



Bildiriler Kitabı | Proceedings Book

II. Uluslararası Yapay
Zeka ve Veri Bilimi
Kongresi

**ICADA
2022**

17-18 Haziran 2022
Online

2nd International Congress on Artificial Intelligence and Data Science

Proceeding Book

2. Uluslararası Yapay Zeka ve Veri Bilimi Kongresi

Bildiriler Kitabı

Editörler/Editors

Prof. Dr. Ayşegül ALAYBEYOĞLU

Doç. Dr. Aytuğ ONAN



İzmir Kâtip Çelebi Üniversitesi Yayın No: 25

Bu eserin, İzmir Kâtip Çelebi Üniversitesi Yönetim Kurulu'nun 09.08.2022 tarih ve 2022-29 sayılı toplantısında alınan 25 kararı uyarınca, elektronik kitap olarak yayımlanmasına karar verilmiştir.

Her hakkı saklıdır.

© İzmir Kâtip Çelebi Üniversitesi Yayınları
2022

Sertifika No: 46629

**Editörler: Prof. Dr. Ayşegül ALAYBEYOĞLU
Doç. Dr. Aytuğ ONAN**

ISBN: 978-605-70737-4-7

International Congress on Artificial Intelligence and Data Science (II. : İzmir : 2022)
2nd International Congress on Artificial Intelligence and Data Science Proceeding Book,
17-18 June 2022 = 2.Uluslararası Yapay Zeka ve Veri Bilimi Kongresi Bildiriler Kitabı, 17-
18 Haziran 2022 / Editors/Editörler: Ayşegül Alaybeyoğlu, Aytuğ Onan. -- İzmir : İzmir
Kâtip Çelebi Üniversitesi, 2022.
Çevrimiçi (127 sayfa : şekil, tablo ; 26 cm.). -- (İzmir Kâtip Çelebi Üniversitesi; Yayın
No: 25)
ISBN: 978-605-70737-4-7
1. Yapay Zeka – Kongreler 2. Veri Bilimi – Kongreler
I. Alaybeyoğlu, Ayşegül – II. Onan, Aytuğ

Adres : İzmir Kâtip Çelebi Üniversitesi Rektörlüğü, Balatçık Yerleşkesi, 35620 Çiğli
İzmir, Türkiye
Telefon : +90 232 329 3535 / 1255 **E-posta** : ykb@ikc.edu.tr
Belge-geçer : +90 232 386 0888 **Web** : ykb.ikc.edu.tr

Eserin hukuki ve etik sorumluluğu yazarlara aittir. Tüm hakları saklıdır. Bu kitabın
yayın hakkı İzmir Kâtip Çelebi Üniversitesi'ne aittir. İzinsiz kopyalanamaz ve çoğaltılamaz.

İçindekiler/Contents

	<u>Page/Sayfa</u>
Invitation/Davet	5-6
Committees/Kurullar	7-9
Congress Program/Kongre Programı	10-13
Proceeding Papers/Tam Metin Bildiriler	15-127

Dear Colleagues and Participants;

We are delighted and honored to invite you to the 2nd International Congress on Artificial Intelligence and Data Science, which will be held online between 17-18 June 2022, hosted by Artificial Intelligence and Data Science Application and Research Center of İzmir Kâtip Çelebi University. The main topics of our congress are the new methods developed in the field of artificial intelligence and the systems developed for the application of artificial intelligence in many different areas such as health, engineering, education, law, marketing and finance, textile, city and regional planning. National and international speakers will be included in our Congress for which we organize to increase interaction and communication, to cooperate, to act together, to share knowledge and experience by bringing together researchers, industrial organizations, public institutions and organizations working in the field of artificial intelligence and data science. Oral presentations will be made on topics related to all areas of artificial intelligence. We hope to see you among us at the 2nd International Congress on Artificial Intelligence and Data Science, which will be enriched with your participation, and thank you in advance for your valuable contribution and participation.

Prof. Dr. Ayşegül Alaybeyoğlu
Chair of the Congress

Değerli Meslektaşlarımız ve Katılımcılarımız;

İzmir Kâtip Çelebi Üniversitesi, Yapay Zeka ve Veri Bilimi Uygulama ve Araştırma Merkezi ev sahipliğinde, 17-18 Haziran 2022 tarihleri arasında online olarak düzenlenecek olan II.Uluslararası Yapay Zeka ve Veri Bilimi Kongresi'ne sizleri davet etmekten büyük mutluluk ve onur duymaktayız.

Kongremizin ana konularını, yapay zeka alanında geliştirilen yeni yöntemler ve mühendislikte yapay zeka ile yapay zekanın sağlık, eğitim, hukuk, pazarlama ve finans, tekstil, şehir ve bölge planlama gibi bir çok farklı alanlarda uygulanmasına yönelik olarak geliştirilen sistemlerin oluşturması planlanmaktadır.

Yapay zeka ve veri bilimi alanında çalışan araştırmacıları, endüstri kuruluşlarını, kamu kurum ve kuruluşlarını bir araya getirerek etkileşim ve iletişimi artırmak, iş birliği içinde olmak, birlikte hareket etmek, bilgi ve tecrübeleri paylaşmak amacıyla düzenlediğimiz uluslararası kongremizde,ulusal ve uluslararası konuşmacılara yer verilecek olup yapay zekanın tüm alanları ile ilgili konularda sözlü bildiri sunumları yapılacaktır.

Katılımlarınızla zenginleşecek olan II. Uluslararası Yapay Zeka ve Veri Bilimi Kongresi'nde sizleri aramızda görmeyi umuyor, değerli katkı ve katılımlarınız için şimdiden teşekkür ediyoruz.

Prof. Dr. Ayşegül Alaybeyoğlu
Kongre Başkanı

COMMITTEES/KURULLAR

Honorary President/Onursal Başkan

Prof. Dr. Saffet KÖSE İzmir Katip Çelebi Üniversitesi Rektörü

Congress Chair/Kongre Başkanı

Prof. Dr. Ayşegül ALAYBEYOĞLU

Organizing Committee/Düzenleme Kurulu

Prof. Dr. Adnan KAYA

Prof. Dr. Ayşegül ALAYBEYOĞLU

Doç. Dr. Merih PALANDÖKEN

Doç. Dr. Aytuğ ONAN

Doç. Dr. Levent AYDIN

Dr. Öğretim Üyesi Erdal ÖZBEK

Dr. Öğretim Üyesi Osman GÖKALP

Dr. Öğretim Üyesi Serpil YILMAZ

Dr. Öğretim Üyesi Esra AYCAN BEYAZIT

Dr. Öğretim Üyesi Onan GÜREN

Scientific Secretariat/Bilimsel Sekreteryä

Fatma Günseli Çıklaçandır fatma.gunseli.yasar@gmail.com

Hande Parlak hndeparlk@gmail.com

SCIENTIFIC COMMITTEE/BİLİMSEL KURUL

Prof. Dr. Abd Samad Hasan Basari	Universiti Tun Hussein Onn Malaysia
Prof. Dr. Adnan Kaya	İzmir Katip Çelebi University
Prof. Dr. Aybars Uğur	Ege University
Prof. Dr. Ayşegül Alaybeyoğlu	İzmir Katip Çelebi University
Prof. Dr. Bilge Karaçalı	İzmir Institute of Technology
Prof. Dr. Bing Zhang	Sichuan University
Prof. Dr. Chirag Paunwala	Sarvajanik College of Engineering and Technology
Prof. Dr. Dunwei Gong	China University of Mining and Technology
Prof. Dr. Filiz Güneş	Yıldız Technical University
Prof. Dr. İbrahim Pirim	İzmir Katip Çelebi University
Prof. Dr. Müştak Erhan Yalçın	İstanbul Technical University
Prof. Dr. Narendra C. Chauhan	A D Patel Institute of Technology
Prof. Dr. Nejat Yumuşak	Sakarya University
Prof. Dr. Özlem Coşkun	Süleyman Demirel University
Prof. Dr. Saurabh Shah	GSFC University
Prof. Dr. Vedvyas Jayprakash Dwivedi	C. U. Shah University
Prof. Dr. Y. Cengiz Toklu	Beykent University
Prof. Dr. Zahriladha Bin Zakaria	Universiti Teknikal Malaysia
Orhan Balbal	Republic of Turkey Court of Cassation
Assoc. Prof. Dr. Ali Turgut	Tepecik Training and Research Hospital
Assoc. Prof. Dr. Amit Thakkar	Charusat University
Assoc. Prof. Dr. Aytuğ Onan	İzmir Katip Çelebi University
Assoc. Prof. Dr. Cemal Hanılçı	Bursa Technical University
Assoc. Prof. Dr. Cheng Jin	Beijing Institute of Technology
Assoc. Prof. Dr. Christos Volos	Aristotle University of Thessaloniki
Assoc. Prof. Dr. Esra Meltem KOÇ	Izmir Katip Celebi University
Assoc. Prof. Dr. Gabriel Bekdaş	İstanbul University- Cerrahpaşa
Assoc. Prof. Dr. Gökçe Nur Yılmaz	TED University
Assoc. Prof. Dr. Hakan Özbaşaran	Eskişehir Osmangazi University
Assoc. Prof. Dr. Mehmet Ali Belen	İskenderun Technical University

SCIENTIFIC COMMITTEE/BİLİMSEL KURUL

Assoc. Prof. Dr. Merih Palandöken	İzmir Katip Çelebi University
Assoc. Prof. Dr. Mohd Sanusi Azmi	Universiti Teknikal Malaysia Melaka
Assoc. Prof. Dr. Mustafa Agah Tekindal	Izmir Katip Celebi University
Assoc. Prof. Dr. Mustafa Emiroğlu	Tepecik Training and Research Hospital
Assoc. Prof. Dr. Nour El Madhoun	Ecole d'ingénieurs informatique Paris-EPITA
Assoc. Prof. Dr. Peyman Mahouti	İstanbul University- Cerrahpaşa
Assoc. Prof. Dr. Sharnil Pandya	Symbiosis International University
Assoc. Prof. Dr. Sinan Melih Niğdeli	İstanbul University- Cerrahpaşa
Assoc. Prof. Dr. Trushit Upadhyaya	Charusat University
Assoc.Prof.Dr. Levent Aydın	İzmir Katip Çelebi University
Assist Prof. Dr. Partha Pakray	National Institute Of Technology Silchar
Assist. Prof. Dr. Ali Murat KOÇ	Izmir Katip Celebi University
Assist. Prof. Dr. Amrithesh Kumar	National Institute Of Technology Silchar
Assist. Prof. Dr. Ayşe Kalaycı ÖNAÇ	Izmir Katip Celebi University
Assist. Prof. Dr. Başak Esin Köktürk Güzel	İzmir Democracy University
Assist. Prof. Dr. Esra Aycan Beyazıt	İzmir Katip Çelebi University
Assist. Prof. Dr. Malaya Dutta Borah	National Institute Of Technology Silchar
Assist. Prof. Dr. Mehmet Erdal Özbek	İzmir Katip Çelebi University
Assist. Prof. Dr. Onan Güren	İzmir Katip Çelebi University
Assist. Prof. Dr. Osman Gökalp	İzmir Katip Çelebi University
Assist. Prof. Dr. Serpil Yılmaz	İzmir Katip Çelebi University
Assist. Prof. Dr. Taimoor Khan	National Institute of Technology Silchar
Assist. Prof. Dr. Volkan Kılıç	İzmir Katip Çelebi University
Assist. Prof. Olgun Aydın	Gdansk University of Technology
Dr. Arpan Desai	Charusat University
Dr. Kadriye Filiz Balbal	Ministry of Education Malaysia-Japan International Institute of Technology,
Dr. Mohd Ibrahim Shapiai Razak	Universiti Teknologi Malaysia
Dr. Sümeyye Sınır	İzmir Katip Çelebi University
Dr. Tuğbanur Özen Balaban	İzmir Katip Çelebi University
Dr. Zihao Chen	Harbin Institute of Technolgy

II. Uluslararası Yapay Zeka ve Veri Bilimi Kongresi (ICADA 2022), 17-18 Haziran 2022 (Online)

CONGRESS PROGRAM / KONGRE PROGRAMI

17.06.2022	10.30- Cuma 10:40	Açılış Konuşmaları		
	10:40- 11:00	Prof. Dr. Ayşegül Alaybeyoğlu	İzmir Katip Çelebi University, Congress Chair	
	11:00- 11:30	Prof. Dr. Saffet Köse	İzmir Katip Çelebi University, Rector	
		Davetli Konuşmacılar		
	11:30- 12:00	Prof.Dr. Tülay Yıldırım	Yıldız Technical University	Challenges with data and privacy in artificial intelligence
	12:00- 12:30	Dr Frank Hopfgartner	Information School of University of Sheffield	Exploring Lifelog Archives - A Case for Data Scientists
	12:30- 13:00	Dr. Şükrü Ozan	Adres Gezgini Kurucu Ortağı	The Importance of Deep Learning and Machine Learning in Call Center Operations

CONGRESS PROGRAM / KONGRE PROGRAMI

17.06.2022 Cuma		
OTURUM 1: 14:00-15:00, OTURUM BAŞKANI: Dr. Öğr. Üyesi Esra AYCAN BEYAZIT		
4832	Emrah İnan	A Turkish Metaphor Detection Method Using Masked Language Models
635	Fatma Günseli Çıklaçandır, Samet Çıklaçandır, Semih Utku	Ensemble Learning Based Classification of Infected and Uninfected Cells
7313	Ensar Arif Sağbaş, Serkan Ballı	Davranışsal Biyometri ve Makine Öğrenmesi Kullanılarak Akıllı Telefon Yetkilendirmesi Üzerine Kısa Bir İnceleme
2111	Kadir Kaan YAZGAN, Yunus NOGAY, Sudenur ATA, Ahmet Berkay SARIASLAN Gökçe Nur YILMAZ	Sleep detection system
7455	Serkan Ansay, Bayram Köse	Meteorolojik Parametrelere Dayalı NARX Yapay Sinir Ağı Kullanarak Yağış Tahmini
OTURUM 2: 15:00-16:00, OTURUM BAŞKANI: Dr. Öğr. Üyesi Serpil YILMAZ		
986	Harun Yeşilkaya, Ayşegül Alaybeyoğlu	Smart Web University System for People with Disabilities: Case of İzmir Katip Çelebi University
7299	Vasif Nabiyev, Eyüp Ensar Kalaycı	Satranç Figür Seslendirmelerinin Mel Ölçeği ve Ses Görüntüsü ile Yapay Sinir Ağları Kullanılarak Sınıflandırılması
8896	Şevket Umut Çakır, Vasif Nabiyev	Street Fighter için Genetik Programlama Kullanarak Yapay Oyuncu Geliştirme
8769	Aybike Özyüksel Çiftçioğlu	Machine Learning to Predict Ultimate Pressure Load for Concrete-Filled Steel Tube Columns
7111	Ertuğrul Orman, Bayram Köse	İzmir Bakırçay Üniversitesi Güneş Enerji Santralinin Elektrik Üretiminin Saatlik Tahmini

CONGRESS PROGRAM / KONGRE PROGRAMI

17.06.2022 Cuma		
OTURUM 3: 16:00-17:00, OTURUM BAŞKANI: Dr. Öğr. Üyesi Osman GÖKALP		
6027	Hilal Koçak, Gürcan Çetin	Classification of Generative Adversarial Networks Used in the Development of Facial Recognition Systems
3163	Behlul Sarikaya, Aybars Ugur	Farklı Veri Artırım Teknikleri ile Derin Öğrenme Tabanlı Cilt Lezyonu Tespiti
1055	Utku Işıl, Yunus Emre Yurdagül, Okan Vural, Kaan Çelik, Haluk Atli, Devrim Ünay, Murat Sağlam.	Automatic Equipment Effectiveness and Status Detection System Based on Image Processing and Advanced Analytical Methods
1431	Berkan Yüce, Murtaza Cicioğlu, Ali Çalhan	Makine Öğrenmesi Kullanılarak Dünya Kupası Müsabakalarının Analizi
7323	Umut Atakul, Mustafa Cem Orhan	Task Activation Latency Characteristics on Real Time System Schedulers
OTURUM 4: 17:00-17:50, OTURUM BAŞKANI: Doç. Dr. Aytuğ ONAN		
9793	Ekrem Akar	Machine Learning Based WLAN Antenna Design For 5.2 GHz Frequency Band
8497	Gökçen Demirbaş	2.4 GHZ Antenna Design for New Generation Wireless Communication
6258	Yasar Kaplan, Cem Göçen	U-Shaped Slotted Patch Antenna Design for 2.4 GHz Wireless Applications
1921	Selin HACIOĞLU, Tahsin ÜSTÜNEL, Gökçe Nur YILMAZ	Color detection with clothes
8261	Cem Göçen, Mehmet Ali Belen, Peyman Mahouti, Adnan Kaya, Merih Palandöken, Ömür Ceran, Ozan Tanergeç	Data Driven Modelling of Dual Band Microstrip G- Shape Radiator Antenna

CONGRESS PROGRAM / KONGRE PROGRAMI

18.06.2022 Cumartesi		
OTURUM 5: 10:00-10:50, OTURUM BAŞKANI: Doç. Dr. Merih PALANDÖKEN		
6865	Kubilay Ayturan, Fırat Hardalaç, Bo Hai, Fatih Mert	Seçili Metin Verisinin İşlenmesi ve Graf Veritabanında Sorgulanması
	Yasemin Gülay Tonguç	Sanatta yapay zeka örnekleri ve dijital sanatta özel algoritmalar
7184	Farid Bagheri, Derya Eren Akyol	Interpreting Black-Box Machine Learning Algorithm through Anomaly detection of Mobile ad hoc networks
2389	Kadriye Filiz Balbal	Makine Öğrenmesi Yöntemleri İle Tutumun Tahmin Edilmesi
7449	Farid Bagheri, Derya Eren Akyol	Non-destructive Contactless Quality Control In The Agroalimentary Supply Chain
1492	Aykutalp Özkuyumcu, Ahenk Karcı Demirkol, Ayşe Kalaycı Önaç	Mimarlık Disiplininde Sanal Gerçeklik Teknolojisi Kullanımı
10:50-11:00	KAPANIŞ	

Tam Metin Bildiriler | Proceeding Papers

Ensemble Learning Based Classification of Infected and Uninfected Cells

Fatma Günseli ÇIKLAÇANDIR ^{1,*}, Samet ÇIKLAÇANDIR ², Semih UTKU ³

¹ Computer Engineering Department, İzmir Katip Çelebi University, Turkey, fatma.gunseli.yasar@gmail.com

² Biomedical Engineering Department, İzmir Katip Çelebi University, Turkey, samet.cikla@gmail.com

³ Computer Engineering Department, Dokuz Eylül University, Turkey, semih@cs.deu.edu.tr

Abstract

Malaria is a disease in which diagnosis and treatment are important, and a waste of time and misdiagnosis can result in death. For this reason, studies for systems that will help the specialist to evaluate the patients has been started. In this study, six different approaches are used for feature extraction, namely discrete cosine transform, principal component analysis, gray level co-occurrence matrix, local binary patterns, ResNet18 and GoogLeNet. The extracted features are classified with Adaboost based on ensemble learning. In the study, in which six different metric results, namely accuracy, sensitivity, specificity, F1 score, time, and accuracy/time, were presented, the approach that performed the best feature extraction for the problem addressed was investigated.

Keywords: *Malaria; classification; ensemble learning.*

1. Introduction

Health is the greatest gift given to us. Malaria is one of the most dangerous diseases for human health [1]. It is a disease caused by five different Plasmodium species: P.falciparum, P.malariae, P.ovale, P.knowlesi, and P.vivax. P.falciparum poses the greatest threat to humans [2]. However, all species have the potential to cause significant illness and death. This disease manifests itself with symptoms such as fever, vomiting, chills, sweating and weakness after an average of 7 days of incubation period. Early diagnosis and treatment are important to save the patient's life. Therefore, the diagnosis stage of the disease is important. Diagnosing individuals with the diseases as healthy causes the diseases to progress, while diagnosing healthy individuals as sick causes them to be exposed to side effects of drugs due to unnecessary drug use.

With the development of technology, there is an increasing trend in the demand for automated systems. Automated systems have advantages in terms of diagnostic reliability and cost. These systems are less likely than human-based estimations to be incorrect. However, considering the possibility of even a low probability when it comes to human life, full automation is not recommended, especially in the field of health. It is recommended to start the appropriate treatment after the decision of the designed system is approved by a specialist.

When the past studies are examined, it is seen that the studies carried out in recent years are generally based on convolutional neural network (CNN). Loh et al. [3] developed Mask R-CNN, which performs classification in a shorter time and with higher accuracy (82%) compared to human-based diagnosis. Çınar and Yıldırım [4] compared the performances of six different CNN methods (AlexNet, Resnet50, DenseNet201, Vgg19, GoogleNet and Inceptionv3). In addition, the effects of two different filters (medium and gaussian) were investigated. As a result of the study, it is seen that the best results were obtained (97.83%) when DenseNet201 was applied to gaussian filtered images. Liang et al. [5] developed a model based on 16-layer CNN. The developed model performed better than transfer learning (97.37%). Sriporn et al. [6] obtained the most accurate results (99.28%) when they combined Nadam and Mish with Xception in their studies testing different optimizers, activation functions and methods. Dong et al. [7], when testing LeNet-5, AlexNet, GoogLeNet and SVM on their own datasets, it is seen that CNN-based models classify data with over 95% accuracy, while classification is performed with approximately 92% accuracy when using SVM.

In this study, an investigation has been carried out on the performances of various feature extraction approaches. In feature extraction, CNN-based approaches and non-CNN-based approaches are compared. Classification was carried out with Adaboost which is based on ensemble learning.

2. Materials and Methods

2.1. Data set

In this study, a dataset containing malaria cell images from Kaggle [8] was used. It contains a total of 27.558 images, of which 13.779 are infected and 13.779 are not (Figure 1).




Figure 1. Samples from dataset (a) Uninfected samples (b) Malaria infected samples

2.2. Feature extraction methods

Six different approaches were used to extract features in the study. The first four approaches (discrete cosine transform, principal component analysis, gray level co-occurrence matrix, local binary patterns) are based on statistical measurements, while the last two approaches (ResNet18, GoogLeNet) are based on CNN.

Discrete cosine transform (DCT) and Discrete Fourier Transform (DFT) are similar [9]. DCT gives the frequency domains of images. If the image has a high frequency component, it is understood that these pixels contain any defects. The two-dimensional DCT of the image is calculated as in Equation (1), with $A(x,y)$ being an input image of size $M \times N$. The coefficients $C(m)$ and $C(n)$ in the equation are taken as $1/\sqrt{2}$ when m and n are zero, and 1 in other cases.

$$T(m, n) = \frac{2}{\sqrt{MN}} C(m)C(n) \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} A(x, y) \cos \frac{\pi(2x+1)m}{2M} \cos \frac{\pi(2y+1)n}{2N} \quad (1)$$

Principal Component Analysis (PCA) is the process of reducing a large number of connected variables to a smaller number of new variables that do not have any correlations. In this method, where the image matrix is taken as an input, the average of all the elements in the matrix is found. Then, the average is subtracted from each element. After calculating the eigenvalues and eigenvectors with the help of the covariance matrix, the PCA vector is obtained.

The Gray Level Co-occurrence Matrix (GLCM) is based on statistical measurements [11]. Four different statistical GLCM properties (contrast, correlation, energy, homogeneity) were used in the study (Table 1). M is a gray level image matrix with each (i,j) pixel value between 0 and 255. Contrast value calculates local variations in M . The correlation value calculates the linear dependence in M . In the equation, σ is the standard deviation and μ is the mean. The energy value is the sum of the squares of the elements in M . The homogeneity value gives the homogeneity of M .

Table 1. GLCM.

Contrast	$\sum_{i,j} i - j ^2 M(i, j)$
Correlation	$\sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)M(i, j)}{\sigma_i \sigma_j}$
Energy	$\sum_{i,j} M(i, j)^2$
Homogeneity	$\sum_{i,j} \frac{M(i, j)}{1 + i - j }$

Local binary patterns (LBP) perform an assignment according to the result obtained by comparing the center pixel with the surrounding pixels in the 3×3 neighborhood of the pixel for each pixel in the image [12]. Equations used in feature calculation using LBP are given in (2) and (3). g_m is the gray value of the center pixel, and g_k is the value of the center pixel's neighbors. P is the total number of neighboring pixels and R is the neighborhood radius.

$$LBP_{P,R} = \sum_{i=0}^{P-1} s(g_k - g_m) 2^i \quad (2)$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3)$$

There are many different types of deep learning architectures created by increasing the number of layers in artificial neural networks. Convolutional Neural Network (CNN) is one of these architectures. CNN is a multilayer artificial neural network model built specifically for computer vision applications. It is an approach that provides higher performance than other classification methods. ResNet18 [13] and GoogLeNet [14] approaches used in this study are pre-trained CNN-based approaches. In order for the input images to be processed in these two approaches, the images must be 224×224 in size. Taking its name from the words 'Residual Network', ResNet18 has 18 convolution layers. The inception modules used in [14] have made GoogLeNet deeper.

2.3 Classification

Ensemble Learning (EL) is a method for classification based on predictions from multiple classifiers. It uses the knowledge of multiple classifiers simultaneously to apply the result of each classifier by consensus. This method outperforms a single classifier in most cases. The fact that the errors of the classifiers are different from each other improves the ensemble classification performance. Different subsets of the training dataset are used to obtain the differences in the predictions of the classifiers. Predictions from trained networks must be combined to arrive at a final result. The choice of the correct coupling approach for the predictions has a great influence on the classification performance in the ensemble learning method. There are many ensemble learning approaches based on assembly procedures, sample selection for the training dataset, and processing processes. Bagging, boosting and voting are three of these approaches [15]. In this study, Adaboost algorithm, which is an increment-based classifier, was used.

3. Experimental Results

In this study, all methods (DCT+EL, PCA+EL, GLCM+EL, LBP+EL, ResNet18 + EL, GoogLeNet + EL) were compared in terms of six metrics: accuracy, sensitivity, specificity, F1 score, time, and accuracy/time (Table 2). In the study, 5-fold cross validation was preferred as the validation method. Since the classifiers are the same in all methods, it can be said that the success rates obtained show the success rates of the approaches used for feature extraction. According to these results, it is seen that the most successful feature extraction approach is GoogLeNet with 92.91% accuracy. In feature extraction with ResNet18, results were as successful as GoogLeNet (92.74%). When classified with EL, the method with the worst success was DCT+EL with an accuracy rate of 56.50%.

Table 2. Classification Performance

Method	Accuracy	Sensitivity	Specificity	F1
DCT+EL	56.50%	56.36%	55.19%	54.33%
PCA+EL	62.10%	65.88%	59.83%	44.92%
GLCM+EL	66.60%	73.69%	62.74%	60.65%
LBP+EL	77.90%	80.41%	75.75%	76.93%
ResNet18 + EL	92.74%	93.74%	91.79%	92.66%
GoogLeNet + EL	92.91%	92.82%	92.59%	92.70%

In Table 3, a new metric is given in addition to the completion times of the methods used. Due to the use of the same classifier in the methods, the time metric varies depending on the feature extraction approach used. In order to embody this, the accuracy/time ratios of the methods were also examined.

When comparing two methods that terminate in different times and have the same accuracy rate, the method that terminates in a shorter time should be preferred. Because one has a higher accuracy/time ratio. As the completion time increases, the accuracy/time ratio decreases. The GLCM+EL method, which has an accuracy of 66.60%, is the method with the highest accuracy/time ratio (170.77). However, the success rate of this method is quite low, especially compared to ResNet18 and GoogLeNet. From this, it is concluded that Table 2 and Table 3 should be compared together and the best method should be chosen. Considering the malaria disease discussed in the study, a few minutes delay in diagnosis may not be fatal for the patient, but a misdiagnosis that will mislead the specialist carries a fatal risk. Therefore, methods with high accuracy are more preferable in problems where time is not the first priority.

Table 3. Comparisons based on time.

Method	Time	Accuracy/Time
DCT+EL	3.98 min	14.20
PCA+EL	1 min	62.10
GLCM+EL	0.39 min	170.77
LBP+EL	0.84 min	92.74
ResNet18 + EL	9.92 min	9.35
GoogLeNet + EL	11.42 min	8.14

4. Conclusion

Six different methods (DCT+EL, PCA+EL, GLCM+EL, LBP+EL, ResNet18 + EL, GoogLeNet + EL) were examined in this study, which was designed to help experts in order to prevent time loss in the diagnosis of malaria parasite, where time is important. While classification in all methods is performed with Adaboost, which is an EL algorithm, feature extraction methods are different. All 27,558 different images in the dataset were used in the study, in which the performances of four different non-CNN-based approaches (DCT, PCA, GLCM, LBP) and two different CNN-based approaches (ResNet18, GoogLeNet) were investigated.

Methods were compared using metrics of accuracy, sensitivity, specificity, F1 score, time, and accuracy/time. According to the experiments, when this data set is used, it has been observed that the feature extraction with CNN-based approaches gives results with an accuracy rate of over 92%. However, CNN-based feature extraction has its advantages as well as disadvantages. In this study, when using CNN-based approaches, it is seen that these approaches are disadvantageous in terms of time while performing classification with high accuracy.

References

- [1] F. Yang, M. Poostchi, H. Yu, Z. Zhou, K. Silamut, J. Yu, Z. Zhou, K. Silamut, J. Yu, R. J. Maude, S. Jaeger, and S. Antani, "Deep learning for smartphone-based malaria parasite detection in thick blood smears," *IEEE Journal of Biomedical and Health Informatics*, vol. 24, no. 5, pp. 1427-1438, 2019.
- [2] B. J. Neves, R. C. Braga, V. M. Alves, M. N. Lima, G. C. Cassiano, E. N. Muratov, F. T. Costa, and C. H. Andrade, "Deep Learning-driven research for drug discovery: Tackling Malaria," *PLoS Computational Biology*, vol. 16, no. 2, 2020.
- [3] D. R. Loh, W. X. Yong, J. Yapeter, K. Subburaj, and R. Chandramohanadas, "A deep learning approach to the screening of malaria infection: Automated and rapid cell counting, object detection and instance segmentation using Mask R-CNN," *Computerized Medical Imaging and Graphics*, vol. 88, 101845, 2021.
- [4] A. Çinar, and M. Yildirim, "Classification of Malaria Cell Images with Deep Learning Architectures," *Ingénierie des Systèmes d'Inf.*, vol. 25, no. 1, pp. 35-39, 2020.
- [5] Z. Liang, A. Powell, I. Ersoy, M. Poostchi, Silamut, K., Palaniappan, K., Guo, P., Hossain, M., Sameer, A., Maude, R.J., Huang, J.X., Jaeger, s., and Thoma, G., "CNN-based image analysis for malaria diagnosis", *IEEE International Conference on Bioinformatics and Biomedicine*, 493-496, 2016.
- [6] K. Sriporn, C.F. Tsai, C. E. Tsai, and P. Wang, "Analyzing Malaria Disease Using Effective Deep Learning Approach," *Diagnostics*, vol.10, no. 10, 744, 2020.
- [7] Y. Dong, Z. Jiang, H. Shen, W. D. Pan, L. A. Williams, V. V. Reddy, W. H. Benjamin, and A. W. Bryan, "Evaluations of deep convolutional neural networks for automatic identification of malaria infected cells," *IEEE EMBS International Conference on Biomedical & Health Informatics*, pp. 101-104, 2017.
- [8] Kaggle: Your Machine Learning and Data Science Community. <https://www.kaggle.com/datasets/iarunava/cell-images-for-detecting-malaria>.
- [9] N. Ahmed, T. Natarajan, and K. R. Rao, Discrete cosine transform. *IEEE Transactions on Computers*, vol. 100, no. 1, pp. 90-93, 1974.
- [10] K. Pearson, "On lines and planes of closest fit to systems of points in space," *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, vol. 2, no. 11, pp. 559-572, 1901.
- [11] R. M. Haralick, K. Shanmugam, and I. H. Dinstein, "Textural features for image classification," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 6, pp. 610-621, 1973.
- [12] N. Abbas, T. Saba, A. Rehman, Z. Mehmood, H. Kolivand, M. Uddin, and A. Anjum, "Plasmodium life cycle stage classification based quantification of malaria parasitaemia in thin blood smears," *Microscopy research and technique*, vol. 82, no. 3, pp. 283-295, 2019.
- [13] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778, 2016.
- [14] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, and A. Rabinovich, "Going deeper with convolutions," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1-9, 2015.
- [15] E. Karal, and M. Turan, "Assistant in diagnosis for doctor, artificial intelligence supported disease detection specialist", *European Journal of Science and Technology*, Special Issue 26, pp. 100-116, 2021.

ENGELSİZ ÜNİVERSİTE İÇİN AKILLI WEB SİSTEMİ : İZMİR KATİP ÇELEBİ ÜNİVERSİTESİ ÖRNEĞİ

SMART WEB UNIVERSITY SYSTEM FOR PEOPLE WITH DISABILITIES: CASE OF İZMİR KATİP ÇELEBİ UNIVERSITY

Harun YEŞİLKAYA ¹, Ayşegül ALAYBEYOĞLU²

¹ Yazılım Mühendisliği Anabilim Dalı, İzmir Katip Çelebi Üniversitesi, İzmir, harunyesilkaya@gmail.com

² Bilgisayar Mühendisliği Bölümü, Yapay Zeka ve Veri Bilimi Uygulama ve Araştırma Merkezi, İzmir Katip Çelebi Üniversitesi, İzmir, aysegul.alaybeyoglu@ikc.edu.tr

Özet

Bu çalışmanın amacı görme engelli bireylerin üniversite web sayfalarında diğer engelsiz kullanıcılarla eşit erişilebilirlik faaliyetlerini gösterebilmesini sağlamaktır. Bu kapsamda İzmir Katip Çelebi üniversitesi web sayfasına (<https://ikc.edu.tr>) kullanıcıların sesle iletişime geçeceği sesli asistan özelliği eklenmiştir. Kullanıcılar sesli olarak üniversitenin alt sayfalarına erişebilmekte; sayfalar içerisindeki duyuruları, etkinlikleri ve haberleri yine sesli komutlarla sonrasında dinleyebilmektedirler. Bu işlemlerin hepsi sistem üzerindeki dinamik yapılardır. Sabit veriler üzerinden değil sistemin editörlerinin güncel olarak girdiği bilgilerin sesli dönüşümleri yapılmaktadır. Sisteme eklenen sesli asistan sesli olarak verilen komutları algılayabilmekte; sistemde bulunan yazı içeriklerini kullanıcıya sesli olarak dönmektedir. Sesi algılamada bu yaklaşımlarda en çok kullanılan algoritmalar olan Long Short-term Memory Recurrent Neural Networks(LSTM-RNN) kullanılmıştır.

Anahtar Sözcükler: *Derin öğrenme, Konuşma Tanıma*),*LSTM (Uzun Kısa Süreli Bellek),RNN (Yinelemeli Sinir Ağı)*.

Abstract

The aim of this study is to enable visually impaired individuals to show equal accessibility activities with other non-disabled users on university web pages. In this context, a voice assistant feature has been added to the İzmir Katip Çelebi University web page (<https://ikc.edu.tr>) with which users can communicate by voice. Users can access the sub-pages of the university by voice; afterwards, they can listen to the announcements, events and news within the pages with voice commands. All of these processes are dynamic structures on the system. Voice transformations of the information currently entered by the editors of the system are made, not through fixed data. The voice assistant added to the system can detect voice commands; the text content in the system is returned to the user audibly. Long Short-term Memory Recurrent Neural Networks (LSTM-RNN), which is one of the most used algorithms in these approaches, is used to detect sound.

Keywords: *Deep Learning, LSTM (Long-Short Term Memory), RNN (Recurrent Neural Networks), Speech Recognition.*

1. Giriş

İletişim, duygu, düşünce veya bilgilerin akla gelebilecek her türlü yolla başkalarına aktarılması, bildirişim, haberleşme, iletişim olarak tanımlanmaktadır ki iletişimin en büyük aracı da konuşma olarak kabul edilir [1, 2].

