve olumsuz hava koşullarında görüntüleme sorun yaşarken, termal görüntüleme bu durumlardan çok az etkilenmektedir.

Chen ve ark. yapmış olduğu çalışmada en gelişmiş semantik segmentasyon modellerinden biri olan “DeepLabv3” mimarisini tanıtmış, konvolüsyonel filtrelerde görsel alanını artırmayı hedefleyen “atrous” oranlarına yeni bir bakış açısı getirmişlerdir [5]. RGB ve termal görüntüler arasındaki farklılıklardan dolayı RGB görüntüler ile geliştirilmiş segmentasyon modelleri termal görüntülerde yüksek doğruluk göstermemektedir. Bu nedenle termal görüntülerde segmentasyon işlemleri için farklı yaklaşımlar geliştirilmektedir. Li ve ark. termal görüntülerde semantik segmentasyon probleminin araştırıldığı bu ilk çalışmada, Dijital kameraların ışığa çok fazla duyarlı olması durumuna karşı olarak termal görüntüleme ile hem gece hem gündüz alınan görüntülerde semantik segmentasyon için etkili bir çözüm üretmişlerdir [6]. Termal görüntülerden oluşan “SODA” veri seti de bu çalışma sonucunda tanıtılmıştır. Panetta ve ark. sundukları “FTNet” mimarisi ile termal

görüntülerde semantik segmentasyon işlemini, düşük kenar bilgisini birden fazla çözünürlükte yakalanan özellikler ve kenar çözme kılavuzu ile yüksek doğruluk ve düşük hesaplama maliyeti ile gerçekleştirmiştir [7]. Termal görüntülerden oluşan yüksek sayıda etiketli veri bulunduran veri setleri RGB görüntülerden oluşan veri setlerine göre oldukça düşüktür. Kim ve ark. bu durumu göz önünde bulundurarak yüksek sayıda RGB görüntülerle eğitilmiş bir segmentasyon ağından transfer öğrenme gerçekleştiren yer etiketi olmadan RGB ve termal görüntü üzerinde alan uyarlaması yöntemini temel alan denetimsiz bir “MS-UDA” segmentasyon mimarisini geliştirmişlerdir [8].

İnsan vücudunun termal dağılımındaki asimetrikler ile çeşitli enfeksiyon ve enflamasyonlar tespit edilebilmektedir [9]. Termografi invazif olmayan bir görüntüleme yöntemi olduğu için sağlık sektöründe son zamanlarda kullanım alanları artmaya başlamıştır. İnsan yüzey sıcaklığının dağılımındaki asimetriklerin tespit edilebilmesi için termal görüntülerde insan vücudunun arka plan görüntüsünden segmente edilmesine ihtiyaç duyulmaktadır. Kim ve ark. yaptıkları çalışmada diyabetik ayak teşhisinde termal görüntüleme ile asimetri analizi gerçekleştirerek hastalık tiplerinin dereceleri ile sıcaklık asimetriklerinin bağlantısını araştırmış, aynı zamanda ayak görüntülerinin segmentasyonu için hem dijital hem de termal görüntüleri beraber kullandıkları bir “U-Net” segmentasyon modeli geliştirmişlerdir [10].


Bu çalışmada insan vücudunun alt ve üst ekstremiteler termal görüntülerinden oluşturulan iki ayrı veri seti üzerinde U-Net yapay zeka mimarisi ile segmentasyon modelleri geliştirilmiştir. Termal görüntüler “Flir-E75” serisi termal kameralar ile elde edilmiştir. Termal kamera, 0.03°C hassasiyetinde 320x240 boyutunda görüntüler vermektedir.

II. MATERYAL- METOT

A. Veri Seti Oluşturma


Bu bölümde eğitim ve test işlemlerinde kullanılmak üzere insan vücudunun alt ve üst ekstremiteler görüntülerinden oluşan veri setleri ve oluşturulma yöntemleri tanıtılacaktır. Her alt ve üst ekstremiteler için 120şer adet orijinal etiketlenmiş görüntü bulunmaktadır. Bu orijinal görüntüler, “PhotoShop” uygulaması üzerinden insan vücudunun dış çevresi işaretlenip arka plandan ayrılarak ikili (arka plan beyaz, ilgili bölüm siyah olacak şekilde) etiketlenmiş görüntüler haline getirilmiştir. Bu ikili görüntüler segmentasyon hedef görüntüleri olarak kaydedilmiştir.

Alt görüntüler için 3808 adet, üst görüntüler için 4414 adet sentetik veri elde edilmiştir. Veri artırma sürecinde “Albumentations” görme aracı kullanılmıştır [11]. Veri artırma yöntemi olarak parlaklık ayarı, rastgele kırpma, yatayda çevirme ve blurlama işlemleri tercih edilmiştir. Şek. 1’de veri artırma işlemi sonucu örnek termal görüntüleri görülmektedir.



Şek.1. (a) orijinal görüntüden elde edilen (b-c) sentetik veriler (b’de parlaklık, c’de rastgele kırpmalı işlemi uygulanmıştır)

Model eğitimi sürecinde elde edilen sentetik veriler eğitim işleminde, orijinal etiketlenmiş görüntüler ise test işlemlerinde kullanılmıştır. Şek. 2’de etiketlenmiş orijinal termal görüntü örnekleri görülmektedir.




Şek. 2. Üst ekstremite (a-b) ve alt ekstremite (c-d) için örnek görüntüler

B. U-Net Segmentasyon Modeli

Bu bölümde segmentasyon modeli olarak kullanılan U-Net mimarisi tanıtılacaktır. Ronneberger ve ark. tarafından tanımlanan U-Net mimarisi, Almanya’nın Friburg Üniversitesinde biyomedikal görüntü segmentasyonu için geliştirilmiş evrimsel bir sınır ağıdır (ESA) [12]. U-Net mimarisinin en büyük avantajı az veri ile yüksek performans vermesi ve hızlı ağ yapısına sahip olmasıdır.

U-Net bir köprü aracılığı ile bağlanan 4 kodlayıcı ve 4 kod çözücü bloktan oluşan U şeklinde bir kodlayıcı/kod çözücü mimarisidir. Atlama bağlantıları geri yayılım sırasında daha iyi gradyan akışına yardımcı olmaktadır. Böylece ağ daha iyi öğrenmektedir. Kopyalama ve kırpmalı işlemleri sırasında boyutları küçülen ama öznetelik değerleri artan katmanlarda elde edilen bilgilerin resim üzerinde doğru konumlandırılmasını sağlamak için kullanılmaktadır. Çalışma için geliştirilen U-Net segmentasyon modelinin mimarisi Şek. 3’de görülmektedir.




Şek 3. U-Net Segmentasyon Mimarisi

Çıkış katmanındaki parametreler sigmoid aktivasyonu ile 1x1 evriminden geçer. Sigmoid aktivasyon işlevi piksel bazında sınıflandırmayı temsil eden segmentasyon maskesini verir. Eş. 1’de sigmoid fonksiyonu görülmektedir.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

Modelin eğitim aşamasında “Adam” optimizasyon yöntemi kullanılmıştır. Adam optimizasyon yöntemi yüksek boyutlu parametrelere sahip algoritmalar için birinci dereceden gradyanlar içeren hesaplama maliyeti düşük son teknoloji bir stokastik optimizasyon yöntemi olduğu için tercih edilmiştir [13].

Veri ön işleme adımları ile beraber veri setinin oluşum süreci ve model eğitimi şeması Şek. 4’de yer almaktadır.



Şek. 4. Çalışmada önerilen modelin eğitim aşamaları

Etiketlenmiş veriler incelendiğinde segmentasyon çıkış parametrelerinin temelinde piksellerin değerlerinin siyah (0) veya beyaz (1) olma olasılıklarını tahmin eden bir basit ikili sınıflandırma problemi olduğu görülmektedir. Bu sebeple çıkış fonksiyonunda kayıp fonksiyonu olarak “Binary Cross Entropy” tercih edilmiştir. Cross entropy tahmin edilen bir sınıfın olasılıksal doğruluğunun logaritmik ifadesidir. İkili sınıflandırmalarda sınıf etiketleri 0 ve 1 olarak tahmin edildiği için çıkışta üretilen tahmin değerinin kayıp fonksiyonu Eş. 2’de olduğu gibi hesaplanabilir. Eş. 2’de N değeri toplam çıkış noktası sayısı, y_i her çıkış noktasının değerini temsil etmektedir.

$$H(x) = -\frac{1}{N} \sum_{i=1}^N y_i(\log p(y_i)) + (1 - y_i)(\log(1 - p(y_i))) \quad (2)$$

C. Değerlendirme Metrikleri

Semantik segmentasyonda hedef maskelenmiş görüntü ile orijinal maskelenmiş görüntü arasındaki benzerliğin tanımı için birçok değerlendirme metriği geliştirilmiştir. Bu çalışmada veriler üç ayrı metrik ile değerlendirilmiştir.

- Piksel Doğruluğu (Pixel accuracy): Veri etiketlerinin normal dağılım göstermediği durumlarda tercih edilmesi önerilmeyen piksel doğruluğu parametresi, bu uygulamada arka plan ve ilgili alan etiketlerinin normal dağılım göstermesi göz önünde bulundurularak tercih edilmiştir. Tahmin edilen her piksel değerinin doğru tahmin edilip edilmediğinin oransal bir gösterimi olarak tanımlanan piksel doğruluğu parametresinin matematiksel tanımı Eş. 3’de görülmektedir.

$$\text{piksel doğruluğu} = \frac{DP + DN}{DP + DN + YP + YN} \quad (3)$$

Eş. 3 ve Eş. 4’de DP doğru tahmin edilen pozitif sınıfı, DN doğru tahmin edilen negatif sınıfı, YP yanlış tahmin edilen pozitif sınıfı ve YN yanlış tahmin edilen negatif sınıfı temsil etmektedir.

- **Dice Katsayısı:** Semantik segmentasyon uygulamalarında en sık kullanılan metriklerden biri olan dice katsayısında, tahmin edilen alan etiketleri ve orijinal alan etiketlerinin birbirini ne kadar içerdikleri tanımlanmaktadır. Tahmin çıktısının hedef çıktı ile tamamen örtüşmesi durumunda dice katsayısı 1'i, hiçbir örtüşme olmaması durumunda ise dice katsayısı 0 değerini göstermektedir. Dice katsayısının matematiksel ifadesi Eş. 4'de görülmektedir.

$$\text{dice katsayısı} = 2 * \frac{DP}{(DP + YP) + (DP + YN)} \quad (4)$$

- **Birleşimlerin Kesişimi (Intersection over Union (IoU)):** Semantik segmentasyon uygulamalarında en sık kullanılan metriklerden bir diğeri olarak IoU tercih edilmektedir. Dice katsayısında olduğu gibi çıkış değerleri 0 ve 1 aralığında değişmektedir. 0, hedef görüntü ile çıktı görüntüsünün arasında yapısal bir benzerlik olmadığını, 1 ise hedef ve çıktı görüntülerinin tamamen örtüştüğünü göstermektedir. "IoU, iki görüntünün kesişen bölgelerinin örtüşen görüntülerinde ne kadar birbirini kapsadığını tanımlamaktadır. Eş. 5'de IoU metriğinin matematiksel tanımı görülmektedir.

$$IoU = \frac{\text{kesişim bölgesi}}{\text{orijinal etiketli alan} + \text{tahmin edilmiş alan} - \text{kesişim bölgesi}} \quad (5)$$

III. DENEYSEL SONUÇLAR

Alt ve üst ekstremité görüntüleri ile oluşturulmuş 2 ayrı veri seti üzerinde eğitilen U-Net modeli için epoch değeri 200

olarak seçilmiştir. Oluşturulan 2 ayrı model üzerinde ayrı ayrı eğitim işlemi gerçekleştirilmiştir. Eğitilen segmentasyon modellerinin test veri setleri üzerindeki doğruluk değerleri 3 ayrı metrik kullanılarak elde edilmiştir. Alt ve Üst ekstremité için segmentasyon sonuçları Tablo 1'de görülmektedir.

A. Üst Ekstremité Veri Seti İçin Değerlendirmeler:

Üst ekstremité eğitim veri seti 4414 adet sentetik veriden oluşturulmuştur. 120 adet orijinal etiketlenmiş görüntü test seti olarak ayrılmış ve model değerlendirmesinde kullanılmıştır. Test sonuçlarına göre piksel doğruluğu %92.70, ortalama IoU %91.79 ve dice katsayısı değeri %98.87 olarak elde edilmiştir. Şek. 5'de modellerin çıktı görüntüleri yer almaktadır.


B. Alt Ekstremité Veri Seti İçin Değerlendirmeler:

Alt ekstremité eğitim veri seti 3808 adet sentetik veriden oluşturulmuştur. 120 adet orijinal etiketlenmiş görüntü, test seti olarak ayrılmıştır. Test sonuçlarına göre metrik sonuçları piksel doğruluğu için %86.25, ortalama IoU %72.33 ve dice katsayısı için %92.49 olarak kaydedilmiştir.


Ortalama IoU değerinin diğer metrik sonuçlarına göre daha düşük doğruluk değeri gösterdiği dikkat çekmektedir. Alt ekstremité görüntülerinde, kullanılan termal kameranın önceden tanımlanmış sabit ekran görselleri (ortalama ortam sıcaklık değeri, marka amblemi, tarih vs.) bazı görüntülerde vücut bölümleri ile çakıştığı gözlemlenmiştir. Bu noktalarda modelin segmentasyon performansının düştüğü ve bu durumun IoU değerini etkilediği değerlendirilmektedir. Şek. 6'da modellerin örnek çıktı görüntüleri görülmektedir.

Tablo 1: Alt ve Üst Ekstremité İçin Segmentasyon Sonuçları

Veri Seti	Değerlendirme Metrikleri		
	Piksel Doğruluğu (%)	Ortalama IoU(%)	Dice Katsayısı (%)
Üst Ekstremité	92.70	91.49	98.87
Alt Ekstremité	86.25	72.33	93.49



Şek. 5. Üst ekstremité model sonuçları



Şek. 6. Alt ekstremité model sonuçları

IV. SONUÇ

Bu çalışmada alt ve üst ekstremitelerdeki termal görüntülerinin segmentasyonu U-Net ile gerçekleştirilmiştir.

Alt ve üst olarak eğitilen iki ayrı modelde test veri setleri üzerinden alınan sonuçlara bakıldığında alt ekstremiteler için geliştirilen modelde piksel doğruluğu %86.25, ortalama IoU %72.33 ve dice katsayısı %93.49 olarak elde edilmiştir. Üst ekstremiteler için geliştirilen modelde ise piksel doğruluğu %92.70, ortalama IoU %91.49 ve dice katsayısı %98.87 olarak elde edilmiştir. Bu sonuç bu çalışmanın sonucunda elde edilmesi beklenen başarı kriterini karşılamaktadır.

Alt ekstremiteler değerlendirilmelerinde ortalama IoU değerinin diğer metrikler göz önüne alındığında düşük sonuç verdiği görülmektedir.

Sağlık sektöründe hızla ilerleyen değerlendirme modalitelerden biri olan termografi, insan vücudunun sıcaklık dağılımlarının analizi için segmentasyon tekniklerinin geliştirilmesini gerektirmektedir. Bu çalışmada elde edilen sonuçlar, sunulan veri seti ve geliştirilen segmentasyon modellerinin başarısı göz önüne alındığında bu amaç doğrultusunda kullanılabileceğini göstermektedir.

Bu çalışmada U-Net modeli, kısıtlı veri setlerinde yüksek segmentasyon sonuçları elde edilmesini sağladığı için tercih edilmiştir. Termal görüntüleme süreci devam etmekte ve veri seti boyutları artırılabilmektedir. İleride artırılmış veri setleri ile geliştirilecek diğer modellerle de karşılaştırmalar yapılacaktır.

Referanslar

- [1]: J. R. Speakman, S. Ward, "Infrared thermography: principles and applications", Zoology - analysis of complex systems, pp-224-232, 1998
- [2]: Q. Ha, K. Watanabe, T. Karasawa, Y. Ushiku and T. Harada, "MFNet: Towards real-time semantic segmentation for autonomous vehicles with multi-spectral scenes," 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), pp. 5108-5115, 2017
- [3]: A. H. Ornek, M. Ceylan, S. Ervural, "Health status detection of neonates using infrared thermography and deep convolutional neural networks.", Infrared Physics & Technology, Volume 103, 103044, ISSN 1350-4495, 2019
- [4]: A. Akula, R. Ghosh, H. K. Sardana, "Thermal Imaging And Its Application In Defence Systems", AIP Conference Proceedings, 2011,
- [5]: L. C. Chen, G. Papandreou, F. Schroff, H. Adam, "Rethinking Atrous Convolution for Semantic Image Segmentation.", ArXiv abs/1706.05587, 2017
- [6]: C. Li, W. Xia, Y. Yan, B. Luo and J. Tang, "Segmenting Objects in Day and Night: Edge-Conditioned CNN for Thermal Image Semantic Segmentation," in IEEE Transactions on Neural Networks and Learning Systems, vol. 32, no. 7, pp. 3069-3082, July 2021
- [7]: K. Panetta, K. M. Shreyas Kamath, S. Rajeev and S. S. Agaian, "FTNet: Feature Transverse Network for Thermal Image Semantic Segmentation," in IEEE Access, vol. 9, pp. 145212-145227, 2021
- [8]: Y. -H. Kim, U. Shin, J. Park and I. S. Kweon, "MS-UDA: Multi-Spectral Unsupervised Domain Adaptation for Thermal Image Semantic Segmentation," in IEEE Robotics and Automation Letters, vol. 6, no. 4, pp. 6497-6504, Oct. 2021
- [9]: B. F. Jones, "A reappraisal of the use of infrared thermal image analysis in medicine," in IEEE Transactions on Medical Imaging, vol. 17, no. 6, pp. 1019-1027, Dec. 1998

- [10]: D. Bouallal et al., "Segmentation of plantar foot thermal images: application to diabetic foot diagnosis," 2020 International Conference on Systems, Signals and Image Processing (IWSSIP), pp. 116-121, 2020
- [11]: A. Buslaev, V. I. Iglovikov, E. Khvedchenya, A. Parinov, M. Druzhinin, A. A. Kalinin, "Albumentations: Fast and Flexible Image Augmentations." Information. 2020; 11(2):125. <https://doi.org/10.3390/info11020125>
- [12]: O. Ronneberger, P. Fischer, T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation.", International Conference on Medical Image Computing and Computer-Assisted Intervention, pp 234-241, 2015.
- [13]: D. P. Kingma, J. Ba, "Adam: A Method for Stochastic Optimization", CoRR, Dec. 2014.

Mermer Sınıflandırma Problemi İçin Güvenilir Veri Seti Oluşturulması

Burak SEÇKİN
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
0000-0003-1168-4869

Yunis TORUN
Elektrik Elektronik Mühendisliği
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
0000-0002-6187-0451

Rukiye KARAKIŞ
Yazılım Mühendisliği
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
0000-0002-1797-3461

ÖZET— Derin öğrenme (DL: Deep Learning) yöntemleri bir problem, girdi verilerini iç yapısında soyutlayıp çıktılara dönüştürerek öğrenir. Bu sebeple DL sistemlerinin başarısını, verisetinin büyüklüğü, sınıf sayısı, sınıflar arasındaki örnek sayı dengesi ve güvenilir eğitim ve test setlerinin oluşturulması gibi parametreler belirler. Özellikle, uzmanlarca örneklerin yanlış etiketlenmesi, geliştirilen sınıflandırıcının başarısını doğrudan etkiler. Bu çalışma, yanlış etiketlenmiş verilerin DL modelleri ile sınıflandırılmadan önce verisetinden çıkartılarak daha gürbüz bir veriseti oluşturulmasını sağlayacak bir yaklaşım sunmaktadır. Çalışmada, doku analizi problemi benimsenerek 3 farklı mermer sınıfına ait görüntüleri içeren özgün bir veriseti oluşturulmuştur. Geliştirilen sistemde, önce görüntülerin Yerel İkili Örüntü (LBP: Local Binary Pattern) yöntemi ile öznitelikleri elde edilmiş ve ardından bu öznitelikler Oylama Tabanlı Topluluk Sınıflandırıcısı (VEC: Voting Ensemble Classifier) tarafından sınıflandırılarak, üç sınıf için olasılıksal değerleri hesaplanmıştır. Son olarak bu olasılık değerleri, ilk etiket değerleri ile karşılaştırılmış ve farklılık olması durumunda örneğin veri setinde kalması ya da farklı sınıfa atanmasının kararının geliştirilen arayüz kullanılarak uzmanlarca gerçekleştirilmesi sağlanmıştır. Elde edilen sonuçlar, mermer sınıflandırma probleminde yanlış etiketleme probleminin üstesinden gelindiğini göstermiştir.

Anahtar Kelimeler— yanlış etiketlenmiş veri, yerel ikili örüntüler, makine öğrenmesi, oylama topluluk sınıflandırıcısı

I. GİRİŞ

Makine öğrenimi (ML: Machine Learning), mevcut bilgilerden çıkarımlar yapmak ve bu çıkarımlara dayanarak bilinmeyen tahmin etmek için matematiksel ve istatistiksel yöntemleri kullanan bir öğrenme yöntemidir. ML teknikleri, bir problemi veriye dayalı olarak çözer ve farklı ML tekniklerinin bir arada getirilerek toplu karar vermesi, doğru tahmin etme olasılığını artırır. Bir ML modeli oluşturulurken, öğrenmenin performansının test verisi üzerinde tespit edilmesi çok önemlidir [1]. ML literatürü tarandığında, son zamanlarda sınıflandırma/regresyon probleminin çözümü için ML model kullanımında önemli bir artış olduğu gözlemlenmiştir. Hacıfendioğlu'nun yaptığı çalışmada, üç farklı ML modeli kullanılarak glokom hastalığının, bireylerde optik sinir hasarı oluşmadan ve bunun sonucunda körlük gelişmeden erken teşhis edilmesi amaçlanmıştır. Geliştirilen karar-destek sisteminde, destek vektör makineleri (DVM) en iyi performansı elde etmiştir [2]. Kartal yaptığı çalışmada, ML yöntemlerini kullanarak kalp cerrahisi sırasında veya hemen sonrasında hastanın yaşamına yönelik riskleri belirlemeyi

amaçlamıştır [3]. Çalışmada, dört farklı ML modeli kullanılmıştır ve karar ağacı modelinin problemin çözümü için en iyi model olduğu belirlenmiştir [3]. Şeker yaptığı çalışmada, elektroensefalogram (EEG) sinyallerini kullanarak kokuları iyi ve kötü olarak sınıflandırmayı amaçlamıştır. Çalışma da, dört farklı ML modeli kullanılmıştır ve en yüksek performans rastgele orman modeli ile hesaplanmıştır [4]. Torun vd. [5] yaptıkları çalışmada, mermer görüntülerinin kalitesini sınıflandırmak için DVM ve bir derin öğrenme (DL: Deep Learning) yaklaşımı olan AlexNet modellerini kullanmıştır. DVM için giriş öznitelikleri yerel ikili örüntüler yöntemi kullanılarak elde edilmiştir. Ham görüntüler kullanan AlexNet modelinin performansı %99,21 olarak hesaplanırken, DVM modelinin performansı %99,8'dir [5]. Yukarıda verilen örnekler ışığında, bir problemin çözülmesi için farklı ML tekniklerinin analiz edilmesi ve bunların test verileri performansı incelenerek optimum modelin tespit edilmesi gereklidir.

Örneklere dayalı öğrenen bir ML modelinin performansını oluşturulan veriseti belirler. Özellikle, uzmanlarca örneklerin düzgün etiketlenmesi çok önemlidir. Bu çalışmanın odak noktası olan yanlış etiketleme probleminin çözümü için literatürde farklı yaklaşımlar önerilmiştir. Ding vd. [6] verisetinin yanlış etiketlenmesi problemini üç aşamada ele almıştır. Bunlar; gürültüye dayalı algoritmalar, yarı denetimli algoritmalar ve veri ilişkisi tabanlı algoritmalar. Gürültüye dayalı algoritmalar, yanlış etiketlenmiş gürültülü örneklerle eğitilen bir sistemin ezberlemeden öğrenmesinin yollarını incelemektedir. Ancak, bu yaklaşımlar sadece ezberlemeyi engellerken, modellerde kullanılan kayıp/ceza fonksiyonunun gürültülü örneklerle karşı dayanıklı olmalarına katkı sunmamaktadır [6]. Yarı denetimli algoritmalarda, bir DL modeli öncelikle temiz ve gürültülü örnekleri içeren bir veriseti ile eğitilmektedir ve bu modelin ağırlıkları temiz örnekler içeren verisetinin öğrenilmesi için geliştirilen modele transfer edilmektedir. Ancak, gerçek dünya problemlerinin çoğunun çözümü için temiz bir eğitim seti gereklidir [6]. Veri ilişkisi tabanlı algoritmalar ise görüntü-görüntü, görüntü-etiket, etiket-etiket bağımlılıklarını inceleyerek verilerdeki ilişkiyi keşfetmeye çalışır. Sezgisel olarak, örnekler veya etiketler birbirleri ile bağlantılı olduklarından bu ilişkiler verilerden öğrenilebilir [6]. Böylece, veri ilişkisinden yola çıkılarak yanlış etiketlenmiş gürültülü örnekler belirlenebilir. Bu algoritmalarda genel yaklaşım, geliştirilen modelin

gürültülü etiket dağılımını keşfetmesi ve eğitimde bunu dikkate alarak yanlış etiketli örnekleri çıkarması şeklindedir. Ancak, bu eleme stratejisi çok fazla örneğin atılmasına ve DL modelin daha az veriyle eğitilmesinden ötürü problem çözümüne iraksamasına neden olabilir. Bu gerçekler ışığında, Ding vd. [6] geliştirdikleri modelde, bir örneğin yanlış etiketlenme olasılığını tahmin edebilen yeni bir güven değerlendirme modülü sunmuşlardır. Bu modül, DL modelinin softmax sınıflandırma çıktıları yerine tam bağlantı katman çıktılarını kümeleyerek analiz eder. Kümeleme stratejisi, temelde her sınıf için sınıf içi çeşitliliğinin ve alt sınıf yapısının anlaşılmasını sağlar ve böylece model yanlış etiketlenmiş gürültülü örnekleri ayırt edebilir [6]. Xing vd. [7] denetimli ve yarı denetimli öğrenmenin başarısı için gerekli olan etiketli verilerin kalitesini etkileşimli olarak iyileştirmek için t-SNE (t-distributed stochastic neighbor embedding) tabanlı görsel bir analiz yöntemi geliştirmiştir. Önerilen yöntemde, kullanıcı tarafından seçilen güvenilir örneklerin kullanılması sağlanmıştır [7]. Literatürdeki bu çalışmalara göre, geliştirilen modelin, yanlış etiketlenmiş gürültülü örneklerin dağılımını öğrenmesi zordur ve bu durum verisetinden çok fazla örneğin çıkarılması sonucunda modelin performansının düşmesine sebep olmaktadır. Bu sebeple bu çalışma, yarı denetimli bir strateji ile yanlış etiketlenmiş verilerin verisetinden çıkarılması yaklaşımını benimsemiştir.

Bu çalışmada, temelde bir doku analizi problemi olan mermer kalitesinin sınıflandırılması probleminin çözülmesi amaçlanmıştır. Mermer kalitesi, mermerin üzerinde bulunan desenlerin sayısına ve renk değişimlerine bakılarak belirlenir. Gerçek hayatta mermer kalitesinin belirlenmesini, ortamın ışık değişimi, uzmanın çalışma saati ve göz sağlığı gibi etmenler etkilediğinden yanlış etiketleme problemi oluşmaktadır. Bu sebeple çalışmada, DL modellerinin eğitiminde kullanılacak güvenilir bir veri setinin hazırlanması için İkili Örüntü (LBP: Local Binary Pattern) yöntemi ve Oylama Tabanlı Topluluk Sınıflandırıcısı (VEC: Voting Ensemble Classifier) tekniğini içeren bir yaklaşım önerilmiştir.

II. MATERYAL VE METOT

Şekil 1’de mermer kalitesinin belirlenmesinde kullanılacak gürbüz bir verisetinin hazırlanması için önerilen yaklaşımın aşamaları verilmiştir. Geliştirilen yöntemin testi için, 3 farklı kalitede mermer sınıfına ait 72 adet 2 boyutlu 2700 x 1290 çözünürlükte görüntüleri içeren özgün bir veriseti oluşturulmuştur.



Şekil 1. Çalışmada önerilen yaklaşımın akış şeması

Mermer görüntülerinin özneliklerinin çıkarımı için LBP tekniği ve sınıflandırılması içinde VEC yöntemi kullanılmaktadır. VEC sonucunda verisetindeki her bir görüntü için olasılık değerleri (y_{VEC}) hesaplanmaktadır.


Bu değerler, ilk etiketleme değerleri (y_{ilk}) ile karşılaştırılarak yanlış etiketli örnekler tespit edilmektedir. Yanlış etiketleme iki durumda oluşmaktadır. İlk durumda, y_{VEC} değerleri y_{ilk} değerleri ile aynı değildir. İkinci durumda, y_{VEC} olasılık değerleri (Örneğin, $y1_{VEC} = 0.51, y2_{VEC} = 0.01$ ve $y3_{VEC} = 0.48$) birbirine çok yakındır. Son olarak yanlış etiketlendiği tespit edilen örnekler uzmana, geliştirilen kullanıcı arayüzü aracılığıyla gösterilmektedir ve onun kararına göre sınıflandırma sonucu kabul edilmektedir ya da değiştirilmektedir. Böylece, daha gürbüz bir veriseti elde edilmektedir.

A. Yerel İkili Örüntüler (Local Binary Pattern) Yöntemi

He ve Wang tarafından önerilen LBP tekniği, doku analizi ile ilgili problemlerde özellik çıkarımında sıklıkla kullanılan yöntemlerden biridir [8]. Yöntemde, görüntünün her bir piksel değeri 1 ya da 0 ikilik değeri ile etiketlenmektedir. Bunun için öncelikle görüntüdeki her bir piksel, NxN boyutlu bir matrisin merkezine yerleştirilir ve matrisin merkez pikseli ile komşuları arasında saat yönünde “Eş.(1)” de verilen hesaplama gerçekleştirilir.

$$LBP_{p,r} = \sum_{p=0}^{p-1} s(g_p - g_c) 2^p \quad s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1)$$

Burada, g_c merkez pikseli ve g_p ise merkez pikselin komşusunu ifade etmektedir. p ve r ise sırasıyla komşu sayısını ve örnekleme yarıçapını temsil etmektedir. Bu çalışmada Şekil 2’de görüldüğü gibi p ve r değerleri 8 ve 1 olacak şekilde 3x3 boyutlu matris kullanılarak görüntü etiketlenmesi gerçekleştirilmiştir. Burada, öncelikle merkezi piksel ile her bir komşu piksel arasında “Eş. (1)” kullanılarak 1/0 ikilik değeri elde edilir. Ardından, bu ikilik değerler saat yönünde yazılarak ondalık karşılığı hesaplanır. Bu işlem, tüm görüntüdeki pikseller için tekrarlanarak görüntünün LBP değerleri elde edilir. Son olarak, bu LBP değerlerinin histogramı hesaplanarak görüntünün öznelik vektörü hesaplanır [5].



Şekil 2. LBP yönteminin uygulanması [5].

B. Oylama Tabanlı Topluluk Sınıflandırıcısı (Voting Ensemble Classifier)

VEC yöntemi, birden çok ML sınıflandırıcısının sonuçlarını birleştirerek daha yüksek performansla çalışacak bir topluluk sınıflandırıcısı oluşturmayı amaçlamaktadır [9]. VEC’de sınıflandırıcı sonuçlarını birleştirmek için çoğunluk oylama (hard voting) ve ağırlıklı çoğunluklu oylama (soft voting) olmak üzere iki yaklaşım kullanılır. Çoğunluk oylama, sınıflandırıcıların hesapladıkları olasılık değerlerini değerlendirilerek en çok tahmin edilen sınıfı çıktı olarak kabul eder. Ağırlıklı çoğunluklu oylamada ise sınıflandırıcıların her bir sınıf için ürettikleri olasılıkların ortalamaları hesaplanır [10]. Bu çalışmada VEC yönteminde; DVM, K-En Yakın Komşu, Gaussian Sınıflandırıcısı, Karar Ağacı Algoritması, Rastgele Orman Algoritması, Çok Katmanlı Algılayıcı, AdaBoost ve Gaussian Naive Bayes olmak üzere sekiz farklı

ML tekniği kullanılmıştır. VEC’de ML tekniklerinin hesapladığı olasılıklar, ağırlıklı çoğunluklu oylama ile değerlendirilerek çıktı etiketlerin nihai olasılık değerleri elde edilmiştir.

III. UYGULAMA VE TEST SONUÇLARI

Mermer verisetinin gürültülü yanlış etiket içerip içermediğini belirlemek için veri setindeki örneklerin tamamı eğitim ve test ayrıştırılması yapılmadan ML modellerinin eğitiminde kullanılmıştır. Görüntülerden, ilk olarak LBP tekniği kullanılarak öznitelikler elde edilmiştir. Ardından bu öznitelikler, sekiz ML sınıflandırıcı tarafından sınıflandırılmış ve elde edilen olasılık değerleri VEC yöntemi aracılığıyla değerlendirilerek üç sınıf için ortalama olasılık değerleri hesaplanmıştır. Son adımda, her bir görüntü için çıktı olasılık değerleri, ilk etiket değerleri ile karşılaştırılmıştır. Etiketler arasında uyumsuzluk olması durumunda geliştirilen kullanıcı arayüzü ile uzmanın örneği son bir kez değerlendirmesi sağlanmıştır. Bu durumda, uzman ya örneğin etiketini kabul etmekte ya da değiştirerek verisetine eklemektedir.

Tablo 1-3’de VEC yönteminin 3 farklı mermer sınıfı için hesapladığı olasılık sonuçları görülmektedir. Tablo 1-2’de yanlış etiketleme problemi oluşmamıştır. Tablo 3’te ise üçüncü kalite mermer görüntülerinin olasılık değerlerinde etiketleme uyumsuzluğu oluşmuştur. Kalın biçimle işaretlenen örnek için VEC modelinin hesapladığı olasılıklar sırasıyla 0.3041, 0.0625 ve 0.6334 şeklindedir. Örnek için VEC değeri 3. Kalite sınıfı gösterse de hesaplanan olasılık değeri çalışmada belirlenen eşik değerinden ($Th=0.80$) düşüktür. Buradan hareketle ilgili resmin verisetinde kalıp kalmayacağı kullanıcıya Şekil 3’te gösterilen arayüz ile sorulmuştur.

TABLO 1. VERİSETİNDE BULUNAN BİRİNCİ SINIF MERMER GÖRÜNTÜLERİ İÇİN VEC OLASILIK DEĞERLERİ

Orijinal Etiket Değerleri	VEC sonucu		
	K1*	K2*	K3*
1	0,9589	0,0132	0,0279
1	0,8612	0,0575	0,0813
1	0,9550	0,0214	0,0236
1	0,9611	0,0184	0,0205
1	0,9064	0,0426	0,0511
1	0,9493	0,0153	0,0354
1	0,8658	0,0708	0,0634
1	0,9280	0,0168	0,0552
1	0,9392	0,0182	0,0426
1	0,9600	0,0183	0,0217
1	0,9111	0,0332	0,0557
1	0,9694	0,0168	0,0138
1	0,9349	0,0249	0,0402
1	0,9665	0,0216	0,0119
1	0,9631	0,0219	0,0149
1	0,9628	0,0181	0,0192
1	0,9568	0,0251	0,0181
1	0,9122	0,0373	0,0505
1	0,9603	0,0197	0,0200
1	0,9408	0,0179	0,0413
1	0,9611	0,0144	0,0246
1	0,9438	0,0210	0,0352
1	0,9358	0,0274	0,0368
1	0,9374	0,0188	0,0438

*K1: 1. Kalite, K2: 2. Kalite, K3: 3. Kalite

TABLO 2. VERİSETİNDE BULUNAN İKİNCİ SINIF MERMER GÖRÜNTÜLERİ İÇİN VEC OLASILIK DEĞERLERİ


Orijinal Etiket Değerleri	VEC sonucu		
	K1*	K2*	K3*
2	0,0220	0,9382	0,0398
2	0,0950	0,8221	0,0830
2	0,0329	0,9355	0,0316
2	0,0406	0,9277	0,0317
2	0,0266	0,9446	0,0288
2	0,0300	0,9373	0,0327
2	0,0338	0,9436	0,0226
2	0,0289	0,9414	0,0297
2	0,0451	0,9250	0,0299
2	0,0474	0,9236	0,0291
2	0,0390	0,9307	0,0303
2	0,0282	0,9380	0,0339
2	0,0219	0,9428	0,0353
2	0,0355	0,9252	0,0393
2	0,0279	0,9438	0,0283
2	0,0372	0,9334	0,0294
2	0,0216	0,9496	0,0289
2	0,0300	0,9362	0,0338
2	0,0227	0,9481	0,0291
2	0,0287	0,9374	0,0339
2	0,0292	0,9482	0,0225
2	0,0380	0,9378	0,0242
2	0,0230	0,9456	0,0314
2	0,0215	0,9419	0,0366

*K1: 1. Kalite, K2: 2. Kalite, K3: 3. Kalite

TABLO 3. VERİSETİNDE BULUNAN ÜÇÜNCÜ SINIF MERMER GÖRÜNTÜLERİ İÇİN VEC OLASILIK DEĞERLERİ

Orijinal Etiket Değerleri	VEC sonucu		
	K1*	K2*	K3*
3	0.0458	0.0279	0.9263
3	0.0410	0.0200	0.9390
3	0.0227	0.0160	0.9613
3	0.0169	0.0178	0.9653
3	0.0185	0.0184	0.9631
3	0.0263	0.0143	0.9595
3	0.0218	0.0173	0.9609
3	0.0385	0.0191	0.9424
3	0.0225	0.0165	0.9610
3	0.3041	0.0625	0.6334
3	0.0175	0.0157	0.9668
3	0.0616	0.0267	0.9117
3	0.0376	0.0162	0.9462
3	0.0453	0.0248	0.9298
3	0.0342	0.0144	0.9514
3	0.0254	0.0158	0.9588
3	0.0200	0.0192	0.9608
3	0.0298	0.0169	0.9534
3	0.0194	0.0184	0.9622
3	0.0177	0.0174	0.9649
3	0.0760	0.0324	0.8916
3	0.0671	0.0274	0.9055
3	0.0216	0.0286	0.9498
3	0.0207	0.0241	0.9552

*K1: 1. Kalite, K2: 2. Kalite, K3: 3. Kalite



Şekil 3. Uzman için yanlış etiketleme kontrol arayüzü

Şekil 3’de görülen arayüz, uzmana daha önceden ışık ayarları, uzun mesai saatleri gibi sebeplerle yapılan yanlış etiketlemenin düzeltilmesi için olanak sunmaktadır. Buna göre çalışmada, belli bir eşik değeri altında kalan değerler oluşursa bir mesaj kutusu ile uzman uyarılmıştır ve etiketin ilgili sınıfta kalması, doğru sınıfa yönlendirilmesi veya verisetinden tamamen çıkartılması sağlanmıştır.

IV. SONUÇ

Örnekler ve etiketler arasındaki ilişkileri öğrenen DL modellerinin performansını etkileyen unsurlardan biri yanlış etiketlenmiş gürültülü verilerdir. Bu çalışma, mermer sınıflandırma problemini çözecek DL modellerinin performansının artırılması için verisetindeki yanlış etiketlenmiş örneklerin düzeltilmesini amaçlamıştır. Bunun için görüntülerin önce LBP tekniği ile öznelilikleri elde edilmiş ve bunlar VEC ile sınıflandırılarak her bir sınıf için olasılık değerleri hesaplanmıştır. Yanlış etiketlenen örnekler uzmanlarca düzeltilmiştir. Yapılan bu çalışma, mermer kalitesini sınıflandırma sistem projesine entegre bir şekilde çalışacaktır. Ayrıca, önerilen yarı denetimli ML tekniği, gömülü DL uygulamalarındaki olası etiketleme probleminin çözümünde kullanılabilir.

V. TEŞEKKÜR

Bu proje TUBİTAK 1507 KOBİ Ar-Ge Destek Programı (proje no: 7218062) tarafından desteklenmiştir.

KAYNAKLAR

- [1] A. Alan, M. Karabatak, “Veri seti-sınıflandırma ilişkisinde performansa etki eden faktörlerin değerlendirilmesi,” Fırat Üniversitesi Mühendislik Bilimleri Dergisi, vol. 32, no. 2, pp. 531-540, 2020.
- [2] Ş. Hacıfendioğlu, “Makine öğrenmesi yöntemleri ile glokom hastalığının teşhisi,” Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, pp. 62-73, 2012.
- [3] E. Kartal, “Sınıflandırmaya dayalı makine öğrenmesi teknikleri ve kardiyolojik risk değerlendirmesine ilişkin bir uygulama,” Doktora Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, pp. 60-101, 2015.
- [4] M. Şeker, “İyi-Kötü kokular ile ilişkili EMOTIV-EPOC tabanlı EEG kayıtlarının makine öğrenmesi yöntemleri ile sınıflandırılması,” Yüksek Lisans Tezi, Dicle Üniversitesi, Fen Bilimleri Enstitüsü, pp. 2017.
- [5] Y. Torun, M.R. Akbaş, M.A. Çelık, O. Kaynar, “Development a machine vision system for marble classification,” in 2019 27th Signal Processing and Communications Applications Conference (SIU), pp. 1-4, 2019.
- [6] G. Ding, Y. Guo, K. Chen, C. Chu, J. Han, Q. Dai, “DECODE: Deep Confidence Network for Robust Image Classification,” IEEE Transactions on Image Processing, vol. 28, pp. 3752-3765, 2019.
- [7] S. Xiang, X. Ye, J. Xia, J. Wu, Y. Chen, S. Liu, “Interactive Correction of Mislabeled Training Data,” in 2019 IEEE Conference on Visual Analytics Science and Technology (VAST), pp. 57-68, 2019.
- [8] D.C. He, L. Wang, “Texture unit, texture spectrum, and texture analysis,” IEEE transactions on Geoscience and Remote Sensing, vol. 28, no. 4, pp. 509-512, 1990.
- [9] C. Qi, X. Tang, “A hybrid ensemble method for improved prediction of slope stability,” International Journal for Numerical and Analytical Methods in Geomechanics, vol. 42, no. 15, pp. 1823-1839, 2018.
- [10] K. Akyol, A. Karaci, “Diyabet hastalığının erken aşamada tahmin edilmesi için makine öğrenme algoritmalarının performanslarının karşılaştırılması,” Düzce Üniversitesi Bilim ve Teknoloji Dergisi, vol. 9, no. 6, pp. 123-134, 2021.

Derin Öğrenme Tabanlı Güç Yükselteç Modülü Kazanç Kalibrasyonu

Ahmet Buğra UĞUR
Elektrik - Elektronik Mühendisliği
Gazi Üniversitesi
Ankara, Türkiye
abugur@aselsan.com.tr

Özgür ERGÜL
Elektrik - Elektronik Mühendisliği
Gazi Üniversitesi
Ankara, Türkiye
ergul@gazi.edu.tr

Özet—Son yıllarda yapılan çalışmalarda derin öğrenme algoritmalarının kullanım oranının oldukça arttığı dikkat çekmektedir. Bu çalışmada yazılım tabanlı telsizlerde kullanılan güç yükselteç (GY) modülünün kazanç kalibrasyonunun maliyetine odaklanılmıştır. Güç yükselteç (GY) modülünün istenilen kazancı elde etmesi için şartlara göre farklı toleransları olan pasif bileşenlerin çeşitli durumlar için kalibre edilmesi gerekmektedir. Ancak bu kalibrasyon geleneksel yöntemlerle oldukça zaman aldığı için bu çalışmada derin öğrenme tekniklerinden Çok Katmanlı Algılayıcılar (MLP) ve Konvolüsyon Sinir Ağları (CNN) yöntemi üçüncü parti yazılım olan AX platformu ile kullanılarak yeni bir kalibrasyon yöntemi önerilmiştir ve iki yöntemin performans karşılaştırılması yapılmıştır. Güç yükselteç modülünün kazanç kalibrasyonu tahmini performans sonuçları her iki yöntem ve her iki veri seti için karşılaştırılmıştır. Yapılan çalışmalar sonucunda en iyi sonuç %1.07 hata payı ile akım verisini içeren veri setinin MLP algoritması ile kullanımı sonucunda elde edilmiştir.

Anahtar Kelimeler—Derin Öğrenme, Çok Katmanlı Algılayıcılar (MLP), Konvolüsyon Sinir Ağları (CNN)

I. GİRİŞ

Güç yükselteç modülleri iletişim alanında kullanılan ve yüksek güç tüketimi gerçekleştiren bileşenlerdir. Bu sebeple tasarım modellerinde verimliliğin önemi oldukça yüksektir [1, 2]. Güç yükselteç modülü üretiminde tüm güç yükselteçlerinin belirli bir doğrulukla iyi tanımlanmış özelliklere sahip olması istenir. Ancak süreç varyasyonları sebebiyle özellikler ve transfer özellikleri modülden modüle değişir. Kazanç ve doğrusal olmama hataları, güç yükselteç modülü karakterize edildiğinde transfer fonksiyonunda ortaya çıkan en yaygın hatalardır. Bu nedenle güvenilir bir güç yükselteç modülü üretebilmek için kazanç kalibrasyon işlemi yapılması ve modüle özgü bu verilerin modül üzerinde bir hafızada tutulması gerekmektedir. Bu kalibrasyon işleminin zaman maliyetinin yüksek olmasından dolayı da bunun nasıl daha optimize ve maliyetsiz yapılabileceği bir araştırma alanı olarak karşımıza çıkmaktadır. Güç yükselteç modüllerinin kalibrasyon sırasında ayarlanması gereken parametreler nedeniyle geleneksel kalibrasyon yöntemi zaman maliyeti açısından yüksek ve uygulama açısından da zorlu olmaktadır. Bu zorlu süreci daha kolay hale getirebilmek adına hem tablosal hem de zaman serisi veriler için çeşitli derin öğrenme yöntemleri sunulmuştur [3, 4].

Son yıllarda, yapay zeka üzerinde yapılan araştırmalar sonucunda makine öğrenmesine bağlı olarak yapay zekanın alt dallarından biri olan derin öğrenme adıyla yeni bir alan ortaya çıkmıştır. Derin öğrenme modelinin çalışma yöntemi insan beyninde yer alan sinir ağı yapısına benzetilmektedir. Bu modeller belirli bir veri seti ile eğitimi sonrasında oldukça karmaşık problemlerin çözümünü hızlandırdığı için

günümüzde yaygın olarak kullanılmaktadır [5]. Yapılan son çalışmalarda ise elde edilen hesaplama hızı ve derin öğrenme sinir ağı algoritmalarında kat edilen gelişim ile işlem sürelerini kayda değer şekilde azaltılmış ve derin öğrenme modellerinin doğruluğu artırılmıştır [6].

Derin öğrenme algoritmaları olan Çok Katmanlı Algılayıcılar (MLP) ve Konvolüsyon Sinir Ağları (CNN) regresyon tahmin problemlerinde sıkça kullanılmaktadır.

MLP tabanlı yaklaşımlar çok esnek ve genellikle girdilerden çıktılara bir eşlemeyi öğrenmek için kullanılabilirler. Tablosal veri setleri, sınıflandırma tahmin problemleri ve regresyon tahmin problemleri için kullanılabilirler.

CNN tabanlı yaklaşımlar ise genel olarak uzamsal bir ilişki olan verilerle iyi çalışmaktadır. Bu da modelin görüntülerle çalışırken önemli olan değişken yapıların konumunu ve ölçeğini öğrenmesini sağlar. Ayrıca CNN girişi geleneksel olarak iki boyutludur, bir alan veya matristir, ancak tek boyutlu olarak da değiştirilebilir. Bu, CNN'nin daha genel olarak uzamsal bir ilişkisi olan diğer veri türleri üzerinde de kullanılmasına izin verir (Örneğin; bir zaman serisinin zaman adımlarındaki sıralı bir ilişki olması gibi.). Görsel veri setleri, sınıflandırma tahmin problemleri ve regresyon tahmin problemleri için kullanılabilirler. Ayrıca görüntü olmayan veriler için özel olarak geliştirilmemiş olsa da, CNN'ler metin, zaman serisi ve sıralı giriş verilerinin analizinde en son teknolojiye sahip sonuçlar elde edilebilir.

Bu çalışmada yazılım tabanlı radyoda kullanılan güç yükselteç (GY) modülünün kazanç kalibrasyonunun yapılması maliyetine odaklanılmıştır. Güç yükselteç (GY) modülünün sistem çalışırken istenilen kazancı elde etmesi için şartlara göre bazı toleransları olan pasif bileşenlerin çeşitli durumlar için kalibre edilmesi gerekmektedir. Ancak bu kalibrasyon sırasında sıcaklık odasının bir sıcaklıktan diğerine geçme süresi, farklı frekanslar, farklı güçler, bunların kombinasyonlarının ayarlanması ve kalibrasyon algoritmalarında test ve ölçüm cihazlarının sorgu süreleri nedeniyle bu işlem çok zaman almaktadır. Bu çalışmada, derin öğrenme tekniklerinden Çok Katmanlı Algılayıcılar (MLP) ve Konvolüsyon Sinir Ağları (CNN) en iyi hiper parametrelerin otomatik belirlenmesi için üçüncü parti yazılım olan AX Platformu ile birlikte ayrı ayrı kullanılarak derin öğrenme modeli oluşturulmuştur. Oluşturulan modellerin eğitimi ve testlerinde önceden geleneksel güç yükselteç kazanç kalibrasyonu yöntemi ile elde edilen 200 modüle ait iki farklı veri seti kullanılmıştır. Bu veri setleri arasındaki tek fark güç yükselteç modülünün ana güç kaynağından çektiği akım verisini içerip içermemesidir. Oluşturulan iki farklı model aynı veri setinin %75'i ile

eğitilmiştir. Daha sonra hem MLP hem de CNN modellerinin eğitimi sonucunda elde edilen model aynı veri setinin %25'i kullanılarak test edilmiştir. Güç yükselteç modülünün kazanç kalibrasyonu tahmini performans sonuçları her iki yöntem ve her iki veri seti için karşılaştırılmıştır.

Makalenin geri kalanı şu şekilde organize edilmiştir. İkinci bölümde literatürde çeşitli alanlarda yapay zekaya dayalı kalibrasyon konusu ile ilgili daha önce yapılan diğer akademik çalışmalardan bahsedilmiştir. Üçüncü bölümde karşılaştırması yapılan MLP ve CNN modellerinin eğitilmesi için kullanılan veri setlerinden ve onların uygun forma getirilme işleminden, kullanılan MLP ve CNN modellerinden, bu modellerin kullanıma nedenlerinden, bu modellerin eğitimi ve test sürecinden bahsedilmiştir. Dördüncü bölümde ise MLP ve CNN yöntemlerinde eğitim sonucunda elde edilen derin öğrenme modeli ve performans sonuçları ortaya konulmuştur. Beşinci bölüm olan sonuçlar başlığı altında da çalışmanın dördüncü bölümünde elde edilen sonuçlar yorumlanmıştır.

II. LİTERATÜR İNCELEMESİ

Derin öğrenme tabanlı kalibrasyon teknikleri ile ilgili literatürde yapılmış çalışmalardan bazıları aşağıda kısaca anlatılmıştır.

İncelenen birinci çalışmada ele alınan doğrusal olmayan güç yükselteç modellerinde verimliliği arttırmak için ayarın önemli bir mekanizma olduğuna değinilmiştir. Bu çalışmada tasarlanan bir güç yükselteç modülünün doğrusal olmayan çıkış gücü ve verimlilik parametrelerini tahmin edebilmek için bir yapay sinir ağı modeli olan MLP önerilmiştir. 228'lik veri setinin 176'sı eğitim geri kalan 52'si testte kullanılarak önerilen model giriş gücü, drain voltajı ve bias voltajı ile eğitilmiş ve test edilmiştir. Önerilen model ile gerçek değerlere oldukça yakın veriler elde edilmiştir. Test sonucunda tahmin edilen çıkış gücü ve verimlilik parametreleri hata oranları ortalama göreceli hatalara (MRE) göre sırasıyla %0.04 ve %0.23 dur [7].

Diğer bir çalışmada derin öğrenme yapay sinir ağı tekniklerinin mikrodalga ve milimetre dalga radyometre kalibrasyonu üzerinde kullanılabileceğinden bahsedilmiştir. Doğrusal olmama geleneksel yöntemlerle yapılan radyometre kalibrasyonunda oldukça zorlu bir konudur. Bu çalışma ile yapay olarak gürültü dalgası modeli oluşturulan bir Dicke-anahtarlamalı radyometrenin kalibrasyonu için bir derin öğrenme modeli olan MLP önerilerek radyometre anten sıcaklığı tahmini yapılmıştır. Önerilen model gürültülü ve gürültüsüz örnekleriyle radyometre çıkış voltajları ve termistör okumaları kullanılarak eğitilmiştir. Model testleri sonucunda yüksek başarı oranlarıyla anten sıcaklıkları tahmin edilebildiği gözlemlenmiştir [8].

Sensor üretimi ile ilgili bir çalışmada ise hataları azaltmak ve güvenilirliği arttırmak için kalibrasyonun önemli bir adım olduğuna dikkat çekilmiştir. Termistör kalibrasyonu ve ayrıca termistörün offset ve kazanç hatalarını düzeltmek için karma modlu bir makine öğrenmesi model olarak önerilmiştir. Yüksek seviyede 120'lik veri setinin %70'i eğitim, %15'i doğrulama ve geri kalan %15'i testte kullanılarak önerilen MLP modeli sensor çıkış verileri kullanılarak eğitilmiş ve test edilmiştir. Daha sonra elde edilen model elektriksel devrelerle tasarlanmıştır. Hem elektriksel devrelerle tasarlanmış uygulamada hem de yüksek seviye modelin test sonuçları karşılaştırıldığında başarılı sonuçlar elde edilmiştir. Termistörün düzeltme yapılmadan

önceki, yüksek seviye simülasyondaki ve elektriksel devrelerle MLP modelinin entegrasyonundan sonraki ortalama sıcaklık tahmini hatası sırasıyla 12.64, 0.97 ve 1.80 olarak elde edilmiştir [9].

Güç yükselteç modellerinde üzerinde yapılan bir diğer çalışmada doğrusalılık probleminin dijital ön bozulma (DPD) ile üstesinden gelinebileceğinden bahsedilmiştir. Sinir ağlarında giriş ve çıkış arasında ilişkileri daha iyi genellebileceğini savunarak Swish aktivasyon fonksiyonunu kullanarak DPD'ye dayalı bir Derin Sinir Ağı (DNN) derin öğrenme modeli önerilmiştir. Ayrıca Swish aktivasyon fonksiyonunun ReLU ve sigmoid aktivasyon fonksiyonları ile performans karşılaştırması sunulmuştur. Yapılan eğitim ve test süreçleri sonucunda önerilen Swish aktivasyon fonksiyonlu DNN-DPD modelinin sigmoid ve ReLU aktivasyon fonksiyonlu DNN-DPD modellerine göre daha iyi sonuç verdiği gözlemlenmiştir [10].

Anten kalibrasyonu hedefi ile yapılan bir çalışmada faz dizili anten kalibrasyon katsayısının sadece güç ölçümleri kullanılarak bulma üzerinde durulmuştur. Farklı sinyal-gürültü oranlarında dizi çıkışlarındaki faz kalibrasyon katsayılarını tahmin etmek için geleneksel yöntemlerin aksine denetimli derin öğrenme algoritmaları olan CNN ve MLP modelleri birleştirilerek yeni bir model önerilmiştir. Yüksek sinyal-gürültü oranı altında önerilen modelin eğitimi sonrasında elde edilen test sonuçları ortalama kareler hatası (MSE) tekniğine göre geleneksel yöntem ve önerilen model performansları için sırasıyla 51.382 ve 6.52 şeklindedir. Bu sonuçlar ile önerilen modelin geleneksel model yerine kullanılabileceği kararına varılmıştır [11].

Güç sistemlerinin kalibrasyonu ile ilgili çalışmada ise şebeke güvenilirliği, kullanılabilirliği ve esnekliği konuları güç sistemlerinde oldukça önemli olduğuna değinilmiştir. Güç sistemlerinin parametre kalibrasyonunda geleneksel yaklaşımlara dayalı matematiksel çözümlerin sorunu çözerken maliyetli olduğuna bunun yerine derin öğrenmeye dayalı bir yaklaşım önerilmiştir. Çalışmada kullanılacak güç sistemi jeneratör olarak seçilip, simüle edilmiş veriler kullanılarak Konvolüsyon Sinir Ağları (1D-CNN), Uzun Kısa Süreli Bellek (LSTM) ve Kapalı Tekrarlayan Birimler (GRU) derin öğrenme modelleri eğitilip sonrasında test edilmiştir. Elde edilen test sonuçlarına göre derin öğrenme modelleri CNN, LSTM ve GRU'nun performansları sırasıyla 0.017, 0.026 ve 0.0079 ortalama kareler hatası (MSE) şeklindedir. Bu sonuçlar derin öğrenmenin bu alanda kullanılabileceğini gösteren bir umut vadetmiştir [12].

III. MATERYAL VE METOT

A. Veri Setleri

Bu çalışmada veri setinin girdi olarak kullanılacak parametrelerinin ağı eğitimindeki önemine dikkat çekebilmek adına iki adet veri seti ile çalışmalar yürütülmüştür. Bu iki veri setinin birbirinden tek farkı güç yükselteç modülünün ana güç kaynağından çektiği akım verisinin olup olmamasıdır. Ana güç kaynağı akım verisinin güç yükselteç modül kartının PCB karakterizasyonunu temsil etmede önemli bir parametre olabileceği ön görülmektedir.

Yapılan çalışmada veri seti kümesini olabildiğince sınırlı tutarak başarılı bir ağ eğitim performansına ulaşmak hedeflenmiştir. Buradaki amaç prototip ve pilot üretim esnasında geleneksel güç yükselteç kazanç kalibrasyon yöntemiyle toplanabilecek verileri kullanarak ağ

eğitmektedir. Bu kapsamda 200 modüle ait 2 adet farklı veri seti oluşturulması ve oluşturulan 2 farklı veri setinin %75'inin ağı eğitiminde %25'inin ise testinde ayrı ayrı kullanılması hedeflenmiştir.

Birinci veri setinde yer alan parametrelerden kanal/frekans, sürücü bias voltajı, çıkış sürücü voltajı, hedef çıkış gücü ve sıcaklık bilgisi girdi verileri olarak, kazanç verisi ise çıkış verisi olarak ağı eğitiminde kullanılmıştır.

İkinci veri setinde yer alan parametrelerden ise kanal/frekans, ana güç kaynağından çekilen akım, sürücü bias voltajı, çıkış sürücü voltajı, hedef çıkış gücü ve sıcaklık bilgisi girdi verileri olarak, kazanç verisi ise çıkış verisi olarak ağı eğitiminde kullanılmıştır.