Aile ve Sosyal Hizmetler Bakanlığı'nın Ulusal Engelli Veri Sisteminde 2.6 milyon vatandaş bulunmaktadır. Sistemde görme engelli kişi sayısı 215 bin 76'dır [3]. Görme engellilerin dijital ortamda engelsiz bireylerle aynı yetkinliklere ve kullanım koşullarına sahip olmaları amaçlanmalıdır. Sosyal sorumluluk çerçevesinde bu kapsamda yapılan çalışmalar oldukça önemlidir.

Milli kütüphanenin sağlamış olduğu konuşan kitaplık sayesinde okunan kitapların kaset ve cd'lere kaydedilmiş ve görme engelli bireylerin kullanımına sunulmuştur.[4] Hacettepe üniversitesinde engelli bireyler için açılan bilgisayar laboratuvarında 2 adet bilgisayara kurulan JAWS 7.10 ve GVZ programları sayesinde ekran okuması sağlanmaktadır [5]. Geliştirilen mobil yön yardım cihazı ile GPS yardımıyla Gazi Üniversitesi Kampüsü içerisinde sesli yön bulma işlemi gerçekleştirilmiştir[6]. Görme engellilere bilgisayar eğitimi veren web uygulaması sayesinde engellilerin öğrenime katkı sağlanması amaçlanmış öğrenim tarafında başarılı olunmuş fakat eğitim için sağlanan kaynakların eksikliği gözlemlenmiştir[7]. AB'nin finanse ettiği Hayat Boyu Öğrenme programı

kapsamında geliştirilen Dicomp Transfer Projesi ile görme engellilerin Office uygulamaları ve genel internet kullanımını alanlarında başarılı sonuçlar elde edilmiştir [8]. [9]'da Microsoft işletim sistemi üzerinde çalışabilen dikteapi'yi kullanan sesi analiz edip mail gönderimi yapabilen uygulama geliştirilmiştir.


Çalışmanın devamında görme engelli bireylerin sesle iletişim kurabildiği üniversitemiz web sayfası dijital ortamında konuşmasının optik kelime karşılığının tespiti sonrasında komut olarak algılanması ve sonrasında da konuşma olarak cevap verilmesi veya komut sonucunda işlem yapılması süreçlerinde kullanılan yöntemlerinden bahsedilmiş ve sistem ara yüzlerine yer verilmiştir.

2. Sistem Alt Yapısı ve Yöntemler

2.1. Saklı Markov Modeli

Saklı markov modeli ülkemizde ve dünyanın bir çok bölgesinde konuşmadaki zaman bazında değişikliklere uğramasından dolayı en çok tercih edilen modeldir.

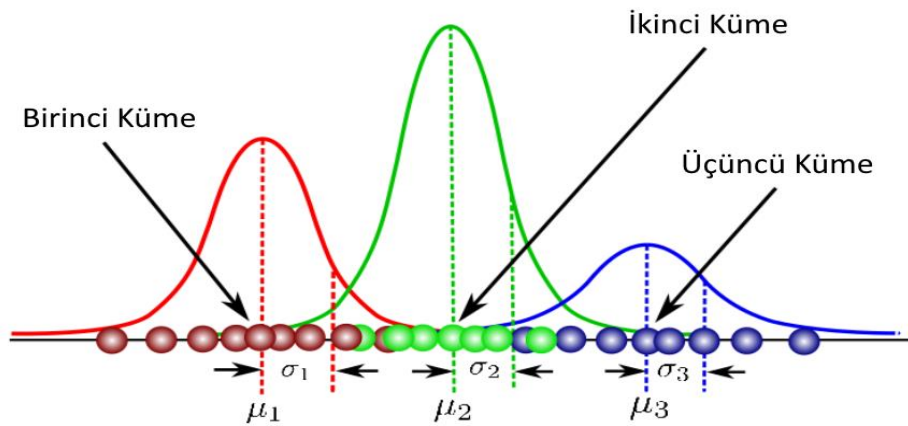
$P(X_t=j|X_{t-1}=i)$ olarak formülize edilir. t zamanı x değişkenleri i ilk konumu j geçiş sonraki konumu temsil eder



Şekil 1. Saklı Markov Modeli[10]

2.2. Gauss Karışım Modeli

Gauss Karışım modeli akustik verinin tespitinde öznelilik katsayılarının SMM hizalama hesaplarının tespiti için kullanılmaktadır.




Şekil 2. Gauss Karışım Modeli[11].

μ kümenin orta noktasını σ ise kesişim noktasını temsil etmektedir. Bunun gibi hizalama olasılıklarını tahminlemede kullanılan başka bir yöntem ise ileri beslemeli derin sinir ağlarıdır.

2.3 Yinelemeli Sinir Ağları (RNN)

Sıralı olarak elde edilen verileri hesaplamak için üretilen bir yapay sinir ağı yaklaşımıdır. Evrişimli sinir ağları veriler arasında uzamsal bir bağlam olması durumunda ele alınacak bir yapıdır. Ayrıca evrişimli sinir ağları veri kümesi olarak büyük dağıtık yapılarda ölçeklenebilir ve bu dizileri işleyebilir[12]. Şekil 3 te x girdiyi h çıktısı temsil etmektedir. A ise işlemin tekrarlılığını göstermektedir.




Şekil 3. Yinelemeli Sinir Ağı[13].

$h_t = f(h_{t-1}, x_t)$ olarak formülize edilen yapıda H_t : Şu anki h değerini; H_{t-1} : Bir önceki h değeri ise X_t : şu anki girdi vektörü temsil etmektedir.

Yinelemeli Sinir ağları Elman Ağları, Jordan Ağı ve Uzun kısa vadeli bellek modeli olarak 3 ayrı alt grubu vardır. Konuşma tanıma yapısında zaman bazında değişikliklere uğramasından dolayı uzun kısa vadeli bellek kullanılmaktadır.

2.4. Uzun Kısa Vadeli Bellek(LTSM)

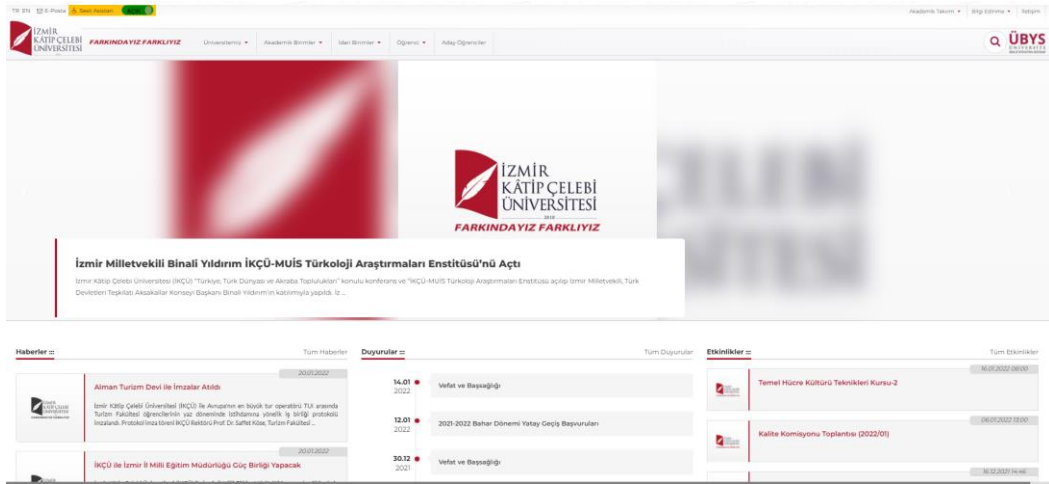
Uzun kısa süreli bellek sinir ağı elman ve jordan ağlarına benzer bir yapıya sahiptir. Farkı ise nöronlar ile gizli birimler arasında bir bellek yapısı içermesidir[14]. Bu bellek yapısına LSTM hücresi denir.yapısında zaman bazında değişikliklere uğramasından dolayı uzun kısa vadeli bellek kullanılmaktadır.



Şekil 4. Uzun Kısa Vadeli Bellek[15].

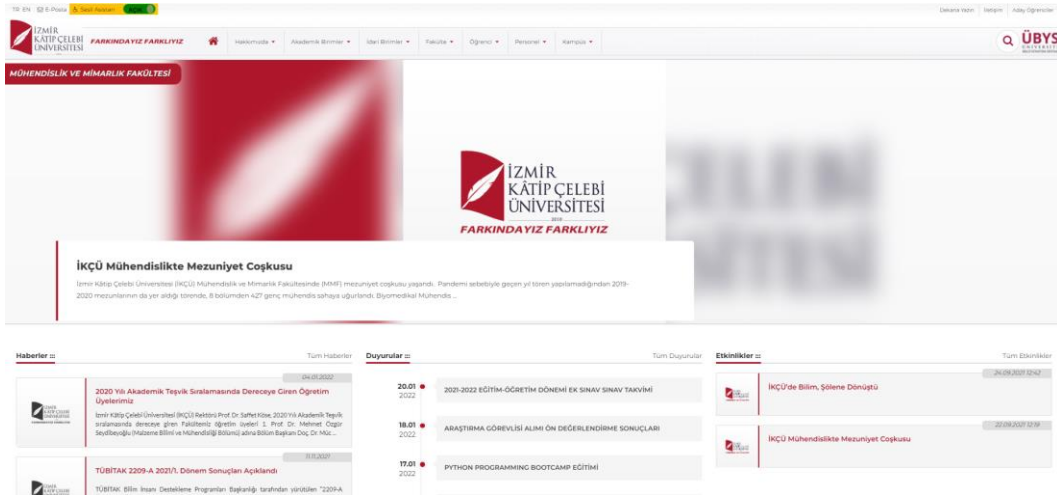
Bir LTSM hücresinde (Şekil 4) uzun vadeli durumu c_t kısa vadeli durumu ise h_t vektörleri temsil etmektedir. LSTM hücresinde amaç depolanacak ve unutulacak verilerin eğitiminin yapılmasıdır. c_{t-1} anından gelen x kapısından geçer ve verilerin bir kısmı burdan çıkarılır sonrasında c_t üzerinden dışarı alınan veri bir sonraki girişte daha az veriyle işleme başlamış olur. Elde edilen verilerin bir kopyası tanjant aktivasyonuna uğrar. Bu kısımda kısa vadeli durum h_t üretilmiş olur.

3. Geliştirilen Uygulama ve Arayüzleri



Şekil 5. Uygulama Giriş Sayfası. (İzmir Katip Çelebi Üniversitesi Ana Sayfa)

İzmir Katip Çelebi Üniversitesi Web Sayfasına görme engelli bireylerin siteyi rahatlıkla kullanabilmeleri için sesli asistan eklenmiştir. Bu sesli asistan ile kullanıcılar klavye yardımıyla sesli olarak iletişime geçebilmekte ve sistemdeki haberleri duyuruları ve etkinlikleri dinleyebilmektedir. Sistem üzerinde bulunan diğer alt sayfalara yine aynı şekilde sesli komut ile erişebilmektedirler. Alt sayfalarda da yine aynı senaryoyu işletebilmektedirler.



Şekil 6. Uygulama İç Sayfası. (Mühendislik Mimarlık Fakültesi Sayfası)

Sistem Html5 standartlarında ses dinlemesi sağlamaktadır. Asp.net MVC ile yazılan uygulamaya kaydı alınan ses yığını gönderilmektedir. LSTM kullanılarak konuşmanın karşılığı tespit edilmekte sistemin cevaplayabileceği bir konuşma yığını ile karşılaşıldıysa sesli olarak web sayfası üzerinden kullanıcıya geri dönüş sağlanmaktadır. Eğer cevaplanamayacak yada anlaşılamiyan bir konuşma yığını ile karşılaşıldıysa kullanıcıya tekrar sesli aksiyon verilmesi için cevap dönülmektedir.

4. Genel Değerlendirme ve Sonuç

Bu çalışma kapsamında geliştirilen yazılım sistemi ile Görme Engelli bireylerin üniversitemiz web sayfasında sayfalar arasında rahatlıkla konuşarak dolaşabilmeleri ve sayfalardaki ilgili bilgilere sesli iletim yolu ile ulaşabilmelerini sağlayan bir yazılım sistemi geliştirilmiştir. Çalışma devam etmekte olup, geliştirilen yazılım sistemini üniversitemiz Görme Engelli öğrencileri tarafından kullanımını sağlayarak, yapılacak olan anket ve analizler ile çalışmanın katkısı akademik olarak değerlendirilecektir.

Referanslar

- [1] <https://sozluk.gov.tr/>.
- [2] <https://acikders.ankara.edu.tr/mod/resource/view.php?id=74315>
- [3] <https://www.aile.gov.tr/haberler/evde-bakim-hizmetinden-yararlanan-gorme-engelli-sayisi-39-bini-asti>
- [4] R. Bakırcı , Milli Kütüphane’de Görme Engellilere Sunulan Hizmetler ve Gelişmeler, 1.Ulusal Körler ve Kütüphanecilik Sempozyumu, Ankara, 100 -104 2007
- [5] <https://engelliler.gen.tr/konular/goerme-engelliler-dicomp-ile-interneti-rahatca-kullanabilecek.5727/>
- [6] https://acikbilim.yok.gov.tr/bitstream/handle/20.500.12812/712180/yokAcikBilim_416702.pdf?sequence=-1&isAllowed=y
- [7] <http://www.edebiyat.hacettepe.edu.tr/eb1.php>
- [8] <https://dspace.gazi.edu.tr/bitstream/handle/20.500.12602/177511/?sequence=1&isAllowed=y>
- [9] Nursel YALÇIN, Ülkü ÜLKER (2011) Görme Engelliler İçin Ses Analizi İle E-posta İletimi BİLİŞİM TEKNOLOJİLERİ DERGİSİ, CİLT: 4, SAYI: 3, EYLÜL 2011
- [10] https://burakbayramli.github.io/dersblog/tser/tser_080_hmm/sakli_markov_modelleri__hidden_markov_models_hmm_.html
- [11] <https://towardsdatascience.com/gaussian-mixture-models-explained-6986aaf5a95>
- [12] W Fedus, I Goodfellow, AM Dai - arXiv preprint arXiv:1801.07736, 2018 - arxiv.org ICLR 2018 <https://arxiv.org/abs/1801.07736>
- [13] <https://www.datacamp.com/community/tutorials/tutorial-for-recurrent-neural-network>
- [14] S Hochreiter, J Schmidhuber - Neural computation, 1997 <https://ieeexplore.ieee.org/abstract/document/6795963>
- [15] https://www.researchgate.net/figure/Structure-of-the-LSTM-cell-and-equations-that-describe-the-gates-of-an-LSTM-cell_fig5_329362532

Görüntü İşleme ve İleri Analitik Yöntemler Tabanlı Otomatik Makine Durumu ve Verimliliği Tespit Sistemi

Automatic Equipment Effectiveness and Status Detection System Based on Image Processing and Advanced Analytical Methods

Utku İŞİL¹, Yunus Emre YURDAGÜL², Okan VURAL³, Kaan ÇELİK⁴, Haluk ATLI⁵, Devrim Ünay⁶, Murat SAĞLAM⁷

Supply Chain Wizard Teknoloji LTD. ŞTİ. Ar-Ge Merkezi, İzmir, Türkiye,

¹ utku.isil@supplychainwizard.com,

² yunusemre.yurdagul@supplychainwizard.com,

³ okan.vural@supplychainwizard.com,

⁴ kaan.celik@supplychainwizard.com,

⁵ haluk.atli @supplychainwizard.com,

⁷ murat.saglam @supplychainwizard.com,

⁶ İzmir Demokrasi Üniversitesi, Elektrik-Elektronik Mühendisliği, İzmir, Türkiye, unaydevrim@gmail.com

Özet

Üretim endüstrisinde genel ekipman verimliliği (OEE), üretim süreçlerinin takibi ve geliştirilmesi için gerekli bir parametredir [Nakajima, 1988]. OEE hesabının yapılabilmek için karar destek sistemlerine bağlanabilmesi için temelde sahadaki üretim hattının anlık durumunun sağlıklı şekilde sayısal hale getirilip verileştirilmesi vardır. Bu bağlamda geliştirdiğimiz çözüm, endüstride verimlilik takibi ve veri güdümlü karar verebilmek için gerekli olan üretim hattı durumu ve OEE verisinin ideal bir şekilde toplanabilmesine olanak sağlamaktadır. Mevcut çözümlerde bulunan sorunlar, video görüntü işleme ve derin öğrenme / makine öğrenmesi gibi ileri analitik yöntemler ile aşılmıştır. Video verilerinde nesne tespiti problemin çözümü için literatürde geleneksel görüntü işleme yaklaşımlarını [Dalal, 2005] veya makine öğrenmesi yöntemlerini [Felzenszwalb, 2010] kullanan çok sayıda çözüm mevcuttur. Son yıllarda derin öğrenme yöntemleri nesne tespitinde de başarılı sonuçlar vermiştir [Girshick, 2014]. Bu ileri yöntemlerin kullanımı ile sunduğumuz çözümün yenilikçi yönü, her üretim hattı için farklı olabilecek görüntüleri kendi kendine öğrenen, yani üretim hattı durumunu otomatik kestiren bir sistem olmasıdır.

Anahtar Sözcükler: *Derin Öğrenme, Görüntü İşleme, Makine Öğrenmesi, OEE.*

Abstract

Overall equipment effectiveness (OEE) is a necessary metric for monitoring and improving production processes in industry [Nakajima, 1988]. In order to make the OEE calculation properly, one needs to digitize the accurate data coming from the production line on the shopfloor, which is a challenge itself. The solution we present provides the accurate collection of production line status and OEE data required for monitoring and decision making. The problems found in existing solutions are overcome with advanced analytical methods such as video image processing and deep learning / machine learning. There are many solutions in the literature using traditional image processing approaches [Dalal, 2005] or machine learning methods [Felzenszwalb, 2010] to solve the object detection problem in the video. In recent years, deep learning methods have also yielded successful results in object detection [Girshick, 2014]. The innovative aspect of the solution we offer is that it is a system that learns patterns that may be different for each production line, and automatically predicts the production line status.

Keywords: *Deep Learning, Video Processing, Machine Learning, OEE.*

1. Giriş

Endüstride bir hattın verimli ve kaliteli üretim yapacak şekilde çalışır durumda olması, planlı ya da plansız nedenlerle hat durma süresinin minimuma indirilmesi ile mümkündür. Bu hedefe üretim hattının durumunu temsil eden verilerin doğru bir şekilde toplanması ile ulaşılabilir. Bu noktada, sahadan verinin uygun maliyetle, yaygın şekilde ve kaliteli (doğru) toplanabilmesi hususları öne çıkmaktadır. Sunduğumuz çözümde, üretim sahasındaki makinelerin üretim durumunu gösteren görsel işaretler (sinyal kuleleri) görüntü işleme ve makine öğrenmesi teknolojileri ile yorumlanarak, üretim hattının analizini sağlayan yapay zekâ tabanlı bir yazılım geliştirilmiştir.

2. Amaç

2.1. Mevcut uygulamaların eksiklikleri ve yetersizlikleri

Hat durumu verisinin doğru, ekonomik ve ölçeklenebilir şekilde toplanabilmesine engel olan problemler şu şekilde listelenebilir: (1) Maliyet: Piyasada önerilen mevcut sistemler yüksek maliyetli cihaz entegrasyonu (örn. Programmable Logic Controller [PLC] entegrasyonu) gerektirmektedir. PLC entegrasyonu üretim hattındaki tüm makine bileşenlerine tek tek elektriksel bağlantı yapma ya da yazılım katmanında her bir makinenin protokolünü anlayan uyumlu karşı yazılımı geliştirmeye tekabül eder. Ancak bu şekilde maliyetli entegrasyonlar sonucunda veri çeşitliliği ve kalitesine ulaşılabilir. (2) Ölçeklenebilirlik: Bir üretim firması maliyetli entegrasyon yapsa dahi uygulanan çözüm değişen protokoller, marka model çeşitliliği düşünüldüğünde üretim hattını oluşturan her bileşen makine için sil baştan tekrar edilmelidir. (3) Veri Kalitesi: Maliyet problemini aşmaya çalışan alternatif çözümler ise entegrasyon olmadan bir arabirim vasıtası ile operatörden veri toplayarak hat durumu hakkında veri elde edebilir. Ancak insana bağımlı operatör veri girişi hata ve sapmalara açıktır.

2.2. Ortaya konulan çözümün amacı

Sağladığımız “Görüntü İşleme ve İleri Analitik Yöntemler Tabanlı Otomatik Makine Durumu ve Verimliliği Tespit Sistemi”, firmalarının üretim hattı durumunun, yani OEE verisinin, verimli şekilde toplanabilmesine olanak sağlayan mevcut çözümlerin aksine, maliyet düşüklüğü, ölçeklenebilirlik ve veri kalitesi anlamında öne çıkmaktadır. Konvansiyonel yüksek efor/maliyet/zaman gerektiren PLC entegrasyonu benzeri uygulamaların aksine, yenilikçi olarak “görüntü işleme”, “makine öğrenmesi” (spesifik olarak “derin öğrenme”) yöntemleri kullanılmaktadır. “Öğrenebilen” sistem, operatör hatalarından bağımsız, ölçeklenebilir ve veri güdümlü karar sistemlerini besleyebilecek inovatif bir çözümdür.

3. Materyal ve Yöntem

3.1. Endüstriyel üretim hatlarından IP kamera ile video bazlı veri toplama

Üretim hattının bulunduğu ortama yerleştirilen geniş açılı, yüksek çözünürlüklü IP kamera sayesinde üretim ortamı sürekli olarak izlenmektedir. Yerleştirilen bu kamera ile üretim ortamından elde edilen gerçek-zamanlı video verisi, görüntü işleme ve makine öğrenmesi yöntemleri kullanılarak üretim hattının durumu, örn. üretme modu, âtıl durumda duruş, arıza kaynaklı duruş gibi oluşan durumlar ve hattı oluşturan alt makinelerin durum tespiti yapılmaktadır.

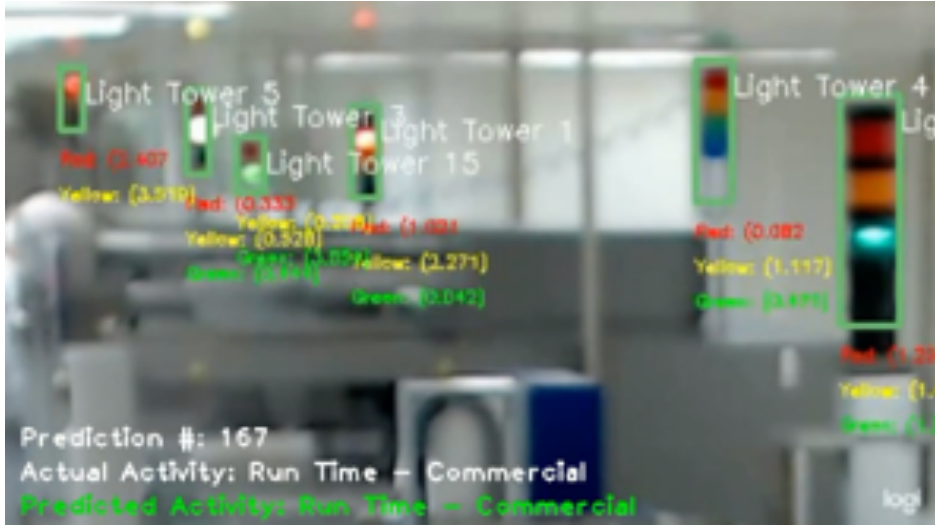
3.2. Veri etiketleme ve işaret kulelerinin tespiti

Anlamlı görsel işaretin videonun hangi bölgesinde olduğunun sağlıklı tespiti için, operatör video kayıtlarında sinyal kulelerini içine alan ilgi alanlarını (region-of-interest) seyrek aralıklarla (örn. günde 1 defa) işaretleyerek (dikdörtgen içine alarak) sisteme veri eklemektedir. Üretilen bu etiketli veri, görüntü işleme ve makine öğrenmesi temelli çözümlerin geliştirilmesi için kullanılmaktadır. Bu aşamada video verisinden sinyal kulelerinin otomatik tespiti derin öğrenme ile gerçekleştirilmektedir. Tespit edilmiş sinyal kulesi ilgi alanları kullanılarak video çerçevelerinden (frame) ışık bilgisi elde edilmektedir. Her sinyal kulesine ait ışık bilgisi zaman-serisine çevrilerek çok-kanallı zaman-serisi üzerinde makine öğrenmesi/derin öğrenme kullanılarak arızanın üretim hattının hangi makinesinde oluştuğu belirlenmektedir. Bu çerçevede sinyal kulelerinin otomatik tespiti için bölge temelli evrişimsel sinir ağları (region-based convolutional neural networks) ve YOLO (You Only Look Once) gibi derin öğrenme mimarilerinden faydalanılmıştır. Bu mimarilerin problemimize uyarlanması için öğrenme aktarımı (transfer learning) yaklaşımı kullanılmış ve mimarilerin ilk katmanlarına ait ağırlık değerleri sabit tutularak sadece son katmanları etiketli verimiz ile eğitilmiştir. Derin öğrenme mimarisinin çıktısı, video verisinde sinyal kulelerinin yerlerini belirten ilgi alanlarıdır (region-of-interest).

3.3. Hat durumunu temsil eden zaman serisi oluşturma

Sinyal kulesi tespiti sayesinde elde edilen ilgi alanları kullanılarak her bir video çerçevesinde sinyal kulelerinin sinyalizasyon/reng bilgisi çıkarılmaktadır. Bu amaçla ilgi alanı içine düşen piksellerin renk dağılımları renk histogramı kesişimi (color histogram intersection), renk eş-oluşum matrisi (color co-occurrence matrix), baskın renk temsili gibi çeşitli görüntü işleme yaklaşımları RGB, HSV gibi farklı renk uzaylarında koşturulmaktadır ve en iyi yaklaşım kullanılarak sinyal kulelerindeki renkler tespit edilmektedir (Bkz. Şekil 1). Çok-kanallı zaman-

serisinden hangi anda hangi makinede arıza olduğunun tespitini gerçekleştirebilmek için operatör tarafından etiketlenmiş veriyi kullanarak hem geleneksel makine öğrenmesi yaklaşımlarının hem de derin kalıntı ağları (deep residual networks), uzun kısa-süreli bellek (long short-term memory) gibi verideki zamansal bağlantılıktan (temporal coherence) faydalanan derin öğrenme yaklaşımları kullanılmaktadır.



Şekil 1. Üretim hattı video kaydından bir kesit. Hattaki sinyal kuleleri algoritma tarafından tespit edilmiş aynı zamanda hat durumu kulelerin sağladığı sayısal veri derin öğrenme modeli tarafından skorlanarak doğru şekilde kesitirilmiştir.

3.4. Kullanılan veri seti

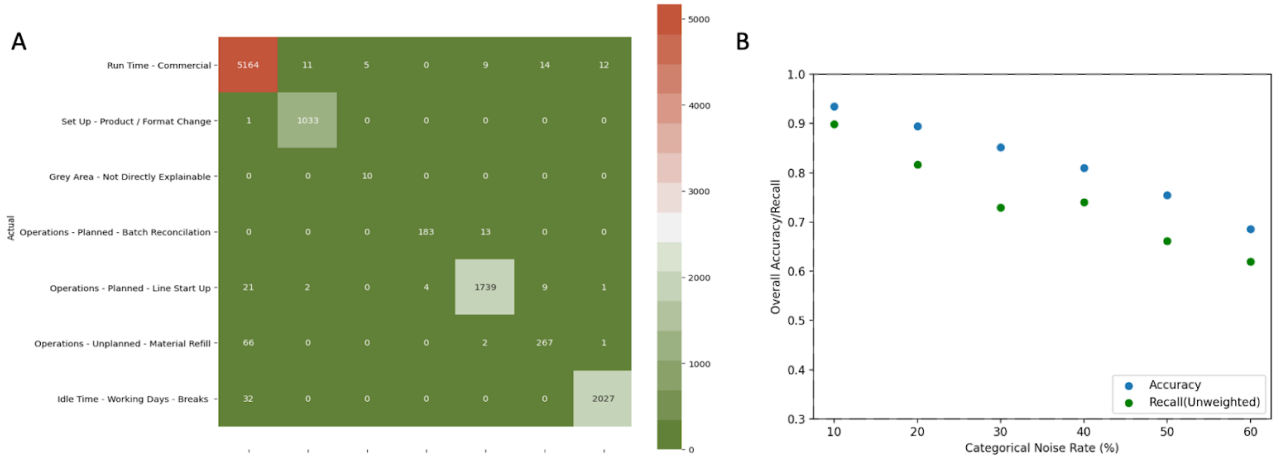
Kullandığımız veri seti iki farklı kategoriye ayrılmaktadır:

- Görüntü verisi: Kullanılan video, saniyede 30 çerçeve olmak üzere toplam 8 saat 56,6 dakikadır. Bütün veri seti 32197 çerçevedir $[(8*60)+56,6]*60$. Kamera hattın makinelerine bağlı olan 6 ışık kulesini gözlemleyecek şekilde konumlandırılmıştır. Işık kuleleri, 9 saatlik bu video üzerinde, saniyede bir çerçeve örneklenecek şekilde sırasıyla YOLO ve DeepSORT modelleriyle tespit edilmiştir. Takip edilen kuleler bir renk aralıklandırma algoritmasıyla 1 saniye aralıklı, 8 saniyelik sliding window zaman serisine dönüştürülmüştür.
- Hat Durum Kestirimi İçin Etiket Verisi: Hat durum kestirimi safhasında, eğitimi ve testi gerçekleştirebilmek adına, hat durum etiketleri toplanmıştır. Bunun için, hat operatörlerinden, hattın durum etiketlerini doğru zamanda, doğru bir şekilde işlenmesi istenmiştir. Elde edilen veri setinde, ortalama 25,5 dakikalık aralıklı, toplamda 21 farklı hat durumu değişimi mevcuttur.


4. Bulgular

4.1. Makine öğrenmesi uygulamaları

GRU makine öğrenme algoritması, veri seti %67 eğitim ve %33 test olacak şekilde rastgele bölünerek saha verisi üzerinde uygulanmıştır. Bu bağlamda modelin öğreniminde ayarlama yapılan hiper parametreleri şöyle listenebilir: Epoch, Batch Size, Hidden Layer Sayısı, Hidden Layer Aktivasyon Fonksiyonu. Bu hiper parametre denemeleri sırasında en iyi sonuçlardan birini veren parametre seti de şu şekildedir: Epoch: 300, Batch Size: 256, Hidden Layer Sayısı: 3, Aktivasyon Fonksiyonu: ReLu. Bu parametre setiyle eğitilen modelin testte gösterdiği performans metrikleri şöyledir: Doğruluk: 0.9809 Duyarlılık: 0.9545. Bu performansı temsil eden karışıklık matrisi ise Şekil 2A'da görülebilir. Modelin performansının bu hiper parametrelerdeki değişimlerden nasıl etkilendiğini gözlemlemek amaçlı bir çalışma yapılmıştır. Şekil 3'de hiper parametre setindeki parametrelerden her birinin izole değişiminin Doğruluk ve Duyarlılık ölçütlerine karşı grafikleri görülebilir.



Şekil 2. A) GRU performans matrisi B) Noise-injection analizi



Şekil 3. Hiper parametre setindeki elemanların izole edilmiş şekilde Doğruluk ve Duyarlılık ölçütlerine karşı grafikleri

4. Sonuç ve Öneriler

Elde edilen sonuçlar 3 ana başlıkta toplanabilir: (1) Makine öğrenmesi modelinin video verisi üzerinde görsel belirteç ilgi alanlarını tutarlı tespiti için yapılan saha uygulamalı denemelerde, 6 kulenin minimum 4'ünün rastgele seçilen 500 çerçeve içerisinde tespit edilme oranı hedef olarak belirlenmiştir. 4 kulenin tespit edilebilmesi aktivite kestirimi için yeterli olduğundan, nesne tespiti için 4 kule hedef kabul edilmiştir. Sonuç olarak %90 oranında (463/500) başarı yakalanmıştır. (2) Görüntü işleme fazından çıkan zaman serisinin üretim hattı durumunu tutarlı kestirimi konusunda, GRU çıktılarını göze alındığında %97 gibi oldukça yüksek bir başarı oranı yakalanmıştır. Bu başarı oranı, üretim hattı durumunun detay seviyede kestirimi için de geçerlidir. Detay seviye kestirimi ile ilgili 'etiketleme' sistemi geliştirilmiş, makine öğrenmesi sistemlerinin öğrenmeye çalıştığı ilişki, yani "hat durumu"- "ışık kulesi ışık yanma örüntüsü" arasındaki bağıntı başarılı bir şekilde gerçekleştirilmiştir. Operatör örneğin duruş tuşuna basıp daha sonra karşısına çıkan ekranda duruş sebebini seçebilmekte ve ilgili duruma "etiket" verisi girilmesi suretiyle detay seviyede kestirime olanak sağlamaktadır. (3) Sahada görülebilecek olumsuz durumların analizi için, görüntü işleme fazından çıkan zaman serisinin kesintiye uğramalarına karşı gürbüzlüğü (robustness) kontrol edilmiştir. YOLO ve DeepSORT algoritmalarının kullanarak elde edilen çıktılarının sonuçlarına göre, %10 seviyesinde 'noise injection' uygulanan durumda %95 doğruluk oranında başarı yakalanmıştır. Farklı 'noise injection' seviyelerindeki başarılı oranları için aşağıda bulunan Şekil 2B'de görülebilir.

Sonuç olarak sağlanan yöntem ve uygulamalar, yüksek başarı oranları ile endüstride geliştirilerek, daha az maliyetli ve teknolojik bir çözüm olarak kullanılabilir.

Referanslar

- [1] S. Nakajima, An Introduction to TPM, Productivity Press, Portland, OR, 1988
- [2] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in CVPR, 2005
- [3] P. F. Felzenszwalb, R. B. Girshick, D. McAllester, and D. Ramanan, "Object detection with discriminatively trained part-based models," IEEE Trans. Pattern Anal. Mach. Intell., vol. 32, pp. 1627–1645, 2010
- [4] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," in CVPR, 2014

Makine Öğrenmesi Kullanılarak Dünya Kupası Müsabakalarının Analizi

Analysis of World Cup Competitions Using Machine Learning

Berkan YÜCE¹, Murtaza CİCİOĞLU^{2,*}, Ali ÇALHAN³

¹ Bilgisayar Mühendisliği, Bursa Uludağ Üniversitesi, Türkiye, 031690066@ogr.uludag.edu.tr

² Bilgisayar Mühendisliği, Bursa Uludağ Üniversitesi, Türkiye, murtazacicioglu@uludag.edu.tr

³ Bilgisayar Mühendisliği, Düzce Üniversitesi, Türkiye, alicalan@duzce.edu.tr

Özet

Nesnelerin interneti gibi yeni yaklaşımlar ile üretilen veri miktarı her geçen gün artmaktadır. Bu ham verilerden anlamlı desenler ortaya çıkarmak farklı sektörlere çözümler sunabilmektedir. Futbol sektöründe de bu veriler birçok amaç için kullanılabilir. Ayrıca üretilen bu veriler de futbolun gelişmesine katkı sunabilmektedir. Futbol içinde yayıncılık, antrenman ve sağlık bilimi, yetenek avcılığı gibi birçok alt sektör birbirleri ile çok yakından etkileşim halindedir. Futbol maç sonuçlarının tahmin edilmesi, futbolun tüm paydaşları için önemli bir değer taşımaktadır. Futbol maç tahminleri, izleyicilere daha ayrıntılı yayın yapan yayıncı kuruluşlar, takımlara en doğru oyuncuyu bulmaya çalışan yetenek avcıları, doğru taktiği geliştirmeye çalışan teknik adamlar gibi futbolun her alanında kullanılmaktadır. Bu çalışmada, geçmiş maç sonuçları, takımların kuvvetleri ve takımların dünya sıralamaları kullanılarak bir makine öğrenmesi modeli geliştirilmiştir. Geliştirilen model 2018 Dünya Kupası'nda oynanan son 16 maça uygulanmış ve yaklaşık %70 başarı göstermiştir.

Anahtar Sözcükler: *Futbol Maç Tahmini, Destek Vektör Makinesi, Makine Öğrenmesi.*

Abstract

The amount of data produced by new approaches such as the Internet of Things is increasing day by day. Revealing meaningful patterns from these raw data can offer solutions to different sectors. In the football industry, these data can be used for many purposes. In addition, these data can contribute to the development of football. Many sub-sectors in football such as broadcasting, training and health science, and talent hunting are in close interaction with each other. Predicting football match results has an important value for all stakeholders of football. Football match predictions are used in all areas of football, such as broadcasters that broadcast to the audience in more detail, talent scouts trying to find the right player for the teams, and technical guys trying to develop the right tactic. In this study, a machine learning model has been developed by using the past match results, the strengths of the teams and the world rankings of the teams. The developed model has been applied to the last 16 matches played in the 2018 World Cup and has achieved approximately 70% success.

Keywords: *Football Match Prediction, Machine Learning, Support Vector Machine.*

1. Giriş

İnternette ve günlük hayatta üretilen veri miktarının artması ve bu veriler ile üretilen katma değerli projeler birçok sektöre çözüm sunmaktadır. Futbolda ise antrenörler, futbolcular, yetenek avcıları, yayıncı kuruluşlar futbol verileri ile rakip analizi, oyuncu analizi, maç analizi gibi amaçlar hedeflenmektedir. Bu amaçla gelecekte oynanacak maçlar makine öğrenmesi teknikleri ile tahmin edilebilmektedir. Profesyonel hayatın her alanında olduğu gibi futbolda da verilerin etkisi oldukça yüksektir. Oyuncu antrenmanları verilere göre düzenlenir, teknik direktörler rakip verilere göre futbol maçlarını analiz eder, futbolcular verilerine göre piyasa değerini arttırmaktadır. Bu nedenle futbolda makine öğrenmesi kullanımı son yıllarda yükselişe geçmiştir. Dünyanın en önde gelen kulüpleri antrenmanlarında, maçlarda, oyuncu transferlerinde makine öğrenmesinden faydalanmaktadır. Bir forvet oyuncusunun attığı goller, defans oyuncusunun yediği kırmızı kart, topun oyunda kalma süresi, sol ayakla atılan goller gibi birbirinden farklı birçok veri üretilmektedir. Bu verilerden katma değer yaratmak ise veri analizleri ve makine öğrenmesi algoritmaları ile mümkündür.

Makine öğrenmesi, sistemlerin deneyimleri ve ürettikleri veriler yoluyla davranışlarının öğrenilmesi ve iyileştirilebilen bilgisayar algoritmalarının incelenmesidir [1], [2]. Makine öğrenmesi, istatistik, yapay zekâ, bilgisayar bilimi ve istatistiksel öğrenme konularının kesiştiği disiplinler arası veriden bilginin ayıklanması ile ilgilenen bir alandır. Makine öğrenme algoritmaları, sonucu bilinen örnekleri analiz ederek bir karar mekanizması oluşturan denetimli öğrenme ile öncesinden herhangi bir etiket, puan gibi sonuçların verilmediği denetimsiz öğrenme olmak üzere farklı kategorilere ayrılmaktadır [2], [3]. Çalışmamızda denetimli öğrenme algoritmaları

kullanılmıştır. Denetimli öğrenme algoritmalarında girdi ve çıktı verileri arasındaki örüntüler tespit edilmeye çalışılmaktadır. Bu algoritmalar, verilen girdiler ve çıktılar arasındaki ilişkiyi tespit etmeye çalışmaktadır. Akabinde oluşturulan modele daha önce hiç görmediği bir girdi verildiğinde modelin herhangi bir insan yardımı olmadan kendi kendine sonuç vermesi beklenmektedir. Makine öğrenmesi problemlerinin çözümünde belli adımlar takip edilmektedir. Bunlar sırasıyla; problemi tanımlamak, veri toplama, veri düzenleme, ön işleme, veri görselleştirme, modelin eğitimi, test işlemleri ve model iyileştirilmesi olarak sıralanabilir. Model oluşturma aşamasında kullanılacak olan metotlar problemin tanımında belirlenen duruma göre şekillenmektedir. Eğer aranan sonuç sürekli bir değer ise bu problem regresyon modelleri ile çözülürken, ayrık değerler ise sınıflandırma modelleri ile çözülürken.

Futbol maç sonuçlarının tahmin edilmesi bir sınıflandırma problemi olarak ele alınmaktadır [4]–[6]. Bir futbol turnuvasında sonuçlar, tur atlayan takım ve elenen takım şeklinde iki sınıfa ayrılabilir. Ancak atılan gollerin maç başına ortalaması düşük olduğu için (maç başına 2-3) bir oyuncunun anlık hatası veya dalgınlığı nihai sonucu doğrudan etkileyebilmektedir. Bu nedenle, tahmini kolaylaştıracak özellikleri ve sınıflandırma yöntemini seçmek büyük bir sorundur [4], [7].

Yazarlar [4], futbolun en popüler etkinliklerinden biri olan Şampiyonlar Ligi üzerinde makine öğrenmesi algoritmalarını kullanmışlardır. Maçlar sonuçlarının yaklaşık %68 doğrulukla yapay sinir ağı kullanılarak tahmin edebilecek bir yazılım sistemi önermişlerdir. Yazarlar [5], maç ve oyuncu özelliklerine dayalı olarak futbol oyunlarının sonucunu tahmin etmek için makine öğrenimini kullanmışlardır. 2006 ve 2018 yılları arasında Avrupa'nın en büyük beş futbol liginin ve bunlara karşılık gelen ikinci liglerin tüm maçlarını içeren bir benzetim çalışması yapılmış ve Rastgele orman ile %81.26 oranında doğruluğa sahip bir model geliştirilmiştir. Futbol maçları için makine öğrenmesi kullanılan birçok çalışma bulunmaktadır [4], [7]–[9].

Bu çalışmada makine öğrenmesinde kullanılan sınıflandırma algoritmaları ile futbol maç sonuçlarını tahmin eden bir makine öğrenmesi modeli geliştirilmiştir. Bu modelin amacı; geçmiş maç sonuçlarına, takımların güçlerine ve dünya sıralamalarına bakarak gelecekte oynanacak maçlar hakkında bir tahmin yapmaktır. Yapılan uygulamanın tüm kaynak kodları için [10] numaralı referansta bulunmaktadır.

2. Amaç materyal ve yöntem

Makine öğrenmesi modelinde kullanılacak özelliklerin seçimi konusunda farklı yaklaşımlar bulunmaktadır. Bunlardan biri, sorun hakkında (bu durumda futbol maçları) biraz bilgi sahibi olduğuna ve bu bilgiye dayanarak nihai sonucu en çok etkileyeceğine inanılan özellikleri seçmektir. Diğer bir yol, problem hakkında çok az bilgi sahibi olduğuna veya hiç bilgi sahibi olunmadığı ve bu nedenle sonucu etkileyebilecek tüm özellikleri seçip ardından en büyük etkiye sahip olanların kademeli olarak belirlenmeye çalışıldığı yöntemdir [4]. Bir maçın sonucunu etkileyebilecek çok sayıda özellik ve bunları toplamadaki birçok sorun nedeniyle, bu çalışmada ilk yaklaşım kullanılmıştır. Geliştirilecek olan makine öğrenmesi modelinin amacı, dünya kupası son 16 turunda tur atlayacak takımları bulmaktır. Modelde üç farklı kaynaktan toplanan veri setleri kullanılmıştır. Bu veri setlerinde her yıla ait FIFA video oyununda bulunan ülkelerin güçleri, takımların FIFA dünya sıralamaları ve geçmişe ait maç sonuçları bulunmaktadır. Üç farklı kaynaktan toplanan veri setleri incelendiğinde 2004-2008 yılları arasında oynanan 1071 adet maç tespit edilmiştir. Nihai modelde kullanılmak üzere beş farklı özellik seçilmiştir. Takımın Defans Gücü, Takımın Orta Saha Gücü, Takımın Atak Gücü, Takımın Ortalama Gücü, Takımın İlgili Yıldaki Dünya Sıralaması.

Her ne kadar Dünya Kupası maçları tarafsız sahalarda oynansa da milli takımların turnuvadan önce eleme maçları farklı ülkelerde oynanmaktadır. Bu durum ev sahibi takımların kendi sahalarını, iklimlerini, vb. durumlara daha aşina olmasından dolayı maçlara daha avantajlı olarak başladıkları şeklinde yorumlanabilir. Nitekim yapılan bir araştırmada elde edilen verilere göre ev sahibi takımların maçı kazanma oranı %12 daha fazladır [11]. Bu araştırmadan yola çıkılarak elde edilen 1071 maçtan ev sahibi takımın kazandığı rastgele 171 maç çıkarılmıştır. Model, geriye kalan 900 maç ile geliştirilmiştir. Aynı zamanda, tur atlayan takımı bulma problemi, 0 ve 1 gibi ayrık sonuç üreten bir çıktıya sahip olduğu için, turnuvada tur atlayan takımın tahmin edilmesi bir sınıflandırma problemi olarak ele alınmıştır. Geçmiş maç sonuçlarına sahip olduğuna için çalışmada aşağıda açıklanan sınıflandırma algoritmaları kullanılmıştır. Lojistik regresyon sınıflandırma problemlerinde kullanılan bir makine öğrenme algoritmasıdır. Bu modelin amacı, deneysel verileri verilen bir Y rastgele değişkeninin 0 veya 1 olma olasılığını modellemektir [12]. Destek Vektör Makinesi, eğitim verilerindeki herhangi bir noktadan en uzak olan iki sınıf arasında bir karar sınırı bulan, vektör uzayı tabanlı makine öğrenmesi yöntemidir. Sınıflandırma problemlerinde kullanılmaktadır [13]. Rastgele orman sınıflandırıcısı ise sınıflandırma, regresyon ve diğer görevler için, eğitim aşamasında çok sayıda karar ağacı oluşturarak problemin türüne göre sınıflandırma veya regresyon tahmini yapan makine öğrenmesi yöntemidir. Rastgele orman sınıflandırıcısı, karar ağaçlarının eğitim

setlerini aşırı öğrenmesi problemini gidermektedir [14]. Veri kaynağı olarak StatsBomb [15] şirketinin açık kaynaklı sağladığı veritabanı kullanılmıştır. Yazılım dili olarak Python kullanılmış olup, Streamlit, Matplotlib, Seaborn, Pandas, Numpy gibi kütüphanelerden faydalanılmıştır. Geliştirilen uygulama Streamlit kütüphanesi yardımı ile web tabanlı olarak paylaşılmıştır [10].

3. Bulgular

Model oluşturulmadan önce eldeki verilerin ne olduğunun analiz edilmesi gerekmektedir. Geliştirilecek olan model eldeki veri seti ile ne kadar uyumlu olursa model o kadar başarılı geliştirilebilir. Takımların güç dağılımı; güçsüz, orta, güçlü olacak şekilde üç gruba ayrılmıştır. En güçlü takımların kimler olduğu ve takımların ortalama güçleri ile aralarındaki farklar, takımların sahip olduğu defans, orta saha, atak güçlerinin dağılımı incelenmiştir. İspanya'nın 2007'den 2018'e kadar en güçlü takım olduğu tespit edilmiştir.

Lojistik Regresyon, Destek Vektör Makinesi ve Rastgele Orman sınıflandırıcısı kullanılarak eğitilen modelin performans sonuçları bu bölümde verilmiştir. Aşağıda kullanılan üç farklı denklemin uygulanması ile modelin farklı makine öğrenmesi algoritmalarında elde ettiği doğruluk, kesinlik ve duyarlılık değerleri bulunmuştur. Buna göre elde edilen doğruluk parametresi, modelin doğru olarak tahmin ettiği maçların oynanan tüm maçlara oranını gösterir. Kesinlik, modelin pozitif olarak tahmin ettiği maçların, gerçekteki pozitif durum ile ne kadar örtüştüğünü gösterir. Duyarlılık ise doğru pozitif tahmin etmesi gereken maçların kaçının doğru tahmin ettiğini gösterir. Bu değerlere bakıldığında Tablo 1'de makine öğrenmesi sınıflandırma algoritmaları için elde edilen doğruluk, kesinlik ve duyarlılık sonuçları verilmiştir. Destek Vektör Makinesi, Rastgele orman sınıflandırıcısı ve Lojistik Regresyon için sırasıyla %75, %70 ve %73 doğruluk sonuçları bulunmuştur. Bu değerler ışığında futbol maçlarının tahmini için Destek Vektör Makinesi modelinin tercih edilmesi gerektiği görülmektedir.

$$\text{Doğruluk} = (DP + DN) / (DP + YP + YN + DN), \text{Kesinlik} = DP / (DP + YP), \text{Duyarlılık} = DP / (DP + YN)$$

Tablo 1. Makine öğrenmesi model sonuçları

	Doğruluk	Kesinlik	Duyarlılık
Destek Vektör Makinesi	0.75	0.81	0.72
Rastgele Orman Sınıflandırıcısı	0.70	0.75	0.69
Lojistik Regresyon	0.73	0.79	0.71

Makine öğrenmesi modellerinin performanslarını karşılaştırmak için kullanılacak diğer bir yöntem kutu grafiklerine bakmaktır. Şekil 1'de modellerin kutu grafikleri verilmiştir. Modellerin doğruluk değerlerine göre kutu grafiği oluşturulduğunda Destek Vektör Makinesinin medyan değerinin diğer iki modelden ortalama olarak daha yüksek olduğu görülebilir. Bu, modelin diğer modellere kıyasla daha iyi sonuç verdiğini gösterir. Aynı zamanda kutular arası aralıkların kısa olması da bu modelin bulduğu sonuçların tutarlı olduğunu gösterir. Ayrıca kutunun simetrik olarak dağılması, bulunan değerlerin normal dağılıma daha yakın olduğunu gösterir. Bu da elde edilen sonuçların tutarlılığı için önemli bir kıstastır. Bu sonuçlar ışığında Destek Vektör Makinesinin kullanılmasına karar verilmiştir.

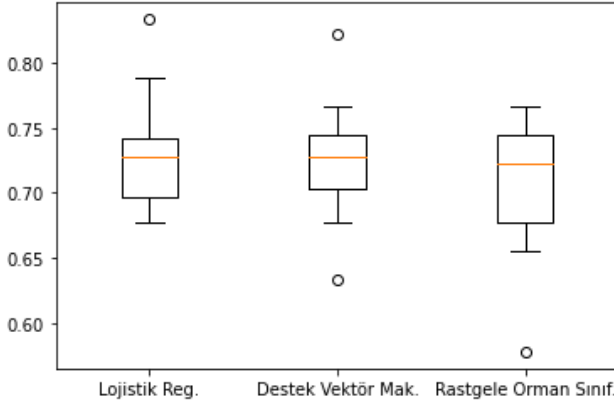
Bir makine öğrenmesi modelinin farklı denemelerde tutarlı sonuçlar vermesi beklenir. Sonuçların tutarlılığının artması için ortalama bir deneme sayısı bulunmalıdır. Nihai modelde maçların benzetiminde kullanılacak olan iterasyon sayısını bulmak için rastgele iki takım arasında oynanan bir maç 10.000 kez tekrar edilmiştir. Şekil 2'deki grafik, tutarlılık değerinin 6.500 maçtan sonra tutarlı bir hale geldiğini göstermektedir. Turnavadaki maçlar, bu grafikten elde edilen sonuçtan yola çıkılarak 6.500 defa benzetimi yapılarak tahmin edilmiştir.

Denemeler FIFA 2018 Dünya Kupası son 16 maç üzerinden yapılmıştır. Turnavadaki son 16 maç, iki farklı şekilde tahmin edilmiştir. Birinci yöntemde, tek seferde tüm maçlar tahmin edilmeye çalışılmıştır. Bu yöntemin amacı, turnuva başlamadan önce hangi takımın turnuvayı kazanacağını tahmin etmektir. Bu yöntemde yanlış bilinen maçlardan doğan sonuçlar, kalan maçları da etkilediği için doğru bilinen maç sayısının önemi yoktur. Model, turnuvayı kazananın Brezilya olduğunu tahmin etmiştir. Ancak gerçekte turnuvayı kazanan takım Fransa olmuştur.


İkinci yöntemde maçlar teker teker tahmin edilmiştir. Bu yöntemde yanlış tahmin edilen maçların ardından oynanan diğer maçların benzetimi ayrı olarak gerçekleştirilmiştir. Bu yöntemde model, maçları birbirinden bağımsız tahmin ettiği için önceki turda yaptığı yanlış tahminlerin telafisini yapabilmektedir. Bu deneme yönteminin amacı, son 16 maç içerisinde olabildiğince çok sayıda maçı doğru tahmin etmektir. Yapılan denemeler sonucunda oynanan 16 maçtan 11 tanesi model tarafından doğru tahmin edilmiş olup genel başarı oranı % 68.75 olarak hesaplanmıştır.

Geliştirilen uygulamanın kaynak kodunun tamamı, uzunluğu sebebiyle bu bildiriye eklenmemiştir. Sadece önemli bazı kısımlar ve sonuçlar açıklanmıştır. Uygulamanın tüm kodları GitHub ortamında açık kaynaklı bir

şekilde paylaşılmıştır [10]. Birçok görselleştirme imkânı bulunmaktadır. Örneğin turnuva tahmini analizi seçildiğinde turnuva için geliştirilen makine öğrenmesi modeli ile ilgili açıklamalar ayrıntılı olarak paylaşılmıştır.



Şekil 1. Modellerin kutu grafiği ile karşılaştırılması



Şekil 2. Modelin tutarlılığı için oluşturulan benzetim sayısı

4. Sonuçlar ve Öneriler

Maç sonuçlarının tahmini, futbolun daima en büyük problemlerinden birisi olmuştur. Literatürde futbol maç sonuçlarının tahmini ile ilgili yapılan çeşitli çalışmalarda makine öğrenmesi modeli için farklı özellik seçimleri kullanılmıştır. Bu çalışmada açık kaynak veri depolarından elde edilen özgün bir veri seti oluşturulmuştur. Bir futbol maçını tahmin eden modelde kullanılan özellik sayısının fazla olması, modelin farklı güçlere sahip takımların maçları hakkında yaptığı tahminleri zorlaştırabilmektedir. Bu da başarı oranını düşürmektedir. Lojistik regresyon, Destek Vektör Makinesi ve Rastgele orman algoritmaları ile bu veri setleri eğitilmiştir. Geliştirilen modelde kullanılan özellikler, takımın genel gücünü kullanırken aynı zamanda takımın zayıf ve güçlü yönlerini de modelde kullanılmasını sağlamıştır. Elde edilen sonuçlara göre Destek Vektör Makinesi daha başarılı olduğu ve eğitim sonuçları ile gerçek maçlarda denenen sonuçlar karşılaştırıldığında modelin başarıyla çalıştığı gözlemlenmiştir. Gelecek çalışmalarda 2018'den günümüze oynanan yeni maçlar ve yeni özellik seçimleri ile 2022 dünya kupasının tahmini için modelde geliştirmeler yapılması planlanmaktadır.

Referanslar

- [1] T. M. Mitchell, Machine learning. Burr Ridge, Illinois: McGraw Hill, 1997.
- [2] E. Alpaydin, Introduction to Machine Learning Ethem Alpaydin. 2014.
- [3] A. C. Müller and S. Guido, Introduction to machine learning with Python: a guide for data scientists. O'Reilly Media, 2016.
- [4] J. Hucaljuk and A. Rakipović, 'Predicting football scores using machine learning techniques', 2011.
- [5] J. Stübinger, B. Mangold, and J. Knoll, 'Machine learning in football betting: Prediction of match results based on player characteristics', Applied Sciences (Switzerland), vol. 10, no. 1, 2020, doi: 10.3390/app10010046.
- [6] M. Karabıyık and B. Yet, 'Football Analytics using Bayesian Networks: the FutBA Model', Pamukkale University Journal of Engineering Sciences, vol. 25, no. 1, 2019, doi: 10.5505/pajes.2018.12979.
- [7] P. Tüfekci, 'Prediction of football match results in Turkish super league games', in Advances in Intelligent Systems and Computing, 2016, vol. 427, doi: 10.1007/978-3-319-29504-6_48.
- [8] I. Chinwe Peace, 'An Improved Prediction System for Football a Match Result', IOSR Journal of Engineering, vol. 04, no. 12, 2014, doi: 10.9790/3021-04124012020.
- [9] B. Ćwiklinski, A. Giełczyk, and M. Choraś, 'Who will score? A machine learning approach to supporting football team building and transfers', Entropy, vol. 23, no. 1, 2021, doi: 10.3390/e23010090.
- [10] A. B. Yüce and M. Cicioğlu, 'FIFA World Cup 2018 Visualization and Prediction Project', 2021. <https://github.com/berkanyuce/FIFA-World-Cup-2018-Visualization-and-Prediction> (accessed Jan. 15, 2022).
- [11] R. Pollard, 'Home Advantage in Football: A Current Review of an Unsolved Puzzle', The Open Sports Sciences Journal, vol. 1, no. 1, 2008, doi: 10.2174/1875399x00801010012.
- [12] J. Tolles and W. J. Meurer, 'Logistic regression: Relating patient characteristics to outcomes', JAMA - Journal of the American Medical Association, vol. 316, no. 5. 2016, doi: 10.1001/jama.2016.7653.
- [13] C. K. I. Williams, 'Learning With Kernels: Support Vector Machines, Regularization, Optimization, and Beyond', Journal of the American Statistical Association, vol. 98, no. 462, 2003, doi: 10.1198/jasa.2003.s269.
- [14] Tin Kam Ho, 'Random Decision Forests Tin Kam Ho Perceptron training', Proceedings of 3rd International Conference on Document Analysis and Recognition, 1995.
- [15] StatsBomb, 'StatsBomb Open Data'. <https://github.com/statsbomb/open-data> (accessed Dec. 15, 2021).

Mimarlık Disiplininde Sanal Gerçeklik Teknolojisi Kullanımı

Use of Virtual Reality Technology in the Architecture Discipline

Aykutalp ÖZKUYUMCU^{1*}, Ahenk KARCI DEMİRKOL², Ayşe KALAYCI ÖNAÇ³

¹Kentsel Dönüşüm Bölümü, İzmir Kâtip Çelebi Üniversitesi, Türkiye, s.aykutsalpp@gmail.com

²Kentsel Dönüşüm Bölümü, İzmir Kâtip Çelebi Üniversitesi, Türkiye, ahnkcarci@gmail.com

³Kentsel Dönüşüm Bölümü, İzmir Kâtip Çelebi Üniversitesi, Türkiye, ayseklyc@gmail.com

Özet

Mimarlık disiplini insanlığın başlıca ihtiyaçlarından biri olan barınma ihtiyacını karşılamak amacıyla doğmuş, medeniyetin gelişmesine paralel olarak ilerleme göstermiştir. Mimarlık mesleğinin pratiğini tasarım, görselleştirme ve uygulama olmak üzere üç temel çalışma aşaması oluşturmaktadır. Mimari tasarımın uygulanma aşamasına geçilmeden önce gerçekçi ve detaylı görselleştirilmesi büyük önem taşımaktadır. Küreselleşen dünyanın teknolojik gelişmeleri mimarlık alanına da yansımaktadır. Günümüzde dijital tasarım ve uygulama teknolojileri mimarlık alanında sıkça kullanılmaktadır.

İlk olarak 1970'li yıllarda ortaya konmuş olan sanal gerçeklik kavramı (VR), 19. yy.'da görüntülere üç boyutlu derinlik katılmaya çalışarak geliştirilmeye başlanmış ve günümüzde bilgisayar teknolojisinin yardımıyla büyük gelişim göstererek ulaşılabilir bir teknoloji haline gelmiştir. Günümüzde sağlık, eğitim, kültür turizm, eğlence gibi alanlarda da kullanılan sanal gerçeklik mimarlık alanda tasarımların gerçekçi bir şekilde görselleştirilmesini sağlamak amacıyla da kullanılmaktadır.

Bu çalışmada öncelikle sanal gerçeklik (VR) teknolojisi ve tarihi yapılmış olan literatür taraması ışığında açıklanmıştır. Daha sonra bu teknolojinin mimarlık alanında kullanımı örneklerle incelenmiştir. Son olarak da sanal gerçekliğin meslek disiplinine katılımları, avantaj ve dezavantajları değerlendirilmiştir.

Anahtar Sözcükler: *Bilgisayar teknolojileri; Mimarlık; Sanal gerçeklik.*

Abstract

The discipline of architecture was born in order to meet the need for shelter, one of the main needs of human beings, and progressed in parallel with the development of civilization. The practice of the architectural profession consists of three basic working stages: design, visualization, and application. Realistic and detailed visualization of the architectural design is of great importance before proceeding to the implementation phase. The technological developments of the globalizing world are also reflected in the field of architecture. Today, digital design and application technologies are frequently used in the field of architecture.

The concept of virtual reality (VR), which was first introduced in the 1970s, started being developed in the 19th century by trying to add three-dimensional depth to the images, and today it has become an accessible technology with the help of computer technology. Virtual reality, which is also used in fields such as health, education, culture, tourism, and entertainment, is also used in the field of architecture to provide realistic visualization of designs.

In this study, first of all, virtual reality (VR) technology and its history are explained in the light of the literature review. Then, the use of this technology in the field of architecture is examined with examples. Finally, the contributions of virtual reality to the professional discipline, its advantages, and disadvantages have been evaluated.

Keywords: *Computer technologies; Architecture; Virtual reality.*

1. Giriş


2019 yılında ortaya çıkan Covid-19 ekonomik ve sosyal anlamda dünyada büyük bir etki bırakarak, insanların var olan alışkanlıklarının değişimine neden olmuştur. Bu süreç zarfında insanlar eğitim, iş, ticaret, kamu hizmetleri, eğlence gibi birçok farklı alanlarda pandemi nedeniyle uzaktan iletişim kurmak zorunda kalmışlardır. Bunun sonucunda 20. yy.'da geliştirilmeye başlanan sanal ortamların önemi global anlamda artmıştır [1]. Sanal gerçeklik (VR), teknoloji kullanılarak oluşturulan kurgular ile gerçek ve hayalin birleştirilmesi olarak tanımlanabilir. Sanal gerçekliğin çıkış noktası görsel iletişime dayanmaktadır [2].

Mimarlık endüstrisindeki büyük gelişme ve proje tasarımı ve formlarının karmaşıklığı nedeniyle, mimari alanda sürükleyici sanal gerçeklik, videolar ve simülasyon teknolojileri gibi multimedya kullanılarak geliştirilmesi oldukça önem taşımaktadır [3]. Günümüzde mimarlık alanında sanal gerçeklik kullanılarak inşa edilmemiş olan bir projenin gerçeklik algısı ile sunulması oldukça popüler bir teknik haline gelmiştir [4]. Sanal

ortamlar başlangıçta mimarlar tarafından konsept sunumu için kullanılmaktaydı. Ancak daha sonra VR teknolojisinin mimarlık sektörünün ve sektörün hedef gruplarıyla görsel ve sanal gerçeklik yöntemleriyle nasıl daha etkili iletişim kuracağına odaklanmıştır. Mimarlık deneyimi sanal gerçeklik teknolojisinin ortaya çıkmasından önce sadece soyut bir ifadeydi. Teknoloji ortaya çıktıktan sonra deneyimi yaşayacak olan gruplar görsel ve işitsel deneyimin yanı sıra VR destekli, etkili psikolojik iletişim yöntemlerinin kullanımıyla psikolojik olarak da bu deneyimi yaşayabilir ve verilmek istenen mesajı çok daha doğru bir biçimde alabilmesine olanak tanımıştır. Sanal gerçeklik teknolojisinin üç boyutlu evreninde kullanıcılara sunulan dinamik erkan ve aktif gezginlikle birlikte birinci kişi bakış açısının kullanımı bu teknolojinin hedef grupların kullanıcılarına adeta deneyim yaşıyormuş gibi hissettirmektedir [3].

2. Materyal ve Yöntem

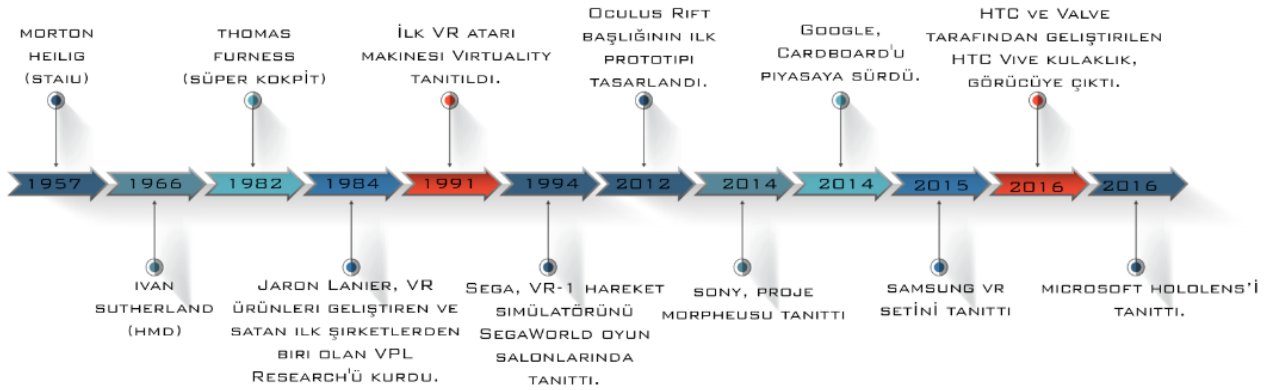
Çalışmanın yöntemi başlıca üç aşamadan oluşmaktadır. Öncelikle VR. teknolojisinin tarihsel gelişimi ve mimarlık alanında kullanımıyla ilgili ulusal ve uluslararası bilimsel yayınlar incelenmiştir. Çalışmanın ikinci aşaması olan analiz aşamasında ise yapılmış olan literatür taraması ışığında elde edilmiş bilgilerden yola çıkılarak VR. teknolojisinin mimarlık alanında kullanımının avantaj ve dezavantajları değerlendirilmiştir. Son olarak ise, konu ile genel bir değerlendirme yapılmıştır (Şekil 1. Yöntem akış şeması).



Şekil 1. Yöntem akış şeması

Araştırmanın materyallerini ise, konuya ilişkin çalışmaların yer aldığı uluslararası, ulusal ve internet kaynakları oluşturmaktadır.

3. VR'ın Tarihsel Gelişimi




Şekil 2. VR'ın tarihsel gelişim şeması

VR'ın ortaya çıkışı temel olarak insan ile iletişim kurarken sadece görsel ve işitsel bilgi aktarımı yapmak yerine insanı bu bilgilerin olduğu sanal bir evrene sokarak iletişimin güçlendirilmesidir. Bu da ilk olarak karşımıza tarihte tiyatro, sinema ve televizyon olarak çıkıyor. Tarihten çağdaş VR sistemlerinin işlevine en çok yaklaşan 1957'de Morton Heilig tarafından geliştirilen Bireysel Kullanım için Stereoskopik Televizyon Cihazı (STAIU) olmuştur. Daha sonra 1966 yılında MIT'de Ivan Sutherland tarafından geliştirilen Bilgisayar Tabanlı Başa Takılan Ekran (HMD) tarihsel gelişimin ikinci adımı olmuştur. 1982 yılında Thomas Furness pilotlar için Süper Kokpit isimli bir kask geliştirdi. Bu kask pilotlara sanal bir uçuş ortamı yaratıp özel eldivenler sayesinde sanal bir kokpitte beraber uçuş eğitimi yapmalarını sağlıyordu. Daha sonra NASA erişilemeyen saha keşiflerinde kullanılmak üzere uzay istasyonunda çalışan astronotların kullanması için dışarıdaki robotun gerçek zamanlı olarak çalışmasına olanak sağlayan görselleştirme destekli bir VR kask geliştirdi [5]. Daha sonra Jaron Lanier arkadaşı ile VR geliştirmeği amaçlayan VPL Research adlı girişimi kurmuşlardır [6]. 1991 yılında ise VR oyunu olan 'Datcyl Nightmare' ile birlikte VR teknolojisi oyun konsolu sektörüne giriş yaptı. Hemen ardından 1994 yılında Sega VR-1 hareket similatörü ile SegaWorld eğlence salonlarında tanıtılmıştır [7]. Günümüzde hala gelişimine devam etmekte olan ve VR teknolojilerinin ilklerinden biri olan Oculus Rift 2012' de kitle fonlamasıyla birlikte

piyasaya sürülmüştür [8]. 2014 yılında 'Google Glass'ın gözlük ve 'Karton' ile birleştirilmesiyle tasarım yönü güçlendirilmiştir. Aynı yıl içerisinde Sony, HMZ serisinin ev sineması için en son sürümü olan HMZ-T3'ü satmaya başlamıştır. Bunun yanında GDC2014 ile PS4'ü destekleyen VR için HMD olan Morpheus'u tanıtmıştır [9]. 2015 yılında kullanıcılar için VR deneyimini güçlendirmek ve ulaşılabilir bir hale getirebilmek için Samsung Galaxy akıllı telefon ile birlikte kullanılabilen yenilikçi bir VR teknolojisi olan Samsung Gear VR tanıtılmıştır [10]. 2016 yılında ise HTC ve Valve Corp. tarafından geliştirilen HTC Vive piyasaya sürülmüştür [11]. Son olarak 2016 yılında piyasaya sürülen Microsoft Hololens ile birlikte bu konuda teknolojiye bariz bir yenilik olmuştur [12].

4. VR'ın Mimarlık Alanında Kullanımı

Tasarım projeleri genellikle matematiksel tanımıyla 0'dan 1'e yani hiçlikten tamamın oluşturulmasına doğru oluşur. Bu durum tasarımın geliştirme aşamasında pek çok yeni güncellemeye ihtiyaç duymasına yol açar. VR teknolojisinin kullanımı burada tasarım ile yapı arasında gerçek zamanlı bir iletişim kurulmasını sağlar [13].



Şekil 3. VR'ın mimarlık alanında kullanımı

Tasarım sürecinden sonra yapım esnasında da çeşitli kullanım yöntemleri vardır. Örneğin mimar veya mühendisler tarafından çizilen tasarımlar saha içinde çalışan kişilere VR teknolojisi sayesinde eş zamanlı olarak aktarılıp yapım esnasında yapılan hataların anında tespitini ve düzeltilmesini olanak tanır. Bir saha çalışanı kullandığı VR başlığı sayesinde sahada yapılması gereken işin tasarımcı tarafından sisteme girilmesi halinde anında hayata geçirilmesini sağlar [5]. Aynı zamanda VR teknolojisinin yapay zeka algoritması ile çalışması da mümkündür. Yapay zeka algoritması ile çalışan VR teknolojisi yeterince veri tabanı oluşturulduktan sonra optimum tasarım şeklinin tasarımcıya önerilmesinde kullanılmaktadır [3]. Ayrıca VR teknolojisinden mimarlık eğitiminde de yararlanılmaktadır [14].

5. VR Teknolojisinin Avantaj ve Dezavantajları

VR teknolojisi Tasarım mesleğinde çeşitlilik kişisel vizyonu genişletecek, zihinsel görüntülerin hafızası ve çok yönlü düşünmeyi teşvik eder. VR, bir ortamın gözleminden ziyade yapay mekanlara uzaktan veya yakından sanal bir bağlantıdır. Üç boyutlu, stereoskopik, kafa izlenen ekranlara, el/vücut takibine ve çoklu sese dayanır. VR, sürükleyici, çok algılı bir deneyimdir. Fikirlerin daha önce hiç olmadığı şekilde ifade edilmesini ve inşa edilmesini mümkün kılar. Bu teknoloji tasarım alanında tasarımcıyla hedef veya saha çalışanı arasında bilginin aktarımını gerçeğe en yakın düzeyde aktarımını sağlar bu da tasarımcıya en doğru tasarımı yapma fırsatını verir [5]. VR teknolojisi mimarı projenin henüz tasarım aşamasında iken oluşturulan tasarımın hedefe gerçeğe en yakın olarak aktarımını ve geri dönüş bilgilerini elde etmeyi sağlar. Bu durum tasarım isteklerinin hayata geçmesinin tasarımcı tarafından optimize edilmesine olanak sağlar [13]. Sistem yeterince veri toplayabilirse farklı mekanlarda bulunan tasarımcılar VR vasıtası ile bilgileri birlikte görebilir ve üzerinde birlikte çalışabilir. [5]. Ayrıca, yapılmış olan bilimsel çalışmalar ışığında insanların gerçek mekan deneyimi ile VR ile oluşturulmuş mekan deneyimlerine vermiş oldukları psikolojik tepkilerinde anlamlı bir fark bulunamamıştır [15].