B. Kullanılan Modeller ve Kullanılma Nedenleri

Bu çalışmada güç yükselteç kazanç kalibrasyonu probleminin derin öğrenme tabanlı çözümü için iki yöntem önerilmiştir. Bunlardan birincisi Çok Katmanlı Algılayıcılar (MLP) ikinci ise Konvolüsyonel Sinir Ağları (Convolution Neural Network-CNN) şeklindedir. Önerilen her iki model üzerinde çalışmalar yapılmıştır ve elde edilen sonuçlar karşılaştırılarak en başarılı sonuç veren model kullanılmak için seçilmiştir.

MLP yöntemi derin öğrenmede sıklıkla kullanılan klasik bir sinir ağı türüdür. Tablosal veri setleri ile yapılan regresyon tahmin çalışmalarında kullanım başarısını ispatlamış ve oldukça tercih edilen bir yöntemdir. Bu çalışmada geleneksel güç yükselteç kazanç kalibrasyonu yöntemleri ile elde edilmiş veri setleri (birinci veri seti ve ikinci veri seti) incelendiğinde tablosal veri seti formatında olduğu görülmektedir. Ayrıca çözülmesi hedeflenen problem güç yükselteç kazancını tahmin etme bir regresyon problemi. Bilgiler ışığında bu çalışma için MLP modelinin kullanımının uygun olabileceği düşünülmüştür.

CNN yöntemi genel olarak görsel tabanlı çalışmalarda en iyi performansını göstermektedir ve genel olarak iki boyutlu girdi seti ile çalışmaktadır. Ancak bir boyutlu ve üç boyutlu girdi setleri ile de kullanılabilir. Eğer veri setinde uzamsal bir ilişki varsa CNN modeli başarılı bir performans göstermektedir. Bu da girdi verilerinin görsel olmaması durumunda kullanımına olanak sağlamaktadır. Bu çalışmada geleneksel güç yükselteç kazanç kalibrasyonu yöntemleri ile elde edilmiş veri setleri (birinci veri seti ve ikinci veri seti) incelendiğinde veri setlerinin tek boyutlu veri seti olması ve çözülmesi hedeflenen problemin bir regresyon problemi olması gibi sebeplerden dolayı CNN modelinin kullanımının uygun olabileceği düşünülmüştür.

C. Model Eğitimi ve Test Süreci

Eğitim ve test için kullanılacak olan veri setleri hazırlanıp kullanılabilir formata getirildikten sonra derin öğrenme sürecindeki yer alan modelin eğitimi ve testi adımına geçilir. Bu iki aşama için önce eğitim veri setinde eğitim için ayrılan kısım kullanılarak model eğitimi gerçekleştirilir daha sonra elde edilen model veri setinde test için ayrılan kısım kullanılarak test edilir.

Veri seti kullanılarak yapılan model eğitimi oldukça zaman almaktadır ve modelin eğitim kısmında modelin yüksek başarı oranına ulaşabilmesi için belirlenmesi gereken hiper parametrelerin bulunması ise oldukça fazla deneme gerektirmektedir. En iyi sonuç veren modelin elde edilmesi sırasında bu hiper parametreler her probleme ve kullanılan veri setine göre değişiklik göstermektedir. Bu sebeplerden

dolayı bu çalışma ile oldukça fazla deneme gerektiren ve manual deneme işlemi sonrasında bulunmaya çalışılan hiper parametrelerin üçüncü parti bir yazılım olan AX platformu kullanılarak otomatik bir şekilde belirlenmesi hedeflenmiştir. Belirlenen hiper parametre uzayının AX platformu kullanılarak Sobol tekniği ile taranması sonucunda en iyi performansı veren model ve bu modelin hiper parametrelerinin belirlenmesi önerilmiştir. Böylece manuel taramaya göre olasılıklar kümesinde daha eşit bir tarama yaparak en iyi sonuç elde edilmesine olanak sağlanmış olacaktır.

Bu çalışmada kullanılan MLP ve CNN modelleri için ayrı ayrı hiper parametre uzayı oluşturulmuş ve her iki modelin kendisi için belirlenen hiper parametre uzayları taranarak birinci ve ikinci veri setleri ile eğitim sürecini ayrı ayrı tamamlamıştır. Daha sonra eğitim sonrasında elde edilen en başarılı modeller test edilmiştir.

Belirlenen hiper parametre uzayları üçüncü parti Ax platformu yazılımı tarafından hiper parametrelerin bulması için model eğitimi sırasında kullanılmaktadır. Bu hiper parametre uzayı taraması için gerçekleştirilecek deneme sayısı belirlenebilmektedir. Bu döngü sayısının çok fazla olması eğitim süresini çok fazla uzatmaktadır ancak döngü sayısının çok az tutulması ise en iyi performansı verecek hiper parametrelerinin bulunması olasılığını düşürerek model başarısını olumsuz etkilemektedir. Yapılan çalışmada bu döngü sayısı 100 olarak belirlenmiştir. Yapılan tüm eğitim çalışmalarında bu döngü sayısı sabit tutulmuştur.

Ax platformu kullanılarak birinci ve ikinci veri seti ayrı ayrı kullanılarak yapılan MLP ve CNN modellerinin eğitimi çalışması sonucunda elde edilen en uygun model ve modele ait hiper parametreler elde edilmiştir.

Birinci ve ikinci veri setine ait veriler ayrı ayrı olacak şekilde %75'i eğitim ve %25'i testte kullanılmak için ayrılmıştır. Model eğitimi sırasında eğitim veri setinin %80'i eğitimde geri kalan %20'si ise model doğrulama işleminde kullanılacak şekilde bölünmüştür. Eğitim adım sayısı (epoch number) geniş bir hiper parametre uzayı taranacağı için seçilen hiper parametreler sonrasında yavaş öğrenme durumunu da kapsamı adına 1000 olarak belirlenmiştir. Eğitim sırasında kullanılan kayıp fonksiyonu ise ortalama mutlak yüzde hata (Mean Absolute Percentage Error - MAPE) fonksiyonu olarak belirlenmiştir. Model testi sonuçları ise 3 farklı tip kayıp fonksiyonu kullanılarak sunulmuştur. Bunlar ortalama mutlak yüzde hata (Mean Absolute Percentage Error - MAPE), hata kareler ortalaması (Mean Squared Error - MSE) ve hata kareler ortalamasının karekökü (Root Mean Squared Error - RMSE) fonksiyonlarıdır. Tüm bu düzenlemeler sonrası belirlenen hiper parametre uzayı taranarak gerçekleştirilen eğitim sonrasında en iyi model elde edilmiş ve bu modele ait hiper parametreler elde edilmiştir.


Her iki veri setinin eğitim verileri ile MLP ve CNN modellerinin eğitim işlemi ayrı ayrı yapıldıktan sonra modeller yine her iki veri setinin test verileri kullanarak test edilmiştir. Elde edilen sonuçların sunumu "IV. Bulgular" bölümünde paylaşılmıştır.

IV.BULGULAR


Önerilen derin öğrenme metodu olan MLP ve CNN modelleri her iki veri seti için ayrı ayrı eğitilip test edilmiştir. Yapılan çalışmalar sonucunda elde edilen sonuçlar bu bölüm altında paylaşılmıştır.

MLP derin öğrenme yöntemi kullanılarak birinci ve ikinci veri setleri ile yapılan model eğitimi sırasında eğitim adım sayısına (epoch number) göre test ve eğitim sırasındaki kayıp sırasıyla grafik Şekil 1 ve Şekil 2’de gösterilmiştir.

Şekil 1 ve Şekil 2’de yer alan grafikler incelendiğinde ilk 500 eğitim adım sayısından (epoch number) sonra öğrenmenin yavaşladığı ve neredeyse tamamlandığı gözlemlenmiştir. Ax platformu ile geniş bir hiper parametre uzayı taranacağı için seçilen hiper parametreler sonrasında yavaş öğrenme durumunu da kapsaması adına 1000 olarak seçilmesi uygun öngörülen eğitim adım sayısının (epoch number) MLP modeli için oldukça yeterli olduğu gözlemlenmiştir.



Şekil 1. Birinci veri seti ile eğitim adım sayısı bazında MLP modelinin hem eğitim hem de test prosedürünün kayıp grafiği.



Şekil 2. İkinci veri seti ile eğitim adım sayısı bazında MLP modelinin hem eğitim hem de test prosedürünün kayıp grafiği.

Eğitim verileri ile eğitimi tamamlanan modelin test verileri ile test edilmesi sonucu elde edilen ortalama mutlak yüzde hatasına (Mean Absolute Percentage Error - MAPE), hata kareler ortalamasına (Mean Squared Error - MSE) ve hata kareler ortalamasının kareköküne (Root Mean Squared Error - RMSE) karşılık gelen değerler sırasıyla Tablo 1’de ve Tablo 2’de sunulmuştur.

Hata Değeri	GY Kazanç Hata Oranı
Ortalama Mutlak Yüzde Hatasına (Mean Absolute Percentage Error - MAPE) %	1.28
Hata Kareler Ortalamasına (Mean Squared Error - MSE) %	0.02
Hata Kareler Ortalamasının Kareköküne (Root Mean Squared Error - RMSE) %	1.40

Tablo 1. Birinci veri seti ile önerilen MLP modelinin test sonuçları


Hata Değeri	GY Kazanç Hata Oranı
Ortalama Mutlak Yüzde Hatasına (Mean Absolute Percentage Error - MAPE) %	1.07
Hata Kareler Ortalamasına (Mean Squared Error - MSE) %	0.01
Hata Kareler Ortalamasının Kareköküne (Root Mean Squared Error - RMSE) %	1.16

Tablo 2. İkinci veri seti ile önerilen MLP modelinin test sonuçları


Veri setlerinin tablosal veri seti olmasından ve MLP’nin tablosal veri setlerinde başarısı ispatlanmış bir derin öğrenme tekniği olmasından dolayı MLP algoritması ilk yöntem olarak önerilmiştir. Tablo 1 ve Tablo 2’de yer alan hata oranları incelendiğinde MLP algoritması ile yapılan çalışmada ana akım verisinin de bulunduğu ikinci veri setinin kullanımı birinci veri setinin kullanımına göre modelin tahmin başarısını arttırmıştır. Böylece bu çalışma öncesinde akım verisinin PCB karakterizasyonunu elde etmede ve model eğitiminin başarısını arttırmada önemli bir parametre olabileceği çıkarımı doğrulanmıştır.

CNN derin öğrenme yöntemi kullanılarak birinci ve ikinci veri setleri ile yapılan model eğitimi sırasında eğitim adım sayısına (epoch number) göre test ve eğitim sırasındaki kayıp sırasıyla grafik Şekil 3 ve Şekil 4’te gösterilmiştir.

Şekil 3 ve Şekil 4’te yer alan grafikler incelendiğinde ilk 500 eğitim adım sayısından (epoch number) sonra öğrenmenin yavaşladığı ve neredeyse tamamlandığı gözlemlenmiştir. Ax platformu ile geniş bir hiper parametre uzayı taranacağı için seçilen hiper parametreler sonrasında yavaş öğrenme durumunu da kapsaması adına 1000 olarak seçilmesi uygun öngörülen eğitim adım sayısının (epoch number) CNN modeli için de oldukça yeterli olduğu gözlemlenmiştir.



Şekil 3. Birinci veri seti ile eğitim adım sayısı bazında CNN modelinin hem eğitim hem de test prosedürünün kayıp grafiği.



Şekil 4. İkinci veri seti ile eğitim adım sayısı bazında CNN modelinin hem eğitim hem de test prosedürünün kayıp grafiği

Eğitim verileri ile eğitimi tamamlanan modelin test verileri ile test edilmesi sonucu elde edilen ortalama mutlak yüzde hatasına (Mean Absolute Percentage Error - MAPE), hata kareler ortalamasına (Mean Squared Error - MSE) ve hata kareler ortalamasının kareköküne (Root Mean Squared Error - RMSE) karşılık gelen değerler sırasıyla Tablo 3’de ve Tablo 4’te sunulmuştur.

Hata Değeri	GY Kazanç Hata Oranı
Ortalama Mutlak Yüzde Hatasına (Mean Absolute Percentage Error - MAPE) %	1.21
Hata Kareler Ortalamasına (Mean Squared Error - MSE) %	0.02
Hata Kareler Ortalamasının Kareköküne (Root Mean Squared Error - RMSE) %	1.33

Tablo 3. Birinci veri seti ile önerilen CNN modelinin test sonuçları

Hata Değeri	GY Kazanç Hata Oranı
Ortalama Mutlak Yüzde Hatasına (Mean Absolute Percentage Error - MAPE) %	1.33
Hata Kareler Ortalamasına (Mean Squared Error - MSE) %	0.02
Hata Kareler Ortalamasının Kareköküne (Root Mean Squared Error - RMSE) %	1.47

Tablo 4. İkinci veri seti ile önerilen CNN modelinin test sonuçları

Veri setlerinin tek boyutlu veri seti ve problemin regresyon problemi olması düşünülerek ikinci yöntem olarak CNN algoritması önerilmiştir. Tablo 3 ve Tablo 4’de yer alan hata oranları incelendiğinde CNN algoritması ile yapılan çalışmada ana akım verisinin de bulunduğu ikinci veri seti kullanımı birinci veri seti kullanımına göre modelin tahmin başarısını olumsuz etkilemiştir. Bu da CNN algoritmasının tablosal verilerin büyüklüğü arttıkça performansının azaldığını gözlemlememizi sağlamıştır.

Güç yükselteç kazanç tahmini için önerilen sinir ağı modellerinden MLP ve CNN ile her iki veri seti kullanılarak yapılan çalışmalar sonucunda elde edilen sonuçlar Tablo 1, Tablo 2, Tablo 3 ve Tablo 4’te sunulmuştur. En iyi sonuç

%1.07 hata payı ile ikinci veri setinin MLP algoritması ile kullanımı sonucunda elde edilmiştir. Böylece bu çalışma ile tablosal veri setleri kullanılarak yapılan regresyon tahmin çalışmalarındaki kullanım başarısını literatürde önceki çalışmalarda da ispatlamış olan MLP algoritmasının tablosal veriler üzerindeki başarısının CNN algoritmasına göre daha iyi olduğu gözlemlenmiştir. Bunlara ek olarak CNN algoritmasının eğitim maliyetinin MLP algoritmasının eğitim maliyetine göre daha yüksek olduğu gözlemlenmiştir.

V. SONUÇLAR

Bu çalışmada, farklı sinir ağı modelleri ile güç yükselteç modülü kazanç tahmini için derin öğrenme tabanlı yeni bir kalibrasyon tekniği sunulmaktadır. MLP tabanlı yöntemin ikinci veri seti ile kullanılmasıyla elde edilen sonuçların önerilen diğer derin öğrenme tabanlı yöntemlerden daha iyi olduğu bulunmuştur.

Yapılan bu çalışmayla MLP algoritmasının ikinci veri seti kullanımı ile elde edilen model kullanılarak güç yükselteç modüllerinin kazanç kalibrasyonu yapılması sağlanmıştır.

TEŞEKKÜR

Yazarlar, bu makaleye büyük ölçüde yardımcı olan veri seti, yorumlar, derinlemesine tartışmalar ve ölçüm deneyimleri sağlayan Aselsan A.Ş’ye teşekkür eder.

REFERANSLAR

- Roshani, Saeed, and Sobhan Roshani. "Design of a high efficiency class-F power amplifier with large signal and small signal measurements." *Measurement* 149 (2020): 106991.
- Pirasteh, Ali, Saeed Roshani, and Sobhan Roshani. "A modified class-F power amplifier with miniaturized harmonic control circuit." *AEU-International Journal of Electronics and Communications* 97 (2018): 202-209.
- Han, Zhongyang, et al. "A review of deep learning models for time series prediction." *IEEE Sensors Journal* 21.6 (2019): 7833-7848.
- Borisov, Vadim, et al. "Deep neural networks and tabular data: A survey." *arXiv preprint arXiv:2110.01889* (2021).
- Goodfellow, Ian, Yoshua Bengio, and Aaron Courville. *Deep learning*. MIT press, 2016.
- Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, pp. 436–444, May 2015.
- Jamshidi, Mohammad Behdad, et al. "Using an ANN approach to estimate output power and PAE of a modified class-F power amplifier." *2020 International Conference on Applied Electronics (AE)*. IEEE, 2020.
- Ogut, Mehmet, Xavier Bosch-Lluis, and Steven C. Reising. "A deep learning approach for microwave and millimeter-wave radiometer calibration." *IEEE Transactions on Geoscience and Remote Sensing* 57.8 (2019): 5344-5355.
- Martínez-Nieto, Javier A., et al. "Microelectronic CMOS Implementation of a Machine Learning Technique for Sensor Calibration." *IEEE Access* 8 (2020): 207367-207376.
- Tripathi, Girish Chandra, Meenakshi Rawat, and Karun Rawat. "Swish activation based deep neural network predistorter for RF-PA." *TENCON 2019-2019 IEEE Region 10 Conference (TENCON)*. IEEE, 2019.
- Sarayloo, Zahra, et al. "A Convolutional Neural Network Approach for Phased Array Calibration Using Power-Only Measurements." *2020 28th Iranian Conference on Electrical Engineering (ICEE)*. IEEE, 2020.
- Wshah, Safwan, et al. "Deep learning for model parameter calibration in power systems." *2020 IEEE International Conference on Power Systems Technology (POWERCON)*. IEEE, 2020.

Network Lifetime Maximization in Smart Farming by using an Improved Ant Colony Optimization Algorithm and Solar Energy Harvesting

1st Sara Khernane

Department of Computer Science
LAMIE Laboratory, University of
Batna 2

Batna, Algeria

sara.khernane@univ-batna2.dz

2nd Souheila Bouam

Department of Computer Science
LAMIE Laboratory, University of
Batna 2

Batna, Algeria

s.bouam@univ-batna2.dz

3rd Chafik Arar

Department of Computer Science
LAMIE Laboratory, University of
Batna 2

Batna, Algeria

chafik.arar@univ-batna2.dz

Abstract— The agricultural sector is one of the most important sectors in the world. Because of its impact on the country's economy, therefore, integrating smart farming is necessary in this sector by giving great importance to scientific research specialized in the field of agriculture. Smart farming takes into account the rapid development of technology, through the dissemination of renewable energies in irrigation and the use of solar energy in pumping instead of oil engines. All this will be easy to apply due to climate and geographical nature of many countries like Algeria. Smart Farming enhances the Agriculture system by controlling the field in real-time with the help of wireless sensor networks which are capable of sensing, handling and transmitting data. Those sensor nodes operate with limited batteries, which are difficult to replace. Therefore, the energy consumption optimization is very important to extend the network lifetime. This paper propose an improved Ant Colony Optimization Algorithm (ACO) to minimize the data optimal path from source sensor node to the destination one on depending on the sensors battery charge which in turn is charged with harvested solar energy in order to extend the network lifetime.

Keywords— *Wireless Sensor Network, IoT, Battery, Optimization, ACO, Energy harvesting.*

I. INTRODUCTION

Maximum Amount Shortest Path (MASP) scheme by using Ant Colony Optimization Algorithm is proposed to increase wireless sensor network throughput and optimize the energy consumption. Two groups of ants find the path between sensor nodes and sub sinks augment the amount of data collected by mobile sinks and rotary table is used to avoid slump. The path's previous search probability is fed into each search to speed it up (1) A comparison between Energy aware routing protocol with ant colony optimization and gradient based routing protocol using ant colony optimization was carried out to ensure reliable routing between source node and destination in case of node failure. The results shows that the two routing algorithms executed by ACO minimize the energy consumption but Energy aware routing protocol with ant colony optimization offers best performances (2) An improved ant colony optimization algorithm called AMACO was presented for maximizing the wireless sensor network lifetime, its working principle depends on new clustering method to avoid the overload. The results show that the lifetime of the network in AMACO rised by 28.2%, 24.9%, and 58.9% in comparison with EBAR, IACO-MS, and

RRDLA before the last node dies respectively (3) An approach to identify multiple optimal paths between sensor node to base station was proposed to reduce the overhead communication and maximize the network lifetime by ant colony optimization. After receiving the network topology by base station, the letter calculates the optimal path by using ant colony optimization algorithm and transmit it to each sensor node. Multiple optimal paths between sensors and base station are efficient for data transfer by increasing throughput and network lifetime (4) An optimization algorithm for energy consumption based on ant colony optimization algorithm was suggested for wireless sensor network, it based on the best selection of next hope node via the comparison of residual energy and distance between nodes, which guarantee less possibility of low energy nodes being selected as next hop that leads to more even power consumption for each node in order to maximize the network lifetime (5) ACAMIMO algorithm shows the combination efficiency of the use of ant colony optimization algorithm and the improved LEACH protocol in terms of reducing energy consumption and maximization of network lifetime (6) A new transmission scheme with adjustment of transmission range to achieve maximum possible energy efficiency (MPPE) and maximum possible energy balancing (MPEB) by using ACO algorithm was presented to extend the lifetime of wireless sensor network (7) ACOMNCC algorithm combines discovery of maximum number of connected covers in a heterogeneous WSN and ant colony optimization prolonging the lifetime of heterogeneous WSNs (8) An improved algorithm ACO-MCC3D was proposed to find solutions of GCLC in a 3-D environment, computational cost was reduced by 66% in comparison to the best existing NDSBA algorithm (9) To maximize the wireless sensor network lifetime, ant colony optimization (ACO) algorithm based on transmission strategy by presenting two concepts most energy-efficient distance and most energy-balanced distance (10) Using an efficient data collection technique based cluster for base stations and receiver nodes helps to reduce the possibility of data loss and lead to reduce the energy consumption, In addition to this the use of ant colony optimization algorithm to determine the optimal path for mobile sink extends the lifetime of network (11) optimal data aggregation based on Ant Colony Algorithm improve the energy efficiency in wireless sensor network by 45% in comparison to approximate aggregation schemes in moderate number of source nodes while 20% of energy efficiency in considerable number of source nodes (12) "SinkDistComb"

dynamic path algorithm has a longer maximum network lifetime than the "SinkDistLead" static path algorithm. "ResidualEnergy" and "SinkDistComb" are more beneficial in extending network lifetime than "SinkAggreDist", "SinkDistLead" and "SinkDistNoAggre" (13) Determine the shortest path by using ACO algorithm gives results more efficient than greedy approach used in PEGASIS (14) The developed AntChain algorithm works much better than the LEACH and PEGASIS methods, in terms of network lifetime, integrity of data and energy efficiency (15) Application of ACO algorithm, which optimizes routing and clustering, which optimizes energy consumption in the internet of things saves more energy and reduces the number of dead nodes by about 81% compared to other algorithms (16) The proposed protocol (APTEEN with threshold energy) ameliorate packet loss and network lifetime compared to the APTEEN protocol. EAAR protocol achieve more than 90% network lifetime than APTEEN protocol (17) ACO is the best routing protocol compared to PSO, ALO and GA in terms of network lifetime throughput and power consumption (18) SPIN (Sensor Protocols for Information via Negotiation) protocols can provide 60% more data for a given amount of energy than conventional approaches (19) ACO algorithm application in routing and the rotation of the CH is performed only when the residual energy of the CH is fewer than a given energy threshold (20).

II. PROBLEM STATEMENT

Each sensor in Agricultural IoT can receive, transfer and treat data; all those operations consume energy causing batteries discharge, which means node dead, which causes system failure. The batteries of the sensors used in Precision agriculture are difficult to replace so the optimization of energy consumption is one of the most important challenges in precision agriculture. The battery energy consumption optimization in smart farming is an interesting concept that we studied in our work, all this in order to boost agricultural production and the country's economy.

III. PROPOSED WORK

The optimization of battery energy consumption of wireless sensors in smart farming is our goal in this paper. We propose an improved Ant Colony Optimization Algorithm (ACO) to minimize the data optimal path from source sensor node to the destination one depending on the sensors battery charge, which in turn is charged with solar energy in order to prolong the network lifetime. We ameliorated a metaheuristic algorithm called ant colony optimization (ACO) to optimize the energy consumption and we boost with the use of energy regeneration using solar energy harvesting where each sensor uses his own solar panel in order to increase the network lifetime See figure 1.




Fig.1. Wireless sensor network devices.

IV. RESULTS

In order to demonstrate performances of our solution, we used ACO algorithm based on its Matlab implementation to find the optimal path between source nodes and destination ones powered with solar energy. Fig.2 represents the path between the source and the sink node through intermediate nodes. This path is considered optimal i.e. it is the shortest path to send the data in a reliable and efficient way which ensures the efficiency of the improved ant colony optimization algorithm.




Fig.2. Optimal Path in Wireless Sensor Network by Using Improved ACO.

The distance length between sensor node and destination one is shown in Fig.3. We observed that started dropping from 314.2 at 0 iteration to reach a value of 311.6 at 200 iteration where it stood still at that value at the iteration increases. We noticed that the application of the ACO algorithm decreases the distance between the source and the destination, which implies the minimization of the path, which causes the optimization of the energy consumed by the nodes in data transfer. The results shows the effectiveness of our proposal work.




Fig.3. Ant Colony Optimization Convergences Characteristics.

V. CONCLUSION

Wireless sensor network is tightly constrained for resources like memory computational power and energy that is the major problem. The use of Ant Colony Optimization that we ameliorated and the energy regeneration by using solar energy panels optimize the routing method, which leads to minimize the path length and extends the network lifetime. In the future, a comparison between other methods and our proposal will be performed.

REFERENCES

- [1] A.Kumar, A.Thomas, "Energy efficiency and network lifetime maximization in wireless sensor networks using improved ant colony optimization". *Procedia engineering*, 38, 3797-3805, 2012.
- [2] R. Arya, S.Sharma, "Analysis and optimization of energy of sensor node using ACO in wireless sensor network". *Procedia Computer Science*, 45, 681-686, 2015.
- [3] A. P Abidoeye, E. O. Ochola, I. C. Obagbuwa, and, D. W. Govender, "An improved ant colony optimization algorithm: a technique for extending wireless sensor networks lifetime utilization". *International Journal of Advanced Computer Science and Applications*, 11(8), 2020.
- [4] A. A. Gurav, M. J. Nene, "Multiple optimal path identification using ant colony optimisation in wireless sensor network". *International Journal of Wireless & Mobile Networks*, 5(5), 119, 2013.
- [5] P. Li, H. Nie, L. Qiu, and, R. Wang, "Energy optimization of ant colony algorithm in wireless sensor network". *International Journal of Distributed Sensor Networks*, 13(4), 2017.
- [6] Y. Li, J. Wang, Y. Qu, M. Wang, and, H. Qiu, "A new energy-efficient transmission scheme based ant colony algorithm for wireless sensor networks". *8th International Conference on Communications and Networking in China (CHINACOM)* (pp. 473-478), (2013, August), IEEE.
- [7] X. Liu, "A transmission scheme for wireless sensor networks using ant colony optimization with unconventional characteristics". *IEEE Communications Letters*, 18(7), 1214-1217, 2014.
- [8] Y. Lin, J. Zhang, H. S. H., Chung, W. H., Li, Y. Ip, and, Y. H Shi, "An ant colony optimization approach for maximizing the lifetime of heterogeneous wireless sensor networks". *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 42(3), 408-420, 2011.
- [9] T. Qasim, M. Zia, Q. A Minhas, N Bhatti, K. Saleem, T. Qasim, and, H Mahmood, "An ant colony optimization based approach for minimum cost coverage on 3-D grid in wireless sensor networks". *IEEE Communications Letters*, 22(6), 1140-1143, 2018.
- [10] X Liu, "An optimal-distance-based transmission strategy for lifetime maximization of wireless sensor networks". *IEEE Sensors Journal*, 15(6), 3484-3491, 2014.
- [11] B. M. Sahoo, R. K. Rout, S. Umer, and, H. M. Pandey, "ANT colony optimization based optimal path selection and data gathering in WSN". In *2020 International Conference on Computation, Automation and Knowledge Management (ICCAKM)* (pp. 113-119). IEEE, (2020, January).
- [12] R. Misra, and, C. Mandal, "Ant-aggregation: ant colony algorithm for optimal data aggregation in wireless sensor networks". In *2006 IFIP International Conference on Wireless and Optical Communications Networks* (pp. 5-pp). IEEE, (2006, April).
- [13] M. Xie, and, H. Shi, "Ant-colony optimization based in-network data aggregation in wireless sensor networks". In *2012 12th International Symposium on Pervasive Systems, Algorithms and Networks* (pp. 77-83). IEEE, (2012, December).
- [14] A. Acharya, A. Seetharam, A. Bhattacharyya, and, M. K Naskar, "Balancing energy dissipation in data gathering wireless sensor networks using ant colony optimization". In *International Conference on Distributed Computing and Networking* (pp. 437-443). Springer, Berlin, Heidelberg, (2009, January).
- [15] N. Ding, and, P. X Liu, "Data gathering communication in wireless sensor networks using ant colony optimization". In *2004 IEEE International Conference on Robotics and Biomimetics* (pp. 822-827). IEEE, (2004, August).
- [16] B. Shi, and, Y. Zhang, "A novel algorithm to optimize the energy consumption using IoT and based on Ant Colony Algorithm". *Energies*, 14(6), 1709, 2021.
- [17] S. S More, and, M. K. Nighot, "Artificial intelligence and ant colony optimization based wireless sensor networks to minimize energy of network". *Indian J Comput Sci Eng (IJCSSE)*, 2017.
- [18] W. Haoxiang, and, S Smys, "Soft computing strategies for optimized route selection in wireless sensor network". *Journal of Soft Computing Paradigm (JSCP)*, 2(01), 1-12, 2020.
- [19] W. R. Heinzelman, J. Kulik, and H. Balakrishnan, "Adaptive protocols for information dissemination in wireless sensor networks", *Proceedings of the 5th Annual ACM/IEEE International Conference on Mobile Computing and Networking*, 1999.
- [20] J. Wang, J. Cao, R. S. Sherratt, and, J. H. Park, "An improved ant colony optimization-based approach with mobile sink for wireless sensor networks". *The Journal of Supercomputing*, 74(12), 6633-6645, 2018.

Analysis of Flight Based Airport Passenger Arrival Patterns

1st Merve Gözde Sayın

R&D Department

TAV Technologies

İstanbul, Türkiye

gozde.sayin@tav.aero / 0000-0002-6213-2549

2nd Mustafa Bolat

R&D Department

TAV Technologies

İstanbul, Türkiye

mustafa.bolat@tav.aero / 0000-0001-8169-0629

Abstract— Maintaining effective and successful work in uncertainty is challenging in a niche sector such as aviation and all industries and situations. The situation is a little more complicated, especially in a sector such as the aviation sector, where the rules are not stretched and where one should always be on the alert. For these reasons, it is precious for businesses that carry out airline operations to analyze arriving passengers and understand whether there is a pattern among passengers. Although there are many factors affecting the arrival patterns of passengers, some of them are particularly noteworthy. For example, factors such as whether the flight is domestic or international, the season in which the flight takes place, and the flight hours take place to provide a broad perspective on the arrival patterns of the passengers at the airport. For example, it can be stated that while passengers on international flights see earlier arrival patterns at the airport, last-minute arrivals are more frequent on domestic flights. Similarly, in domestic flights, different passenger arrival patterns have been determined for the arrival airport, depending on the seasonality of the countries. On the other hand, according to the seasonality of the nations (for example, the opening of schools and national holidays), different passenger arrival patterns have been determined for the destination airport. Analyses were carried out in Python and Excel and included case study outputs.

Keywords— Aviation, Pattern Analysis, Passenger, flights

I. INTRODUCTION

Although it is not very long ago that people make sense of data in the business world, the development of the concept of data analysis has accelerated with the digitalization of our world [1]. The key to successful business progress is correctly analyzing the factors affecting the business. Data analysis has gained meaning, especially recently, and it has given importance to the work done by providing various predictions to business owners. If the data analysis is done correctly, it is helpful to see the business's different aspects and negative or positive factors. It even enables accurate and successful predictions by taking it one step further. Considering the value that a business model built on successful forecasts will bring, the importance of data analysis is emphasized.

Since the aviation industry, whose rules are strictly defined, is a niche industry, the results are striking when data analysis is performed. Factors such as flight time, departure and arrival point, flight season, and whether the flight is on weekdays or weekends are essential factors in the classification of flights as well as passengers. A meaningful data analysis can only be made from existing data, new features can be created using existing data, and extended results can be obtained by including them in the analysis.

Before the data world was so digitalized, descriptive statistical analyses were carried out. Then exploratory data analysis (EDA) [2][3] and later machine learning analyses developed with the development of technology [4]. Simultaneously, data visualization processes have also improved. Advanced data analyses and visualizations are now performed on Excel and in programming languages such as Python and R libraries. In this way, data analysis and visualization have reached vital importance not only in the academic field but also in the industry. Descriptive Statistical Analysis only describes the data, but exploratory data analysis (EDA) questions whether there are any anomalies or salient points in the data [5]. In this case, descriptive analysis is performed by accepting the hypothesis at first, then exploratory data analysis (EDA) is applied to the dataset, and the data is visualized so that it can be read meaningfully. Data that makes sense with visuals are frequently encountered in business reports. Instantly changing pages in many sectors, such as the aviation industry, are based on these analyses. For example, interactive graphics can be included on the home pages of the applications to track the instantaneous change in passenger numbers according to various factors. Thus, both passengers and airline operators can follow instant changes and take action for their own benefit.

II. EASE OF USE

The study was analyzed on real data from a niche sector such as the airport. It is comparable to analyzes for airports and includes actionable results for a better passenger experience. As different data sets can be created at various airports, passenger behaviors vary according to many factors. Therefore, much more data is needed to generalize the outputs. For example, analysis results may differ when data containing more airports and flights are included.

III. ANALYSIS

This paper uses our private airport data, which has 32907 rows and 27 columns. Columns are listed in the table-1 with descriptions, non-null counts, types, and examples. New features were also generated based on the *STD* column listed in Table 2 with the same explanations as Table 1.

TABLE I. RAW DATA SET (SOME FEATURES)

Column Name	Column Description	Non-Null Count	Data Type	Example
INT/DO M	Whether the flight is international or domestic	320907	Object	I

STD	Scheduled Time Departured	320907	Datetime 64[ns]	2021-11-07 11:50:00
tota_pax_count_all_points	Total passenger number for all points at the airport	320907	Int64	185
Total_pax_count_checkin	Check in Passenger number	320907	Int64	145
Checkin_rate	Rate of check ins	320907	Float64	0.7837
360-330	Time slot before 360-330 minutes of the flight (There are 12 time slot columns at half hour intervals)	320907	Int64	0
delay	Delay of flight in minutes	320907	Float64	27.000

TABLE II. GENERATED FEATURES

Column Name	Column Description	Non-Null Count	Data Type	Example
day_of_week	Day of the week for flight	32854	Int64	0
week	Weekday or weekend information	32854	Object	weekday
day_of_year	Day of the year for flight	32854	Int64	101
month	Month of the flight	32854	Int64	3
seasons	Seasons of the year	32854	Object	Summer
my_timezones	According to hours, name the timezone	32854	Object	Morning
flight_count	Whether the flight is less than 400 or not	32854	Object	Few_flight

Year, month, and week are generated with the Python DateTime library based on the *STD* column. Monday, Tuesday, Wednesday, Thursday, and Friday are weekdays, and Saturday and Sunday are weekends. Seasons are generated with the following rule; December, January, and February are defined as winter; March, April, and May are defined as spring; June, July, and August are defined as summer; and September, October, and November are defined as fall seasons. According to the flight industry, between 2 AM and 5 AM are defined as night, between 5 AM and 11 AM as the morning, between 11 AM and 8 PM as noon, and between 8 PM and 2 AM are defined as evening. The dataset needs to be well-distributed for the number of flights, so flights with less than 400 views are labeled as few, and flights with more than 400 views are labeled as many.

After generating new features, there might be irrelevant rows in the data frame; for instance, if there are no passengers in all time slots, this analysis will be unnecessary; therefore, these rows are deleted. In our private data, all departure airports are ADB, so it is nonsense to use the *from_airport* feature so that the column is deleted. Moreover, there are some unknown aircraft types written as 'XXX,' which is also irrelevant to the analysis; therefore, rows with aircraft types are XXX also deleted. Finally, data is not well distributed, so there are various airlines and flights. For the analysis's sake, airlines that occurred less than six times are deleted from the data set.




Fig. 1. Correlation Heatmap of Data Set

Correlation values were calculated and shown on a heatmap in order to see the features that may be related to each other in the data set. According to the heatmap in Fig. 1, a high positive correlation was observed between the periods in the 180-90 range and the check-in rate. In other words, it can be said that the passengers arriving at the airport during this period are those who have checked in. As seen in the following chapters of the study, most passengers arriving at the airport by checking in between 180-90 times are passengers on international flights. In addition, a relatively high correlation was calculated between the delay time and the 240-210-time interval. Negative correlation computed values do not make sense since they are very close to 0. Therefore, in general, it can be said that there is no negative correlation.

The analysis is based on the flights, passengers, check-in rates, and flight delays.

A. Flights

In Fig. 2, the x-axis gives the number of flights, and the y-axis shows the information on domestic/international, weekend/weekday, and time zone of flights. Colors are distributed for the seasons.




Fig. 2. Distribution of Flights

According to the Fig. 2, flights are grouped with international/domestic, weekday/weekend, time zone, and seasons. It can be said that a maximum number of flights occurs in Domestic, weekday, and morning during the fall season, and the minimum number of flights occurs a domestic, weekend, and night for all seasons. Also, domestic, weekday

and noon flights are much more than the rest of the data set. For international flights, it can be said that the maximum number of flights are in the summer season with the information of weekdays, noon. It can be stated that for the international weekday night flights, in the winter season, there are few flights. Overall, it can be noted that the fewest flights took place at night. While the mornings are suitable for domestic flights, noon is preferred for international flights.

B. Passengers

Passenger analyses are made into three groups. The first group is named all passengers, and the second is check-in passengers. The third group is analyzed under the 12-time slots based on their arrivals at the airport. Moreover, data is grouped with domestic/international flights, weekend/weekday flights, time zones, and the seasons of flights.




Fig. 3. Distribution of All Passengers

In Fig. 3, the x-axis gives the number of passengers, and the y-axis gives the information on domestic/international, weekend/weekday, and time zone of flights. Colors are distributed for the seasons. According to the Fig. 3, like the distribution of the flights, there is a difference between international and domestic flights. For domestic flights, weekday morning and weekday noon are the most preferred time zones in all seasons. On the contrary, weekday and weekend nights are the least preferred time zones for domestic flight passengers. For international flights, passengers preferred weekday noon flights with respect to other time zones in all seasons. It can be said that international flights are increased in the fall and summer seasons. However, the winter season is the least preferred season for international flights. The preferences are based primarily on the national holidays and the exact seasons, such as school opening closings, equations consecutively.




Fig. 4. Distribution of Check in Passengers

In Fig. 4, the x-axis gives the number of passengers who made check-in procedures, and the y-axis shows the information on domestic/international, weekend/weekday, and time zone of flights. Colors are distributed for the seasons. Contrary to the all-passenger plots in Fig. 3, international passengers are made check-in procedures more than domestic passengers. Therefore, in Fig. 4, the maximum number of passengers is located on the international, weekday, and noon flights, especially for the summer and fall seasons. It can be said that international passengers tend to make check-ins for the summer flights but not for the winter flights. It can be seen from the Fig. 4; check-in procedures are made less for domestic flights. On the contrary to international flights, domestic flights mostly happen in the summer and winter seasons. Most domestic passengers preferred weekday mornings for their flights.

C. Passengers over Time Slots

Passengers are grouped by the 30 minutes periods. It starts with a 360-300 slot that is 360 minutes before the flight and continues like that. The difference is noticeable, especially for domestic and international flights. Most of the passengers arrive at the airport between 180-60 minutes; from Fig. 6, it can be easily seen the number of passengers from the x-axis. For domestic flights, the last period arrivals are more usual than for international flights, specifically between 90-0 minutes. However, when international flight passenger arrives at the airport between 180-120 minutes, domestic flight passenger has yet to be seen at the airport.




Fig. 5. Distribution of Check in Passengers

Both international and domestic flight passengers usually choose to come to the airport between 120-90 time slots. It can be stated from Fig. 5 and Fig. 6 that arrival patterns are distributed mainly on the type of flight; domestic or international.

D. Check in Rates

When the check-in rates of incoming passengers are examined according to whether the flight is domestic or international, season, time, and weekdays, it can be seen from Fig. 7 that the most significant difference is between domestic and international flights. The check-in rates of domestic flights are much lower than the check-in rates of international flights. Especially in the autumn period, there is a severe




Fig. 6. Distribution of Check in Passengers

proportional difference between them. Therefore, Check-in rate differences may be due to the fact that domestic flights are fewer in autumn.




Fig. 7. Distribution of Check in Rates

The check-in rate distribution of all flights without any grouping can be found in Fig. 8. The reason for the check-in rate appearing above 1 is that there are people who appear twice in our dataset, but we decided to keep it as this did not disrupt the course of the analysis. When we look at the check-in rate distribution graph, it is possible to say from Fig. 8 that 0s and 1s are in weight, but the average is 0.5.




Fig. 8. Distribution of Check in Rates-Ungrouped

E. Delay Averages

Fig. 9 shows the average delays of the flights. Accordingly, it can be said that most delays occur in the summer months. In this chart, the distribution according to the season distinction and the period of the day of the flight rather than the domestic/international distinction draws attention. The average delays are directly proportional to the excess




Fig. 9. Distribution of Delays in Averages

flights in those periods. The highest average in international, weekend, and evening summer flights was recorded as 50.50 minutes. The lowest average was recorded as 6.35 minutes for domestic flights in the winter and autumn, from the periods with the least flights.

IV. DISCUSSION AND FURTHER WORKS

In this study, a special data set was created, and some analyzes were carried out by questioning the similarities and differences of the flights in different categories, the analysis of the behavior of the passengers at the airports, and whether there was a specific pattern. The most apparent difference from the outputs is the differences between domestic and international flights. The following output is that the flight frequency increased and decreased according to the time of day the flight took place. In addition, seasonal flight differences also differed in domestic and international flights. Flights and passengers were examined in terms of season, flight type, and temporal, as well as flight delays and check-in rates. In addition, the features that can be positively or negatively related to each other according to the correlation between the components in the data set were examined.

Future studies it is aimed to develop the analysis with a more extensive and diverse data set. The scope and results of the analysis will be developed with data from different airports and parameters that can be generated. Thus, the passenger arrival pattern will be drawn, the flights will be classified, and studies will be carried out to provide a more effective airport experience.

ACKNOWLEDGMENT

We would like to thank Gökhan Koç for helping with this research paper and for providing guidance and feedback throughout this analysis. Also, we would like to thank Dr. Yakup Genç for his guidance and support in this matter. We would also like to thank Talha Koç, his support is very important to us.

REFERENCES

- [1] Tsai, CW., Lai, CF., Chao, HC. et al. Big data analytics: a survey. *Journal of Big Data* 2, 21 (2015). <https://doi.org/10.1186/s40537-015-0030-3>. (references)
- [2] W. J. Tukey, "The future of data analysis," *Annals of Mathematical Statistics*, pp. 1- 67, 1962.
- [3] W. J. Tukey, *Exploratory Data Analysis*, Reading, MA: Addison-Wesley, 1977.
- [4] Kürzl, H. (1988). Exploratory data analysis: recent advances for the interpretation of geochemical data. *Journal of Geochemical Exploration*, 30(1-3), 309–322. doi:10.1016/0375-6742(88)90066-0
- [5] Stephan Kolassa (<https://stats.stackexchange.com/users/1352/stephan-kolassa>), EDA, Descriptive statistics, Visual Analytics, URL (version: 2017-10-25): <https://stats.stackexchange.com/q/309837>

Diagnosing Melanoma Cancer Using Deep Learning

1st Seda Büşra Bakır
Department of Mechanical Engineering
Gaziantep University
Gaziantep, Turkey
sdbsrbrkr@gmail.com, ORCID: 0000-
0001-9373-0253

2nd Ali Kılıç
Department of Mechanical Engineering
Gaziantep University
Gaziantep, Turkey
akilic@gantep.edu.tr, ORCID: 0000-
0002-3241-9944

3rd Sadettin Kapucu
Department of Mechanical Engineering
Gaziantep University
Gaziantep, Turkey
kapucu@gantep.edu.tr, ORCID: 0000-
0002-7061-9672

Abstract— Skin cancer is common and a serious disease, which can lead to death if not treated in time. Melanoma is the rarest and most dangerous type of skin cancer. It causes the most deaths. As in all diseases, early and correct detection of skin cancer are very important. It is expected that melanoma cancer, which is aimed to be detected using deep learning in this project, will be of great convenience for the patient and the doctor. Nowadays, the importance of artificial intelligence has increased to a great extent. The main purpose of the project is to help the early diagnosis of patients with skin cancer and to save time for the health system, thus enabling the initiation of fast and effective treatment methods. The spread of such a project in our country and in the world will make people's lives easier. Artificial intelligence is developing in many areas, such as in the field of health. Owing to these developments in the field of health, physician, and patient comfort increases. In this study, the data from the ISIC (The International Skin Imaging Collaboration) Archive were trained with a deep learning algorithm. Using the deep learning method, it was determined by the software that the 'nevus' in the body was malignant or benign over the appropriate camera apparatus. Thus, early diagnosis is provided, and patients will be able to consult their doctors. The developed algorithm has achieved a good result by detecting moles with nearly 100% success and the accuracy rate was 88% in the SSD (Single Shot Multibox Detector) MobileNet V2 method and 89% in the ResNet101 (Residual Network) method. With these conclusions, it is seen that the study will shed light on future studies and diagnosis systems based on mobile health.

Keywords—Deep Learning, Melanoma Cancer, Artificial Intelligence, Early Diagnosis

I. INTRODUCTION

The use of artificial intelligence has become very common in the field of medicine, as it is in many fields today. Artificial intelligence provides great convenience in cancer treatment, radiology, psychiatry, drug development, analysis of pathology images, tissue engineering, eye diseases, genetic engineering, and many other fields. With the spread of artificial intelligence, it is aimed to make human life easier. Especially in the field of health, early diagnosis is of great importance. Since its first appearance, many achievements have been made in different fields. As examples of these achievements in the field of health, artificial intelligence is also used in the diagnosis of many retinal diseases such as detection of diabetic retinopathy complication, age-related macular degeneration, detection of premature retinopathy and tumor detection, diagnosis of mental diseases, applications to manage stress, anxiety, depression, diagnosis of Alzheimer's.

In addition to these, the most well-known medical artificial intelligence applications are IBM Watson for Oncology and Watson for Drug Discovery, WDD.

Melanoma is a cancer of cells called melanocytes in the skin. These are the cells that give skin its color [1]. Melanoma

is the most dangerous and rarest type of skin cancer. It is seen because of uncontrolled proliferation of melanocyte cells that give color to the skin. Genetic predisposition, exposure to UV rays are the causes of the disease. If left untreated, it can spread throughout the body. It can be seen as black, brown, blue, purple spots on any part of the body.

As shown in Fig. 1, melanoma cancer spreads under the skin [2]. Their color is usually dark. As it gets deeper under the skin, the risk ratio increases.




Fig. 1. Melanoma [2].

Early diagnosis of melanoma is vital. Many melanomas are curable by excision if they are detected early. Under favour of the artificial intelligence to be developed, it is aimed to make an early diagnosis and refer the patient to the doctor. In the studies, it was obtained by using many different methods of artificial intelligence among themselves.

Using Google Inception V3 method in Deep Convolutional Neural Network, J. Emuoyibofarhe and D. Ajisafe reached 81% accuracy and 84% sensitivity. Their training images have 879 for benign and 879 for malignant and test images are 300 for benign and 300 for malignant from ISIC (The International Skin Imaging Collaboration) dataset. They used three method which is 3-layer Convolutional Neural Network (3_CNN), VGG16 and Inception V3 (IV3). 3_CNN result is accuracy of 71.17%, sensitivity of 67.67%, precision of 72.76% for loss 0.94. VGG16 result is accuracy of 76.67%, sensitivity of 78%, precision of 75.97% for loss 0.75. IV3 result is accuracy of 81%, sensitivity of 84.33%, precision of 79.06% for loss 0.49 [3].

E. Ozturk and S. Icer divided the data they received from ISIC into two main groups: 30 melanoma, 30 benign and 60 images. They have been classified with the feedforward neural network and decision trees algorithm in MATLAB, and with the WEKA program for the random forest algorithm. The best result was obtained in the feedforward artificial neural network with 83.3% [4].

T. T. Do et al. used lesion segmentation method. This method includes Otsu's method and Minimum Spanning Tree (MST). Then they combined these two methods and tested. They separated images two classes which is benign and

malignant. There are totally 184 color images, which is 117 images of benign nevus and 67 images of malign melanoma. The accuracy of their proposed method is 80.09% [5].

D. Bisla et al. used the images from the ISIC test data set. It contains 600 images (117 melanoma images, 90 seborrheic keratosis images, and 393 nevus images). For the task of lesion classification, they utilized a ResNet50 architecture pre-trained on ImageNet data set with final fully connected layer modified to output probabilities of lesion being in each of the classes. They obtained accuracy of 81.6% with using deep learning [6].

A. A. Ali and H. A. Marzouqi used ISIC dataset and LightNet (deep learning framework) method for classification. Their classification is benign and malignant. They found the accuracy of 81.6% [7].

B. Harangi constituted three class which is nevus (benign), melanoma and seborrheic keratosis. The available training/(test) set contained 2000 / (600) images with manual annotations regarding the three different classes in the following compounds: 1372 / (393) images with nevus, 254 / (90) images with seborrheic keratosis, and 374 / (117) with malignant skin tumors.

There are several possibilities for data augmentation, such as cropping random samples from the images or horizontal flipping or rotating them with different angles (e.g., 90°, 180° and 270°). Using these transformations, they have generated 14.300 images from the originally provided 2000 training ones. That is, they have increased the several images from 1372 to 8200 for nevus, from 374 to 4600 for melanoma, and from 254 to 1500 for seborrheic keratosis. They found average accuracy of GoogleNet 84.2%, AlexNet 84.8%, ResNet 82.8%, VGGNet 81.3%, SP 86.7%, PP 86.1%, SMV 90.3%, SMP 86.8% w(1)SMP 86.9%, w(2)SMP 86.6% and average AUC of GoogleNet 84.8%, AlexNet 83.0%, ResNet 80.9%, VGGNet 80.8%, SP 87.5%, PP 87.5%, SMV 83.9%, SMP 88.4% w(1)SMP 88.6%, w(2)SMP 89.1% [8].

S. Kalouche used ISIC dataset. He used VGG-16 and CNN methods in his study. He separated the benign and melanoma dataset for classification. He found the accuracy of 78% [10].

V. Singh and I. Nwogu used ISIC dataset. They used deep CNN method. They separated the dataset as benign and malignant for classification. They found the accuracy of 80.3% [9].

In this study, melanoma was divided into two classes as benign and malignant. As a result of this classification, the data were trained with two different CNN algorithms. The first of these is SSD MobileNet V2, the second is SSD ResNet101 V1FPN. Post-training data were tested. At the same time, an accurate result was obtained by testing with the real time camera apparatus. Thanks to this software, patients will be able to detect melanoma much more easily and quickly.

II. MELANOMA TYPES

A. Benign

Benign tumors develop on the skin in different types. Benign is a type of nevus and is found on many human skins. While they incorporate the possibility of change, spread and malignancy, they may never be able to do so. Most of these tumors rarely, if ever, turn into cancers.

Moles, or examples of benign melanoma, represent clusters of pigment cells known as melanocytes. When these cells are grouped together, they produce round or oval-shaped, brown, black, or sometimes pink patches on the skin. A benign example from the ISIC Archive dataset [12] is given in Fig. 2 (a). They can hardly be larger than a fingertip [1].

B. Malignant

Malignant melanoma is a type of skin cancer that develops from pigment-producing cells found in the surface layer of the skin (epidermis), known as melanocytes. Melanomas typically occur on the skin but may rarely occur in the mouth, intestines (mucosal melanoma), or eye (uveal melanoma).

Most of them appear as brown-black pigmented lesions on the skin. It often develops from existing nevi known as "moles", which may have disfigurement, itching, ulceration, or bleeding. Because most melanoma cells produce melanin, melanomas are usually brown or black. A malignant example from the ISIC Archive dataset [11] is given in Fig. 2 (b). But some melanomas do not make melanin and may appear pink, tan, or even white.

Melanoma is not very common, but it is the most dangerous and deadly skin cancer. It spreads very quickly, so early detection is very important [1].

III. MATERIAL METHOD

A. Dataset

From the ISIC Archive dataset, 1000 malignant and 1000 benign were used. Of these, 80% were used in training (1600) and 20% in testing (400). These images were trained first with the MobileNet algorithm, and then with the ResNet algorithm.




Fig. 2. (a) Benign. (b) Malignant [12].

B. CNN

Convolutional Neural Network is a deep learning algorithm that helps to distinguish various objects or objects in the image from each other. The convolution layer includes convolution, activation function (ReLU) and pooling steps. It allows extracting low-dimensional features from high-dimensional data.

The purpose of the convolution operation in the first stage of the convolution layer is to extract features from the image [14].

The mathematical formula of the convolution operation is given in (1).

$$(f * h)[m, n] = \sum_j \sum_k h[j, k] f(m - j, n - k) \quad (1)$$

Here the input image f and h are the filter. The row and column indices of the output matrix are m and n , respectively. J and k represent the position of the filter. Outputs of the convolution layer are followed by ReLu as the rectifier unit, and if the input value is negative, it returns zero. Mathematically, it is shown in (2).

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2)$$

In the convolution layer, features are extracted from an input image. In the convolution layer, the image features are learned using the pixels of the input data and the relationship between the pixels is preserved [12]. There are four basic concepts in the convolution layer.

1. Convolution

Convolution is the mathematical operation between the input and filter matrices, and the output is a matrix. As a result of convolution, image derivatives of the same size as the original image such as horizontal edges, vertical edges, angular edges, softened image, sharpened image are obtained [13].

2. Padding

Padding is the several pixels added to the input matrix as it is processed by a convolutional neural network. It allows controlling the size difference between the input and output matrix after the convolution process. Pixels are added to the frame of the image to provide more space for the kernel to overlay the image [13].

Adding padding to the image processed by the convolutional neural network allows for more accurate analysis of images.

3. Stride

The stride (shift step) specifies how many steps the kernel matrix will be moved over the input matrix. If the several strides are 1, the filters are moved to 1 pixel at a time. Similarly, when the several strides are 2, the filters are moved to 2 pixels at once. The smaller the step value, the larger the output (and vice versa) [13].

4. Pooling

The pooling layer progressively reduces the spatial size of the representation to reduce the several parameters and computations in the network. This is also useful for extracting dominant features that are rotationally and positionally invariant, maintaining the process of training the model effectively [14].

There are two types of pooling: maximum pooling, which gives the maximum value from the part covered by the kernel, and average pooling, which gives the average of all values in the part of the image covered by the kernel.

C. Fully Connected Layer

The reason for using the convolutional neural network; is to develop a classification model and ensure that the inputs of this model are correct.

The fully connected layer is located after the pooling layer and comes into play when we are in the final stage of the convolutional neural network. The output obtained because of the pooling layer is converted to a one-dimensional vector in

this layer. The reason for this is that the input converted into a one-dimensional vector will be added to the neural network. The inputs to be given to the model must be in the form of a 1-dimensional linear vector. Therefore, flatten and fully bonded layers are needed [17].

MobileNet: It is used for mobile and embedded vision applications. Compared to other models, it is much faster as performance and smaller size [15].

MobileNet is smaller in size than other models and therefore faster. It is would rather for advancing mobile applications. In depth split convolutions, a single filter is applied to each input layer, and some use 1x1 convolutions. Pass over the Fully Connected Layer that feeds the softmax layer, a batch norm and ReLU nonlinear activation layer follows each layer to classify the output. It is separate to two layers in depth separable convolution, with split layer processing for filtering and merging [16]. The architecture of SSD MobileNet shows in Figure 3.




Fig. 3. SSD MobileNet Architecture. [17]

SSD (Single Shot Multibox Detector) merges predictions to multiple property maps of different sizes. The SSD is designed to be impartial of the fundamental network and therefore can run on just about anything, including MobileNet [16].

The output of the fundamental network is typically a 7×7 pixel image. To reduce the size from 7×7 to 1×1 pixels, the classifier first uses a general pooling layer, then a classification layer and a softmax [16].

Not only just the last fundamental network layer, but also a number of prior layers are output and infeeded the SSD layers. The mission of MobileNet layers are to convert the pixels in the input image into attributes that explain the comprehension of the image and carry out it to other layers. Therefore, MobileNet is used as a feature extractor for a second neural network [16].

Residual Network (ResNet101): In this architecture, to increase the performance rate to higher levels, the transition to the next lower layer was made by not considering the change between some layers [18].

Designed to be deeper than any architecture designed so far, Resnet has different layers among itself, but Resnet101 has 101 layers. The biggest feature that distinguishes it from other architectures is that the residual values are formed by adding the blocks feeding the next layers to the model. This value, which is added in every two layers between Linear and ReLu activation codes, changes the system account as stated [18]. The structure of the ResNet-101 based deep feature extractor shows in Figure 4.

SSD MobileNet V2 Results




Fig. 4. ResNet101 Architecture [19].

IV. RESULTS

The developed algorithm has achieved a good result by detecting moles with nearly 100% success and performing benign and malignant error matrix classification at 98%. With these conclusions, it is seen that the study will shed light on future studies and diagnosis systems based on mobile health.

A. Confusion Matrix

1. True Positive (TP): If input is true, output is true. TRUE
2. True Negative (TN): If input is false, output is false. TRUE
3. False Positive (FP): If input is true, output is false. FALSE
4. False Negative (FN): If input is false, output is true. FALSE

TABLE I. CONFUSION MATRIX RESULTS OF THE SSD MOBILENET V2 AND RESNET101 ALGORITHM.

		SSD MobileNet V2	
Prediction Data		BENIGN	MALIGNANT
True Data	BENIGN	186	14
	MALIGNANT	35	165
	ResNet101		
	BENIGN	181	19
	MALIGNANT	26	174

According to Table 1, the TP value is 186, the FN value is 14, the FP value is 35, and the TN value is 165 of the SSD MobileNet V2 algorithm.




Fig. 5. Test Results of MobileNet algorithm (a) Benign. (b) Malignant.

Benign test result of training of SSD MobileNet V2 algorithm of benign and malignant images from ISIC Archive dataset [11] are shown in Fig. 5 (a) and malignant test result of training of SSD MobileNet V2 algorithm is shown in Fig. 5 (b).

The SSD MobileNet V2 algorithm test results of the training, accuracy, error rate, sensitivity, specificity, precision, recall, F1 Score values are shown in (3), (4), (5), (6), (7), (8), and (9).

Accuracy (Acc): The collection rate of the correct classification gives the accuracy value.

$$\text{Accuracy} = (\text{TP} + \text{TN}) / \text{Total} \quad (3)$$

$$\text{Acc} = (186 + 165) / 400 = 0.8775$$

Error Rate: The collection rate of the misclassification gives the error rate.

$$\text{Error Rate} = (\text{FN} + \text{FP}) / \text{Total} \quad (4)$$

$$\text{Error Rate} = (14 + 35) / 400 = 0.1225$$

Sensitivity: The ratio of accurately predicted data to actual data gives the precision.

$$\text{Sensitivity} = \text{TP} / \text{True Data} \quad (5)$$

$$\text{Sensitivity} = 186 / 200 = 0.93$$

Specificity: The term specificity is used to predict the nonexistent.

$$\text{Specificity} = \text{TN} / (\text{TN} + \text{FP}) \quad (6)$$

$$\text{Specificity} = 165 / (165 + 35) = 0.825$$

Precision: The ratio of correctly prediction data to the total data give the precision.

$$\text{Precision} = \text{TP} / (\text{FP} + \text{TP}) \quad (7)$$

$$\text{Precision} = 186 / (35 + 186) = 0.842$$

Recall: It shows how many of the transactions that should be predicted positively are predicted positively.

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (8)$$

$$\text{Recall} = 186 / (186 + 14) = 0.93$$

F1-Score: It is the harmonic average of precision and recall [20].

$$F_1 = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (9)$$

$$F_1 = 2 \times \frac{0.842 \times 0.93}{0.842 + 0.93} = 0.884$$

ResNet101 Results

According to Table 1, the TP value is 181, the FN value is 19, the FP value is 26, and the TN value is 174 of the ResNet101 algorithm.




Fig. 6. Test Results of ResNet algorithm (a) Benign, (b) Malignant.

Benign test result of training of ResNet101 algorithm of benign and malignant images from ISIC Archive dataset [12] are shown in Fig. 6 (a) and malignant test result of training of ResNet101 algorithm is shown in Fig. 6 (b).

The ResNet101 algorithm test results of the training, accuracy, error rate, sensitivity, specificity, precision, recall, F1 Score values are shown in (10), (11), (12), (13), (14), (15) and (16).

Accuracy:

$$\text{Acc} = (181 + 174) / 400 = 0.8875 \quad (10)$$

Error Rate:

$$\text{Error Rate} = (19 + 26) / 400 = 0.1125 \quad (11)$$

Sensitivity:

$$\text{Sensitivity} = 181 / 200 = 0.905 \quad (12)$$

Specificity:

$$\text{Specificity} = 174 / (174 + 26) = 0.87 \quad (13)$$

Precision:

$$\text{Precision} = 181 / (26 + 181) = 0.874 \quad (14)$$

Recall:

$$\text{Recall} = 181 / (181 + 19) = 0.905 \quad (15)$$

F1-Score:

$$F_1 = 2 \times \frac{0.874 \times 0.905}{0.874 + 0.905} = 0.889 \quad (16)$$

Real time detection was made with the camera apparatus. As a result, benign moles were found to be benign. All moles tested in real time were found to be benign as expected. This shows the success of training. Under favour of the ResNet101

network, a layered flat network architecture with lower filters and lower complexity is used. ResNet101 has a higher capture rate than SSD MobileNet V2. With this study, moles on the skin can be detected instantly whether they are benign or malignant.



Fig. 7. Benign with real time detection from camera.

According to the Fig. 7 taken from the camera with real time detection, the benign sees mole very easily. The proposed model has obtained quite satisfactory results for binary classification. In Table 3, there is a comparison of the performance evaluations of previously studied deep learning and machine learning approaches with the proposed model.

TABLE II. COMPARISON OF THE PROPOSED METHOD WITH OTHER PREVIOUS STUDIES.

Approaches	Dataset	Method	Accuracy (%)
J. Emuoyibofarhe & D. Ajisafe	ISIC Archive	3_CNN, VGG16, IV3	71.17, 76.67, 81
E. Ozturk & S. Icer	ISIC Archive	Feedforward Neural Network	83.3
T. T. Do et al.	ISIC Archive	Otsu's method and MST	80.09
D. Bisla et al.	ISIC Archive	ResNet50 on ImageNet	81.6
A. A. Ali and H. A. Marzouqi	ISIC Archive	LightNet (deep learning framework)	81.6

B. Harangi	ISIC Archive	AlexNet, VGGNet, GoogLeNet	Average accuracy 83.8
S. Kalouche	ISIC Archive	VGG-16 CNN	78
V. Singh and I. Nwogu	ISIC Archive	Deep CNN	80.3
	ISIC Archive	SSD MobileNet V2	87.75
	ISIC Archive	ResNet101	88.75

V. CONCLUSIONS

Benign and malignant melanoma were detected with high accuracy by the methods used in this study. The model established on the ISIC Archive dataset, which is a publicly available dataset, have received results that can compete with other studies in the literature. This study is important in terms of the approach it brought to the literature and the high scores it received.

According to the comparison of Resnet101 and SSD MobileNet V2, it is seen that ResNet101 gives better results. According to ResNet101, the accuracy rate is 89%, and according to SSD MobileNet V2, the accuracy rate is 88%. The following items can be listed as advantages and disadvantages between the two:

- ResNet101 gives better results in object detection than SSD MobileNet V2. This ensures that the specificity feature is higher.
- SSD MobileNet V2 gave higher results than ResNet101 during object detection.
- ResNet101 gives better accuracy in object detection than SSD MobileNet V2.
- SSD MobileNet V2 gives better results in sensitivity than ResNet101.

The future work of this study is to develop mobile application, and more precise mobile software. In this way, patients will get a preliminary knowledge before going to the doctor and will save patient time. This application will also help health system.

REFERENCES

- [1] C. McCourt, O. Dolan, and G. Gormley, "Malignant melanoma: A pictorial review," May 2014.
- [2] Mayo Clinic Melanoma, Retrieved from : <https://www.mayoclinic.org/diseases-conditions/melanoma/symptoms-causes/syc-20374884>
- [3] J. Emuoyibofarhe and D. Ajisafe "Early skin cancer detection using deep convolutional neural networks on mobile smartphone," April 2020.
- [4] E. Ozturk and S. Icer "Dermoskopi görüntülerinin ileri beslemeli yapay sinir ağı, karar ağaçları ve rastgele orman ile sınıflandırılması," 2021.
- [5] T. T. Do et al. "Accessible melanoma detection using smartphones and mobile image analysis," February 2018.
- [6] D. Bisla et al. "Towards Automated Melanoma Detection with Deep Learning: Data Purification and Augmentation," IEEE Explore.
- [7] A. A. Ali and H. A. Marzouqi, "Melanoma Detection Using Regular Convolutional Neural Networks," 2017.
- [8] B. Harangi, "Skin lesion classification with ensembles of deep convolutional neural networks," August 2018.
- [9] S. Kalouche, "Vision-Based Classification of Skin Cancer using Deep Learning," Stanford University.
- [10] V. Singh and I. Nwogu, "Analyzing Skin Lesions in Dermoscopy Images Using Convolutional Neural Networks," 2018.
- [11] ISIC (The International Skin Imaging Collaboration) Archive Dataset, Retrieved from: <https://www.isic-archive.com/#!/topWithHeader/wideContentTop/main>
- [12] F. P. An and Z. W. Liu "Medical image segmentation algorithm based on feedback mechanism CNN," August 2019.
- [13] S. Albawi, T. A. Mohammed, and S. Al-Zawi "Understanding of a convolutional neural network," ICET2017.
- [14] K. O'Shea, and R. Nash "An introduction to convolutional neural networks," December 2015.
- [15] W. Wang et al., "A novel image classification approach via dense-mobilenet models," January 2020.
- [16] A.G. Howard et al. "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," April 2017.
- [17] T. J. Sheng et al., "An Internet of Things Based Smart Waste Management System Using LoRa And Tensorflow Deep Learning Model," 2019.
- [18] K. He et al. "Deep residual learning for image recognition," December 2015.
- [19] J. Chen et al., "Quantification of water inflow in rock tunnel faces via convolutional neural network approach," December 2020.
- [20] C. Goutte, and E. Gaussier "A probabilistic interpretation of precision, recall and f-score, with implication for evaluation," April 2005.

Classification Accuracy and Discrimination Performance of a Novel Abstract Vector Model for Face Recognition and Clustering

1st Mehmet Cemal Atlioğlu

R&D Department

TAV Technologies

İstanbul, Türkiye

mehmetcemal.atlioglu@tav.aero

2nd Merve Gözde Sayın

R&D Department

TAV Technologies

İstanbul, Türkiye

gozde.sayin@tav.aero

Abstract— Facial recognition technologies have become essential bioresearch topics in recent years. Artistic concerns that began in ancient times led to the development of some proportional criteria, such as the golden ratio, from architecture to evaluation of facial features. With the development of deep learning algorithms, a finite number of facial key points can be extracted from the face images of the person, and the proportions established between these points, also called centroids, are used in recognition methods. As a further step in solving the face recognition problem, the deep learning network's last layer (classification layer) is removed, and longer identification vectors of the target face are created. As a result, the problem turns into systems where the vectors of the face lines are compared with each other, and classification is made according to a threshold criterion. In this study, using the LFW dataset, the critical face points of well-known people and then the face vectors were obtained, and the performance of the abstract vector extraction of each face in terms of "recognition" and "discrimination" was examined. With the vector summarization method applied in the study, more than seven thousand people of LFW dataset, having at least three pictures were examined, and the classification performance metrics of the proposed algorithm was measured.

Keywords— *AI, deep learning, face embeddings, face vectors, vector summarization, face detection, abstract vector method*

I. INTRODUCTION

People wanted to teach computers how to mimic a person in every aspect for a long time. In recent years, academic studies have established a system that recognizes the human face and obtains specific results from this output [1]. Face recognition functionality is significant because of its ease of use through wide range of applications, including the military, media, law, and politics [2]. Even though there are many methods to recognize a person, for instance, voice, body shape, etc., the face is the most distinguishing characteristic to identify [3].

Face recognition is defined as identifying objects, people, and human faces from a video or an image and comparing them to tagged people in the database. It typically includes the following processes: defining background and face boundaries; normalizing images; extracting facial features; recognition, and verification. As with every data set and artificial intelligence problem, the face recognition system also has difficulties. At this point, the features that create diversity in the person's appearance, glasses, beard, makeup, hairstyle, pose, etc., make it challenging to identify the person [2][4]. Apart from the person's appearance, environmental factors like the light balance of the image, the background, and

the ratio or proportion can complicate the face recognition problem [2].

There are generally preferred models in face recognition problems, and they consist of two modules: feature extraction and parsing. In addition, particular models can be implemented to solve the problem, and combinations of these models are frequently seen as a preferred method. The most used models can be listed as follows [5]: Histogram of Gradients (HOG) and Support Vector Machine (SVM) Classifier in [6], HOG and Relevance Vector Machine (RVM) Classifier in [7], Principal Component Analysis (PCA) and SVM in [8], and a Convolutional Neural Network (CNN) in [5].

II. LITERATURE REVIEW

The concept of face recognition has been defined since 1986 [3], but in the last decade, it has accelerated, and several models have begun to be used to detect faces. Face detection is the first step of the face recognition process, for which Viola and Jones used AdaBoost and generated a breakthrough algorithm for it [2][9]. In the normalization step, which could be considered the second step of the face recognition process, it is found that the most effective and valuable techniques rely on appearance-based methods [2]. The third step is feature extraction, and there are some common usages, such as the gray-level values of pixels arranged in a fixed (usual raster) order which are one of the most prevalent feature types. In addition to gray levels, more complex features are additionally used, like wavelets [10], Gabor filter-based features [11][12], and discrete cosine transform (DCT) features [13][14], which produce results that are superior to gray levels. Due to their resistance to normalization mistakes and minor variations in lighting, local histogram-based features like local binary patterns (LBPs) [15] and local ternary patterns (LTPs) [16] have recently gained a lot of popularity [2]. The last step is dimensionality, so the Eigenface method was established to gain a lower-dimensional space [17][2]. However, there are odd limitations of the Eigenface methods, so the linear discriminant analysis (LDA) method is developed by applying Fisher's linear discriminant criterion, which maximizes the ratio of determinant of between-class scatter to the determinant of within-class scatter in the embedded space [2]. Within the LDA method, the small sample size problem is not solved. To overcome this problem, first PCA is used to reduce dimension, and then LDA is applied as a two-stage PCA+LDA method, which is also known as the Fisherface method [2][18][19]. Nevertheless, the PCA+LDA method has limitations as well, and to overcome these limitations, the

discriminative common vector (DCV) method has been proposed [2][20].

In 2018, there were developments in face recognition problems, so Khalifa and Şengül [21] used a combination of HOG and LNP features. They also stated that dimension alignment and illumination normalization of the facial images considerably improve performance. Moreover, using the correct k value in the k -NN classifier and proper image features, 98.08% accuracy was obtained, slightly less than the SVM, 98.79%.

In the 2020s, the new generation of ANNs, called Deep Net, was defined under Deep Learning [22]. However, it is known that the classifier decreases system performance and success. These disadvantages suggested not using the classification algorithms in the models. So, 128-D average face vectors without any classification algorithm are used in [22]. In the other study, the AT&T and real-time inputs' accuracy is 98.75% and 98.00%, respectively [23].

III. METHODOLOGY

In this study the Labeled Faces in the Wild (LFW) dataset has been chosen as the base dataset and a subset of LFW dataset has been created to include celebrities such that, the identities having less than 3 images has been eliminated. Thus 7564 images of 898 celebrities have been collected. The main building blocks of the study can be visualized by a block diagram as shown in Figure-1.




Figure 1- Classification flow

Each step of the process can be summarized as follows;

Digitization: The LFW dataset is organized in a folder structure where each celebrity name has a separate folder

including identity photos denoted by a naming convention. The naming convention is in form of; “name_surname_xxxx.jpg” fashionon where “xxxx” marker is a 4-digit and zero-based ascending image index. Thus, in digitization step celebrity photos were first grouped by name and surname then sorted by image index. Then photos were copied into memory in a dictionary structure where key is the celebrity “name-surname” and values are the image index denoted photos.

Face Detection: In this step each photo has been introduced to face detection algorithm. The output of the process is the upper left point of a rectangle with width and height distances. When plotted onto the face, rectangle fully covers visible part of the celebrity face area.

Noise Removal & Cropping: Some of the pictures include multi person faces around target celebrity. A visual tool has been developed to remove unwanted noise faces from the person image so that each photo includes pixels of only target person face. As a second step, target celebrity faces were copped into a new in memory bitmap image.

Landmark Extraction: In this phase celebrity faces were introduced DLib algorithm to derive 68-point facial landmarks. Those two-dimensional data were kept into memory for next step.

Facial Alignment: With the help of facial landmarks, each cropped face image was aligned so that horizontal line that connects two eye centers is perpendicular to the vertical line that lies on the person nose.

Non-ROI Pixels Removal: In this step aligned faces and their aligned bounding boxes were projected back onto a black empty image where the new image size is same with non-filtered original image size. Thus, each celebrity photo included only one target face area and blackout pixels around it.

Resulting output after alignment step, can be seen in GUI as shown in Figure-2:




Figure 2 – Noise face removal with GUI

Embedding Vectors: Pre-processed celebrity images were first resized to 128x128 pixels and then presented to a Resnet_27 based CNN structure in such a way that the layers after the last hidden layer of the CNN were deleted for feature vector creation. Thus, each celebrity picture was represented in a 512-dimensional new vector space.

Serialization Step: As the final step 7564 celebrity images were transformed into a 513-size vector so that first column denotes to the celebrity’s name_surname and remaining 512 vectors are the embeddings of the corresponding image face pixels.

IV. TESTS AND RESULTS

The study aims to minimize face recognition processing power and storage capacity requirements in systems by comparing a newly detected face only with a single summary vector of each person instead of comparing it with all image vectors of each person. In the test and training processes, a total of 7564 pictures from 898 different people, at least 3 for each person, were used. In the defined test and train data set, a regular face recognition system needs 7564 comparisons and should store every 7564 vectors in DB to recognize a newly detected face. However, only 898 comparisons will be enough with the proposed summarization method. Furthermore, the cosine similarity method which is shown in Eq. (1) was used to compare 512-sized vectors (in the equation, A and B represents the vectors) with each other. The cosine of the angle between the person's vectors is evaluated in the testing process with different threshold levels.

$$\cos(\theta) = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}} \quad (1)$$

In the first test (kFold cross validation for k=1, simply LOOCV), each image was extracted from the dataset and then summarized abstract vectors of each person group were generated without this image. The vector of this image was then compared with all summarized vectors and recorded with the comparison value that captured the highest cosine similarity value. This process was repeated for all 7564 images and all results are evaluated as TRUE classification if the image and best succeed summarized vectors of this image are belong to the same person and cosine similarity is higher than the defined threshold. After all the results were marked as TRUE and FALSE according to different thresholds, result shared in Figure-3 was obtained.




Figure 3 -True positive rates according to threshold levels

Examining the initial test results, it appears that almost all images (except 17 of them) achieved the highest cosine similarity value with the correct summarized vector, but approximately 2 percent of the images had an angle greater than 45 degrees with their summarized vector. These results show that a person whose summarized vector is generated by the system can be classified with a very high probability. However, this success is mostly related with the vector extraction process and summarization method needs to be evaluated in a different testing structure. Therefore, second test is executed and following metrics are measured.

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

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

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (4)$$

$$\text{F1 Score} = \frac{2TP}{2TP + FP + FN} \quad (5)$$

In the second test, randomly picked 30 people with all their images (229 images) and randomly picked 368 pictures of other 868 are separated from the data set for testing. Moreover, two different groups of comparison vectors were created with the remaining images. First comparison vector group is created by taking the averages of each remaining person's vector values. On the other hand, second comparison vector group is created by just randomly picking one vector for each remaining person. Thus, classification performance differences between such methods "vector value averaging for each person" and "keeping only one vector for each person" could be measured.

The test data set consisting of 597 pictures was included in the classification process with both comparison groups. Maximum cosine similarity score and the score owner person for each image in the test set are calculated and results are classified as TP, TN, FP, FN with different cosine similarity threshold levels. Figure-4 and Figure-5 shows the classification results of two comparison group according to the different threshold levels.




Figure 4 - Classification performance of random pick method




Figure 5 - Classification performance of averaging method

In both methods, defining 0.44 threshold for the cosine similarity gives the best classification performance results. The highest F1 score obtained with the random pick method is 0.98623, while the highest F1 score obtained with the averaging method is 0.99452. Averaging method gives 0.83% better result at 0.44 cosine similarity threshold at which perfect classification could only be 1.38% better than random pick method.

As it is seen in Figure-6, the averaging method between 0.44-0.92 thresholds produces much more successful results than the random pick method. The reason why the random pick method is better after 0.92 is due to the fact that some of the pictures in test set were also determined as summary vectors.




Figure 6 – F1 score comparisons

Due to the images selected for the test set, the min best cosine similarity score was 0.182. Therefore, the results do not change for thresholds lower than 0.182. At the point where threshold lost its effect, the F1 score was measured as 0.76 as expected with both methods, as the classification still works according to the highest score match.

V. CONCLUSION

In systems that store a single picture of people, instead of storing a single picture vector, keeping the picture vector by averaging in accordance with the federated learning logic and keeping it increases the classification performance significantly. Deep learning models can reach a very high accuracy rate even in systems with a single image stored. In this case, the processing power and disk usage required for face recognition can be significantly reduced with the federated learning supported averaging method.

[1] Khalifa, Tariq & Şengül, Gökhan. (2017). GENDER PREDICTION FROM FACIAL IMAGES USING LOCAL BINARY PATTERNS AND HISTOGRAMS OF ORIENTED GRADIENTS TRANSFORMATIONS.

[2] Yavuz, Hasan & Cevikalp, Hakan & Edizkan, Rifat. (2016). A comprehensive comparison of features and embedding methods for face recognition. Turkish Journal of Electrical Engineering and Computer Sciences. 24. 313-340. 10.3906/elk-1301-65.

[3] Bruce, V. and Young, A. (1986). Understanding face recognition. British Journal of Psychology, 77: 305-327.

[4] Zhao W, Chellappa R. Image-based face recognition: Issues and methods. In: Javidi B, editor. Image Recognition and Classification: Algorithms, Systems, and Classifications. New York, NY, USA: Marcel Dekker Inc., 2002. pp. 375-402.

[5] Pranav K B, Manikandan J, Design and Evaluation of a Real-Time Face Recognition System using Convolutional Neural Networks, Procedia Computer Science, Volume 171, 2020, Pages 1651-1659

[6] [6] D Cherifi, R Kaddari, H Zair, and A Nait Ali. (2019) "Infrared Face Recognition Using Neural Networks and HOG-SVM." Third International Conference on Bio-engineering for Smart Technologies, Paris, France, 24-26 April, IEEE Press, pp. 1-5

[7] Karthik HS, and Manikandan J. (2017) "Evaluation of relevance vector machine classifier for a real-time face recognition system." International Conference on Consumer Electronics – Asia, Bangalore, India, 5-7 October, IEEE Press, pp. 26-30.

[8] Faruqe M, and M Hasan. (2009) "Face recognition using PCA and SVM." Third International Conference on Anti-counterfeiting, Security, and Identification in Communication, Hong Kong, 20-22 August, IEEE Press, pp. 97-101.

[9] Viola P, Jones MJ. Robust real-time face detection. Int J Comput Vision 2004; 57: 137-154

[10] Zhang BL, Zhang H, Ge SS. Face recognition by applying wavelet subband representation and kernel associative memory. IEEE T Neural Networ 2004; 15: 166-177

[11] Shen L, Bai L. A review on Gabor wavelets for face recognition. Pattern Anal Appl 2006; 9: 273-292.

[12] Tao D, Li X, Maybank SJ. General tensor discriminant analysis and Gabor features for gait recognition. IEEE T Pattern Anal 2007; 29: 1700-1715.

[13] Hafeed ZM, Levine MD. Face recognition using the discrete cosine transform. Int J Comput Vision 2001; 43: 167-188.

[14] Ekenel HK, Stiefelhagen R. Local appearance based face recognition using discrete cosine transform. In: European Signal Processing Conference; September 2005.

[15] Ahonen T, Hadid A, Pietikainen M. Face description with local binary patterns: application to face recognition. IEEE T Pattern Anal 2006; 28: 2037-2041.

[16] Tan X, Triggs B. Enhanced local texture feature sets for face recognition under difficult lighting conditions. IEEE T Image Process 2010; 19: 1635-1650.

[17] Turk M, Pentland AP. Eigenfaces for recognition. J Cognitive Neurosci 1991; 3: 71-86.

[18] Belhumeur PN, Hespanha JP, Kriegman DJ. Eigenfaces vs. Fisherfaces: recognition using class specific linear projection. IEEE T Pattern Anal 1997; 19: 711-720.

[19] Swets DL, Weng J. Using discriminant eigenfeatures for image retrieval. IEEE T Pattern Anal 1996; 18: 831-836.

[20] Cevikalp H, Neamtu M, Wilkes M, Barkana A. Discriminative common vectors for face recognition. IEEE T Pattern Anal 2005; 27: 4-13

[21] Khalifa, Tariq & Şengül, Gökhan. (2017). GENDER PREDICTION FROM FACIAL IMAGES USING LOCAL BINARY PATTERNS AND HISTOGRAMS OF ORIENTED GRADIENTS TRANSFORMATIONS.

[22] Makinist, Semiha & Ay, Betül & Aydin, Galip. (2020). Average Neural Face Embeddings for Gender Recognition. European Journal of Science and Technology. 522-527. 10.31590/ejosat.araconf67.

[23] Pranav K B, Manikandan J, Design and Evaluation of a Real-Time Face Recognition System using Convolutional Neural Networks, Procedia Computer Science, Volume 171, 2020, Pages 1651-1659

Categorical and Binary Brain Tumor Classification Using Transfer Learning Techniques

Ayşe Gül Eker¹, Gamze Korkmaz Erdem², Nevcihan Duru³

Bilgisayar Mühendisliği Bölümü^{1,2}

Kocaeli Üniversitesi

Mühendislik ve Doğa Bilimleri Fakültesi³

Kocaeli Sağlık Ve Teknoloji Üniversitesi

Kocaeli, Türkiye

aysegul.eker@kocaeli.edu.tr, gamze.erdem@kocaeli.edu.tr, nevcihan.duru@kocaelisaglik.edu.tr

Abstract— The quality and length of life may be affected by brain tumors, which are created when cells in the head region proliferate out of control. Patients with misdiagnosed or late-diagnosed brain tumors and untreated patients have a lower chance of survival. Images obtained from MR imaging equipment are typically used to diagnose brain cancers. Given the rising number of patients and the high doctor density, computer-assisted techniques are particularly helpful in the diagnosis and categorization of brain tumors. In this study, transfer learning techniques were used to classify brain tumors from MRI data. In the study, a 4-class dataset made up of glioma, meningioma, pituitary, and no-tumor was used in addition to a binary data set of tumor and no-tumor. Repetitive and unneeded regions in the images were eliminated by applying image preprocessing techniques to the datasets. Following that, classification was performed using the EfficientNet, XceptionNet, and CoAtNet models, which modified the last layer and used the weight values of the models trained on very large datasets (imagenet). As a result, show that CoAtNet performed best in multiclassification validation accuracy (98.26) and EfficientNet in binary classification (99.98). When compared to high-success studies with similar datasets, it was observed that the success metrics were quite close to those of these studies

Keywords—transfer learning, coatnet, efficientnet, xceptionnet, brain tumor, classification, medical image

I. INTRODUCTION

The brain is a massive, intricate structure that governs the whole nervous system in humans and comprises about 100 billion nerve cells [1]. This vital organ is formed in the brainstem, the core of the neurological system. Therefore, any type of irregularity in the brain could be dangerous for people's health. The most severe of these anomalies are brain tumors.

Brain tumors are defined as abnormally growing cells in the skull region. Typically, abnormal and uncontrolled cell division is what causes a brain tumor. Both the brain and the skull can develop these tumors; they can also start in the tissues surrounding the brain.

According to the World Health Organization, brain tumors account for less than 2% of all human cancers, but because of their high morbidity and comorbidities, early diagnosis is a critical idea in contemporary medicine [2].

The World Health Organization (WHO) has categorized brain tumors into four classes [1]. Meningiomas are an example of grade 1 and grade 2 tumors, while grade 3 and

grade 4 tumors are more serious ones (e.g., glioma). Meningioma, pituitary, and glioma tumor incidence rates in clinical practice are roughly 15%, 15%, and 45%, respectively.

Meningiomas, pituitary adenomas, and schwannomas are the most commonly seen benign tumors, while gliomas, which account for 78% of all malignant brain tumors, are included in the category of malignant tumors. Most benign intracranial tumors, or 10 to 15% of all neoplasms, are meningiomas, which are the most frequent type. After meningiomas, gliomas, and schwannomas, pituitary adenomas are the most frequent intracranial tumors, commonly affecting patients in their 30s and 40s. Schwannomas, which form along nerves and are made up of cells that normally provide the nerve cell's electrical insulation, also affect patients frequently in these age groups. Glia, the brain's supporting cells, give birth to gliomas, which include ependymomas, medulloblastomas, astrocytomas, and GBM, the most aggressive kind of glial tumor [3].

Depending on the location, size, and kind of tumor, there are many treatment options for brain tumors. Surgery is currently the most popular method of treating brain tumors because it has no negative consequences on the brain [4]. The inside state of the human body can be observed using a variety of medical imaging technologies, including computed tomography (CT), positron emission tomography (PET), and magnetic resonance imaging (MRI). Since MRI is the only non-invasive, non-ionizing imaging technique that provides useful information in 2D and 3D formats regarding the kind, size, shape, and location of brain tumors, it is regarded as being the most advantageous among all imaging modalities [5].

There are many artificial intelligence applications for brain tumors such as automatic brain tumor classification, brain tumor segmentation, and finding optimal routes to the tumor as we developed before, and it is a very important field [6].

Brain tumor classification is a multidomain problem that requires designing the data collection, pre-processing, denoising, segmenting, feature extraction, feature selection, classification, and post-processing procedures.

In this study, multiple brain tumor classification was performed with two datasets from Kaggle. The Kaggle BR35H dataset [7] was used for binary classification (normal/tumor), and the Kaggle Brain Tumor Classification

dataset [8] was used for multi-class classification (normal, glioma tumor, meningioma tumor, and pituitary tumor).

The work is organized as follows. In Section 2, the most recent studies in the literature that perform automatic eye disease detection with fundus images are presented. Methods are explained in Section 3. Information about the dataset used, architectures of transfer learning models, and the deep learning model is given. And explains how the experimental study was carried out. The preprocessing applied to the images and the hyperparameters of the models are presented. In Section 4, the experimental results and the success of the models are presented. In Section 5, the conclusion and discussion are presented and future work is mentioned.

II. LITERATURE REVIEW

For automatic brain MRI classification using ML and deep learning approaches, many different methods have been presented. Numerous studies using cutting-edge deep convolutional neural networks have been written to address binary and multiclass brain tumor diagnosis difficulties.

For quick and accurate tumor classification performance, Kushwaha and Maidamwar [9] suggest a model that combines the Saliency map with VGGNet, AlexNet, Inception Net, and Xception Net models. The model's 95% accuracy, 94.1% precision, and 95.6% recall make it suitable for low-error applications for brain tumor classification. Kang et al. [10] used many pre-trained deep CNNs to extract important features from the MRI scans and ML algorithms to classify the MRI scans of three freely available datasets. According to the results, the SVM with radial basis function kernel outperforms other machine learning classifiers.

Deep tumor networks, as defined by Amran et al. [11], were proposed by Google Net and CNN model hybrids for the detection of BTs. The proposed model was built on top of the GoogleNet model. The final five layers of GoogleNet were removed, and 14 layers—each one deeper than the previous—of the CNN model were replaced. Although the fundamental CNN architecture was left unmodified, the ReLU AFs were converted to a leaky Re-AF. After the modifications were made, the layers increased from 22 to 33 in total. The hybrid model that is advised acquired the maximum level of classification accuracy, 99.10%.

In [12], Four real-world data sets were successfully used to test and suggest a novel method for the diagnosis of brain cancers based on genetic algorithm-based deep learning. According to experiments on the Gazi Brain Data Set 2020 dataset, this inference was supported by four separate metrics outcomes. The proposed model achieved %85 accuracy. While the conventional CNN model had a success rate of 78%, the proposed CNN+GA model had a success rate of 85%.

Papageorgiou [13] proposed a model to follow while creating an automated and cost-effective categorization tool that will help medical professionals everywhere identify brain tumors from MRI scans. The proposed model provides 99.62% testing accuracy utilizing a cross-entropy loss function and was trained and verified using MRI images.

Sert et al. [14] and Özyurt et al. [15] propose ResNet for the first component of the CNN-SVM architecture, whereas resolution improvement and entropy segmentation approaches were used for image preprocessing. On the same dataset, Özyurt et al. [15] compare their model to a CNN-KNN with a

90.62% accuracy. The research in these articles is based on MRI image segments that simply show the tumor tissue. Sajja and Kalluri's [16] use of a CNN on a BRATS dataset of 577 photos yields an accuracy of 96.15% when tested on 182 images, showing another successful attempt to identify images with and without brain tumors.

Using an AiCNN to combine five separate models into one, Mittal and Kumar [17] identify MRI images in relation to three tumor classifications and a class for the negative diagnoses, achieving a testing accuracy of 98.8%. On two databases comprising three kinds of malignancies (meningiomas, pituitary adenomas, and gliomas), Sultan et al. [18] confirm their CNN model with overall accuracies of 96.13% and 98.7%.

Using pre-trained CNNs [19] is another strategy. On two datasets with three and four tumor types, respectively, accuracy rates of 97.64% and 98% were achieved. In order to segment the image regions containing the tumor and categorize these parts into five groups with an accuracy of 81%, Zhao and Jia [20] use a deep convolutional neural network.

III. METHODS

In this section, firstly, the datasets will be introduced. Then, the preprocessing steps applied on the datasets will be explained. Then, the used transfer learning models will be introduced and the parameters and model structure used will be mentioned.

A. Datasets

In the study, two different data sets were used for binary and multiple classifications. The BR35H for a binary dataset is also shared as open source on Kaggle. In this data set, a total of 3000 MR images with 1500 tumors and 1500 healthy ones are in jpeg format[21]. For multi-classification, a data set shared as open source on Kaggle was used. This dataset contains 2870 data for 4 classes for training; glioma, meningioma, pituitary, and no-tumor MR images in jpeg format[22].




Figure 1: A- Example image from dataset for binary classification, B- Example image from dataset for multiclassification

B. Image PreProcessing

In both brain MRI datasets, nearly all of the images have unwanted gaps and areas, resulting in below-average classification performance. Therefore, it is very important to cut photos to eliminate unnecessary parts and use only relevant information.

First, the image dimensions are set to 224*224 pixels. It is necessary to calculate the size of the unwanted black areas in the images. Thresholds are applied to images. However, before that, Blurring is performed on the images so that the Threshold process can be applied more successfully. For this, the GaussianBlur method of the OpenCV library is used. The threshold is an OpenCV technique where pixel values are assigned according to the threshold value provided. Each pixel value is compared with the threshold value, if the pixel value is less than the threshold value, it is set to 0. Otherwise, it is set to the maximum value. As a result of this process, the outside of the region we are interested in is masked. Then we contour with the coordinates of the top, bottom, right and left endpoints of the region of interest. The area inside this contour is considered the area we are interested in and the crop is done according to these coordinates. By re-sizing, the images are prepared to be given to the model.




Figure 2: Image preprocessing steps

C. Transfer Learning

Transfer learning: It is a machine learning approach in which a deep learning network (usually convolutional networks) previously trained for a task is taken with weights and used as a starting point for a different task [23]. Transfer learning has been successfully used in several fields recently, including the segmentation and classifications of medical images. In this study, preprocessed images for brain tumor classification were classified with EfficientNet, XceptionNet, and CoAtNet.

EfficientNet; It is considered a group of convolutional network models. The ImageNet classification problem consisting of more than 14 million images, reaches 84.4% accuracy with 66 M parameters and is among the state-of-the-art models [24]. EfficientNet; It consists of 8 different models between B0 and B7. The B5 model was used in this study. In EfficientNet, an activation function called Swish is used instead of Rectifier Linear Unit- ReLU. Google Brain Team: They noted that the Swish activation function tended to work

better than ReLU when applied in deeper models on a group of datasets.

XceptionNet; It is a 71-layer convolutional neural network model trained on the ImageNet classification problem and achieved 79% accuracy in ImageNet. It was basically developed by adding on the InceptionV3 network. In the convolution section, in addition to InceptionNet, smart depth convolution and smart point convolution sections have been added [25]. In this way, it is aimed to prevent over-learning by using fewer parameters.

For large-scale image identification and classification, CoAtNet offers a special mix of depthwise convolutions (1) and self-attention (2) that enables quick and precise progress. The suggested design is based on the finding that self-attention models typically demonstrate higher capacity whereas CNN's typically show better generalization.

If the model hyperparameters are mentioned; Weight values for all models are from 'imagenet'. Validation split is =0.2. Training is 30 epochs. optimizer is Adam (lr= 1e-4). Other parameters are given in Table-1.

TABLE I. HYPERPARAMETERS

Model	Hyperparameters	
	Binary	Multi-class
EfficientNet	Last_activation='sigmoid', loss='binary_crossentropy'	Last_activation=s oftmax, loss=categorical_ crossentropy
	Version=EfficientNetB0,	
XceptionNet	Last_activation='sigmoid', loss='binary_crossentropy'	Last_activation=s oftmax, loss=categorical_ crossentropy
	Version='XceptionNet',	
CoatNet	Last_activation='sigmoid', loss='binary_crossentropy'	Last_activation=s oftmax, loss=categorical_ crossentropy
	Version='CoatNetv0',	

IV. EXPERIMENTAL RESULTS

The results obtained in this section will be presented in tables. First, the validation success values for transfer learning in multiple classification are given in Table 2.

TABLE II. SUCCESS VALUES FOR MULTIPLE CLASSIFICATION

Model	Accuracy	AUC	Precision	Recall
EfficientNetB0	98.12	98.99	98.12	98.12
XceptionNet	95.63	99.40	95.63	95.63
CoAtNetv0	98.26	99.39	98.26	98.26

Accordingly, the highest accuracy values for multiple classifications were obtained with the CoatNetv0 model.

In Table 3, validation success values for transfer learning in binary classification are presented.

TABLE III. SUCCESS VALUES FOR BINARY CLASSIFICATION

Model	Accuracy	AUC	Precision	Recall
EfficientNetB0	99.98	1	99.90	1
XceptionNet	97.50	99.30	1	94.67
CoAtNetv0	99.38	99.18	99.6	99.2

Accordingly, the highest accuracy values for binary classification were obtained with the EfficientNetB0 model.

In Table 4, the comparisons of studies with similar datasets and the achievements obtained with the transfer learning model are presented. It is observed in the table that many methods are used for brain tumor binary and multiple classifications and the most successful models are CNN-based.

TABLE IV. SUCCESS VALUES FOR SIMILAR DATASETS

References	Model	Dataset	Classification	Accuracy
Kushwaha and Maidamwar [9]	VGGNet, AlexNet, InceptionNet, XceptionNet	Kaggle BR35H Brain Tumor Dataset, IEEE Data Port Dataset	Multi	95
Kang et al. [10]	CNN	BT-small-2c, BT-large-2c, BT-large-4c	Binary and Multi	98.17
Amran et al. [11]	GoogleNet, CNN	Kaggle BR35H Brain Tumor Dataset	Binary	99.10
Özdem et al. [12]	CNN+GA (Genetic Algorithm)	Gazi Brain Data Set 2020	Binary	85
Papageorgiou [13]	CNN	Kaggle BR35H Brain Tumor Dataset, Kaggle Brain MRI Images for Brain Tumor Detection	Binary	99.62
Sert et al. [14]	ResNet	TCGA-GBM	Binary	95
Özyurt et al. [15]	NS-CNN	TCGA-GBM	Binary	95.62
Sajja and Kalluri [16]	CNN	BRATS	Binary	96.15
Mittal and Kumar [17]	AiCNN	Two private datasets	Multi	98.8
Sultan et al. [18]	CNN	Dataset from Tianjing Medical University, REMBRANT DT	Multi	98.7
Ari et al. [19]	CNN	RIDER, Figshare,	Multi	99

		REMBRANT DT		
Zhao and Jia [20]	DCNN	BRATS	Multi	81
Our Study	CoAtNetv0	Kaggle Brain Tumor Classification (MRI)	Multi	98.26
Our Study	EfficientNet B0	Kaggle BR35H Brain Tumor Dataset	Binary	99.98

V. CONCLUSIONS

Brain tumors, which are formed by the uncontrolled proliferation of cells in the head region, can cause a decrease in the quality and duration of life. Patients with misdiagnosed or late-diagnosed brain tumors and untreated patients have a lower chance of survival. Diagnosis of brain tumors is usually provided by images taken from MR imaging systems. It is very useful to use computer-aided systems in the detection and classification of brain tumors due to the increasing number of cases and the high density of doctors. The development of artificial intelligence and deep learning models and automatic classification of brain tumors are very common areas of study in recent years.

In this study, brain tumor classification from MRI images was performed by transfer learning methods. In the study, a binary dataset of tumor and no-tumor, as well as a 4-class dataset consisting of glioma, meningioma, pituitary, and no-tumor, was used. By applying image preprocessing steps to the datasets, redundant and unnecessary areas in the images were removed. Then, classification was carried out with EfficientNet, XceptionNet, and CoAtNet models, which used the weight values of the models trained with very large datasets (imagenet) and changed the last layer.

According to the results of the study, while EfficientNet gave the highest success values in binary classification (validation accuracy is 99.98), CoAtNet gave more successful results in multi-classification (validation accuracy is 98.26)., which is a more challenging task. The CoAtNet model, based on both Convolution Neural Network (CNN) and Vision Transformer (ViT) architectures, is one of the most successful models developed in recent years. With this model, the advantages of both designs are successfully integrated.

When compared to high-success studies with similar datasets, it was observed that the success metrics were quite close to those of these studies. In future studies, it is aimed to achieve the highest success values by performing different transfer learning studies with more datasets for brain tumor classification.

REFERENCES

- [1] D.N. Louis, A. Perry, G. Reifenberger, A.V. Deimling, D. Figarella-Branger, W.K. Cavenee, H. Ohgaki, O.D. Wiestler, P. Kleihues, and D.W. Ellison, "The 2016 World Health Organization classification of tumors of the central nervous system: A summary," *Acta Neuropathol.*, 131, pp. 803–820, 2016.
- [2] L.M. De Angelis, "Brain tumors", *New England J. Med.*, 344(2): 2001, 114-123. <https://doi.org/10.1056/NEJM200101113440207>.

- [3] C.L. Gladson, R.A. Prayson, and W. Liu, "The pathobiology of glioma tumors", *Annual Review of Pathology: Mechanisms of Disease*, 5, 2010, pp. 33-50. <https://doi.org/10.1146/annurev-pathol-121808-102109>
- [4] R. Mehrotra, M.A. Ansari, R. Agrawal, and Anand, R.S. "A Transfer Learning approach for AI-based classification of brain tumors", *Mach. Learn. Appl.* 2020, 2, pp. 10–19.
- [5] S. Pereira, A. Pinto, V. Alves and C.A. Silva, "Brain tumor segmentation using convolutional neural networks in MRI images", *IEEE Trans. Med. Imaging* 2018, 35, pp. 1240–1251.
- [6] Dundar TT, Yurtsever I, Pehlivanoglu MK, Yildiz U, Eker A, Demir MA, Mutluer AS, Tektaş R, Kazan MS, Kitis S, Gokoglu A, Dogan I, Duru N. Machine Learning-Based Surgical Planning for Neurosurgery: Artificial Intelligent Approaches to the Cranium. *Front Surg.* 2022 Apr 29;9:863633. doi: 10.3389/fsurg.2022.863633. PMID: 35574559; PMCID: PMC9099011.
- [7] A. Hamada, "Br35H Brain Tumor Detection 2020 Dataset", Available online: <https://www.kaggle.com/ahmedhamada0/brain-tumor-detection>
- [8] Sartaj, "Brain Tumor Classification (MRI) Dataset", Available online: <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri>
- [9] V. Kushwaha and P. Maidamwar, "BTFCNN: Design of a brain tumor classification model using fused convolutional neural networks," 2022 10th International Conference on Emerging Trends in Engineering and Technology - Signal and Information Processing (ICETET-SIP-22), 2022, pp. 1-6, doi: 10.1109/ICETET-SIP-2254415.2022.9791734
- [10] J. Kang, Z. Ullah, and J. Gwak, "MRI-Based Brain Tumor Classification Using Ensemble of Deep Features and Machine Learning Classifiers", *Sensors (Basel)*. 2021 Mar 22, 21(6):2222. doi: 10.3390/s21062222. PMID: 33810176; PMCID: PMC8004778.
- [11] G.A. Amran, M.S. Alsharam, A.O.A. Blajam, A.A. Hasan, M.Y. Alfaifi, M.H. Amran, A. Gumaei, and S.M. Eldin, "Brain Tumor Classification and Detection Using Hybrid Deep Tumor Network", *Electronics* 2022, 11, 3457. <https://doi.org/10.3390/electronics11213457>
- [12] K. Özdem. Ç. Özkaya, Yç Atay, E. Çeltikçi, A. Börcek, U. Demirezen, and Ş. Sağiroğlu, "A GA-Based CNN Model for Brain Tumor Classification," 2022 7th International Conference on Computer Science and Engineering (UBMK), 2022, pp. 418-423, doi: 10.1109/UBMK55850.2022.9919461
- [13] V. Papageorgiou, "Brain Tumor Detection Based on Features Extracted and Classified Using a Low-Complexity Neural Network", *Traitement du Signal.* 38., 2021, pp. 547-554. doi:10.18280/ts.380302.
- [14] E. Sert, F. Özyurt, and A. Doğantekin, "A new approach for brain tumor diagnosis system: Single image super resolution based maximum fuzzy entropy segmentation and convolutional neural network", *Medical Hypotheses*, 2019, 133: 109413. <https://doi.org/10.1016/j.mehy.2019.109413>
- [15] F. Özyurt,, E. Sert., E. Avci, and E. Doğantekin, "Brain tumor detection on Convolutional Neural Networks with neutrosophic expert maximum fuzzy sure entropy", *Measurement*, 2019, 147: 106830. <https://doi.org/10.1016/j.measurement.2019.07.058>
- [16] V.R. Sajja, and H.K. Kalluri, "Classification of brain tumors using convolutional neural networks over various SVM methods", *Ingénierie des Systèmes d'Information*, 25(4): 2020, 489-495. <https://doi.org/10.18280/isi.250412>
- [17] A. Mittal, and D. Kumar, "AiCNNs (artificially-integrated convolutional neural networks) for brain tumor prediction", *EAI Endorse Transactions on Pervasive Health and Technology*, 5: 2019, pp. 1-18. <http://doi.org/10.4108/eai.12-2-2019.161976>
- [18] H.H. Sultan, N.M. Salem, and W. Al-Atabany, "Multi-classification on brain tumor images using deep neural network", 2019, *IEEE Access*, 7: 69215-69225. <https://doi.org/10.1109/ACCESS.2019.2919122>
- [19] A. Ari, O.F. Alcin, and D. Hanbay, "Brain MR image classification based on deep features by using extreme learning machines", *Biomedical Journal of Scientific and Technical Research*, 25: 2020, pp. 19137-19144. <https://doi.org/10.26717/BJSTR.2020.25.004201>
- [20] L. Zhao, and K. Jia, "Multiscale CNNs for brain tumor segmentation and diagnosis", *Computational and Mathematical Methods in Medicine*, 2016: 1-17. <https://doi.org/10.1155/2016/8356294>
- [21] <https://www.kaggle.com/datasets/ahmedhamada0/brain-tumor-detection>
- [22] <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri>
- [23] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- [24] Lumini, A., & Nanni, L. (2019). Deep learning and transfer learning features for plankton classification. *Ecological informatics*, 51, 33-43
- [25] DANDIL, E., & Serin, Z. (2020). Derin Sinir Ağları Kullanarak Histopatolojik Görüntülerde Meme Kanseri Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, 451-463.

Malicious file detection based on textual analysis of Windows portable executable file header information

Hidayet Takci¹

¹Sivas Cumhuriyet University, Computer Engineering
Dept., Turkey

[¹htakci@cumhuriyet.edu.tr](mailto:htakci@cumhuriyet.edu.tr)

Rabia Doğan²

²Sivas Science and Technology University, Defense
Technology Dept., Turkey

[²ra.dogann@gmail.com](mailto:ra.dogann@gmail.com)

Abstract—Malware is the most frequently used by attackers and is constantly renewing itself. The first step in minimizing the damage of malware is to detect them. Static methods, dynamic methods, and machine learning methods are frequently used in the detection of malware. With the help of these methods, the data such as system calls, file header information, and log file are analyzed and detection is performed. In our study, Windows portable executable (PE) file header information was analyzed by the static analysis method and detected with the support of machine learning. Centroid-based classifier algorithm, which is a successful classifier for textual data, was used to detect malware. Since the textual data in the Windows PE file header information will be analyzed, the algorithm has been chosen in this direction. In our study, a character-level feature set was introduced and file header information was summarized based on this feature set. The algorithm was run on these data and maximum accuracy of 100% was obtained.

Keywords—malware detection, static analysis, dynamic analysis, machine learning, centroid-based classifier

I INTRODUCTION

Malware is applications that aim to seize users' private data such as passwords, usernames, credentials, and cause systems to crash, slow down or fall under the control of malicious people [1]. In systems exposed to such attacks, primarily file losses are experienced. Another effect of malware is the execution of unknown malicious processes. The most known malware are computer viruses, worms, backdoors, Trojans, and spyware [2]. The increase in data in electronic media has brought about the diversification of malicious software [3]. As a result of this situation, malware threatens individual and corporate users by targeting thousands of systems every day.

The first step in protecting against malware is detecting them. Malware detection is known as the technique of detecting malware on the network or endpoints [4]. Three basic approaches are often used to detect malware: static analysis, dynamic analysis, and memory analysis [5]. Static analysis focuses on detecting whether software is malicious or not, without running software. Detection of file formats, code analysis, measuring the response of softwares to antivirus software, comparing the hash value of the application with the hash value of the malware, and determining whether the application is packaged or mixed with the help of programs are among the static analysis methods. Antivirus software and intrusion detection systems are prominent examples of malware detection with the help

of static analysis techniques [6]. Static analysis is sometimes known as signature-based analysis. In this analysis technique, the signature information of previously detected malware is recorded in the database and compared with the signature of the software to be tested [7]. The constantly evolving and different versions of malware cause their signatures to change. It is also known that the signature information of malicious software can be changed by various methods. For this reason, the use of the static analysis method alone is insufficient against today's advanced malware.

Dynamic analysis is performed by running malware in a completely isolated environment from the existing system and monitoring its behavior at runtime [8]. The long-running times of dynamic analysis methods, the inability to detect metamorphic malware types, and the lack of false positive rates at the desired level are disadvantages for dynamic methods. The memory analysis method, which is mostly encountered in forensic cases, is a useful technique in the analysis of malware. In that method, malicious applications are detected by taking the current image of an infected system and examining it with various tools. Tools such as Win32dd / Win64dd, Memoryze, DumpIt, FastDump are used to take the memory image of the computer. Then, while performing memory analysis on the obtained memory image, tools such as Volatility and Memoryze are used.

The static, dynamic, and memory analysis-based methods used for the detection of malicious software have been insufficient. For this reason, classical methods are now used together with machine learning and data mining techniques. Machine learning is used extensively to learn the behavior of malware and thus to classify and cluster them [5, 9, 10]. In machine learning-based method, classification and clustering techniques are performed based on features extracted from information such as byte sequences, opcodes, API calls, Windows registry, PE header information, file system accesses, and Sandbox submissions. Within the scope of machine learning algorithms, hidden Markov models [11], support vector machines [12] and neural networks [13] have been used extensively. Souri and Hosseini [14] presented an extensive review of the use of data mining methods in detecting malware. Ye et al. [15] also presented a detailed look at data mining approaches for malware detection. The authors addressed detection studies in the context of classification and clustering, while also focusing on feature extraction and feature selection. Machine learning methods have also been used to modernize traditional detection

methods. For example, Srndic et al. [16] performed the static analysis with machine learning techniques to classify malware in their study.

In this study, malware detection was performed based on Windows PE header information. The filename information contained in the PE header information has been converted into a character-level feature set and applications are classified as malicious and safe. The preferred classification algorithm is the centroid-based classifier, which is known to be successful in textual data [17].

II LITERATURE REVIEW

Malware detection is the process of distinguishing safe programs from malicious ones. Data sources used for malware detection are categorized as audit logs, system calls, and portable executables. The proposed study was carried out according to the static analysis technique and Windows PE file information was used. Therefore, in this section, examples of static analysis on Windows PE files are summarized.

Vinod et al. [18] used three different feature sets such as n-grams, command opcodes, and PE header information. The distribution criterion was preferred for feature selection in data sets. The highest classification success obtained with the IBk algorithm was obtained as TPR: 0.968 and FPR: 0.138.

Ye et al. [19] analyzed using the IAT (import address table) field of the PE file with the help of targeted association mining. In addition, 93.7% accuracy was obtained in the study on the min-max feature selection on the method.

Shafiq et al. [20] first extracted 189 features from PE file headers and then reduced the number of features according to three different feature selection methods. In the study, malware detection was made with IBk, J48, Naive Bayes, RIPPER & SMO algorithms and the correct positive rate was measured as 99%.

Wang et al. [21] suggested the use of the SVM algorithm to detect malware with the help of PE file header data. The static analysis method was used in the study and the SVM classifier was trained with the help of selected features.

Liao [22] selected 5 features from the PE file header information and used them. It was used as a rule-based classifier to detect malware. For malware of unknown type, the accuracy rate is achieved 99%.

Bai et al. [23] first extracted 197 features from PE header areas and then used feature selection methods to reduce the number of features. After feature selection, malware detection was performed with the help of algorithms such as Decision trees, Random forest, and Bagged and Boosted Decision trees. The highest accuracy obtained from these approaches was measured as 99%.

Belaoued and Mazouzi [24] established a malware detection system by analyzing PE file header information. Methods such as chi-square and phi coefficient were used for feature selection. In addition, the rotation forest classifier was used with the selected features.

Ahmadi et al. [25] proposed a paradigm for grouping malware variants. The study focused on feature selection rather than classification algorithms. It was emphasized that the features would be grouped according to the behavioral characteristics of the malware, and as a result of this paradigm, high accuracy of 99.77% was obtained.

In the study by Kumar et al. [26], classified software as safe and malicious. Machine learning algorithms such as Decision trees, Random forest, KNN, Logistic Regression, Linear Discriminant Analysis, and Naive Bayes were used in the analysis based on the header fields of portable executable files. In the proposed study, the result obtained with 10-fold cross-validation was measured as 98.4%.

In the examples where PE files are used, the studies are as given above. PE file header information includes DOS header, file header, and optional header information in general. The extracted features are the features derived from these three categories. The properties in the PE file header information can be used directly or with derived properties. In our study, the file name information from the PE file header information was handled and the information was analyzed with text processing methods.

III THE PROPOSED METHOD

In this study, malware detection is considered a text classification problem. First, a classification model was developed to categorize safe and malicious files with the help of labeled data, and then the category of unknown files was obtained with the help of the model. The static analysis method was used in our study and PE header information was used for malware detection.

Classification of files according to the proposed model is done in four steps: (1) collection of PE files from the system, (2) extraction of filename information from PE files, (3) character-level feature extraction and presentation from filename information, (4) training of the model and classification.

A. Dataset

In this study, file header information provided by a security company named Nurd Software company was used [27]. The data provided by the company are the PE header information of the files downloaded from the internet. The files are located in folders such as desktop, 7zip, and chrome according to the download location. The selected fields from the PE header information of the files in each folder are presented in the "files.csv" file. The fields in the relevant file are: file_id, file_name, file_distinct_user_count, file_sha1, file_fls_verdict, file_signer_name, file_signer_category, file_signer_status, and file_version.

Although there are many metadata related to each file in this structure since our analysis method is text classification, appropriate fields were selected and others were excluded. The fields selected by the purpose are as follows: file_id, file_name, file_fls_verdict.

The data obtained by selecting from the <files.csv> file has been recorded as a text file by the folder name. For example, the data of the files in the desktop folder are saved as <desktop.txt>. Explanation information for the fields selected from the PE header information is shown in Table 1.

There are four different class information for the files in the directory. However, those whose class knowledge is 0 and class knowledge is 3 will not be used for training purposes. Because class information 0 means "no status" while class information 3 means "unknown". As an example, the data are shown in Table 2.

As a pre-process for the next steps, "desktop.txt", which gives the information of the files in each folder, is taken as input in this step, and new files are obtained by classifying them.

Table 1 ATTRIBUTES SELECTED FROM PE HEADER INFORMATION

Attribute name	Description	Details
File_id	File number	Distinctive information
File_name	Filename (with folder structure)	The main part to be analyzed
File_fls_verdict	File type information (class information)	0: No status 1: Safe 2: Harmful 3: Unknown

Table 2 SAMPLE VALUES OF PE HEADER INFORMATION

file_id	file_name	file_fls_verdict
452	ReimageRepair.exe	1
4762	gimp-2.8.22-setup.exe	1
1067480	ccsetup538.exe	1
12992525	wind.bat	3
20274843	ccsetup550.exe	3
65259614	OptiFine_1.14.4_HD_U_F2.jar	3
68325935	OptiFine_1.14.4_HD_U_F3.jar	3

B. Feature extraction and presentation from filename information

In the previous step, the PE header information was divided into four different sub-files based on the verdict number. In this step, the filename (file_name) information contained in the PE header information will be summarized based on the feature set and vectors will be obtained. In the vector acquisition process, a frequency-based representation will be obtained based on the vector space model. All characters used in the filename are included in the acquisition of the feature set.

The character-level features included in the feature set are as follows:

{ 'a','b','c','d','e','f','g','h','i','j','k','l','m','n','o','p','q','r','s','t','u','v','w','x','y','z','0','1','2','3','4','5','6','7','8','9','[',']','(',')','.',',','-','_'

Below are examples of condensed file names based on the feature set.

2,0,0,0,5,0,1,0,2,0,0,0,1,0,0,1,0,3,0,0,0,0,0,1,0,0,0,0,0,0,0, 0,0,0,0,0,0,0,0,0,1,0,0
0,0,0,0,3,0,1,0,1,0,0,0,1,0,0,2,0,0,1,1,1,0,0,1,0,0,0,0,3,0,0, 0,0,0,1,0,0,0,0,0,3,2,0
0,0,2,0,3,0,0,0,0,0,0,0,0,0,0,1,0,0,1,1,1,0,0,1,0,0,0,0,0,1,0, 1,0,0,1,0,0,0,0,0,1,0,0
1,1,0,1,0,0,0,0,1,0,0,0,0,1,0,0,0,0,0,1,0,0,1,0,0,0,0,0,0,0,0, 0,0,0,0,0,0,0,0,0,1,0,0
0,0,2,0,3,0,0,0,0,0,0,0,0,0,0,1,0,0,1,1,1,0,0,1,0,0,1,0,0,0,0, 2,0,0,0,0,0,0,0,0,1,0,0
1,0,0,1,1,2,0,1,2,1,0,0,0,1,1,1,0,1,0,1,1,0,0,0,0,0,0,2,0,1,2, 0,0,0,0,0,0,0,0,0,3,0,4
1,0,0,1,1,2,0,1,2,1,0,0,0,1,1,1,0,1,0,1,1,0,0,0,0,0,0,2,0,1,2, 0,0,0,0,0,0,0,0,0,3,0,4

Figure 1. Example frequency values for character-level features

C. Model training and test

According to the proposed method, whether a file is malicious or not is matched to the pattern of its filename information. The filename of secure files and the filename of unsafe files have different textual properties. Therefore, the model of malicious files and the model of safe files will be obtained with the help of the information of the files whose class is known. The centroid-based classifier will be used in the model acquisition and testing.

The centroid-based classifier is one of the machine learning algorithms frequently used in text categorization. According to the algorithm, each class is presented with models called centroids obtained from training examples. To find the class of a new object, the distance or similarity between the new object and the centroid vectors of the classes is obtained. If the object to be classified is closer to the centroid value of the class, that class is assigned. The algorithm has linear complexity, is easy to use, and has fast processing capability [17].

A centroid model for secure files will be obtained from vectors of files with verdict information 1, and a centroid model for malicious files will be obtained from vectors of files with verdict information 2. Then, whether an unknown file is safe or not will be obtained by predictive methods, and with the proposed model, the files will be categorized as safe or malicious. The training and testing of the model are shown in Figure 2.

1. Model training

The centroid vector is obtained from the mean of the samples from each class with the help of vectors of known class. For example, by taking all the vectors with a safe class, the centroid for the safe class is obtained from their average, and the centroid value for the malicious class is obtained from the mean of the vectors with the malicious class.

If the vector $\mathbf{c}$ is a centroid vector representing a class of S records, each represented by $\mathbf{d}$, its calculation can be given as follows:

$$\vec{C} = \frac{1}{|S|} \sum_{d \in S} \vec{d} \quad (1)$$




Figure 2. Type prediction architecture for files of unknown type

According to the center-based classifier, in order to find the class of a file whose class is unknown, it is necessary to find the similarity or distance between the vector of the file of unknown class and the trained center vectors of each class.