VR teknolojisinin elde edilmesi finansal açıdan açıdan zor olduğu gibi teknolojinin tasarıma entegrasyonu da oldukça zordur [5]. VR teknolojisinin yapay zeka algoritması ile çalışmasının da belirli zorlukları bulunmaktadır. Yazılımı oluşturmak yapılacak işlerin aşamalarının tanımını gerektirdiği için uzun zaman alır [3].

6. Sonuç ve Değerlendirme

Günümüzde artan teknolojiyle birlikte hızla gelişmekte olan sanal ortamların gerçekliğe en yakın olmasını sağlayan önemli teknolojilerden birisi de VR teknolojisidir. Bu teknoloji 1957 yılından günümüze gelişmiş ve her geçen gün daha da gelişerek ve ulaşılabilir olarak hayatımıza entegre olmaya başlamıştır. Meta evren gibi kavramların hayatımıza dahil olmasıyla VR teknolojilerinin kullanımı yaygınlaşacaktır.

VR teknolojisi günümüzde birçok farklı alanlarda kullanılmaktadır. Bu alanlardan birisi de mimarlıktır. VR teknolojisinin mimarlık alanında kullanımlarının avantajları; sürükleyici bir deneyim sağlaması, görsel ve işitsel duylara hitap etmesi, tasarımcıya en doğru tasarımı yapmasına olanak sağlaması, tasarımın optimize edilmesine olanak sağlaması, yapının tasarım aşamasındayken bile gerçeğe yakın sonucunu görme fırsatı sağlaması, yapay zeka algoritmasıyla çalışma fırsatı sunmasıdır. Bu teknolojinin avantajları olduğu gibi dezavantajları da bulunmaktadır. Bunlar; tasarıma entegrasyonu zor olması, yüksek maliyetli olması ve entegrasyonunun zaman alıcı olmasıdır.

Tablo 1 .VR teknolojinin mimarlık alanında kullanımının avantaj ve dezavantajları

Avantajları	Dezavantajları
Sürükleyici bir deneyim sağlaması	Tasarıma entegrasyonu zor
Görsel ve işitsel duylara hitap etmesi	Maliyetli
Tasarımcıya en doğru tasarımı yapmasına olanak sağlaması	Entegrasyonu zaman alıcı
Tasarımın optimize edilmesine olanak sağlaması	
Yapının tasarım aşamasındayken bile gerçeğe yakın sonucunu görme fırsatı sağlaması	
Yapay zeka algoritmasıyla çalışma fırsatı sunması	

VR teknolojisinin mimarlık alanında kullanımında kullanıcıların görsel algılarını ve entegrasyonlarını artırıcı etkileriyle yapıların tasarlanmasında ve uygulanmasında kolaylık sağlama potansiyeline sahiptir. Tasarımın bir tamamlanmasındaki bilişsel yükü azaltarak kullanıcıların performansına olumlu katkı sunabilir. Ayrıca VR, mimarlık alanında tehlikeli veya rahatsız ortamlarda çalışanların işini hızlandırmaya yardımcı olarak yaşam kalitesini iyileştirebilir.

Referanslar

- [1] Chan, C. S., Bogdanovic, J., & Kalivarapu, V., 'Applying immersive virtual reality for remote teaching architectural history', *Education and Information Technologies*, 27(3), 4365-4397, 2022.
- [2] Portman, M. E., Natapov, A., & Fisher-Gewirtzman, D, 2015. 'To go where no man has gone before: Virtual reality in architecture, landscape architecture and environmental planning', *Computers, Environment and Urban Systems*, 54, 376-384, 2015.
- [3] Grepon, B. G., & Martinez, A. L., 'Architectural Visualization Using Virtual Reality: A User Experience in Simulating Buildings of a Community College in Bukidnon', Philippines. *arXiv preprint arXiv:2103.06238*, 2021.
- [4] Abdelhameed, W.A., 'Virtual Reality Use in Architectural Design Studios: A case of studying structure and construction', *Procedia Computer Science*, 25, 220-230, 2013.
- [5] Chan, C. S., 'Virtual reality in architectural design' In *CAADRIA 1997 Workshop* (pp. 1-10), 1997.
- [6] Lanier, J., 'Dawn of the new everything: A journey through virtual reality' Random House, 2017,
- [7] Kurland, E., 'History of VR. In *Virtual Reality Filmmaking*', (pp. 7-17), Routledge, 2017.
- [8] Ruyg, M., Teunisse, C., & Verhage, S., 'Virtual reality for the web: Oculus Rift', *Leida: Leiden University*, 2014.
- [9] Kim, J. Y., 'Investigative Analysis of Virtual Reality Technology through Case Study', *Journal of Next-generation Convergence Information Services Technology*, 3(2), 101-108, 2014.
- [10] Alzahrani, A., Corban, H., Hsu, W. C., Lu, C. C., & Dai, X., 'Samsung Gear VR Marketing Plan', 2017.
- [11] Egger, J., Gall, M., Wallner, J., Boechat, P., Hann, A., Li, X., ... & Schmalstieg, D., 'HTC Vive MeVisLab integration via OpenVR for medical applications', *PloS one*, 12(3), e0173972, 2017.
- [12] Hammady, R., & Ma, M., 'Designing spatial ui as a solution of the narrow fov of microsoft hololens: Prototype of virtual museum guide' In *Augmented reality and virtual reality* (pp. 217-231), Springer, Cham, 2019.
- [13] Xu, J., 'The Future Application of Virtual Reality Technology in Architectural Design', 2021.
- [14] Sun, C., Hu, W., & Xu, D., 'Navigation modes, operation methods, observation scales and background options in UI design for high learning performance in VR-based architectural applications', *Journal of Computational Design and Engineering*, 6(2), 189-196, 2019.
- [15] Yin, Jie., "Bringing Nature Indoors with Virtual Reality: Human Responses to Biophilic Design in Buildings, 2019.

Sanatta Yapay Zeka Örnekleri Ve Dijital Sanatta Özel Algoritmalar

Examples of Artificial Intelligence in Art and Special Algorithms in Digital Art

Yasemin Gülay TONGUÇ^{1*}

¹ Yazılım Mühendisliği, İzmir Katip Çelebi Üniversitesi, Türkiye, yasemingulaytonguc@gmail.com

Özet

Günümüzde makine öğrenme tabanlı yapay zeka algoritmaları, tıp alanında, finansal sepet analizinde, kapsamlı reklam ve pazarlama analizlerinde, kişisel ve kurumsal eğitim sektöründe, sürücüsü olmayan araç tasarımında, müzik kişiselleştirme uygulamalarında, video ve online oyun tasarımında daha birçok alanda kullanılmaktadır.

İnsan zekasının taklit edilip rasyonelleştirme düşüncesi ve yüksek matematiksel tabanlı yapay zeka, bilişim teknolojisinin gelişimi ve yeni medya sanatının popülerleşmesi ile dijitalleşmeyi yaygınlaştırmaktadır. Bu kullanım önce görsel sanatlar olmak üzere sanatın bir çok alanında yaratıcılık ve hayal gücünü zorlamakta ve kültürel alanı da etkisi altına almaktadır.

Generatif sanatla geleneksel sanatın birlikte kullanımı yani melez sanat; Sanatçı ve Makina işbirlikteliği ile 3 boyutlu yazıcılar, grafiksel tasarım yazılımları ve A.I gibi teknoloji imkanları ile sanat eserleri üretme kurallarına dayanmaktadır.

A.I için varsayım, bilgisayara yeni bilgi yüklenince ve eğitim süreci gerekli yerde durdurulduğunda, Yapay Zekalı makinanın bu yeni bilgiyi, algoritmik eğitimleri varolan modellere kullanıp işleyebilmesidir

Anahtar Sözcükler: *Dijital Sanat; Gan Algoritması; Optimizasyon Algoritmaları; Perlin Gürültü Algoritması, Yapay Zeka.*

Abstracte

Today machine learning-based artificial intelligence algorithms are used in medicine, financial basket analysis, comprehensive advertising and marketing analysis, personal and corporate education sector, driverless vehicle design, music customization applications, video and online game design.

The idea of imitating and rationalizing human intelligence and artificial intelligence with a high mathematical basis are popularizing digitalization with the development of information technology and the popularization of new media art. This use forces creativity and imagination in many fields of art, first of all, visual arts, and it also affects the cultural field.

Hybrid art that emerged with the use of generative art and traditional art; With the collaboration of Artist and Makina, 3D printers, graphical design software and it is based on the rules of creating works of art with technology possibilities such as Artificial Intelligence.

The assumption for AI is that when new information is loaded into the computer and the training process is stopped, the AI machine can use and process this new information into existing models as a result of special algorithmic training.

Keywords: ; *Artificial Intelligence; Digital Art ; Gan Algorithm; Perlin Noise Algorithm; Optimization Algorithms.*

1. Giriş

Geleneksel sanatta sanatkarlar; eskiden beri gelen eser örneklemelerinden, sanat akımlarından ve ustalardan esinlenerek, felsefik ve edebi düşünceleri bakış açılarıyla değerlendirip, kendine özgü doğal ve sonradan geliştirdiği yetenekleriyle bütünleştirip yaratıcı zekalarıyla sanat eserleri üretmişlerdir.

Yeni medya sanatında ise sanatkarlar; Fraktal Sanat teknikleri ile matematiksel mükemmellikteki fraktalları düzenleyip, bilgisayar teknolojisi ile birleştirerek yaptıkları hesaplama sonucun da; soyut sanat eserleri, dijital görüntü ve animasyonlar üretmektedirler.

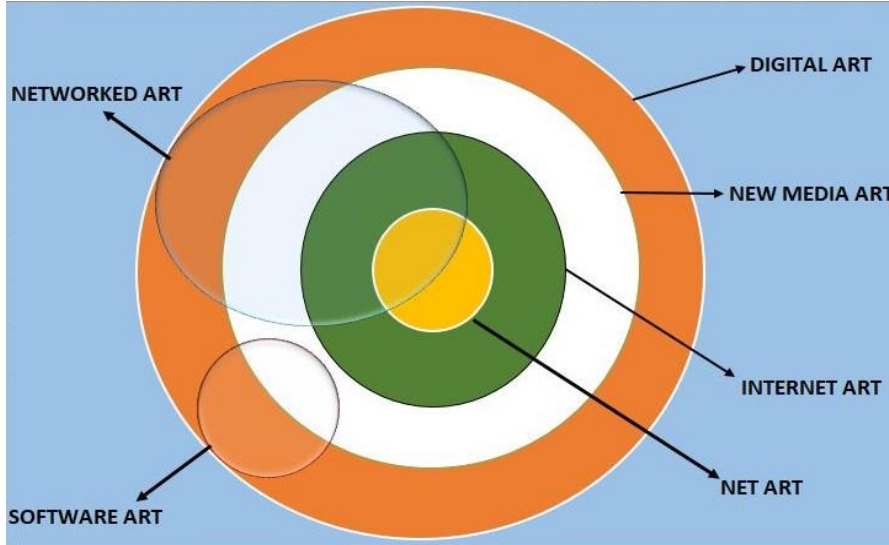
Dijital sanatta ise sanatçılar; Generatif sanat teknikleri ile sanal nesnelere biçimlendirerek, özel algoritmik destekli dijital tasarım, rasyonel matematiksel tabanlı yazılım dilleri kullanarak sanal nesnelere estetik yapay zeka sanat eserleri üretmektedirler.

Yapay zeka sanatta iki şekilde eserler üretir;

1 - Sanatçı kendi sanat eserine algoritmalarla destekli yapay zekadan yardımcı olarak faydalanır.

2 - Doğrudan algoritmalarla ve tamamen yapay zeka tarafından eserler üretilir.

Medya sanatı; video, internet, televizyon, radyo ve telefonu da içeren kitle iletişim araçları ve telekomünikasyonla ilişkili olan çalışmalara gönderme yapar. Karışık teknik ve internet sanatı gibi artistik kavramlarla da benzeşmektedir (Keser, 2009: 209).



Şekil 1 - Karen Verschooren' a Göre Yeni Medya' da Dijital Sanat Kategorizasyonu

2. Amaç

Bu çalışmada; klasik sanatla generatif sanat karşılaştırması genel olarak yapılmış ve bazı farklılıklardan genel anlamda bahsedilmiştir. Dijital Sanatın çeşitli dalları arasında yapay zekanın kullanımı ve insan makine işbirliği ile üretilen eserlerin getirdiği yenilikler örneklerle aktarılmaya çalışılmıştır. Yapay Zeka'nın sanatın dijitalleşmesinde ki yazılımsal çalışma altyapısı mantığının teknolojik ifadesi ve özel algoritmalarının işlevsel özellikleri tanıtılmaya çalışılmıştır. Amaç, yapay zekanın çağdaş sanata katkısını ve gelişimini aktarmaktır.

3. Materyal ve Yöntem

Araştırma da ikincil tarama yöntemine başvurulmuştur. Microsoft Visual Studio 2019, Microsoft Visual Studio Code, Unity 2020-1, Pure Data 0.52-2 versiyonlu yazılımlar kullanılmıştır.

Sanat içinde yapay zekanın kullanımı için Optimizasyon algoritma çeşitlerinden Harmoni Arama Algoritması, Yapay Arı Kolonisi Algoritması, Perlin Gürültü Algoritması, Gan algoritması ve Kapsül Ağları algoritmalarından faydalanılmıştır.

4. Yapay Zekanın Sanatta Kullanım Örnekleri

Fraktal Sanatın temelleri algoritmik desenlere dayanmaktadır. Dünyada ise algoritmik tabanlı geometrik eserlere; Wassily Kandinsky'e ait 1927 tarihinde yapmış olduğu Spitze In Bogen eseri örnek verilebilir.

Sanat tarihini incelediğimizde; Osmanlı mimarisinde saray, cami ve han yapımlarında ince matematiksel ve oransal hesaplamalara sahip, günümüz algoritma tabanlı çalışma mantığının temelleri olan; bolca örneğini görebileceğimiz geometrik ve estetik motiflere rastlanmaktadır.



Şekil-2 Algoritmik Tabanlı İslami Geometrik Desen-Selimiye Camii Kubbesi-Mimar Sinan Ustalık Eseri Edirne

4.1-Görsel sanatlarda;

- Harold Cohen' in 1992 yılında Theo adında; AARON yazılımı ile yaptığı tuval üzerine yağlı boya eseri vardır.
- Sanatçı Beeple Everyday: The First 5000 Days isimli dijital sanat eseri 1981 yılında yapılmış ve 69.3 milyon dolara satılmıştır.
- Delft University of Technology Microsoft, Korsten 'la ekibi 2016 da yapay zeka ile Rembrant tablosu yapmışlardır.
- Mario Klingemann Memories Of Passersby I Eseri (Companion Version), 2018.Çoklu GAN algoritmaları ve uygulamaları bileşimi ve Yapay zeka teknikleri ile yapılmış bir eserdir.
- Mikael Hvidtfeldt Christensen' in Octopod adlı eseri; Structure Synth adlı A.I Yazılımı ile üretilmiştir.
- Dijital Enstalasyon sanatçısı, Sougwen Young' un The Limitless, The Absolute 2017 eseri
- Sanatçı Refik Anadol'un Black Sea A Eseri 2018
- Ahmet Elgemal, "Edmond Belamy'nin Portresi" adlı yapay zeka resmini 2018 de yapmıştır.
- Sanatçı Refik Anadol'un Machine Hallucinations – Grotesque architecture dataset adlı Dijital enstalasyon eseri 2020
- Sanatçı Refik Anadol'un yine Machine Hallucinations – Iss Dreams adlı Dijital Enstalasyon eseri 2020
- Engineered Arts tarafından yaratılan Lucy Steal ve Aidan Meller tarafından tasarlanan Ai-Da, Yapay Zekalı ilk robot ressamdır.

4.2-İşitsel Sanatlarda;

- "Blue Jeans and Bloody Tears" Eurovision Şarkısı Sweaty Machine şirketince Yapay Zeka ile yapılmıştır.
- "Daddy's Car" adlı sözleri bir besteciye ait şarkının müziği Sony'nin Flow Machine Yapay Zeka yazılımı ile yapılmıştır..
- Türkiye 'de ise Divan isimli bir yapay zeka, hayatını kaybeden Türk arabesk şarkıcı Müslüm Gürses 'in tarzında kayda alınan kendi sesinden, Benim Meselem 2 albümünü çıkartmıştır.
- Şebnem Ferah İstanbul konserinin 20. yılı anısına, ses ikizi diye tanımlanan Okyanus isimli yapay zeka ile Bostancı Kültür merkezinde 10 Mart 2007 ' de bir konser yapılmıştır.
- Youtube içerik üreticisi Taryn Southern IAMAİ adlı albümünden Break Free adlı şarkısı Amper adlı yazılım şirketince tamamen yapay zeka tarafından yapılmıştır.
- Hayatını kaybeden Ludwig Von Bethoven'ın 10. Senfonisi Yapay Zeka ile 2021' de tamamlanmıştır.

4.3 Edebiyat Sanatında;

- “Şiir Portreleri” isimli Google projesinde, algoritma sayesinde Yapay Zeka tarafından iki mısralık şiirler oluşturulmaktadır.
- Kanadalı Adam King’in geliştirdiği Talk to Transformer uygulaması ile birkaç kelime ile başlattığımız hikayenin devamını Yapay Zekalı robot getirebiliyor..
- İstanbul Bilgi Üniversitesi Bilgisayar Mühendisliği’ nin 9 ayda tamamladığı ROMTU adı verilen proje bir şair robotla sonuçlanmıştır. (Utku Şen ve Danışmanı Yrd.Doç Tuğba Yıldız)
- Yazılımcı Sanatçı Bager Akbay tarafından; Deniz Yılmaz adlı robot kola sahip şiir yazabilen şair yapay zeka robotu tasarlanıp geliştirilmiştir.

5. Dijital Sanatta Kullanılan Özel Algoritmalar

5.1 O.A – Optimizasyon Algoritmaları

Optimizasyon, karar aşamalarını hızlandırıp, doğru ve işe yarar karar alma oranını yükseltmek için kullanılır, reel hayat problemlerinde gerçek zamanlı, doğru ve etkili çözüm üretmek için tercih edilmektedir.

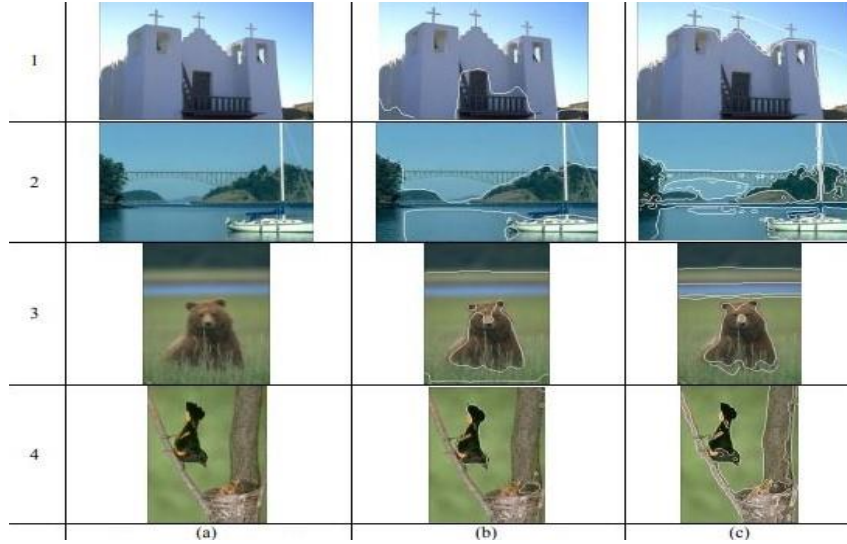
Sıklıkla kullanılan optimizasyon algoritmaları; Parçacık Sürü Optimizasyonu, Tavlama Benzetimi, Karınca Kolonisi Optimizasyonu, Genetik Algoritma, Tabu Arama ve Yapay Sinir Ağları denilebilir.

Sanat alanında; tasarım değişkenlerinin tanımlanması ve dizayn problemlerinde kullanılır. En yaygın kullanımı ise mimarlık ve yapı sanatıdır.

5.2. A.B.C.A – Yapay Arı Kolonisi Algoritması

Gri renkte ve de renkli görsellerin sayısal analizinde önemli olan, görüntü bölütleme işlemi, bir görselin her yerde eşit özelliklere sahip, farklı kısımlara ayırma işlemidir. Eşikleme tekniği kullanılan en temel tekniklerdendir ama günümüzde artık bu teknik olarak yetersiz kalmaktadır.

Bu doğadan esinlenerek bulunmuş ve kullanılan A.B.C.A algoritması ile düzenli istatistiksel renk ve doku değerleri içermeyen, tipik doğal görüntülerin bölütlenmesi sağlanabilmektedir.



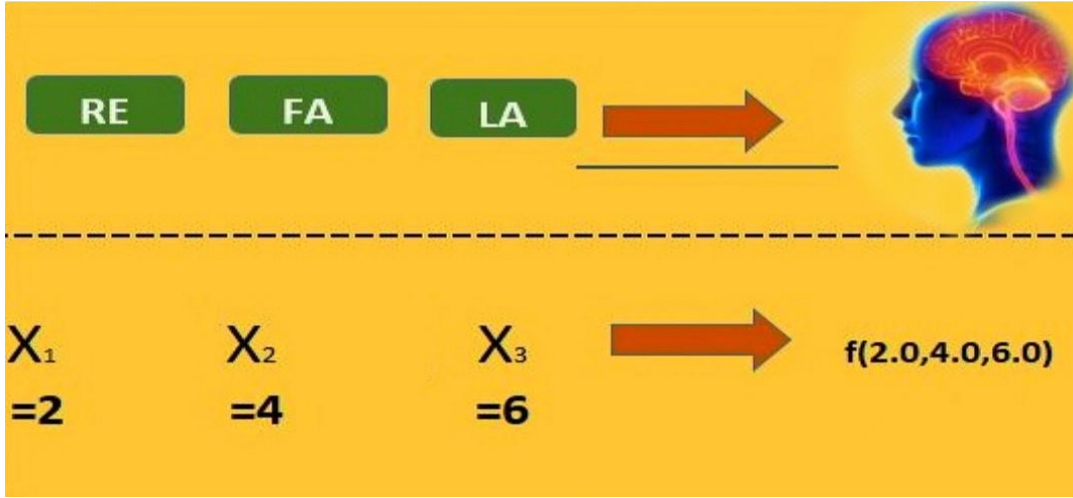
Şekil-3 Dalgacık Dönüşümü ve Yapay Arı Kolonisi Algoritmasıyla Bölütleme İşlemi

(a)Orijinal Görüntü b) Yöntem Bölütleme c) Görüntü Bölütleme

5.3 H.S -Harmoni Arama Algoritması

H.S müzik tabanlı sezgisel algoritmalarından bir meta-sezgisel bir algoritmadır. Müzik geliştirirken, sanatçılar enstrümanlarının akordlarını yaparlar. Gerekli ve olanaklı ses aralıkları içinde performans sergiler ve birlikte bir harmoni vektörü oluştururlar. Akortlar güzel bir harmoni sağlarsa sanatçının hafızasında bu harmoni depolanır.

Müzikte çok sayıda ses ile kusursuz bir harmoni bulma sürecini taklit etme ve bu süreci optimizasyon da kullanma, harmoni algoritmasının ortaya çıkış sebebidir. Harmoni arama algoritmasında, bir müzisyenin esinlenme süreci taklit edilmektedir.



Şekil-4 Mühendislik Optimizasyonu ve Müzik Geliştirme İlişkisi (Lee ve Geem, 2005)

6. P.N.A- Perlin Gürültü Algoritması

Ken Perlin adında bir profesör tarafından geliştirilen gradyan gürültü yaratma algoritmasıdır. Bilgisayar tarafından oluşturulan görüntünün doğal olması için kullanılır. Rastgele sayılarla doğal sıralı dizi ürettiği için görüntüsü daha doğal olmaktadır.

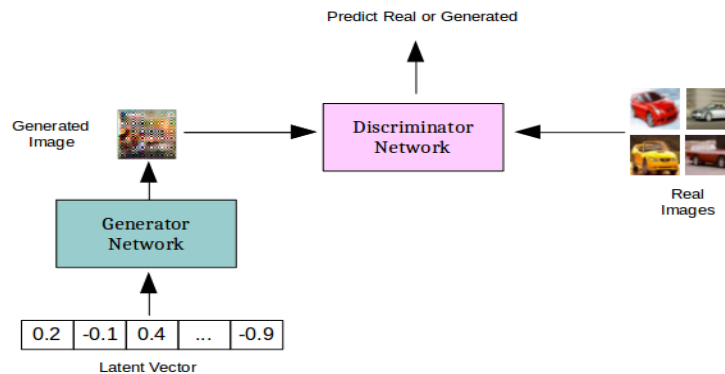
Haritalar, dağlar, bulutlar, manzaralar gibi doğal özellikli çeşitli etkiler, desenli dokular oluşturmak ve 1,2 ve 3 boyutlu görüntüler elde etmek için kullanılabilir. Sinema ve oyun sektörü en popüler kullanım alanıdır.

7. G.A.N Algoritması

G.A.N algoritması Sanat alanında kullanılan birçok Yapay Zeka yazılım, program ve üretim aşamasında en çok kullanılan algoritmik sistemdir.

Üretken karşıt ağ denilen ve iki nöral ağın en iyi sonuçlar alabilmek için birbiriyle mücadele etmesi mantığına dayanan G.A.N sistemi üzerinde çalışılmıştır.

Hem üretken hem de ayırıcı sinir ağlarıdır. Jeneratör çıkışı doğrudan diskriminatör girişine bağlanır. Geri yayılım yoluyla, ayırıcının sınıflandırması, jeneratörün ağırlıklarını güncellemek için kullandığı bir sinyal sağlar.



Şekil-5 Gan Algoritması ile Görselleştirme Teknolojik Sistemi

Üretken bir çekişmeli ağ (GAN) iki bölümden oluşur:

- Jeneratör makul veriler **üretmeyi** öğrenir. Oluşturulan örnekler, ayırıcı için olumsuz eğitim örnekleri haline gelir.

- Ayırt edici , üreticinin sahte verilerini gerçek verilerden ayırmayı öğrenir. Ayırmacı, üretici mantıksız sonuçlar ürettiği için cezalandırır.
- Eğitim başladığında, üretici açıkça sahte veriler üretir ve ayırmacı hızla bunun sahte olduğunu söylemeyi öğrenir.

8. C.N.A- Kapsül Ağları Algoritması

Derin öğrenmeden bildiğimiz evrişimli sinir ağları yapısından farklı olarak nesnelere dokusunu kokusunu, hızını, pozunu, deformasyonunu, boyutunu, yönünü tahmin edebilmek için tercih edilen kapsül ağları dinamik yönlendirme algoritmaları içerir.

Kapsül ağlarında derinlik art arda bağlanan katmanlarla değil iç içe konumlanan kapsüllerin bağlanmasıyla sağlanmaktadır. Verilerdeki uzamsal ilişkiyi değerlendiremeyen sinir ağlarından kapsül ağlarının üstünlüğü, bir görüntüdeki parçaların oryantasyonunu veri analizinin önemli bir parçası olarak kabul etmesidir. Bu da bize veri analizinde avantaj ve kolaylık sağlamaktadır.

5. Sonuç ve Öneriler

Sanat ve Yapay Zekâ üzerine derinleşen tartışmalara baktığımızda, Coeckelbergh, yapay zekâ tarafından üretilen ürünlerin hem sanat hem de objektif ve subjektif kriterler ile ilişkili olabileceğini savunmaktadır (Coeckelbergh, 2017: 290)

Derin öğrenme, makine öğrenmesi ve yapay zeka yazılımlarıyla görsel, işitsel, edebi sanatta sınır ötesi yaratıcı eserler üretilmektedir. Metaverse de yer edinmek isteyen sanatçı ve insanoğlu bu gelişmeleri ilgiyle takip etmekte ve yapay zekayı sanat eserleri üretimine dahil etmektedirler.

Rutgers Üniversitesi'nden ekip üyesi Ahmed Elgammal, "Gerçekten yaratıcı ve çarpıcı bir şeye sahip olmak istiyorsanız - ama aynı zamanda fazla ileri gidip estetik açıdan hoş olmayan bir şey yapmayın" diyor. Yapay zeka ile estetik sanat anlayışından uzaklaşmamak gerektiğini vurgulamıştır

Yapay Zekanın bilgisayar çizimlerinden gerçek resimleri ayırt edebilmesi için aylarca öğrenme yaptırılması, büyük ve maliyetli veri analiz yapması gerekmektedir. Kendi başına öğrenen yazılımlar ise insandan daha yavaş öğrenmekte ve insanların yaptığı birçok şeyi yapamamaktadır. Bu da yapay zeka kullanımını sınırlandırmakta ve insanın yerine tamamen robot ve makine kullanım fikrini olanaksızlaştırmaktadır. İnsan ve makine işbirliği ile oluşturulan melez sanat bu sebeplerden kullanılmaya devam edecektir ve gelecek bu eserlerle heyecan verici olmaya devam edecektir.

Referanslar

- [1] Hanbay K., Şengür A., Dalgacık Dönüşümü ve Nötrozofi Yaklaşımı ile Renkli Doku Görüntülerinin Bölütlenmesi., Bingöl Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 1(1),1-4,2011,9-17
- [2] G.Zhu, S.Kwong, Gbest-guided artificial bee colony algorithm for numerical function optimization, Applied Mathematics and Computation 217 (2010) 3166-3173.
- [3] Omran, M. G. H., Mahdavi, M., 2008, "Global-Best Harmony Search", Applied Mathematics and Computation, Vol.198, No.1, pp. 643–656.
- [4] Akkoyunlu, M. C. & Engin, O. (2011). Kesikli Harmoni Arama Algoritması İle Optimizasyon Problemlerinin Çözümü: Literatür Araştırması. Selçuk Üniversitesi Mühendislik, Bilim Ve Teknoloji Dergisi , 26 (4) , 140-148
- [5] Erozan, İ Harmoni Arama Algoritması (2018) Jan. 26,2022 [Online] Available: <https://birimler.dpu.edu.tr/>
- [6] Ballı. Ö Yapay Zekâ ve Sanat Uygulamaları Üzerine Güncel Bir Değerlendirme, STD Dergipark 2020 Aralık, 277-307
- 7) <https://puredata.info/> Apr. 13, 2022. [Online]
- 8) <https://unity.com/> Oct.5, 2021. [Online]
- 9) <https://cdn.wannart.com/production/post/2018/09/26712-dnzmen-1747-950px.jpg> May.3, 2022 [Online]
- 10) <https://refikanadol.com/> Nov.10, 2021. [Online]
- 11) https://miro.medium.com/max/1330/1*pHOKZ0HJrUSP827-fZFETg.png Dec.20, 2021. [Online]
- 12) <https://developers.google.com/> Jul.2, 2021. [Online]
- 13) <http://www.leblebitozu.com/> Marc. 5,2022. [Online]

COLOR DETECTION WITH CLOTHES

Selin HACIOĞLU¹, Tahsin ÜSTÜNEL², Gökçe NUR YILMAZ³

¹ Computer Engineering Department, Ted University, Turkey, selin.hacioglu@tedu.edu.tr

² Computer Engineering Department, Ted University, Turkey, tahsin.ustunel@tedu.edu.tr

³ Computer Engineering Department, TED University, Turkey, gokce.yilmaz@tedu.edu.tr

Abstract

In today's world, the consumption of clothing and accessories is increasing day by day. In this consumption area, people sometimes have difficulty in finding a color outfit or jewelry they want. Especially in face-to-face shopping, people look at all the stores to find the color they are looking for and consume a lot of energy in those stores. Considering this increasing problem, a model is proposed in this study that detects color and then displays the images of the clothing and accessory data it contains according to the color it perceives. In this way, this model provides ease of finding what people are looking for. Therefore, it could be easily stated that this system turns the filtering process into a kind of visual filtering. The results derived using the proposed model prove its effectiveness for detecting the colors.

Keywords: *Clothes; Color Detection; Filtering.*

1. Introduction

In today's conditions, clothing and accessories consumption is increasing. This increased consumption can make people to have difficulty in finding a color outfit or jewelry they require which in return causes a lot of energy and time consumption. Considering this problem, a model detecting the color of the clothes and accessories required and then displaying the images of the clothing and accessory data it contains according to their color is developed in this study. It could be easily stated that color is the significant feature for our proposed model. Human eyes and brain work in coordination to convert light into color, and light receptors in the eyes transmit the signal to the brain, which in turn recognizes color. Adapting this strategy to the machines is the key factor in identifying the color names in the developed model and fulfilling its main task. To express the color of some pictures, Red, Green, Blue (RGB) based color recognition system [1] is used. In this system, each color always consists of 3 values between 0 and 255 followed by RGB [1]. In the literature, there are some models relying on this system, for instance; Lee et. al. [2] applied the color identification technique for the NOKIA smart mobile device. This system uses phone cameras to recognize colors. This system's disadvantage is to only use three basic colors (red, green, blue) [2]. Duth et.al. shade and model images in the color detection system proposed in [3].

Contrary to the existing systems in the literature, using RGB in our proposed model is not efficient. The reason behind this is that it is desired and aimed to detect the color of a currently displayed image and to show its color in our model. For this purpose, the HSV in OpenCV method is used in our proposed study. There are red, green, and blue colors in the HSV method but in addition to these there are H, S, V. In HSV, color can be changed with 'H', saturation can be changed with 'S', value can be changed with 'V'[4]. This makes it easier to adapt the system to real life. Another reason for using this method is that the CCD camera used to define color in more complex systems is not used. The abbreviation for this camera is device with charging connection. Cameras with such image sensors perform well in low light conditions [5]. But in the proposed system, the webcam is used to detect the object.

In our proposed model, another important factor other than color is to save the data in the system and display it on the screen. The filing method was used to make this happen. With this simple and time-saving filing (dataset) method, the desired images are displayed on the screen according to the colors. As a result, a webcam is used to

model real-life objects, the colors are determined by the HSV method to detect the colors of these objects and display on the screen, and a window is created using some libraries in Python. Colors can be printed on the screen with OpenCV. Finally, the requested data is displayed with the file system.

The remainder of the article is organized as follows. The model proposed is introduced in the second section. The proposed model is discussed in section 3. In section 4, the results are presented. Finally, in section 4, conclusions and considerations for future work are presented.

2. Proposed Model

Our proposed model's framework can be visualized in Figure 1. As can be observed from the framework, OpenCV and NumPy libraries have an important place in the working algorithm of our proposed system. The reason for using these libraries is that they are useful for image processing. NumPy is also widely used for multidimensional arrays and mathematical operations, which are frequently encountered in image processing.

As can also be observed from Figure 1, after importing the OpenCV and NumPy libraries, a video capture method is created in our proposed framework. The reason for this is to be able to capture and detect the images in the video recording. While creating this, the size of the frame of the capture screen is also adjusted. After this stage, methods are defined to detect colors. Following these defined methods, it is necessary to open a color palette to define the colors. This color palette is opened using the cv2.Color method. Then, it is time to determine how the image we want to be detected would be detected by the camera. For this, a point is specified in the middle of the screen. The camera is defined as a round value and set to the middle of the camera. In this way, the objects shown to the point appearing in the middle of the screen can be detected. After detecting the object with the camera, the process of detecting colors is started. Numbers between 0 and 255 corresponding to the colors are used here. The range is determined for each color. Colors corresponding to numbers could be defined thanks to the cycles defined in the system. After determining the color of the detected objects, the putText method is used to display the detected colors on the screen. When it comes to the final stage of the project, it is requested to display a visual on the screen according to the colors. For this, images are displayed on the screen by using the circle method. Finally, the system is terminated with the release and destroyAllWindows methods so that the video from which the video is taken will not continue.