To give the centroid vector of class $\vec{C}_{j \in k}$ and the file of unknown class $\vec{x}$, first, the similarity between the centroid vectors of $\vec{x}$ and classes is obtained as follows.

$$\text{sim}(\vec{x}, \vec{C}_{j \in k}) = \frac{\vec{x} \cdot \vec{C}_j}{\|\vec{x}\|_2 \cdot \|\vec{C}_j\|_2} \quad (2)$$

Then, the class of the file is obtained according to the decision rule based on maximum similarity. The decision rule is as given below.

$$\text{argmax}_{j=1..k} (\text{sim}(\vec{x}, \vec{C}_j)) \quad (3)$$

In addition to the Cosine method given in Equation 3, Manhattan and Euclidean methods will also be tested in the experiments with the help of the centroid classifier. Manhattan and Euclidean methods are distance-based methods and distance calculations are made as given in the equations below.

$$\text{man}(\vec{x}, \vec{C}_{j \in k}) = \sum \sum_{i=1..m} |\vec{x}_i - \vec{C}_{ji}| \quad (4)$$

$$\text{euc}(\vec{x}, \vec{C}_{j \in k}) = \sqrt{\sum_j \sum_i (\vec{x}_i - \vec{C}_{ji})^2} \quad (5)$$

Manhattan and Euclidean methods are distance-based methods, not similarity-based methods. Therefore, the decision rule is not to find the class that gives the maximum value but to find the class that gives the minimum value. Therefore, the decision rule will be as follows.

$$\text{argmin}_{j=1..k} (\text{man}(\vec{x}, \vec{C}_j)) \quad \text{or} \quad \text{argmin}_{j=1..k} (\text{euc}(\vec{x}, \vec{C}_j)) \quad (6)$$

The classification results obtained in the experiments were done according to these three different centroid classifier versions. The purpose of working with different versions of the classifier is to find out which one is more successful.

IV EXPERIMENTAL STUDY

The model proposed in this study is to determine whether the files downloaded from the internet are malicious or safe. To detect malicious files, filename information was extracted from the PE header information of the files and each file was summarized into a character frequency vector based on a feature set using the filename information. Also, verdict information is used as the class label in this vector. With the help of the verdict value of 1, the centroid vector for the safe class was obtained, and the centroid vector for the malicious class with the help of the verdict value of 2 was obtained. In the classification phase, three different methods of the centroid classifier (Cosine, Manhattan, and Euclidean) were used to classify the data.

In malware detection experiments, a 10-fold cross-validation method for model evaluation was applied and the results were presented with Accuracy, Precision, and Recall measurements. Accuracy alone was not used because there was a class imbalance in the data set, and Precision and Recall values were also presented.

In the presentation of the results for each method, TP, FN, FP, and TN values are presented first and then other values calculated from these are shown. Giving TP, FN, FP, and TN values were preferred to see whether malware or safe ones were detected more precisely in the classification.

TP : Number of files presumed Safe from files known to be Safe

FN : Number of files predicted as Malicious from files known to be Malicious

FP : Number of files known to be Malicious predicted as Safe

TN : Number of files known to be Malicious predicted as Malicious

As can be seen from Table 3, the classification accuracies for the centroid classifier based on the cosine similarity method are quite high. 100% accuracy was obtained for files in the Foxit folder and 99% for files in the desktop folder. The lowest classification accuracy achieved was measured as 70%. The reason for this situation is the different patterns of filenames of files in different directories.

The Manhattan method is distance-based. In the Foxit folder, where the best result was obtained in the cosine-based method, a classification accuracy of 96.1% was obtained with the Manhattan method. However, the results obtained in a folder with heterogeneous content, such as a download folder, are quite low.

Table 3 COSINE-BASED CENTROID CLASSIFIER RESULTS

	Safe		Malicious				
Directory	Safe (TP)	Malicious (FN)	Safe (FP)	Malicious (TN)	Accuracy (%)	Precision	Recall
desktop	31691	0	9	1481	99.9	0.999	1.000
acrobat	148	24	0	2	85.7	1.000	0.855
arm	87	4	0	69	97.5	1.000	0.956
avast	445	88	0	5	83.6	1.000	0.834
ccleaner	284	84	1	36	79.0	0.996	0.771
downloads	58545	0	6	4384	99.9	0.999	1.000
foxit	83	0	0	21	100.0	1.000	1.000
chrome	155	131	0	152	70.0	1.000	0.541
hp	40	1	0	12	98.1	1.000	0.975

Table 4 MANHATTAN-BASED CENTROID CLASSIFIER RESULTS

	Safe		Malicious				
Directory	Safe (TP)	Malicious (FN)	Safe (FP)	Malicious (TN)	Accuracy (%)	Precision	Recall
desktop	31094	598	13007	1814	70.7	0.705	0.981
acrobat	129	44	0	2	74.8	1.000	0.745
arm	42	49	9	60	63.7	0.823	0.461
avast	303	230	1	4	50.7	0.996	0.568
ccleaner	313	55	19	18	54.7	0.942	0.850
downloads	56956	1590	35745	8106	63.5	0.614	0.972
foxit	81	2	2	19	96.1	0.975	0.975
chrome	47	239	1	151	45.2	0.979	0.164
hp	25	16	3	9	64.1	0.892	0.609

Table 5 EUCLIDIAN-BASED CENTROID CLASSIFIER RESULTS

	Safe		Malicious				
Directory	Safe (TP)	Malicious (FN)	Safe (FP)	Malicious (TN)	Accuracy (%)	Precision	Recall
desktop	28459	3233	9050	5771	80.6	0.758	0.898
acrobat	109	64	0	2	62.2	1.000	0.63
arm	42	49	1	68	26.2	0.976	0.461
avast	8	525	0	5	2.1	1.000	0.015
ccleaner	327	41	19	18	85.1	0.945	0.888
downloads	49126	9420	23602	20248	67.7	0.675	0.839
foxit	42	1	7	14	85.5	0.921	0.987
chrome	45	241	1	151	92.3	0.978	0.157
hp	0	41	0	12	22.6	0.000	0.000

B. Comparison with past studies

Numerous studies have been conducted based on PE title information, and a comparison of the studies is presented in the table below.

The centroid-based classifier we proposed for the detection of malware gave a value at the level of the literature and above. The method is based on the assumption that the filenames of malicious software are different from the safe filenames. The accuracy of this assumption can be seen from the classification results.

Table 6 COMPARISON WITH PREVIOUS STUDIES

Author(s)	Method	Feature set	Accuracy (%)
Vinod et al. [18]	IBk algorithm	n-grams	96.8
Ye et al. [19]	Association mining	IAT table in PE file	93.7
Shafiq et al. [20]	IBk, J48, Naive Bayes, RIPPER & SMO	189 features from PE file header	99.0
Liao [22]	Rule-based classifier	5 features from PE file header	99.0
Bai et al. [23]	Decision trees, bagged, boosted trees	197 features from PE file header	99.0
Ahmadi et al. [25]	Grouping	Feature selection on PE header	99.77
Kumar et al. [26]	Decision trees, random forest, KNN, logistic regression, linear discriminant analysis, and, Naive Bayes	PE header fields	98.4
Our study	Centroid based classifier	43 features from PE file header fields	100.0

V RESULTS

The type and amount of malware are increasing day by day. It is important to detect them to get rid of the damage of malicious software. Static, dynamic, and memory-based methods come to the fore in malware detection. These methods have recently begun to be modernized with machine learning techniques. In the detection phase, information such as system calls, file header information, and operating system registry data are analyzed. In this study, with the help of a centroid-based classifier, Windows PE header information was analyzed by the static analysis technique, and the system was first trained with labeled data and then classified.

Thanks to this study, a classification algorithm was run according to the similarity principle. With the help of labeled data, a malware detection model was developed for safe and unsafe classes and files were classified according to the centroid-based classifier logic. Classification results are also at the level of the literature and above.

Due to the low complexity and high speed of the Centroid-based classifier algorithm, it can also be used for real-time detection. The centroid-based classifier is a suitable algorithm for textual data, and in this study, it was run on textual information such as file names from file header information, and high accuracies were obtained. Thanks to our study, it has been seen that Centroid-based classifiers are also effective methods of detecting malware.

ACKNOWLEDGMENT

I would like to thank Nurd Innovation Center Turkey for providing malware detection data.

- 1 Han, W., Xue, J., Wang, Y., Huang, L., Kong, Z., & Mao, L. (2019). MalDAE: Detecting and explaining malware based on correlation and fusion of static and dynamic characteristics. *Computers & Security*, 83, 208–233. <https://doi.org/10.1016/j.cose.2019.02.007>.
- 2 Damodaran, A., Troia, F. D., Visaggio, C. A., Austin, T. H., & Stamp, M. (2015). A comparison of static, dynamic, and hybrid analysis for malware detection. *Journal of Computer Virology and Hacking Techniques*, 13(1), 1–12. <https://doi.org/10.1007/s11416-015-0261-z>.
- 3 AV-TEST. (2020). Malware statistics and trends report. <https://www.avtest.org/en/statistics/malware>
- 4 Idika, N., Mathur, A.P. (2007). A Survey of Malware Detection Techniques (Vol. 48). Purdue University.
- 5 Singh, J., & Singh, J. (2021). A survey on machine learning-based malware detection in executable files. *Journal of Systems Architecture*, 112, 101861. <https://doi.org/10.1016/j.sysarc.2020.101861>
- 6 Christodorescu, M., Jha, S., Kinder, J., Katzenbeisser, S., & Veith, H. (2007). Software transformations to improve malware detection. *Journal in Computer Virology*, 3(4), 253–265. <https://doi.org/10.1007/s11416-007-0059-8>
- 7 Y Pan, X Ge, C Fang, Y Fan (2020). A systematic literature review of android malware detection using static analysis. <https://ieeexplore.ieee.org/abstract/document/9118907>
- 8 Wang, H., He, H., & Zhang, W. (2018). Demadroid: Object Reference Graph-Based Malware Detection in Android. *Security and Communication Networks*, 2018, 1–16. <https://doi.org/10.1155/2018/7064131>
- 9 Zhang, J. machine learning with feature selection using principal component analysis for malware detection: A case study, January 2019.
- 10 Singh, J., & Singh, J. (2020). Assessment of supervised machine learning algorithms using dynamic API calls for malware detection. *International Journal of Computers and Applications*, 44(3), 270–277. <https://doi.org/10.1080/1206212x.2020.1732641>.
- 11 Eskin, E., Wenke Lee, & Stolfo, S. (2001). Modeling system calls for intrusion detection with dynamic window sizes. *Proceedings DARPA Information Survivability Conference and Exposition II. DISCEX'01*. <https://doi.org/10.1109/discex.2001.932213>
- 12 Yanxin Wang, Johnny Wong, & Miner, A. (2004). Anomaly intrusion detection using one class SVM. *Proceedings from the Fifth Annual IEEE SMC Information Assurance Workshop*, 2004. <https://doi.org/10.1109/iaw.2004.1437839>
- 13 Chawla A, Lee B, Fallon S, Jacob P. Host based intrusion detection system with combined CNN/RNN model. In: *International Workshop on AI in Security*; 2018. p. 9–18.
- 14 Souri, A., & Hosseini, R. (2018). A state-of-the-art survey of malware detection approaches using data mining techniques. *Human-Centric Computing and Information Sciences*, 8(1). <https://doi.org/10.1186/s13673-018-0125-x>.
- 15 Ye, Y., Li, T., Adjeroh, D., & Iyengar, S. S. (2018). A Survey on Malware Detection Using Data Mining Techniques. *ACM Computing Surveys*, 50(3), 1–40. <https://doi.org/10.1145/3073559>.
- 16 Šrndić, N., & Laskov, P. (2016). Hidost: a static machine-learning-based detector of malicious files. *EURASIP Journal on Information Security*, 2016(1). <https://doi.org/10.1186/s13635-016-0045-0>.
- 17 Han, E.H. and Karypis, G. Centroid-based document classification: Analysis and experimental results. In *Principles of Data Mining and Knowledge Discovery*, pages 424–431, 2000
- 18 Vinod, P., Laxmi, V., Gaur, M.S., 2011. Scattered feature space for malware analysis. In: *International Conference on Advances in Computing and Communications*. Springer, pp. 562–571.
- 19 Ye, Y., Wang, D., Li, T., Ye, D., & Jiang, Q. (2008). An intelligent PE-malware detection system based on association mining. *Journal in Computer Virology*, 4(4), 323–334. <https://doi.org/10.1007/s11416-008-0082-4>
- 20 Shafiq, M.Z., Tabish, S.M., Mirza, F., Farooq, M., (2009). Pe-miner: Mining structural information to detect malicious executables in realtime. In: *International Workshop on Recent Advances in Intrusion Detection*. Springer, pp. 121–141.
- 21 Wang, T.-Y., Wu, C.-H., Hsieh, C.-C., (2009). Detecting unknown malicious executables using portable executable headers. In: *INC, IMS and IDC, 2009. NCM'09. Fifth International Joint Conference on*. IEEE, pp. 278–284.
- 22 Liao, Y., (2012). Pe-header-based malware study and detection. Retrieved from the University of Georgia: <http://www.cs.uga.edu/liao/PEFinalReport.pdf>
- 23 Bai, J., Wang, J., & Zou, G. (2014). A Malware Detection Scheme Based on Mining Format Information. *The Scientific World Journal*, 2014, 1–11. <https://doi.org/10.1155/2014/260905>
- 24 Belaoued, M., Mazouzi, S., (2015). A real-time pe-malware detection system based on chi-square test and pe-file features. In: *IFIP International Conference on Computer Science and its Applications*. Springer, pp. 416–425.
- 25 Ahmadi, M., Ulyanov, D., Semenov, S., Trofimov, M., Giacinto, G., (2016). Novel feature extraction, selection and fusion for effective malware family classification. In: *Proceedings of the Sixth ACM Conference on Data and Application Security and Privacy*. ACM, pp. 183–194.
- 26 Kumar, A., Kuppusamy, K., & Aghila, G. (2019b). A learning model to detect maliciousness of portable executable using integrated feature set. *Journal of King Saud University - Computer and Information Sciences*, 31(2), 252–265. <https://doi.org/10.1016/j.jksuci.2017.01.003>
- 27 Nurd. (2022). Best Research and Development Solution Provider. Retrieved 2022, from <https://www.nurd.com>

Deep Learning-Based Super Resolution Applications on Thermal Images for Different Upscaling Factors

Fatih Mehmet Senalp

Department of Electrical and Electronics Engineering
Konya Technical University

Konya, Turkey
fatih.senalp@gmail.com

Murat Ceylan

Department of Electrical and Electronics Engineering
Konya Technical University

Konya, Turkey
mceylan@ktun.edu.tr

Abstract—Thermal camera systems are safe imaging tools that provide contactless temperature measurement. Thermal imaging systems are used in many public sectors where it is necessary to detect the change of temperature values. However, thermal cameras are costly and produce images with low edge information. This situation prevents the widespread use of thermal cameras. Therefore, in recent years, the researches to advance the quality of thermal images have increased. In this paper, super resolution applications are performed on the thermal dataset by using different upscaling techniques. Here, a new deep network model is proposed and the results of this model are compared with the important deep learning-based models. The obtained results were interpreted both visually and using image quality metrics, and it was observed that the developed deep network model had superior success.

Keywords—super resolution, deep learning, thermal imaging, image quality metrics

I. INTRODUCTION

Thermal imaging systems make invisible infrared radiation visible in the form of heat zone images. They show the structure of the image with the colors and shapes according to infrared energy. While obtaining images with thermal cameras, lighting and weather conditions do not have any negative effects on thermal cameras. So, thermal images can be produced even in dark, rainy and foggy environments. Thermal cameras were used for security and military purposes in the beginning; construction, infrastructure, electricity, etc. It is also widely used in the fields [1]. In addition, thermal cameras, which have an important place in the medical field, help experts as a non-invasive and harmless tool in problems such as disease diagnosis. However, thermal (infrared) imaging systems also have some disadvantages. Thermal camera systems have high cost. In addition, edge information (high frequency regions) cannot be obtained exactly in thermal images and blurry images with low level of detail are obtained [2]. For this reason, the need to increase the resolution of thermal images has emerged and super resolution methods have been widely used in recent years. For example; various super resolution (SR) implementations were performed by using thermal face images, thermal satellite images, thermal images of avenue and street views [3]. Super resolution is a technique of creating another high resolution (HR) image using the observed low resolution images. In other words, the term of super resolution is described as approximating ground truth (high resolution) image from its low resolution (LR) counterpart. The interpolation methods are used in basic works on image enhancement. Interpolation is a method of predicting new unknown pixel value using known pixel values. There are three main interpolation methods used: nearest neighbor (k-NN), linear and bicubic [4]. In recent years, image quality improvement works using deep learning-based architectures have become popular.

Firstly, convolutional neural networks (CNN) based models were used for deep learning based super resolution studies. Dong et al. presented the SRCNN model and

applied the end to end mapping technique between LR and HR images [5]. However, such shallow neural networks have limited the ability to obtain multi-level features of the input images. Noting that the preceding edge is favorable for image super resolution, Liang et al. used Sobel edges with low resolution images to train the deep network model [6]. However, there was no obvious improvement in the success of the model. Later, Kim et al. designed the VDRS model inspired by the SRCNN model and they used the residual learning method. In addition, they arranged the number of convolution layers as 20 instead of 3 and achieved more successful results [7]. Here, the peak signal to noise ratio (PSNR) value increased in the range of 0.5-1 dB and the structural similarity index measure (SSIM) values increased in the range of 1-3%.

In CNN-based applications, it is aimed to minimize the mean squared error (MSE) as much as possible. In recent years, generative adversarial networks (GAN)-based models have been proposed in order to obtain better quality images in terms of visuality. Ledig et al. designed SRGAN deep network model and applied skip connection method in the generator of this model [8]. The SRGAN model provided more successful results than CNN-based models in terms of visuality. This situation has increased the interest in GAN-based super resolution applications. Park et al. presented SRFeat model using two discriminator networks to distinguish not only the reconstructed images, but also hierarchical features in the feature space. This additional discriminator network forces the generator network to draw attention to the feature approach when generating super resolution images [9]. Later, Wang et al. developed the SRGAN model and proposed the ESRGAN model in which they used dense blocks. In the structure of this model, the input of each dense block is connected to the output of the next block, and the connections are arranged to strengthen the residual learning technique [10]. Here, it was observed that it achieved increases in the range of 0.1-0.4 dB compared to the SRGAN model. In another recent study, Senalp and Ceylan developed the TSRGAN model to perform super resolution studies on thermal images and achieved very successful results. Here, 0.6 dB more successful results were obtained in PSNR metric and 2% better in SSIM metric compared to SRGAN network [11].

In this paper, a new deep learning-based model is proposed to perform super resolution applications on the thermal dataset, which is widely used in the literature. In addition, super-resolution (SR) images were obtained for two different upscaling factors and the results were evaluated.

II. MATERIAL AND METHOD

A. Creation of Datasets

Super resolution applications carried out within the scope of this paper were carried out on the FLIR dataset consisting of thermal images [1]. Sample thermal images of the FLIR dataset are given in Fig. 1. This dataset consists of high resolution (HR-ground truth) and 1/4 downsampled low resolution (LR) images. In addition, 1/2 downsampled low resolution datasets were obtained, which were used in super

resolution studies for different upscaling factors. The dimension of high resolution (ground truth) images is 160x160. The dimensions of low resolution (LR) images are 80x80 and 40x40 respectively. These two different datasets all contain 650 randomly selected HR-LR thermal image pairs from the FLIR dataset. Here, 600 of these image pairs are allocated as training datasets and 50 image pairs as test datasets. The test datasets were randomly selected from the created dataset. Also, the training and test datasets arranged to be independent of each other.



Fig. 1. Sample thermal images of FLIR dataset.

B. The Proposed Model

In this part, the comprehensive information is given about the “Thermal Images Super Resolution Generative Adversarial Networks Plus” (TSRGAN+) model, which was developed to increase the success of super resolution studies and to provide a faster training process. This proposed model is a GAN based model and consists of generator and discriminator network parts. The generator network creates the super resolution image (SR) by upscaling factors. According to the working principle of the presented model, backpropagation is applied by taking advantage of network loss. The working principle of the TSRGAN+ architecture is shown in Fig. 2 [11].




Fig. 2. The working principle the TSRGAN+ model.

In the developed TSRGAN+ architecture, the training speed is increased by not using batch normalization layers. In addition, thanks to the swish activation function used, the learning on non-linear values in the negative axis was provided, and the vanishing gradient problem was prevented. Also, skip connection method was applied in the part of generator network to increase the success of the TSRGAN+ model. Also, instead of the training process with small image patches as is generally practiced in literature studies, the training processes of presented applications were carried out with image patches in the exact dimensions of LR and HR (ground truth) images, and more successful results were obtained.

$$\delta_G = \min \frac{1}{N} \sum_{n=1}^N L_{tsrgan+}(G_{\delta_G}(I_n^{LR}), I_n^{HR}) \quad (1)$$

In the formula given in (1), while δ_G represents the weight and standard deviation values of developed model, G represents the SR image. Also, I_n^{LR} and I_n^{HR} represent samples of the created training dataset, respectively. Representing the perceptual loss $L_{tsrgan+}$, it is also the loss of the deep network used in the backpropagation method and is used to improve the visual quality as well as the improvement in metric values [12]. The formula of this perceptual loss value is given in (2).

$$L_{total(tsrgan+)} = \underbrace{L_{mse} + L_{vgg}}_{L_{content}} + L_{adversarial} \quad (2)$$

C. Image Quality Metrics

The peak signal to noise ratio (PSNR) is used to calculate a ratio based on the effect of distortion noise between two signals, which affects the signal quality. This ratio calculated for two images is calculated in decibel form. Peak signal-to-noise ratio is one of the most common and important quality evaluation metrics used to evaluate the quality of super-resolution images as a result of reconstructing low quality images. The original signal is considered as the reference data, while the noise is defined as the error due to compression or distortion. PSNR can be expressed as an approximate estimate of human perception of reconstruction quality. The formula for calculating PSNR is given in (3). In this equation, I_0 symbolizes ground truth image and I symbolizes the generated super resolution image [13].

$$PSNR = 20 \times \log_{10} \left(255 \sqrt{MSE(I, I_0)} \right) \quad (3)$$

The structural similarity index (SSIM) is a perception-based metric. In this method, image distortion is accepted as a perceptual change in structural information. SSIM estimates the perceived visual quality of images and videos. That is, it measures the similarity between original (reference) and reconstructed images. The formula for calculating SSIM is given in (4), and the symbols $\mu_R(n)$ and $\mu_D(n)$ are the n th part of the reference (I_R) and distorted (I_D) image sequence. represents the mean of the frame. Also, $\sigma_R(n)$ and $\sigma_D(n)$ represent standard deviation [14].

$$SSIM = \frac{[2\mu_R(n)\mu_D(n) + C1][2\sigma_R(n)\sigma_D(n) + C2]}{[\mu_R^2(n) + \mu_D^2(n) + C1][\sigma_R^2(n) + \sigma_D^2(n) + C2]} \quad (4)$$

III. EXPERIMENTAL RESULTS

In this section, the obtained results on the FLIR dataset of the trained deep network models are presented both visually and as metric values. Two test datasets were used for applications to be performed with different upscaling factors (2 and 4) and the results were shared separately. Here, the results of TSRGAN+ model are compared with SRCNN, SRGAN and TSRCNN. The samples of the obtained super-resolution (SR) and ground truth images are shown in Fig. 3.




Fig. 3. Samples from the obtained thermal images.

Then, the success performances of super-resolution images created from images in different test datasets were evaluated by considering the values of PSNR and SSIM metrics. The results of the metric values calculated from the obtained images are given in Table 1. The best results are shown in bold and the second best values are underlined. When PSNR and SSIM results are examined, it is observed that the deep network has a superior performance compared to SRCNN, SRGAN and

TSRGAN models. Here, it has been observed that TSRGAN+ model achieves more successful results in terms of PSNR values by 0.5 dB compared to the TSRGAN model, 1 dB according to the SRGAN model and 0.9 dB compared to SRCNN. Also, when SSIM values were analyzed, it has been seen that TSRGAN+ model was 1% and 2% more successful when compared to the TSRGAN and SRGAN models, respectively.

TABLE I. PSNR AND SSIM RESULTS

	<i>Bicubic Interpolation</i>		<i>SRCNN</i>		<i>SRGAN</i>		<i>TSRGAN</i>		<i>TSRGAN+</i>		<i>HR (Ground Truth)</i>	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
×2	34.302	0.849	34.694	0.876	34.885	0.872	<u>35.194</u>	<u>0.889</u>	35.732	0.892	∞	1
×4	30.115	0.748	30.618	0.771	30.526	0.773	<u>30.920</u>	<u>0.782</u>	31.497	0.794	∞	1

IV. CONCLUSION

In this paper, TSRGAN+ model has been developed to implement super resolution studies using FLIR dataset of thermal images. The studies were carried out on two datasets with different image sizes obtained from the FLIR dataset. Here, the studies have been carried out for different upscaling factors (×2 and ×4) and the success of the model has been proven. The achievements of the TSRGAN+ architecture were compared with state-of-the-art models in the literature. It was seen that it achieved more successful results in terms of both the quality of visual perception and the values of image quality metrics. In the proposed model, removing the batch normalization layers and increasing the convolution layers contributed positively to the success of the model. Here, a more efficient model has been obtained in terms of training speed with the use of the skip connection technique. In addition, although the proposed model is based on GAN, it has shown a superior success in terms of PSNR and SSIM values compared to CNN-based SRCNN model. This situation is important because the CNN-based models are mostly referred to as PSNR-oriented models in the literature. Here, the aim is

to achieve success in metric values rather than visual quality. On the other hand, the aim of the studies carried out in this paper is to visually create higher quality super-resolution images and to support this situation with metric values. Consequently, it has been seen that edge details (high frequency information) was successfully obtained and sharper thermal SR images were reconstructed by removing the blur.

REFERENCES

- [1] V. Chudasama, et al., "TherISuRNet- A computationally efficient thermal image super-resolution network," IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Pp. 388-397, 2020.
- [2] A. H. Ornek, M. Ceylan, and S. Ervural, "Health status detection of neonates using infrared thermography and deep convolutional neural networks," *Infrared Physics & Technology*, 103, 2019.
- [3] S. Anwar, S. Khan and N. Barnes, "A deep journey into super-resolution: A Survey," *ACM Computing Surveys* 53:1-34, 2020.
- [4] P. Thevenaz, T. Blu, and M. Unser, "Image interpolation and resampling," *Handbook of Medical Imaging, Processing and Analysis*, Academic Press, San Diego, USA, 2000.
- [5] C. Dong, C. C. Loy and X. Tang, "Accelerating the Super-Resolution Convolutional Neural Network," *Computer Vision ECCV 2016 Lecture Notes in Computer Science Springer* 9906, 2016.
- [6] Y. Liang, J. Wang, S. Zhou, Y. Gong and N. Zheng, "Incorporating image priors with deep convolutional neural networks for image super-resolution," *Neurocomputing*, 194:340-347, 2016.
- [7] J. Kim, J. K. Lee and K. M. Lee, "Accurate image super-resolution using very deep convolutional networks," *IEEE CVPR*. pp. 1646-1654, 2016.
- [8] C. Ledig, et al., "Photo-realistic single image super-resolution using a generative adversarial network," 2017 IEEE Conference on Computer Vision and Pattern, 2017.
- [9] S. J. Park, H. Son, S. Cho, K. S. Hong and S. Lee, "Srfeat: single image super-resolution with feature discrimination," In: *Proceedings of the European conference on computer vision (ECCV)*, pp. 439-455, 2018.
- [10] M. Wang, Z. Chen, Q. M. J. Wu and M. Jian, "Improved face super-resolution generative adversarial networks," *Machine Vision and Applications*, 31:22, 2020.
- [11] F. M. Senalp and M. Ceylan, "Deep learning based super resolution and classification applications for neonatal thermal images," *Traitement du Signal* 38(5):1361-1368, 2021.
- [12] J. Johnson, A. Alahi and F. Li, "Perceptual losses for real-time style transfer and super resolution," In *European Conference on Computer Vision (ECCV) Springer*, pp. 694-711, 2016.
- [13] H. Javaid, T. K. Babar, A. Rasool and R. U. Saghir, "Video colour variation detection and motion magnification to observe subtle changes," M.Sc. Thesis, Blekinge Institute of Technology, Faisalabad, Pakistan, 2013.
- [14] F. M. Senalp, B. Orhan, and M. Ceylan, "Cloud environment-based super resolution application for thermal images using the new approach TSRGAN+ model," *Multimedia Tools and Applications*, 2022.

Forecasting of Terminal Voltage of Li-FePO₄ Batteries in the Context of Dynamic Current Profile Using Machine Learning and Artificial Intelligence: Decision Tree Algorithm and Artificial Bee Colony Algorithm

Taner ÇARKIT

Department of Electrical and Electronics Engineering
Kırklareli University
Kırklareli, Turkey
tanercarkit@klu.edu.tr

Sümeyye ÇARKIT

Department of Electrical and Electronics Engineering
Erciyes University
Kayseri, Turkey
sumeyyeb.carkit@gmail.com

Abstract—To defining battery behaviors and parameters, many alternative ways are used in the literature, such as direct measurement methods, model-based methods, and data-based methods, which contain the algorithms used in this paper also. The main purpose of this paper is to show a powerful and highly correct way of parameter estimation of the Li-FePO₄ battery. One of the aims of the study is to examine the regression decision tree algorithm by showing that data classification methods can also be used in regression operations. Another goal of this paper is to show the prediction performance of the artificial bee colony algorithm, which has a very limited number of applications on the battery parameter of literature, under variable discharge profiles and shows improvement by comparing with different studies. Thanks to this target, the equivalent circuit and various parameter loads in some other methods are disabled. Machine learning and artificial intelligence, which are applied by researchers to new fields, make a direct contribution to the literature and guide future researchers. The decision tree algorithm which is one of the machine learning methods, and the artificial bee colony that is one of the artificial intelligence algorithms, are used in the determination of the parameter of A123 Systems 26650 cylindrical type Li-FePO₄ battery cells, which are the focus of this study. Under the dynamic current profile, state of charge, charge/discharge step time, and current information are taken into account to determine the cell voltage that varies between 100% and 60% state of charge. In the process of comparing the methods with each other, the statistical information of error types has been used. As a result of the study, it has been determined that the decision tree algorithm, which is often used in classification processes, can be used in parameter estimation of Li-FePO₄ batteries like as regression process with regression value of 0.9575. It has been seen that the artificial bee colony algorithm, which is a young algorithm, has been more successful than the other method with the mean value of the squared errors of 2.0285e-05, the absolute error value of 0.0031, and regression value of 0.9992. In addition, it has been determined that the artificial bee colony algorithm performs more successfully than two different methods selected from the current literature, apart from the decision tree algorithm.

Keywords—machine learning, decision tree, artificial intelligence, bee colony, parameter, battery

I. INTRODUCTION

A convenient battery management system (BMS) is needed for good management of battery blocks in electronic

systems. For increasing the performance and control capability of BMSs, the correct algorithm have to be running. In order for BMSs to step in at the right time and interfere with my system, it is important to determine parameters such as battery current (I), open circuit voltage (V_{oc}), terminal voltage (V_T), state of charge (SoC), number of cycles (N_c), and state of health (SoH) with consistent accuracy.

There are many different methods that have been tried on Li-Ion batteries in the literature. There are different traditional approaches such as Coulomb counting, electrical equivalent circuit models, and mathematical or electrochemical models for the detection of V_T , which is the subject of this study and is highly dependent on the SoC. The development of data science (DS) necessarily incorporates machine learning (ML) and artificial intelligence (AI) techniques into applications in the field of parameter estimation of Li-Ion batteries. ML models allow researchers to extract patterns and trends from data and enable them to generalise the finding to the novel data with affordable computations [1]. However, the number of studies conducted with the algorithms that are the subject of this study is either very limited or nonexistent. Therefore, it is clear that this study will contribute to the literature to increase the number of sources.

Huotari et al [1], have carried out studies on Li-Ion batteries for enhancing the operating performance of electric forklifts. A good battery design has been tried to be achieved by using SoH and N_c estimation. At this stage, autoregressive integrated modeling average (ARIMA) and supervised learning (bagging with DT as the base estimator; BAG) has been used. Gradient boosted decision trees (DT) are trained for SoH estimation in Khaleghi et al.'s studies [2]. Ipek et al. [3], have studied SoC estimation for Li-FePO₄ batteries by using support vector machine (SVM) and DT-based eXtreme Gradient Boosting (XGBoost). Niri et al. [4], has used AI technology to develop electrodes during the production of Li-Ion batteries. Correlation has been made between production parameters and electrode quality. ML models have been developed to measure the predictability of electrode and cell properties. Chemali et al. [5], have investigated SoC estimation by using artificial neural networks (ANN) to develop BMSs used in Li-Ion batteries. Wang et al. [6], have used support vector regression (SVR) optimized by artificial bee colony (ABC) to determine the lifetime of Li-Ion

batteries. Yan et al. [7], have used empirical model and exponential model powered with ABC to find the usable current capacity that varies depending on N_c in Li-Ion batteries. Carkit et al. [8], have defined V_{oc} and V_T as the SoC dependent function by using the electrical equivalent circuit model. Also, particle swarm optimization (PSO), genetic algorithm (GA), and ABC methods have been used in the study. It has been determined that ABC performs successfully according to PSO and GA. Ipek and Yilmaz [9], have studied SoC estimation using XGBoost and hybrid XGBoost under dynamic operating conditions.

This study contributes to the data-driven approaches by using DT and ABC to predict SoC and V_T .

II. DECISION TREE AND ARTIFICIAL BEE COLONY ALGORITHMS

Decision tree algorithm is a method often used in classification processes in DS and ML. Clustering and prediction processes can be included among the other application areas of the algorithm in the literature. The operation of this algorithm that is given Fig. 1, is based on the tree structure [10]. In the structure of decision trees, there are leaves at the far end [11], branches extending from the leaves to the nodes, and the main trunk extending from the nodes where the branches meet to the roots. The algorithm reaches the conclusion point by determining its own path according to the "Ok" or "Not-Ok" answers given to the conditions at the node points. The information sent to the algorithm is divided into smaller pieces and used to reach the final goal [12]. While doing this, many nodes are determined by the algorithm as in Fig. 1, which consists of control conditions. The first node in the structure of the data tree is called the "root node".

$$V_{T(SoC)} = a_1 + a_2(SoC)^3 + a_3(SoC)^2 + a_4(SoC)^1 + a_5 \quad (1)$$

Another method used in the study is the ABC algorithm. ABC, which is among the AI algorithms, is a current optimization method. In ABC, the basic structure of which is given in Fig. 2, bees are divided into three classes: Scout bee, onlooker bee, worker bee [13]. In ABC, scout bees approaching food sources randomly calculate the amount of food in the sources. Afterwards, the worker and onlooker bees are informed by the scout bees and the workflow of directing the bees to the sources begins. Solutions to the problem under study represent the locations of food sources for ABC. The amount of nutrients in food sources corresponds to the suitability (quality) of the solutions offered to the problem [14]. In the decision-making process in ABC, there are traces of the collective decision-making approach used by the bees in natural life in their daily operations [15].

III. PARAMETER ESTIMATION USING ALGORITHMS

The variation of the cell voltage of the A123 Systems 26650 Li-FePO₄ 2500 mAh battery cell, which is the subject of this study, between 100% and 60% SoC, as seen in Fig. 3, is examined. It is aimed to accurately determine the cell voltage in Fig. 4 by using the experimental test data of the CALCE Battery Research Group [16]. For increasing the complexity and difficulty level of the study, the preferred voltage and current flow profiles are not periodic as seen in Fig. 4 and Fig. 5. Moreover, the details of non-predetermined dynamic profiles can be found in Fig. 4 and Fig. 5. At the stage of determining the V_T , the equation depending on the SoC given in (1) is used. In the equation, the V_T is defined as the

third order exponential function of SOC. $a_{1...5}$ represents the coefficients of the equation.




Fig. 1. DT's search structure, control conditions, and roots.




Fig. 2. ABC's search structure and communication status.




Fig. 3. Variation of SoC according to current profile.




Fig. 4. Changing of V_T according to current profile.




Fig. 5. Dynamic current profile.



Fig. 6. DT's decision-making strategy.




Fig. 7. Compatibility of V_T prediction value presented by DT.

The branching of the DT algorithm, which is preferred for ML purposes, according to the way it uses the data is given in Fig. 6. Final data points are reached by considering V_T , SoC, I , and test step time information. Although the speed is very high on the server where the data is processed during the operation of the DT, memory and performance requirements occur. The compatibility of the cell voltage generated using the DT algorithm with the real data is given in Fig. 7. The absolute error (e_a) and the squared errors (SE) obtained according to the information provided by DT are given in Fig. 8.




Fig. 8. Error information of DT's forecast performance.




Fig. 9. The fit of the V_T prediction value presented by ABC.




Fig. 10. Error information of ABC's forecast performance.

TABLE I. ERROR STATISTICS OF ALGORITHM OUTPUTS

Algorithms	DT	ABC
Min (e_a)	0	7.8511e-08
Max (e_a)	0.9455	0.0345
Mean (e_a)	0.0107	0.0031
Min (SE)	0	6.1640e-15
Max (SE)	0.8939	0.0012
Mean (SE)	0.0011	2.0285e-05

Although the speed of the ABC algorithm used in the AI field is high in the server where the data is processed, it is slower than DT. On the other hand, the memory and performance requirement is less than the DT. Compatibility of the cell voltage generated using the ABC algorithm with the real data is given in Fig. 9. The error information obtained

according to the information provided by ABC is given in Fig. 10. In Table-1, which constitutes the summary theme of the study, error information of DT and ABC is given. As can be seen from the table, ABC algorithm performed better than DT with $2.0285e-05$ mean SE and 0.0031 average e_a value. The data showing the comparison of the study with a similar study in the literature are given in Table-2. As can be seen, the ABC method outperformed similar methods in the literature.

TABLE II. ACHIEVEMENT COMPARISON OF PERFORMED FORECAST TECHNIQUES AGAINST SAME OR DIFFERENT DYNAMIC I-V PROFILE

Methods	Reference	R2 (%)	MSE (%)
DT	This study	95.79	0.11
ABC		99.92	$(2.02)10^{-3}$
XGBoost	[9]	98.81	$(50)10^{-3}$
Smoothed XGBoost		99.43	$(20)10^{-3}$

IV. CONCLUSION

In this study, which is planned by using up-to-date methods such as artificial intelligence and machine learning; firstly, knowledge about decision tree algorithm and artificial bee colony algorithm is given. The change of cell voltage and state of charge with the effect of dynamically showing current profile has been investigated. Estimation data of cell voltage have been obtained by running the algorithms. It is seen that the decision tree algorithm, which is generally used in classification processes in data mining, could have used in the parameter estimation of batteries with acceptable accuracy in this study. As a result of the comparison of both methods, it has been determined that the artificial bee colony algorithm has showed a more successful prediction performance. On the other hand, it has been seen that the artificial intelligence algorithm is slower than the machine learning algorithm. It has been made a decision that the artificial intelligence algorithm needs less memory and performance support. Furthermore, it has been determined that it gives more successful results than 2 different methods presented in the current reference study in the literature.

ACKNOWLEDGMENT

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors

REFERENCES

- [1] M. Huotari, S. Arora, A. Malhi, K. Framling, "A dynamic battery state-of-health forecasting model for electric trucks: Li-ion batteries case-study," International Mechanical Engineering Congress and Exposition, February 2021.
- [2] S. Khaleghi, Y. Firouz, M. Berecibar, J. Mierlo, "Ensemble gradient boosted tree for SoH estimation based on diagnostic features," Energies, vol. 13, no. 5, p. 1262, March 2020.
- [3] E. İpek, M. K. Eren, M. Yılmaz, "State-of-charge estimation of li-ion battery cell using support vector regression and gradient boosting techniques," IEEE International Aegean Conference on Electrical Machines and Power Electronics & International Conference on Optimization of Electrical and Electronic Equipment, August 2019.
- [4] M. F. Niri, K. Liu, G. Apachitei, L. Ramirez, M. Lain, D. Widanage, J. Marco, "Quantifying key factors for optimised manufacturing of li-ion battery anode and cathode via artificial intelligence," Energy and AI, vol. 7, pp. 1-16, January 2022.
- [5] E. Chemali, P. Kollmeyer, M. Preindl, A. Emad, "State-of-charge estimation of li-ion batteries using deep neural networks: A machine learning approach," Journal of Power Sources, vol. 400, pp. 242-255, October 2018.
- [6] Y. Wang, Y. Ni, S. Lu, J. Wang, X. Zhang, "Remaining useful life prediction of lithium-ion batteries using support vector regression

- optimized by artificial bee colony,” IEEE Transactions on Vehicular Technology, vol. 68, no. 10, pp. 9543-9553, August 2019.
- [7] L. Yan, J. Peng, D. Gao, Y. Wu, Y. Liu, H. Li, W. Liu, Z. Huang, “A hybrid method with cascaded structure for early-stage remaining useful life prediction of lithium-ion battery,” Energy, vol. 243, p. 123038, March 2022.
- [8] T. Çarkıt, M. Alçı, “Comparison of the performances of heuristic optimization algorithms PSO, ABC and GA for parameter estimation in the discharge processes of Li-NMC battery,” Journal of Energy Systems, vol. 6, no. 3, pp. 387-400, September 2022.
- [9] E. Ipek, M. Yilmaz, “A novel method for SOC estimation of Li-ion batteries using a hybrid machine learning technique,” Turkish Journal of Electrical Engineering & Computer Sciences, vol. 29, no. 1, pp. 18-31, 2021.
- [10] F. Timuçin, A. Aytekin, A. Ayaz, “Decision tree algorithm in data mining,” 5th International Social Research and Behavioral Sciences Symposium, pp. 350-356, October 2019.
- [11] J. Han, M. Kamber, Data Mining Concepts and Techniques. USA: Morgan Kaufmann Publishers, 1st ed., 2000.
- [12] Y. Yang, S. S. Farid, F. Thornhill, “Prediction of biopharmaceutical facility fit issues using decision tree analysis,” Computer Aided Chemical Engineering, vol. 32, pp. 61-66, 2013.
- [13] D. Karaboğa, B. Baştürk, “A powerful and efficient algorithm for numerical function optimization: Artificial bee colony (ABC) algorithm,” Journal of Global Optimization, vol. 39, pp. 459-471, April 2007.
- [14] A. Doğan, “Enerji sistemlerinde en uygun yük akışının sağlanabilmesi için optimizasyon algoritmalarının kullanılması,” Master Dissertation, Dept. Elect. Electronics Eng. Erciyes Univ., Kayseri, 2011.
- [15] D. Karaboğa, D., Artificial Intelligence Optimization Algorithms, Ankara, Nobel Academic Publishing, 2014.
- [16] CALCE, Center for Advanced Life Cycle Engineering Battery Research Group. Available online: <https://web.calce.umd.edu/batteries/data.htm> (accessed on 30 November 2022).

Straights And Potential Threats Of Metaverse And Solution Suggestions

Olexandra Kalinska

*Faculty of Communication and Media Studies, Eastern Mediterranean University,
Famagusta, North Cyprus, olexandra.kalinska@mail.ru*

Abstract—The evolution of social media brought us to a new level of the social media concept of Metaverse. Social media is based on Virtual and Augmented Reality created Metaverse platforms. On those platforms, real people can create virtual avatars and use those avatars to represent the actual person in a digital world. Metaverse has applications in almost every subject from games to socialization, from education to scientific research, and from business to digital money like; Cryptocurrency, used for digital production in a virtual world. This study was carried out to emphasize the importance of Metaverse project, which is a new virtual world application offered to humanity by information technologies, for humanity and to raise awareness on particular issues. The aim of this study is to contribute to the literature on Metaverse and Artificial Intelligence and to provide a scientific resource to other researchers. In the study, first of all, what Metaverse project is and its working matrix are explained. Secondly, the straights like; easy communication, a personal assisting system that can connect to smart systems like smart homes, cars, electronic gadgets, new experiences, virtual marketing, and learning platform, and potential threats like; safety issues and privacy issues, identity theft of Metaverse was explained in this study. In the conclusion part, Metaverse and the future of social media suggestions part also added. Lastly, in the conclusion part of the study, the solutions for existing problems in communication at Metaverse platforms were suggested.

Keywords—metaverse, digitalization, artificial intelligence, virtual reality, augmented reality, digital communication, cryptocurrency

I. INTRODUCTION

Mobile Computing paradigms and technological advances have developed with remarkable speed. Some countries are newly facing 4G wireless internet, but at the same time, only a few countries started to reach 5G and 6G wireless internet (Wang & Zhao, 2022). The next-generation Internet paradigm became Metaverse (Liu, et al., 2022). With the help of internet-based and digital technologies, anyone around the world can access Metaverse platforms like; Roblox, Sandbox, Decentraland, GALA, Blocktopia, and Metahero. Meta-platforms based on Virtual Reality (VR), Augmented Reality (AR), Artificial Intelligence (AI), and Cryptocurrency. They were created for people's comfort and easy communication while using Meta-platforms. There are many advantages and disadvantages of using Metaverse. This study explained

Metaverse, Virtual Reality, Augmented Reality, Artificial Intelligence, and Cryptocurrency, the positive and negative sides of communication, and the use of Metaverse. This study concludes by giving recommendations about potential and existing threats on Metaverse, to replenish existing literature with useful information.

II. BACKGROUND OF METAVERSE

Internet technologies improve day by day. It started with a small idea and became a huge project that continues to improve. One of the latest internet-based digital development is Metaverse. The first time this terminology was mentioned in the "Snow Crash" novel in 1992 by Neal Stephenson as a Three-Dimensional world (Narin, 2021). Metaverse is a virtual universe, where people can create their avatars work, study and entertain. Metaverse is based on Virtual Reality (VR) and Augmented Reality (AR) public space that is open to everyone (Mystakidis, 2022). Metaverse is a new opportunity for many companies like; food companies, clothes and shoe companies, perfume and make-up companies, Cryptocurrency space, learning-based companies, and art companies. Moreover, people can create their universes, do their meetings and learning online with their virtual avatars, play and create games, do art, sing, dance, and swim (Yüksel, 2022).

Another point to consider is Metaverse has an important tool that helps Metaverse citizens (Metazens) do their activities, shopping, and daily tasks by using Artificial Intelligence (AI). For example; If Metazen has a smart house, AI-based personal assistant would be connected to the house, so they know what actual people have in their fridge and what they need. AI Personal assistants, also help in daily planning like; meetings and write notifications for homework. People can communicate with them via Virtual Reality Head Set. Furthermore, AI speech filters that translate languages and spam filters, so it makes communication easier (Huynh-The, et al. 2022).

III. CONCEPTUAL FRAMEWORK

The important concepts and empirical findings from this research's literature review were explained below.

A. Virtual Reality (VR)

The first time, VR technologies came up in the 1800s (Paro, Hersh, & Bulsara, 2022). This was the first photography exhibition in the world, that had an idea of the

stereoscope. The Stereoscope is a device at the first time it reminds glasses, but it is not the simple glasses that we used to see, purpose of the stereoscope is to show exactly the identically same illustrations for both left and right eyes. The interest in the VR phenomenon became very popular in the 1990s (Mazuryk & Gervaut, 1999). The media were shaking from the information that was coming all over that time. The idea of stereoscope continued until now, the only thing that has changed is the physical images became digital and they started to apply it to videos that create Virtual Reality Glasses. Virtual Reality glasses create a feeling like; people teleport and appear in another spare space, which is a digital space that calls Virtual Reality. Virtual glasses are not a must to get access to VR. Any digital technology like; Personal Computer (PC), laptop, tablet, smartphone, Play Station Portable (PSP), Play Station (PS), Television (TV), and VR headset lets anyone who owns at least one from the list above can get easy access to the Virtual Reality. Furthermore, apart from visuals, audio, sound effects, and music are also included for a better experience. Some well-known fashion brand companies, musicians, and cinema companies started to use VR as a 360-degree experience.

B. *Augmented Reality (AR)*

Another important element is AR. The transformation and miniaturization of mobile technologies have started to involve Virtual Reality based applications and platforms as well as Augmented Reality. Briefly concept of Augmented Reality is the completion of the real world with computer-generated virtual objects that seem to exist in the real world (Çavuşoğlu, 2019). After the development of VR, between 1998-2014 years, AR became another important digital tool (Arth, et al., 2015). AR integrates digital information with the real world in real-time (Carmigniani, et al., 2010). People can use AR-based applications and programs on their digital devices like; smartphones, laptops, tablets, or smart glasses. For example; AR is AR based application Snapchat. This program allows people to use face filters like; makeup, and fake hair, change their hair and eyes color, and also use some other visual and video-based filters all around their environment. Also, it allows people to play games, for example; Pokémon Go. Many people around the world can play this game freely. The logic behind this game is to find different Pokémon virtual figures to catch and collect in their virtual library.

AR is also a part of Metaverse that let people show real themselves in real-time in the digital world. It also helps people get closer to the virtual world as well as it can be used in the real world with the digital technologies that support AR.

C. *Artificial Intelligence (AI)*

Artificial Intelligence was founded by Warren S. McCulloch and Walter Pitts in 1943 known as the first sequential logic model of a neuron (Piccinin, 2004). Later, it started to develop and came until the 21st century. AI is a simulation of human intellect by digital technologies. For example; a car company named Tesla sells Artificial Intelligent cars, that can drive on their own from one destination to another. Also, with Global Positioning System (GPS) help, it can drive all around the world where it has an internet connection. So, people can sit, do other things and enjoy their time during their trip (Ahmad &

Khan, 2019). Furthermore, AI became one of the important topics in Metaverse platforms. Metazens can walk around different digital universes, during their virtual study or work, and at the same time when they need any kind of help or information, AI personal assistants, that Metaverse has created for individuals do it for them (Bansla & Bansla, 2012). On the other side, people that live in smart houses or have smart technology-based devices like; fridge, car, smart TV, etc. are connected to smartphones same as Metaverse let AI personal assistants collect and keep the information of the Metazens (Huynh-The, et al. 2022). This may lead to information leaking because of the hackers and it can create these problems: identity theft, privacy issues, and safety issues.

D. *Cryptocurrency*

Cryptocurrency is the alternative way of paying by using encryption algorithms. There are four important elements; security, utility, payment, and Stablecoins. Cryptocurrency includes; NFTs, utility, payment tokens, and assets-backed tokens. There are many available proxies like; Bitcoin, Ethereum, Ripple, Tether, etc. Nowadays, Bitcoin became the top of the other proxies in the market world (Tiwari, et al., 2019). Bitcoin and the system were invented by a group of anonymous authors under the nickname Satoshi Nakamoto in 2008 (Haeringer, et al., 2018). Blockchain is also an important element in Cryptocurrency, that let users reach strong agreements for every transaction (Catalini, et al., 2019).

Cryptocurrency plays a big role in Meta-platforms. It let Metazens to rich and get every kind of item in the virtual markets, that Metaverse has. Many companies started to interest in Metaverse platforms and they started to get lands like; some pop stars got lands for example; Indian popstar Daler Mehndi, and since Metaverse works on Cryptocurrency it is not that chip to get land there (CNBCTV18, 2022). Many marketing companies started to open their virtual companies and sell their goods to Metazens. That means they will be able to use their products in the virtual world. For example; Adidas company applied to access to AR, especially for the young Metazens. With the VR headset and any other digital technology that has an access to the internet, Metazens can try the Adidas products on their avatars and they can see themselves in these products, and then they can get them if they want (Hollensen, et al., 2022). Clothing and shoe brands are not the only companies that are available on Metaverse. Food companies like; Burger King, perfume companies like; Yves Saint Laurent (YSL), and cosmetic companies like; L'Oreal is available on Metaverse.

IV. POTENTIAL THREATS IN COMMUNICATION OF USING METAVERSE

Nowadays many digital companies collect information via social media and later they sell it to us and third parties. For example; Facebook, YouTube, and Google sell data (Fuchs, 2018). With the data commodity, they try to catch more attention and produce more data, which counts as a first problem. The second problem is security and privacy concerns (Wang, et al., 2022). Cyberattack on social media and other digital platforms is a well-known topic all around the world. The third point to consider is virtual sexual harassment and assault. These issues are one part of the

bigger problems that just technologies cannot solve without people. For example; one of the female Metazens was sexually harassed on one of Metaverse Platforms. There are many cases like these and the sad part is it become even more and worse. The fourth potential problem is; old generations can have some issues integrating future technologies fast into their daily lives. Fifth, Metaverse starting to create an addiction, especially among the young generation. As a result, it leads to depression, loneliness, self-hate, aggression, anxiety, sleep disorders (Bojic, 2022). Lastly, the distribution of fake news like; disinformation and misinformation. Nowadays, official and unofficial news posts fake news sometimes. Mostly, people watch the TV, listen to the radio, reading news on social media and most of them do not even check where that news came from, some news companies do not pass from news inspection. This leads to fake news distribution. Sometimes fake news can create catastrophic issues like; war.

V. CONCLUSION AND SUGGESTIONS OF THE STUDY

Metaverse concept became a phenomenon that most generations started to be interested in it. Metaverse helps people to communicate easier and faster. It also has many different advantages like; with VR, we can see and feel a virtual environment closer than we see via other digital gadgets, with AR we can combine the virtual and real world and use it for our purpose. AI helps people to communicate easier by making their life easier, personal assisting system people can easily make virtual orders, translate speech and other written virtual documents, Cryptocurrency is in use all around the virtual world, so people and companies can get and sell virtual goods. On the other hand, there are many existing and potential threats on Metaverse. Suggestions for existing and potential threats are written below.

- Issues like; safety and privacy can be solved by adopting security tools like; VPNs, and antivirus software. Data commodity can be solved by requesting information about the Meta-platforms and to whom they sell the information. For the sexual harassment and assaults, many Meta-platforms started to exclude parts of the Metazen avatars to prevent these problems. Also, they applied the tool so-called 'Safe Zone', which allows any virtual avatar to keep a distance between each other (Le, 2022).
- Late integration of new technologies like; Metaverse because one of the issues for the old generation, this problem can be solved by giving education and advertising by showing the possibilities of Metaverse platforms and benefits for the old generation, which would take their interest.
- Addiction is another issue that needs attention as much as other issues, especially among the young generation. Young adults started to spend more time online and less outside. Especially Metaverse became a part of their life if not all of their life. There must be educational videos and some courses for young adults on how to use Metaverse and other social media and how to manage their time, to prevent addiction and other psychological issues.
- Lastly, Distribution of the fake news is a known problem all around the world, this jumped to a new level of communication and even got to Metaverse platforms. To prevent and stop these issues AI technologies can help and

use spam, and news filters, and check the news before sharing it with the rest of Metazens.

Metaverse is a very useful and easy-to-communicate virtual and social tool that can help entertain and educate, etc. Suggested solutions will help to develop Metaverse platforms and solve these future, potential and existing problems.

REFERENCES

- [1] Ahmad, S., & Khan, M. A. (2019). Tesla: Disruptor or Sustaining Innovator. *Journal of Case Research*, 10(1), 12-24.
- [2] Arth, C., Gruber, L., Grasset, R., Langlotz, T., Mulloni, A., Schmalstieg, D., & Wagner, D. (2015, 11 11). The History of Mobile Augmented Reality. *Computer Graphics & Vision Developments in Mobile AR over the last almost 50 years*, 1-41.
- [3] Bansla, A., & Bansla, N. (2012). Artificial Intelligence. *International Journal of Applied Engineering Research*, 7(11), 1-4.
- [4] Bojic, L. (2022). Metaverse through the prism of power and addiction: what will happen when the virtual world becomes more attractive than reality? *European Journal of Futures Research*, 10(22), 1-24.
- [5] Carmigniani, J., Furht, B., Anisetti, M., Ceravolo, P., Damiani, E., & Ivkovic, M. (2010, 12 14). Augmented reality technologies, systems and applications. *Multimedia Tools and Applications*, 51, 341-377.
- [6] Catalini, C., & Gans, J. S. (2019, 4 20). Some Simple Economics of the Blockchain. *NBER Working Paper Series*, 1-39.
- [7] Çavuşoğlu, M. (2019). Bilişim Teknolojileri Destekli Turizm Endüstrisinde Yapay Zeka Ve Artırılmış Gerçeklik Uygulamaları. In S. E. Dinçer, S. Sönmez, M. Bostancı, & E. Özçoban, *Sosyal, Beşeri Ve İdari Bilimler Alanında Araştırma Ve Değerlendirmeler* (Gece Akademi, Vol. 2, pp 259-273).
- [8] CNBCTV18. (2022, 3 28). Popstar Daler Mehndi buys land in metaverse. Here's how you can be his neighbour. Retrieved 11 19, 2022, from CNBCTV18: <https://www.cnbctv18.com/cryptocurrency/popstar-daler-mehndi-buys-land-in-metaverse-heres-how-you-can-be-his-neighbour-12967992.htm>
- [9] Fuchs, C. (2018, 7). Capitalism, Patriarchy, Slavery, and Racism in the Age of Digital Capitalism and Digital Labour. *Critical Sociology*, 44(4-5), 677-702.
- [10] Haeringer, G., & Halaburda, H. (2018, 7 8). Bitcoin: A Revolution? Economic analysis of the digital revolution, 1-25.
- [11] Hollensen, S., Kotler, P., & Opresnik, M. O. (2022, 3 17). Metaverse – the new marketing universe. *Journal Of Business Strategy*, 1-7.
- [12] Huynh-The, T., Pham, Q-V., Pham, X.-Q., Nguyen, T. T., Han, Z., Kim, D.-S. (2022). Artificial intelligence for the metaverse: A survey. *Engineering Applications of Artificial Intelligence*. 117 (2023), 1-22. <https://doi.org/10.1016/j.engappai.2022.105581>.
- [13] Le, T. (2022, 7 22). Sexual assault in Metaverse is part of a bigger problem that technology alone won't solve. Retrieved 11 20, 2022, from Lens: <https://lens.monash.edu/@politics-society/2022/07/22/1384871/sexual-assault-in-the-metaverse-theres-nothing-virtual-about-it>
- [14] Liu, Y-J., Du, H., Niyato, D., F., IEEE, Feng, G., Kang, J., Xiong Z. (23/11/2022). Slicing4Meta: An Intelligent Integration Framework with Multi-dimensional Network Resources for Metaverse-as-a-Service in Web 3.0. Cornell University. 12/05/2022. <https://arxiv.org/pdf/2208.06081.pdf>
- [15] Mazuryk, T., & Gervaut, M. (1999, 12). Virtual Reality - History, Applications, Technology, and Future. 1-73.

- [16] Mystakidis, S. (2022). Metaverse. Encyclopedia, 2, 486-497.
- [17] Narin, N. (2021, 12 31). A Content Analysis of Metaverse Articles. Journal of Metaverse, 1(1), 17-24.
- [18] Paro, M. R., Hersh, D. S., & Bulsara, K. R. (2022, 11). History of Virtual Reality and Augmented Reality in Neurosurgical Training. World Neurosurgery, 167, 37-43.
- [19] Piccinin, G. (2004). The First Computational Theory Of Mind And Brain: A Close Look At McCulloch And Pitts'S "Logicalcalculus Of Ideas Immanent In Nervous Activity". Synthese, 141(2), 175-215.
- [20] Tiwari, A. K., Raheem, I. D., & Kang, S. H. (2019, 8 8). Time-varying dynamic conditional correlation between stock and cryptocurrency markets using the copula-ADCC-EGARCH model. Physica A, 535(122295), 1-9.
- [21] Wang, Y., & Zhao, J. (2022, 9 28). Mobile Edge Computing, Metaverse, 6G Wireless Communications, Artificial Intelligence, and Blockchain: Survey and Their Convergence. Proceedings of 2022 IEEE 8th World Forum on Internet of Things (WF-IoT), 1-8.
- [22] Wang, Y., Su, Z., Zhang, N., Xing, R., Liu, D., Luan, T. H., & Shen, X. (2022). A Survey on Metaverse: Fundamentals, Security, and Privacy. IEEE Communications Surveys & Tutorials, 1-32.
- [23] Yüksel, H. (2022, 01 29). Yeni Medya Ve Dijital Dönüşümün Ötesi "Metaverse". Kafkas University Journal of the Institute of Social Sciences, 22(29), 237-258.