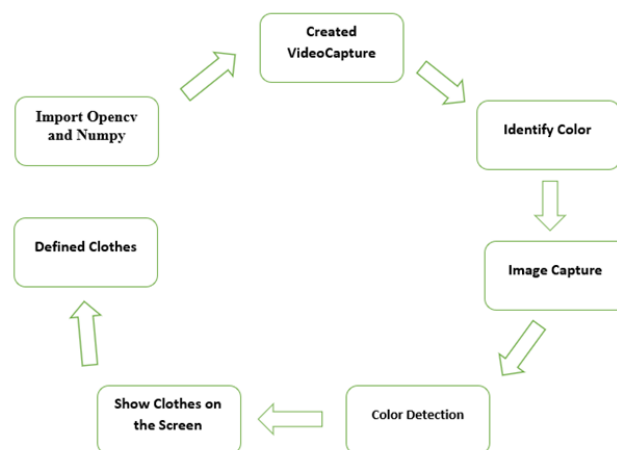


Figure 1. The framework of the proposed model

In addition to all these processes, the idea of transferring data from files is studied when displaying the data as seen in Figure 2. Then, a dataset is created as seen in Figure 3. The pictures that are requested to be included in this created data set are positioned according to their colors and then called from the system. In this way, the desired images are displayed on the screen when the colors are detected.

blue	25.05.2022 00:19	Dosya klasörü
green	25.05.2022 01:29	Dosya klasörü
orange	25.05.2022 01:43	Dosya klasörü
red	25.05.2022 00:19	Dosya klasörü
violet	25.05.2022 01:45	Dosya klasörü
yellow	25.05.2022 01:40	Dosya klasörü

Figure 2. Filling Method




Figure 3. The dataset in the proposed system

3. Results and Discussions

In order to derive results, the RGB method is first used for the color detection. With this method, different and inefficient results are obtained for our system as exemplified in Figure 4. For example, as seen in Figure 4, when run for orange color, data [0 94 254] is received. So 'Green' is 94. In this method, each pixel has the same value. Although there is no problem with still images, it is not useful as the aim of the project is to capture real-life images at that moment. Because this method simply mixes the colors and identifies the presence of each by showing the resulting color. So, RGB method is converted to the HSV method to obtain results with our proposed method.

```
import cv2
img = cv2.imread("orange_background.webp")
print(img)
cv2.imshow("Tm", img)
cv2.waitKey(0)
cv2.destroyAllWindows()
```

```
[[ 0  94 254]
 [ 0  94 254]
 [ 0  94 254]
 ...
 [ 0  94 254]
 [ 0  94 254]
 [ 0  94 254]]
```

Figure 4. The end obtained from the RGB method

In our proposed model, another important thing to mention is the camera point, which plays an important role in perceiving the color of the image. The biggest disadvantage with this is that the color detection capacity of the camera is different due to the image quality. For example, it may detect a distant white object as blue due to camera quality. Therefore, it can actually display images of unwanted colors. For example, when it detects a white wall in a distant and illuminated environment, it can print it in blue on the screen. This is a negative result we get. However, to minimize this and get efficient results, we convert RGB to HSV and we receive the results we want. The results screen of our proposed model can be seen in Figure 5. Apart from camera quality the system is working properly when we bring an object to the screen, whatever color the part corresponding to the point is, that color appears on the screen and the relevant pictures are displayed. The result is about the registered colors that we add to our filling system.




Figure 5. Result Screen

4. Conclusions and Future Work

In this study, a model that brings images of clothes and accessories according to the desired colors has been proposed. The wealth of the Python-OpenCV libraries have been used in the proposed study. In addition, the differences and usage areas of the methods used in color perception and the areas where they are efficient have attracted attention. Along with the results of the proposed model, different color perception models have also been observed to prove the effectiveness of the proposed model. The results of the proposed model have been observed as desired compared to the different color perception models.

There are many ways that can be done in the future to make this app useful in real life. For this application, high resolution cameras that are more sensitive and adaptable to environmental conditions can be used. In order to expand the color range, more color ranges can be added to the system and tested one by one. In addition to these, the data system can be supported with database systems so that it can be integrated into a more complex system. Thanks to this database support, it can even be transformed into a system that proposes combinations for users who use the application. As a result of all these, it can be turned into a system that can be used in stores in the future. In other words, a user who shows the color he wants to the camera can see all the clothes with that color and even the content that is compatible with it and can easily choose it.

References

- [1] Google Inc., “What does RGB even mean? Find out this and more with a brief overview of what RGB is and how you can use it in your web designs.” 2022. [Online]. Available: <https://www.shutterstock.com/blog/rgb-definition-design-work>. [Accessed 13 June 2022].
- [2] Hsiao Ping Lee, Jun-Te Huang, Chien-Hsing Chen*, Tzu-Fang Sheu “Building a Color Recognizer System on the Smart Mobile Device for the Visually Challenged People” The Sixth International Multi-Conference on Computing in the Global Information Technology –2011
- [3] P. Sudharshan Duth, M. Mary Deepa, “Color Detection in RGB-modeled images using MATLAB” Research Paper-2018
- [4] Hüseyin Bilal Macit, “Python ve OpenCV ile RGB Üzerinde HSV Renk Kodu Tespiti” 2020. [Online]. Available:<https://www.hbmacit.com/2020/09/15/python-ve-opencv-ile-rgb-uzerinde-hsv-renk-kodu-tespiti/>. [Accessed 13 June 2022].
- [5] CCD information: <https://www.guvenlikonline.com/makale/413/ccd-kamera.html>

SLEEP DETECTION SYSTEM

Ahmet Berkay SARIASLAN¹, Sudenur ATA², Yunus NOGAY³, Kadir Kaan YAZGAN⁴,
Gökçe NUR YILMAZ⁵

¹ Computer Engineering Department, Ted University, Turkey, aberkay.sariaslasn@tedu.edu.tr

² Computer Engineering Department, Ted University, Turkey, sudenur.ata@tedu.edu.tr

³ Computer Engineering Department, Ted University, Turkey, yunus.nogay@tedu.edu.tr

⁴ Computer Engineering Department, Ted University, Turkey, kaan.yazgan@tedu.edu.tr

⁵ Computer Engineering Department, TED University, Turkey, gokce.yilmaz@tedu.edu.tr

Abstract

In today's day by day developing technological area, automobiles have become more of a software tool than a mechanical tool. Moreover, safe driving becomes more important than motor technologies. Considering these, in this study, we focus on safe driving and we develop a system that can make alert in emergency situations. While developing our proposed system, we consider the driver of a vehicle as an object representation and then we measure the distance of this object to a camera placed in this vehicle using specific distance measures. The performance evaluation results of our proposed model prove that it is quite effective for assisting safe driving.

Keywords: *Driver, Safety, Security*

1. Introduction

With the day by day developing technology, automobiles have been considered as a software tool than a mechanical tool. When we look at recent years, they are more noted for their safe driving equipment than motor technologies. At this point, our main goal is to highlight the dynamism of safe driving. It is carelessness that causes thousands of traffic accidents every year. In this study, important causes such as inattention and insomnia are examined. In order to prevent these things, we believe that it is right for computer vision to come into play at this point. In addition to the safe driving, we want to design a system that could also be used as a stimulus system in emergency situations. It should also be used for unexpected head drops, sudden approach to the steering wheel, for example, in emergency situations such as a heart attack.

As a priority when designing our study, we use an open source image processing library. At this point, we have reviewed many projects that will be examples of image processing and computer vision thanks to OpenCV. Finally, we prepare an algorithm to get the security alert we want. A measurement will be made between the driver's eyes and the steering wheel while the driver is actively at vehicle. The result of this measurement will give a warning message on the screen with the arrival of the driver at a dangerous distance for instance if he gets too close to the steering wheel. In this way, it will reflect a safety warning for the driver. Another issue is the incident when the driver falls asleep, that is, if his eyes are completely closed or yawned, the warning system is activated. Because this is also a very dangerous situation in traffic [3].

Thanks to the introduction of computer vision into our lives, it is possible for us to see autonomous vehicles. However, autonomous driving is being tested before autonomous vehicles. We also wanted to try a more reliable

and inexpensive way of autonomous driving in our study. Its cost as an integration is low, and its application efficiency is high. At this point, it is possible to say that our project is distinctive [5].

The remainder of the article is organized as follows. The model proposed is introduced in second section. The proposed model is discussed in section 3. In section 4, the results are presented. Finally, in section 4, conclusions and considerations for future work are presented.

2. Proposed Model

The framework of our proposed system is presented in Figure 1. It shows the driver as an object representation. We use the focal length and distance formulas presented in this framework. In order to handle these formulas in our proposed model, we consider measuring the distance as can be observed from Figure 2. For measuring the distance, we proceed taking the distance at first from the shoulders of the drivers. Our pixel size and the distance we take from the heads of the shoulders successfully measured the distance when we approach the camera. However, no warning returns a signal. Then, we decide to draw the distance at eye level as the right place. At this point, the resource scanning discussed in the literature become quite useful to us. In this way, it has become more effective for us to analyze the driver's sleep stop or sudden health problem at eye level [6].




Figure 1. The framework of our proposed model




Figure 2. The distance measurement of our proposed model

3. Results and Discussions

While deriving results using our proposed system, first of all, there is a section where the camera should be turned on on our current machine [1] Then, our face section is located. We keep our FaceMash command "False". Because we don't want the driver to see the "FaceMashes" at this stage. Since we can calculate the points in the background ourselves, we can determine the image closest to the natural image as "draw=False" both in terms of the driver's attention and in terms of the natural image. We have points inside the Try block. Thanks to these points, we are able to decipher the distance between the two eyes. After this distance, it remains to add conditions [4]

The condition block is the golden key to our security system. Because the value of 35 centimeters is peeped here. As soon as it drops below 35 centimeters, the warning system that will come out is kept here [2].

We also consider about closed eyes and yawning detection while deriving the results. We decouple the pixels, measured them as the distance between the two eyelids and lips.[7]. We fix the ideal time by trial and error. We press the same warning on the screen for situations that will occur due to yawning and drowsiness [8].

The results obtained using our proposed systems by considering all of these facts can be seen from Figure 3. As observed from the results of the proposed system, when the distance decreases or the lips are wide open or the eyes are open, a warning is given by the system. All of the other results derived by the proposed system also present similar results which proves the effectiveness of our proposed model for the safe driving.

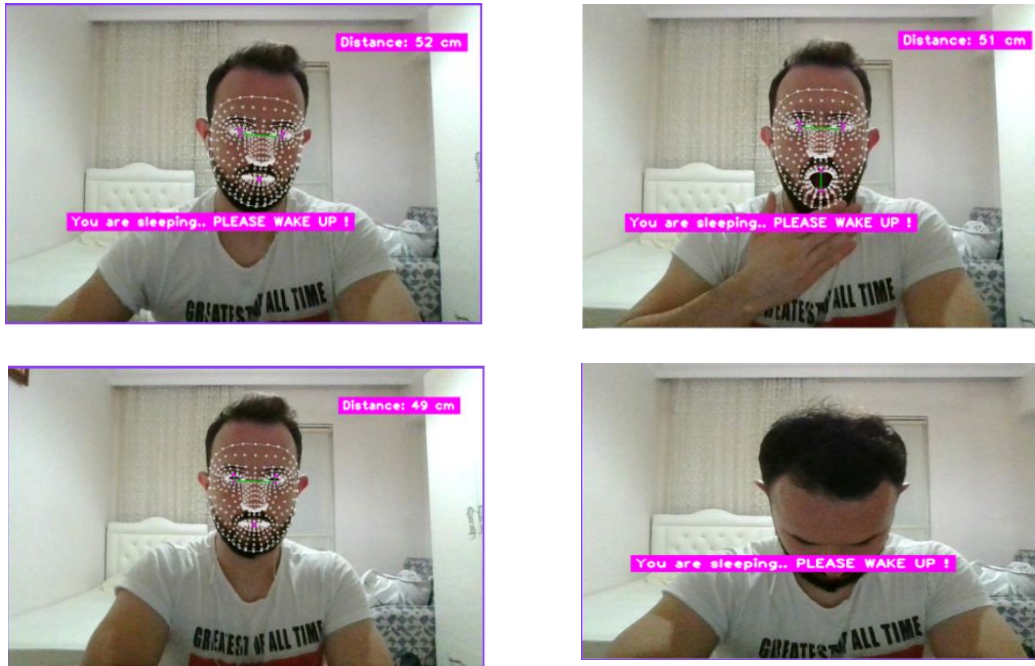


Figure 3. The derived results

4. Conclusions and Future Work

In this study, we have focused on safe driving and we have developed a system that can make alert in emergency situations. We have considered the driver of a vehicle and then we have measured the distance of this driver to a camera placed in this vehicle in this system. Specific distance measurement equations have been considered while measuring these distances. The performance evaluation results of our proposed model have proven that the proposed system is quite effective for assisting safe driving.

With the day by day developing technology, the detection time is significantly reduced, and even thanks to autonomous driving features, it is possible to park the car in a safe area at the time of danger, call for emergency assistance. We believe that we have released a system that is suitable for integration with the new technological improvements.

References

- [1] YouTube. (2020, October 5). Real-time drowsiness detection tutorial | transfer learning | tensorflow | python | opencv. YouTube. Retrieved May 11, 2022, from <https://www.youtube.com/watch?v=qwUIFKi4V48>
- [2] How to install pip on windows ? GeeksforGeeks. (2021, October 5). Retrieved May 2, 2022, from <https://www.geeksforgeeks.org/how-to-install-pip-on-windows/>
- [3] Yorgunluk Tespit sistemi nedir? Nasıl çalışır? " Bilgiustam. Bilgiustam. (2017, December 27). Retrieved May 25, 2022, from <https://www.bilgiustam.com/yorgunluk-tespit-sistemi-nedir-nasil-calisir/>
- [4] Mhproductionhouse. (2022, January 9). Face distance measurement with a normal webcam | computer vision. YouTube. Retrieved May 1, 2022, from <https://www.youtube.com/watch?v=jsoe1M2AjFk>

- [5] Masala, G.L., Grosso E., (2014). Real time detection of driver attention: Emerging solutions based on robust iconic classifiers and dictionary of poses. Transportation Research Part C, 49, 32-42.
- [6] YouTube. (2022, February 1). How to download Dlib without any errors for python 3.10.x | cool py. YouTube. Retrieved May 14, 2022, from <https://www.youtube.com/watch?v=cfu64Po3-nl>
- [7] Marmara Fen Bilimleri Dergisi, 2018, 3: Real Time Driver Fatigue Detection System 249-259 Retrieved May 17, 2022, from <https://dergipark.org.tr/tr/download/article-file/580461>
- [8] Dalal, N., Triggs B., (2005). Histograms of oriented gradients for human detection. Proceedings on IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 1, 886-893. Retrieved May 3, 2022

Makine Öğrenmesi Yöntemleri İle Tutumun Tahmin Edilmesi

Predicting Attitude With Machine Learning Methods

Kadriye Filiz BALBAL

Milli Eğitim Bakanlığı, Türkiye, kfbalbal@gmail.com

Özet

Bu çalışmada lisans öğrencilerinin mobil öğrenmeye yönelik tutumlarının makine öğrenmesi yöntemleri ile tahmin edilmesi amaçlanmaktadır. Bu amaçla, lisans öğrencilerine demografik bilgiler anketi ve mobil öğrenmeye yönelik tutum ölçeği uygulanmıştır. Öğrencilerin; yaş, cinsiyet, sınıf, interneti hangi amaçlarla kullandıkları ve haftalık internet kullanma süresi verileri kullanılarak mobil öğrenmeye yönelik tutumlarının tahmini için sınıflandırma çalışması gerçekleştirilmiştir. WEKA yazılımı ile gerçekleştirilen çalışmada Naive Bayes, K-En Yakın Komşu, Destek Vektör Makineleri, Rastgele Orman ve J48 Karar Ağacı sınıflandırma algoritmaları kullanılmıştır. Sınıflandırma algoritmaları için varsayılan parametre değerleri kullanılmıştır. Veri setinin eğitim ve test setleri olarak ayrılmasında 10-fold cross-validation yöntemi ve eğitim seti için %66, test seti için %34 paylaştırarak uygulanan Percentage Split yöntemi kullanılmıştır. Sınıflandırma algoritmalarının tahmin etme başarımlarının değerlendirilmesinde doğruluk, kesinlik, duyarlılık, F-ölçütü ve kappa istatistiği değerleri dikkate alınmıştır. Veri setinin eğitim ve test setleri olarak ayrılmasında kullanılan her iki yöntemde de en başarılı sınıflandırma algoritmasının Rastgele Orman Algoritması olduğu gözlenmiştir. Belirlenen değerlendirme kriterlerine göre gerçekleştirilen sınıflandırmada en başarısız algoritmanın Naive Bayes algoritması olduğu görülmüştür.

Anahtar Sözcükler: *eğitsel veri madenciliği; makine öğrenmesi; sınıflandırma.*

Abstract

In this study, it is aimed to predict the attitudes of undergraduate students towards mobile learning with machine learning methods. For this purpose, a demographic information questionnaire and an attitude scale towards mobile learning are applied to undergraduate students. A classification study is carried out to estimate the students' attitudes towards mobile learning by using age, gender, class, the purposes for which they use the internet and the weekly internet usage time. Naive Bayes, K-Nearest Neighbor, Support Vector Machines, Random Forest and J48 Decision Tree classification algorithms are used in the study performed with WEKA software. Default parameter values are used for classification algorithms. The 10-fold cross-validation method and the Percentage Split method, which is applied by splitting the data set into training and test sets, are used by dividing 66% for the training set and 34% for the test set. In evaluating the estimation performance of the classification algorithms, accuracy, precision, sensitivity, F-measure and kappa statistics values are taken into account. It has been observed that the most successful classification algorithm is the Random Forest Algorithm in both methods used to separate the data set into training and test sets. It is seen that the most unsuccessful algorithm in the classification performed according to the determined evaluation criteria is the Naive Bayes algorithm.

Keywords: *educational data mining; machine learning; classification.*

1. Giriş

Günümüzde makineler, büyük miktarda veriyi çok hızlı bir şekilde inceleyip anlamlı ilişkiler bulacak şekilde eğitilmektedir. Disiplinlerarası bir çalışma alanı olan makine öğrenmesi sağlık, ekonomi, astronomi, tıp ve eğitim gibi pek çok alanda uygulanmaktadır [1].

Eğitim alanında yapılan makine öğrenmesi araştırmalarının sayısı her geçen gün artmaktadır. [2], lise öğrencileri ile gerçekleştirdikleri çalışmada okulun doğası ile öğrencilerin akademik başarıları arasındaki ilişkiyi makine öğrenmesi yöntemleri ile incelemişlerdir. [3], Hindistan'daki bir ortaokulda öğrenim gören 400 öğrencinin akademik performanslarını etkileyen faktörleri makine öğrenmesi algoritmaları ile incelemiştir. [4], öğrencilerin akademik başarıları üzerinde en çok etkisi olan değişkenlerin anne eğitim durumu ve ailenin gelir durumu olduğunu buldukları çalışmada basit doğrusal regresyon analizi kullanmışlardır. [5], üniversite öğrencilerinin performanslarını tahmin etmek için 5 farklı sınıflandırma algoritması kullanmışlar ve yüksek tahmin doğruluğu elde etmişlerdir.

Literatürde yer alan araştırmalar incelendiğinde eğitimde makine öğrenmesi yöntemlerini uygulayan çalışmaların genellikle öğrencilerin performansları ve akademik başarıları üzerinde yoğunlaştıkları görülmektedir. Oysa, öğrencilerin derse karşı geliştirdikleri tutumun ve tutumu etkileyen değişkenlerin makine öğrenmesi yöntemleri ile incelenmesinin eğitimciler ve eğitim yöneticilerine faydalı bilgiler sağlayabileceği düşünülmektedir. Bu amaçla çalışmamızda, lisans öğrencilerinin mobil öğrenmeye yönelik tutumları makine öğrenmesi yöntemleri ile incelenmiş ve ileriye dönük tahminleme yapılmıştır. Çalışmanın ikinci bölümünde yöntem, üçüncü bölümünde makine öğrenmesi algoritmaları, dördüncü bölümünde bulgular ve beşinci bölümünde ise sonuç ve öneriler yer almaktadır.

2. Yöntem

Çalışmada, lisans öğrencilerine demografik bilgiler anketi ve [6] tarafından geliştirilen mobil öğrenmeye yönelik tutum ölçeği uygulanmıştır. Öğrencilerin; yaş, cinsiyet, sınıf, interneti hangi amaçlarla kullandıkları ve haftalık internet kullanma süresi verileri kullanılarak mobil öğrenmeye yönelik tutumlarının tahmini için sınıflandırılma çalışması gerçekleştirilmiştir. WEKA yazılımı ile gerçekleştirilen çalışmada varsayılan parametre değerleri ile beş farklı sınıflandırma algoritması kullanılmıştır. Sınıflandırma algoritmalarının tahmin etme başarımlarının değerlendirilmesinde doğruluk, kesinlik, duyarlılık, F-ölçütü ve kapa istatistiği değerleri dikkate alınmıştır.

3. Makine Öğrenmesi

Makine öğrenmesinde karar vermek için insan düşünce yapısını modelleyen algoritmalar geliştirilmektedir [7]. Uygun makine öğrenmesi algoritmaları ile büyük miktarda veri sınıflandırılarak geleceğe yönelik tahminlemeler yapılabilmektedir [8]. Bu çalışmada Naive Bayes, K-En Yakın Komşu, Destek Vektör Makineleri, Rastgele Orman ve J48 Karar Ağacı sınıflandırma algoritmaları kullanılmıştır.

Naive Bayes algoritması, Bayes teoremine dayalı olarak geliştirilmiş yaygın kullanılan, istatistik temelli bir algoritmadır [9]. K-En Yakın Komşu algoritması, veri setindeki değişkenler arasında en yakın komşuları bularak sınıflandırma analizi yapar. Algoritmanın başarısı, veri seti için uygun bir k parametresi seçilmesi ile yakından ilişkilidir [10]. 1965 yılında geliştirilen ve güçlü bir matematiksel altyapıya sahip olan Destek Vektör Makineleri algoritması n-boyutlu bir hiper düzlem oluşturarak verileri sınıflandırır [11]. Rastgele Orman algoritması, kategorik ve sürekli verilerin olduğu veri setlerinde kullanılabilirken kayıp verilerden de etkilenmez [12]. J48 Karar Ağacı algoritması ise kök ve karar düğümleri oluşturarak sınıflandırma yapan güçlü ve yaygın kullanımı olan algoritmalarından biridir.


4. Bulgular

Bu bölümde, lisans öğrencilerinin mobil öğrenmeye yönelik tutumlarının tahmini için uygulanan sınıflandırma algoritmaları sonucunda elde bulgular yer almaktadır.

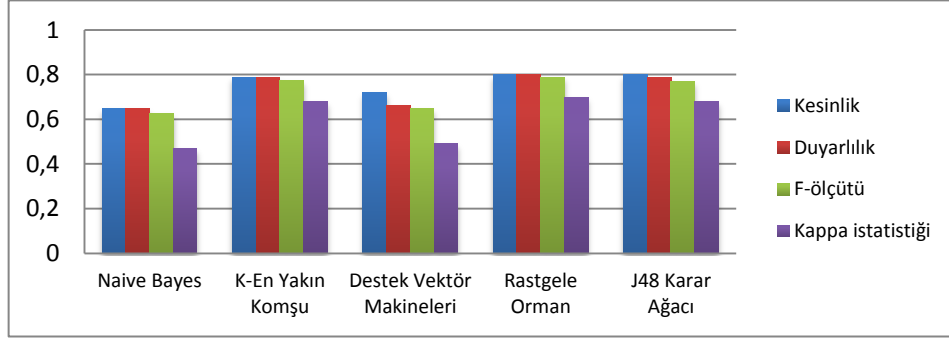
Tablo 1. 10-fold cross-validation yöntemi kullanılarak gerçekleştirilen analiz sonucunda sınıflandırma algoritmaları ile elde edilen doğruluk, kesinlik, duyarlılık, F-ölçütü ve kapa istatistiği değerleri.

Sınıflandırma	Doğruluk (%)	Kesinlik	Duyarlılık	F-ölçütü	Kapa istatistiği
Naive Bayes	64.6667	0.647	0.647	0.626	0.47
K-En Yakın Komşu	78.6667	0.789	0.787	0.774	0.68
Destek Vektör Makineleri	66	0.721	0.660	0.649	0.49
Rastgele Orman	80	0.801	0.800	0.789	0.7
J48 Karar Ağacı	78.6667	0.801	0.787	0.770	0.68

Tablo 1’de 10-fold cross-validation yöntemi kullanılarak gerçekleştirilen analiz sonucunda sınıflandırma algoritmaları ile elde edilen doğruluk, kesinlik, duyarlılık, F-ölçütü ve kapa istatistiği değerleri verilmiştir. Tablo 1’e göre bütün değerlendirme kriterleri bakımından en başarılı sınıflandırma Rastgele Orman Algoritması ile, en başarısız sınıflandırma ise Naive Bayes Algoritması ile elde edilmiştir. Tablo 1’de elde edilen sonuçlara ait sütun grafikleri Şekil 1 ve Şekil 2’de yer almaktadır.



Şekil 1. 10-fold cross-validation yöntemi kullanılarak gerçekleştirilen analiz sonucunda sınıflandırma algoritmaları ile elde edilen doğruluk değerleri.




Şekil 2. 10-fold cross-validation yöntemi kullanılarak gerçekleştirilen analiz sonucunda sınıflandırma algoritmaları ile elde edilen kesinlik, duyarlılık, F-ölçütü ve kappa istatistiği değerleri.

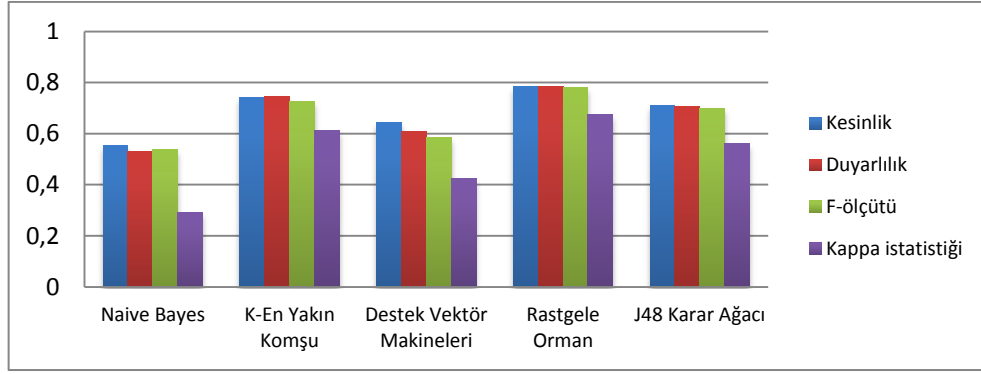
Tablo 2’de Percentage split yöntemi kullanılarak gerçekleştirilen analiz sonucunda sınıflandırma algoritmaları ile elde edilen doğruluk, kesinlik, duyarlılık, F-ölçütü ve kappa istatistiği değerleri verilmiştir. Tablo 2’ye göre bütün değerlendirme kriterleri bakımından en başarılı sınıflandırma Rastgele Orman Algoritması ile, en başarısız sınıflandırma ise Naive Bayes Algoritması ile elde edilmiştir. Tablo 2’de elde edilen sonuçlara ait sütun grafikleri Şekil 3 ve Şekil 4’te yer almaktadır.

Tablo 2. Percentage split yöntemi kullanılarak gerçekleştirilen analiz sonucunda sınıflandırma algoritmaları ile elde edilen doğruluk, kesinlik, duyarlılık, F-ölçütü ve kappa istatistiği değerleri.

Sınıflandırma	Doğruluk (%)	Kesinlik	Duyarlılık	F-ölçütü	Kappa istatistiği
Naive Bayes	52.9412	0.555	0.529	0.537	0.2925
K-En Yakın Komşu	74.5098	0.741	0.745	0.726	0.6145
Destek Vektör Makineleri	60.7843	0.645	0.608	0.586	0.4231
Rastgele Orman	78.4314	0.784	0.784	0.781	0.6768
J48 Karar Ağacı	70.5882	0.709	0.706	0.700	0.5603



Şekil 3. Percentage Split yöntemi kullanılarak gerçekleştirilen analiz sonucunda sınıflandırma algoritmaları ile elde edilen doğruluk değerleri.



Şekil 4. Percentage Split yöntemi kullanılarak gerçekleştirilen analiz sonucunda sınıflandırma algoritmaları ile elde edilen kesinlik, duyarlılık, F-ölçütü ve kappa istatistiği değerleri.

5. Sonuçlar

Bu çalışmada, lisans öğrencilerinin yaş, cinsiyet, sınıf, interneti hangi amaçlarla kullandıkları ve haftalık internet kullanma süresi verileri kullanılarak mobil öğrenmeye yönelik tutumlarının tahmini için WEKA yazılımı ile sınıflandırılma çalışması gerçekleştirilmiştir. 5 farklı sınıflandırma algoritması için varsayılan parametre değerleri kullanılmıştır. Veri setinin eğitim ve test setleri olarak ayrılmasında 10-fold cross-validation yöntemi ve eğitim seti için %66, test seti için %34 paylaştırarak uygulanan Percentage Split yöntemi kullanılmıştır. Sınıflandırma algoritmalarının tahmin etme başarımlarının değerlendirilmesinde doğruluk, kesinlik, duyarlılık, F-ölçütü ve kappa istatistiği değerleri dikkate alınmıştır. Veri setinin eğitim ve test setleri olarak ayrılmasında kullanılan her iki yöntemde de en başarılı sınıflandırma algoritmasının Rastgele Orman, en başarısız algoritmanın ise Naive Bayes olduğu görülmüştür.

Referanslar

- [1] Savaş, S., Topaloğlu, N., & Yılmaz, M. (2012). Veri madenciliği ve Türkiye'deki uygulama örnekleri. İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, 21, s. 1-23.
- [2] Beaumont-Walters, Y., & Soyibo, K. (2001). An analysis of high school students' performance on five integrated science process skills. Research in Science & Technological Education, 19(2), 133-145.
- [3] Khan, Z. N. (2005). Scholastic Achievement of Higher Secondary Students in Science Stream, Journal of Social Sciences, Vol., No. 2, 2005, pp. 84-87.
- [4] Hijazi, S.T. and Raza Naqvi, S.M.M. (2006). Factors Affecting Students' Performance A Case Of Private Colleges. Bangladesh e-Journal of Sociology. Volume 3. Number 1, January 2006, pp. 90-100.
- [5] Kotsiantis, S., Pierrakeas, C. and Pintelas, P. (2004). Prediction of Student's Performance in Distance Learning Using Machine Learning Techniques. Applied Artificial Intelligence, Vol. 18, No. 5, 2004, pp. 411-426.
- [6] Çelik, A. (2013). M-Öğrenme Tutum Ölçeği: Geçerlik ve Güvenirlik Analizleri. Journal of Research in Education and Teaching, 2(4), 2146-9199.
- [7] İnik, Ö. & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6(3), 85-104.
- [8] Suthaharan, S. (2014). Big data classification: Problems and challenges in network intrusion prediction with machine learning. ACM SIGMETRICS Performance Evaluation Review, 41(4), 70-73.
- [9] H. Zhang, "The optimality of naive Bayes," in: FLAIRS Conference, 2004, s. 562-567.
- [10] B. Li, S. Yu ve Q. Lu, "An improved k-nearest neighbor algorithm for text categorization," Proceedings of the 20th International Conference on Computer Processing of Oriental Languages, 2003, <https://arxiv.org/ftp/cs/papers/0306/0306099.pdf>.
- [11] C. Cortes ve V. Vapnik, "Support-vector networks," Machine learning, cilt 20, sayı 3, s. 273-297, 1995.
- [12] Akman, M., Genç, Y., & Ankaralı, H. (2011). Random Forests Yöntemi ve Sağlık Alanında Bir Uygulama/Random Forests Methods and an Application in Health Science. Türkiye Klinikleri Biyoistatistik, 3(1), 36.

Farklı Veri Artırım Teknikleri ile Derin Öğrenme Tabanlı Cilt Lezyonu Tespiti Deep Learning Based Skin Lesion Detection with Different Data Augmentation Techniques

Behlul SARIKAYA^{1,*}, Aybars UGUR²

¹ Bilgisayar Mühendisliği Bölümü, Pamukkale Üniversitesi, Türkiye, behluls@pau.edu.tr

² Bilgisayar Mühendisliği Bölümü, Ege Üniversitesi, Türkiye, aybars.ugur@ege.edu.tr

Özet

Cilt kanseri günümüzde görülen en yaygın kanser türlerinden biridir. Cilt kanserinin bazı türlerine toplumda daha az rastlanmasına rağmen bu tür vakaların ölümle sonuçlanma olasılığı daha yüksektir. Cilt lezyonları iyi huylu ve kötü huylu olarak iki gruba ayrılır. Bazı cilt lezyonu türleri kanser olarak nitelendirilmese de kansere dönüşme eğilimi gösterebilir. Cilt lezyonu türünün erken teşhisi, hem kansere dönüşme ihtimalini öngörebilmek hem de uygun biyopsi ve tedavinin seçilebilmesi için son derece önemlidir. Cilt lezyonunun ön tespiti bir profesyonel tarafından lezyonun karakteristik özelliklerine göre dermoskopik olarak yapılabilir. Ancak dermoskopik yöntemler, lezyonların birbirine benzediği durumlarda zaman alabilmekte ve patolojik sonuçlara göre farklılık gösterebilmektedir. Bu çalışmada derin öğrenme tabanlı cilt lezyonu tespitine odaklanılmıştır. Deneylerde 7 sınıftan toplam 10015 görüntüye sahip HAM10000 veri seti kullanılmıştır. Çalışmada, veri seti sınıflarındaki örnek sayısı dengesizliği probleminin üstesinden gelmek için stratejiler önerilmiştir. Bu kapsamda veri artırımı aşamasında, örnek sayısı fazla olan sınıflar ile örnek sayısı az olan sınıflara farklı sayıda görüntü ekleme yaklaşımı baz alınmıştır. Çalışmada 8 farklı veri artırımı stratejisi tasarlanarak deneysel sonuçlar elde edilmiş ve sınıflandırma performansına etkileri incelenmiştir.

Anahtar Sözcükler: *Derin öğrenme; cilt lezyonu; veri artırımı; sınıflandırma; ham10000.*

Abstract

Skin cancer is one of the most common types of cancer seen today. Although some types of skin cancer are less common in society, cases of these types are more likely to result in death. Skin lesions are divided into two groups, benign and malignant. Some skin lesions is not considered cancer but may tend to become cancer. Early diagnosis of skin lesion type is essential for both predicting the possibility of transform to cancer, and for selecting the appropriate biopsy and treatment. Pre-detection of skin lesion can be performed by a professional according to the characteristics of the lesion dermoscopically. However, the dermoscopic method may take a long time in cases where the lesions are similar to each other and may differ according to the pathological results. This study focused on deep learning-based skin lesion detection. The HAM10000 dataset with a total of 10015 images from 7 classes was used in the experiments. Strategies are proposed to overcome the problem of sample size imbalance in dataset classes. In this context, in the data augmentation phase, the approach of adding a different number of images to the classes with a large number of examples and to the classes with a small number of examples was taken as a basis. In the study, 8 different data augmentation strategies were designed, experimental results were obtained and the effects of designed strategies on classification performance were examined.

Keywords: *Deep learning; skin lesion; data augmentation; classification; ham10000.*

1. Giriş

Cilt kanseri en yaygın görülen kanser türlerindenidir. Yalnızca ABD’de her yıl 5 milyondan fazla yeni cilt kanseri vakasına rastlanmaktadır [1]. Melanom, kötü huylu cilt kanserlerinin en nadir görülen türü olsa da en yüksek ölüm sayısına sahip türdür [2]. Amerikan Kanser Topluluğu’na (ACS) göre 2022 yılında 99.780 yeni melanom vakası ve 7.650 ölüm olacağı beklenmektedir [1]. Doğrudan kanser olarak nitelendirilmeyen ancak kanser öncüsü olarak nitelendirilen lezyon türleri de bulunmaktadır [3]. İyi huylu cilt lezyonlarının kansere dönüşme süreci; kişinin UV ışın, kimyasal madde ve radyasyon teması gibi risk faktörlerine maruz kalma şiddetine göre değişebilmektedir. Cilt lezyonlarının biyopsisi ve tedavisi için bazı yöntemlere başvurulmaktadır [2], [3]. Ancak uygulanacak bu yöntemlerin lezyon türüne göre seçilmesi gerekmektedir; Örneğin, pigmentli bir lezyon veya melanom türü için shave biyopsisi uygun değildir [2]. Bu sebepten dolayı cilt lezyonlarının biyopsi

ve tedavi öncesi ön teşhisinin yapılması gerekmektedir. Ön teşhis ise profesyoneller tarafından bazı cihazlar ile manuel olarak yapılmaktadır. Dermoskopik olarak yapılan ön teşhis ve patoloji sonuçları karşılaştırıldığında ise dermoskopik yöntemlerin patolojik yöntemlere göre bazı yanlış tanıları koyduğu belirtilmiştir [4], [5]. Yanlış tanıları ortadan kaldırmak ya da azaltmak için bilgisayar destekli sistemlere ihtiyaç duyulmaktadır.

Derin öğrenme günümüzde pek çok alana dahil edilmekte ve kullanımı araştırılmaktadır [6]. Cilt lezyonu sınıflandırma problemi için pek çok derin öğrenme tabanlı çalışma yapılmıştır. Bu çalışmalarda cilt lezyonu tespitine; farklı sinir ağlarının performanslarını karşılaştırma, veri setine sentetik görüntü ekleme, görüntü ön işleme gibi farklı yönlerden yaklaşılmıştır [7], [8]. Huang ve arkadaşlarının yaptığı çalışmada, hafif bir derin öğrenme modeli geliştirilmiştir. En uygun modelin seçildiği bu çalışmada eğitim 2, 5 ve 7 sınıflı veri setleri ile yapılmıştır [9]. Veri setlerine göre sırası ile 89,5%, 72,1% ve 89,5% doğruluk değerleri elde edilmiştir. Ergün ve Kılıç'ın yaptıkları çalışmada, 6 farklı derin öğrenme modeli veri artırımı ve veri artırımı olmadan eğitilerek performansları karşılaştırılmıştır. Modeller veri artırımı olmadan ve veri artırımı ile eğitilerek değerlendirilmiştir [10]. Yazarlar, HAM10000 veri setindeki görüntüleri iyi ve kötü huylu olarak 2 sınıfa ayırmışlardır. Veri artırma teknikleri olarak ise yatay ve dikey çevirmeler, açı değiştirme, yakınlaştırma, kontrast ve parlaklık değiştirme gibi teknikler kullanılmıştır. Çalışmada, en iyi sonuç 87,5% doğruluk değeri ile ResNet-34 modeline aittir. Jain ve arkadaşlarının yaptıkları çalışmada altı farklı transfer learning modelinin HAM10000 veri seti üzerindeki performansı karşılaştırılmıştır [11]. Elde edilen değerlere göre, 90,48% doğrulukla XceptionNet, diğer modellerden daha iyi sonuç vermiştir.


Çalışmamızda; veri artırma ve ön işlemede başarısı bilinen yöntemlerin, cilt lezyonlarını sınıflandırmadaki performansı incelenmektedir. Veri seti olarak 7 farklı sınıftan örnekler barındıran, yaklaşık 10000 görüntüye sahip HAM10000 veri seti kullanılmaktadır. Literatürdeki çalışmalardan farklı şekilde; görüntü çözünürlükleri 64x64 boyutuna küçültülmüştür. Model olarak kullanılan önceden eğitilmiş VGG-16 modelinin ise tam bağlı katmanları yeniden oluşturulmuştur. VGG-16 modelinin kullanılmasının sebebi; temel modellerden biri olması ve başarılı sonuçlar elde etmesidir. Veri artırımı için “performansı iyi yönde etkilediği bilinen kesme ve döndürme yöntemleri” [12] kullanılmıştır. Veri setindeki dengesizliğin üstesinden gelebilmek için, veri artırımı ile sayıca daha az örnek barındıran sınıflara daha fazla görüntü eklenirken; sayıca oldukça fazla örnek barındıran sınıflara ise daha az görüntü eklenmiş ya da hiç görüntü eklenmemiştir. Tasarlanan stratejiler sonucu elde edilen veriler ile eğitilmiş modellerin performansı, ham görüntüler ile eğitilen model performansları ile karşılaştırılmıştır. Tasarlanan veri artırma stratejilerinde kullanılan dönüşüm yöntemleri ise şu şekildedir;

- Sadece kesme (crop)
- Sadece döndürme (rotate)
- Kesme ve döndürme kombinasyonları

2. Materyal ve Yöntem

2.1. Veri Seti

Çalışmada veri seti olarak 10015 görüntüye sahip HAM10000 veri seti kullanılmıştır. Veri setinde; Aktinik keratoz ve Bowen hastalığı (akiec), basal cell carcinoma (bcc), iyi huylu keratoz benzeri lezyonlar (bkl), dermatofibroma (df), melanoma (mel), melanositik nevüs (nv) ve damar lezyonları (vasc) olmak üzere toplam 7 lezyon sınıfı bulunmaktadır. Çalışmamızda, verilerin 70%'i eğitim, 30%'u ise test verisi olarak ayrılmıştır. Veri seti, sınıflara ait örnek sayısına bakıldığında dengesiz bir veri setidir. (Bkz: Şekil 1).



Şekil 1 : HAM10000 veri setindeki 7 adet cilt lezyonu sınıfı ve örnek sayıları

2.2 Yöntem ve Veri Artırım Teknikleri

Veri artırımı için 2 ana yöntem kullanılmıştır. Bunlar “Caltech101 veri seti üzerinde en başarılı artırım teknikleri olarak tespit edilen”[12] kesme (crop) ve döndürme (rotate) yöntemleridir. Kesme için rastgele kesme yöntemi kullanılmıştır (Limitleri : 90-128). Döndürme yöntemindeki döndürme açısı ise 15° olarak seçilmiştir. Seçilen teknikler ve limit değerleri, daha önceki çalışmamızda elde ettiğimiz sonuçlara göre belirlenmiştir. Son aşamada ise görüntüler, kaynakların daha verimli kullanılabilmesi için 64x64 çözünürlüğüne düşürülmüştür.

Veri artırmada ayrıca her sınıftaki örnek sayısına duyarlı bir artırma tekniği kullanılmaktadır. Örnek sayısının limit değeri olarak 2000 sayısı seçilmiştir. Bu durumda 2000’den az veri bulunduran sınıflara daha fazla görüntü eklenirken; 2000’den daha fazla örnek içeren sınıflara daha az görüntü eklenmiştir. Önerilen “örnek sayısına duyarlı” artırım tekniği için sınıflara eklenen her yeni görüntü, döndürme ve kesme teknikleri ile oluşturulmuştur. (Bkz. Şekil 2). Önerilen yöntemin performansa katkısını incelemek için 8 farklı veri artırım stratejisi geliştirilmiştir:

- **Strateji 1** : Tüm görüntülere kesme işlemi uygulanmaktadır.
- **Strateji 2** : Yalnızca az sayıda örnek içeren sınıf görüntülerine (nv sınıfı dışındakiler) kesme işlemi uygulanmaktadır.
- **Strateji 3** : Tüm görüntülere kesme işlemi uygulanmakta; Nv sınıfındaki görüntülerden 1, diğer sınıflardaki görüntülerden 2’şer görüntü üretilmektedir.
- **Strateji 4** : Tüm görüntülere döndürme yöntemi uygulanmaktadır.
- **Strateji 5** : Yalnızca az sayıda örnek içeren sınıf görüntülerine döndürme uygulanmaktadır.
- **Strateji 6** : Tüm görüntülere döndürme uygulanmakta; Nv sınıfındaki görüntülerden 1, diğer sınıflardaki görüntülerden 2’şer görüntü üretilmektedir.
- **Strateji 7** : Her iki yöntem ile 1’er görüntü üretilmektedir.
- **Strateji 8** : İki yöntem aynı anda uygulanmaktadır.



Şekil 2 : Deneylerde kullanılan görüntü örnekleri [13]
(a): Orijinal görüntü (b): Kesme yöntemi ile üretilmiş görüntü (c): Döndürme yöntemi ile üretilmiş görüntü

Tasarlanan stratejiler ile elde edilen veri setleri VGG-16 modeli üzerinde eğitilmiştir. Önceden daha büyük bir veri seti ile gerçekleştirilmiş öğrenme sürecinin daha küçük veri setlerine aktarılması sınıflandırma başarısını artırabilmektedir. Ayrıca tüm eğitimi tekrarlamamak açısından bazı katmanlar dondurularak eğitim dışı bırakılmaktadır. Bu sayede daha hızlı bir eğitim süreci geçirilmektedir. Bu çalışmada da ilgili model, ImageNet veri seti üzerindeki ağırlıkları ile dahil edilmiş ve üst katmanları dondurularak tam bağlı katman yeniden oluşturulmuştur.

3. Deneysel Çalışma ve Bulgular

Cilt lezyonu görüntüleri 7 sınıfta değerlendirilmiştir. Veri seti, 70%’i eğitim, 30%’u test verisi olacak şekilde ikiye ayrılmıştır. Model, kullanılan veri seti ile 30 devir (epoch) boyunca 0,01 öğrenme oranı ile eğitilmiştir. Son olarak; elde edilen 8 farklı modelin performans değerleri karşılaştırılmıştır. Veri artırımı yalnızca eğitim setlerinde yapılmıştır. Bazı deneylerde veri dengesizliğinin üstesinden gelmek için az sayıda örnek içeren sınıflara daha fazla görüntü eklenmiştir. Deneylere göre; kesme ve döndürme yöntemi ile yapılan artırımın, herhangi bir ön işleme ve artırım uygulamadan eğitilen modelin başarısını artırdığı gözlenmiştir (Bkz. Tablo 1). Uygulanan tekniklere bakıldığında, yalnızca kesme (crop) yönteminin kullanıldığı modeller daha yüksek başarı göstermiştir. 2. en iyi yöntem döndürme (rotate) olurken; her iki yöntemin kullanıldığı deneylerde modeller daha az başarılı olmuştur.

Deneyler görüntü artırım sayılarına göre değerlendirildiğinde; örnek sayısı az olan sınıflardaki görüntüleri çoğunluk sınıfa göre daha fazla sayıda artırmanın; kesme tekniğinin uygulandığı deneylerde model başarısını olumlu etkilediği ancak döndürme tekniğinin uygulandığı deneylerde başarıyı geliştirmediği gözlenmiştir.

Tablo 1. Veri artırım deneylerinden elde edilen başarımların sonuçları.

Teknik	Doğruluk	Kesinlik	Duyarlılık	F1-Skor
Veri Artırımı Olmadan (64x64)	0,6744	0,6012	0,6741	0,6266
Veri Artırımı Olmadan (128x128)	0,7147	0,6746	0,7161	0,6907
Strateji 1 (64x64)	0,7678	0,7333	0,7675	0,7386
Strateji 2 (64x64)	0,7681	0,748	0,7698	0,7538
Strateji 2 (128x128)	0,7725	0,7739	0,7745	0,7726
Strateji 3 (64x64)	0,7698	0,7489	0,7702	0,7516
Strateji 4 (64x64)	0,7655	0,7711	0,7655	0,7645
Strateji 4 (128x128)	0,7735	0,7551	0,7712	0,7611
Strateji 5 (64x64)	0,7604	0,7597	0,7618	0,7576
Strateji 5 (128x128)	0,7809	0,7692	0,7796	0,7725
Strateji 6 (64x64)	0,7594	0,7485	0,7597	0,7435
Strateji 7 (64x64)	0,7554	0,7627	0,755	0,7575
Strateji 8 (64x64)	0,7584	0,7513	0,7564	0,7444
Strateji 8 (128x128)	0,7772	0,7495	0,7752	0,7585

4. Sonuç ve Öneri

Sınıflardaki örnek sayılarında farklılıklar bulunan HAM10000 veri setinden elde edilen deneysel sonuçlara göre, az görüntü içeren sınıflarda daha çok veri artırımı yapmanın başarımı biraz daha fazla iyileştirebildiği görülmüştür. Önerilen örnek sayısına duyarlı veri artırım yöntemi, kesme (crop) tekniğinin kullanıldığı stratejilerde sınıflandırma performansını olumlu yönde etkilerken, döndürme (rotate) yönteminin kullanıldığı stratejilerde performansa katkı sağlamadığı gözlenmiştir. Sonuç olarak, önerdiğimiz veri artırım yaklaşımının değişik uygulama alanlarındaki benzer türdeki veri setlerine de uyarlanabileceği; stratejilerin ilerletilerek başarımın daha da artırılacağı değerlendirilmektedir.

Çalışmada eğitilen modellerin cilt lezyonunun ön tespitine ne ölçüde katkı sağlayacağı da incelenmiştir. Hekimler tarafından yapılan manuel teşhislerde en düşük 25% lik hata oranı bulunmaktadır [5]. Bu hata oranı hekimlerin uzmanlığına göre değişmektedir. Deney sonuçlarında en yüksek 77% lik doğruluk oranı ile önerilen yöntemlerin hekimlere ön teşhis için yardımcı olabileceği düşünülmektedir.

Literatürdeki çalışmalar, genel olarak daha gelişmiş modeller ile başarımları artırmaya odaklanmışken; bu çalışmada veri artırım tekniklerinin performansa etkisi incelenmiştir. Bundan dolayı bu çalışmada literatürdeki yüksek başarılı çalışmalara göre daha düşük doğruluk değerleri elde edilmiştir. Literatürdeki çalışmalarda daha yüksek çözünürlüklü görüntülerin kullanılması da değerlerin daha yüksek olmasını sağlamaktadır. 128x128 ve 64x64 çözünürlükteki iki farklı set görüntü ile eğitilen modellerin performansları karşılaştırıldığında 128x128 çözünürlüklü görüntüler ile eğitilen modellere ait doğruluk değerlerinin yüksek olması bunu açıklamaktadır.

Referanslar

- [1] "Skin Cancer Research Highlights | Skin Cancer New." <http://web.archive.org/web/20220517010505/cancer.org/research/acs-research-highlights/skin-cancer-research-highlights.html> (accessed Apr. 20, 2022).
- [2] M. A. Linares, A. Zakaria, and P. Nizran, "Skin Cancer," *Primary Care*, vol. 42, no. 4, pp. 645–659, 2015, doi: 10.1016/J.POP.2015.07.006.
- [3] "Deri Kanseri Öncüsü Lezyonlar." <https://web.archive.org/web/20210622145255/https://www.derikanseri.org/lezyon-deri-kanseri> (accessed Apr. 21, 2022).
- [4] N. Kurt Özkaya, S. Sağlam Zor, and M. Çepni, "Pigmente Deri Lezyonlarında Dermoskopik ve Patolojik Tanıların Karşılaştırılması," *Van Medical Journal*, vol. 22, no. 3, pp. 177–181, 2015.
- [5] M. Turhan, A. Türel Ermertcan, I. İnanır, A. Demir, and S. Öztürkcan, "Nevus Nevosellularislerde Dermoskopik ve Histopatolojik Tanıların Karşılaştırılması," *ADÜ Tıp Fakültesi Dergisi*, vol. 5, no. 2, pp. 19–22, 2004.
- [6] Ferdi Doğan and İbrahim Türkoğlu, "Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme," *DÜMF Mühendislik Dergisi*, vol. 10, no. 2, pp. 409–445, 2019, doi: 10.24012/dumf.411130.
- [7] M. Dildar *et al.*, "Skin Cancer Detection: A Review Using Deep Learning Techniques," *International Journal of Environmental Research and Public Health*, vol. 18, no. 10, p. 5479, May 2021, doi: 10.3390/IJERPH18105479.
- [8] M. A. Kassem, K. M. Hosny, R. Damaševičius, and M. M. Eltoukhy, "Machine Learning and Deep Learning Methods for Skin Lesion Classification and Diagnosis: A Systematic Review," *Diagnostics*, vol. 11, no. 8, p. 1390, Jul. 2021, doi: 10.3390/DIAGNOSTICS11081390.

- [9] H. W. Huang, B. W. Y. Hsu, C. H. Lee, and V. S. Tseng, "Development of a light-weight deep learning model for cloud applications and remote diagnosis of skin cancers," *The Journal of Dermatology*, vol. 48, no. 3, pp. 310–316, Mar. 2021, doi: 10.1111/1346-8138.15683.
- [10] E. Ergün and K. Kılıç, "Derin Öğrenme ile Artırılmış Görüntü Seti üzerinden Cilt Kanseri Tespiti," *Black Sea Journal of Engineering and Science*, vol. 4, no. 4, pp. 192–200, Oct. 2021, doi: 10.34248/BSENGINEERING.938520.
- [11] S. Jain, U. Singhanian, B. Tripathy, E. A. Nasr, M. K. Aboudaif, and A. K. Kamrani, "Deep Learning-Based Transfer Learning for Classification of Skin Cancer," *Sensors*, vol. 21, no. 23, p. 8142, Dec. 2021, doi: 10.3390/S21238142.
- [12] L. Taylor and G. Nitschke, "Improving Deep Learning with Generic Data Augmentation," *Proceedings of the 2018 IEEE Symposium Series on Computational Intelligence, SSCI 2018*, pp. 1542–1547, Jan. 2019, doi: 10.1109/SSCI.2018.8628742.
- [13] "Skin Cancer MNIST: HAM10000 | Kaggle." <http://web.archive.org/web/20220507101104/https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000> (accessed Apr. 29, 2022).

A Turkish Metaphor Detection Method Using Masked Language Models

Emrah İNAN¹

¹ National Centre for Text Mining, School of Computer Science, The University of Manchester, United Kingdom, emrah.inan@gmail.com
<https://orcid.org/0000-0002-1229-6895>

Özet

Metaforlar günlük sözlü ve yazılı iletişimde yaygın olarak kullanılan ifadelerdir. Bu ifadeler, verilen kelimelerin bağlamındaki gerçek anlamlarını almak yerine, bir kavram hakkında başka bir kavram ile akıl yürüterek doğal dili zenginleştirir. Ancak, bu ifadeler bir makinenin dili anlama yeteneğini azaltma eğilimindedir. Bu çalışmada, Türkçe metinlerdeki metaforları tespit etmek için bir yöntem sunulmaktadır. İlk olarak, mecazi ifadelerle ait anlamlar ve örnek metinler çevrimiçi bir Türkçe sözlükten alınmaktadır. Ardından, gerçek terimi, maskeli dil modelinin ona daha yüksek bir olasılık atayıp atamadığını tahmin etmek için modelin puanlama yöntemini kullanırız. Deneysel sonuçlar, Türkçe metinlerdeki metaforları tespit etmek için ELECTRA modelinin maske doldurma yöntemi kullanıldığında, oluşturulan değerlendirme veri seti için sunulan yöntemin 0,65 olarak en iyi F1 sonucunu elde ettiğini göstermektedir.

Anahtar Sözcükler: *Maskelenmiş dil modelleri; Mecaz tespiti; Türkçe.*

Abstract

Metaphors are widely-used expressions in daily verbal and written communication. These expressions enrich natural language by reasoning about one concept in terms of another, rather than taking their literal meanings of the given words in the context. However, these expressions tend to reduce the capability of a machine to comprehend language. In this study, we present a method to detect metaphors in Turkish texts. First, we gather metaphorical expressions with their meaning and sample texts from an online Turkish dictionary. Then, we employ a masked language model scoring method to predict the real term whether the model assigns it a higher probability. Experimental results denote that the proposed method achieves the best F1 result as 0.65 for the generated evaluation dataset when we use mask filling method of ELECTRA model to detect metaphors in Turkish texts.

Keywords: *Masked language models; Metaphor detection; Turkish.*

1. Introduction

Metaphor is a widely-used feature of natural language which allows us to conceptualize abstract concepts using more concrete terminology. Lakoff and Johnson [1] coin the term conceptual metaphor mapping in which a source concept can be used figuratively to express some aspect of a target concept. Selectional Preference Violation (SPV) and Metaphor Identification Procedure (MIP) are two main categories of metaphor detection based on linguistic theories [2]. SPV task concentrates on a semantic contrast between the target word and its context, whereas MIP focuses on the difference between the literal meaning of the target word and the meaning of this word in the context of the given text. Both MIP and SPV models are similar while analyzing the relations among metaphors and their contexts, but these models have different procedures for this analysis.

Mao et al. [2] present end-to-end metaphor identification models for both MIP and SPV tasks for detecting metaphors. Wu et al. [3] treat the metaphor identification task as a sequence tagging task and present a model based on Word2vec [4], Part-of-Speech (PoS) tags and word clusters encoded by a Convolutional Neural Network (CNN) and BiLSTM. Gao et al. [5] propose a method that combines GloVe [6] and ELMo [7] embedding models encoded by BiLSTM. These end-to-end models require large well-defined training datasets and the production of this type of training dataset is time-consuming.

To minimize the time-consuming training cost for the generation of the labelled samples for the metaphor detection task, masked language models provide a competitive performance without any fine-tuning setting. In this study, we present a method performed on the masked word prediction by adapting it to detect the metaphorical usage of the input terms. For two sample sentences including either metaphorical or real usage of an input term that is masked before the detection, the proposed method assigns the given term a higher probability and it tends to reveal that general usage of the given term occurs often in the real form.

2. Related Work

Metaphor detection is generally formulated as a binary classification task, either with subject-verb-object tuples or considering whole sentences as input in which the main aim is to predict metaphorical usage. In early supervised learning studies on metaphor detection, Birke and A. Sarkar [7] employ seed sets of literal and metaphorical texts and leverage distributional similarities of these texts to classify verbs in English.

Turney et al. [8] find out the correlation between the metaphorical word usage and the degree of abstractness of the context of the given words. They select adjectives, nouns, and verbs as target terms. Terai and M. Nakagawa [9] propose a computational model for metaphor detection based on statistical language analysis of corpora. This computational model employs frequency data for adjective, noun and verb modifications.

Recently, Wu et al. [3] present a method that encodes a Convolutional Neural Network (CNN) and BiLSTM on Word2vec, PoS tags and word clusters. Then they encode information directly which is conditioned on a softmax classifier. Gao et al. [5] propose a model which concatenates GloVe and ELMo embedding models and encodes them with a BiLSTM. After that, a softmax classifier classifies the hidden states of the BiLSTM. These sequential metaphor detection methods classify labels over these hidden states. Mao et al. [2] explore linguistic theories such as MIP and SPV to directly use a deep neural network for end-to-end sequential metaphor identification task. Their first MIP based model encapsulates the idea that a metaphor is classified by the contrast between its contextual and literal meanings. Their second SPV model presents a window-based contextual attentive method that considers important fragments of BiLSTM hidden states and hence it can better extract the context of the text.

3. Method

The masked word prediction task has been adapted to various tasks such as sentence ranking [10] and automatic speech recognition [11] by building a sentence-level language scorer. The proposed method predicts the real term if the masked language model assigns it a higher probability than its local perturbations. The intuition behind the proposed method relies on sentences using a literal representation of the given term having a higher score than metaphorical usage. Since a large volume of samples tends to be related to the real-based sentences in the pre-trained language models as illustrated in Eq. 1:

$$score(r) > score(m) \quad (1)$$

where r and m indicate real and metaphorical usage scores of the given term and then if the real usage score is higher, it is set to 1 for the unlabelled sentence as the detector method.

$$d(s) = \begin{cases} 1 & \text{if } s \text{ is } r \\ 0 & \text{if } s \text{ is } m \end{cases} \quad (2)$$

where $d(s)$ refers to the detector method for the input sentence which consists of the masked version of the input term either real or metaphorical meaning.

We generate the metaphor detection dataset from Turkish WordNet [12]. For each term, we then query the Turkish Dictionary [13] to get the term, the meaning of this term, the label as literal or metaphor and sample text which includes this term. Table 1 illustrates an example of the term “altın (gold)”.

Table 1. *Extracted information about sample term “altın (gold)”.*

Term	Meaning	Type	Sample sentence
Altın	Bu elementten yapılmış	Gerçek	Kolundaki altın künye, okuduğu kağıdın üzerine sürtünüyor.
Gold	Made of this element	Literal	The golden imprint on her arm rubs on the paper she reads.
Altın	Üstün nitelikli, değerli	Mecaz	Altın ses.
Gold	High quality, valuable	Metaphor	Golden voice.

Table 1 denotes the extracted information from the Turkish Dictionary for the example term with their translations in English. In Turkish, the literal meaning of the term “gold” is an element and it can be used for defining high quality and valuable concepts. By extracting these terms, we obtain a balanced test set that comprises 641 literal-metaphor usage pairs for each term extracted from the Turkish dictionary.

4. Results

By using two sample masked sentences for the given term, it predicts whether or not the type of the term is a metaphor. The generated dataset guarantees that one of the sample sentences includes metaphorical usage of the given term, and another masked sentence contains real usage of the same term. To differentiate the term in real or metaphorical usage for the given sentence pairs, we leverage masked language models from Transformers library’s fill-mask pipeline. The first two models BERT [14] and DistilBERT [15] are pre-trained smaller versions by preserving the original accuracy from the original model with the same representations [16]. ConvBERT [17] and ELECTRA [18] are pre-trained models by exploiting the released Turkish part of the multilingual C4 corpus [19].

Table 2. Comparison between “fill-mask” and “sim-defini” based models.

Method	F1
Bert_fill_mask	0.57
Distilbert_fill_mask	0.59
Convbert_fill_mask	0.51
Electra_fill_mask	0.65
Bert_sim_defini	0.37
Distilbert_sim_defini	0.39
Convbert_sim_defini	0.41
Electra_sim_defini	0.31

We compare “fill-mask” task based language models with their similarity-definition “sim_defini” settings. In this setting, we compute the cosine similarity between the sample sentence and the definition of the given term for both real and metaphorical samples. Then we assign the “literal” label in which the sentence-definition pair has higher cosine similarity. Table 2 denotes that ELECTRA [18] model reaches the highest score while performing the “fill-mask” task since it operates on the replaced token detection instead of the masked language model of BERT in which plausible alternative input tokens are replaced from a small generator network. Hence, it performs better than BERT, Distilbert and ConvBERT, because of learning from all input tokens rather than just the masked out small subset.

5. Conclusion

In this paper, we proposed a metaphor detection method for separating literal and non-literal usages of terms through a scorer by using the masked language models. Experimental results show that our method achieves competitive results when we use the ELECTRA model as the “fill-mask” scoring method to detect metaphors in Turkish texts. Moreover, we present the generated dataset [20] for the metaphor detection task that is also useful for future research in other Turkish NLP tasks.

In future work, we will apply different graph embedding models to the current model. Also, we examine word embedding-based semantic path similarity methods. We will extend our dataset with other metaphoric expressions especially from online news and tweets by using semi-supervised learning methods to reach large amounts of metaphors.

References

- [1] G. Lakoff and M. Johnson, *Metaphors we live by: With a new afterword*. Chicago, Ill: The University of Chicago Press, 2008.
- [2] R. Mao, C. Lin, and F. Guerin, ‘End-to-End Sequential Metaphor Identification Inspired by Linguistic Theories’, In *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, 2019, pp. 3888–3898.
- [3] C. Wu, F. Wu, Y. Chen, S. Wu, Z. Yuan, and Y. Huang, ‘Neural metaphor detecting with cnn-lstm model’, In *Proceedings of the Workshop on Figurative Language Processing*, 2018, pp. 110–114.
- [4] T. Mikolov, I. Sutskever, K. Chen, G. S. Corrado, and J. Dean, ‘Distributed Representations of Words and Phrases and their Compositionality’, In *Advances in Neural Information Processing Systems 26: 27th Annual Conference on Neural Information Processing Systems 2013. Proceedings of a meeting held December 5-8, 2013, Lake Tahoe, Nevada, United States.*, 2013, pp. 3111–3119.
- [5] G. Gao, E. Choi, Y. Choi, and L. Zettlemoyer, ‘Neural Metaphor Detection in Context’, In *Proceedings of the 2018 Conference on*

Empirical Methods in Natural Language Processing, 2018, pp. 607–613.

- [6] J. Pennington, R. Socher, and C. Manning, “Glove: Global vectors for word representation”, in Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP), 2014, pp 1532–1543.
- [7] J. Birke and A. Sarkar, ‘A clustering approach for nearly unsupervised recognition of nonliteral language’, In 11th Conference of the European Chapter of the Association for Computational Linguistics, 2006.
- [8] P. D. Turney, Y. Neuman, D. Assaf, and Y. Cohen, ‘Literal and metaphorical sense identification through concrete and abstract context’, In Proceedings of the Conference on Empirical Methods in Natural Language Processing, 2011, pp. 680–690.
- [9] A. Terai and M. Nakagawa, ‘A corpus-based computational model of metaphor understanding consisting of two processes’, *Cognitive Systems Research*, τ. 19, pp. 30–38, 2012.
- [10] A. Wang, K. Cho, and C. A. G. Scholar, ‘BERT has a Mouth, and It Must Speak: BERT as a Markov Random Field Language Model’, *NAACL HLT 2019*, p. 30, 2019.
- [11] J. Shin, Y. Lee, and K. Jung, ‘Effective sentence scoring method using bert for speech recognition’, In *Asian Conference on Machine Learning*, 2019, pp. 1081–1093.
- [12] R. Ehsani, E. Solak, and O. T. Yildiz, ‘Constructing a wordnet for turkish using manual and automatic annotation’, *ACM Transactions on Asian and Low-Resource Language Information Processing (TALLIP)*, vol. 17, no. 3, pp. 1–15, 2018.
- [13] “Turkish Dictionary,” [Online]. Available: <https://sozluk.gov.tr/>. [Accessed: 20-Mar-2022]
- [14] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, ‘Bert: Pre-training of deep bidirectional transformers for language understanding’, *arXiv preprint arXiv:1810.04805*, 2018.
- [15] V. Sanh, L. Debut, J. Chaumond, and T. Wolf, ‘DistilBERT, a distilled version of BERT: smaller, faster, cheaper and lighter’, *arXiv preprint arXiv:1910.01108*, 2019.
- [16] A. Abdaoui, C. Pradel, and G. Sigel, ‘Load What You Need: Smaller Versions of Multilingual BERT’, *arXiv preprint arXiv:2010.05609*, 2020.
- [17] Z.-H. Jiang, W. Yu, D. Zhou, Y. Chen, J. Feng, and S. Yan, ‘Convbert: Improving bert with span-based dynamic convolution’, *Advances in Neural Information Processing Systems*, τ. 33, pp. 12837–12848, 2020.
- [18] K. Clark, M.-T. Luong, Q. V. Le, and C. D. Manning, ‘Electra: Pre-training text encoders as discriminators rather than generators’, *arXiv preprint arXiv:2003.10555*, 2020.
- [19] L. Xue et al., ‘mT5: A Massively Multilingual Pre-trained Text-to-Text Transformer’, In *Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, 2021, pp. 483–498.
- [20] “Turkish Metaphor Dataset,” [Online]. Available: <https://github.com/einan/hicaz>. [Accessed: 22-May-2022]

Classification of Generative Adversarial Networks Used in the Development of Facial Recognition Systems

Hilal KOÇAK^{1,*}, Gürcan ÇETİN²

¹ Information Systems Engineering, Mugla Sitki Kocman University, Turkey, hilalkocak@mu.edu.tr

² Information Systems Engineering, Mugla Sitki Kocman University, Turkey, gctin@mu.edu.tr

Abstract

Facial recognition systems are the most widely used biometric identification technology in surveillance systems. Differences in poses, angles, and any occlusive barriers on the face are the challenges that affect the success of face recognition systems. Face recognition programs have seen significant success as deep learning has spread. Generative Adversarial Networks (GANs) have recently come to the forefront due to their high success in expanding tabular or image datasets, increasing image resolution or clearing occlusion. In this study, the use of Generative Adversarial Network in face recognition systems was investigated and extensive information provided about the studies in the literature as well as the various types of GANs. Models which used to improve face recognition methods were investigated in four different categories, namely Multi-View Generation, Frontal Face Generation, 3 Dimensional(3D) Model Generation and Removing Occlusions with GANs.

Keywords: *Deep learning; face recognition; generative adversarial networks; identity detection.*

Yüz Tanıma Sistemlerinin Geliştirilmesinde Kullanılan Üretici Çekişmeli Ağların Sınıflandırılması

Hilal KOÇAK^{1,*}, Gürcan ÇETİN¹

¹ Bilişim Sistemleri Mühendisliği, Muğla Sıtkı Koçman Üniversitesi, Türkiye, hilalkocak@mu.edu.tr

² Bilişim Sistemleri Mühendisliği, Muğla Sıtkı Koçman Üniversitesi, Türkiye, gctin@mu.edu.tr

Özet

Yüz tanıma sistemleri, gözetim sistemlerinde en yaygın kullanılan biyometrik kimliklendirme teknolojisidir. Yüz görüntülerindeki açının, pozun farklılığı ya da yüzde herhangi bir tıkaçıcı engelin olması yüz tanıma sistemlerinin başarısını etkileyen zorluklardır. Derin öğrenmenin kullanımı yaygınlaştıkça yüz tanıma sistemlerinde önemli başarılar elde edildiği görülmektedir. Üretici çekişmeli ağlar, tablo veya görüntü veri kümelerini genişletmek, görüntü çözünürlüğünü artırmak ya da resimlerde yüzü kapatan engelleri gidermedeki yüksek başarılarından dolayı son zamanlarda öne çıkmıştır. Bu çalışmada, Üretici Çekişmeli Ağlar(GAN)'ın yüz tanıma sistemlerinde kullanımı araştırılmış ve literatürdeki çalışmalar ile çeşitli GAN türlerinin yüz tanıma hakkında bilgi verilmiştir. Yüz tanıma yöntemlerini geliştirmek için kullanılan modeller, Çoklu Görüntü Oluşturma, Ön Yüz Oluşturma, 3 Boyutlu(3B) Model Oluşturma ve GAN ile Tıkanıklıkları Kaldırma olmak üzere dört farklı kategoride incelenmiştir.

Anahtar Kelimeler: *Derin öğrenme; kimlik tespiti; üretici çekişmeli ağlar; yüz tanıma.*

1. Introduction

Face recognition is the automatic recognition and verification of a person from video or images. Also, one of the most extensively researched areas of computer vision is facial recognition. In addition to security systems, it is widely used in business applications such as personnel tracking and mobile payment. There are also companies that offer facial recognition software as a product. (like SenseTime) However, in order to successfully perform face recognition, the face must be seen in the right light and from the front. Face recognition is extremely successful in systems used to unlock mobile phones, where people are aware that face recognition will be performed and their faces will be correctly displayed [1]. However, in unannounced photographs, low resolution or when people wear masks, hats, berets, etc., the success of face recognition systems drops clearly. With the development of technology, easy access to human face images has led to the use of the rapidly growing deep

learning field in face recognition. The use of deep learning is spreading day by day in order to solve the problems encountered in face recognition.

Deep learning is based on the extraction of the characteristics of the data by representing it with multiple layers, that is, the realization of learning. When models are trained with large data sets, image classification studies using deep learning have shown great performance [2-3]. As a result, data augmentation methods are used to find a solution, because small data sets cause issues such as overfitting. Many studies have shown that the Generative Adversarial Network (GANs) is effective at increasing both tabular and image data [4-5-6-7]. GANs were introduced by Ian Goodfellow in 2014 [8]. In this model, two different networks, called Generator and Discriminator, are in conflict with each other. At the end of each training, the generator tries to produce more realistic data from noise, while the discriminator tries to distinguish whether the generated data is fake or real. While the Generator and Discriminator try to beat each other, the generator starts to produce better data, while the discriminator starts to distinguish the real and the fake better. GANs has been used in studies such as image synthesis [9], image resolution increase [10], and image style transfer [11]. Recent studies in the field of face recognition have shown that synthesized artificial faces reduce the negative effect of facial deformation on face recognition [8,12]. In this study, GAN models used to diversify and expand the data set that increase the success of face recognition systems were investigated.