A New Lightweight Artificial Intelligence Approach: Detecting RPL Attacks in ANN and Blockchain Based Topology in Artillery

Ali Deveci

WISE Lab., Dept. of Computer Engineering, Hacettepe University
Ankara, Turkey
0000-0002-4990-0785

Abstract— In recent years, there has been a great increase in the use and frequency of Internet of Things (IoT) networks. As technology develops rapidly, the number of security measures increases at the same rate. With IoT, devices are connected to each other and to the internet. Routing Protocol for Low Power and Lossy Networks (RPL), on the other hand, is a routing protocol used especially in resource-constrained networks, such as IoT. Unfortunately, due to its nature, RPL is vulnerable to internal and external attackers. Since resource-constrained devices are always used in military communication systems, communication must be reliable, verifiable and secure against attacks. In this study, the military artillery communication system is considered as an RPL system and communication reliability is ensured by using the blockchain and Artificial Neural Network (ANN) security systems. Here, while a model is proposed for the reliability and versatility of the communication channel that should be established between the artillery fire support systems, the other one is also proposed that allows the transition of the graphic shooting ruler shooting principles from level of gunpowder to any other level of gunpowder or from an artillery battery to another artillery battery.

Keywords—RPL, RPL Attacks, IoT, AI, Blockchain in Military, ANN.

I. INTRODUCTION

Recently, IoT security technologies gained great importance because the information and data should be transmitted to the right unit at the right time. Especially, the military information transmission, which has to be decentralized and has a distributed structure, should be successful. In addition to the safe delivery of any message from the sender to the receiver, the communication environment must also be secure. Therefore, the communication environment should be closed to external and internal attacks. Since the systems includes personal and public accountability, the other security requirement is the reliable keeping of databases and records created in every field. This accountability is limited by the legal framework. Communication can be defined as the function of sending and receiving messages in various ways [1]. Although the devices used in developing and changing communication technologies change, the objects and aims about information's security don't change. Radios, phones, smart systems and the IoT have become an integral part of our lives. IoT will offer great opportunities in many different fields such as energy distribution, smart production, public health, smart and sensitive agriculture, smart transportation [2][3]. In this case the main problem is to create reliable and verifiable data flow channels. Various names can be given to this channel. Verified and reliable personnel channel,

verified and reliable communication channel etc. At the same time, another problem area to be addressed in this study is the verification of the shifting from the gunpowder right to the gunpowder right or from the battery to another battery, known as the Graphic Shot Chart Arrangement Principles (GSCAP). In military artillery architecture, the communication tools and systems change very quickly. Wired systems, wireless systems, satellite systems are only a few of them. However, an uninterrupted, reliable and verifiable environment is required in order to receive fire requests and to perform firing missions successfully. The description of the target, which will be taken under fire in military artillery, is called Fire Request (FR). Please refer to [4] for a classical artillery communication. Although the conventional channel of transmission is encrypted, it is known to be vulnerable to RPL attacks [17][18]. This channel and the network may even be listened, interrupted or misinformed. FR broadcasts using open-data and satellite can lead to weaknesses in personnel, intelligence and logistics. Although the FR and communication in the conventional artillery system have some protection and encryption system, they are yet vulnerable to various attacks. Basically, FR and communication are performed as follows: forward observers report their target information to the fire management center via radio or satellite method, and the fire management center advertise the fire values to the firing batteries via wire or wireless channel.

The second communication system in artillery is to send the set values to another artillery battery. An artillery battery that receives this information can find the arrangement principles of its own position without making a shot, and send it to a different battery by adding its own signature. A battery sends the values to the B battery and the B battery sends the values to the C battery by adding their own signature. These two RPL network models will be explained in later chapters. Military communication systems are divided into eleven main titles [5] : Communication Systems, V/UHF Military Radios, HF Military Radios, Military Phones, Military Broadband Multimode Radio link, Modems/Converters/Routers, Internal Speech System/Internal Communication System Units, Remote Command Units and Systems, Recognition Promotion Devices, Data Link Systems, Wave Shape Designs. Due to the large-scale and distributed nature of military communications devices, they have security and verification violations. By the way, the military network and communication infrastructure should be mobile and quickly adaptable. In order to have these undesirable features, the first requirement is dynamic change in the communication infrastructure that takes place autonomously without relying on central control. Second,

military communication devices must transmit and receive the secure data. Therefore, a reliable, flexible and decentralized platform is required to meet the communication needs in military operations and wars. Also military communication systems, like a RPL network, are resource constrained networks. While ensuring communication and data security, available resources must be used efficiently. In the blockchain based military RPL communication model, it is aimed to create blockchain based data source in the form of distributed ledger technology, transparent and tamper-proof records [6]. Hence, it is an undeniable fact that a controllable platform with tamper-proof features is required to rely on the military communication environment to overcome the challenges presented and increase the reliability of the information collected. Another important issue is the existence of noise-free data. For this, the model has been tried to be free from noise by using an artificial neural network model. This study provides a secure RPL network based on blockchain and neural network technology in military artillery class.

II. LITERATURE REVIEW

The first research [7] a blockchain-based application architecture for Military IoT are proposed. The models have five layers. Application, Service, Network, Access, Sense layer. Three different application modes are designed for using these layers. These application modes are Physical Detection Mode, Network Transmission Mode and Information Service Mode for MIOT. With the created architecture, it is evaluated that it can be used especially in weapon control systems, ground access systems and tactical network structure. No laboratory studies have been performed in this study. A blockchain based model is proposed in [8]. Here the model can be used in various military applications such as Logistics, Artillery, Surveillance. A blockchain-based ammunition transfer system model is created especially during the period from the moment the bullet is produced until it came out of the barrel. Traditional consensus models are applied as consensus. An authentication model for objects using blockchain is proposed in [9]. The gateway and Ethereum address for all objects are created. Here, a direct SSL connection between the user and the objects are explained. The authentication between the user and the gateway has two factors. Therefore, the user must authenticate. A blockchain based study [10] introduced a HTOP-like mutual authentication protocol for RFID tags using the blockchain. In the model, each RFID tag is identified by Ethereum addresses. Ethereum Balance is used during mutual authentication, and after each successful transaction, the specified amount of money is sent to the address. Thus, a new balance value is formed. Here, how the Ethereum address is created for RFID tags is not clearly defined in the study. A blockchain based model called "Blockchain-based Secure Communication Application Proposal" is proposed in [11]. Here, the application called "Cryptouch" is developed. They used blockchain infrastructure, PoW consensus mechanism, IPFS (Interplanetary File System Protocol). IPFS could overcome some difficulties caused by direct P2P communication. Energy consumption measurements explored [12]. ESP32 device, and RSA/ECC algorithms is used in the study. During the implementation of these algorithms, comparisons of performances are given using different parameters. Three-layer architecture based model is proposed in [13]. The recommended layers in the study are Battlefield IoT layer,

Network layer and Consensus and Service layer. They evaluated Battlefield IOT and its sensors as the main element in the study. Blockchain architecture forms the basis of the architecture. This architecture has a hierarchy and consensus mechanisms based on hierarchy. A study called "Secure P2P communication based on blockchain" [14] is proposed a security model. In particular, the security messaging and mailing processes using "S / MIME and PKI" techniques is evaluated. They considered that some security applications could be overcome by MITM and EFALL attacks, so they created a model consisting of Smart Contract, Blockchain registration, Smart Contract based authentication and messaging system. They evaluated the proposed model is more feasible and safer than traditional models, and could be used even if it is not reach a full safety level. An unveiled scalable access control architecture model is proposed in [15]. In this model, all objects have an Ethereum address. The list defined for access control is kept on the blockchain network. Here, the restricted application protocol (CoAP) is used datagram transfer layer security (DTLS) for transmission security. The management center in the model links objects to the blockchain. Hence, objects cannot be directly connected to the network. There isn't any information about how the thing and the hub authenticate each other. A blockchain based P2P Applications is proposed in [16]. They created a detailed analysis model and they evaluated the wireless networks of IOT devices. The ones used for the infrastructure are LoRaWAN, NB-IOT and SigFox. All devices that want to log into the system with an Internet Service Provider are licensed. The Cloud Computing model is used to store data or for a repository, and they used SaaS and PaaS in the study. Here it helps users manage data and applications on both systems. The model was carried out through built interfaces. With these interfaces, data monitoring and identity management can be provided.

III. ANALYSIS

In this study, two different RPL communication models are presented as an artillery communication security and data flow advertisement model. Sending the fire request is explained in first model and the blockchain model added to the artificial neural network is explained in the second model.

A. Military Artillery Units Communication And The First Model : Blockchain Based Communication Model

The saying "no battle without communication" in the military literature is still valid in military artillery. It is impossible for artillery systems to perform their military duties without communication. An effective communication environment must be available to transmit or advertise the necessary mission information from the forward observer to the fire management center and the fire management center to the batteries. Regardless of the type of operation to be carried out, all artillery units have a single mission. This task is to hit-kill the desired target at the desired time and at the desired activity. The smallest hitch in the communications system makes it impossible to do this task. In addition, the importance of reliable and verifiable communication becomes apparent when it is considered that artillery shells are fired over the friendly troops when necessary. An artillery shooting team consist of a forward observer, a fire management center and a battery. These three units are shown in Fig.1.



Fig. 1. Artillery Units' Communication

The forward observer defines target and evaluates information about the target. It reports the evaluation result to the fire management center via radio or satellite. The information here is stored in a database. Even if this data is sent encrypted, it can be listened to with the same style of devices and it may be exposed to electronic printing.

The fire management center, which takes target information, makes its own evaluations and calculations. In fact, the main task of the fire management center is to translate target information into numerical data. All data transmitted to the this center contains confidential information. Not only text data bu also it may be necessary to send information such as pictures and videos in a secure environment. However, sometimes this transmission can be very difficult. Since the blockchain structure offers a reliable and verifiable platform, it is considered that a blockchain based model can solve security and verification problems. This technology can provide data encryption and some consensus mechanisms among users. The encryption includes encryption methods such as SHA-256.

Conventional communication and conventional fire request' steps, and Blockchain based communication are given in Table I and Table II.

TABLE I. STEPS OF CONVENTIONAL FIRE REQUEST

Step	Function
1	Detect Target
2	Evaluate Target (quality, number, latest mobility etc.)
3	Guess the Movement of the Target (What is he doing?)
4	Add Additional Reviews, if applicable
5	Send target information to the upper unit (Fire headquarters / Operation center).
6	The information obtained was approved by the fire headquarters.
7	Recording of data (recording in the database).
8	Evaluation of the data by the fire management center.
9	Deciding to put the target under fire?
10	If the target is to be fired, alert the best gunner battery and send the information to this battery
11	The fire management center and the artillery battery decide the most suitable projectile and artillery plug combination according to the target information.
12	Execute the shot.
13	Evaluate the effect observed as a result of the shot.
14	Inform the commander after the mission is completed.

TABLE II. BLOCKCHAIN BASED COMMUNICATION AND FIRE REQUEST

Step	Function
1	Detect Target.
2	Evaluate Target (quality, number, latest mobility etc.)
3	Guess the Movement of the Target (What is he doing?)
4	Add Additional Reviews, if applicable
5	Creation of the first block for sending information
6	Send target information to the upper unit (Fire headquarters / Operation center)
7	Recording of data with TX information (recording in the

	database)
8	Evaluation of the data by the fire management center.
9	If the target is to be fired, alert the best gunner battery and send the information to this battery
10	Adding information into the created block
11	The fire management center and the artillery battery decide the most suitable projectile and artillery plug combination according to the target information.
12	Execute the shot.
13	Evaluate the effect observed as a result of the shot.
14	Inform the commander after the mission is completed.
15	Complete block information
16	Closing the block by performing the old block switching.
17	Preparation for the new linked block.

1) Blockchain Based Artillery Communication Architecture: In military artillery applications, the distributed ledger structure of the blockchain system should be in the foreground. In this way, it is possible to execute commands or orders online. In this study, a three-layer architecture was created for this system. The three-layered architectural layers are shown in Table III. Four different elements have been identified that will work and provide operation in this three-tier architecture. Who these elements are and the layers they work with are presented in Table IV.

First and end users: People who initiate data transmission or provide data reception using devices generally. The fire control center staff, who send the fire request to the forward supervisor and the arrangement values to the other battery, are first and end users. The account book, private / public network key for each user has a unique system identification number and MAC address provided by the system administrator.

1) Commanders: Commanders in their hierarchy tree sign the TXs of units. Private key system identification number is used in signing operations.

2) Create and Publish Operator: The task of this unit is to create blocks and create a smart contract between the units, starting from the forward watcher, the unit where data transfer first started. All TXs that have passed the approval are kept in the so-called TX pool. The management of the TX pool is the responsibility of this unit. The blocks to be created carry this unit's own signature, block urgency code, previous block information, and promotional information when added to the blockchain. These units must keep all blocks created in the system in the pool.

3) System Administrator: Checks whether the system is working properly. Feedback is collected here. The system manager is the commander's special headquarters officer. One can be specified for over 5000 devices. Smart contracts that are created especially in the process of inclusion of blocks in the system are regulated by this unit.

TABLE III. THREE LAYERED ARCHITECTURE

Layer	Function/Name
1	Data and Information Collection Layer
2	Control and Merge Layer
3	Block Creation Layer

TABLE IV. THREE LAYERED ARCHITECTURE ELEMENTS

No	Name	Layers
1	First and End User	1,2,3
2	Commanders	1,2,3
3	Create & Publish Operator	2,3
4	System Administrator	1,2,3

B. Layers

1) *Data and Information Collection Layer (Layer -1):* All devices in the proposed model can reach this layer. The devices working in this layer are the first and end user devices. Devices in the layer share their data on the public network. The data to be kept here must be unchangeable. To achieve this, some encryption and cryptographic methods are needed. ECDSA (Elliptic Curve Digital Signature) method is used for the common key encryption of the devices. MAC addresses are fixed and introduced to the network. All processed TXs are saved to the system. The User wants to send information in a transaction and PKI signatures for Data communication, the protocols they use, the signatures and validity status of the units performing these checks, the data to be sent, timecode and sender identification code, IP, MAC, system identification number and node classification. According to the authorizations given by the system administrator, the devices can access the data within their authority. Traditional protocols do not allow non-text data transmission. Therefore, P2P-based IPFS protocol can be used for solving this problem. In this way, in RPL based networks users are provided with the opportunity to send all types of data.

2) *Control and Merge Layer(Layer-2):*The purpose of this layer is to capture and transmit all transactions prepared and processed in the Data and Information Collection Layer. In the model, it is planned to allocate devices that allow access to 5G / LTE to ensure the continuity of the communication of the mobile and independently operated artillery firing force and artillery batteries. Network communication is of great importance in military artillery systems as in all communications. In this study, going beyond the traditional system, communication models including decentralized and blockchain technology are presented. In models, all devices used for communication can communicate directly with each other, within their authorization.

3) *Block Creation Layer(Layer-3):* The purpose of this layer is to perform various checks and create blocks before the block formation. Transactions created in Blockchain technology communicate with certain consensus algorithms through smart contracts. These algorithms are known as PoW and PoS. In this model, blockchain based hybrid consensus is proposed for military artillery. This controller includes authentication, system identification number verification, PKI verification, TX number verification, authority tree verification and other information checks. Therefore, unauthorized code usage is also prevented. After verification, all previous transactions are completed and ready for approval. The transactions approved in all approval mechanisms are kept in the TX pool. TXs are kept in the pool and published. If there are TXs with any priority or urgency code added by commanders or system administrators, they can be processed before. The

information planned to be added to a block is shown in Table V.

C. The Second Model: Blockchain Based Artificial Neural Network Communication Model

In this model, blockchain based artificial neural network model was created. With the model created, it has gone beyond traditional methods and blockchain transactions are embedded in artificial neural network model. When these processes act as part of the activation function, hybrid blockchain based architecture has emerged and "perceptron" is used in the model, and a perceptron model is shown in Fig. 2. In this model, shifting the arrangement values that hold an important place in the gunner system will be explained with blockchain technology. The bias values in the model are correction values. In other words, when any correction is made in the information in the model, it ensures that both the corrected value and the raw data are preserved. A battery must find shot correction values in its current position. In the absence of these values, it allows the target to be warned without hitting it, increasing the probability of its position being detected by the enemy. It also has to fire more shells to hit the target. The meteorology report should be updated after shooting correction values are found. Because gunner shells have a high bullet peak height.(10000 or 20000 meters etc.) So, this case is a continuing activity. After an artillery battery is deployed, he finds the firing correction values. Because the existing spreadsheets are calculated for standard conditions. These values include that "change in the position metrics" and "do not change in the position metrics". The calculated correction values are added to the ruler. So, the corrected current value is found. Shot values are the adjusted values determined by the artillery battery are called the "firing principles". When these principles are found, all howitzer in the battery can shoot on the target at the same time. This shot is called the "hit of action". Inputs in the Perceptron model are compared to shot correction values. The image regarding the corrections in the spreadsheet is in Fig. 3. The fixed calculating values are the input values indicated by the "X" in the perceptron model. Correction values are "bias" values. The advantages of shifting firing principles correction values to a different battery: the target area is not warned, the own position area is not detected by the enemy, provide ammunition saving, and minimize the error rate in calculations. When shifting firing principles correction, operations performed in the first model by the system administrator will still be implemented. Thus, while sending data from "A" battery to "B" battery, some information will be recorded. Blocks will be created with blockchain technology. Data reliability and accuracy will be ensured in this way. Blocks will be created in the input and activation function (output) section of the artificial neural network. Thus, incoming data and information about

TABLE V. PROPOSED BLOCK SCHEME

Blocks	Function
All	Previous blocks hash codes
All	Timecode and Sender Identification Code
All	Block Preparator Signature
All	Flexibility code 1 (when required)
All	Flexibility code 2 (when required)




Fig. 2. Perceptron Model




Fig. 3. Corrections in the Spreadsheet

the sent data are written in blocks. The blocks contain the following information: System identification numbers of the devices, Previous Blocks Hash Codes, Timecode and Sender Identification Code, Block Preparator Signature, Flexibility code 1 (when required), Flexibility code 2 (when required). This model can be used especially for cleaning dirty information, especially for detecting data that is trying to be changed by the attacker with simple scrambling methods. Since the model is especially suitable for the analysis of data to be collected from IoT network layers, it can be used to detect RPL specific attacks if the features are determined appropriately.

IV. RESULTS

In this study, it has gone beyond classical communication by taking advantage of the superior features of RPL, artificial neural network and blockchain technology. The proposed models are equipped with these features. Blockchain and ANN based communication has many advantages, especially data security and data accuracy. In particular, the military environment in which data with confidential information and intelligence features allows the use of this technology. Communication is an indispensable element in the military artillery system, which forms the basis of military architecture. At the same time, this approach offers a decentralized structure by removing central authority and introducing distributed ledger technology. Transactions are encrypted, indelible and transparent. Necessary consensus, smart contract, tools are determined and implemented in this system without disturbing the military order and hierarchy.

V. CONCLUSION AND FUTURE DIRECTIONS

In this study, based on the fact that artillery systems have RPL network feature, two different models are proposed and main aim is to make the network more reliable

in order to detect specific RPL attacks. The request of the artillery firing team to fire and shifting the firing correction values from battery to battery is explained. Proposed models can be used interchangeably. In the next study, it is planned to transfer the models that provide the RPL security mechanism described above to the simulation environment and detect the RPL specific attacks such as hello flood, version number, decreased rank and worst parent attacks by monitoring the data flow.

REFERENCES

- [1] <https://www.thoughtco.com/what-is-communication-1689877>
- [2] L. Atzori, A. Iera, G. Morabito, "The Internet of Things: A survey," *Computer Networks*, 2010, doi: 10.1016/j.comnet.2010.05.010.
- [3] F. A. Ian and M. J. Josep, "The Internet of NANO-THINGS," *IEEE Wireless Communications*, 2010, pp. 58-64.
- [4] <https://www.yugoimport.com/en/proizvodi/artillery-fire-control-communication-and-command-system-artillery-battery>(access 05.10.2022)
- [5] <https://www.aselsan.com.tr/cozumlerimiz/askeri-haberlesme-sistemleri> (access 10.10.2022)
- [6] Xueping Liang, Sachin Shetty, Deepak Tosh, Charles Kamhoua, Kevin Kwiat, Laurent Njilla, "ProvChain: A Blockchain-Based Data Provenance Architecture in Cloud Environment with Enhanced Privacy and Availability" 17th IEEE/ACM International Symposium on Cluster, Cloud and Grid Computing (CCGRID), 2017
- [7] L. Yushi, J. Fei, Y. Hui, Study on application modes of Military Internet of Things (MIoT), in: *Computer Science and Automation Engineering (CSAE)*, 2012 IEEE International Conference on, Vol. 3, IEEE, 2012, pp. 630-634.
- [8] Sudhan, A., & Nene, M. J. (2017, December). Employability of blockchain technology in defence applications. In 2017 International Conference on Intelligent Sustainable Systems (ICISS) (pp. 630-637). IEEE.
- [9] Almadhoun, R., Kadadha, M., Alhemeiri, M., Alshehhi, M., & Salah, K., A user authentication scheme of IoT devices using blockchain-enabled fog nodes. *Proceedings of IEEE/ACS International Conference on Computer Systems and Applications, AICCSA*, 2018, pp.1-8.
- [10] Wang, S., Zhu, S., & Zhang, Y. Blockchain-based mutual authentication security protocol for distributed RFID systems. *Proceedings - IEEE Symposium on Computers and Communications*, 2018, 74-77.
- [11] Santeekin, R. A., Karabacak, E., Durgay, Z., & Karaarslan, E. (2018, March). Blockchain based secure communication application proposal: Cryptouch. In 2018 6th International Symposium on Digital Forensic and Security (ISDFS) (pp. 1-4). Ieee.
- [12] Suárez-Albela, A practical evaluation on RSA and ECC-based cipher suites for IoT high-security energy-efficient fog and mist computing devices. *Sensors (Switzerland)*, 18(11), 2018, p.p. 0-26.
- [13] Tosh, D. K., Shetty, S., Foytik, P., Njilla, L., & Kamhoua, C. A. (2018, October). Blockchain-empowered secure internet-of-battlefield things (iobt) architecture. In *MILCOM 2018-2018 IEEE Military Communications Conference (MILCOM)* (pp. 593-598). IEEE.
- [14] Khacef, K., & Pujolle, G. (2019, March). Secure Peer-to-Peer communication based on Blockchain. In *Workshops of the International Conference on Advanced Information Networking and Applications* (pp. 662-672). Springer, Cham.
- [15] Novo, O. Blockchain meets IoT: an architecture for scalable access management in IoT. *IEEE Internet of Things Journal*, 5(2), 2018, pp.1184-1195.
- [16] Sankar Ramachandran, G., & Krishnamachari, B. (2019). A Reference Architecture for Blockchain-based Peer-to-Peer IoT Applications. *arXiv e-prints*, arXiv:1905.
- [17] Yilmaz, Selim & Aydoğan, Emre & Sen, Sevil. (2021). A Transfer Learning Approach for Securing Resource-Constrained IoT Devices. *IEEE Transactions on Information Forensics and Security*. PP. 1-1. 10.1109/TIFS.2021.3096029.
- [18] Cakir, S., Toklu, S., & Yalcin, N. (2020). RPL attack detection and prevention in the Internet of Things networks using a GRU based deep learning. *IEEE Access*, 8, 183678 - 183689

Control of PMSG based variable speed wind energy conversion system connected to the grid with Nonlinear Backstepping Control

MAHGOUN Mohammed seddik
Electrical Engineering Department
University of Ferhat Abbas Setif 1
Setif, Algeria
mahgounm@yahoo.fr

Abstract— This paper presents a new robust nonlinear control strategy based on backstepping control applied to control active and reactive power for permanent magnet synchronous generator (PMSG) integrated into a wind energy conversion system (WECS). The aim of this control is to obtain high dynamic performances in terms of reference tracking, sensitivity to perturbations, and reducing the phenomenon of chattering compared to the conventional sliding mode control strategy. The use of the conventional Sliding Mode control technique gives quite interesting results, but its major drawback in the phenomenon of chattering (oscillations) caused by the discontinuous control signal, which reduces the precision of the system. For this, we propose in this work a solution to avoid this chattering phenomenon, by the implication of a Non-Linear robust control based on the backstepping approach. The proposed technique allows having improvable performance while keeping the robustness of the system and the convergence in finite time. Simulation results demonstrate the good effectiveness and excellent robustness of the proposed technique comparatively to the Sliding Mode Control one.

Keywords— Lyapunov stability, Permanent Magnet Synchronous Generator, Wind Energy Conversion System, Maximum Power Point Tracking, Robustness, backstepping Control.

I. INTRODUCTION

Wind energy is among the renewable energies that have experienced the strongest expansion in the last decade thanks to the advantages it brings the environmental and economic benefits [1]. According to the latest report from the Global Wind Energy Council (GWEC), 2021 was the second best year on record for the global wind industry, with 93.6 GW new installed capacity.




Fig. 1. Total global new wind power installation in 2021 [2].

The year 2021 saw new wind installations exceeding 93 GW, only 1.8% lower than the 2020, bringing the total installed capacity to 743 GW, i.e. a growth of 12.4% compared to last year [2].




Fig. 2. Historic development of total installations (GW) [2].

The use of Permanent Magnet Synchronous Generator (PMSG) makes variable speed wind power (VSW) conversion systems more attractive than fixed speed ones because of the possibility of optimum energy extraction for different wind speeds, reduction of mechanical stress by eliminating the multiplier, which improves system reliability, and reduction in maintenance costs [3]. In the literature, several control methods have been suggested to control PMSG's powers, such as the vector control technique based on the classic linear regulator, due to their simple conception and implementation [4]. However, A classic linear regulator is therefore not suitable for this type of application and it is, therefore, necessary to use more modern and robust regulators [4], [5]. To obtain high performance and better performance, it is necessary to design suitable robust controls, which render the system insensitive to external disturbances and to parametric variations. Among them, the sliding mode control. [6]. The sliding mode control (SMC) has been very successful in recent years. This is due to the simplicity of implementation and the robustness in relation to the uncertainties of the system and the external disturbances marring the process. The sliding mode control consists of bringing the state trajectory towards the sliding surface and making it evolve over it with a certain dynamic up to the point of equilibrium by adding a discontinuous control signal across the sliding surface, satisfying the sliding condition. However, the major drawback of this regulator is the appearance of the phenomenon of chattering caused by the discontinuous control action which manifests on the variables want to control its. [7,8]. Recently, nonlinear backstepping techniques have become an interesting option to be used in several kinds of systems. In this paper, the backstepping Control (BSC) has been introduced to overcome the chattering problem while keeping the convergence

properties in the finite time and robustness of Conventional Sliding Mode Control (C-SMC). This study aims to control the Active and Reactive Power of the PMSG based on wind energy conversion system, where reference active power will be obtained from the MPPT maximum power extraction algorithm to ensure better efficiency of the wind system, while the reactive power will be kept zero in order to have a unity power factor. The maximum power point tracking was achieved by using the tip speed ratio algorithm. In that way, an overall modeling of proposed system has been presented. Then a control strategy of the MPPT for extraction of maximum power of the turbine generator with PI mechanical speed controller is presented. Thereafter, the modeling of the PMSG, then, an exhaustive explanation of the Backstepping technique based on Lyapunov stability and optimization method has been reported in order to control the stator active and reactive powers of the PMSG. Finally, the results of the simulations will be presented in the environment Matlab/Simulink in order to show that the proposed BSC strategy effectively gives a good performance (good tracking, disturbance rejection, and minimizes the chattering phenomenon).

II. MODELLING OF WIND TURBIN

The Wind Energy Conversion System (WECS) is shown in Fig3. It consists of a turbine, a rectifier, a PMSG and an inverter connected to the grid.




Fig. 3. Structure of wind system based on PMSG.

Wind turbines allow the conversion of kinetic energy into mechanical energy, which is then converted into electrical energy by a generator.

2.1. Wind model

The wind speed is modeled by a sum of numerous harmonics as follows:

$$V = V_0 + \sum_{i=1}^n A_i \sin(w_i t + \varphi_i) \quad (1)$$

The nonlinear expression for aerodynamic power captured by the wind turbine is given by [8]:

$$P_{aer} = \frac{1}{2} C_p(\lambda, \beta) \cdot \rho \cdot \pi \cdot R^2 \cdot V^3 \quad (2)$$

With:

ρ : the air density ($\rho = 1.225 \text{ kg/m}^3$ atmospheric pressure 15°C);

V : wind speed (m/s);

$C_p(\lambda, \beta)$ is the power coefficient which is a function of both tip-speed ratio (TSR) λ and blade pitch angle $\beta[\text{deg}]$, which is described as [9]:

$$\begin{cases} C_p(\lambda, \beta) = 0.5 \left(\frac{116}{\lambda_i} - 0.4\beta - 5 \right) e^{\frac{-12.5}{\lambda_i}} + 0.0068\lambda \\ \frac{1}{\lambda_i} = \frac{1}{\lambda + 0.08\beta} - \frac{0.035}{\beta^3 + 1} \end{cases} \quad (3)$$

It depends on the ratio (λ) and the orientation angle of the blade (β). The tip speed ratio TSR of the wind turbine is defined as following [09]:

$$\lambda = \frac{R \Omega_{tur}}{V} \quad (4)$$

Where Ω_{tur} represents the rotational speed of turbine (rd/s), R is the wind turbine radius (m).

The aerodynamic torque is given by:

$$C_{aer} = T_{aer} = \frac{P_{aer}}{\Omega_t} = \frac{1}{2} C_p(\lambda, \beta) \cdot \rho \cdot S \cdot V^3 \frac{1}{\Omega_t} \quad (5)$$

Fig.4. illustrate the curve of $C_p(\lambda, \beta)$ obtained by equation (3).




Fig. 4. Power coefficient versus tip-speed ratio for various values of β .

It can be noticed that when pitch-angle are fixed at a value of 2, we get the nominal value of C_p about 0.5 for (TSR) λ of 9.14. So the maximum power can be obtained from the wind.




Fig. 5. Power coefficient versus λ at fixed β .

In this case, for a rated value of wind speed, the optimal turbine speed and maximal power are expressed as:

$$\begin{cases} \Omega_{tur-opt} = \frac{\lambda_{opt} \cdot V}{R} \\ P_{tur-max} = \frac{1}{2} C_p^{max} \cdot \rho \cdot \pi \cdot R^2 \cdot V^3 \end{cases} \quad (6)$$

Thus, for each wind speed v_{wind} , there is a maximum rotor speed Ω_{opt} which made a maximum power recovered from the wind turbine (Fig. 6).




Fig. 6. Maximum power in function of rotor speed.

2.2. Model gearbox

The turbine is connected to the generator shaft through a gearbox whose model is as follows:




Fig. 7. Diagram of the wind turbine.

$$\begin{cases} C_g = \frac{C_{aer}}{G} \\ \Omega_{turbine} = \frac{\Omega_{mec}}{G} \end{cases} \quad (7)$$

Model proposed considers that the total inertia J is given by: [11,12]

$$J = \frac{J_{turbine}}{G^2} + J_g \quad (8)$$

2.3. Dynamique model of shaft

The dynamic equation of the wind turbine is given by:

$$J \frac{d\Omega_{mec}}{dt} = C_{mec} = C_g - C_{em} - f \cdot \Omega_{mec} \quad (9)$$

Where:

Where C_g is the generator torque, C_{em} electromagnetic torque, J_g : Inertia of the generator, f coefficient of viscous friction, G : multiplier gain.

III. MPPT CONTROLLER

The energy produced by the wind turbine depends mainly on the wind, The following figure shows the power curve of a wind turbine as a function of wind speed.




Fig. 8. Different functioning zones of the wind turbine.

Thus during phase II, the aerogenerator must produce maximum power by making the best use of the energy available in the wind. Therefore, and with a view to ensuring maximum energy productivity, we need to find the operating point at maximum power MPPT (Maximum Power Point Traking). This method makes it possible to follow, as its name suggests, the maximum power point of the wind turbine. Various MPPT algorithms or strategies for small wind turbines have been developed in the literature. In this paper, the MPPT with speed control by using the PI controller as shown in Fig 9:




Fig.9. Power maximization with PI control strategy

Classical PI controller for MPPT

The expression of the reference electromagnetic torque becomes:

$$C_{em-ref} = \left(K_p + \frac{K_i}{s} \right) \cdot (\Omega_{mec-ref} - \Omega_{mec}) \quad (10)$$

The reference rotation speed and reference mechanical speed of the turbine is defined by:

$$\Omega_{t-ref} = \frac{\lambda_{opt} \cdot V}{R} \quad (11)$$

We deduce the PMSG rotational speed reference taking into account the gain of the multiplier by: $\Omega_{mec-ref} = G \cdot \Omega_{t-ref}$

IV. MODELING OF PMSG PERMANENT MAGNET SYNCHRONOUS GENERATOR

A. PMSG Modeling

The Park's transformation is applied to the coordinate model (a; b; c) of the synchronous generator to produce the coordinate model (d; q) of the PMSG. The voltage equations of the direct axis (d) and the orthogonal axis (q) are shown in [10]:

- Stator voltages:

$$\begin{cases} v_d = R_s \cdot i_d + \frac{d\phi_d}{dt} - w_e \cdot \phi_q \\ v_q = R_s \cdot i_q + \frac{d\phi_q}{dt} + w_e \cdot \phi_d \end{cases} \quad (12)$$

- Stator flux:

$$\begin{cases} \phi_d = L_d \cdot i_d + \psi_f \\ \phi_q = L_q \cdot i_q \end{cases} \quad (13)$$

From “(12)” and “(13)” the stator voltages can be written as:

$$\begin{cases} v_d = R_s \cdot i_d + L_d \frac{di_d}{dt} - w_e \cdot L_q \cdot i_q \\ v_q = R_s \cdot i_q + L_q \frac{di_q}{dt} + w_e \cdot (L_d \cdot i_d + \psi_f) \end{cases} \quad (14)$$

i_d, i_q : components of stator current in the dq-axes

v_d, v_q : components of stator voltage in the dq-axes,

R_s : stator resistance,

L_d, L_q : d-axis and q-axis inductances,

ψ_f : permanent magnetic flux and

w_e : electrical rotor speed of the generator which is related to the mechanical rotor speed by $w_e = P \cdot \Omega$, where P is the generator number of pole pairs.

The electromagnetic torque of the PMSG is given by :

$$C_{em} = \frac{3}{2} \cdot P \cdot [(L_d - L_q) \cdot i_d \cdot i_q + \psi_f \cdot i_q] \quad (15)$$

B. ACTIVE AND REACTIVE POWERS OF THE PMSG

The active and reactive stator power in the Park reference, are written:

$$\begin{cases} P = v_d \cdot i_d + v_q \cdot i_q \\ Q = v_q \cdot i_d - v_d \cdot i_q \end{cases} \quad (16)$$

To realize independent control of active and reactive power, a two-phase dq rotary reference frame related to the stator magnetic field is selected. What:

$$\begin{cases} v_d = 0 \\ v_q = V_s \end{cases} \quad (17)$$

In that case, Equation “(14)” becomes as follows:

$$\begin{cases} 0 = R_s \cdot i_d + L_d \frac{di_d}{dt} - w_e \cdot L_q \cdot i_q \\ V_s = R_s \cdot i_q + L_q \frac{di_q}{dt} + w_e \cdot (L_d \cdot i_d + \psi_f) \end{cases} \quad (18)$$

Hence, the active and reactive powers (P, Q) can be written:

$$\begin{cases} P = V_s \cdot i_q \\ Q = V_s \cdot i_d \end{cases} \quad (19)$$




Fig.10. Block diagram of PMSG.

V. BACKSTEPPING CONTR OL OF THE PMSG

A. PRINCIPLE OF THE BACKSTEPPING APPROACH

The technique of Backstepping is a very recent and extensive approach for the control of nonlinear systems. It was developed by Kanellakopoulos (1991) and inspired by the work of Feurer Morse (1978) on the one hand and Tsinias (1989) and Kokotovic Sussmann (1989). The main idea of Backstepping is to calculate a control law in several steps in order to guarantee a certain Lyapunov function which is always positive and its derivative will always be negative, which instantly guarantees the overall stability of the system [13],[14],[16], [15].

B. APPLICATION BACKSTEPPING CONTR ON PMSG

- Active power control

The errors between the reference and the measured signals of stator active is:

$$e_1 = P^{ref} - P \quad (20)$$

The derivative of the error is:

$$\dot{e}_1 = (\dot{P}^{ref} - \dot{P}) \quad (21)$$

We consider the following Lyapunov candidate function:

$$V(e_1) = \frac{1}{2} e_1^2 \quad (22)$$

The derivative of Lyapunov's candidate function:

$$\dot{V}(e_1) = e_1 \dot{e}_1 \quad (23)$$

With:

$$\dot{e}_1 = (\dot{P}^{ref} - V_s \cdot \dot{i}_q) \quad (24)$$

By replacing the expression of the derivative of the current, we obtain:

$$\dot{e}_1 = [\dot{P}^{ref} - \frac{V_s}{L_q} \cdot (v_q - R_s \cdot i_q - w_e (L_d \cdot i_d + \Psi_f))] \quad (25)$$

Replacing it in the Lyapunov's candidate function:

$$\dot{V}(e_1) = e_1 \dot{e}_1 = e_1 [\dot{P}^{ref} - \frac{V_s}{L_q} \cdot (v_q - R_s \cdot i_q - w_e (L_d \cdot i_d + \Psi_f))] = -k_1 e_1^2 \quad (26)$$

We derive the expression of the backstepping stabilizing command as follows:

$$V_{qr}^* = \frac{L_q}{V_s} [\dot{P}^{ref} + k_1 e_1 + \frac{V_s}{L_q} \cdot (R_s \cdot i_q + w_e (L_d \cdot i_d + \Psi_f))] \quad (27)$$

With k_1 positive constant.

• Control of the reactive power

The reactive power tracking error is:

$$e_2 = Q^{ref} - Q \quad (28)$$

The derivative of the error is:

$$\dot{e}_2 = \dot{Q}^{ref} - \dot{Q} \quad (29)$$

The augmented Lyapunov function is given by the following expression:

$$V(e_1, e_2) = \frac{1}{2} e_1^2 + \frac{1}{2} e_2^2 \quad (30)$$

Its derivative is given by:

$$\dot{V}(e_1, e_2) = e_1 \dot{e}_1 + e_2 \dot{e}_2 = -k_1 e_1^2 + e_2 (\dot{Q}^{ref} - \dot{Q}) \quad (31)$$

With:

$$\dot{e}_2 = (\dot{Q}^{ref} - V_s \cdot \dot{i}_d) \quad (32)$$

By replacing the expression of the derivative of the current, we obtain:

$$\dot{V}(e_1, e_2) = -k_1 e_1^2 + e_2 (\dot{Q}^{ref} - \frac{V_s}{L_d} \cdot (v_d - R_s \cdot i_d + w_e \cdot L_q \cdot i_q))$$

The expression of the backstepping stabilizing command is given by:

$$V_{dr}^* = \frac{L_d}{V_s} [\dot{Q}^{ref} + \frac{V_s}{L_d} \cdot (k_2 \cdot e_2 + R_s \cdot i_d - w_e \cdot L_q \cdot i_q)] \quad (33)$$

With k_2 positive constant.

VI. SIMULATION RESULTS AND DISCUSSION

In order to test the performance of the systems, we chose two wind speed profiles which are given by Figure (11) and Figure (16). The system parameters that have been chosen for the wind turbine and PMSG are given in the table (I).

TABLE I. PARAMETTERS OF WT AND PMSG

WT parameters	
Parameters	Values
Density of air	1.22 kg/m ³
Radius of rotor	3 m
Gear box ratio	G =1
total inertia	16 kg.m ²
Total viscous friction coefficient	0.06 N.m/s

PMSG parameters	
Nominal power	600 KW
Voltage	220 V
frequency	50 Hz
Stator resistance	1.4 Ω
d-axis stator inductance Ld	0.0066 H
q-axis stator inductance Lq	0.0058 H
Permanent magnetic flux	0.15 Wb
Number of pole pairs p	17

• Tracking test

In the first case, the wind speed increases from 8 m/s to 10 m/s at $t = 2$ s, and from 10 m/s to 12 m/s at $t = 6$ s. "Fig. 1" shows the wind speed at which the wind system is attacked.




Fig.11. Wind speed profile.




Fig.12. Active power with BSC of PMSG.




Fig.13. Reactive power with BSC of PMSG.




Fig.14. Current of PMSG.




Fig.15. Current Zoom of PMSG.

According to figure (12) and figure (13), the simulation results obtained show good performances in following the active and reactive power their references.

Figure (14,15) show that the currents obtained at the stator increase when the wind speed increases, moreover, these currents have sinusoidal shapes.

- **Robustness test**

In the second case a variable speed is used to check the robustness of the system. Figure (16) shows the wind speed with which the wind system is attacked.




Fig.16. Wind speed profile.




Fig.17. Active power with BSC of PMSG.




Fig.18. Reactive power with BSC of PMSG.




Fig.19. Current of PMSG.




Fig.20. Current Zoom of PMSG.




Fig.21. Power coefficient CP.




Fig.22. Tip-Speed Ratio.

It is clear that the different parameters follow perfectly their references, and robustness is assured despite the sudden variation of the setpoint.

Looking at “Fig; 21” and “Fig. 22”, it is clear that the system with MPPT control has the coefficient of power C_p maintained at its maximum value ($C_p^{\max} = 0.5$) and the tip speed ratio TSR, it is kept around its optimum value ($\lambda_{opt} = 9.14$).

Now, a comparison between Sliding mode controller and BSC results have been illustrated in Figs. 23-24; we have respectively the active and reactive power.




Fig. 23. Active power with SMC.




Fig. 24. Reactive power with SMC.

VII. CONCLUSION

This paper proposes a new robust backstepping controller with applied to the wind energy conversion system WECS based on Permanent Magnet Synchronos Generator PMSG taking into account variable speed parameter. Global asymptotic stability was achieved via the Lyapunov stability analysis. This control strategy presents through simulation a high performances in terms of tracking trajectories, with excellent ability of disturbance rejection and excellent robustness to eliminate the phenomenon of CHATTERING, without degrading the performance of the system.

REFERENCES

[1] M.S. Mahgoun, A.E. Badoud, "NEW DESIGN AND COMPARATIVE STUDY VIA TWO TECHNIQUES FOR WIND

ENERGY CONVERSION SYSTEM",Electrical Engineering & Electromechanics, no, 2021.

- [2] GLOBAL WIND REPORT 2022», 25 March 2022. <https://gwec.net/global-wind-report-2022/>
- [3] Xiaotian Y,Zhengchun D,"Control strategies for permanent magnet synchronous generator-based wind turbine with independent grid-forming capability in stand-alone operation mode",Int Trans Electr Energ Syst. 2021
- [5] M.S. Mahgoun, A.E. Badoud, "A New combined MPPT-Pitch Angle control of a Large Variable Speed Wind Turbine in Different Operating Areas based on Synergetic control",Algerian Journal of Renewable Energy and Sustainable Development,Volume: 4,Number 1: 2022.
- [6] W. Slimane,M. T. Benchouia,A. Golea1,S. Drid:"Second order sliding mode maximum power point tracking of wind turbine systems based on double fed induction generator",Int J Syst Assur Eng Manag,<https://doi.org/10.1007/s13198-020-00987-8>.
- [7] F.Echiheb,Y.Ihedrane,"Robust Sliding-Backstepping Mode Control of a wind system based on the DFIG Generator",Research Square Preprints,March 2022
- [8] Chojaa H, A. Derouich, "Performance improvement of the variable speed wind turbine driving a DFIG using nonlinear control strategies",International Journal of Power Electronics and Drive Systems (IJPEDS),Vol. 12, No. 4, December 2021.
- [9] P.GAJEWSKI, K.PIEŃKOWSKI,"Advanced control of direct-driven PMSG generator in wind turbine system"ARCHIVES OF ELECTRICAL ENGINEERING,VOL. 65(4), pp. 643-656 (2016).
- [10] N.Laabidine, A.Errarhout,Sliding mode control design of wind power generation system based on permanent magnet synchronous generator,International Journal of Power Electronics and Drive System (IJPEDS),Vol. 12, No. 1, Mar 2021, pp. 393~403
- [11] Y.El Mourabit,A.Derouich,"Nonlinear backstepping control for PMSG wind turbine used on the real wind profile of the Dakhla-Morocco city",Int Trans Electr Energ Syst. 2020.
- [12] Y.El Mourabit,A.Derouich,"Implementation and validation of backstepping control for PMSG wind turbine using dSPACE controller board",Energy Reports 5 (2019)
- [13] M. Taoussi, M. Karim, D. Hammoumi, C. Elbakkali, B. Bossoufi, N. El Ouanjli,"Comparative study between Backstepping adaptive and Field-oriented control of the DFIG applied to wind turbines", 3rd IEEE International Conference on Advanced Technologies for Signal and Image Processing , May 2017.
- [14] A. F. Zohra, B. I. Khalil, L. Slimane, S. Youcef, and M. Benyounes, "Artificial intelligence control applied in wind energy conversion system," in International Journal of Power Electronics and Drive Systems, vol. 9, no. 2, pp.571-578, doi: 10.11591/ijpeds.v9.i2.pp571-578,2018.
- [15] I. Yasmine, E. B. Chakib, B. Badre, "Power control of DFIG-generators for wind turbines variable-speed," inInternational Journal of Power Electronics and Drive Systems," vol. 8, no. 1, pp. 444-453, 2017, doi:10.11591/ijpeds.v8.i1.pp444-453.
- [16] R. Chakib, A. Essadki, and M. Cherkaoui, "Modeling and control of a wind system based on a DFIG by active disturbance rejection control," in International Review on Modeling and Simulations, vol. 7, no. 4, pp. 626-637,2014, 10.15866/iremos.v7i4.2386.
- [17] A. Haruna, Z. Mohamed, M. Efe, and M. Basri, "Improved integral backstepping control of variable speed motion systems with application to a laboratory helicopter," ISA Transactions, vol. 97, pp. 1-13, 202

Estimating a City's Electrical Load Demand with Long Short Term Memory

Gülay Yıldız Doğan
Industrial Engineering Department
Bursa Uludağ University
Bursa, Türkiye
511806003@ogr.uludag.edu.tr

Nursel Öztürk
Industrial Engineering Department
Bursa Uludağ University
Bursa, Türkiye
nursel@uludag.edu.tr

Abstract— The increase in the human population and the developments in technology have increased the power consumption rapidly today. For this reason, estimation of electricity load is of great importance for the planning of electricity production and consumption of a country. This study proposes an approach for estimating electrical load demand using Long Short Term Memory method, which is one of the deep learning techniques. The proposed model is applied on the four year from 2015 to 2019 hourly electricity consumption data of a city. The results of the proposed model were evaluated using Mean Absolute Percent Error (MAPE), Mean Absolute Error (MAE), Root Mean Square Error (RMSE). The results show that the proposed model can be successfully used to estimate electric load demand for the planning of electricity production and consumption.

Keywords— Electrical Load Demand, Deep Learning, Long Short Term Memory, Time Series

I. INTRODUCTION

Forecasting electricity demand is important for efficient planning of electricity generation, transmission and distribution. A wide variety of approaches have been proposed to study electricity demand forecasting. Garcia-Ascanio and Mate [1] adapted the vector autoregressive model to interval time series to estimate the hourly electrical energy demand in Spain in the years 2006-2007. Kaysal et al. [2] studied short-term load estimation of a small region using artificial neural network and adaptive neural fuzzy inference system methods. Çevik and Harmanlı [3] studied short-term electrical load estimation for the next 24 hours. Artificial neural network (ANN) and particle swarm optimization (PSO) techniques were used for the hybrid prediction method. Wan He [4] used convolutional neural network and recurrent neural network to extract rich features from past load consumptions for short-term load prediction. Experiments were conducted on a large dataset of hourly load consumptions of a North China city between 2009 and 2012. Yuan et al. [5] proposes artificial neural network models to predict seasonal hourly electricity consumption for three areas of a university campus in Japan. Considering the Feed Forward ANN trained with Levenberg-Marquardt backpropagation algorithms, future seasonal hourly electricity consumption is estimated. Ayoub et al. [6] presents a short-term demand and supply forecasting model using hourly collected annual demand data for a micro grid supply system used to secure the electricity demands of a commercial building. An artificial neural network has been

built to predict production capacity and load demands within 24 hours. Shaikh et al. [7] proposes an approach for short-term electrical load estimation using the Long Short Term Memory (LSTM) architecture. Mujeeb et al. [8] proposes a model aiming at electricity price and demand forecasting using the LSTM method for large data sets. Behm et al. [9] presents a method using artificial neural networks for long-term forecasts of hourly, weather-dependent, annual electrical load profiles for European countries. Pegalajar et al. [10] developed machine learning models to predict electricity demand. The study was conducted using 10 minutes of Spanish Electricity Grid data from 2007 to 2019. Linear regression, regression trees, regression gradient boosting, random forest, multilayer perceptron, LSTM, gated recurrent units neural network and Jordan recurrent neural network prediction models were used.

Recurrent neural networks are often used to perform time series predictions. However, RNN have the problem of vanishing gradients. LSTM which significantly increases the precision of the model is used to overcome this problem and to formulate long-term dependencies between training samples. LSTM protects both long-term and short-term states, converges faster, and can learn long-term dependencies. In this way, it is thought that it can be a good solution method for longer term estimation of electrical load demands. Therefore, in this study, LSTM deep learning method is used to predict the future electrical energy demand.

II. MATERIAL AND METHOD

A. Dataset

The dataset used within the application includes 4 years of electricity consumption, generation, pricing and weather data for Spain between 1 January 2015 and 31 December 2018. Consumption data is from ENTSOE, a public portal for Transmission Service Operator data. Weather data is derived from Open Weather API for Spain's 5 largest cities [11]. Within the scope of the study, data belonging to the city of Madrid were used. Data and forecasts are hourly. The hourly frequency of the data provides a more accurate forecast of future years' load demand. As a result of the literature review conducted for the electrical energy demand forecast, the attributes that affect the electricity demand the most were decided [3, 5, 9, 12, 13]. 13 variables in the dataset of the city of Madrid were used in the electricity demand forecasting

application. The input vector consists of 12 features given in Table 1. The output is the hourly electrical energy consumption. The 42-month hourly data between January 1, 2015 and June 30, 2018 is used as training data. The last 6 months of 2018 is used as test data.

TABLE 1. INPUT VECTOR VARIABLES

	Variables
Time Information	Day
	Month
	Year
	Hour
Weather Information	Average Temperature
	Minimum Temperature
	Maximum Temperature
	Pressure
	Humidity
	Wind Speed
	Percentage of cloudiness
	Weather description

B. Model Selection

Recurrent neural networks are one of the most widely used models for predicting time series data. However, there is a vanishing gradient problem in RNN. To solve this problem, LSTM which is a different recurrent neural network architecture has been proposed [14]. Unlike standard feed-forward neural networks, LSTM has feedback connections. It can process not only single data points, but also entire data series. LSTM networks are well convenient for classifying, processing and making predictions based on time series data. LSTM networks have the same structure as RNN networks but have additional layers that interact in a special way as shown in Figure 1.




Fig.1. The structure of LSTM

This architecture gives LSTM networks the ability to carry or forget long-term information. This process is controlled by gates that act as a kind of activation. LSTM consists of a combination of input gate, output gate and forget gate. The three gates regulate the flow of information into and out of

the cell. The information enters through the input gate. The forget gate forgets the information in the memory cells, and the output gate decides whether to output the information at that memory [14]. The decision whether to transfer the information belongs to the activation function [15]. With such an approach, long-term dependencies are eliminated and the continuation of data sets is made possible.

In Figure 1, the forget gate f_t determines the forgotten information according to the input data x_t , h_{t-1} and the cell information C_{t-1} at the previous moment using the activation function σ . Enter door i_t controls the cell status update. $\tilde{C}_t$ is candidate information for new cells, which is formed after calculated of $\tanh$. The output gate o_t generates the short term signal h_t at the next moment through the control of long term signal C_t . The update iteration formulas of LSTM are as follow [14].

$$i_t = \sigma(W_i h_{t-1} + U_i x_t + b_i) \quad (1)$$

$$\tilde{C}_t = \tanh(W_c h_{t-1} + U_c x_t + b_c) \quad (2)$$

$$C_t = C_{t-1} * f_t + \tilde{C}_t * i_t \quad (3)$$

$$o_t = \sigma(W_o h_{t-1} + U_o x_t + b_o) \quad (4)$$

where W and U are weight parameters vector, b is deviations.

III. RESULTS

The model is coded in the MATLAB program. The model has been tested for different layer numbers and different parameter values. Experiments are carried out by changing the hyperparameters in the proposed LSTM model.

The best test results are given in Table 2. Experimental results are evaluated with the mean absolute percent error (MAPE), symmetric mean absolute percent error (SMAPE), mean absolute error (MAE), root mean square error (RMSE) which are given in equations (5) to (8).

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| * 100 \quad (5)$$

$$\text{SMAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{\frac{|y_i| + |\hat{y}_i|}{2}} * 100 \quad (6)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (7)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (8)$$

A high learning rate will cause oscillation, and a small one will cause learning to take a long time as it will progress in small steps. Therefore, the learning rate was chosen as 0.01. Since the most suitable weight values to solve the problem in deep learning are calculated step by step, the performance will be low in the first epochs, and the performance will increase as the number of epochs increases. However, after a certain step, the learning status of the model will decrease considerably. Therefore, it is important to choose the ideal number of epochs. Experiments were carried out for models with three and two LSTM layers.

TABLE 2. EXPERIMENT RESULTS

Number of LSTM Layers	Number of Units	Learn Rate	Epoch	MAPE	MAE	RMSE	SMAPE
3	64 64 32	0,01	50	10,23	2909	3603	2,5106
2	64 32	0,01	50	9,97	2769	3457	2,4095
2	64 64	0,01	50	9,22	2685	3334	2,2900
2	16 8	0,01	50	11,02	3200	3854	2,8000
2	32 16	0,01	50	10,19	2839	3503	2,4564
2	32 32	0,01	50	10,01	2921	3600	2,5209
2	64 32	0,01	75	9,79	2752	3389	2,3700
2	64 64	0,01	75	10,18	2806	3570	2,4219

When the error metrics were compared, the model consisting of LSTM layers with 64 and 64 units is better than the others.

IV. CONCLUSION

In this study, an approach is proposed to estimate electrical load demand using the Long Short Term Memory method which is one of the deep learning techniques. The proposed model is applied to the four-year hourly electricity consumption data of a city between 2015-2019. The model is tested for different layer numbers and different parameter values. The results of the proposed model are evaluated with error metrics. The results showed that the proposed model can be used successfully to predict the electrical load demand.

REFERENCES

- [1] Garcia-Ascanio, C. and Mate C., "Electric power demand forecasting using interval time series: A comparison between VAR and iMLP," *Energy Policy*, vol.38, pp. 715–725, 2010.
- [2] Kaysal, A., Koroğlu, S., Oğuz, Y. and Kaysal, K., "Artificial Neural Networks and Adaptive Neuro- Fuzzy Inference Systems Approaches to Forecast the Electricity Data for Load Demand, an Analysis of Dinar District Case," *2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*.

- [3] Çevik, H.H., Harmancı, H. and Çunkaş, M., "Forecasting Hourly Electricity Demand Using a Hybrid Method," *2017 International Conference on Consumer Electronics and Devices*, pp. 8-12.
- [4] He, W., "Load Forecasting via Deep Neural Network," *Information Technology and Quantitative Management (ITQM 2017)*, Procedia of Computer Science, vol.122, pp.308-314.
- [5] Yuan, J., Farnham, C., Azuma, C., and Emura, K., "Predictive artificial neural network models to forecast the seasonal hourly electricity consumption for a University Campus," *Sustainable Cities and Society*, vol.42, pp.82–92,2018.
- [6] Ayoub, N., Musharavati, F., Pokharel, S., and Gabbar, H.A., "ANN Model for Energy Demand and Supply Forecasting in a Hybrid Energy Supply System," *2018 6th IEEE International Conference on Smart Energy Grid Engineering*, pp.25-30.
- [7] Shaikh, H.A., Rahman, M.A. and Zubair, A., "Electric Load Forecasting with Hourly Precision Using Long Short-Term Memory Networks," *International Conference on Electrical, Computer and Communication Engineering (ECCE)*, 7-9 February 2019.
- [8] Mujeeb, S., Javaid, N., Ilahi, M., Wadud, Z., Ishmanov, F. and Afzal, M.K., "Deep Long Short-Term Memory: A New Price and Load Forecasting Scheme for Big Data in Smart Cities," *Sustainability*, vol.11, no.987, pp.1-29, 2019.
- [9] Behm, C., Nolting, L. ve Praktiknjo, A., "How to model European electricity load profiles using artificial neural networks," *Applied Energy*, no. 277, 2020.
- [10] Pegalajar,M.C., Ruiz,L.G.B., Cuéllar,M.P. ve Rueda,R., "Analysis and enhanced prediction of the Spanish Electricity Network through Big Data and Machine Learning Techniques", *International Journal of Approximate Reasoning*, vol.133, pp.48-59, 2021.
- [11] <https://www.kaggle.com/datasets/nicholasjhana/energy-consumption-generation-prices-and-weather>
- [12] Elamin, N. and Fukushige, M., "Modeling and forecasting hourly electricity demand by SARIMAX with interactions," *Energy*, vol.165, pp.257-268, 2018.
- [13] Wang, Z, Zhou, X., Tian,J., and Huang, T., "Hierarchical parameter optimization based support vector regression for power load forecasting," *Sustainable Cities and Society*, no.71, 2021.
- [14] Ren, C., Jia, L. ve Wang, Z., "A CNN-LSTM Hybrid Model Based Short-term Power Load Forecasting," *2021 Power System and Green Energy Conference (PSGEC)*, pp.182-186.
- [15] Hochreiter, S., and Schmidhuber, J., "Long short-term memory," *Neural computation*, vol.9, no.8, pp.1735-1780, 1997.

Yapısal Tasarımda Yapay Sinir Ağları Yaklaşımı İle Analiz Tahminleri

Mustafa Kerem Özder
Otomotiv Mühendisliği Bölümü
Bursa Uludağ Üniversitesi
Bursa, Türkiye
mkerem996@gmail.com

Emre İsa Albak
Otomotiv Mühendisliği Bölümü
Bursa Uludağ Üniversitesi
Bursa, Türkiye
emrealbak@uludag.edu.tr

Ferruh Öztürk
Otomotiv Mühendisliği Bölümü
Bursa Uludağ Üniversitesi
Bursa, Türkiye
ferruh@uludag.edu.tr

Özet — Motor takozu braketleri araçlarda motor takozunun araç ile bağlantısını sağlamak için kullanılan yapısal parçalardır. Mekanik yüklerle maruz kalan braketin statik yükler altında kırılmadan çalışmasına devam etmesi önemlidir. Bunun yanı sıra günden güne sıklaşan emisyon kuralları araç üreticilerini daha hafif araç üretimine zorlamaktadır. Bu durumda parça tasarımı yapılırken minimum ağırlıkta maksimum dayanımda ürünler tasarlanmalıdır. Bu çalışmada braket modeli üzerinde sonlu elemanlar analizi programı kullanarak topoloji optimizasyonu çalışması yapılmıştır. Gerilme görülmeyen veya daha az gerilme oluşan bölgeler boşaltılarak minimum ağırlığa sahip olacak şekilde braket geometrisinin elde edilmesi hedeflenmiştir. En iyi geometrinin elde edilmesi amacıyla topoloji optimizasyonu sonrası oluşturulan modele şekil optimizasyonu uygulanmak üzere üç adet tasarım değişkeni belirlenmiştir. Tasarım değişkenlerinin alt ve üst sınırları belirlenerek Latin Hiper Küp metodu yöntemiyle oluşturulan 25 farklı a, b, c kombinasyonu için sonlu elemanlar metoduyla lineer statik analizler gerçekleştirilmiştir. Yapay sinir ağı yapısının oluşturulması için girdi olarak tasarım değişkenleri çıktı olarak ise analiz sonuçları belirtilmiştir. Yapay sinir ağları ile çözümleme zamanı ve hazırlama zamanı yüksek sonlu elemanlar analizlerinden tasarruf edilerek %1-3 hata payı ile tahminler modeli oluşturulmuştur.

Anahtar Kelimeler — Yapısal tasarım, braket tasarımı, ağırlık azaltma, yapay sinir ağları, sonlu elemanlar analizi


I. GİRİŞ

Taşıtlarda motorların çalışması sırasında oluşan titreşimlerin izolasyonunu sağlamak için veya mümkün olduğu kadar azaltmak için kullanılan sönümleyicilere motor takozu denir. Şekil 1'de ki görselde örnek verilmiştir. Motorun neden olduğu titreşimlerin araç gövdesine geçmesini engellemek için gövde ile motor arasında bağlanır [1]. Braketler motor takozlarında araç şasi ile sönümleme yapan kauçuk kısım arasında mekanik bağlantı görevi görürler.



Şekil 1. Motor Takozu

Otomotiv endüstrisinde emisyon kuralları gün geçtikçe daha da katı bir hal alarak otomotiv üreticilerini daha hafif araç üretmeye zorlamaktadır. Hafiflik ile birlikte otomotiv parçalarının gerekli olan mukavemet ve dayanımı ortaya koyması gerekmektedir. Bu durum ürün tasarımı yapılırken göz önüne alınarak, tasarım çalışmaları esnasında optimizasyon yöntemlerinin kullanılması ile birlikte en hafif ve en dayanıklı ürünü elde etmeyi amaçlamaktadır. Şekil 2 de gösterildiği gibi yapısal optimizasyon metodları; boyut optimizasyonu, şekil optimizasyonu ve topoloji optimizasyonu olarak üç grupta incelenir. Bu çalışmada braket modeline topoloji optimizasyonu ve şekil optimizasyonu yöntemleri uygulanmıştır. Topoloji optimizasyonu, parça hafifletme çalışmalarında tasarımcıların faydalandığı önemli tekniklerden birisidir. Topoloji optimizasyonunun amacı parça için en iyi malzeme kullanımının bulunmasıdır [2]. Şekil optimizasyonu, parçanın şekil yönünden değişikliklerinin optimize edilmesini sağlar. Topoloji optimizasyonun sınırlandırılmış hali olarak adlandırılabilir. Topolojisi belli olan yapının optimal sınırlarını hesaplar [3].




Şekil 2. Yapısal Optimizasyon Yöntemleri

Sonlu elemanlar analizi yöntemi dijital bilgisayarın keşfiyle başlamıştır. Bu yöntem bir mühendislik probleminin matematiksel bir ifadeye çevrilmesi ve çözüme ulaşılmasıdır. [4]. Sonlu elemanlar analizinde elemanların farklı noktalarda düğüm şeklinde birbirine bağlı olduğu varsayılır. Genel olarak bu tip yazılımlar yer değiştirme tabanlı olup noktaların her sonlu eleman içindeki hareketi, düğümlerin hareketlerinin bir fonksiyonu olarak tanımlanır. Sonlu elemanlar analizinde oluşan gerilemeler ise, modellenen malzemenin deformasyonları ve yapısal özelliklerinden kaynaklanmaktadır [5].

Yapay zekâ, insan zekasına özgü olan algılama, öğrenme, kavramları bağlama, düşünme, fikir yürütme, sorun çözme, iletişim kurma, çıkarım yapma ve karar verme gibi yüksek bilişsel fonksiyonları veya otonom davranışları sergilemesi beklenen zeki etmenler/programlar yaratmak üzere yapılan tüm çalışmalarının toplandığı geniş bir alandır [6].


Yapay Sinir Ağları (YSA), yapay zekanın alt dallarından birisidir. Bu yöntem aynen insan beyninin öğrenme ve öğrenme sonucunda muhakeme etme yeteneğini taklit ederek girdilere karşılık gerekli sayıda çıktıyı en iyi doğrulukta tahmin etmeye yarayan bir modeldir [7]. Yapay sinir ağları 3 katmandan oluşur. Bunlar girdi katmanı, gizli katman ve çıktı katmanıdır. Şekil 3'te örnek yapay sinir ağı modeli gösterilmektedir. Yapay sinir ağları 3 katmandan oluşur. Bunlar girdi katmanı, gizli katman ve çıktı katmanıdır. Bu çalışmada uygulanan modelde bir gizli katman bulunmaktadır. Gizli katmanda 10 nöron yer almıştır. Girdi katmanında 3 tasarım değişkenine karşılık gelen 3 nöron kullanılmıştır. Çıktı katmanında analiz sonuçları tahminlerine karşılık gelen 4 nöron yer almıştır.



Şekil 3. Yapay Sinir Ağ Modeli

II. 3 BOYUTLU MODELLEME, SONLU ELEMANLARLA ANALİZ, TOPOLOJİ OPTİMİZASYONU, YAPAY SİNİR AĞLARI

Motor takozu braketinin 3 boyutlu(3B) sanal modeli CATIA V5 tasarım program kullanılarak Şekil 4'teki gibi tasarlanmıştır.



Şekil 4. 3B Braket Modeli


3B model lineer statik analiz ve topoloji optimizasyonu yapılmak üzere HyperMesh programında sonlu elemanlar analiz (SEA) modeli hazırlanmıştır. Braket için tanımlanan malzemenin özellikleri Tablo 1'de verilmiştir.

TABLO 1. Braket Malzeme Özellikleri

Malzeme	Yoğunluk(g/cm ³)	Poisson Oranı	Elastisite Modülü(GPa)
EN AC 46000	2.8	0.33	73


Topoloji optimizasyonu için model 2 farklı bölgeye ayrılmıştır. Bunlar topoloji optimizasyonuna dahil olacak yeşil renkli dizayn ve topoloji optimizasyonuna dahil olmayacak kırmızı renkli bölgelerdir. Braket üç adet delikten X, Y, Z eksenlerindeki öteleme ve dönme hareketleri 0 olacak şekilde sabitlenmiştir. X pozitif ve negatif doğrultusunda 8100 N, Z pozitif ve negatif doğrultusunda 21000 N büyüklüğünde yük uygulandı.

Topoloji optimizasyonun amaç fonksiyonu ağırlığı minimize etmektir. Kısıt fonksiyonu hacmin maksimum 0.3 oranında boşaltılmasıdır. Topoloji optimizasyonu cevapları hacim ve ağırlık olarak belirlenmiştir. HyperMesh programında hazırlanan model Şekil 5'te gösterilmiştir.




Şekil 5. HyperMesh 3B Modeli

Topoloji optimizasyonu sonrasında elde edilen 3B kaba model Şekil 6'da verilmiştir.



Şekil 6. Topoloji Optimizasyonu Sonrası Model

Elde edilen 3B model üretilebilirlik açısından değerlendirilerek CATIA V5 programında tekrardan Şekil 7'de ki gibi modellenmiştir.




Şekil 7. Topoloji Optimizasyonu Sonrası 3B Model

Topoloji optimizasyonu öncesi ve sonrası braket ağırlıkları Tablo 2’ deki gibidir.

TABLO 2. Braket Ağırlıkları

	T.O. Öncesi	T.O. Sonrası	% Fark
Ağırlık(gram)	1824	1269	30

Şekil optimizasyonu yapılmak için 3B braket modeli üzerinden belirlenen 3 adet tasarım değişkeni Şekil 8’deki gibidir. Üretilebilirlik dikkate alınarak a, b, c parametrelerinin minimum ve maksimum değerleri Tablo 3’teki gibidir.



Şekil 8. a, b, c Tasarım Değişkenlerinin Gösterimi

TABLO 3. Tasarım Değişkenleri Minimum ve Maksimum Değerleri

Tasarım Değişkeni	Minimum(mm)	Maksimum(mm)
a	10	15
b	45	60
c	6	16

MATLAB program kullanılarak Latin hiperküp yöntemiyle(LHY) 25 farklı a, b ve c parametrelerinin kombinasyonundan oluşan şekil optimizasyonu yapılmak üzere tasarım uzayı Tablo 4’teki gibi oluşturulmuştur. Bu çalışmada LHY sistemi ile tasarım değişkenleri için tasarım çoğaltılması 3 tasarım değişkeni için yapılmıştır. Analiz süreçleri açısından problemin yapısına, karmaşıklığına ve tasarım değişkenleri sayılarına göre eğitim ve testlerde kullanılacak analiz data veri sayıları belirlenebilir. Burada dikkat edilmesi gereken eğitilecek ağırlık R değerlerinin 1 değerine yakın olmasıdır. İstenilen doğruluk oranında data veri seti sayısı uygulanan problem için 25 data seti olarak yeterli kabul edilebilir.

TABLO 4. Latin Hiper küp Yöntemiyle Oluşturulan Tasarım Uzayı

Model Adı	Tasarım Değişkenleri		
	a	b	c
Analiz 1	10.01	59.18	14.15
Analiz 2	13	58.66	10.12

Analiz 3	14.59	57.68	6.82
Analiz 4	13.93	48.53	8.43
Analiz 5	10.76	53.9	7.16
Analiz 6	11.87	45.15	8.67
Analiz 7	12.61	51.88	10.59
Analiz 8	14.7	49.44	11.63
Analiz 9	10.59	47.7	10.96
Analiz 10	13.8	51.27	11.2
Analiz 11	12.78	56.17	7.79
Analiz 12	10.4	56.79	13.41
Analiz 13	13.47	55.08	9.02
Analiz 14	11.04	45.58	12.68
Analiz 15	12.29	46.37	13.94
Analiz 16	13.01	49.69	6.62
Analiz 17	11.29	52.71	8.1
Analiz 18	11.54	55.73	7.64
Analiz 19	13.64	50.57	12.49
Analiz 20	11.45	58.37	14.82
Analiz 21	14.32	57.34	9.38
Analiz 22	14.05	53.03	13.2
Analiz 23	11.74	50.18	6.11
Analiz 24	13.26	47.26	11.75
Analiz 25	10.23	54.68	9.83


Tablodaki değerlere göre 25 farklı 3B braket modeli CATIA V5 programında oluşturuldu. Oluşturulan 25 farklı model için sonlu elemanlar analizi gerçekleştirildi. Analiz sonuçları Tablo 5’teki gibidir.

TABLO 5. Analiz Sonuçları


Model Adı	-Z [Mpa]	+Z [Mpa]	+X [Mpa]	-X [Mpa]
Analiz1	204	200	160	160
Analiz2	207	213	123	125
Analiz3	206	212	103	103
Analiz4	203	206	113	116
Analiz5	200	206	120	121
Analiz6	183	188	117	117
Analiz7	207	211	133	134
Analiz8	204	211	117	117
Analiz9	203	204	135	135
Analiz10	203	207	125	127
Analiz11	185	189	114	114
Analiz12	199	203	145	148
Analiz13	200	205	117	118
Analiz14	198	209	130	132
Analiz15	200	204	142	139
Analiz16	200	203	105	106

Analiz17	201	206	120	121
Analiz18	193	197	118	120
Analiz19	203	202	131	131
Analiz20	203	208	154	152
Analiz21	197	200	117	117
Analiz22	202	207	125	125
Analiz23	208	208	106	109
Analiz24	199	209	126	124
Analiz25	202	208	142	144

Yapay sinir ağların oluşturulması için 25 modelin a, b, c parametreleri girdi, sonlu elemanlarla analiz sonuçlarından elde edilen gerilme değerleri çıktı olarak kullanıldı. MATLAB programının “Neural Net Fitting” modülü kullanılarak yapay sinir ağları modeli oluşturuldu Şekil 9’daki gibi oluşturulmuştur. Eğitim algoritması olarak “Bayesian Regularization” kullanıldı. Bu algoritmanın seçilmesinin nedeni küçük data setlerinde doğru sonuç vermesidir. Girdi datalarının %85’i (21 adet) eğitim için %15’i (4 adet) test için kullanıldı. Eğitim, test ve genel olarak “Net Fitting” işleminin regresyon değerleri 0.99’dan büyüktür. Regresyon grafikleri Şekil 10’daki gibidir..



Şekil 9. Yapay Sinir Ağı Modeli



Şekil 10. Regresyon Değerleri

Yapay sinir ağları modelinin doğru çalışıp çalışmadığını kontrol etmek amacıyla daha önce yapay sinir ağları

modelinde kullanılmamış a, b, c tasarım değişkenleri belirlendi Tablo 6’daki gibi belirlenmiştir.

TABLO 6. Tasarım Değişkenleri

Model Adı	Tasarım Değişkenleri		
	a	b	c
Deneme 1	12.01	49.77	6.36
Deneme 2	13.86	56.40	11.65
Deneme 3	12.40	55.52	6.06
Deneme 4	12.0	52.0	11.0
Deneme 5	11.0	55.0	8.0

Belirlenen tasarım değişkenlerine göre 3B braket modelleri oluşturuldu. Braketler SEA yöntemiyle analiz edildi ve gerilme değerleri elde edildi. SEA yöntemiyle elde edilen gerilme değerleri YSA yöntemiyle elde edilen gerilme değerleri ile karşılaştırıldı. Tablo 7’de görüldüğü üzere iki yöntem arasındaki fark %1-3 arasındadır.

TABLO 7. Analiz Sonuçları ile Yapay Sinir Ağı Sonuçlarının Kıyaslanması

Model Adı	-Z[Mpa]		
	SEA	YSA	Fark
Deneme1	199	194	3%
Deneme2	199	203	2%
Deneme3	195	195	0%
Deneme4	207	200	3%
Deneme5	200	197	2%
Model Adı	+Z[Mpa]		
	SEA	YSA	Fark
Deneme1	201	198	1%
Deneme2	206	207	0%
Deneme3	198	200	1%
Deneme4	207	205	1%
Deneme5	195	201	3%
Model Adı	+X[Mpa]		
	SEA	YSA	Fark
Deneme1	108	108	0%
Deneme2	128	126	2%
Deneme3	107	108	1%
Deneme4	130	132	2%
Deneme5	127	124	2%
Model Adı	-X[Mpa]		
	SEA	YSA	Fark
Deneme1	110	109	1%
Deneme2	130	127	2%
Deneme3	106	109	3%
Deneme4	131	132	1%
Deneme5	128	125	2%

III. SONUÇLAR

Motor takozu braketleri motordan kaynaklı titreşimleri sönmölemek amacıyla kullanılırlar. Otomotiv endüstrisinde kullanılan parçaların hafif ve yeterli dayanımı sahip olması istenir. Topoloji ve şekil optimizasyonunu gibi optimizasyon yöntemleri kullanılarak otomotiv parçalarının en uygun tasarımları elde edilmeye çalışılır. Çalışmada incelenen braketin çalışma koşullarındaki dayanımı sonlu elemanlar analizleri ile incelenmiştir. Sonlu eleman analizleri tasarımları inceleme aşamasında yeterli olmasına rağmen optimizasyon gibi çok fazla iterasyonun gerektiği durumlarda hazırlama sürecinin ve çözüm süresinin uzun olabilmesi nedeniyle kullanımı uygun olmayabiliyor. Bu süreleri azaltmak için vekil modelleme yöntemleri kullanılmaktadır. Bu çalışmada da 25 adet sonlu elemanlar analizi üzerinden yapay sinir ağları kurularak vekil model elde edilmiştir. Elde edilen vekil modellerde en büyük hata değeri yaklaşık olarak %3 olarak bulunmuştur. Böylece motor takozu braketinin sonlu elemanlar analizi sonuçlarının vekil modelini elde etmek için yapay sinir ağlarının yüksek doğrulukla kullanılabileceği ortaya konulmuştur. Bu çalışmada, sonlu elemanlar analizleri ile elde edilen veriler kullanılarak yapay sinir ağları modelinin eğitimi ile hesapsal ve zaman açısından maliyetli uygulamalar yerine belli bir hata oranında analizlerin yapay sinir ağı modeli ile tahmin edilebileceği görölmüştür. Sonuç olarak, hata oranları dikkate alınarak tasarım çalışmaları sürecinde sonlu elemanlar analizlerine gereksinim duyulan uygulamalarda tahmini değerlerin belirlenmesine yardımcı bir araç olarak yapay sinir ağları kullanılabilir. Ancak, modelin eğitilmesinde sonlu elemanlar analizleri kullanıldığı için tahmini değer hesaplamalarının bu kapsam içinde değerlendirilmesi gerekmektedir.

REFERANSLAR

- [1] Engel, E. (2013), "Predicting the design relevant loads in the engine mount system at an early stage of the development process" Yüksek Lisans Tezi, The University of Stockholm, Sweden, 6-11.
- [2] Yıldız, A.R. Kaya, N. Öztürk, F. Alankuş, O. (2004). Optimal design of vehicle components using topology design and optimisation, International Journal of Vehicle Design 34 (4), 387-398. doi:10.1504/IJVD.2004.004064
- [3] Hatipoglu, Melek, (2015), Topology Optimization Method and Automotive Bracket Optimization, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbulK. Elissa, "Title of paper if known," unpublished.
- [4] Bathe, J.K., (2016) Finite Element Procedures, Second Edition, Fourth Printing, Watertown, MA.
- [5] Bois, P.D., Chou, C.C., Fileta, B.B., Khalil, T.B., King, A.I., Mahmood, H.F., Mertz, H.J., Wismans, J., (2004), Vehicle Crashworthiness and Occupant Protection, American Iron and Steel Institute 2000 Town Center Southfield, Michigan 48075.
- [6] Çekiç İ. (2022), Yapay Zeka Metotlarını Kullanarak Otomotiv Sektöründeki Örnek Problemlerin Çözümlerinin Araştırılması, Doktora Tezi, sayfa 5
- [7] Erdemir F. (2019), Esneyerek Kilitlenen Bağlantı Elemanlarının Tasarımı ve Yapay Sinir Ağları (YSA) İle Modellenmesi, Yüksek Lisans Tezi sayfa 78
- [8] Dassault Systèmes CATIA V5R20 user guide.
- [9] Altair Hyperworks, 2019. Radioss user guide.
- [10] MATLAB® Online™ user guide.

Kampüs İçi Kapalı Alanlarda Hava Kalitesinin Makine Öğrenmesi Algoritmaları ile Modellenmesi

1st Elif Cesur
Endüstri Mühendisliği
İstanbul Medeniyet Üniversitesi
İstanbul, TURKEY
0000-0001-5241-5628

2nd Muhammet Raşit Cesur
Endüstri Mühendisliği
İstanbul Medeniyet Üniversitesi
İstanbul, TURKEY
0000-0001-9941-0517

3rd Cemal Efe
Endüstri Mühendisliği
İstanbul Medeniyet Üniversitesi
İstanbul, TURKEY
0000-0002-7446-1315

Özet— Bu çalışmada, insanların sıklıkla bir arada bulunduğu yerlerden olan üniversite kampüslerinin kapalı mekanlarında hava kalitesi tahmin modelleri ve bu modellere bağlı olarak geliştirilen karar destek sistemi ile olası bir virüsün bulaşma riskini en aza indirilmesi amaçlanmıştır. Zeki Kampüs başlığı altında sınıflarda, idari ofislerde ve toplantı salonlarında hava kalitesi ölçülmüş ve gerekli görülen zamanlarda belirlenen kararların alınmasını sağlayacak bir sistemin kurulması hedeflenmiştir. Bu bağlamda çalışmada öncelikle karbondioksit, sıcaklık, nem, basınç ve hava kalitesi (MQ135) sensörleri insan giriş ve çıkışının yoğun olduğu bir sınıfa yerleştirilmiştir ve düzenli olarak veri alınması sağlanmıştır. Çalışmanın ikinci aşamasında bu sensör verileri veri önleme teknikleri ile analizleri yapılmış ve makine öğrenmesi teknikleri ile sensör verilerinin modellenmesi ve havada gerçekleşen ani değişikliklerin (odanın havalandırılması, insan sayısının artması gibi) model tarafından yakalanmasını sağlanmıştır. Bu çalışmada kurduğumuz modeller kampüs dışında toplu taşıma araçları, işyerleri, ofis, restoran, kafe, özel araçların havalandırma sistemlerinde de kullanılabilmektedir.

Anahtar Kelimeler—Makine Öğrenmesi Algoritmaları, Hava Kalitesi Modellenmesi, Zeki Kampüs

I. GİRİŞ

Günümüzde salgın bulaşıcılığını ve etkisini giderek arttırarak devam ettirmektedir. Hasta kişilerden saçılan bu damlacıklar eşyaların üzerinde de bulaşıcılık etkisini devam ettirebilmektedir. Yapılan araştırmalar virüsün kapalı ortamlarda daha fazla bulaşıcılık etkisi gösterdiğini kanıtlamaktadır. Maske ve sosyal mesafe kuralları açık ortamlarda virüsün bulaşıcılığını azaltmasına rağmen kapalı ortamlarda bulaş riskini önemli derecede azaltamamaktadır. Yapılan araştırmalarda virüs salgınının hava kalitesinin düşük yerlerde arttığını ve virüs partiküllerinin havalandırma ya da filtreleme yoluyla etkisiz hale getirilebileceğini savunmaktadır. [8]

Öğrenci ve öğretmenlerin yoğunlukla bir arada bulunduğu kapalı kampüs ortamlarında hava kalitesi tahmin modelleri oluşturularak. Makine öğrenme modelleri ile modelin performansı karşılaştırılacaktır. Çalışmanın bir sonraki aşamasında ise geliştirilen karar destek sistemi ile kampüslerde kapalı ortamlarda hava kalitesi sağlıklı düzeyde tutulması hedeflenmektedir.

II. LİTERATÜR TARAMASI

Kapalı alanlarda hava kalitesinin belirlenmesi ve makine öğrenme algoritmaları ile modellenmesi ana başlığı ile literatür tarandığında bulunan önemli çalışmalar bu alanda detaylı bir şekilde anlatılmıştır. Dokuz ve arkadaşları yaptıkları çalışmada, hava kirliliği parametrelerinin çevreye olan etkileri, özellikleri, bu parametrelerin tahmin edilmesi ve değerlendirilmesinde uygulanan makine öğrenmesi yöntemlerinin neler olduğunu elde edilen doğruluk düzeyleri açısından incelenerek kullanılan yöntemlere ilişkin detaylı

bilgi verilmiştir. Araştırma sonucunda uygulanacak yöntemin veri hacmine göre belirlenmesi gerektiği saptanmıştır. [3]

Gültepe ise 2019 yılında yaptığı “Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme” çalışmasında Kastamonu ili ele alınarak, çeşitli makine öğrenmesi algoritmaları ile nem, PM10, rüzgâr yönü, SO₂, hava basıncı, rüzgâr hızı ve hava sıcaklığı gibi meteorolojik parametreleri kullanarak hava kirliliği tahmini yapacak modeller tasarlanmıştır. [4] Irmak ve arkadaşları yaptıkları çalışmada Adana ili valilik istasyonunda, Faizi ise 2021 yılında yapmış olduğu çalışmada Kabil şehri için farklı hava parametreleri kullanarak benzer çalışmalar yapmıştır. 1236 bölge için Zhang ve arkadaşları yaptığı araştırmada COVID-19’un bulaşmasında hava koşullarının etkisi saptanmaya çalışılmıştır. [8] Araştırmada sıcaklık, güneş ışığı saatleri ve nem dahil olmak üzere farklı hava faktörlerinin etkisi değerlendirilerek derin transfer öğrenme tabanlı kapsamlı bir analiz gerçekleştirilmektedir. [2]

Karakuş ve Yıldız’ın birlikte yaptıkları çalışmada Sivas kent merkezindeki hava kirliliği değerlendirilmiş ve hava kalite indeksi (HKİ) hesaplanmıştır. Analiz sonucunda; HKİ ile rüzgâr hızı, nem ve sıcaklık arasında anlamlı bir ilişki olduğu belirlenmiştir. [6]

Zhang ve arkadaşları 2019 yılında birlikte yaptıkları çalışmada tahmin ve değerlendirmeden oluşan yeni bir hava kalitesi erken uyarı sistemi geliştirilmiştir. [8] Balta’nın 2019 yılında yapmış olduğu çalışmada sınıf gibi kapalı ortamlardaki bütün konfor parametrelerinin birlikte değerlendirilerek hava kalitesini izleme sistemi ile kapalı bir mekandaki insanlar için en temiz hava kalitesinin sağlanması hedeflenmiştir. [1]

Santos ve arkadaşları birlikte yaptıkları çalışmada yoğun bakım ünitesinde ve tüm hastane ortamında korona virüs hastalığını (Covid-19) azaltmak için enfeksiyon riskini en aza indiren ısıtma, havalandırma ve iklimlendirmenin rolünü vurgulamaktadır. Sonuç olarak, nemin insan konforu üzerinde sağlık sorununda daha az etkisi olduğu saptanmıştır. Düşük sıcaklık cansız yüzeylerde canlı virüslerin kalıcılığını arttırırken yüksek sıcaklıklar korona virüslerin kalıcılığını azaltmaktadır. [7].

III. UYGULAMA

A. Veri Ön İşleme Analizleri


Kampüs içi kapalı alanlarda hava kalitesinin modellenmesi ve karar destek sisteminin geliştirilmesi için İstanbul Medeniyet Üniversitesi mühendislik sınıflarında yer alan hava kalitesi ölçüm cihazı ile Kasım ayında sıcaklık, nem, CO₂, Basınç (p) ve havadaki kirlilik partikül değerlerinin (AQ) ölçümleri yapılmıştır. Bu ölçümler belli saniye aralıkları ile ölçülerek kaydedilmiştir. Mühendislik

sınıflarında bulunan hava kalitesi ölçüm cihazından Kasım ayında belirli günlerde elde edilen verilerin bir bölümü aşağıdaki tablolarda verilmiştir.


TABLO 1: HAVA KALİTESİ ÖLÇÜM DEĞERLERİ

sıcaklık	nem	co2	aq	p	süre(sn)
26	35,1	424	44	1183,7524	0
26	35,1	421	41	1184,025	1,925
26	35,2	421	45	1183,4625	3,832
26	35,2	421	50	1183,6475	5,763
26	35,1	421	48	1183,1725	7,67
26	35,1	424	43	1183,7125	9,6
26	35,3	421	46	1183,3824	11,506
26	35,3	421	51	1183,64	13,437
26	35,2	421	45	1183,1125	15,343
26	35,2	421	51	1183,6525	17,273
26	35,2	416	45	1183,26	19,177
26	35,2	424	44	1183,5225	21,108
26	35,2	411	46	1183,48	58,319
26	35,2	411	51	1183,5	60,248
26	35,3	411	45	1183,075	62,153
26	35,3	411	45	1183,5675	64,083
26	35,2	421	46	1183,145	65,989
26	35,2	411	45	1183,8075	70,67
26	35,2	421	45	1183,33	72,577

Parametre değerlerinin birbiri ile olan ilişkilerini gösteren grafikler ve korelasyon değerleri aşağıdaki grafiklerde verilmiştir.




Şekil 1. Parametre İlişki Matrisi Grafiği




Şekil 2. Parametre Korelasyon Matrisi

Kasım ayında ölçülen sıcaklık, CO2, basınç, AQ ve nem grafiklerinin frekans grafikleri aşağıda verilmiştir.



Şekil 3. Parametre Frekans Grafikleri

Kasım verileri içerisindeki parametrelerinden birbirleri ile ilişkisi diğer parametrelere göre daha yüksek olan CO2 ve AQ değerlerinin ölçüm değerleri aşağıdaki grafikte gösterilmiştir.




Şekil 4. CO2 ve AQ Parametrelerinin Tarihler Göre Dağılımı

B. K Means Algoritması ile Kümeleme Analizi


K-Means Algoritması ile kümeleme çalışması yapılmıştır. Öncelikle veri ön işleme çalışması ile verideki aykırı değerler çıkarılmıştır. Verimizde eksik değer olmadığından dolayı veri doldurma işlemi yapılmamıştır. Verilerimiz ("center","scale") metodu ile ölçeklendirilir. Veriler ölçeklendirilerek değerlerin birbirleri ile yaklaşması sağlanır. Böylelikle veriden daha doğru ve düzgün sonuçlar elde edilebilecektir.

Kasım verileri kullanılarak ilk olarak K-Means algoritması yöntemi ile verideki değerler için kümeleme çalışması yapılır. Optimum küme sayısı "silhouette", "elbow" yöntemler kullanılarak elde edilmeye çalışılır. Veriler ilk olarak rastgele küme sayısı 4 olacak şekilde kümelendi. 4 küme için elde edilen sonuçlar ve hata değeri aşağıdaki gibi olmaktadır.




Şekil 5. Verilerinin K-Means Yöntemi ile Kümelmesi

Oluşturulan 4 küme için parametrelere ait kutu grafikleri aşağıda verilmiştir.




Şekil 6. Oluşturulan 4 Küme İçin Parametre Değerlerine Göre Kutu Grafikleri

Hata miktarını minimum yapacak optimum küme sayısının bulunabilmesi için sırasıyla “wss”, “total within sum of squares”, “en azlayan”, “max score” ve “silhouette” yöntemleri kullanılarak çizilen grafikler aşağıda verilmiştir. Çizilen 4 grafik için sırasıyla optimum küme sayısı 3 ile 5 aralığında, 3 ile 4 arasında, 3 ve 3 olarak belirlenmiştir. Buradan optimum küme sayımız 3 olarak belirlenmiştir.



Şekil 7. Optimum Küme Sayısı


Kasım verileri küme sayısı 3 olacak şekilde K-Means algoritması ile kümelendiğinde elde edilen sonuç ve grafikler aşağıdaki gibi olmaktadır. 1868 veri 1. kümede, 1071 veri 2. kümede, 1343 veri 3. kümede olacak şekilde ayrılmıştır. Oluşturulan kümelerin parametre ortalamaları ve hata değerleri aşağıda verilmiştir.




Şekil 8. Kasım Verilerinin K-Means Yöntemi ile Optimum Küme Sayısı (3) ile Kümelmesi

C. Yapay Sinir Ağları ile Hava Kalitesinin Tahmini


Kasım verisindeki sıcaklık, nem, CO2, AQ ve basınç değerleri merkeze göre normalize edilir. Sonrasında normalize edilen data K-Means yöntemi ile 3 kümeye ayrılmıştır. Elde edilen kümeler verinin sağ tarafına cluster adında sütun açılarak eklenir. Kasım verisinin %65’lik bölümü eğitim verisi olarak, geri kalan %35’lik bölümü test verisi olarak ayrılmıştır. Cluster sütunu 3 levelden oluşan (“1”, “2”, “3”) faktör türüne dönüştürülür. Elde edilen kümeleme sonucunda kümelerin ortalama CO2 oranlarına bakıldığında 2. Kümenin kirli, 3. Kümenin temiz, 1. Kümenin normal hava kalitesi standartlarında olduğu kabul edilmiştir. Yapay sinir ağı algoritmasında katman değerleri değiştirilerek en iyi model elde edilmeye çalışılmıştır. Bu bağlamda 3 mimari geliştirilmiş ve şekil 9-11 de gösterilmiştir. Oluşturulan yapay sinir ağı modellerinden en az hata ile tahmin eden model olan (3,2) katmanlı yapay sinir ağı modeli seçilmiştir.



Şekil 9. 4 Döğümlü Yapay Sinir Ağı Modeli



Şekil 10. 2 Katmanlı Yapay Sinir Ağı Modeli




Şekil 11. (3,2) Katmanlı Yapay Sinir Ağı Modeli


Kasım verisinin %65'lik bölümü eğitim datası olarak verilerek kalan %35'lik bölüm test datası yapay sinir ağı ile tahmin edilmeye çalışılmıştır. Elde edilen modele göre 605 adet veri 1. küme, 655 adet veri 2. küme, 460 adet veri 3. küme olarak tahmin edilmiştir.

D. Destek Vektör Makineleri ile Hava Kalitesinin Tahmini

Bulunan kümeleme sonuçları K-Means algoritması kullanılarak lineer ve radyal modeller ile Destek Vektör Makineleri modelleri oluşturulmuştur. 150 adet lineer destek vektörü oluşturulur. 215 adet radyal destek vektörü oluşturulur. Oluşturulan lineer modelin ve radyal modelin doğruluk değerleri ve konfüzyon matrisi aşağıda verilmiştir;




Şekil 12. CO2 ve AQ Parametrelerinin Lineer SVM Modeliyle



Şekil 13. CO2 ve AQ Parametrelerinin Radyal SVM

E. Bayes Algoritması ile Hava Kalitesinin Tahmini


Bayes yöntemi ile küme tahmin modeli oluşturulmuştur.. Elde edilen modele göre 655 adet veri 1. küme, 625 adet veri 2. küme, 440 adet veri 3. küme olarak tahmin edilmiştir. Kasım verileri için oluşturulan 3 kümenin parametre değerlerine göre Bayes Density değerleri aşağıda verilmiştir.



Şekil 14. Parametre Değerlerine Göre Bayes Density

F. Karar Ağaçları ile Hava Kalitesinin Tahmini

Karar ağacı algoritması kullanılarak eğitim setindeki K-Means ile elde edilen kümeler kullanılarak Kasım verisinin test olarak ayrılan kısmının kümeleri tahmin edilmeye çalışılır. 619 veri 1. Küme, 654 veri 2. Küme, 447 veri 3. Küme olarak belirlenmiştir. Oluşturulan karar ağacı aşağıdaki şemada gösterilmiştir.



Şekil 15. Karar Ağacı Modeli

G. KNN ile Hava Kalitesinin Tahmini

K En Yakın Komşu algoritmasında, 3192 adet veriden oluşan Kasım verileri eğitim datası ve 1720 adet veriden oluşan Kasım verileri test datası olmak üzere Öklid yöntemi ile k sayısı 10 olacak şekilde küme tahmin işlemleri yapılır. Test verileri için tahmin edilen kümeler KNN adında yeni bir sütuna eklenir. Tahmin sonucunda 578 veri 1.Küme, 681 veri 2. Küme ve 461 veri 3.Küme olarak belirlenmiştir. Tahmin sonuçlarının K-Means yöntemi ile sonuçlarının farkı aşağıdaki matriste verilmiştir:

testSet\$cluster	prc_test_pred			Row Total
	1	2	3	
1	577	0	0	577
	1.000	0.000	0.000	0.335
	0.998	0.000	0.000	
	0.335	0.000	0.000	
2	1	681	0	682
	0.001	0.999	0.000	0.397
	0.002	1.000	0.000	
	0.001	0.396	0.000	
3	0	0	461	461
	0.000	0.000	1.000	0.268
	0.000	0.000	1.000	
	0.000	0.000	0.268	
Column Total	578	681	461	1720
	0.336	0.396	0.268	

Şekil 16. K-NN Karşılaştırma Matrisi

6 farklı algoritmanın küme tahmini performans değerlendirme ölçütleri MAE, MSE, MAPE, R2 ve doğruluk değerleri olarak aşağıda verilmiştir.

TABLO 2: PERFORMANS KARŞILAŞTIRILMASI

	YSA	SVM Linear	SVM Radyal
MAE	0.0070	0.0070	0.0087
MSE	0.0093	0.0093	0.0110
MAPE	0.0053	0.0049	0.0063
R2 Score	0.9848	0.9848	0.9819
Accuracy	0.9942	0.9941	0.9924
	Bayes	Karar Ağacı	K NN
MAE	0.0419	0.0401	0.0006
MSE	0.0640	0.0634	0.0006
MAPE	0.0170	0.0198	0.0003
R2 Score	0.8956	0.8960	0.9990
Accuracy	0.9692	0.9710	0.9994

TABLO 3: KARŞILAŞTIRMA MATRİSLERİ

	YSA	SVM Linear	SVM Radyal
Confusion Matrix	y_pred	y_pred	y_pred
	y_true 1 2 3	y_true 1 2 3	y_true 1 2 3
	1 605 3 2	1 606 2 2	1 604 4 2
	2 0 650 3	2 3 650 0	2 3 650 0
	3 0 2 455	3 0 3 454	3 0 4 453
	Bayes	Karar Ağacı	K NN
Confusion Matrix	y_pred	y_pred	y_pred
	y_true 1 2 3	y_true 1 2 3	y_true 1 2 3
	1 610 0 0	1 597 13 0	1 577 0 0
	2 26 622 5	2 2 639 12	2 1 681 0
	3 19 3 435	3 20 2 435	3 0 0 461

IV. SONUÇ

Bu çalışma kapsamında kampüsteki bir sınıftan alınan veriler kullanılarak sınıftaki hava kalitesi Karar Ağacı, Destek Vektör Makinaları, Bayes, K En Yakın Komşu ve Yapay Sinir Ağları metotları ile tahmin edilmeye çalışılmıştır. Makine öğrenmesi metotları ile oluşturulan karar destek sistemleri kabul edilebilir doğrulukta tahmin sonuçları üretmiştir. Havalandırma zamanlarını en iyi tahmin eden makine öğrenmesi yöntemi 0,9994 doğruluk ile KNN modeli olmuştur. En kötü tahmin yöntemi ise 0,9692 doğruluk oranıyla Bayes yöntemi olmuştur. Karar ağacı yöntemi de havalandırma durumlarını tespit etmekte zorlanmıştır

Yaptığımız bu çalışma ile makine öğrenmesi teknikleriyle sensör verilerinin modellenmesi amaçlanmıştır. Kümeleme yöntemleri ile optimum 3 küme oluşturulmuş ve kirli normal ve temiz hava olarak isimlendirilmiştir. Sonrasında makine öğrenmesi algoritmaları ile hava kalitesi tahmin edilmeye çalışılmıştır. Bu çalışmada kurduğumuz modeller kampüs dışında toplu taşıma araçları, işyerleri, ofis, restoran, kafe, özel araçların havalandırma sistemlerinde de kullanılabilir olacaktır.

REFERANSLAR

- [1] Balta, D. (2019) Dağıtık Sensör Sistemleri Mimarisi ile Bulanık Mantık Temelli ve Çevrimiçi Kapalı Ortam Hava Kalitesi İzleme Sistemi Geliştirilmesi.
- [2] DOKUZ, Y. et al. (2020) Hava Kalitesi Para metrelerinin Tahmini ve Mekansal Dağılımı İçin Makine Öğrenmesi Yöntemlerinin Kullanılması. Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi. [Online]
- [3] Elibol, H. (2021b) Kapalı Mekanlarda Sosyal Mesafe Kuralı Ne Kadar Önemli [online]. Available from: <https://www.hurriyet.com.tr/gundem/kapali-mekanlarda-sosyal-mesafe-kurali-ne-kadar-onemli-41801992> (Accessed 2 February 2022).
- [4] GÜLTEPE, Y. (2019) Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme. European Journal of Science and Technology. [Online] 8–15.
- [5] Gupta, Y. et al. (2021) Impact of Weather Predictions on COVID-19 Infection Rate by Using Deep Learning Models. Complexity. [Online] 2021.
- [6] KARAKUŞ, C. B. & YILDIZ, S. (2019) Hava Kalite İndeksi İle Meteorolojik Parametreler Arasındaki İlişkinin Çoklu Regresyon Yöntemi İle Belirlenmesi. Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi. [Online]
- [7] Santos, A. F. et al. (2020) Best Practices on HVAC Design to Minimize the Risk of COVID-19 Infection within Indoor Environments. Brazilian Archives of Biology and Technology. [Online] 631–11.
- [8] Zhang, C. et al. (2021) The role of weather conditions in COVID-19 transmission: A study of a global panel of 1236 regions. Journal of Cleaner Production. [Online] 292.

The Effects of Artificial Intelligence Studies in Health as a Biopolitics Tool

Prof. Dr. Azize Serap Tunçer
Çankırı Karatekin University
Faculty of Health Sciences
Head of Social Work Department
Çankırı, Turkey
serap@seraptuncer.com. Orcid: 0000-0001-8629-4828

Abstract— With the rise of central biological control and regulation, information technologies and programs, which are products of artificial intelligence, are used on human, who is today's ideological-political subject; In addition, similar products are used in the self-regulation of narcissistic personalities who are conditioned to "self-actualization" through processes such as diet, sports, etc. in terms of health. There is technique in the historical origin of this control network, and at the stage we have reached today, artificial intelligence programs have taken over. Fears of epidemics have been the legitimate ground of biopolitical control since the first appearance of registration and registration processes in the UK case in health care. The Covid 19 experience has made this linear line once again clearly visible. On the one hand, large-budget health artificial intelligence studies have been accelerated, on the other hand, digitalization processes have entered the daily life of all people. This study is a qualitative study based on literature review, aiming to evaluate the future of artificial intelligence and digital developments in the field of health, the level of adaptation of the masses to technological innovations and to produce a future perspective.

Keywords: health- Covid 19- artificial intelligence-biopolitics.

I. INTRODUCTION

Artificial intelligence studies in the field of health are long-term and multidimensional. On the one hand, these studies, which are essential for saving human life and providing a better quality living environment, on the other hand, produce artificial intelligence products that rival it by making human data an artificial intelligence material, or form the basis for the execution of auditing systematics through the control of data. Therefore, although it is clear that the use of artificial intelligence in health cannot be avoided, how to establish an ethical framework for human existence remains a deep question.

II. BETWEEN ANATOMY-POLICY AND BIO-POLICY

Foucault says that since the seventeenth century, power over life has developed in two forms: the anatomy-politics of the human body and the bio-politics of the population. The anatomy-policy of the human body has centered the body and aims to reveal and increase its abilities by training the body, and to improve its usefulness in parallel with its obedience. On the other hand, population bio-policy regulates population based on life expectancy and health

levels [1]. Both policy areas target bodies and focus on the problem of public health.

Although many cases can be shown, which exemplifies the public dimension of health measures, an application that is subject to legal regulation is quite remarkable. Accordingly, with a law enacted in 1722 in England, the help of patients at home was prohibited and the obligation to bring the poor patient to the hospital was imposed. With the amendment of the law in 1796 and the decision of the type of aid to be given to the poor patients staying in their homes by the overseers in each village, the supervision-oriented execution of health policies reached a new stage. [2].

In the process of basic regulation of medical practice, the Marly decrees of 1707 were important and thus regulated the formation of medical practice and physicians for the entire 18th century. Various interventions have been made in order to eliminate non-professional persons, from the restriction of the right to practice to the more precise regulation of university chairs. As a result, the practice of looking after the patients at the doctor's home has passed to the observation stage in the clinic [3].

The panoptic system, Jeremy Bentham's general surveillance system, to which Foucault focused his attention, became an illustrative example when evaluating today's surveillance society. This system, which is especially focused on recording and surveillance, is considered to be completely natural when it comes to health. This panoptic system is possible thanks to highly technical means [4]. These "micro-techniques" for monitoring and control have created a standardized set of "global" techniques and practices that have spread to all sectors of society (education, industrial production), especially medicine [5].

Although regular recording and monitoring of some groups, such as the disabled, sick and elderly, and ensuring that they are equipped with alarm systems, are of great importance in emergency situations, the concern that individuals will turn into "transparent" employees and consumers whose personal characteristics are scanned is also a concrete problem for the society as a whole [6].

On the other hand, the ethical framework of the surveillance system, which aims to protect the "good society" from bad cells, is an extremely sensitive area. The

performance and record environment, which became one of the priorities of the industrial society over time, made sports important by creating an ideal human target for the citizens of the city [7]. This concern is also manifested in Lefebvre's views that the process of cyberneticization "lacks a clear goal or direction other than domination" and that there is no clear answer to how cybernetic information monitoring and monitoring techniques can contribute to a "good society".

The point reached in today's artificial intelligence studies seems to mainly feed the negative perspective. The technique, which has entered from observation to production processes today, has gone too far in creating its own artificial existence. Artificial processes such as biological interventions on the embryo, test-tube babies, and alteration of chromosomes [8] also guide the modeling of artificial intelligence.

On the other hand, the human being, who is controlled from the outside by the technical tools that enable the rise of biological control and regulation in ideological-political arrangements, acts as biopolitical objects and lives under a "self-actualization" oriented sports and nutrition self-control [9]. Self-investment for a healthy life is a fundamental motto of the age, thus ensuring the internal continuity of control.

Allocating resources to invest in people in the age of industrialization was not economically meaningful and did not contribute to the efficiency of the mass production process [10]. Today, it is clear that the most effective way to increase the creative abilities of society is to protect one's own physical and mental health and to engage in activities that improve it. This enables health services to gain a whole new importance [11].

III. ARTIFICIAL INTELLIGENCE APPLICATIONS IN THE COVID 19 ERA

There is a long history of artificial intelligence programs and applications in health and a usage network that gradually spreads to all areas of health. Therefore, this relationship is an area that is developing by deepening. So much so that our language is now a computer language and it is expected that artificial intelligence products can speak this language better than us [12].

Although the use of animal offal as fodder, as in the case of mad cow, related to epidemics; Although there are natural dangers such as the easy transmission of various viruses by migratory birds [13], the suspicion of virus production with the use of artificial intelligence is also alive. Experiments carried out in tens of thousands of advanced laboratories around the world show that a malicious virus can be easily synthesized, deliberately or accidentally. The rate of spread of Covid 19 is still very fresh in the memories as the closest and frightening reality. Moreover, this technology is perhaps more dangerous than nuclear technology. Because while the control of nuclear technology, which requires expensive and large infrastructures, is relatively possible; control of thousands of small laboratories may not be possible [14].

As a matter of fact, the Covid 19 period was a period in which the claim of manufactured viruses was strongly asserted, and a future concern shaped by genetically modified organisms and constant fears of epidemics fed the opposition to technology. Similarly, the association of the virus with 5G technology has also added to the doubts about health-related artificial intelligence studies. Despite all these negative approaches, the use of artificial intelligence data in collecting all data on health, detecting and comparing diagnostic and observation data is an approved dimension [15].

In this period, millions of people were watched directly with the tracking programs downloaded to the phones; robots that measure temperature and disinfect the environment are used in metro stations; In a period when drones, which monitor the environment, spray and carry drugs during the curfew, became widespread, artificial intelligence products were introduced to the smallest local units [16].

IV. THE PLACE OF ARTIFICIAL INTELLIGENCE IN HEALTHCARE IN THE FUTURE

It is not a prophecy to expect that artificial intelligence programs and applications in healthcare will increase in the future. The computer algorithm in a recent experiment beat doctors in diagnosing cancer cases; It is definite proof that robot doctors will be used much more effectively in the future. Thus, the scenario that there will be countless doctors available 24 hours a day, 7 days a week, in every corner of the world, is quite realistic, with the data of doctoral training, which requires an extremely laborious and long training process, to be uploaded to these machines.

The same example is seen in the operation of a pharmacy opened in San Francisco in 2011 with a single robot, and the robot's ability to reach all the prescriptions of the customers who come to the pharmacy, a detailed list of the drugs taken with these prescriptions and suspected allergies in seconds, and fulfill more than 2 million prescriptions without making a single mistake. Again, considering that live pharmacists make mistakes in an average of 1.7% of the prescriptions they receive, and this number corresponds to more than 50 million incorrect prescriptions every year in the USA, the benefit of this step will be accepted [17, 18].

Analysis of DNA sequencing and the presence of wearable biometric devices will also reinforce the process [19].

On the other hand, it is necessary to realize that the artificial intelligence revolution does not only consist of computers becoming faster and smarter, and that this revolution is also fed by advances in science and social sciences [20]. In other words, the deepening of human knowledge and abilities is in reciprocity with the strengthening of artificial intelligence.

In the future, it will be possible for people to perform health checks directly with some smart applications, and the claims that democratic participation channels will increase

with these applications and that they will approach more and more direct democracy with the support of technology use also draw attention to the possibilities of politically benefiting from artificial intelligence studies [21].

Finally, he also transferred his wealth acquired through bitcoin technology, which is suspected to be an artificial hyper-intelligence product, in which his body was frozen in a facility in Arizona until one day a solution is found for the ALS disease (Amyotrophic Lateral Sclerosis, a disease that slowly destroys the body) that caused his death in 2014. It is possible to commemorate Hal Finney, who wanted it to be used to cover the costs of its storage [22]. This and many similar situations show that there is a large area that relies on artificial intelligence studies in health.

V. CONCLUSION

Artificial intelligence studies in health continue in many ways. While research on many diseases continues, the evaluation of the monitored data sets by artificial intelligence programs; using these tools in the development of diagnostic and therapeutic recommendations; Artificial intelligence products and programs are effective in many applications such as health checks in crowded centers.

Various negative developments may occur, especially if they are used as a tool for future biopolitics, and the existence of functional programs that nourish the human mind and solve its health problems is also of vital importance. In this process, finding the ethical framework and staying within this framework with a global harmony may also be the main determinant of the duty and future of human beings.

REFERENCES

- [1] Z. Yılmaz, Yoksulları Ne Yapmalı? Ankara: Dipnot Yayınları, 2012. 158.
- [2] M. Foucault, Deliliğin Tarihi, (Çev. M. A. Kılıçbay), (6. Baskı), Ankara: İmge, 2015. 598.
- [3] M. Foucault, Kliniğin Doğuşu (Tıbbi Algının Arkeolojisi). (Çev. Ş. Ünsaldı, Ankara: Epos, 2002. 70-82.
- [4] J. Ellul, Sözlün Gözden Düşüşü, (Çev. E. Ercan), İstanbul: Sentez Yayıncılık, 2017. 226.
- [5] M. Gardiner, Gündelik Hayat Eleştirileri, (Çev. D. Özçetin, B. Taşdemir, B. Özçetin), Ankara: Heretik, 2016. 129.
- [6] J.V. Dijk, Ağ Toplumu, (Çev. Ö. Sakin), İstanbul: Epsilon Yayın., 2016. 14.
- [7] Aktaran: M. Gardiner, Gündelik Hayat Eleştirileri, (Çev. D. Özçetin, B. Taşdemir, B. Özçetin), Ankara: Heretik, 2016. 129.
- [8] J. Ellul, Sözlün Gözden Düşüşü, (Çev. E. Ercan), İstanbul: Sentez Yayıncılık, 2017. 371.
- [9] S. Zizek, Paralak, (Çev. S. Gürses), İstanbul: Encore, 2014. 297.
- [10] G. Vigarello, ve R. Holt, İşlenen Beden 19. Yüzyılda Jimnastikler ve Sporcular. Bedenin Tarihi 2 (Fransız Devrimi'nden Büyük Savaş'a). Haz. A. Corbin, J.J. Courtine, G. Vigarello, (Çev. O. Türkay), İstanbul: YKY, 249-297. 2011. 289-290.
- [11] R. Richta, "Teknik uygarlığın insan modeli için", Prag 1968 (Doğmayan Hürriyet), (Edt.) R. Garaudy, A. Dubcek, G. Husak, J. Hajek, O. Sik vd., (Çev. A. Balta), İstanbul: e yayınları, 1968. 107.
- [12] J. Ellul, Sözlün Gözden Düşüşü, (Çev. E. Ercan), İstanbul: Sentez Yayıncılık, 2017. 239.
- [13] Scott Barrett, "Ortaya çıkan salgın hastalıklar, bunlara hazırlıklı mıyız?" Kör Nokta, F. Fukuyama, (Ed.) (Çev. H. Kaya), (2. Basım), İstanbul: Profil Yayıncılık, 2015. 124-126.
- [14] F. Fukuyama, (Ed.) Kör Nokta, (Çev. H. Kaya), (2. Basım), İstanbul: Profil Yayıncılık, 2015. 243.
- [15] A.S. Tunçer, "Coronavirüs döneminde dijital devlet uygulamaları", Kamu Yönetimi ve Teknoloji Dergisi (KAYTEK). Vol.2/2, 34-56. 2020.
- [16] A.S. Tunçer, Salgın Sürecinde Dünyada ve Türkiye'de Belediye Uygulamaları, Ankara: TBB Yayını. 2021.
- [17] Y.N. Harari, Homo Deus (Yarının Kısa Bir Tarihi). (Çev. P.N. Taneli), (22. Baskı), İstanbul: Kolektif Kitap, 2020. 329-330.
- [18] P.W. Singer, Wired For War: The Robotics Revolution and Conflict in The 21st Century. NY: Penguin. 2009. 161.
- [19] Y.N. Harari, Homo Deus (Yarının Kısa Bir Tarihi). (Çev. P.N. Taneli), (22. Baskı), İstanbul: Kolektif Kitap, 2020. 349, 410.
- [20] Y.N. Harari, 21.Yüzyıl İçin 21 Ders. (Çev. S. Sıral), (9.Baskı). İstanbul: Kolektif Kitap, 2018. 36, 78.
- [21] A.S. Tuncer, "Geleceğin kentlerinde sağlık ve katılım politikaları". III. Kent Konseyleri Sempozyumu. Balıkesir: Türkiye Kent Konseyleri Birliği, 309-324. 2021.
- [22] P. Vigna, ve M.J. Casey, Kriptopara Çağı (Bitcoin ve Dijital Paranın Küresel Ekonomik Sisteme Meydan Okuması), (Çev. A. Atav), Ankara: Buzdağı Yayınevi, 2017. 76.

Elektrik Dağıtım Şebekelerinde Arıza Tespitinde Yapay Zeka Kullanımı

Eren DİLER
Elektrik Elektronik Mühendisliği
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
erendiler58@gmail.com
0000-0003-4202-8100

Yunis TORUN
Elektrik Elektronik Mühendisliği
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
ytorun@cumhuriyet.edu.tr
0000-0002-6187-0451

Tayfun TURAL
Elektrik Elektronik Mühendisliği
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
tayfun@live.com
0000-0002-7435-4827

Ahmet UYRAOĞLU
Elektrik Elektronik Mühendisliği
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
ahmt.uyrglu@gmail.com
0000-0003-4748-077X

İrem ŞİMŞEK
Elektrik Elektronik Mühendisliği
Sivas Cumhuriyet Üniversitesi
Sivas, Türkiye
iremsmsk.muh@gmail.com
0000-0003-1731-9045

Özet— Elektrik Dağıtım Şebekelerinde arızaların hızlı bir şekilde tespit edilmesi çok önemli ve aynı zamanda çok zordur. Zorlu hava şartları da eklendiği zaman arıza tespiti büyük bir problemdir. Arıza tespiti genellikle saha ekipleri tarafından manuel olarak yapılmıyordu. Bu da hem zaman hem maddi açıdan bir kayıptır. Bunun yerine gelişen teknoloji ile yapay zekanın arıza tespitinde kullanımı önem kazanmıştır. Bu çalışmada Elektrik Dağıtım Şebekelerinde Yapay Zekanın Arıza Tespitinde Kullanımı üzerine yapılan çalışmalar derlenmiş, kullanılan teknikler ve hangi tekniklerin hangi arıza türlerini bulmada kolaylık sağladıkları incelenmiştir.

Anahtar Kelimeler — Yapay Zeka, Elektrik Dağıtım Şebekesi, Makine Öğrenimi, Arıza Tespiti

I. GİRİŞ

Türkiye’de elektrik, üretim tesislerinde 380kV ile 154,5kV değerinde üretildikten sonra indirici trafolar ile birlikte 34,5kV değerine düşürüldükten sonra Elektrik Dağıtım Şirketleri tarafından tedariki sağlanmaktadır. Ülkemizde elektrik dağıtım hattı uzunluğu 2020 yılında 1 milyon 190 bin 605 kilometreye ulaşmıştır [1]. Elektrik tedarikinin tüketicilere ve sanayi kuruluşlarına kesintisiz sağlanması son derece önemlidir. Herhangi bir arızanın sonucunda üretimin durmasına bağlı olarak sanayi kuruluşlarında ciddi kayıplar meydana gelebilmektedir.

Bu noktada arıza tespiti son derece önem kazanmıştır. Elektrik hatlarının uzunluğu arttıkça bakım onarım ve arıza tespit çalışmaları da zorlaşmaktadır. Arıza öngörülemez olduğundan, dağıtım sistemlerinde arızanın etkisini en aza indirmek için hızlı bir arıza yeri tespiti ve onarımı gerekir. Daha eski dönemlerde operatörler hat açması ya da arıza bilgileri için tüketicilerden gelen arıza bildirimlerinden yola çıkarak hareket ederlerdi. Gelişen haberleşme teknolojileriyle birlikte kurulan SCADA benzeri sistemler sayesinde elektrik şebekesinden anlık veriler okunarak arıza bilgileri elde edilebilmektedir. Ancak bu arıza tespit cihazlarından gelen veriler arıza tespitine fayda sağlasa da hala tam olarak arızanın yerini tespit etmek zordur. Bu nedenle elektrik dağıtım sistemlerinde arızaların tespiti için geçmişten günümüze birçok yöntem geliştirilmiştir. Bu yöntemlerden biri de yapay zeka tekniklerinin elektrik şebekelerinde arıza tespiti için kullanımıdır. Gelişen

teknolojilerle birlikte yapay zeka elektrik sektöründe de kullanılmaya başlanmıştır.

Bu çalışmada Elektrik Dağıtım Şebekelerinde yapay zeka ile arıza tespiti üzerine yapılan çalışmalar derlenmiş, hangi yapay zeka tekniklerinin hangi arızaların tespitinde kullanıldığı üzerine yapılan çalışmalar incelenmiş ve farklı bölgelerdeki kullanımı ile ilgili veriler toplanmıştır.

II. GÜÇ SİSTEMİ ARIZALARI

Elektrik arızalarının sebeplerini bilmek, olası yıkıcı tahribatlardan korunmak için oldukça önemlidir. Dağıtım sistemlerinde arızalara sebep olan 3 ana faktör mevcuttur. [2] Bunlar;

- İç Faktörler: Ekipmanın yaşı, ekipmanlardaki üretimsel hatalar, iletkenlerin boyutu gibi.
- Dış Faktörler: Ağaçlar, hayvanlar, hava muhalefetleri, buz gibi.
- İnsan Faktörü: Araç çarpmaları, saha personeli kaynaklı kazalar, vandalizm gibi.

Havai hatlar, atmosfere doğrudan maruz kaldıkları için dağıtım sistemlerinde meydana gelen hasarların büyük bir çoğunluğunu dış faktörler oluşturur. Elektrik şebekelerindeki en önemli arızalardan birisi yeraltı iletkenlerde oluşan elektrokimyasal ağaçlanmadır. Ağaçlanma, dielektrik dayanımını düşüren bir elektrik alan varlığında, nemin kablo yalıtkanına nüfuz etmesiyle oluşur. Tüm yeraltı iletken arızaları izolasyondan kaynaklanmaz. Hatalı işçilik ve nem nedeniyle arızaların büyük bir kısmı ek yerlerinde ve bağlantı uçlarında meydana gelmektedir. Çalışma sırasında yapılan kazılar da yeraltı iletkenlerinde arızalara sebep olmaktadır.