2. Methods Used to Improve Face Recognition

As shown in Table 1, the usage of GANs in face recognition has been investigated into four categories: Multi-View Generation, 3D Model Generation, Frontal Face Generation, and Removing Occlusions with GANs.

2.1. Multi-View Generation

The term Multi-View Generation is used in our study to mean producing multiple images from a single image. The use of deep learning in face recognition systems has made it necessary to use a large amount of data. However, there is not always the required number of images for successful facial recognition. For this reason, multi-image production with image synthesis is generally done to eliminate the bad effects of exposure differences and different light of the image on face recognition. It is aimed to obtain poses that do not exist by referencing a face picture. Yu et al. suggested using multiple images for face recognition in order to eliminate the disadvantage of pose differences [13]. As a similar study, the DC-IGN model proposed by Kulkarni et al. is composed of multiple layers of convolution and de-convolution operators and generates multiple images with different pose and light [14]. In addition Tian et al used an encoder-decoder as a generator and created a model called CR-GAN to generate multiple views [15]. In a related manner, Zhuang et al proposed the CycleGAN model in which the landmarks of the face key points and the details of the shapes are retained [1].

2.2. 3D Model Generation

3 Dimensional(3D) face synthesis is one of the collaborative fields of machine learning and computer vision, as it avoids pose differences and different lights from interfering with face recognition. 3D Model Generation is the work that takes two-dimensional face images as input and serves to complete the invisible parts of the face in three dimensions [16-17]. The goal of this method is to create the desired face or facial geometry in 3D. For this reason, it also includes frontalization by making two-dimensional images three-dimensional. Moschoglou et al. proposed an autoencoder-like network approach called 3DFaceGAN, which allows the face to be synthesized in three dimensions while preserving its details [18]. Also, Geçer et al. have developed model named GANFIT to produce photorealistic facial reconstruction using a 3D Morphological Model fitting technique [19]. Similarly, Luan et al. have proposed the use of a dual-pathway network to facilitate learning, suggesting a Nonlinear 3D Morphable Model that will successfully reconstruct details in 3D [20].

2.3 Frontal Face Generation

The majority of facial recognition systems require human faces to be at a frontal angle. The bad effect of non-frontal images on face recognition success necessitated working on face frontalization techniques. Face frontalization is one of the computer vision challenges that goal to align faces from different perspectives to a frontal position [21]. Face Frontalization is used in our study to mean the production of two-dimensional frontal

face images using non-frontal images. Face frontalization studies using deep learning have shown significant success [22-23-24-25].

Especially, the use of Generative Adversarial Network in face frontalization yielded successful results in the literature. By using the Generative Adversarial Network, front-face synthesis can be made by using images where the face is not fully visible, such as the side profiles of the people. In this context, Yin et al. proposed the Face Frontalization Generative Adversarial Network model which they named FF-GAN to produce neutral head poses of face images [26]. Also, Shen et al. have proposed a model called FaceID-GAN for synthesizing frontal face images while preserving the identities of individuals [27]. Many GAN-based face frontalization methods, however, continue to perform poorly on face recognition tasks in large face poses. Rong et al. have proposed Feature-Improving GAN (FI-GAN) for face frontalization with the goal of improving recognition performance under large face poses [28]. In addition, Huang et al. have proposed a Two-Pathway Generative Adversarial Network (TP-GAN) for photorealistic frontal view synthesis that perceives global structures as well as local details at the same time [29]. Moreover, Tran et al. showed that their proposed DR-GAN model can take a large number of inputs and synthesize a combined representation or random synthetic picture of these inputs [30].

2.4. Removing Oclusions with GANs

Face oclusions are a significant issue that affects the recognition rate and robustness of face recognition systems. There are two techniques, discarding and filling, which are used as solutions to partial occlusion problems on face recognition. The discarding method is based on various algorithms removing the occlusion covering the face and performing face recognition on the remaining portion. However, the applicability of this method is limited because occlusion can occur in important parts of the human face, such as the eyes, mouth, and nose. The filling method is based on repairing and filling the occluded part of the face and then facial recognition. Although deep learning applications have had some success in clearing occlusion, the main success has come from the use of GANs. As an example, Duan et al. worked on face recognition by de-occlusion with the Boosting Generative Adversarial Network they developed using GANs [31]. Also, Ju et al. have proposed the Complete Face Recovery GAN (CFR-GAN) model to fill in collapsed tissues and lost areas [32]. Besides that, Doung et al. proposed a two-stage Occlusion-Aware GAN (OA-GAN), in which the missing parts are completed using GAN in the first stage, and de-occluded face synthesis is performed in the second stage [33].

Table 1. Models Produced Using GAN in Facial Recognition Development.

Reference ID	Used Methods	Used Types of GANs
[14], [15], [1]	Multi-View Generation	DC-IGN, CR-GAN, CycleGAN
[18], [19], [20]	3D Model Generation	3DFaceGAN, GANFIT, Nonlinear 3DMM
[26], [27], [28], [29], [30]	Frontal Face Generation	FF-GAN, FaceID-GAN, FI-GAN, TP-GAN, DR-GAN, DA-GAN
[31], [32], [33]	Removing Oclusions with GAN	BoostGAN, CFR-GAN, OA-GAN

3. Conclusions

Facial recognition systems are the most widely used and studied biometric systems. Problems such as the difference in pose, different light and angle, also occlusion on the face in the images for which face detection is desired affect the success negatively. In addition, the small amount of data on which the model is trained also reduces the success of the model. In this study, different versions of the Generative Adversarial Networks, which were created to increase the success of face recognition systems, are examined. The multi-view generation method for the problem of low amount of data, the face frontalization method for the problem of different poses, and the application of 3D face generation and removing occlusion methods using different GAN types for cases where the face is occluded are analyzed.

References

- [1] Zhuang, W., Chen, L., Hong, C., Liang, Y., & Wu, K. (2019). FT-GAN: Face Transformation with Key Points Alignment for Pose-Invariant Face Recognition. *Electronics*.
- [2] Shorten, C., Khoshgoftaar, T.M. A survey on Image Data Augmentation for Deep Learning. *J Big Data* 6, 60 (2019). <https://doi.org/10.1186/s40537-019-0197-0>

- [3] Perez, Luis & Wang, Jason. (2017). The Effectiveness of Data Augmentation in Image Classification using Deep Learning.
- [4] Park, Noseong & Mohammadi, Mahmoud & Gorde, Kshitij & Jajodia, Sushil. (2018). Data Synthesis based on Generative Adversarial Networks.
- [5] Charitou, Charitos & Dragicevic, Simo & Garcez, Artur. (2021). Synthetic Data Generation for Fraud Detection using GANs.
- [6] Bao, Jianmin & Chen, Dong & Wen, Fang & Li, Houqiang & Hua, Gang. (2017). CVAE-GAN: Fine-Grained Image Generation through Asymmetric Training.
- [7] Tanaka, Fabio & Aranha, Claus. (2019). Data Augmentation Using GANs.
- [8] Goodfellow, Ian & Pouget-Abadie, Jean & Mirza, Mehdi & Xu, Bing & Warde-Farley, David & Ozair, Sherjil & Courville, Aaron & Bengio, Y.. (2014). Generative Adversarial Networks. *Advances in Neural Information Processing Systems*. 3. 10.1145/3422622.
- [9] E. L. Denton, S. Chintala, R. Fergus, et al. Deep generative image models using a Laplacian pyramid of adversarial networks. In *NIPS*, 2015.
- [10] C. Ledig, L. Theis, F. Huszar, J. Caballero, A. Cunningham, A. Acosta, A. Aitken, A. Tejani, J. Totz, Z. Wang, and S. Wenzhe. Photo-Realistic single image super-resolution using a generative adversarial network. *CVPR*, 2017.
- [11] C. Hu, Y. Ding and Y. Li, "Image Style Transfer based on Generative Adversarial Network," 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), 2020, pp. 2098-2102, doi: 10.1109/ITNEC48623.2020.9084750.
- [12] Faez, Faezeh & Ommi, Yassaman & Soleymani, Mahdiah & Rabiee, Hamid. (2021). Deep Graph Generators: A Survey. *IEEE Access*. 9. 106675-106702. 10.1109/ACCESS.2021.3098417.
- [13] Yu, J.; Zhang, B.; Kuang, Z.; Dan, L.; Fan, J. iPrivacy: Image Privacy Protection by Identifying Sensitive Objects via Deep Multi-Task Learning. *IEEE Trans. Inf. Forensics Secur.* 2017, 12, 1005–1016.
- [14] Kulkarni, T.D., Whitney, W.F., Kohli, P., & Tenenbaum, J.B. (2015). Deep Convolutional Inverse Graphics Network. *NIPS*.
- [15] Tian, Y., Peng, X., Zhao, L., Zhang, S., & Metaxas, D.N. (2018). CR-GAN: Learning Complete Representations for Multi-view Generation. *ArXiv*, abs/1806.11191.
- [16] X. Zhu, Z. Lei, X. Liu, H. Shi, and S. Z. Li, "Face alignment across large poses: A 3D solution," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, Jun. 2016, pp. 146–155.
- [17] J. R. A. Moniz, C. Beckham, S. Rajotte, S. Honari, and C. Pal, "Unsupervised depth estimation, 3D face rotation and replacement," in *Proc. Conf. Neural Inf. Process. Syst. (NeurIPS)*, 2018, pp. 9736–9746.
- [18] Moschoglou, Stylianos & Ploumpis, Stylianos & Nicolaou, Mihalis & Zafeiriou, Stefanos. (2019). 3DFaceGAN: Adversarial Nets for 3D Face Representation, Generation, and Translation.
- [19] Gecer, Baris & Ploumpis, Stylianos & Kotsia, Irene & Zafeiriou, Stefanos. (2019). GANFIT: Generative Adversarial Network Fitting for High Fidelity 3D Face Reconstruction. 1155-1164. 10.1109/CVPR.2019.00125.
- [20] Luan, Tran & Liu, Feng & Liu, Xiaoming. (2019). Towards High-Fidelity Nonlinear 3D Face Morphable Model. 1126-1135. 10.1109/CVPR.2019.00122.
- [21] Yin, Y., Jiang, S., Robinson, J.P., & Fu, Y.R. (2020). Dual-Attention GAN for Large-Pose Face Frontalization. 2020 15th IEEE International Conference on Automatic Face and Gesture Recognition (FG 2020), 249-256.
- [22] J. Cao, Y. Hu, H. Zhang, R. He, and Z. Sun. Learning a high fidelity pose invariant model for high-resolution face frontalization. In *NIPS*, 2018.
- [23] R. Huang, S. Zhang, T. Li, and R. He. Beyond face rotation: Global and local perception gan for photorealistic and identity preserving frontal view synthesis. In *ICCV*, 2017.
- [24] J. Yim, H. Jung, B. Yoo, C. Choi, D. Park, and J. Kim. Rotating your face using multi-task deep neural network. In *CVPR*, 2015.
- [25] X. Yin, X. Yu, K. Sohn, X. Liu, and M. Chandraker. Towards large-pose face frontalization in the wild. In *ICCV*, 2017.
- [26] Yin, X., Yu, X., Sohn, K., Liu, X., & Chandraker, M. (2017). Towards Large-Pose Face Frontalization in the Wild. 2017 IEEE International Conference on Computer Vision (ICCV), 4010-4019.
- [27] Shen, Y., Luo, P., Yan, J., Wang, X., & Tang, X. (2018). FaceID-GAN: Learning a Symmetry Three-Player GAN for Identity-Preserving Face Synthesis. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 821-830.
- [28] Rong, C., Zhang, X., & Lin, Y. (2020). Feature-Improving Generative Adversarial Network for Face Frontalization. *IEEE Access*, 8, 68842-68851.
- [29] Huang, Rui & Zhang, Shu & Li, Tianyu & He, Ran. (2017). Beyond Face Rotation: Global and Local Perception GAN for Photorealistic and Identity Preserving Frontal View Synthesis.
- [30] Tran, Luan & Yin, Xi & Liu, Xiaoming. (2017). Disentangled Representation Learning GAN for Pose-Invariant Face Recognition. 10.1109/CVPR.2017.141.
- [31] Duan, Qingyan & Zhang, Lei. (2019). BoostGAN for Occlusive Profile Face Frontalization and Recognition.
- [32] Y. -J. Ju, G. -H. Lee, J. -H. Hong and S. -W. Lee, "Complete Face Recovery GAN: Unsupervised Joint Face Rotation and De-Occlusion from a Single-View Image," 2022 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV), 2022, pp. 1173-1183, doi: 10.1109/WACV51458.2022.00124.
- [33] J. Dong, L. Zhang, H. Zhang and W. Liu, "Occlusion-Aware GAN for Face De-Occlusion in the Wild," 2020 IEEE International Conference on Multimedia and Expo (ICME), 2020, pp. 1-6, doi: 10.1109/ICME46284.2020.9102788.

U-Shaped Slotted Patch Antenna Design for 2.4 GHz Wireless Applications

Yasar KAPLAN ^{1*}, Cem GÖCEN ²

¹Department of Electrical and Electronics Engineering, Izmir Katip Çelebi University, Turkey,
yasarkaplan1510@gmail.com

²Department of Electrical and Electronics Engineering, Izmir Katip Çelebi University, Turkey,
cem.gocen@ikcu.edu.tr

Abstract

Wireless communication technology provides uninterrupted and fast access to information. The importance of this technology is increasing day by day. The most important part of this technology is the antennas that provide wireless communication. Therefore, in this paper, a microstrip Wi-Fi antenna with a resonance frequency of 2.4 GHz has been designed. The estimation of the scattering parameters of the original microstrip antenna design at the operating frequency of 2.4 GHz using machine learning algorithms has been performed and a more successful final antenna design has been obtained. By changing the geometric parameters of the antenna design developed using CST Studio Suite, 125 different S_{11} parameters have been obtained with the parametric sweep feature of CST. These results have been used as a dataset. The results obtained have been obtained in two types of magnitude in dB form and linear magnitude. Decision Tree Regression machine learning algorithm has been applied to the results of two different scattering parameters. When the machine learning results have been examined, it has been achieved that the model had R^2 value of 0.94 and a mean squared error value of 0.06 for the S_{11} in dB results, and R^2 value of 0.98 and a mean squared error value of 0.02 for the linear S_{11} results.

Keywords: *Microstrip Antennas; Antenna Design; Wi-Fi Technology; Machine Learning; Regression.*

1. Introduction

Today, wireless communication technology has increased considerably due to the technical improvement in modern communication components compared to the conventional microwave/millimeter wave components [1-5]. Antennas are the radiating elements in wireless communication technology. The increase in the variety of modern devices using wireless communication technology makes it necessary to design compact antennas. Microstrip antennas can be used in this field due to their small size, easy production, and low production cost [6]. A microstrip antenna consists of a dielectric substrate with a ground plane on the underside and a radiating patch on the other side [7]. The rapid developments in wireless communication technology make it more difficult to design antennas to be used in this field. The microwave simulation programs used in this field meet the need to produce the exact results, but these programs cause a lot of time to spend on antenna design. This causes various problems. It would be wise to use machine learning algorithms to solve these problems [8]. Machine learning is a branch of artificial intelligence (AI) and computer science that focuses on the use of data and algorithms to imitate the way people learn, gradually increasing its accuracy. Machine learning can be briefly defined as follows; predicting the necessary but unknown data from the data obtained, through the development of successful prediction algorithms. Therefore, these algorithms are needed very significantly in optimization problems [10]. Also, in recent years, machine learning-assisted optimization (MLAO) has become widely used to speed up the design process of antennas [8-9].

In this paper, the machine learning-based estimation of the scattering parameters of a U-shaped slotted microstrip patch antenna loaded with a slotted line in the middle of a U-shaped slotted resonator is presented at an operating frequency of 2.4 GHz.

2. Purpose

The purpose of this paper is to achieve a successful antenna design that can be used in 2.4 GHz Wi-Fi applications by applying machine learning-assisted optimization (MLAO) to an antenna design that has been developed. In recent years, it has become clear that Wi-Fi technology is involved in all parts of our lives. that is why a successful antenna design is needed to be developed in this field [11]. Also, machine learning algorithms have been investigated in detail, when the studies conducted are examined, it is observed that it is important to use MLAO to optimize the antenna design that will be performed. Therefore, this paper aims to demonstrate the importance of MLAO for successful antenna design and to realize a successful antenna design with machine learning support.

3. Material and Method

3.1 Antenna Configuration and Design

It is desired that the designed antenna has resonance in the 2.4 GHz frequency band, which is used as the Wi-Fi frequency band. For this purpose, a double-sided copper plated FR-4 material of thickness 1.6 mm with a dielectric constant of 4.3 and a loss tangent of 0.02 is selected as the suitable substrate material. The ground layer of the antenna is completely covered with a copper layer. Also, the geometric configuration of the developed antenna is given in Figure 1 and all information about the dimensions of the developed antenna is given in Table 1.




Figure 1. Front View and Back View of Designed Antenna

Table 1. Dimensions of Proposed Antenna

LS	LP	LT	L1	L2
41 mm	23 mm	13.2 mm	15.3 mm	11 mm
L3	L4	L5	L6	L7
3.2 mm	14 mm	0.4 mm	0.5 mm	3.3 mm
WS	WP	WT - W1	W3	W4
44 mm	24 mm	3 mm	7 mm	4 mm

There are different types of microstrip antenna feeding methods. Some of these types are microstrip feeding, coaxial feeding, aperture coupled feed, and proximity coupled feed method [12]. The antenna design developed is fed using the microstrip line feeding method. The design of the antenna is carried out using CST Studio Suite Electromagnetic Simulator. According to the simulation results obtained in the CST environment, the graph of the S_{11} parameter belonging to the antenna is given in Figure 2.




Figure 2. S_{11} Parameter of Designed Antenna

3.2 Machine Learning in Antenna Design

Machine learning algorithms aim to minimize the antenna design time by reducing the number of simulations expected to be performed by maintaining a high level of accuracy, aiming to predict the performance of the antenna with the least error rate. To use machine learning algorithms in antenna design, the following steps should be followed, respectively.

1. Extraction of the electromagnetic characteristic of the antenna by performing multiple simulation operations,
2. Saving the obtained dataset in the database for use in the training of machine learning algorithms,
3. After the training process is performed, an estimate of the desired parameter is performed by machine learning. The optimum antenna design is realized by determining the values closest to the desired result [13].

Firstly, the operation in the first step specified above is performed. The electromagnetic characteristic of the antenna is obtained using the parametric sweep feature of CST. Changes in the design parameters at the stage of performing multiple simulations are given in Table 2. Here, W1 is the width of the outer slots. Also, changes in this parameter affect the length of the L2 parameter because changes have been applied to W1 by keeping constant the distance between the inner slot and outer slots. In other words, the width of W1 has been increased or decreased from the outer surface. L1 is the length of the outer slots. L4 is the length of the inner slot.

Table 2. Antenna Design Parameters for Dataset

Parameter	Change Rate	Step Size	Number of Samples
W1	[1-5] (mm)	1 mm	5
L1	[13.3-17.3] (mm)	1 mm	5
L4	[12-16] (mm)	1 mm	5
Total Data:			125

Secondly, according to the results obtained from multiple simulations, the results of the S_{11} parameter belonging to the antenna are recorded in the database as dB and linear. Finally, machine learning algorithms are trained using the obtained dataset. Using the algorithms that have been trained, an estimation of the design parameters is performed, which will give the minimum S_{11} value of the antenna. According to the results obtained, an antenna design with optimal antenna performance is performed.

4. Findings


When the studies carried out in this field are examined, it is seen that the regression algorithms including Support Vector Regressor, Linear Regression, Naive Bayes, Decision Tree [8,13,14] are utilized. Support Vector Regressor, Linear Regression, and Decision Tree machine learning algorithms have been developed in the Python environment for this study. When the prediction results of the developed algorithms are examined, it is observed that the best results are obtained in the Decision Tree algorithm. Therefore, the Decision Tree algorithm is selected for machine learning-assisted optimization (MLAO) in this study. The data of the prediction results of the developed Decision Tree algorithm are given in Table 3 and Table 4. The results in Table 3 are the results estimated using the dataset obtained decibel. The results in Table 4 are the results estimated using the dataset obtained linearly. Prediction results of the decibel scattering parameters at the resonance frequency of the proposed antenna design for 10 sample test data are given in Figure 3.a. Prediction results of the linear scattering parameters at the resonance frequency of the proposed antenna design for 10 sample test data are given in Figure 3.b.

Table 3. Algorithm Results of Magnitude in dB Dataset


Mean Absolute Error	0.106
Mean Squared Error	0.062
Root Mean Squared Error	0.249
R Square Value	0.938

Table 4. Algorithm Results of Linear Dataset

Mean Absolute Error	0.087
Mean Squared Error	0.020
Root Mean Squared Error	0.140
R Square Value	0.98



a



b

Figure 3. a) Actual / Predicted Data with Decibel Dataset, b) Actual / Predicted Data with Linear Dataset

5. Results and Recommendations

In this study, firstly, a microstrip antenna design with a resonant frequency of 2.4 GHz has been realized that can be used in Wi-Fi applications. The proposed antenna design has been fed using the microstrip line feeding method. FR-4 has been used as the dielectric material and copper has been used as the radiating surface. The simulation stages have been carried out in the CST Studio Suite environment. Secondly, the electromagnetic characteristic of the antenna developed using CST is obtained. Therefore, by changing 3 different design parameters, a dataset consisting of 125 samples showing the change of scattering parameters has been obtained. Thirdly, the Machine Learning algorithm, which is necessary for estimating the performance data of the antenna, has been developed in the Python environment. That algorithm is the Decision Tree machine learning algorithm. The dataset has been divided into 0.2 test and 0.8 training. Finally, the results have been examined by running the developed algorithm. It has been observed that the obtained results have an acceptable level of predictive performance. Also, it has been observed that the accuracy of the algorithm increases when the dataset recorded as linear is used in the prediction algorithm. Antenna optimization will be achieved in quickly, using the obtained machine learning algorithm without the need for long-time simulation stages.

Acknowledgments

This study has been carried out using the laboratory facilities of İzmir Katip Çelebi University Smart Factory Systems Application and Research Center (AFSUAM).

References

- [1] Montero-de-Paz, J., Oprea, I., Rymanov, V., Babel, S., García-Muñoz, L. E., Lisauskas, A., ... & Carpintero, G. (2013). Compact modules for wireless communication systems in the E-band (71–76 GHz). *Journal of Infrared, Millimeter, and Terahertz Waves*, 34(3), 251-266.
- [2] Rymanov, V., Palandöken, M., Lutzmann, S., Bouhlal, B., Tekin, T., & Stöhr, A. (2012, September). Integrated photonic 71–76 GHz transmitter module employing high linearity double mushroom-type 1.55 μm waveguide photodiodes. In *2012 IEEE International Topical Meeting on Microwave Photonics* (pp. 253-256). IEEE.
- [3] Palandöken, M., Rymanov, V., Stöhr, A., & Tekin, T. (2012, August). Compact metamaterial-based bias tee design for 1.55 μm waveguide-photodiode based 71–76GHz wireless transmitter. In *Progress in Electromagnetics Research Symposium, PIERS*.
- [4] Palandöken, M., & Sondas, A. (2014). Compact Metamaterial Based Bandstop Filter. *Microwave Journal*, 57(10).
- [5] Palandöken, M. (2012). Metamaterial-based compact filter design. In *Metamaterial*. IntechOpen.
- [6] Küçük, H., Teşneli, A. Y., & Teşneli, N. B. (2000). 3.3 GHz mikroşerit anten tasarımı ve farklı besleme yöntemleri için analizi. *Sakarya University Journal of Science*, 17(1), 119-124.
- [7] Tansarıncaya, İ. (2007). *Geniş Bandlı Yama Anten Tasarımı* (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- [8] Wu, Q., Cao, Y., Wang, H., & Hong, W. (2020). Machine-learning-assisted optimization and its application to antenna designs: Opportunities and challenges. *China Communications*, 17(4), 152-164.
- [9] Akdağ, İ., Göçen, C., Palandöken, M., & Kaya, A. (2020, October). Estimation of the Scattering Parameter at the Resonance Frequency of the UHF Band of the E-Shaped RFID Antenna Using Machine Learning Techniques. In *2020 4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1-5). IEEE.
- [10] Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2018). *Foundations of machine learning*. MIT press.
- [11] KAPLAN, Y., & GÖÇEN, C. (2022). A Dual-Band Antenna Design for 2.4 and 5 GHz Wi-Fi Applications. *Avrupa Bilim ve Teknoloji Dergisi*, (34), 685-688.
- [12] Chakravarthy, S. S., Sarveshwaran, N., Sriharini, S., & Shanmugapriya, M. (2016, July). Comparative study on different feeding techniques of rectangular patch antenna. In *2016 Thirteenth International Conference on Wireless and Optical Communications Networks (WOCN)* (pp. 1-6). IEEE.
- [13] El Misilmani, H. M., & Naous, T. (2019, July). Machine learning in antenna design: An overview on machine learning concept and algorithms. In *2019 International Conference on High Performance Computing & Simulation (HPCS)* (pp. 600-607). IEEE.
- [14] AKDAG, I. (2021). Estimation of Scattering Parameters of U-Slotted Rectangular RFID Patch Antenna with Machine Learning Models. *Journal of Artificial Intelligence and Data Science*, 1(1), 63-70.

SEÇİLİ METİN VERİSİNİN İŞLENMESİ VE GRAF VERİTABANINDA SORGULANMASI

PROCESSING SELECTED TEXT DATA AND INQUIRY IN GRAPH DATABASE

Kubilay AYTURAN ^{1*}, Fırat HARDALAÇ ², Bo HAI ³, Fatih MERT ⁴

¹ Elektrik Elektronik Mühendisliği Bölümü, Gazi Üniversitesi, Türkiye, kubilay.ayturan@gazi.edu.tr

² Elektrik Elektronik Mühendisliği Bölümü, Gazi Üniversitesi, Türkiye, firat@gazi.edu.tr

³ Ar-Ge Departmanı, Huawei Telekomünikasyon A.Ş., Türkiye, haibo@huawei.com

⁴ Ar-Ge Departmanı, Huawei Telekomünikasyon A.Ş., Türkiye, fatih.mert@huawei.com

Özet

Teknolojinin günden güne gelişmesiyle birlikte tüm sistem ve veri tabanlarında artarak devam eden miktarlarda veri muhafaza edilmektedir. Artan veri sayıları teknolojinin son kullanıcıları olan bizlerin, anlamlı verilere gün geçtikçe ulaşmakta zorlanacağımız anlamına gelmektedir. Sistem ve veri tabanlarındaki verilerinin yapısı incelendiğinde çoğunun sözel - metinsel verilerden yer aldığı görülmektedir. Bu metin verilerinin çoğunluğunun işlenmemiş olması, veri tabanları sorgulamalarında hızlı ve anlamlı sonuçlar almamızı engellemektedir. Bu problemden yola çıkılarak bu çalışmada, metinlerdeki anlamlı verilerin çok hızlı bir şekilde elde edilmesi amacı ile internet ortamından seçilen metinsel veriler belirli bir şekilde işlenerek bir grafik model oluşturulmaktadır. Seçili metin verilerinden bilgi çıkarmak için eksiksiz bir algoritma önerilmiştir. Bu çalışma, seçili metin verileri üzerindeki ortak referansları (CoRef Çözünürlüğü) çözme algoritması ile birlikte, metin verilerinden tekrarlanan kelimelerin ne ve kim olduğunu belirlemekle başlar. Ortak referansları alınan metin orijinal haline göre sadeleştirilmiş ve programlamaya uygun hale getirilmiştir. Bir sonraki adımımız, ortak referansları alınan metni Open Information Extraction (Stanford OpenIE) algoritması kullanarak üçlü anlamlı veriye dönüştürmektir. Metinden çıkarılan üçlü ifadeler, metin içerisindeki kelimeler arasındaki ilişkileri daha ayrıntılı olarak anlamamıza yardımcı olur. Bu çalışmanın üçüncü adımında metinlerden çıkarılan ifadeler bizim istediğimiz dil yapısına dönüştürülebilmesi adına metinsel çeviri işlemi uygulanacaktır. Çalışmanın son aşamasında ise üçlü yapıya dönüştürülen metin verilerini işlemek için Neo4j yazılımı kullanılmıştır. Bu çalışmada seçili metin verileri grafik veri tabanında işlenmiş ve grafik veri tabanında sorgulama yapılarak metindeki anlamlı veri ve veri kümelerine hızlı bir şekilde ulaşabilmektedir.

Anahtar Sözcükler: Doğal dil işleme; Graf veri tabanı; Metin verileri; Neo4j; Ortak referans çözümü

Abstract

With the day-to-day development of technology, increasing amounts of data are stored in all systems and databases. The increasing amount of data means that we, the end users of the technology, will find it difficult to access meaningful data day by day. When the structure of the data in the system and databases is examined, it is seen that most of them are located from verbal-textual data. The fact that the majority of this text data is not processed prevents us from obtaining fast and meaningful results in database queries. Based on this problem, in this study, in order to obtain meaningful data in texts very quickly, textual data selected from the Internet environment is processed in a certain way and a graphical model is created. This work begins with determining what and who the repeated words are from the text data, together with the algorithm for decoding common references (CoRef Resolution) on the selected text data. The text with common references has been simplified according to its original form and made suitable for programming. Our next step is to convert the text with common references into triple data using the Open Information Extraction (Stanford OpenIE) Algorithm. Triple phrases deciphered from the text help us to understand the relationships between texts in more detail. In the third step of this study, a textual translation process will be applied in order to convert the expressions extracted from the texts into the language structure we want. At the final stage of the study, Neo4j software was used to process text data converted into a triple structure. In this study, the selected text data is processed in the graph database and can be queried in the graph database to quickly access meaningful data and datasets in the text.

Keywords: Common reference solution; Graph database; Natural language processing; Neo4j ; Text data

1. Giriş

Dünyamızda teknolojinin çok hızlı bir şekilde gelişme gösterdiğini görmekteyiz. Bu gelişmeler sadece teknoloji temelli sektörlerin de ötesinde tüm sektörleri etkileyebilecek bir şekilde yaygınlaştığını gözlemlemekteyiz. Bu gelişmeler, sektörlerin ilerlemesi için hızlı destek vermesinin yanında iş yükü boyutunda veri tabanlarında oluşturdukları veri sayıları oldukça artmaktadır. Artan veri sayısı, son kullanıcı olan bizler için istediğimiz veriye ulaşmakta zorluklar yaşayacağımız anlamına gelmektedir.

Bilgi iletişim teknolojilerinin hayatın hemen her alanına girmesi, hızlı gerçekleşen teknolojik gelişmeler veri boyutlarındaki ve türlerindeki artışı tetiklemektedir. Bu nedenle veri yığınları arasından anlamlı, işe yarar bilgi elde edilebilmesi açısından veri analizi için veri madenciliği kavramı [1] ortaya çıkmıştır. Veri Madenciliği ile beraber veri tabanları içerisinde istediğimiz veriye hızlı ve kolay bir şekilde ulaşılabilir. Yapılan çalışma veri madenciliğinin bir alt türü olan metin madenciliği üzerine çalışmalar gerçekleştirilmiştir. Metin Madenciliği yararlı, ilginç ve daha önce bilinmeyen bilginin, bilgi işlem metotları ve teknikleri ile metin halindeki veriden elde edilmesi olarak tanımlanabilir [2].

Dijital dönüşüm ile hayatımıza giren yeni iletişim ortamları ile büyük veri yığınının çoğunluğunu oluşturan yapısal olmayan içeriklerin hacmi dramatik bir artış göstermiştir.[3] Graf veri tabanının veri işleme ve veriye erişim kısımlarındaki kolaylıkları, yapılmış olan çalışmanın graf tabanında işlenmesine ve değerlendirilmesine yol açmaktadır. Yapılan literatür taramalarında da metin verilerinin graf veri tabanına işlenmesinin en doğru sonuçlar ortaya çıkaracağı düşünülmektedir.

2. Amaç

Gelişen teknolojik imkânlar ve yöntemler ile beraber çok hızlı bir şekilde veri yapılarında ve veri sayılarında artışlara sebebiyet vermektedir. Veri sayılarındaki artışlar son kullanıcı olan bizler için doğru ve anlamlı olan veriye erişilebilirliği azaltmakla beraber belirli zorlukları ortaya çıkarmaktadır. Dünyamızdaki olan veri yığınları arasında metin verilerinin oranı oldukça yüksek olup, bilgi ve bilgi topluluğuna ulaşılabilmesi için metin verileri anahtar bir rolü bulunmaktadır.

Metin verileri üzerine uygulanan metin madenciliği işlemini 2 adımda sıralanmaktadır. Bunlardan birincisi, metin madenciliği uygulanan metin verisinin anlaşılması ve özetlenmesi ile başlamaktadır. Seçilen metin verisinin programlamaya ve sonuç çıkarılmasına uygun olacak hale getirilmesi ile başlanmaktadır. İkinci adım olarak metnin modellenmesi ile beraber metin içerisindeki verilerin birbirleri ile olan ilişkilerinin ortaya çıkarılmasıdır.


Yapılan bu çalışmada, internet ortamındaki seçili metin verileri üzerinde belirli algoritmaların uygulanması ile beraber metin içerisinde istediğimiz veriye veya veri topluluğuna hızlı ve kolay bir şekilde ulaşılması amaçlanmaktadır.

3. Materyal

Yapılan bu çalışma ile doğru ve güvenilir veriye ulaşmanın yanı sıra seçili olan verinin metin verileri olması nedeniyle bu çalışmanın kapsamının oldukça geniş bir alanı bulunmaktadır. Dünyamızda bulunan veri ve veri topluluklarının neredeyse büyük çoğunluğu metin verilerinden oluşması, bu çalışmanın etkisini ve kapsamını oldukça büyük olacağı düşünülmektedir.

4. Yöntem

Bu çalışma, internet ortamından seçili metin verilerinin üzerinde bir dizi işlemlerden geçirilerek anlamlı ve doğru veriye ulaşılabilmemizi sağlamaktadır. Seçili metin verileri ham, sınıflandırılmamış ve işlenmemiş verilerden oluşmaktadır. Bu da son yararlanıcı olan bizlerin metinleri analiz edilirken ihtiyaç duyulan veriye ulaşmamızda zorluklar yaşatmaktadır. Bu zorluğun aşılabilmesi adına bu çalışmamızda metin madenciliği yapılarak, ham veriyi Şekil-1’de önerilen algoritmalarla sırası ile geçirilerek anlamlı veriye dönüştürme işlemi gerçekleştirilmiştir.



Şekil-1: Algoritma Şeması [4]

4.1.Ortak Referans Çözünürlüğü (Coref Resolution)

Ortak referans çözünürlüğü algoritması, seçili metin verisi üzerinde kelimelerin neyi ve kimi referans ettiğinin çözümlemesini gerçekleştiren bir algoritmadır. Bu algoritma seçili metin verisindeki cümle içerisinde geçen tüm kelimeleri analiz eder ve analizleri sonucunda cümleler arasında kelimelerden hangisinin birbirlerine referans ettiğinin çözümlemesini yapar. Bu çözümleme, sınıflandırılmamış olan ham metin verisinin anlamlı veriye dönüştürme işlemlerinin ilk adımı olarak görülmektedir.

4.2. Açık Bilgi Çıkarma(Stanford OpenIE)

Açık Bilgi Çıkarma (Stanford OpenIE) algoritması ortak referans çözümlemesi yapılmış olan seçili metnin içerisinden üçlü (triple) dediğimiz yapılar çıkarılmaktadır. Seçili metin verisi içindeki cümleler kelimelerden oluşmakla beraber bir kural yapısı içerisinde hareket etmektedir. Bu kural yapısı tüm dillerde olduğu gibi cümlenin öğelerden oluşmasına ve kurallı bir şekilde bir araya gelmesinden meydana gelmektedir. Kelime topluluklarının bir cümle oluşturulabilmesi için özne, nesne ve yüklemden oluşması gerekmektedir. Tablo-1’de açık bilgi çıkarma algoritmasının cümlenin öğeleri üzerindeki dağılımını yapılarak üçlü (triple) çıkarma işlemi görülmektedir.