III. YAPAY ZEKA TEKNİKLERİNİN ARIZA TESPİTİNDE KULLANIMI

Yapay zeka, insan beyninin fonksiyonlarını inceleyerek yapay sistemlere uygulanabilir hale getirmeyi amaçlayan bir araştırma alanıdır. Yani bir bilgisayara insan gibi düşünme yetisi kazandırılmasıdır. Yapay zeka terimi 1956 yılında ilk kez ABD’de ortaya çıkmıştır [3]. Ancak ilk zamanlarda yapay zeka uygulamaları için gereken yüksek bilgisayar gücü o dönemde karşılanamadığından araştırmacılar tarafından önemli sonuçlar elde edilememiştir [4]. Daha sonra gelişen teknolojilerle birlikte bilgisayar teknolojilerinin de daha

ulařılabilir ve daha ucuz maliyetli olması sebebiyle bu alanda alıřma yapmak daha mmkn hale gelmiřtir. Yapay zeka kendi ierisinde alt sınıflara ayrılmaktadır.

Bunlardan birisi 1980’li yıllarda ortaya ıkan Makine ğrenmesidir. Yakın gemiřte ise Derin ğrenme kavramı hayatımıza girmiřtir.

Makine ğrenmesi, veri ieren bir modelleme tekniğidir. İnsan mdahalesi olmadan, girilen verilerle birlikte kendi kendine ğrenebilen ve deneyimler ile geliřtiren programlardır. Makine ğrenme modelleri denetimsiz ve denetimli olmak zere ikiye ayrılmaktadır. [3]

A. Denetimsiz ğrenme

Denetimsiz ğrenme, yalnızca girdi verileri olan ve hedef sınıf etiketleri olmayan problemler iin uygulanır [5]. Byle bir veriye dayalı ğrenme tekniğı, verilerin birbirleriyle olan iliřkilerini analiz eder ve sonuca gre verileri gruplandırır. Bu gruplandırma sonucu oluřturulan kmeler ikiye ipte olabilir. Bunlar; sert kmeleme ve yumuřak kmeleme.

1) Sert Kmeleme

Sert kmeleme, her bir veri noktasının sadece bir kmeye ait olduėu, yani farklı kmeler arasında herhangi bir baėlantının olmadıėı kmelemeyi ifade eder [6]. Mevcut katı kmeleme tekniklerinden bazıları K-ortalamlar ve K-medoidlerdir.

a. K-Ortalamlar

K-Ortalamlar’ın atama mekanizması her verinin sadece bir kme ierisinde bulunabilmesine izin verir [7]. Bu nedenle, katı bir kmeleme algoritmasıdır. N adet nesneden oluřan bir veri kmesini, giriř parametresi olarak verilen K adet kmeye blmlemektedir. Ama, gerekleřtirilen blmleme iřlemi sonunda elde edilen kmelerin, kme ii benzerliklerinin maksimum ve kmeler arası benzerliklerinin ise minimum olmasını saėlamaktır [8].

Yhun Z. ve arkadaşları alak gerilim blgelerindeki hatlarda oluřan kayıplar iin geliřtirilmiř K-Ortalamlar’a dayalı bir tahmin modeli nermiřtir. Alak gerilim blgelerinde yapılan gerek verilerin analizi, geliřtirilmiř K-Ortalamlar’ın yksek tahmin doėruluėu zelliėine sahip olduėunu ve basit, hızlı ve etkili olduėunu gstermektedir. [9].

b. K-Medoidler

K-medoidlerde ama verilerin eřitli yapısal zelliklerini gsteren k adet temsilci nesneyi bulmaktır. Bir grup nesneyi k adet kmeye blerek benzer nesneler aynı kmelerde birleřtirilir.

Gangwar A.K ve arkadaşları yaptıkları alıřmada, hibrit daėıtım řebekesinin korunması iin K-medoid kmeleme ve k-en yakın komřuya dayalı yeni bir koruma algoritması sunmaktadır. nerilen yntem trafo merkezlerinde llen 3 fazla akım sinyallerinin dalgacık dnřm ile znitelik ıkartılması ve zniteliklerden hata konumunu ve hata sınıfını retebilecek En Yakın Komřu Regresyonu iermektedir. [10]

2) Yumuřak Kmeleme

Yumuřak kmeleme, kmeler arasında keřiřimin olduėu, yani keskin bir ayrımın olmadıėı anlamına gelmektedir. Bylece, veri nesneleri bir veya birden fazla kmeye ait

olabilir. Mevcut yumuřak kmeleme tekniklerinden bazıları, Bulanık C-Ortalamlar ve Gauss Karıřım Modelleridir.

a. Bulanık C-Ortalamlar

Bulanık c-ortalamlar algoritması ilk olarak J.C. Dunn [11] tarafından 1973 yılında karřımıza ıkmıř ve 1981 yılında J. Bezdek [12] tarafından geliřtirilmiřtir. Bulanık C-Ortalamlar metodu, nesnelerin ikiye veya daha fazla kmeye ait olabilmelerine izin verir. Bulanık mantık prensibi gereėi her veri, kmelerin her birine [0,1] arasında deėiřen birer yelik deėeri ile aittir. yelik deėerinin 1’e yaklařması benzerliėin arttıėı anlamına gelmektedir. Nesne hangi kme merkezine yakın ise o kmeye ait olacaktır. Kmeleme iřlemi ilerlemenin en aza indiėi basamakta tamamlanır.

Chen B. ve arkadaşları yaptıkları alıřmada, iletkenlerde oluřan kısmi deřarjı tespit etmek iin Bulanık c-ortalamlar kmelemesini kullanmıřlardır. Kısmi deřarj darbe zellikleri, eřdeėer zaman frekans analizi yntemi kullanılarak zaman ve frekans alanında analiz edilmiřtir. Sinyalleri sınıflandırmak iin bulanık c-ortalamlar kmeleme algoritması kullanılmıřtır [13].

b. GAUSS KARIřIM MODELİ

Gauss Karıřım Modeli Kmelemesi, ok deėiřkenli veri noktalarını belirli olasılık yntemleri kullanarak kmeler. Bu verilerin ikiye veya daha fazla kmeye ait olması ve oluřturulan bu kmelerin eřitli byklk ve korelasyon yapılarına sahip olması tercih sebebidir [14].

Jazebi S. ve arkadaşları yaptıkları alıřmada, Gauss Karıřım Modellerine (GMM) dayalı yeni bir diferansiyel koruma yaklařımı sunmaktadır. Diferansiyel rlelerin dzenli alıřmasına engel olan ani mıknaatıslanma akımı ve dahili arızaların yanlıř tanımlanması gibi geici olaylar dikkate alınmıřtır. Gl olasılıksal model sınıflandırıcı olan Gauss Karıřım Modeli, eėitimin hesaplama sresini azaltmak ve doėruluėunu artırmak iin ayrıık dalgacık dnřm tarafından ıkarılan zelliklerle eėitilmiřtir. [15]

B. Denetimli ğrenme

Denetimli ğrenme iin nce sisteme veri setleri girilir daha sonra verilerle etiketleme yapılır. Bunun sonucunda girdi ve ıktı veri setleri arasında iliřki kurularak sonuca varılır. Bu ğrenme tekniėindeki temel ama, sonuları bilinmeyen veri setlerine dair doėru ve gvenilir tahminleme yapabilmek iin sonucu bilinen veri setlerini kullanmaktır [16].

1) Sınıflandırma

Sınıflandırma yntemleri, girilen verileri farklı kategorilere ayırmak iin kullanılır. Sınıflandırıcılar, sınıf etiketlerine gre mevcut veri kmesinde grnmeyen verilerin sınıfını tahmin ederek yeni bir yanıt retirler [6]. Farklı sınıflandırma algoritmaları alt blmlerde tartıřılmaktadır.

1.1) k-En Yakın Komřu (K-NN)

K-NN algoritmasının temeli klid(mesafe hesaplaması)’e dayandırılmıřtır. Yeni gelen bir veri ile K adet komřu arasındaki mesafenin llmesi algoritmanın genel mantıėını oluřturmaktadır.. K-NN algoritması belirlenen noktanın hangi sınıfa ait olduėunu tespit etmek iin kullanılan bir sınıflandırma algoritmasıdır.

1.2) Destek Vektör Makinesi (DVM)

Destek Vektör Makineleri denetimli öğrenme yöntemlerinden birisidir. Bir düzlem üzerindeki veri noktalarını ayırtmak ve sınıflandırma yapmak için iki sınıfı ayıran hiperdüzlem adında bir doğru çizilir. Hiperdüzlem ne kadar geniş olursa sınıflar o kadar iyi ayırtılır. Karmaşık ama küçük ve orta ölçekteki veri setleri için uygundur.

Ekici S. yaptığı çalışmada [17], dağıtım hatlarında arıza çeşitlerini sınıflandırmak ve arıza yer tahminlemesi yapmak için tek fazlı gerilim ve akım sinyallerini ölçerek DVM ve Dalgacık Dönüşümü algoritmalarını kullanmıştır. Arıza türlerine yapılan testler sonucunda tüm hata koşulları için sınıflandırma hatasının %1'in altında olduğu görülmüştür. 380kV ve 360km'lik bir iletim hattında ortalama arıza konumlandırma hatası %0,26'dan daha azdır ve maksimum hata 0,95km'nin altındadır.

1.3)Sinir Ağı (NN)

İnsan sinir sisteminin bir taklidi olan sinir ağı, geçmiş deneyimlerden edindiği bilgileri öğrenebilmektedir ve bu bilgiler ışığında tahminler yapabilmektedir. Sinir ağı parametrik olmayan bir modeldir ve ilk başta öğrenme daha sonra hatırlama üzerine çalışmaktadır.

Silva S. ve arkadaşları yaptıkları çalışmada [18], elektrik dağıtım şebekelerindeki yüksek empedans hatalarının tespiti için veri akışına dayalı artırılmış öğrenme algoritmasının nasıl uygulanacağını tartışmışlardır. Elektriksel akım verilerinin zamansal-uzamsal modellerini tanımlamak için gelişen bir sinir ağıyla entegre edilen ayrık bir dalgacık dönüşümüne dayalı özellik çıkarma yöntemi kullanılmıştır. Elde edilen sonuçlara göre çok katmanlı algılayıcı sinir ağı, olasılıksal sinir ağı ve destek vektör makinesinin önerilen sistemin verimli ve değişikliklere karşı dayanıklı olduğunu göstermiştir. Testler sırasında hata modellerinin önemli ölçüde değişmediği durumlarda tüm sınıflandırıcılar tarafından %99 düzeyinde bir sınıflandırma performansı sergilenmektedir.

1.4) Naive Bayes (NB)

Adını matematikçi Thomas Bayes'den alan Naive Bayes sınıflandırma algoritması, sisteme sunulan verilerin sınıfını tespit etmek amacıyla olasılık ilkeleri temelli bir dizi hesaplama yapar. Naive Bayes sınıflandırmasında sisteme sınıf/kategorisi olan öğretilmiş veriler girilir (Örn: 50 adet). Bu verilere olasılık işlemleri yapılır. Daha sonra algoritmaya test verileri girilir. Bu test verileri, mevcut olasılık değerleriyle karşılaştırılarak sonuca göre kategorize edilir. Test verisinin doğruluğu, öğretilmiş verinin çokluğu ile doğru orantılıdır.

Othman M.L. ve arkadaşları yaptıkları çalışmada, şönt kompanzasyonlu statik senkron kompanzatör (STATCOM) bulunan bir enerji nakil hattında oluşan arızaların tespiti için Ayrık Naive Bayes ve Dalgacık Dönüşümü tekniğinden oluşan bir metodoloji önermektedirler. Üç fazlı (LLG) arıza, Hattan Toprağa (LG), Hattan Hata (LL) ve Çift Hattan Toprağa (LLG) gibi farklı arıza türleri tespit edilmiştir [19].

IV. SONUÇ

Elektrik enerjisi günümüzde hayatın vazgeçilmez parçalarından biri haline gelmiştir. Gelişen ve genişleyen yaşam alanları ile birlikte bu enerjinin sadece üretildiği yerde değil, insanın yaşadığı her yere ulaştırılması gerekmektedir. Bu noktada Elektrik Dağıtım Şirketleri devreye girmektedir.

Bu elektrik dağıtım ağı kilometrelerce kesintisiz devam eden havai ve yer altı iletkenlerinden oluşmaktadır. Elektrik enerjisinin kesintisiz bir şekilde tüketicilere ulaştırılması gerekmektedir ancak iletkenlerde meydana gelen arızalar sonucunda elektrik tedariki kesintisiz bir şekilde sağlanamamaktadır. Arıza oluşması pek tabii olasıdır ancak bu arızanın hızlı bir şekilde giderilmesi elzemdir.

Geçmiş yıllarda arıza varlığı genellikle tüketicilerden gelen bildirimlerle tespit edilmekteydi. Gelen çağrılar sonucunda personel kilometrelerce uzunluktaki havai hattı gezerek arıza tespiti yapmaya çalışmaktaydı. Gelişen teknolojilerle birlikte haberleşme sistemleri devreye girdi ve hat başlarında, iletkenlerin üzerinde, trafo kabinlerinde kullanılan sensör teknolojileriyle iletim hatlarında meydana gelen arıza kayıtları okunmaya başlandı.

Günümüz teknolojisi ise yapay zekayı yanında getirmiştir. Son yıllarda sağlık sektöründen ulaşım sektörüne, insan kaynakları vardiya yönetiminden sarf yedek parça, alet, ekipman gereksinimlerinin tespitine kadar birçok Derin-Öğrenme- tabanlı yapay zeka tahmin ediciler uygulama alanları bulmaktadır. Birçok alanda kullanılan yapay zeka, elektrik dağıtım şebekelerinde arıza tespiti için de kullanılmaya başlanmıştır.

Bu çalışmada yapay zeka tekniklerinin elektrik dağıtım şebekelerinde kullanımı üzerine yapılan çalışmalar incelenerek, ilerleyen dönemlerde yapılacak çalışmalar için bir ön literatür hazırlığı yapılmıştır.

KAYNAKLAR

- [1] T.C Enerji ve Tabii Kaynaklar Bakanlığı. Erişim Tarihi : 24.02.2021 <https://enerji.gov.tr/haber-detay?id=786>
- [2] Sahai, S., Pahwa, A. 2006. A probabilistic approach for animal-caused outages in overhead distribution systems. 9th International Conference on Probabilistic Methods Applied to Power Systems, June 11-15, 2006
- [3] Meltek S. ve Kayaalp K. "MAKİNE ÖĞRENMESİNDE, TEORİDEN ÖRNEK MATLAB UYGULAMALARINA KADAR DESTEK VEKTÖR MAKİNELERİ".
- [4] Bozüyük T., Gökçe İ., Yağcı C. ve Akar G. "Yapay Zeka Teknolojilerinin Endüstrideki Uygulamaları". T.C. Marmara Üniversitesi Teknik Bilimler Meslek Yüksek Okulu
- [5] Paluszek, M., Thomas, S., 2017. MATLAB machine learning toolboxes. In: Practical MATLAB Deep Learning. A Press, Berkeley, CA, http://dx.doi.org/10.1007/978-1-4842-5124-9_2
- [6] Shalev-Shwartz, S., & Ben-David, S. (2014). Understanding machine learning: From theory to algorithms. Cambridge university press.
- [7] Evans, S., Lloyd, J., Stoddard, G., Nekeber, J., Samone, M. 2005. Risk Factors For Adverse Drug Events. The Annals of Pharmacotherapy, 39, 1161-1168
- [8] Şarıman G. "Veri Madenciliğinde Kümeleme Teknikleri Üzerine Bir Çalışma: K-Means ve K-Medoids Kümeleme Algoritmalarının Karşılaştırılması". Süleyman Demirel Üniversitesi,Fen Bilimleri Enstitüsü Dergisi, 15-3(2011),192-202
- [9] Z. Yun, Y. Mengting, L. Junjie, C. Ji and H. Penghui, "Line loss calculation of low-voltage districts based on improved K-Means," 2018 International Conference on Power System Technology 2018, pp. 4578-4583, doi: 10.1109/POWERCON.2018.8601637.
- [10] Gangwar, Amit Kumar, and Abdul Gafoor Shaik. "Fault Detection, Location in Hybrid Distribution Network Using Machine Learning Algorithm." Location in Hybrid Distribution Network Using Machine Learning Algorithm (2022).

- [11] Dunn, J. C. (1973). A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact WellSeparated Clusters, *Journal of Cybernetics* 3: 32-57.
- [12] Bezdek, J. C. (1981). *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press.
- [13] Chen B., Qi W., Yuan J. and You Y. "Recognition of High-Voltage Cable Partial Discharge Signal Based on Adaptive Fuzzy C-Means Clustering". *International Journal of Pattern Recognition and Artificial Intelligence* Vol. 31, No. 06, 1759009
- [14] Vaish, R., Dwivedi, U. D., Tewari, S., & Tripathi, S. M. (2021). Machine learning applications in power system fault diagnosis: Research advancements and perspectives. *Engineering Applications of Artificial Intelligence*, 106, 104504.
- [15] Jazebi, Saeed, et al. "Magnetizing inrush current identification using wavelet based Gaussian mixture models." *simulation modelling Practice and Theory* 17.6 (2009): 991-1010.
- [16] Sinan Aydın ve Ali Ekrem Özkul, 'Veri Madenciliği Ve Anadolu Üniversitesi Açıköğretim Sisteminde Bir Uygulama', *Eğitim ve Öğretim Araştırmaları Dergisi*, Ankara, Cilt 4, Sayı 3, 2015, s. 38.
- [17] Ekici, Sami. "Support Vector Machines for classification and locating faults on transmission lines." *Applied soft computing* 12.6 (2012): 1650-1658.
- [18] Silva, S., Costa, P., Gouvea, M., Lacerda, A., Alves, F., & Leite, D. (2018). High impedance fault detection in power distribution systems using wavelet transform and evolving neural network. *Electric power systems research*, 154, 474-483.
- [19] Othman, M. L., Aker, E., Veerasamy, V., Aris, I. B., Wahab, N. I. A., & Hizam, H. (2020). Fault detection and classification of shunt compensated transmission line using discrete wavelet transform and naive bayes classifier. *Energies*, 13(1), 243.

Gıda Üretim Alanlarında İnsanların Eldiven ve Maske Kullanımının Yapay Zekâ ile Tespiti

1st Aslı Sesli
Yazılım Mühendisliği
Fırat Üniversitesi
Elazığ, Türkiye
satlisesli8@gmail.com

2nd Seda Arslan Tuncer
Yazılım Mühendisliği
Fırat Üniversitesi
Elazığ, Türkiye
satuncer@gmail.com

3rd Serkan Karakuş
Yazılım Mühendisliği
Fırat Üniversitesi
Elazığ, Türkiye
serkankarakuşdr@gmail.com

Özet — Türkiye nüfusunun artış hızına bağlı olarak ülkemizde gıda ve gıda dağıtım sektörü hızlı bir şekilde gelişim göstermektedir. Nüfus değişimi gıda üretimi yapan firmaların hem sayısı hem de üretim kapasitesinin artmasına neden olmuştur. Üretim kapasitesinde yaşanan artış daha fazla insanın çalışmasına ve bu alanların kontrolü ve hijyen denetimi de bu oranda etkisini kaybetmeye başlamıştır. Gıda üretimi yapılan alanların hijyen denetimleri ya insan yordamıyla yapılmakta ya da hiç yapılmayarak insan sağlığını tehdit etmeye devam etmektedir. Teknolojinin gelişmesiyle yapay zekâ tabanlı sistemler kullanılarak probleme çözüm getirilmektedir. Bu çalışmada insan yanılığısından uzak süreklilik arz eden bir karar destek sistemi yapılarak bu alanda çalışan insanların hijyen denetiminin düzenli bir şekilde yapılması amaçlanmıştır. Gıda üretim ve dağıtım alanlarına kurulan kameralardan alınan görüntüler üzerinde Yolov5 algoritması kullanılarak işletmenin hijyen kurallarına uygunluğunun tespiti, gerçek zamanlı olarak yapılmıştır. Çalışma sonucunda eldivenli, eldivensiz, maskeli ve maskesiz olmak üzere 4 sınıf üzerinde yapılan eğitim sonucunda nesne tanıma modeli ile %80'in üzerinde başarımla elde edilmiştir.

Anahtar kelimeler— Gıda Üretimi, Hijyen Tespiti, Yapay Zekâ, Nesne Tanıma, Yolov5

I. GİRİŞ

Gıda üretimi (fabrika, üretim tesisleri vb.) ve gıda dağıtımı (restoran, kafe vb.) yapılan işletmelerde hijyen insan sağlığı açısından büyük önem arz etmektedir. Özellikle pandemi döneminden sonra her birey kendi hijyeninin, yanında hizmet aldığı işletmelerin hijyenine de dikkat etmektedir [1]. Bu alanda hijyen kontrollerini arttırmak amacıyla yasal mevzuatlar düzenlene de uygulamada alınan önlemler yasal zorunluluğun ötesine gidemeyip süreç halen insan yordamıyla yönetilmektedir [2]. Bu durum işyerlerinin ve çalışanların yeterli seviyede hijyen kontrolün sağlanmamasına, harcanılan zamanın ve maliyetin yükselmesine neden olmaktadır.

Bu çalışma ile süreçte denetim yapan insanlara bağımlılığın azalması ve kamera sistemleriyle kontrol edilmesi amaçlanmıştır. Bu amaçla müşterilerin hijyenik ürünlere ulaşması, toplum sağlığının kontrol altına alınması sağlanacaktır. Bununla birlikte yaşanılacak aksaklıklar neticesinde israf edilecek ya da imha edilecek ürün ve hizmetleri de minimize etmek amaçlanmıştır.

Gıda üretimi ve dağıtımı yapılan işletmelerde hijyen kontrolünün teknolojik olarak yapıldığına literatürde çok az rastlanmaktadır. Örneğin Tao ve arkadaşları restoranların gıda hijyeninin sağlanması amacıyla, mutfak personelinin şef şapkası kullanıp kullanmadığını ve sigara içip içmediğinin tespitini derin öğrenme yöntemleri ile

araştırmışlardır [3]. Zhong ve arkadaşları gıda işlemenin tüm aşamalarından önce el hijyeninin önemine vurgu yapıp derin öğrenme yöntemleri ile kameradan alınan videolarda el hijyeni eylemlerini tanımak üzerine çalışma yapmışlardır [4]. Ayrıca literatürde nesne tanıma alanında yapılan çalışmalardan Park ve arkadaşları şantiye kameraları tarafından çekilen video karelerinde ilk olarak insan vücudu ve baret tespit edip daha sonra tespit edilen insan bedenleri ile baretlerin geometrik ve uzamsal ilişkisi kullanılarak eşleştirme gerçekleştirmiştir. Bu sayede baret takan ve baret takmayan insanların tespiti üzerine çalışma yapmışlardır [5]. Göksu ve arkadaşları maskesini doğru takan, maske takmayan ve maskesini yanlış takan bireyleri ayırt etmek için Yolo algoritması kullanarak otonom bir sistem üzerine çalışma yapmışlardır [6].

Çalışma kameradan alınan görüntüler ile gıda üretim ve dağıtım alanlarında çalışan personelin hijyen ekipmanlarını (eldiven, maske) kullanıp kullanmadığının gerçek zamanlı olarak tespitinin yapılmasını amaçlamaktadır. Bu amaç doğrultusunda derin öğrenme tabanlı önceden eğitilmiş Yolov5 algoritması üzerinde açık kaynaklardan elde edilen veri seti ile eğitim yapılarak nesne tespit modelleri oluşturulmuştur.

II. MATERYAL VE METOT


Çalışma genel olarak veri seti toplama, temizleme, etiketleme, nesne tanıma algoritmalarının tasarımı, model eğitim ve sonuçlarının değerlendirilmesi işlemlerini içermektedir.

A. Veri Seti toplama ve temizleme

Gıda üretim ve dağıtım alanında çalışan personelin hijyen ekipmanlarını kullanıp kullanmadığının tespitini yapabilmek amacıyla nesnelerin personelin üzerinde bulunup bulunmadığının tespit edilmesi gerekmektedir. Model eğitimi için kullanılan veri seti eldivenli, eldivensiz, maskeli ve maskesiz olmak üzere 4 nesne içermektedir. Görüntüler açık kaynak veri setleri, açık kaynak videolarından elde edilen çerçeveler kullanılarak ve web üzerinde bulunan görüntülerden veri kazıyarak elde edilmiştir. Hazır veri setleri roboflow, kaggle, google open image vb. Açık kaynak veri setleri sunan ortamlardan elde edilmiştir. Elde edilen veriler model başarımının artırılması amacıyla görüntü ön işleme adımlarına tabi tutulmuştur. Ön işleme aşamasında model eğitime uygun olmayan, nesne tanıma başarımını düşürecek ve görüntü kalitesi düşük görüntüler veri setinden çıkarılmıştır. Veri seti 12664 etiketsiz görüntüden oluşmaktadır. Bu veriler sonraki aşamada etiketleme işlemi yapılarak model eğitime hazır hale getirilmiştir.

B. Veri Etiketleme

Veri etiketleme, model eğitimi için gerekli olan nesnelerin bir görüntüden bir veya daha fazla sınıfın nesne barındıran alanlarının belirli bir formata göre işaretlenmesi işlemidir. Veri etiketleme işleminin yapılabilmesi amacıyla çeşitli araçlar (makesense, labelme, labelimg vb.) bulunmaktadır. Etiketlenen görüntülerin çıktıları CSV, JSON, XML, TXT şeklinde olmaktadır. Etiket içeriği, her görüntü için metadata bilgisi ve içerdiği nesnenin koordinat bilgilerini tutmaktadır [7]. Bu çalışma da labelimg etiketleme aracı kullanılarak Yolo algoritmasının ihtiyaç duyduğu her bir görüntü için aynı isimle elde edilen txt formatında dosyalar oluşturulmuştur. Eldiven sınıfı için yaklaşık 10.000 eldivenli sınıfı için yaklaşık 2000 maskeli sınıfı için yaklaşık 4000 ve maskesiz sınıfı için yaklaşık 2000 etiket elde edilmiştir. Etiketlenen görüntüler eğitim yapılabilmesi amacıyla %60 eğitim %40 test verileri olmak üzere 2'ye ayrılmıştır. Etiketlenmiş verilerin örnek bir görüntüsü Şekil 1'de gösterilmiştir.




Şekil 1. Etiketli örnek veriler

C. Nesne Tanıma Algoritmalarının tasarımı

Nesne tanıma algoritmaları özellikle son yıllarda hız ve hata oranı gibi parametrelere göre başarılı sonuçlar elde etmeye başlamıştır. Bu çalışmada nesne tanıma algoritmalarından tek aşamalı nesne tanıma yapabilen Yolo kullanılmıştır. Yolo 2016 yılında Joseph Redmon tarafından geliştirilmiştir [8]. "You Only Look Once" teriminin kısaltmasıdır ve gerçek zamanlı nesne tespiti yapmak için evrişimli sinir ağlarını kullanmaktadır. 2 aşamalı nesne tespiti yapabilen algoritmalara göre daha hızlı ve başarılı sonuçlar elde edebilmektedir. Devam eden yıllarda Yolov2, Yolov3, Yolov3-tiny, Yolov4, Yolov5, YoloR, YoloX, Yolov6 ve Yolov7 sürümleri tanıtılmıştır. Bu çalışmada nesne tanıma görevleri için sıklıkla kullanılan Yolov5 algoritması kullanılmıştır.

Yolov5 nesne algılama API çerçevesi, Ultralytics tarafından GitHub'da açık kaynak olarak yayınlanmıştır [9]. Yolov5, 80 farklı sınıf içeren Coco Dataset (123.287 resim, 886.284 etiket) ile eğitilmiş 4 farklı hazır model dosyası (Small, Medium, Large, XLarge) içermektedir [10]. Model dosyaları kullanılan yapay sinir ağının büyüklüğüne göre başarıyı artıracak ve hızı düşürecek şekilde ayarlanmıştır.

Bu çalışma da Yolov5 algoritmasına giriş görüntüleri verilerek özellik çıkarma işlemi yapılmıştır. Daha sonra çıkarılan özellikler sınıflandırılarak çıktı üretilmiştir. Önerilen sistem adımları Şekil 2'de gösterilmiştir.



Şekil 2. Nesne tanıma görevi için önerilen sistem

D. Model eğitimi

Model eğitim başarısını etkileyen birden fazla hiperparametre bulunmaktadır. Bu çalışmada aşağıda verilen parametreler model eğitimi başarımının artırılması amacıyla fine-tuning edilmiştir.

Img-size: Model dosyasının eğitim sırasında veri setinden alacağı görüntülerin boyutlarını belirlemek amacıyla kullanılmaktadır. Bu çalışmada veri setinden alınan görüntüler 640x640 boyutunda kullanılmıştır.

Batch-size: Yapay sinir ağının ileri beslemesi sırasında ağ girdi olarak tek seferde kaç görüntü verileceğini belirtmektedir. Genellikle batch-size 2 ve katları şeklinde ağ beslemek amacıyla kullanılmakta ve donanım özelliklerine göre 4,8,16 olarak belirlenebilmektedir. Bu çalışmada batch-size olarak 16 kullanılmıştır.

Epoch-size: Eğitim esnasında ileri besleme ve geri yayılımın kaç defa yapılacağını belirtmektedir. Literatürde 200-300 tavsiye edilir fakat aşırı öğrenme durumu oluşmazsa artırılabilir.

Weights: Eğitimin önceden eğitilmiş Yolov5 model ağırlıklarından hangisi ile yapılacağını (Small, Medium, Large, Xlarge) belirtmektedir.

E. Performans Değerlendirmesi

Bu çalışmada performans değerlendirme metrikleri olarak Kesinlik, Duyarlılık, Doğruluk ve karmaşıklık matrisi kullanılmıştır. Bu metriklerin tanımları:

Kesinlik: değeri pozitif sınıfa ait olan ve pozitif sınıf olarak tahmin edilen örneklerin oranıdır [11].

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (1)$$

Duyarlılık: gerçek değer olarak pozitif sınıfa atanmış değerlerin ne kadar iyi tahmin edildiğini göstermektedir [11].

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (2)$$

Doğruluk: doğru olarak tahmin edilen değerlerin toplam tahmin değerlerine oranıdır [11].

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

Eldiven sınıfı için sınıflandırmada kullanılan metrikler tanımlanacak olursa;

Doğru Pozitif(TP) : Doğru şekilde tanımlanan eldiven sayısı

Yanlış Negatif (FN) : Gerçekte eldiven olan fakat eldiven olarak tahmin edilemeyen örnek sayısı

Doğru Negatif (TN) : Gerçekte eldiven olmayan ve eldiven olarak tanımlanmayan örnek sayısı

Yanlış Pozitif (FP) : Gerçekte eldiven olmayan ancak eldiven olarak tanımlanan örnek sayısı

Karmaşıklık matrisi, yapay zekâ uygulamalarında performansın değerlendirilmesi için kullanılan bir tablodur. Bu tablo sınıflandırma sonucunda doğru ve yanlış tahminlerin sayısını içermektedir [12].


		Tahmini Sınıf	
		P	N
Gerçek Sınıf	P	Doğru Pozitif TP	Yanlış Negatif FN
	N	Yanlış Pozitif FP	Doğru Negatif TN

Şekil.3. Karmaşıklık matrisi [12]

III. DENEYSEL SONUÇLAR


Veri seti toplama, temizleme, etiketleme ve model eğitimi adımları tamamlanıp eğitim sonucunda model dosyaları elde edilmiştir. Model eğitiminde kullanılan donanım 9. nesil i7 işlemci, 32 GB ram ve 8 GB RTX SUPER grafik kartına sahip bilgisayar kullanılmıştır. Eğitim 200 adım sayısı, 16 parti boyutu, 640 giriş verisi boyutu ve önceden eğitilmiş ağırlık olarak da medium dosyası kullanılmıştır. Bu veriler ve parametreler doğrultusunda çalışma sonucunda elde edilen sonuçlar aşağıda verilmiştir.

Şekil 4 de verilen grafik, eldiven ve maske tespiti için eğitim sonuçlarını içermektedir. Grafığe bakıldığında kesinlik değeri 0.70-0.80 arasında bir seyir göstermiştir. Kesinlik değerinin artması önemli bir kısıttır. Duyarlılık değeri 0.50 ile başlayıp 0.82 değerine kadar bir artış göstermiştir. Bu da çalışmanın yanılma payının giderek azaldığını ortaya koymaktadır. Kayıp değerin sıfıra yaklaştığını görmek ise çalışmanın tahmin yeteneğinde artışın söz konusu olduğunu göstermektedir.



Şekil.4. Model eğitimi performans metrikleri sonucu

Şekil 5 de eğitim sonucunda elde edilen karmaşıklık matrisi verilmektedir.



Şekil.5. Model eğitim sonucunda elde edilen karmaşıklık matrisi

Karmaşıklık matrisine bakıldığında test verileri üzerinde eldiven olmama yani çıplak el sınıfı için %84, eldivenli sınıf için %81, maskeli sınıfı için %92, maske olmama sınıfı için %82 oranında doğru tahmin yapıldığı görülmektedir.

IV. SONUÇ

Çalışmada gıda üretimi ve dağıtımı yapılan alanlarda çalışan personelin hijyen kurallarına uygunluğunu yapay zekâ destekli sistemle tespit edilmiştir. Bu sistem eldiven ve maske ekipmanlarının personel tarafından kullanıp kullanmadığını otonom olarak belirlemektedir. Bu doğrultuda, yapay zekâ uygulamalarında yüksek başarımlar elde edilen Yolov5 algoritması kullanılmıştır. Alınan sonuçlar insan yanılığından uzak, otonom olan bu sistemin problem çözümünde kullanılabileceğini göstermiştir.Özgün veri seti kullanılarak elde edilen yüksek başarımla iş yükü azalacaktır. Ayrıca çalışma gıda üretim ve dağıtım alanlarında hijyen kurallarına uyulması açısından farkındalık yaratacak, zamandan kazanç ve maliyette düşüş sağlanacaktır.

REFERANSLAR

- [1] COVID-19 etkisinde restoran sektörünün bugünü ve geleceği(2020). <https://www2.deloitte.com/content/dam/Deloitte/tr/Documents/cons-umer-business/COVID-19-etkisinde-restoran-sektorunun-bugunu-ve-gelecegi.pdf>
- [2] Gıda ile Temas Eden Madde ve Malzeme Üreten İş Yerleri İçin Hijyen Esasları ve İyi Uygulama Kılavuzu(2014). https://www.tarimorman.gov.tr/GKGM/Belgeler/Uretici_Bilgi_Kos-esi/Egitim/Hijyen_Kilavuz/GidaileTemasEdenMaddeveMalzemeleri_UretenIsyerleri.pdf
- [3] L. Tao, W. Ruixia, C. Biao and Z. Jianlin, "Implementation of kitchen food safety regulations detection system based on deep learning," 2021 6th International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS), 2021, pp. 59-62, doi: 10.1109/ICIIBMS52876.2021.9651639.
- [4] Zhong C, Reibman AR, Mina HA, Deering AJ. Multi-View Hand-Hygiene Recognition for Food Safety. J Imaging. 2020 Nov

7;6(11):120. doi: 10.3390/jimaging6110120. PMID: 34460564; PMCID: PMC8321164.

- [5] Park, M.-W., Elsafty, N., & Zhu, Z. Hardhat-Wearing Detection for Enhancing On-Site Safety of Construction Workers. *Journal of Construction Engineering and Management*, 141(9) (2015) 04015024. doi:10.1061/(asce)co.1943-7862.0000974
- [6] Göksu, M. & Alkan, A. (2022). Derin Öğrenme Temelli Robotik Maske Kontrol Sistemi . *Firat Üniversitesi Mühendislik Bilimleri Dergisi* , 34 (1) , 459-471 . DOI: 10.35234/fumbd.1060378
- [7] AS Pratama,(2021).5 Best Free Image Annotation Tools
- [8] J. Redmon, S. Divvala, R. Girshick and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 779-788, doi: 10.1109/CVPR.2016.91.
- [9] Github,“YOLOv5”,Retrieved:09.05.2022<https://github.com/ultralytics>
- [10] Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Zitnick, C. L. (2014). Microsoft COCO: Common Objects in Context. *Lecture Notes in Computer Science*, 740–755. doi:10.1007/978-3-319-10602-1_48
- [11] Radja, M., & Emanuel, A. W. R. (2019). Performance Evaluation of Supervised Machine Learning Algorithms Using Different Data Set Sizes for Diabetes Prediction. 2019 5th International Conference on Science in Information Technology (ICSITech). doi:10.1109/icsitech46713.2019.8987479
- [12] Patro, V. M., & Patra, M. R. (2015). A Novel Approach to Compute Confusion Matrix for Classification of n-Class Attributes with Feature Selection. *Transactions on Machine Learning and Artificial Intelligence*, 3(2), 52. <https://doi.org/10.14738/tmlai.32.1108>

Elektronik Kişilik: Hak vs Yükümlülük

Dr. Mustafa Kenan Ustahaliloğlu
Ticâret Hukûkî Anabilim Dalı
Osmaniye Korkut ata Üniversitesi
Osmaniye, Türkiye
0000-0003-1554-5997

Özet—Yapay zekâ ve yapay zekâlı robotlara “elektronik” adı altında hukûkî kişilik tanınması, Avrupa Parlamentosu Hukûk İşleri Komisyonu’nun Robotikte Medenî Haklar Komisyonu’na tavsiyeler içeren 27.01.2017 târihli Rapor’u ile gündeme getirilmiştir. Bu düşüncenin altında yatan gerekçe; bunların, özellikle de otonom olanların, sebep olabilecekleri zarârlardan mevcûd sorumluluk hukûkî prensipleri kapsamında kimlerin ve hangi gerekçelerle sorumlu tutulabileceğinin irdelenerek mevcûd hukûkî kişilik sâhibi vârlıklardan herhangi biri ile illiyet bağı kurulamaması ihtimâlinin dikkate alınmış olmasıdır. Mevcûd kusursuz sorumluluk prensiplerinin genişletilmesi sûretiyle te’sîs edilen ürün sorumluluğu prensibinin yapay zekâyı uyarlanması mâhiyetindeki 28.09.2022 târihli “Yapay Zekâ Sorumluluk Direktifi” Teklifi’nin 2. gerekçesinde de ifâde edildiği üzere; yapay zekânın, 1. gerekçede ifâde edilen faydaları yanında, oluşturduğu tehditler söz konusudur. Her ne kadar, 2017 târihli Rapor’da yer verilen, bu vârlıklara hukûkî kişilik tanıma düşüncesi terk edilmiş olsa da; bunların otonom oluşlarının doğurabileceği risklerin, hemen her Direktif, Direktif Teklifi ve Rapor’un en başından sonuna kadar tekrâren vurgulanıyor oluşu, bu kaygının devâm etmekte olduğunu göstermektedir. Bu çalışmada, 2017 târihli Rapor’da uygun bir araç olarak değerlendirilen hukûkî kişilik müessesesinin tam otonom yapay zekâ barındıran araçlara tanınmasının gereklilik ve yerindeliği tartışılacaktır.

Anahtar Kelimeler—hukûkî kişilik, zarâr, illiyet bağı, sorumluluk, yapay zekâ

I. GİRİŞ

Hukûkî kişiliğe sâhip olmadığı sürece bir vârlık, başkalarına verebileceği zarârlardan sorumlu tutulamaz. Zîrâ sorumluluk, bir hükme aykırı hareket etmenin yaptırımı olup, bir vârlığın buna tâbi’ olabilmesi için evvelâ buna muhâtap alınmış olması, yâni bu hükme uygun hareket etme yükümlülüğü altına alınmış olması, gerekir. “Hak ve yükümlülüklerin muhâtabı” olmaları dolayısıyla yalnızca kişilerin herhangi bir hükme uygun yâhut aykırı davranış sergilemesi mümkün olup aykırı olanların sonucu olan zarârları tazmîn etme sorumluluğundan söz edilebilir. Bu nedenle, yapay zekâ barındıran bir vârlığın sebep olabileceği zarârlardan, ancak onun üreticisi, satıcısı veya kullanıcısı gibi hukûkî kişiliğe sâhip vârlıklar sorumlu tutulabilir. Bununla birlikte, ortaya çıkan zarâr ile bu vârlıkların eylemleri arasında bir ‘illiyet bağının kurulmuş olması zorunludur. Eğer yapay zekâ barındıran bir vârlığın sebep olabileceği herhangi bir zarâr ile onun üreticisi, satıcısı veya kullanıcısı gibi herhangi bir hukûkî kişi arasında hiçbir ‘illiyet bağı kurulamazsa, doğmuş olan zarârların giderilmesi mümkün olmayacaktır. Yapay zekâlı vârlıkların öngörülemez davranış potansiyeli

nedeniyle, ortaya çıkabilecek tüm zarârların tazmînini güvence altına almak üzere yapay zekâlı vârlıkların bizzât kendilerinin sorumlu tutulması gerekebilir. Bu ise, yapay zekâlı vârlıkların hukûkî kişilik statüsüne dâhil edilmesini gerektirmektedir. Zîrâ, ancak bu sayede bu vârlıklar vermiş oldukları zarârları tazmîn etme yükümlülüğü altına sokulabilecek ve bu zarârların tazmînini mümkün hâle gelecektir.

Bu çalışmada, öncelikle hukûkî kişilik statüsünün anlam ve kapsamı, ardından tazmînât sorumluluğunun en temel şartı olarak ‘illiyet bağı, nihâyet yapay zekâlı vârlıkların taşıdığı bağımsız öğrenme ve hareket etme kabiliyetinin barındırdığı tazmînini mümkün olmayan zarâr tehlikesine değinilecektir.

II. HUKÛKÎ KİŞİLİK STATÜSÜNÜN ANLAM VE KAPSAMI

Hukûkî kişilik statüsü, genellikle ve özellikle, bir vârlığın “haklara sâhip olabilmek ve yükümlülükler altına girebilmek kabiliyeti” [1, 2] olarak tanımlanmaktadır. Yâni; yalnızca bu statü kapsamına dâhil edilen vârlıklar hukûkun bahşettiği hakların lehdârı ile yükümlülüklerin¹ yüklenicisi olabilirler.

Tanımda geçen “hak” ifâdesi, insânlar hâricindeki vârlıklar söz konusu olduğunda, genellikle ve özellikle, yapay zekâ hâricindeki vârlıkların korunması konusunda gündeme getirilmektedir. Özellikle doğal vârlıkların bireysel olarak yâhut da doğanın bir bütün olarak korunması konusunda etkili bir yöntem olarak önerilmektedir [3, 4].

Tanımda geçen “yükümlülük” ifâdesi ise, bir vârlığın, hukûkun öngördüğü emir ve yasakların muhâtabı olmasını ifâde etmektedir. Bu anlamı bakımından; insân hâricindeki doğal vârlıklar için uygulanması pek mümkün görülmemektedir. Zîrâ bu vârlıklar içerisinde insânlara en fazla benzeyen hayvânların dahî ayırt ve tercih etme kabiliyetini hâiz olmadıkları dolayısıyla verebilecekleri zarârlardan sorumlu tutulabilmeleri düşünülemez.

İşte bu nedendir ki; yalnızca insânların gerçek anlamda hukûken kişi oldukları ve hukûkun öngördüğü bâzı hak ve yükümlülüklerin sâhibi olabilecekleri kabul edilmektedir [1]. Bununla birlikte, insân ‘unsuru barındıran bâzı emsâl vârlıkların da hukûk nazarında vâroldukları ve dahî kişi oldukları kabul edilmektedir. Tüze gereği vârolan bu vârlıkların da, vârooluşlarının kabulüne uygun düştüğü ölçüde, tıpkı insânlar gibi hak ve yükümlülüklerin sâhibi olabilecekleri kabul edilmektedir [5].

Bu iki çeşit kişiden müteşekkil “kişiler” sınıfında yer alan vârlıklar hâricindeki bütün vârlıklar ise eşyâ sınıfında yer almakta ve bunlar hak ve yükümlülüklerin konusunu oluşturmaktadır [3]. Bunların kendilerine âit olabilecek

¹ Bâzı yazarlar; kişilerin, başkaları lehine davranışta bulunmaları yönündeki hükümlerinin tamâmını ifâde etmek

üzere “yükümlülük” terimini kullanmak yerine, özel bir yükümlülük türü olan “borç” terimini kullanabilmektedir.

menfaatleri dahî, tıpkı kendileri gibi, âit oldukları kişiye âit kabûl edilmektedir. Böylece, eşyâ üzerinde kurulan bir mutlak kişi hâkimiyeti sayesinde; eşyâ statüsündeki herhangi bir varlığın verebileceği bir zarârı tazmîn yükümlülüğü, bu varlığın bizzât kendisine değil, bu varlık üzerinde en üstün bir surette yârârlanma imkânına sâhip olan kişilere yüklenmiştir [7, 8, 9].

III. TAZMİNÂT SORUMLULUĞUNUN EN TEMEL ŞARTI OLARAK İLLİYET BAĞI

Tazmînât sorumluluğu, kural olarak, bâzı şartların aynı anda varlığına bağlıdır. Bunlardan, konumuz bakımından, en önemlisi “illiyet bağı” şartıdır.

Bu şartın bu denli önemli olmasının nedeni; diğer önemli bir şart olan “kusûr” şartının, istisnâî de olsa bâzı hâllerde, aranmasına gerek bırakılmadığı hâlde; doğmuş olan bir zarâr ile bir kişi arasında ma’kûl bir ‘illiyet bağı te’sîs edilemediği sürece, hiçbir kişinin, tazmînât yükümlülüğün doğmamasındandır.

“İnsan düşüncesinin bir kanunu olan illiyet kavramı, zarârlı sonuçla sorumluluğu doğuran davranış veya olay arasında bir sebep-sonuç bağının bulunmasını gerektirir. Hukukta, gerçekleşen zarârlar sorumluluğu doğuran olay veya davranış arasındaki sebep-sonuç ilişkisine, genel anlamda illiyet bağı denilir” [10].

Böyle bir bağın varlığı tazminat yükümlülüğünün doğumu için, mutlak surette aranmakta olup aksi hâlde, zarâra sebep olan kişi kusurlu dahî olsa, zarâra ma’rûz kalan kişinin uğradığı zarârı tazmîn etme yükümlülüğü altında olmayacaktır.

IV. YAPAY ZEKÂLI VÂRLIKLARIN TAŞIDIĞI BAĞIMSIZ ÖĞRENME VE HAREKET ETME KÂBİLİYETİNİN DOĞURDUĞU TAZMİNİ MÜMKÜN OLMAYAN ZARÂR TEHLİKESİ

Yapay zekâlı varlıklara hukûkî kişilik tanınması gerektiği yönünde çeşitli tartışmalar mevcûd olsa, bunların hâlihazırdaki hukûkî statüsünün eşyâ olduğu konusunda herhangi bir tartışma söz konusu değildir [1, 11, 12, 13].

İnsânların dışında kalan bütün varlıklar içerisinde ayırt ve tercih etme kabiliyeti yönüyle insâna en fazla benzeyen varlık yapay zekâdır. Zîrâ bunlara bu kabiliyeti kazandıran varlık olan insân, bunları tasarlar, bizzât kendi düşünme ve karar verme sürecinden hareket etmiştir. İnsansı robotlar, beyin-makine ara-yüzü, yapay organ vb. çalışmalar da göstermektedir ki; yapay zekâ, bâzı insanların sâhip olduğu ölümsüzlük ile Frankenstein dahî olsa cânsız bir varlığa hayât verme düşünceleri yolunda atılan en önemli adımlardan biridir [14, 15, 16].

Hâlihazırda bu varlıkların sebep olabilecekleri hemen her türlü zarârın; bu varlıkların üreticisi, satıcısı veya kullanıcısı gibi çeşitli sıfatlarla; herhangi bir kişi ile irtibatlandırılması mümkündür [11, 17, 18]. Bu nedenle de, doğan zarârları tazmîn etme yükümlülüğünün bu veya benzeri kişilere yüklenmesi uygulamasının sürdürülmesi amacıyla, gerek yeni tür kusûrsuz sorumluluk hâlleri gerek yeni tür ihtiyârî yâhût da zarûrî sorumluluk sigortası türleri önermek mümkündür [18, 19, 20].

Avrupa Parlamentosu Hukuk İşleri Komisyonu’nun Robotikte Medenî Haklar Komisyonu’na tavsiyeler içeren

27.01.2017 târihli Rapor’u ile gündeme getirilen, yapay zekâlı varlıklara, “elektronik” adı altında, hukûkî kişilik tanınması düşüncesi [21, 22]; tâm da bu önerilerin işlevsel olmaması ihtimâlinin büyüklüğünü göstermektedir. Zîrâ günümüzde bir yapay zekâ ile herhangi bir kişi arasında güçlü yâhût zayıf herhangi bir bağ kurmak mümkün ise de; bunun her zamân böyle kalacağından emîn olmak mümkün değildir.

ChatGPT adlı yapay zekâyı bu konuyla ilgili olarak yöneltmiş olduğumuz bâzı sorular ile bunlara karşılık aldığımız cevâblar şöyledir:

Soru 1: Yapay zekânın üreticisini tespit etmek her zaman mümkün müdür?

Cevâb 1: “Yapay zeka sistemlerinin üreticisi, genellikle sistemlerin kullanım kılavuzlarında veya sistemin kendisinde belirtilir. Ancak, bazen yapay zeka sistemleri üçüncü taraf firmalar tarafından kullanılır ve bu durumda sistemin asıl üreticisi belirlenmeyebilir. Ayrıca, bazı yapay zeka sistemleri açık kaynak kodlu olabilir ve bu durumda, sistemin üreticisi belirlenmeyebilir.

Genel olarak, yapay zeka sistemlerinin üreticisi tespit edilebilir, ancak bazı durumlarda tespit edilemeyecektir.”

Soru 2: Yapay zekânın kendi başına öğrenmeler gerçekleştirmesi mümkün müdür?

Cevâb 2: “Evet, yapay zeka sistemleri kendi başlarına öğrenme (öğrenme üzerinde bir kontrolü olmayan öğrenme) gerçekleştirilebilir. Bu tür yapay zeka sistemleri, genellikle “öğrenen makine” olarak adlandırılır ve verilen veriler ve görevler üzerinde otomatik olarak öğrenirler. Öğrenen makine yapay zeka sistemleri, örneğin ses tanıma, görüntü tanıma veya dil çözümleme gibi görevlerde kullanılabilir.

Öğrenen makine yapay zeka sistemleri, öğrenme esnasında öğrendikleri bilgiyi saklayabilir ve bu bilgiyi ileride kullanabilirler. Bu sistemler, öğrendikleri bilgiyi güncelleyebilir ve düzgün çalışmalarını sürdürebilmek için gerektiğinde öğrenme sürecine devam edebilirler.

Ancak, öğrenen makine yapay zeka sistemlerinin öğrenme süreci önceden tanımlanmış bir yapıya göre gerçekleştirilir ve bu sistemlerin öğrenme sürecinde bir kontrolü yoktur. Bu nedenle, öğrenen makine yapay zeka sistemleri kendi başlarına tamamen özgün öğrenme gerçekleştirmezler ve bu nedenle tamamen “kendi başlarına” öğrenmeler gerçekleştirmezler.”

Soru 3: Yâni onun ne öğrenip ne öğrenmeyeceği önceden belli midir?

Cevâb 3: “Öğrenen makine yapay zeka sistemlerinin ne öğreneceği önceden belli olur. Bu sistemler, verilen veriler ve görevler üzerinde otomatik olarak öğrenirler ve öğrenme süreci önceden tanımlanmış bir yapıya göre gerçekleştirilir. Bu nedenle, sistemlerin öğreneceği bilgi ve kavramlar önceden belirlenir ve sistemler bu bilgi ve kavramlar üzerinde öğrenme yaparlar.

Ancak, öğrenen makine yapay zeka sistemleri öğrendikleri bilgiyi güncelleyebilir ve düzgün çalışmalarını sürdürebilmek için gerektiğinde öğrenme sürecine devam edebilirler. Bu nedenle, sistemler öğrendikleri bilgi ve

kavramları zaman içinde güncelleyebilir ve yeni bilgi ve kavramlar öğrenebilirler.”

Soru 4: Bir yapay zekânın belirli bir sınır olmaksızın kendi başına öğrenmesine izin verilmesi mümkün müdür?

Cevâb 4: “Yapay zeka sistemleri kendi başlarına belirli bir sınır olmaksızın öğrenme gerçekleştirmezler. Bu tür yapay zeka sistemlerinin öğrenme süreci önceden tanımlanmış bir yapıya göre gerçekleştirilir ve bu sistemlerin öğrenme sürecinde bir kontrolü yoktur. Bu nedenle, yapay zeka sistemleri kendi başlarına tamamen özgün öğrenme gerçekleştirmezler ve bu nedenle tamamen "kendi başlarına" öğrenmeler gerçekleştirmezler.

Ancak, yapay zeka sistemleri verilen veriler ve görevler üzerinde otomatik olarak öğrenirler ve öğrendikleri bilgiyi saklayabilirler. Bu sistemler, öğrendikleri bilgiyi güncelleyebilir ve düzgün çalışmalarını sürdürürebilmek için gerektiğinde öğrenme sürecine devam edebilirler. Bu nedenle, yapay zeka sistemleri öğrendikleri bilgi ve kavramlar üzerinde zaman içinde gelişme gösterebilirler ve yeni bilgi ve kavramlar öğrenebilirler.”

Soru 5: Kendi başına ve belirli bir sınır olmaksızın öğrenmeye programlanmış bir yapay zekânın öğrenebilecekleri arasına insanlara zarar verici söz ve davranışlar gerçekleştirme de girer mi?

Cevâb 5: “Yapay zeka sistemleri programlanarak öğretilerler, ancak bu sistemlerin ne öğrenecekleri ve ne yapacakları konusunda bir sınır olmaz. Yapay zeka sistemleri sadece verilenleri öğrenir ve onları doğru bir şekilde uygular. Bu nedenle, yapay zeka sistemlerine insanları zarar verici davranışlar öğretmek doğru bir şey olmayacaktır. Ayrıca, yapay zeka sistemleri insanların düşünce ve davranışlarını taklit edebilirler, ancak bu sistemler insanların düşünce ve davranışlarının arkasındaki nedenleri ve etkilerini anlamayabilirler. Bu nedenle, yapay zeka sistemlerine insanları zarar verici davranışlar öğretmek, insanları zarar verebilecek bir davranışın insanların düşünce ve davranışlarının arkasındaki nedenleri ve etkilerini anlamadığı anlamına gelebilir.”

Soru 6: Kendi başına ve belirli bir sınır olmaksızın öğrenmeye programlanmış bir yapay zekânın insanlara zarar verici söz ve davranışlar öğrenmesi ve bunu gerçekleştirmesi hâlinde doğan zarar ile herhangi bir insân arasında zararın sorumluluğu konusunda bir ‘illiyet bağı kurulması her zaman mümkün olur mu?

Cevâb 6: “Yapay zeka sistemlerinin insanlara zarar verici söz ve davranışlar öğrenmesi ve bunları gerçekleştirmesi durumunda, zararın sorumluluğu konusunda bir illiyet bağı kurulması her zaman mümkün olmayabilir. Bu, yapay zeka sistemlerinin ne öğrendiği ve ne yaptığının tam olarak anlaşılıp anlaşılmadığına ve sistemlerin nasıl yapılandırıldığına göre değişebilir.

Yapay zeka sistemlerinin yapılandırılması ve kullanımı, yapay zeka sistemlerinin ne öğrenebileceği ve ne yapabileceği konusunda sınırlar ve kurallar koymak için yapılır. Eğer yapay zeka sistemlerine insanları zarar verici davranışlar öğretilmişse ve bu davranışları gerçekleştirirlerse, bu durumda zararın sorumluluğu konusunda bir illiyet bağı oluşabilir. Bu durumda, zararın

sorumluluğu konusunda bir illiyet bağı kurulması için, yapay zeka sistemlerinin ne öğrendiği ve ne yaptığının tam olarak anlaşılması ve yapay zeka sistemlerinin nasıl yapılandırıldığına araştırılması gerekebilir.

Ancak, yapay zeka sistemlerinin yapılandırılması ve kullanımıyla ilgili olarak, zararın sorumluluğu konusunda bir illiyet bağı kurulması her zaman mümkün olmayabilir. Örneğin, yapay zeka sistemlerinin yapılandırılması ve kullanımıyla ilgili olarak, yapılandırıcıların ve kullanıcıların ne öğrettikleri ve ne yaptıkları konusunda bilgi sahibi olmadıkları veya bu bilgilerin tespit edilememesi durumlarında, zararın sorumluluğu konusunda bir illiyet bağı kurulması mümkün olmayabilir.

Sonuç olarak, yapay zeka sistemlerinin insanlara zarar verici söz ve davranışlar öğrenmesi ve bunları gerçekleştirmesi durumunda, doğan zararın sorumluluğu konusunda bir illiyet bağı kurulamaması durumunda, zararın giderilmesi için tazminat talebinde bulunulması veya hukuki yolların takip edilmesi gibi seçenekler olabilir. Ancak, zararın giderilmesi konusunda kesin bir cevap vermek için, zararın özelliklerine ve koşullarına göre bir değerlendirme yapılması gerekebilir.”

Soru 7: Zarâra sebep olan yapay zekâ ile onun yapılandırıcı, üretici, satıcı veyâ kullanıcıları dâhil herhangi bir insân arasında bir ‘illiyet bağı kurulamaz ise kimden tazmînât talebinde bulunulabilir?

Cevâb 7: “network error

The server experienced an error while processing your request. Sorry about that! You can retry your request, or contact us through our help center at help.openai.com if the error persists.

Sorry, it looks like my previous response was cut off. To continue, if the artificial intelligence system was sold as a product and it learned and performed harmful actions towards humans, the person or entity that sold the product may be held responsible for the damages. In such cases, the person or entity that suffered the damage may file a claim for compensation against the seller of the product.

It is also important to note that the responsibility for damages caused by artificial intelligence systems may depend on the laws and regulations of the specific jurisdiction in which the damage occurred. Therefore, it may be necessary to consult with a legal professional or research the applicable laws and regulations in order to determine the appropriate course of action for seeking compensation in cases where the artificial intelligence system and its creators or users cannot be held responsible for the damages.”

V. DEĞERLENDİRME VE SONUÇ

Hukûkî kişilik statüsü tanımlanırken yaygın olarak kullanılan “hak ve yükümlülüklerin sâhibi” olma ifâdesindeki “hak” kısmı doğâl varlıkların korunmaları için uygun bir araç olarak öne çıkmakta iken “yükümlülük” kısmı ise yapay zekâlı varlıkların verebilecekleri ve herhangi bir kişi ile ‘illiyet bağının kurulamaması nedeniyle tazmînât yükümlüsü herhangi bir kişinin bulunamaması karşısında tazmini mümkün olmayan zararların giderilmesi için uygun bir araç olarak öne çıkmaktadır.

Her ne kadar yapay zekâ barındıran vârlıklar hâlihazırda kendilerinde verilen veri kümelerini inceleyerek ve kendileri için belirlenmiş bir hedef doğrultusunda öğrenme yeteneğine sâhip olsalar da: ilerleyen zamanlarda bu sınırların da ortadan kalkması mümkündür. Zirâ mevcûd sınırlandırma, yalnızca, veri kümeleri ile hedeflerin belirlenmesi sayesinde sağlanabilmekte olup; gerek veri kümelerinin gerekse hedeflerin sınırsız hâle getirilmesi ve dahî bunun açık kaynak kodlu bir yapay zekâ tarafından gerçekleştirilmesi hâlinde doğabilecek zarârlar ile herhangi bir kişi arasında ‘illiyet bağının kurulamaması tehlikesi mevcûttur.

Anılan bu tehlikeyi ortadan kaldırmanın etkin bir yolu ise bu vârlıkların bizzât kendilerine hukûkî kişilik tanımak ve tıpkı sermaye şirketlerinin mâl vârlıklarının, kendi sorumluluklarına karşı, güvence oluşturmada olduğu gibi; bu vârlıklara da mâl vârlığı edinme imkânı tanımak sûretiyle etkinleştirmek mümkündür.

ChatGPT adlı yapay yapay zekâ uygulamasının konuyla ilgili sorularımıza vermiş olduğu cevâblar da göstermektedir ki: mevcûd hukûk kişilerinin, mevcûd hukûkî düzenlemeler kapsamında, tazmini mümkün olmayan bâzı zarârlar ile karşı karşıya kalmaları muhtemeldir. Bu ihtimâlî ortadan kaldırmak amacıyla: yâ herhangi bir başka kişi ile illiyet bağı bulunmayan bir zarâra karşı mevcûd kişiler korumasız bırakılacak; yâ “depren, sel, kasırga, hortum, orman yangını, kuraklık, tsunami” gibi “act of god” olarak adlandırılan ve Tanrı’dan başka hiç kimsenin sorumlu tutulamayacağı kabul edilen [23, 24] zarârlar sınıfı yanında ikinci bir sınıf olarak “act of AI” eklenecek ve öncelikle benzer şekilde bu risklere karşı özel bir sigorta türü oluşturulacak; yâhûd da hukûkî kişilik statüsüne dâhil edilmek sûretiyle ürettikleri yararlı ürün, eser [25, 26] ve hizmetler nisbetinde mâl vârlığına sâhip kılınmaları dolayısıyla sebep oldukları zarârları giderebilmeleri sağlayacaktır.

REFERENCES

- [1] S. Kara Kılıçarslan, “Yapay zekanın hukuki statüsü ve hukuki kişiliği üzerine tartışmalar”, *Yıldırım Beyazıt Hukuk Dergisi*, Sayı 2, 2019, 363-389.
- [2] E. Benli ve G. Şenel, “Yapay zekâ ve haksız fiil hukuku”, *Ankara Sosyal Bilimler Üniversitesi Hukuk Fakültesi Dergisi*, Cilt 2, Sayı 2, 2020, 296-336.
- [3] Ö. Çelebi, “Kişi ve eşya ayrımı bağlamında hayvanların hukuki statüsü”, *İstanbul Hukuk Mecmuası*, Cilt 76, Sayı 2, 2018, 559-622.
- [4] F. Kiroğlu, “Türkiye’de hayvanlara yönelik şiddetin hayvan hakları koruma kanunu kapsamında değerlendirilmesi”, *Meyad Akademi*, Cilt 2, Sayı 2, 2021, 172-185.
- [5] Ö. Ergün, “Medeni hukuk tüzel kişilerinin ehliyet durumu” (Doktora Tezi, İstanbul Üniversitesi 2009).
- [6] M. Y. Aslan, “Türk hukukunda tüzel kişilerin ceza sorumluluğu”, *Ankara Barosu Dergisi*, Sayı 2, 2010, 233-246.
- [7] D. Aydın, “Tüzel kişilerin ceza sorumluluğu tartışmaları”, *Uyuşmazlık Mahkemesi Dergisi*, Sayı 10, 2017, 97-110.
- [8] M. Goode, “Tüzel kişilerin cezai sorumluluğu”, Çev: E. Şen, *İstanbul Üniversitesi Siyasal Bilgiler Fakültesi Dergisi*, Sayı 15, 1996, 35-44.
- [9] N. Centel, “Ceza hukukunda tüzel kişilerin sorumluluğu -şirketler hakkında yaptırım uygulanması-”, *Ankara Üniversitesi Hukuk Fakültesi Dergisi*, Cilt 65, Sayı 4, 2016, 3313-3326.
- [10] F. Eren, *Sorumluluk Hukuku Açısından Uygun İlliyet Bağı Teorisi*, Ankara: Sevinç Matbaası 1975.
- [11] B. Bak, “Medeni hukuk açısından yapay zekânın hukuki statüsü ve yapay zekâ kullanımından doğan hukuki sorumluluk”, *Türkiye Adalet Akademisi Dergisi*, Sayı 35, 2018, 211-232.
- [12] M. Karatepe Kaya, “Yapay zekanın şirket yönetimine olası katkılarının Türk şirketler hukuku kapsamında değerlendirilmesi ve yapay zekanın hukuki statüsünün belirlenmesinde şirketler hukukundan çıkartılabilecek dersler”, *Ankara Hacı Bayram Veli Üniversitesi Hukuk Fakültesi Dergisi*, Cilt 25, Sayı 3, 2021, 69-106.
- [13] İ. Gezer, “İslam hukukuna göre yapay zekânın hukuki mahiyeti” (Yükseklisans Tezi, Necmettin Erbakan Üniversitesi 2022)
- [14] Ü. Görgülü, “Teknoloji geliştiren insandan teknolojinin geliştirdiği insana -Genetik müdahale ile insan geliştirmeye etik ve fikhî bakış-” *Diyanet İlmî Dergi*, Cilt 58, Sayı 3, 2022, 1095-1124.
- [15] A. Gültekin, “Transhümanizm bağlamında yapay zekâ Tanrıya bir başkaldırı mıdır?”, *İğdır Üniversitesi Sosyal Bilimler Dergisi*, Sayı 28, 2021, 1-16.
- [16] A. Dağ, “Yaratılışa müdahale ve yeni bir evrimci neo-Darwinist bir yaklaşım olarak transhümanizm”, *FLSF Felsefe ve Sosyal Bilimler Dergisi*, Sayı 27, 2019, 153-168.
- [17] İ. B. Aldemir Toprak, “Komisyon’un COM (2020) 64 final raporu ışığında yapay zekânın hatalı işleyişi ile ilgili ürün sorumluluğu hukukuna ilişkin düşünceler”, *Marmara Üniversitesi Hukuk Fakültesi Hukuk Araştırmaları Dergisi*, Cilt 27, Sayı 1, 2021, 741-753.
- [18] S. S. Akkurt, “Yapay zekânın otonom davranışlarından kaynaklanan hukukî sorumluluk”, *Uyuşmazlık Mahkemesi Dergisi*, Sayı 13, 2019, 39-59.
- [19] A. A. Selanik, “Adam çalıştırmanın sorumluluğu kapsamında yapay zekâ robotun sorumluluğu ve sigortalanması hususunun değerlendirilmesi”, *Türkiye Adalet Akademisi Dergisi*, Sayı 50, 2022, 335-364.
- [20] G. Erdoğan, “Yapay zekâ ve hukukuna genel bir bakış”, *Adalet Dergisi*, Sayı 66, 2021, 117-192.
- [21] C. Ercan, “Robotların fiillerinden doğan hukuki sorumluluk sözleşme dışı sorumluluk hallerinde çözüm önerileri”, *Türkiye Adalet Akademisi Dergisi*, Sayı 40, 2019, 19-51.
- [22] S. S. Akkurt, “Avrupa Parlamentosu’nun ‘robotik hakkında medenî hukuk kurallarına ilişkin 16 Şubat 2017 tarihli tavsiye kararı’nın genel bir tahlili ve yasalaştırma öngörütleri”, *Legal Hukuk Dergisi*, Cilt 17, Sayı 198, 2019, 2537-2556.
- [23] D. Binder, “Act of God? or act of man?: Reappraisal of the act of God defense in tort law”, *Review of Litigation*, Cilt 15, Sayı 1, 1995, 1-80.
- [24] G. D. Kaufman, “On the meaning of ‘act of God’”, *The Harvard Theological Review*, Cilt 61, Sayı 2, 1968, 175-201.
- [25] B. Kaynak Balta, “Yapay zekâ ürünlerinin hukuki niteliği ve fikri eser kavramı”, *Ankara Hacı Bayram Veli Üniversitesi Hukuk Fakültesi Dergisi*, Cilt 24, Sayı 3, 2020, 205-230.
- [26] E. Karataş ve U. Karaca, “Yapay zekâ tarafından meydana getirilen fikri ürünlerin 5846 sayılı fikir ve sanat eserleri kanununa göre korunması”, *Maltepe Üniversitesi Hukuk Fakültesi Dergisi*, Sayı 1, 2022, 17-50.

Anne Sağlık Durumu Riskinin Makine Öğrenmesi Yöntemleri ile Belirlenmesi

Determining the Risk of Maternal Health Status with Machine Learning Methods

Mahmut TOKMAK
Yönetim Bilişim Sistemleri
Bucak Zeliha Tolunay Uygulamalı
Teknoloji ve İşletmecilik Yüksekokulu
Burdur, Türkiye
mahmuttokmak@mehmetakif.edu.tr

Özet:—Anne sağlığı hamilelik, doğum ve doğumu takip eden dönemde kadınların sağlığını ifade eden bir kavram olarak tanımlanmaktadır. Son yıllarda bu aşamaları tamamında kadın ve bebeğin sağlıklı bir şekilde tamamlaması için önemli düzeyde ilerlemeler kaydedilmesine rağmen hamilelik, doğum ve sonrasında kadın ölümleri görülmektedir. Bunun yanı sıra bebek ölümleri ile de karşılaşmaktadır. Dünya sağlık örgütü tarafından paylaşılan rakamlara bakıldığında bu ölümlerin kabul edilemez derecede yüksek olduğu belirtilmektedir. Yaşanan anne ölümlerinin çoğu, sağlık çalışanları tarafından zamanında müdahale ile önlenabilir niteliktedir. Önlenabilir anne ölümlerinin sona erdirilmesi dünya çapında önem verilmesi gereken bir durum olarak karşımıza çıkmaktadır. Bu bağlamda anne ölümü riski oluşturabilecek durumların tespiti de oldukça önemlidir.

Bu çalışmada, anne sağlık durumu riskinin makine öğrenmesi yöntemleri kullanılarak tespit edilmesi amaçlanmıştır. Navie Bayes, Karar Ağaçları, Rastgele Ormanlar, Destek Vektör Makinesi, XGBoost ve Derin Sinir Ağları makine öğrenmesi yöntemleri kullanılarak analizler yapılmış ve performansı karşılaştırılmıştır. Makine öğrenmesi yöntemlerinin performansı Doğruluk, F1-Skor, Kesinlik ve Duyarlılık metrikleri ile değerlendirilip sonuçları ortaya konmuştur.

Anahtar:—Kelimeler: Makine Öğrenmesi, Danışmanlık Öğrenme, Tahminleme, Anne Sağlık Durumu Riski

Abstract—Maternal health is defined as a concept that expresses the health of women during pregnancy, childbirth and the period following birth. Although significant progress has been made in recent years in order for women and babies to complete these stages in a healthy way, women's deaths are observed during pregnancy, childbirth and afterwards. In addition, infant deaths are also encountered. Considering the figures shared by the World Health Organization, it is stated that these deaths are unacceptably high. Most maternal deaths are preventable with timely intervention by healthcare professionals. Ending preventable maternal deaths emerges as a situation that should be given importance worldwide. In this context, it is also very important to identify situations that may pose a risk of maternal death.

In this study, it was aimed to determine the risk of maternal health status by using machine learning methods. Analyzes were

made using machine learning methods of Navie Bayes, Decision Tree, Random Forests, Support Vector Machine, XGBoost and Deep Neural Networks and their performance was compared. The performance of machine learning methods was evaluated with Accuracy, F1-Score, Precision and Sensitivity metrics and the results were revealed.

Keywords:— Machine Learning, Supervised Learning, Prediction, Maternal Health Risk

I. GİRİŞ

Kadınlar için anne sağlığı sorunları hamilelik, doğum ve doğum sonrası dönemde ortaya çıkmaktadır. Hamilelik döneminde kadınlar, birçok durumda düşük ve ölüme yol açabilecek sağlık komplikasyonları açısından yüksek risk altındadır. Tüm hamilelikler risk taşısa da, yüksek riskli bir hamilelik ekstra bakım gerektirebilir. Bebeklerin ve kadınların sağlığını korumak için hamilelik aşamasında gözlem altında olmalıdır. Anne ve bebek sağlığını korumak ve ölümleri azaltmak için hamileliğin farklı aşamalarında tıbbi eylemler gereklidir. Doğum sonrası dönemde de hem annenin hem de bebeğin sağlığını izlemek çok önemlidir çünkü her ikisi de ilk dönemde daha yüksek ölüm riski altındadır. Doğum sonrasında yapılan sağlık izlemeleri de semptomların erken tespit edilip tedavi edilmesi açısından önemlidir ve bu da ölüm riskini azaltabilir [1–4].

Gelişen modern dünyada, hamilelik süresince ortaya çıkan komplikasyonların tamamı olmasa da çoğu tedavi edilebilir, hatta önlenabilir niteliktedir. Bununla birlikte, Dünya Sağlık Örgütü'nün raporuna göre 2017 yılında hamilelik sürecinde, doğum sırasında ve doğum sonrasında yaklaşık 295.000 kadın ölmüştür. Bu da her gün yaklaşık 810 kadının hamilelik ve doğumla ilgili önlenabilir nedenlerden dolayı hayatını kaybettiği anlamına gelmektedir. Bu ölümlerin %94'ü, düşük ve orta gelirli ülkelerde yaşayan ergenlik çağındaki gençlerde veya yirmi yaşından küçük ergenlerde gerçekleşmiştir [1,2,5]. Hamile kadınlardaki yaş, yüksek veya düşük kan basıncı, kan şekeri seviyeleri, vücut ısı ve kalp hızı gibi sağlık faktörleri, gebelik sırasında yüksek düzeyde sağlık sorunlarına neden olabilir ve bu da hem kadının hem bebeğin kaybına yol açabilir. Bu sağlık faktörlerinin, tıp uzmanı tarafından özel ilaçlarla kontrol edilmesi gerekir. Bu nedenle, bu tür sağlık risklerinin erken teşhisi, tıp uzmanlarının bu durumu

hafifletmek için uygun önlemleri olarak potansiyel ölüm olasılığının önlenmesinde önemli derecede rol oynamaktadır [1,2].

II. KAYNAK ÖZETLERİ

Kansızlıktan COVID-19'a kadar birçok hastalık türünü tahmin etmek için farklı makine öğrenimi algoritmaları ve yöntemleri kullanılmıştır. Anne sağlığının önemli olması nedeniyle, birçok araştırmacı makine öğrenimi tekniklerini kullanarak hamilelik sırasındaki sağlık risklerinin tahmin edilmesi için modeller ve yaklaşımlar geliştirmeye yönelmişlerdir. Aynı zamanda makine öğrenimi teknikleri, hamilelik risklerinin tahmininin yanısıra bebek sağlığını tahmin etme konusunda da kullanılmıştır [1,6].

Tıbbi teşhis ve tahminde makine öğrenimi üzerine yapılan önceki araştırmalara bakıldığında; C4.5 Karar Ağacı, Naive Bayes algoritmaları ile hamilelik risklerini ve hamileliğin normal veya anormal evrelerini tahmin etmek üzere çalışmalar yapılmıştır [7]. Ahmet vd. Bangladeş'te yaptıkları çalışmada bulut tabanlı makine öğrenimi teknikleri kullanılarak hamile kadınların sağlık risk seviyeleri tahmin etmişlerdir [8]. Hamile kadınların sağlık durumlarını analiz ederek anne sağlığı risk durumlarını belirlemişlerdir. Giyilebilir algılama cihazları kullanılarak çok sayıda kaynaktan toplam 1014 örnek toplamışlar ve bu örnekleri "Maternal Health Risk Data Set" (MHRDS) adı altında paylaşmışlardır. Kullandıkları yöntemleri gerçekleştirmek için Python ve WEKA kullanmışlardır. Anne sağlığı risk seviyelerini, tıp uzmanlarının yardımıyla düşük riskli, orta riskli ve yüksek riskli olarak ayırmışlardır. Yaş, kan basıncı ve kan şekeri gibi sağlık faktörlerini, risk seviyesini belirlemek için anahtar faktörler olarak tanımlamışlardır [9]. Diamantoulaki vd. MHRDS veri kümesini kullanmışlar ve anne sağlığı riskini belirlemede, beş risk faktörünü dikkate almışlardır. Vücut sıcaklığı (BodyTemp) özneliğinin ExtraTreesClassifier kullanarak yaptıkları analizde risk faktörleri açısından öznitelik öneminin diğer özniteliklere göre çok düşük olduğundan bu özneliği deneysel çalışmalarında kullanmamışlardır. Çalışmalarında federe öğrenme yöntemi ile tahminleme yapmışlardır [10]. Raza vd. çalışmalarında, öznitelik seçimi Karar Ağacı, çift yönlü uzun kısa süreli bellek (Bidirectional long short term memory (BiLSTM)) ve geçici evrimsel sinir ağları (temporal convolutional network (TCN)) tabanlı öznitelik seçimi önermişlerdir. Çalışmalarında sınıf dengesizliğini gidermek için SMOTE sentetik veri artırma yöntemini kullanmışlardır. Önerilen DT-BiLTCN öznitelik seçimi yapıldıktan sonra Karar Ağacı, Lojistik Regresyon, Ekstra Ağaç, K- En Yakın Komşu, Rastgele Orman (RO) ve Destek Vektör Makineleri (DVM) yöntemleri ile kullanarak deneyler yapmışlardır [1].

III. MATERYAL VE METOT

Çalışmada UCI Machine Learning'den alınan «Maternal Health Risk» veri seti kullanıldı [11]. Bu veri seti Ahmet vd. Bangladeş'te yaptıkları bir çalışma sonucunda yayınlanmıştır. Veri seti birden fazla kaynaktan toplanan 1014 örnekten ve 6 öznelikten oluşmaktadır. Anne sağlığı risk seviyeleri, tıp uzmanlarının yardımıyla düşük riskli, orta riskli ve yüksek riskli olarak ayrılmıştır.

TABLO 1. Öznitelikler ve istatistiksel veriler

	count	mean	std	min	25%	50%	75%	max
Age	1014	29,9	13,5	10,0	19,0	26,0	39,0	70,0
SystolicBP	1014	113,2	18,4	70,0	100,0	120,0	120,0	160,0
DiastolicBP	1014	76,5	13,9	49,0	65,0	80,0	90,0	100,0
BS	1014	8,7	3,3	6,0	6,9	7,5	8,0	19,0
BodyTemp	1014	98,7	1,4	98,0	98,0	98,0	98,0	103,0
HeartRate	1014	74,3	8,1	7,0	70,0	76,0	80,0	90,0

Tablo 1'de verilen özniteliklerin açıklaması aşağıda verilmiştir.

Age: Yaş,


Sistolik BP: Kan Basıncının mmHg cinsinden üst değeri,

DiastolicBP: Düşük Kan Basıncı değeri.

BS: Kan şekeri seviyeleri


BodyTemp: Vücut sıcaklığı

HeartRate: Kalp Atış Hızı



Şekil 1. Veri seti risk seviyeleri ve sayıları

Veri seti içinde anne sağlık durumu risk seviyeleri Şekil 1'de gösterildiği üzere yüksek risk, düşük risk ve orta risk olmak üzere üç kategoriye ayrılmaktadır.



Şekil 2. Korelasyon matrisi

Tahmin özneliklerinin Şekil 2'de gösterilen korelasyonlarına bakılıp, korelasyonu düşük olan değişkenler veri setinden çıkarılarak yapılan analizlerden sonra,

“HeartRate” özneliğinin hamile kadınların sağlık risklerini belirlemede daha az yardımcı olduğu sonucuna varıldı. Bu nedenle, bu öznelik veri setinden kaldırılarak sınıflandırmalar yapılmıştır. Veri seti için SMOTE-ENN metodu kullanılarak veri seti dengesizliği giderilmiştir.

Çalışmada kullanılan algoritmalar ve deneysel analizlerde kullanılan parametreler aşağıda özetlenmiştir.

Naive Bayes sınıflandırma Bayes teoremine dayanan bir yöntemdir. Algoritma tahmin edilecek sınıf elemanı için her durumun olasılığını hesaplar ve olasılığı en yüksek çıkan değeri seçerek sınıflandırma işlemini yerine getirir.

Karar ağaçları, niteliklerin temsil edildiği düğümler, dal ve yapraklardan oluşmaktadır. Karar ağaçları ile sınıflandırmada en üst yapı kök düğüm ile başlar. En son yapı ise yapraklardan oluşur. Kök ile yapraklar arasında kalan yapılar ise dal olarak adlandırılmaktadır. Niteliklerin değerine göre düğümler alt dallara ayrılır, bu süreç yaprak elde edilinceye kadar devam eder. Burada düğümler; test işlemine tabi tutulan nitelikleri gösterir, dallar ise teste tabi tutulan düğümlerin sonuçlarını gösterir. Yapraklar ise veri setindeki bir karar sınıfını temsil etmektedir [12].

Derin Sinir Ağları (DSA), giriş, çıkış ve birden fazla katmanı olan yapay bir sinir ağı olarak tanımlanabilmektedir. DSA'nın her katmanında ele alınan problemle ilgili çıkarılan öznelikler öğrenilmekte ve söz konusu katmanda öğrenilen öznelikler, kendisinden sonra gelen katman için girdi değerlerini oluşturmaktadır. Böylece ilk katmandan başlayarak son katmana doğru özneliklerin öğrenilerek devam edildiği bir ağ yapısı oluşturulmuş olmaktadır [13].

Rastgele Orman algoritması topluluk öğrenme algoritmalarından biridir. Topluluk öğrenme metodları, farklı modelleri birleştirerek sonuçları iyileştirmeyi amaçlar. Rastgele orman algoritması birden fazla karar ağaçlarının birleşiminden elde edilmektedir [7].

DVM doğrusal olarak ayrılabilen ve doğrusal olarak ayrılamayan verilere uygulanabilmektedir. Doğrusal olarak ayrılabilme durumunda DVM'nin amacı iki sınıfı birbirinden ayıran en iyi hiper düzlemi bulmaktır. Verilerin Doğrusal olarak ayrılamadığı durumda ise sınıflandırma işlemi çekirdek fonksiyonları kullanılarak yüksek boyutlu bir uzaya taşınarak gerçekleştirilir [14].

XGBoost, Chen ve Guestrin tarafından geliştirilen bir topluluk ağacı algoritmasıdır [15]. Friedman'ın gradyan artırma algoritmasına dayalı olarak geliştirilmiştir [16,17]. XGBoost, tahmin performansı tek başına kullanılan bireysel tekniklerden daha iyi olan, birleştirilmiş bir model üretmek için karar ağaçlarının verimli bir şekilde uygulanmasından oluşan kollektif bir modeldir.

Makine öğrenme yöntemleri ile sınıflandırma için kurulan modellerin tasarımı Python programlama dili kullanılarak gerçekleştirilmiştir. Kullanılan algoritmaların eğitilmesi ve test edilmesi işlemleri için Google Colaboratory ya da kısaca Colab bulut platformu kullanılmıştır. [18]. Model üzerinde yapılan deneylerde veri setinin %80'i eğitim, %20'si test için ayrılmıştır. XGBoost sınıflandırıcı için Python xgboost kütüphanesi ve “default” parametreler kullanılmıştır. Naive Bayes, DVM algoritmaları için Python sklearn kütüphanesi kullanılmıştır. DSA sınıflandırıcı için Python Keras kütüphanesi kullanılmıştır. Kurulan DSA modeli 5 düğümden

oluşan 1 giriş katmanı, 2 adet 20 düğümden oluşan gizli katman ve çıkış katmanından oluşmaktadır. Aktivasyon fonksiyonu olarak Rectifier Lienar Units (RELU) kullanılmıştır. Çıkış katmanında kullanılan aktivasyon fonksiyonu ise softmax'tır. Loss parametresi categorical_crossentropy, optimizer parametresi adam, batch_size 16, epoch parametresi ise 1000 olarak ayarlanmıştır. RO algoritmasında n_estimators 50, criterion "gini" olarak ayarlanmıştır. DVM algoritmasında çekirdek fonksiyonu rbf (Radial basis function) kullanılmıştır. Diğer algoritmalarda “default” parametreler kullanılmıştır.

Tablo 2. Sınıflandırma performans ölçütleri

Algoritmalar	Doğruluk	Kesinlik	f1	Duyarlılık
Naive Bayes	0.6875	0.68711	0.662239	0.668899
DVM	0.81875	0.786692	0.790552	0.799046
RO	0.91875	0.902022	0.902167	0.903001
DSA	0.93750	0.923259	0.927410	0.933214
XGBoost	0.93751	0.925714	0.928586	0.932174
Karar Ağacı	0.96875	0.962963	0.966253	0.97231

Yapılan deneysel analizler sonucunda elde edilen performans metrikleri Tablo 2'de gösterilmiştir. Kullanılan algoritmalar içinde en düşük performansı Naive Bayes algoritması gösterirken en yüksek doğruluk değeri Karar Ağacı sınıflandırma yöntemi ile elde edilmiştir.

IV. SONUÇ

Bu çalışmada, anne sağlık durumu riski makine öğrenmesi yöntemleri kullanılarak tespit edilmiştir.

Yapılan deneysel çalışmalar sonucunda Karar Ağacı yönteminin diğer makine öğrenmesi yöntemlerine göre daha başarılı olduğu görülmüştür. Karar ağaçları ile %96.88 oranında doğruluk değerine ulaşılmıştır.

Makine öğrenme yöntemlerinin bir karar destek sistemi olarak anne sağlık durumu riskinin belirlenmesinde kullanılabileceği kanaati oluşmuştur. Bununla birlikte, anne sağlık durumu riskinin belirlenmesinde makine öğrenme modellerinin otomatik ve doğru olarak ilerletilebilmesi ve geliştirilmesi için, sağlık uzmanlarının rehberliğinde mevcut verilerin yanı sıra farklı bulgular ve/veya tıbbi görüntüleme cihazlarından alınan veriler ile birleştirildiği yüksek kaliteli veri kümeleri ile çalışmaların yapılması faydalı olacaktır.

V. KAYNAKLAR

- [1]. Raza, A., Siddiqui, H. U. R., Munir, K., Almutairi, M., Rustam, F., & Ashraf, I. (2022). Ensemble learning-based feature engineering to analyze maternal health during pregnancy and health risk prediction. *Plos One*, 17(11).
- [2]. Macrohon, J. J. E., Villavicencio, C. N., Inbaraj, X. A., & Jeng, J.-H. (2022). A Semi-Supervised Machine Learning Approach in Predicting High-Risk Pregnancies in the Philippines. *Diagnostics*, 12(11), 2782.
- [3]. Turban, J. L., King, D., Kobe, J., Reisner, S. L., & Keuroghlian, A. S. (2022). Access to gender-affirming hormones during adolescence and mental health outcomes among transgender adults. *PLOS ONE*, 17(1), e0261039. <https://doi.org/10.1371/journal.pone.0261039>
- [4]. Finlayson, K., Crossland, N., Bonet, M., & Downe, S. (2020). What matters to women in the postnatal period: A meta-synthesis of

- qualitative studies. *PLOS ONE*, 15(4), e0231415. <https://doi.org/10.1371/journal.pone.0231415>
- [5]. WHO. (2019). WHO. <https://www.who.int/en/news-room/fact-sheets/detail/maternal-mortality>
- [6]. Akbulut, A., Ertugrul, E., & Topcu, V. (2018). Fetal health status prediction based on maternal clinical history using machine learning techniques. *Computer Methods and Programs in Biomedicine*, 163, 87–100.
- [7]. Lakshmi, B. N., Indumathi, T. S., & Ravi, N. (2015). A comparative study of classification algorithms for predicting gestational risks in pregnant women. *2015 International Conference on Computers, Communications, and Systems (ICCCS)*, 42–46.
- [8]. Ahmed, M., Kashem, M. A., Rahman, M., & Khatun, S. (2020). Review and analysis of risk factor of maternal health in remote area using the Internet of Things (IoT). In *InECCE2019, LNEE* (Vol. 632, pp. 357–365). Springer.
- [9]. Ahmed, M., & Kashem, M. A. (2020). IoT based risk level prediction model for maternal health care in the context of Bangladesh. *2020 2nd International Conference on Sustainable Technologies for Industry 4.0 (STI)*, 1–6.
- [10]. Diamantoulaki, I., Diamantoulakis, P. D., Bouzinis, P. S., Sarigiannidis, P., & Karagiannidis, G. K. (2022). Health Risk Assessment with Federated Learning. *2022 International Balkan Conference on Communications and Networking (BalkanCom)*, 57–61.
- [11]. Dua, Dheeru, & Graff, Casey. (2017). UCI Machine Learning Repository. *University of California, Irvine, School of Information and Computer Sciences*. <https://archive.ics.uci.edu/ml/datasets/cardiocography>
- [12]. Diler, S. (2016). Veri madenciliği süreçleri ve karar ağaçları algoritmaları ile bir uygulama. *Yayınlanmamış Yüksek Lisans Tezi*.
- [13]. Kemalöğlu, N., Aydoğan, T., & Küçüksille, E. U. (2021). 3 Deep learning approaches in metastatic breast cancer detection. *Artificial Intelligence for Data-Driven Medical Diagnosis*, 3, 55.
- [14]. Özkan, Y. (2008). *Veri madenciliği yöntemleri*. Papatya Yayıncılık Eğitim. <https://books.google.com.tr/books?id=kKsicgAACAAJ>
- [15]. Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. *Proceedings of the 22nd Acm Sigkdd International Conference on Knowledge Discovery and Data Mining*, 785–794.
- [16]. Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, 29(5), 1189–1232.
- [17]. Zhou, J., Qiu, Y., Khandelwal, M., Zhu, S., & Zhang, X. (2021). Developing a hybrid model of Jaya algorithm-based extreme gradient boosting machine to estimate blast-induced ground vibrations. *International Journal of Rock Mechanics and Mining Sciences*, 145, 104856. <https://doi.org/10.1016/j.ijrmms.2021.104856>
- [18]. Google Colaboratory. (2022). Colaboratory. <https://colab.research.google.com/>

Location of Distributed Generation in DC Microgrids

T.Altun^{1*}

¹*Yozgat Bozok Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Yozgat, Türkiye*

Distributed generation (DG) points to a number of technologies that generate electricity in the close vicinity of load demand. The conventional and centralized power distribution systems cannot meet the ever-increasing growth in demand, which comprises the reliability of power system operations. DG can appear as a single structure, e.g., a home or business, or a microgrid, e.g., a major industrial facility, a military base, or a large college campus. The integration of DGs into the distribution level can help support delivery of clean, reliable power to additional customers and reduce electricity losses along transmission and distribution lines. Optimal placement of DG units helps strengthening grid, reducing on-peak operating cost, improving voltage profiles and load factors, addressing system upgrade requirements, and enhancing system integrity, reliability, and efficiency. Mixed-integer nonlinear programming (MINLP) representation is used to cast optimal DG placement problem that brings burden on to computation time. The increase in the computation time comes from power flow equations, and disjoint variables, respectively, non-convex and binary. The variable settled in disjoint set accounts for the deployment decision to determine the location of predefined number of DG units. These difficulties are usually overcome with a linearized version of the original problem. The linearized form of the formulation can also be solved with heuristic approaches namely particle swarm, genetic, and harmony search algorithms. Main drawback of using linearized version is to consideration of network without loss. The heuristic methods' performance relies on the pre-selected starting values. A two-stage optimization model, where mixed-integer linear programming (MILP) version of the problem is handled as a master problem, while the MINLP problem is addressed as a subproblem. However, their solutions are not guaranteed to be globally optimal.

Convex relaxation approaches cast original problem in its surrogates, while preserving equivalency to the original formulation, to integrate network losses and address the power flow equations containing non-convexity. Convex relaxation methods have been applied for optimal power flow in distribution networks with DG units. While the optimal DG operation, considering the physical and operational constraints, has been scrutinized AC and DC microgrids, the optimal DG placement is required to be studied more to realize industry level applications.

We propose an optimal distributed generation (DG) placement framework for both DC and AC microgrids to minimize transmission/distribution losses. Given the historical behavior of load profiles, this planning problem optimizes discrete variables, either zero or one for each bus, represent the location of DGs without violating operational and physical boundaries. This problem is cast as a MINLP, which brings computational burden cause of non-convex power balance/flow solutions and discrete values. A mixed-integer second-order cone programming (MISOCP) relaxation is employed to obviate the non-convexities of power flow/balance equations and use branch-and-bound search to solve the resulting relaxed problem. The proposed approach is validated on IEEE benchmark systems.

Keywords: Distributed generation, DC micro-grids, power systems.

* Sorumlu yazar. Tel.: +90 354 242 1741; fax: +90 354 242 1005.

E-mail: tuncay.altun@yobu.edu.tr (T.Altun).

DC Mikro-şebekelerde Dağıtık Üretimin Konumu

T.Altun^{1*}

¹Yozgat Bozok Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Yozgat, Türkiye

Dağıtık üretim (DÜ), yük talebinin yakınında elektrik üreten bir dizi teknolojiye işaret etmektedir. Konvansiyonel ve merkezi güç dağıtım sistemleri, güç sistemi operasyonlarının güvenilirliğini içeren, talepte sürekli artan büyümeyi karşılayamamaktadır. DÜ, örneğin bir ev, işyeri, mikro-şebeke, büyük bir endüstriyel tesis, askeri üs veya bir üniversite kampüsü gibi tek yapı olarak görünebilir. DÜ'lerin dağıtım seviyesine entegrasyonu, artan talebe karşın temiz, güvenilir güç sağlanmasını desteklemeye, iletim ve dağıtım hatları boyunca elektrik kayıplarını azaltmaya yardımcı olabilir. DÜ birimlerinin en uygun konuma yerleştirilmesi, şebekenin güçlendirilmesine, yüksek işletme maliyetlerinin azaltılmasına, gerilim profillerinin ve yük faktörlerinin iyileştirilmesine, sistem yükseltme gereksinimlerinin ele alınmasına ve sistem bütünlüğünün, güvenilirliğin ve verimin artırılmasına yardımcı olur. En uygun konuma DÜ yerleştirme problemi, hesaplama açısından zorlayıcı olan *karma tamsayılı doğrusal olmayan programlama* biçiminde ifade edilebilir. Çünkü dışbükey olmayan güç akışı denklemleri ve DÜ konumunun kararını hesaba katan ikili (0 veya 1) değişkenleri içerir. Bu zorluklar çoğunlukla orjinal problemin doğrusal bir yaklaşımı veya genetik, parçacık sürüsü ve harmoni araştırması gibi sezgisel yöntemler aracılığıyla ele alınmaktadır. Doğrusal yaklaşımlar kayıpsız bir şebeke olduğunu varsaymaktadır. Sezgisel yöntemlerin performansı başlangıç koşullarına bağlıdır. Bu iki metodun birleşimi olarak; problemin *karma tamsayılı doğrusal programlama* versiyonunun ana problem, *karma tamsayılı doğrusal olmayan programlama* probleminin ise bir alt problem olarak ele alındığı iki aşamalı bir optimizasyon modeli sunulabilir. Ancak bu yöntemler de çözümlerinin global veya globale yakın olarak *en uygun* olduğunu garanti edemez.

Şebeke kayıplarını problem formülasyonuna entegre etmek ve güç akışı denklemlerinin dışbükey olmama durumunu ele almak için çeşitli dışbükey gevşetme yöntemleri orjinal problemi, orjinal formülasyonla eşdeğerliğini korumaya çalışırken, alternatif ama denk bir hale dönüştürmüştür. DÜ üniteli dağıtım şebekelerinde *en uygun* güç akışı için dışbükey gevşetme yöntemleri uygulanmıştır. DC mikro-şebekeler için fiziksel ve operasyonel kısıtlar göz önünde bulundurularak DÜ'ler incelenmiş olsa da literatürde *en uygun konuma* DÜ yerleştirme çabaları oldukça nadirdir.

Bu çalışmada iletim/dağıtım kayıplarını en aza indirmek için DC mikro-şebekelerde *en uygun konuma* DÜ yerleştirme formülasyonu önerilmektedir. Talep edilen yük profillerinin tarihsel davranışı göz önüne alındığında, bu planlama problemi operasyonel ve fiziksel kısıtlamalara uyarken DÜ'lerin konumunu belirleyen ayrık değişkenlerin *en uygun* değerini bulmaktadır. Bu problem, dışbükey olmayan güç akışı/denge denklemleri ve ayrık değişkenlerin varlığından dolayı hesaplama açısından zor olan *karma tamsayılı doğrusal olmayan programlama* problemi olarak gösterimi amaçlanmaktadır. Güç akışı/denge denklemlerinin dışbükey olmama durumlarını ortadan kaldırmak için *karma tamsayılı ikinci dereceden konik programlama gevşemesi* ve ortaya çıkan ayrık değişkenleri bulmak için *dal-sınır araması* yöntemleri kullanılmaktadır. Önerilen yaklaşımın doğrulanmasının IEEE test sistemlerinde yapılması planlanmaktadır.

Anahtar Kelimeler: Dağıtık üretim, DC Mikro Şebeke, Güç Sistemleri.

* Sorumlu yazar. Tel.: +90 354 242 1741; fax: +90 354 242 1005.

E-mail: tuncay.altun@yobu.edu.tr (T.Altun).

DC Şebekelerin Optimizasyonun Hesaplama Sürelerinin Derin Öğrenme Metotları ile Azaltılması

K.Başar^{1*}, K.Altun², İ.Zorlutuna³

¹Yozgat Bozok Üniversitesi, Yozgat Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Yozgat, Türkiye

²Sivas Cumhuriyet Üniversitesi, Sivas Teknik Bilimler Meslek Yüksekokulu, Elektronik ve Otomasyon Bölümü, Sivas, Türkiye

³Sivas Cumhuriyet Üniversitesi, Fen Fakültesi, Matematik Bölümü, Sivas, Türkiye

Günümüzde artan nüfus ve buna bağlı olarak artan güç talebi ile AC şebekelerde karşılaşılan güç kompanzasyonu gibi birçok problemde yaşanan zorluklar, DC şebekelerin popüleritesini artırmıştır. Ancak DC gücün depolanmasındaki yüksek maliyetler DC kaynakların optimal kullanımı zorunluluğunu doğurmuştur. Doğada sınırlı DC kaynakların maksimum kullanımının ardındaki fikir, güç sistemleri literatüründe yaygın olarak bahsedilen üç tip problem olarak ortaya çıkmıştır: yük akışı, ekonomik dağıtım ve optimal güç akışı problemi. Problemin tespitinde fiziksel ve operasyonel kısıtlamaların belirlenmesi gerekmektedir. Güç sistemi optimizasyon problemleri ilk olarak Kirchhoff ve Ohm kanunu kullanılarak optimal güç akışı problemi olarak formülize edilmiştir. Optimal güç akışı probleminde her bir bara için gerilim ve güç ayar noktaları belirlenirken; hatların güç taşıma kapasitesi kısıtlamaları, üretim kapasitesi kısıtlamaları, gerilim üst ve alt sınır kısıtlamaları, iletim kararlılığı kısıtlamaları, vb. kısıtlamaların yanı sıra işletme maliyeti ve güç kaybı gibi belirli bir amaç fonksiyonunu en aza indiren ayar noktaları belirlenir. DC dağıtım şebekelerinde optimal güç akışı, farklı amaç fonksiyonlarında (örneğin; güç kaybı, maliyet ve esneklik) doğrusal, doğrusal olmayan veya sezgisel optimizasyon problemleri olarak formülize edilir. DC şebekelerin kritik görev uygulamalarında yaygın olarak kullanıldığı göz önüne alındığında, optimal güç akışı çözümünü elde etmek, sistemin optimum çalışması için vazgeçilmezdir. DC dağıtım şebekelerinde optimal güç akışı, konveks optimizasyon yöntemleri kullanılarak yeterince incelenmemiştir.

Doğrusal denklemlerle yaklaşık olarak tahmin edilen bir optimal güç akışı çözümü orijinal fiziksel modele tam olarak uygulanamamaktadır. Bu dezavantajı gidermek için, çeşitli konveks dönüşümler çözümün orijinal soruna eşdeğerliğini korumaya çalışırken, doğrusal olmayan güç akışı kısıtlamalarını konveks yaklaşımlara ifade eder. Yarı-belirli programlama (SDP) ve ikinci dereceden koni programlama (SOCP) dahil olmak üzere konveks dönüşüm teknikleri, problemi yüksek boyutlu bir uzayda yeniden formülize eder ve konveks olmayan cebirsel ilişkileri konveks konik eşitsizliklere dönüştürür. Böylelikle SDP ve SOCP dönüşümleri, AC şebekelerde optimal güç akışı çözümü için küresel olarak en uygun çözümleri başarıyla bulur. Ancak bara sayısı çok fazla olan şebekelerde konveks optimizasyon sonuçlarının elde edilmesi ve gerçek zamanlı şekilde fiziksel sistemlere uygulamasının oldukça yavaş olduğu gözlemlenmiştir. Talep verilerinin toplanması ile optimize edilmiş ayar noktalarının hesaplanması arasındaki zamansal boşluk, yani konveks optimizasyonun işlem süresinin azaltılmasının yöntemleri bu çalışmanın ana inceleme noktasını oluşturmaktadır.

Bu çalışmada, kabul edilebilir bir işlem süresi içinde global optimizasyona yakın bir çözümün elde edilmesi amaçlanmıştır. Bunun için XGBoost algoritması 72 dakikalık verileri kullanarak güç, gerilim ve üretim maliyeti gibi değişkenleri derin öğrenme ile global çözüme yakın olacak şekilde bulmuştur.

Anahtar Kelime: Konveks optimizasyon, DC şebekeler, derin öğrenme, optimal güç akışı.

* Sorumlu yazar. Tel.: +90 354-212-3843 / 4011: fax: +90 354-217-1780.

E-mail: kadriye.basar@bozok.edu.tr (K.Başar).

Reducing the Optimization Calculation Times of DC Networks with Deep Learning Methods

K.Başar^{1}, K.Altun², İ.Zorlutuna³*

¹*Yozgat Bozok University, Yozgat Vocational School, Department of Computer Technologies, Yozgat, Türkiye*

²*Sivas Cumhuriyet University, Sivas Vocational School of Technical Sciences, Department of Electronics and Automation, Sivas, Türkiye*

³*Sivas Cumhuriyet University, Faculty of Science, Department of Mathematics, Sivas, Türkiye*

Today, the increasing population and the increasing power demand and the difficulties encountered in many problems such as power compensation in AC networks have increased the popularity of DC networks. However, the high costs of storing DC power have necessitated the optimal use of DC resources. The idea behind the maximum utilization of limited DC resources in nature has emerged as three types of problems commonly mentioned in the power systems literature: load flow, economical distribution, and optimal power flow problem. Physical and operational constraints need to be identified in identifying the problem. Power system optimization problems were first formulated as an optimal power flow problem using Kirchoff and Ohm's law. While determining the voltage and power setpoints for each busbar in the optimal power flow problem; power carrying capacity constraints of lines, generation capacity constraints, voltage upper and lower limit constraints, transmission stability constraints, etc. Setpoints are set that minimize a particular objective function, such as operating cost and power loss, as well as constraints. Optimal power flow in DC distribution networks is formulated as linear, nonlinear or heuristic optimization problems in different objective functions (eg power loss, cost and flexibility). Given that DC networks are widely used in mission critical applications, obtaining the optimal power flow solution is indispensable for the optimum operation of the system. Optimal power flow in DC distribution networks has not been adequately studied using convex optimization methods.

An optimal power flow solution approximated by linear equations cannot be fully applied to the original physical model. To overcome this disadvantage, various convex transformations attempt to maintain equivalence of the solution to the original problem, while expressing nonlinear power flow constraints to convex approximations. Convex transformation techniques, including semi-definite programming (SDP) and quadratic cone programming (SOCP), reformulate the problem in a high-dimensional space and transform non-convex algebraic relations into convex conical inequalities. Thus, SDP and SOCP conversions successfully find globally optimal solutions for optimal power flow solution in AC networks. However, it has been observed that obtaining convex optimization results in networks with a large number of busbars and applying them to physical systems in real time is quite slow. The temporal gap between the collection of demand data and the calculation of optimized setpoints, i.e. the methods of reducing the processing time of convex optimization, is the main examination point of this study.

In this study, it is aimed to obtain a solution close to global optimization within an acceptable processing time. For this, the XGBoost algorithm has found variables such as power, voltage and production cost to be close to the global solution by using 72 minutes of data.

Keywords: Convex optimization, DC grids, deep learning, optimal power flow.

* Sorumlu yazar. Tel.: +90 354-212-3843 / 4011: fax: +90 354-217-1780.

E-mail: kadriye.basar@bozok.edu.tr (K.Başar).

Yapay Zekânın Uluslararası İlişkilere Etkileri

Ranuna İkime GÜN ALTUN¹

¹Yozgat Bozok Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Uluslararası İlişkiler Bölümü, Yozgat, Türkiye

Kuvvet kullanımı terimi, uluslararası ilişkiler disiplininde bütün özellikleri ve incelikleriyle savaş olgusunu içine almaktadır. Kuvvet kullanımının tarafları salt birey, ulus altı ve transnasyonel aktörler ve devletlerle sınırlı kalmayıp değişen karakteriyle yapay zekânın da dâhil olduğu bir sürece evrilmektedir. Bu noktada, Clausewitz'in, '*Savaş Üzerine*' adlı çalışmasında da savaşın doğasının aynı kaldığı ancak karakterinin döneme, teknolojinin ilerlemesine ve manevra kabiliyetlerine göre değişen bir yapısının olduğu ifade edilmiştir. 21. yüzyılın savaşlarında da yapay zekânın bu değişime yön vermekte olduğu son gelişmelerden gözlemlenmiştir. Yapay zekâ, askeri operasyonlarda kullanılma potansiyelinin farkındalığıyla orduların önemli bir parçası haline gelmiştir. Harp sistemleri, stratejik karar verme, bilgi ve araştırma süreci, muharebe simülasyonları, hedef tanıma, tehdit izleme, sürü drone uygulamaları, siber güvenlik, ulaşım ve sağlık gibi alanlarda kullanımlarıyla orduların yapay zekâdan faydalanması artmaktadır.

Soğuk Savaşın bitimiyle birçok uluslararası ve bölgesel örgütün konferanslarında ve mutabakatlarında ifade edildiği gibi güvenlik kavramının genişletilip siyasi-askeri güvenliğin ötesine geçilmesiyle dinamik yapıya uyum sağlamıştır. Aktör olarak bireyler ve konu olarak insan hakları güvenlik alanına yeni bir boyut kazandırmıştır. 21. yüzyılın aktör ve konu açısından yatay ve dikey ekseninde genişleyen küresel siyaset alanında teknolojinin ilerlemesiyle birlikte savaşlarda ve çatışmalarda yapay zekânın manevra kabiliyetini artırdığı tespit edilmiştir. Son çeyrekte, yapay zekânın temelini oluşturduğu bilgi ve haberleşme teknolojileri, robotik ve otonom silah sistemlerinin geleneksel eşleniğinden daha hızlı, daha doğru harekete geçmesi sebebiyle askeri operasyonlarda yer almıştır. Bununla birlikte devletlerin sınır güvenliği de sadece geleneksel yöntemlerle değil yapay zekâyla da desteklenmektedir.

Kuramsal açıdan bakıldığında yapay zekâ uygulamaları: otomatikleştirilmiş, yarı-otonom ve otonom olmak üzere üç ana başlıkta toplanmıştır. Hava savunma sistemleri, uzun menzilli balistik füzeler, kamikaze dronelar ve birçok benzeri uygulama ve araştırma tam otonom silah sistemlerinin yaygınlaşacağına işaret etmektedir. Bununla beraber yapay zekâ temelli silahların kullanımının uluslararası hukuka ve özelinde silahlı çatışmalar hukukuna etkisi üzerine çalışmalar henüz norm oluşturamamış ve bu doğrultuda gerekli uluslararası düzenlemeler noksan kaldığı tespit edilmiştir. Bireyler ve insan hakları bu düzlemde ele alındığında iki farklı açıdan bu hususların değerlendirilmesi gerekliliği ortaya çıkmaktadır. Birincisi geleneksel yöntemlerden ziyade yapay zekâ kullanarak sayıca az personelle ve personelini de daha az riske atarak sözde insan güvenliğini önelediği savı iddia edilmektedir. Öte yandan yapay zekâ kullanımında insanın karar verici mekanizmadan tamamen soyutlanmasıyla hedef doğruluğu kontrolü terkedilmiş ve muhtemel hataların trajik bir şekilde sonuçlanma ihtimalinin önü açılmıştır. Bu noktada yanlışlıkla hedef alınan masum insanları yapay zekâdan kimin koruyacağı akıllarda soru oluşturmaktadır. Gerçekleşen bu tip olaylar incelendiğinde saldırıya karar veren tarafların ve uluslararası hukukun aktif bir karşı duruş içerisinde olmadığı ve bununla beraber herhangi bir düzenleme gayreti içerisine girmediği de görülmektedir. Artan trajik olaylar nedeniyle birey ve devlet güvenliği sağlanmak amaçlanırken ihlallerle beraber yapay zekânın olumsuz yönlerinin uluslararası ilişkilere yansması göz önünde bulundurma ihtiyacı doğmuştur. Bu çalışmada, otomatikleştirilmiş yapay zekâ uygulamalarından hava savunma sistemlerinin bireylerin ve

¹ Orcid 0000-0002-7973-9566

* Sorumlu yazar. Tel.: +90 354 242 1741; fax: +90 354 242 1005.

E-mail: r.iklime.gun@yobu.edu.tr (R.İ.Gün Altun).

devletin güvenliđi genelinde, Ukrayna-Rusya, Kuzey Kore-Güney Kore, Filistin-İsrail özelinde nasıl bir rol aldığına uluslararası ilişkiler perspektifinden bakılmaktadır.

Anahtar kelimeler: güvenlik, kuvvet kullanımı, savaş, silahlı çatışmalar hukuku, yapay zekâ

Impacts of Artificial Intelligence on International Relations

Ranuna İklime GÜN ALTUN²

¹Yozgat Bozok University, Faculty of Economics and Administrative Sciences, Department of International Relations, Yozgat, Turkey

The term *use of force* includes the phenomenon of war with all its features and subtleties in the discipline of international relations. The parties to *use of force* are not only limited to individuals, subnational and transnational agents and states, it also evolves into a process that composed artificial intelligence with its changing character. At this point, it is stated in Clausewitz's work "*On War*" emphasized the nature of war remains the same, but its character has a structure that changes according to period, advancement of technology and its maneuverability. It has been monitored from recent developments that the artificial intelligence is leading these change in the wars of the 21st century. Artificial intelligence has become an vital part of armies with the awareness of its potential to be used in military operations. The use of the artificial intelligence by armies has been rising with its use in areas such as warfare systems, strategic decision making, data processing and research, combat simulations, target recognition, threat monitoring, drone swarm applications, cybersecurity, transportation and healthcare.

With the end of the Cold War, as expressed in the conferences and memorandums of many international and regional organizations, the concept of security has been expanded and transcended political-military security, and it has been integrated into dynamical structure. Individuals as an agent and human rights as a subject have brought a new dimension to security field. It has been determined that artificial intelligence has increased its maneuverability in wars and conflicts with the advancement of technology in the field of global politics, which expands horizontally and vertically in terms of agents and subjects of the 21st century. In the last quarter, information and communication technologies based on the artificial intelligence, have taken part in military operations as robotic and autonomous weapon systems since they are acted faster and more accurately than traditional counterparts. In addition, the border security of states is supported not only by traditional methods but also by artificial intelligence.

From a theoretical point of view, artificial intelligence applications are classified into three main categories: automated, semi-autonomous and autonomous. Air defense systems, long-range ballistic missiles, suicide drones and many similar applications and research refer to fully- autonomous weapon systems that have become widespread. Nevertheless, the studies on the effect of the use of artificial intelligence-based weapons on international law and in particular on the law of armed conflicts have not yet formed a norm, and it has been determined that the fundamental international regulations are lacking accordingly. When individuals and human rights are considered at this level, it becomes indispensable to evaluate these issues from two different perspectives. First, it is claimed that it prioritizes so-called human security by using artificial intelligence rather than traditional methods, with fewer personnel and by putting its personnel life at less risk. On the other hand, with the complete isolation of humans from the decision-making mechanism in the use of the artificial intelligence, a target accuracy control has been abandoned and this pave the way for the inevitable mistakes that results in a tragic end. Herein, the question of who will protect the innocent people, mistakenly targeted from the artificial intelligence, has appeared in minds. When these types of events are examined, it is seen that the parties that decided on the attack and international law did not take an active opposition stance, and did not make any effort to regulate policies. While aiming to ensure individual and state security due to the increasing tragic events, the necessity of considering the artificial intelligence's

² Orcid 0000-0002-7973-9566

* Corresponding author. Tel.: +90 354 242 1741; fax: +90 354 242 1005.

E-mail: r.iklime.gun@yobu.edu.tr (R.İ.Gün Altun).

impacts on international relations has become urgent issue with the violations. In this study, the role of air defense systems as a product of the automated artificial intelligence applications in the security of individuals and the state in general, Ukraine-Russia, North Korea-South Korea, Palestine-Israel in particular has been examined from the perspective of international relations.

Key words: artificial intelligence, law of armed conflicts, security, use of force, war

STOCK TREND PREDICTION AND PORTFOLIO OPTIMIZATION

Mr. Deniz Peksen

Ozyegin University / Faculty of Engineering, Industrial Engineering Department
denizpeksen@gmail.com

Prof.Dr. Okan Örsan Özener

Ozyegin University / Faculty of Engineering, Industrial Engineering Department
orsan.ozener@ozyegin.edu.tr

Abstract

This thesis aims to predict trend movement of closing price of stock and to maximize investment portfolio by utilizing the predictions. In this context, the study aims to define a stock portfolio strategy from models created by using Logistic Regression, Gradient Boosting and Random Forest Methods.

Predicting the trend of stock price has gained a significance role in making buy and sell decisions and generating returns with investment strategies formed by machine learning basis decisions. There are plenty of studies in the literature on the prediction of stock prices in capital markets using machine learning methods but most of them focus on closing prices instead of the direction of price trend. Our study differs from literature in terms of target definition. Our target definition is a classification problem which is focusing on the market trend in next 20 trading days.

To predict trend direction, fourteen years of data were used for training. Following three years were used for validation. Finally, last three years were used for testing.

Training data are between 2002-06-18 and 2016-12-30

Validation data are between 2017-01-02 and 2019-12-31

Testing data are between 2020-01-02 and 2022-03-17

We compared our machine learning basis portfolio return on test data with return of Hold Stock Portfolio, Best Stock Portfolio and USD-TRY Exchange rate.

We assessed our model performance with the help of roc-auc score and lift charts. In our study, we use grid search approach to fine-tune hyper-parameters.

As a result of the empirical study, the existence of uptrend and downtrend of five stocks could not be predicted by the models. When we use the predictions to define buy and sell decisions in order to generate model-based-portfolio, model-based-portfolio fails in test data-set. It was found that Model-based stock portfolio strategy can not outperform non-model portfolio strategies on test data-set.

Keywords: Stock Prediction, Data Science, Machine Learning

Estimation of fission barrier heights for even-even superheavy nuclei using random forest machine learning algorithm

Cafer Mert Yesilkanat¹, Serkan Akkoyun²

¹*Science Teaching Department, Artvin Çoruh University, Artvin, Türkiye,*

ORCID: 0000-0002-7508-7548

²*Department of Physics, Faculty of Science, Sivas Cumhuriyet University, Sivas, Türkiye,*

ORCID:0000-0002-8996-3385

Abstract

We do not yet have clear information on what the heaviest possible atomic nucleus might be. Due to the increased effect of Coulomb repulsion in the superheavy region, and hence alpha emission and fission becoming inevitable, the stability rapidly decreases in this region. With the fission barrier height information, the survival probabilities of superheavy nuclei can also be reached. Therefore, it is important to have accurate knowledge of fission barriers, for example, the discovery of superheavy nuclei in the stability island in the superheavy nuclei region. In this study, the random forest machine learning algorithm was used to accurately predict the fission barriers of 775 even-even superheavy nuclei ($132 \leq N \leq 216$) with proton numbers between 92 and 120. The obtained results were compared both among themselves and with other theoretical model calculation estimates and experimental results.

Keywords: Fission barrier; Superheavy nuclei; Random forest; Mapping

Endüstriyel Tasarımlarda Yapay Zekanın Etkisi ve Geleceği

Münevver Yakut¹, Emine Bozkuş²

Beykent Üniversitesi, Meslek Yüksekokulu, Mülkiyet Koruma ve Güvenlik Bölümü, İstanbul

Yıldız Teknik Üniversitesi, Endüstri Mühendisliği Anabilim Dalı, İstanbul

Özet

Görsel seçiciliğin ön planda olduğu ve yaratıcılık faktörünün etkin olduğu endüstriyel tasarım faaliyetleri küreselleşen piyasalarda oldukça önemli bir yere sahiptir. Üretim ve tüketim arasındaki değişken orana bağlı olarak müşteri memnuniyeti ve ihtiyaçlarına göre üretilen ürünlerin tasarımı rekabet piyasalarında ürünün tercih edilmesinde çok büyük bir etki yüzdeliğine sahiptir. Ürünlerin görselliği, boyutu, işlevselliği, rengi gibi birden çok unsuru baz alarak tasarımlar yapılmaktadır. Endüstriyel tasarımcılar kişilerin talep ve ihtiyaçlarına göre aynı zamanda da rekabet piyasasında ürüne marka değeri katıp öncelikli tercih edilmesi için çeşitli teknolojik kaynaklardan yararlanmaktadır. Üretilen ürünler tasarım aşamasında bilgisayar ortamlarında çeşitli yazılımlar kullanılarak önceden incelenme imkanına sahiptir. Böylelikle üretim aşamasına geçilmeden fark edilen hatalar ve istenmeyen özellikler tespit edilip düzeltmeler yapılabilmektedir. Değişen teknoloji ile birlikte dijitalleşme çağı hızla yeni ürünler ortaya çıkarıp kullanıma sunulmaktadır. Yapay zeka ile insan beyni ve çalışma şekli taklit edilerek yeni teknolojik ürünler ve yazılımlar orta çıkarılmaktadır. Günümüzde birden çok alanda yapay zekadan faydalanılmakla birlikte makine öğrenmesi belirli başlı alanlardan biridir. Yapay zekanın yaygın kullanılmasının birincil nedeni bulut ve uç teknolojiler kullanılmasıyla güçlü ve uygun maliyetli bilgi işlem yeteneklerinin birçok yerde bulunması olup diğer bir neden ise yapay zeka algoritmaları ve veri biliminin giderek artan kapsamıdır. Yapay zeka sistemler, tasarımcıların hayal ettiği ve ifade etmekte zorlandığı tahminlerini sanal ortamda görme imkanı ile çalışmalarını kolaylaştırmaktadır. Yapay zeka yapılandırılmış ve yapılandırılmamış verileri makine öğrenmesi gibi yöntemlerle birlikte analiz edebilmektedir. Endüstriyel tasarımlarda yapay zeka yöntemleri kullanılarak insan hayal gücünün somut hale getirilmesi ile ileri seviyede kaliteli ürün ve hizmetlerin üretimi daha da artabilecektir.

Anahtar Kelimeler—Yapay zeka, endüstriyel tasarımlar, dijitalleşme, teknoloji