	Özne	Nesne	Yüklem
1	Türkiye’nin	En Kalabalık Şehri	İstanbul’dur.
2	Elazığ	Doğu Anadolu Bölgesinde	Yer almaktadır.
3	Ankara’nın	25 ilçesi	Vardır.

Tablo-1: Açık Bilgi Çıkarma – Üçlü Çıkarımı

4.3. Çeviri

Bu çalışmadaki üçüncü aşama olan çeviri algoritması, seçili metin verisinde açık bilgi çıkarımı gerçekleştirilmiş verilerin istediğimiz dil türüne çevrilebilmesi adına Google çeviri programı eklentisinden yararlanılmıştır. Bu şekilde çalışmanın tüm diller üzerine etkisi incelenerek önerilen metin madenciliğinin kapsamı genişletilmiştir.

4.4. Neo4j – Graf Veritabanı

Neo4j programı Neo4j Inc. tarafından geliştirilen bir grafik veri tabanı yönetim sistemidir. Bu program açık kaynak kodlu NOSQL, ACID ile uyumlu bir graf veri tabanı sistemidir. Bu veri tabanı sistemi içerisinde graf veri tabanını oluşturarak işlenmesi amaçlanmaktadır. Graf veri tabanında istediğimiz verilerin birbirleri ile olan ilişkilerini Graph Teorisine göre bağlantılar ve düğümler olacak şekilde gösterilmelidir. Neo4j programında veri yapısı iki şekilde yer almaktadır. Bunlar; bağlantılar ve düğümler olacak şekilde 2 adettir. Programda bağlantılar yapısı düğümler içerisinde yer alan veri ilişkilerini, düğümler ise işlemiş olduğumuz verileri göstermektedir.

5. Bulgular

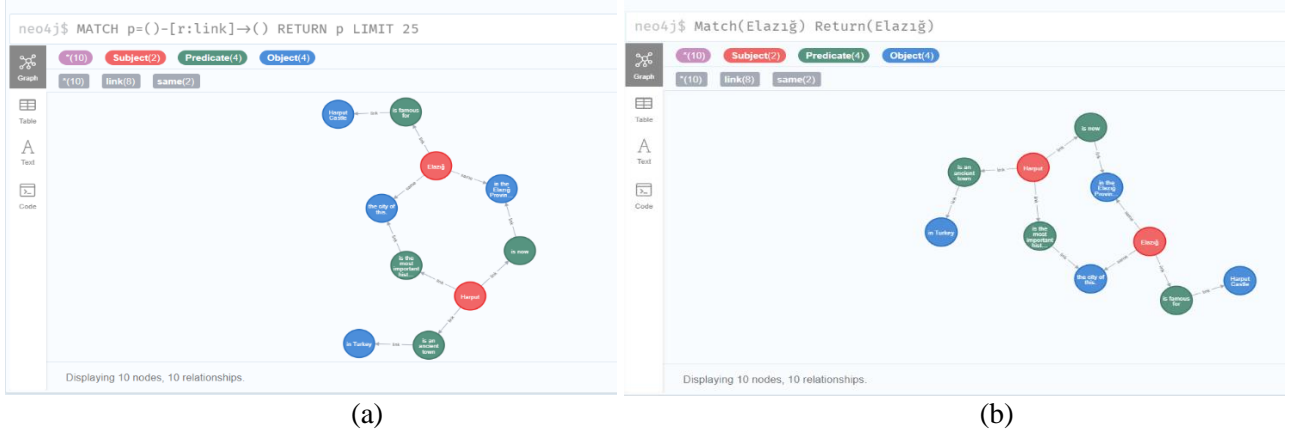
Yapılan bu çalışmada, şekil-1’de bahsedildiği gibi çalışmanın 4 aşamadan oluşan algoritma şemasının tüm adımları, seçili olan şu metin verisi üzerine uygulanmıştır. “*Harput, Türkiye’de bulunan antik bir şehirdir. Harput Elazığ ilindedir. Harput, Elazığ ilinin en önemli tarihi bölgesidir. Harput, Harput Kalesi ile ünlüdür.*”

Çalışmanın birinci aşamasında ortak referans çözünürlüğü algoritmasından yararlanılarak seçili metnin, ortak referanslarının alınması ile beraber tekrarlanan kelimeler seçilerek cümlenin daha programlanabilir ve yalın hale getirilmektedir. Ortak referansları alınan metine açık bilgi çıkarımı algoritması uygulanarak seçili metin içerisinden özne, yüklem ve nesne yapıları çıkarılarak üçlü(triple) yapısına çevrilmiştir. Sonrasında çeviri algoritması kullanılarak çalışmanın evrensel olması adına seçili metin İngilizce diline çevrilmiştir. Tablo-2’de gösterilmektedir.

	Özne	Yüklem	Nesne
1	Harput	is an ancient town	in Turkey
2	İts site(Harput)	is now	in the Elazığ Province
3	This area (Harput)	is the most important historical region of	the city of this.(Elazığ)
4	The town(Elazığ)	is famous for	Harput Castle,

Tablo-2: Açık Bilgi Çıkarımı Algoritma Çıktısı

Bu çalışmanın dördüncü ve son aşamasında, üçlü yapıların Neo4j programı kullanılarak grafa işlenmesi ve sorgulanması yapılmaktadır. Seçilen metnin açık bilgi çıkarma (OpenIE) algoritması uygulanması ile elde edilen özne, yüklem ve nesne verileri şeklinde Neo4j programına Şekil-2(a)'da görüldüğü gibi işlenmiştir.



Şekil-2: (a)Neo4j Programı Düğüm-Bağlantı Verileri (b) Neo4j Veri Sorgulaması

Düğüm verileri işlenmesinden sonra, OpenIE algoritması sonucunda ortaya çıkan üçlüler temel alınarak düğümler arasında bağlantılar oluşturulmuştur. Şekil-2(b)'de görüldüğü gibi Neo4j programı bağlantıları “link” olarak ifade etmiştir. Aynı veriye ait olan bilgileri ise “same” olarak ifade etmiştir. Neo4j programı üzerinde grafa işlenen metin verisi artık ham ve anlamsız olmaktan çıkarak, sorgulama işlemi yapılmasına olanak verecek hale getirilmiştir. Şekil-2(b)'de görüldüğü gibi cümle içerisindeki “Elazığ” öznesini graf veri tabanında aratılması gerçekleştirilmiştir.

6. Sonuç

Yapılan bu çalışmada, seçili metin verisinin önerilen algoritma şemasında sırası ile ortak referans çözünürlüğü, açık bilgi çıkarımı algoritmaları, çeviri ve Neo4j programından yararlanılarak graf veri tabanına işlenmesi gerçekleştirilmiştir. Graf veri tabanına işlenen veriler sorgulama işlemleri yapılarak, işlenmemiş ve sınıflandırılmamış olan metin verilerinin anlamlı sonuçlar ortaya konulması için çalışma gerçekleştirilmiştir. Graf veri tabanında gerçekleştirilen sorgulamalar ile doğru ve hızlı bir şekilde veriye ulaşım sağlandığı gösterilmiştir. Bu çalışma, veri madenciliğini alt dalından biri olan metin madenciliği literatürüne bir katkının yanı sıra seçili veya toplu olarak bulunan metin verilerinin analizinde graf veri tabanının kullanılmasını hedeflenmektedir.

Önümüzdeki çalışmalarda, metin verilerinin daha detaylı analizlerinin yapılabilmesi adına yapay zekâ algoritmaları ekleyerek bu alandaki çalışmaları ilerletilmesi amaçlanmaktadır.

7. Teşekkür

Bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 118C127' nolu proje kapsamında desteklenmiştir. Yazarlar sağlanan destek nedeniyle TÜBİTAK'a teşekkür eder.

Referanslar

- [1] Emre, İ. E., & EROL, Ç. S. (2017). Veri Analizinde İstatistik mi Veri Madenciliği mi?. Bilişim Teknolojileri Dergisi, 10(2): ss.161-167.
- [2] Do Prado, H. A., & Ferneda, E. (Eds.). (2007). Emerging Technologies of Text Mining: Techniques and Applications: Techniques and Applications. IGI Global.
- [3] Değerli, A. (2021). Ağ Toplumu Yaklaşımı İle Akademik Bir Sosyal Ağ Modeli İçin Graf Veri Tabanı Önerisi. Beykoz Akademi Dergisi, 9(1): ss.68-88.
- [4] Do, P., & Le, H. (2021). Building a Knowledge Graph of Vietnam Tourism from Text. Computational Science and Technology: 7th ICCST 2020, Pattaya, Thailand, 29–30 August, 2020, 724, ss:1-13.

İzmir Bakırçay Üniversitesi Güneş Enerji Santralinin Elektrik Üretiminin Saatlik Tahmini

Hourly Forecast of Electricity Production of İzmir Bakırçay University Solar Power Plant

Ertuğrul ORMAN¹, Bayram KÖSE^{2,*}

¹ Akıllı Sistemler Mühendisliği, Bakırçay Üniversitesi, Türkiye, 6016013@bakircay.edu.tr

² Elektrik – Elektronik Mühendisliği, Bakırçay Üniversitesi, Türkiye, bayram.kose@bakircay.edu.tr

Özet

Yenilenebilir enerji kaynaklarının elektrik üretimindeki payının artmasıyla beraber elektrik üretiminin planlanabilmesi için bu kaynaklardan elde edilecek elektriğin doğru tahmin edilmesi daha da önem kazanmıştır. Yenilenebilir enerji kaynaklarından üretilecek elektriğin doğru tahmin edilmesi, şebekede bulunacak elektrik miktarının ayarlanması, akıllı kampüs ve akıllı bina gibi uygulamalar için gereklidir. Bu çalışmada, İzmir Bakırçay Üniversitesi güneş enerji santralindeki saatlik elektrik üretimi meteorolojik veriler kullanılarak yapay sinir ağı ile tahmin edilmiştir. Bu tahminlemede kullanılan meteorolojik veriler, saatlik küresel güneş radyasyonu, bulutluluk, ortalama sıcaklık, ortalama rüzgar hızı ve günlük yağış miktarıdır. Bu meteorolojik veriler kullanılarak hazırlanan veri seti NARX modeli kullanılarak işlenmiş ve elektrik üretimi tahmin edilmiştir. 3 yıllık periyotta 28 ayın elektrik üretimi saatlik olarak tahmin edilmiştir. 5 deneme listelenmiş ve en iyi sonuç veren model ortaya konmuştur. Ortalama mutlak hatanın kullanılabildiği verilerde hata % 15,9869, kök ortalama kare hatası en düşük ayda 3,9744 en yüksek olduğu ayda hata 22,2385 olmuştur. **Anahtar Sözcükler:** Akıllı kampüs; NARX ; tahminleme; zaman serisi.

Abstract

With the increase in the share of renewable energy sources in electricity production, accurate estimation of the electricity to be obtained from these sources has become more important in order to plan electricity production. Accurate estimation of electricity to be produced from renewable energy sources, adjustment of the amount of electricity to be found in the grid, is necessary for applications such as smart campus and smart building. In this study, hourly electricity production in İzmir Bakırçay University solar power plant was estimated by artificial neural network using meteorological data. The meteorological data used in this forecast are hourly global solar radiation, cloudiness, average temperature, average wind speed and daily precipitation. The data set prepared using these meteorological data was processed using the NARX model and electricity generation was estimated. Electricity production for 28 months in a 3-year period is estimated on an hourly basis. 5 trials are listed and the model with the best results is revealed. In the data where the mean absolute error could be used, the error was 15.9869%, and the root mean square error was 3.9744 in the lowest month and 22.2385 in the highest month.

Keywords: Forecasting; NARX ; smart campus; time series.

1. Giriş

Ülkemizin elektrik üretiminde yenilenebilir enerji kaynaklarının yeri günden güne artmaktadır. Öyle ki 2010 yılında yenilenebilir enerji ve atıkların elektrik üretimindeki payı %1,9 iken 10 yıl sonra 2020 yılında üretimin %16,8'i yenilenebilir enerji kaynaklarından ve atıklardan elde edilmiştir[1]. Elektrik üretiminde yenilenebilir kaynakların kullanılmasında yaşanan bu artış, geçmiş yıllara kıyasla elektrik üretiminin tahmin edilmesini daha da önemli kılmıştır. Fosil yakıt santralleri elektrik üretimi, tüketim talebine göre artırılabilir veya azaltılabilir. Yenilenebilir enerji kaynaklarında ise elektrik üretimi doğa koşullarına bağlıdır. Fosil yakıt kullanan santrallerin aksine yenilenebilir enerji santrallerinde elektrik üretimini arttırmak veya azaltmak mümkün değildir[2]. Bu nedenle bu santrallerin üreteceği elektriğin doğru tahmin edilmesi elektrik arz güvenliği ve elektrik maliyetinin düşürülmesi için oldukça önemlidir [3]. Bunun yanı sıra, günümüzde ciddi bir tehdit unsuru olan küresel ısınma ve enerjide dışa bağımlılık gibi problemler de elektrik üretiminin ve tüketiminin doğru dengelenmesi ile aşılabilir[4]. Yenilenebilir enerji kaynaklarından üretilecek elektriğin doğru tahmin edilmesi fosil yakıtlar ile üretilecek elektriğin doğru miktarda olmasını sağlar ve bu durum kaynak israfının önüne geçer[3] [5].

Yenilenebilir enerji kaynaklarından elde edilecek enerjinin doğru tahmin edilebilmesi yalnızca ulusal şebeke için değil, akıllı şebeke uygulamaları için de oldukça önem arz etmektedir. Kendi elektriğini üretmeyi hedefleyen İzmir Bakırçay Üniversitesi için de elektrik üretiminin doğru tahmin edilebilmesi zaruridir. Bu çalışmada İzmir

Bakırçay Üniversitesi güneş enerji santralinin elektrik üretimi yapay sinir ağları ile tahmin edilmektedir. Bu tahmin modelinin üniversitenin gelecek yıllardaki enerji politikalarına katkı sağlayacaktır.

2. Materyal ve Metod

2.1 Veri seti

Tahmin modelinde kullanılan veriler Meteoroloji 2. Bölge müdürlüğünden alınmıştır. Verileri kullanılan istasyonlar 17789 MENM (Menemen) istasyonu ve 17218 LTBL (Çiğli) istasyonudur. Menemen istasyonu, otomatik meteoroloji gözlem istasyonuyken çiğli havaalanı istasyonunda otomatik meteoroloji gözlem istasyonunun yanı sıra sinoptik ve metar gözlem de yapılmaktadır. Menemen istasyonu İzmir Bakırçay Üniversitesi güneş enerji santraline kuş uçuşu 8,41km mesafedeyken Çiğli havaalanı istasyonu İzmir Bakırçay Üniversitesi güneş enerji santraline 8,53km mesafededir.

Modelde kullanılan girdilerden saatlik küresel güneş radyasyonu verisi Menemen istasyonundan alınmış olup birimi wattaat/m²'dir. Veri setinde 00.00 olan üretimler dahil 10317 veri bulunmaktadır. Saatlik bulutluluk verisi Çiğli istasyonundan alınmış olup, Menemen istasyonunda yoktur. Bulutluluk ölçümleri OMGİ'lerde yapılmamakta olup klima sinoptik ve metar rasatları yapan istasyonlar tarafından yapılmaktadır. Saatlik toplam bulut kapallığı ölçümü 8/8 (8 OKTA) olarak yapılmaktadır. 1 ve 2 az bulutlu, 3 ve 4 parçalı bulutlu, 5,6 ve 7 çok bulutlu 8 ise gökyüzü tamamen bulutla kaplı anlamına gelmektedir. Saatlik bulutluluk verilerinde 19496 adet veri bulunmaktadır. Saatlik ortalama sıcaklık verisi menemen istasyonundan alınmıştır. Birimi C^o'dir. Sıcaklık ölçümleri gölgede ve 2 metre yükseklikte ölçülmektedir. 1 temmuz 2019 ile 31 ekim 2021'e kadar olan dönemde 20408 adet veri bulunmaktadır. Saatlik ortalama rüzgar hızı verisi menemen istasyonundan alınmıştır. Birimi m/s'dir. 1 temmuz 2019 ile 31 ekim 2021'e kadar olan dönemde 20424 adet veri bulunmaktadır. Günlük toplam yağış miktarı verisi menemen istasyonundan alınmıştır. Günlük toplam yağış miktarı ölçümleri içinde bulunan günün 06:00 UTC saati ile bir önceki günün 06:00 UTC saatleri arasında yapılmaktadır. Temmuz 2019 ile ekim 2021 tarihleri arasında 854 adet veri bulunmaktadır. Bu verilerin haricinde geçmiş üretim verileri de sisteme girdi olarak verilmiştir. Çıktı verisi ise İzmir Bakırçay Üniversitesinden alınmıştır. Üretim olmayan saatler dahil toplam 20041 adet veri bulunmaktadır.

2.2 Metod

Bu çalışmada matlab programının neural network start eklentisi kullanılarak tahminleme yapılmıştır. Neural network start eklentisinin dinamik zaman serileri için kullanılan tool'u olan time series app kullanılmıştır. Time series app bir veya birden fazla zaman serisinin geçmişteki değerlerinin kullanıldığı bir tür dinamik filtrelemedir. Bu dinamik sinir ağı doğrusal olmayan filtreleme ve tahminler için kullanılmaktadır. Kullanım alanı oldukça geniştir. Finansal analistler bir hisse senedinin, tahvilinin veya bir diğer finansal aracın gelecekteki değerini tahmin etmek için kullanırken, bir mühendis jet motorunun yaklaşan arızasını tahmin etmek için kullanabilmektedir[6].

Tahminleme işlemlerinde üç farklı doğrusal olmayan zaman serisi ile problemler çözülmektedir. Dış girdili doğrusal olmayan otoregresif ağ (NARX), doğrusal olmayan otoregresif ağ (NAR) ve doğrusal olmayan girdi-çıkı bu serilerdir. Oluşturulan modelde tahminleme için tahmin edilecek veri ve bu veriden önceki 2 saatin verisi girdi olarak verilmesi planlanmıştır. Bu nedenle mevcut seriler arasında seçim yapılırken NARX ön plana çıkmıştır. NARX modeli, zaman serilerinde sıklıkla kullanılan ARX'in modelini temel almaktadır. NARX'in karar verici eşitliği Denklem(1) ile verilmektedir. Burada t zaman, y üretim miktarını, y(t-1) ile y(t-n) önceki üretim verilerini u(t-n) ifadesi de diğer meteorolojik verileri girdileri temsil etmektedir.

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y), u(t-1), u(t-2), \dots, u(t-n_u)) \quad (1)$$

Tahminlemenin yıllık yapılması durumunda ışınların güneş panellerinin üzerine farklı açılarda düşmesi başta olmak üzere yıl içerisinde meteorolojik koşulların çok farklılaşması gibi nedenlerden dolayı model istenen başarıyı gösterememektedir. Tahminlemenin aylık yapılması durumunda ise, güneşlenme süresinin düştüğü ve buna bağlı olarak elektrik üretiminin azaldığı kış, aralık, ocak gibi kış aylarında yapay sinir ağını eğitecek sayıda girdi bulunmadığından dolayı istenen başarıya yine ulaşılamamaktadır. Mevsimlik modelde tahminlemenin yapılacağı aralık yıllığa göre kısaldığından sistem daha benzer koşullarda çalışmaktadır. Bu nedenle sistemin başarısı yıllık ve aylığa kıyasla daha iyidir. Ancak veri seti incelendiğinde mevsimlik yerine yılın 4 çeyreğini baz alan modeller daha başarılı görülmüştür. Ocak-Şubat-Mart ayları ilk çeyreği nisan-mayıs-haziran ikinci çeyreği temmuz-ağustos-eylül üçüncü . çeyreği ekim-kasım-aralık son çeyreği oluşturmaktadır. Bu modelin mevsimlik modelden daha doğru sonuç verdiği görülmüştür.

Elektrik üretiminin tahmin edileceği aralığın belirlenebilmesi için saat 03.00 ile saat 18.00 arasındaki üretim değerleri Tablo 1.'de görüldüğü gibi incelenmiştir. Yapılan bu incelemenin sonucunda üretim değerlerinin çok küçük olduğu 03.00-04.00-16.00-17.00-18.00 saatleri tahmin modelinden çıkarılmıştır. Saatlik tahminler 1 temmuz 2019'dan 31 ekim 2021'e kadar olan dönem için yapılmıştır.

Tablo 1. Saatlik verilerin incelenmesi.

Saat (GMT)	Toplam veri	Üretim olmayan veri	5'ten küçük üretim	10'dan küçük üretim	En küçük üretim	En büyük üretim
03.00	835	570	812	834	0	19,32
04.00	835	241	389	480	0	54,51
05.00	835	85	165	197	0	140,07
06.00	835	45	65	88	0	218,04
07.00	835	39	45	53	0	292,56
08.00	835	42	46	48	0	304,94
09.00	835	38	42	49	0	320,85
10.00	835	36	41	46	0	333,96
11.00	835	36	39	49	0	316,02
12.00	835	41	48	55	0	291,87
13.00	835	43	82	124	0	240,81
14.00	835	129	186	222	0	192,51
15.00	835	285	351	369	0	97,29
16.00	835	439	543	606	0	34,5
17.00	835	713	835	835	0	2,07
18.00	835	831	835	835	0	0,19

Modelin hata değerlendirilebilmesi için hata kareler ortalamasının karekökü (HKOK / RMSE) ve ortalama mutlak hata kullanılmıştır.

$$HKOK(RMSE) = \sqrt{\frac{\sum_{i=1}^N (Predicted_i - Actual_i)^2}{N}} \quad (2)$$

$$OMH(MSE) = \left| \frac{Actual - Predicted}{Actual} \right| \quad (3)$$

Tahminleme işlemi için oluşturulan yapay sinir ağı 12 girdiye sahiptir. Girdi katmanı, gizli katman ve çıktı katmanı olmak üzere 3 katmandan oluşan yapay sinir ağının gizli katman nöron sayısı 10'dur. Eğitim algoritması olarak bayesian regularization'ı kullanmaktadır.


3. Bulgular ve Tartışma

Bayesian regularization algoritması kullanılarak yapılan elektrik üretimi tahminleri incelendiğinde, kök ortalama kare hataları tablo 2. deki gibidir. Tabloda T1,T2,T3,T4 ve T5 ile yapılan gösterim aynı yapay sinir ağında farklı test ve eğitim veri setleri ile yapılan 5 farklı tahminlemeyi göstermektedir. Tablo incelendiğinde görülmektedir ki En başarılı tahminlemenin yapıldığı 1. tahminde en az hata 3,9744 iken en yüksek hata 22,2385'tir. Kış aylarında kök ortalama kare hatası düşük çıkarken yaz aylarında daha yüksek çıkmaktadır. Ortalama mutlak hatanın kullanıldığı üretimin 0 olmadığı 7588 verinin ortalama mutlak hatası ise % 15,9869'dur.

Tablo 2. Saatlik tahminlerin aylık hata kareler ortalamasının karekökü çizelgesi

Tarih	T 1	T 2	T 3	T 4	T 5	Tarih	T 1	T 2	T 3	T 4	T 5
Tem.2019	5,9	17	8,04	7,4	18,99	Eyl.2020	14,72	24,27	17,61	23,22	16,82
Ağu.2019	9,66	11,18	10,13	13,44	12,23	Eki.2020	12,25	18,46	14,44	12,29	12,92
Eyl.2019	12,28	13,99	16,1	12,97	19,49	Kas.2020	3,97	4,56	4,61	4,56	7,08
Eki.2019	9,76	11,03	13,42	12,41	29,19	Ara.2020	12,68	14,82	12,87	13,88	12,81
Kas.2019	6,85	10,33	9,26	8,89	10,31	Oca.2021	7,77	8,28	8,69	7,51	8,04
Ara.2019	11,14	13,18	14,4	12,31	12,47	Şub.2021	7,84	8,85	11,04	13,38	13,14
Oca.2020	13,32	14	14,28	16,39	17,13	Mar.2021	9,6	14,56	11,07	12	12,5
Şub.2020	18,82	24,37	21,81	30,87	23,07	Nis.2021	13,55	15,44	15,72	18,91	14,75
Mar.2020	10,91	15,29	17,05	14,81	14,71	May.2021	7,87	9,19	8,51	11,41	10,41
Nis.2020	17,33	19,38	18,71	18,2	22,79	Haz.2021	14,34	18,73	15,72	16,24	16,98
May.2020	17,02	21,14	21,07	21,94	19,6	Tem.2021	18,32	19,57	18,99	20,17	19,59
Haz.2020	10,27	13,74	33,09	24,46	12,2	Ağu.2021	22,23	23,8	27,38	23,37	22,54

Yapılan saatlik tahminlemenin 01.07.2019 tarihi ile 31.07.2019 tarihleri arasında bir aylık süreçte gerçekleşen elektrik üretimi ve tahmin şekil 2.'de gösterilmiştir.



Şekil 2. Temmuz 2019 dönemine ait elektrik üretim ve tahmin değerleri

Benzer çalışmalarda Y.E.Kıymaz “Güneş enerjisi santrallerinde derin öğrenme kullanılarak elektrik üretimi tahmininin yapılması” adlı yüksek lisans tezinde saatlik elektrik tahmini için SARIMA ve LSTM modellerini kullanmış ve her veri setinin %70’ini eğitim %30’unu test olarak ayrılmıştır. Çumra’da kurulduğu belirtilen 1MW gücündeki Santral_A GES’ine ait performans sonuçları şöyledir: SARIMA modelinde hata kareler ortalamasının karekökü 1525,37 ortalama mutlak hata 2326754, LSTM modelinde ise hata kareler ortalamasının karekökü 1163,62 ortalama mutlak hata ise 1354012 olmuştur. Tuzlukçu’da kurulduğu belirtilen 1MW gücündeki Santral_B GES’ine ait performans sonuçları ise şöyledir: SARIMA modelinde hata kareler ortalamasının karekökü 1994,28 ortalama mutlak hata ise 3977153, LSTM modelinde ise hata kareler ortalamasının karekökü 1314,93 ortalama mutlak hata ise 1800776 olmuştur [7]. M.F. Bekçioğulları ve ark.’nın “Güneş enerjisinin kısa-dönem tahmininde farklı makine öğrenme yöntemlerinin karşılaştırılması” adlı makalede 1 saat 2 saat ve 3 saat sonrasının tahmini için makine öğrenme yöntemlerinden destek vektör makinesi (DVM), doğrusal regresyon (DR), karar ağacı regresyonu (KAR), topluluk regresyonu ve gauss süreci regresyonu(GSR) kullanılmıştır. TR,KAR,DR,DVM ve GSR yöntemleri için sırasıyla 1 saat sonrası tahmin edildiğinde oluşan hatalar şöyledir: RMSE için: TR 0,0582 KAR 0,0517 DR 0,0946 DVM 0,0244 ve GSR 0,0388 MSR için TR 0,0344 KAR 0,0272 DR 0,0694 DVM 0,0154 VE GSR 0,0257 olarak hesaplanmıştır [8].

4 .Sonuç ve Öneriler

Yapılan bu çalışma ile İzmir Bakırçay Üniversitesi güneş enerji santralinin elektrik üretimi saatlik veriler kullanılarak yapılan tahminler ortaya konmuştur. Yapılan bu tahminleme ile elektrik üretimi 1 saat önceden tahmin edilebilmektedir. Ekstrem hava olaylarının yaşanmadığı günlerde sistemin doğruluğu daha da artarken, mevsim normallerinin çok dışında ölçümlerin gerçekleştiği günlerde doğruluk düşmektedir. Ekstrem hava olaylarının haricinde bulutluluğun yüksek olduğu günlerde de elektrik üretim tahminlerinde sapma meydana gelmektedir. Bu saptamalara rağmen %15,9869’luk ortalama mutlak hata ve 3,9744 ile 22,2385 arasında değişen kök ortalama kare hatası ile sistem belli bir başarıya ulaşmıştır.

Gelecek çalışmalarda ekstrem meteorolojik parametrelerin tahmin üzerindeki etkisinin azaltılması için çalışmalar yapılması planlanmaktadır. Bunun haricinde üretimin daha erken tahmine edilebilmesi üzerinde çalışmalar yapılacaktır. Üretimin 1 saat önceden değil 1 gün 1 hafta gibi daha erken tahmin edilmesi gerekli planlama ve aksiyomun alınabilmesi için daha fazla vakit ayrılabilmesine imkan sağlayacaktır. Yapılan bu çalışma ve gelecekte yapılacak çalışmalar ile İzmir Bakırçay Üniversitesi’nin gelecekteki akıllı kampüs uygulamalarına ve üniversitenin hedefleri arasında yer alan kendi elektriğini üretme hedefine katkı sağlayacaktır.

Referanslar

- [1] “TEİAŞ, Türkiye Elektrik Üretim - İletim İstatistikleri”,2020.
- [2] F.Yazıcı, M.E.Başoğlu ve B.Çakır, “Akıllı Şebeke Bileşenleri ve Yapısal Analizi,” EMO Bilim. Dergi, 2019,
- [3] Milli Eğitim Bakanlığı. “Yenilenebilir Enerji Teknolojileri GES Üretim Tahmini” 2015.
- [4] A.C.Toker ve O.Korkmaz,, “Türkiye Kısa Süreli Elektrik Talebinin Saatlik Olarak Tahmin Edilmesi”
- [5] B. Düzgün, “Türkiye Elektrik İletim ve Dağıtım Şebekesinin Enerji Verimliliğinin Değerlendirilmesi ve 2023 Projeksiyonları,” J. Polytch., vol. 0900, no. 3, pp. 621–632, 2018..
- [6]https://www.mathworks.com/help/deeplearning/ug/design-time-series-narx-feedback-neural-networks.html?searchHighlight=narx&s_tid=srchtitle_narx_1 adresinden 01.04.2022 tarihinde erişilmiştir
- [7]Y.E.Kıymaz “Güneş enerjisi santrallerinde derin öğrenme kullanılarak elektrik üretimi tahmininin yapılması”,Yüksek Lisans Tezi,Necmettin Erbakan Üniversitesi,2020
- [8] M.F. Bekçioğulları vd. “Güneş enerjisinin kısa-dönem tahmininde farklı makine öğrenme yöntemlerinin karşılaştırılması” EMO Bilimsel Dergi 11/22

Interpreting Black-Box Machine Learning Algorithm Through Anomaly Detection of Mobile Ad Hoc Networks

Farid BAGHERI¹, Derya EREN AKYOL^{2,*},

¹ Industrial Engineering, Dokuz Eylül University, Turkey, farid.bagheri@ogr.deu.edu.tr

² Industrial Engineering, Dokuz Eylül University, Turkey, derya.eren@deu.edu.tr

Abstract

One of the main reasons that the topology of mobile ad hoc networks (MANETs) has been changed rapidly in recent years is node mobility. Therefore, even though the network topology is constantly changing, setting up a system that can detect network traffic anomalies with high accuracy is a fundamental problem for these networks. On the other hand, anomaly detection is indispensable in so many fields that it has received a lot of attention in recent years. Various anomaly detection approaches have been proposed, with isolated forests being one of the most common. In practice, anomaly detection data can be collected in a distributed manner using MANET's wireless sensor network. The lack of interpretability is one of the primary challenges that Isolation Forest confronts. It is, on the other hand, a Blackbox algorithm. Lots of machine learning algorithms which are used nowadays are black box we just have information about inputs and outputs without a considerable knowledge about their insides. Internal model information, such as the structures, optimization strategy, or training dataset, is not openly shared since it caused in many cases leak private information or make the system more susceptible. Such isolation forest attributes may be determined via a sequence of queries, as described in this study. This has several repercussions. However, our study reveals the susceptibility of Blackbox isolation forest to several forms of assaults — in this study we prove that exposed the information inside the black box algorithm are more coherent adversarial instances against the black box model. On the other hand, with ad-hoc algorithm examples, this method may be applied to better analyze and evaluate isolation forest. In compared to existing state-of-the-art anomaly detection techniques for ad-hoc algorithms, the suggested algorithms will not only perform well in terms of anomaly identification, but will also run rapidly and require less CPU memory.

Keywords: *Anomaly detection; Interpreting; Machine Learning; Mobile ad hoc networks*

1. Introduction

Mobile ad hoc networks (MANET) are self-organized networks of mobile nodes that interact with one another using wireless connections with no infrastructure [1]. Each mobile node acts as both a terminal and a router, forwarding traffic from one node to the next. An important MANET reactive routing solution is the ad hoc on-demand distance vector (AODV) [2]. When the source node sends data to the destination node, it is intended to reduce the need for broadcast throughout the route search process. The source node sends a route request packet (RREQ) to the neighboring node and waits for a response. An intermediate node with a new route to the source or destination node receives a route response packet (RREP) [3]. Because MANETs have a dynamic topology and lack centralized monitoring, security is a serious problem. Flooding, Blackhole, Neighbor, and Rushing assaults have all been recognized as plausible routing attacks against these networks [4].

There are two sorts of security solutions offered for MANETs: prevention and detection. The first line of defense against an attack is typically preventative tactics. We cannot, however, rely completely on them. If

the preventive strategy fails, you can adopt detection tactics. Signature-based detection and anomaly detection are two basic types of these techniques.

If the current network activity matches a known attack signature, a signature-based detection approach identifies the attack. One approach to anomaly detection is to model a typical network activity and consider deviations from that model as anomalies. Anomaly detection techniques have the advantage of not requiring known attack signatures and can detect unexpected attacks [3]. Identifying anomalies in isolated forests is a two-step method. The first step (training) is to build an isolated tree from the training set subsamples. In the second stage (evaluation), the test cases are walked along the isolation tree and each anomaly score is calculated. iTree is generated during the training phase by iteratively splitting subsample X until all instances are isolated. Each iTree consists of a subsample X' randomly selected from X without being replaced. Counting the number of edges e from the root node to the external node as instance x moves through the iTree during the evaluation phase produces a single root length $h(x)$. When the traversal approaches the preset height limit h_{lim} , the return value will be e plus adjustment c (size). This adjustment compensates for using size data to find the average root length of a random subtree that can be generated with data that exceeds the tree height limit. The anomaly score is calculated when $h(x)$ is collected for each tree in the ensemble [5].

Due to its established efficiency and inexpensive computational work, isolated forests are one of the most widely used algorithms in the field of anomaly detection. The lack of interpretability that plagues the quarantine forest is the result of the inherent unpredictability that drives the division of the quarantine tree, which is the building part of the quarantine forest [6].

The black box model takes a series of query inputs and provides relevant output while masking the underlying conditions such as the model architecture. These are intentionally used as black boxes to protect intellectual property or private training data. In our research, we are trying to know detail of black-box machine learning in order to convert it to a white box model. The effects of such "whitening" on black box models are wide-ranging. On the one hand, this has a legal impact on Isolation Forest's intellectual property (IP). Internal knowledge of the model architecture can be proprietary and important intellectual property, while training data can be sensitive information. Revealing secret data can also make your model more vulnerable to enemy attacks. However, gaining knowledge of the black box model are utilized in other situations. For example, work is being done to use hostile entities to shield private areas of auto-recognized images (such as faces) [7]. A better understanding of cognitive function increases your chances of protecting your privacy in such cases. In any case, investigating the category of knowledge inside the black box algorithm and its size and quantity that can be collected are used to approach to the machine learning is an important subject of research.

2.Literature Review

The focus of my research was to extract and use information from black box learning algorithms. [8, 9] proposes to generate an avatar model that maximizes the probability that a model extraction attack will recover certain model parameters or that the I / O pair of the query will come from the target model [8]. Equation-solving attacks and avatar strategies have been shown to succeed in determining internal parameters of non-neural network models by [8] and [9] also uses a different approach and they look the problem from different lens of view with the ultimate goal of creating hostile instances. It discriminately trains metamodels to predict model hyperparameters such as model families (architecture) and training data. The avatar approach, on the other hand, presume model hyperparameters such as their architecture, structure and training subset. Avatar's approach complements our approach. If a particular example is included in the training set, a membership inference attack determines this [10; 11]. Ateniese et al. (2015) Specific training on decision tree metamodels containing different classifiers are trained on dissimilar and alternative subsets.

This piece of work survey more than just deriving training data and proves that model’s structure and optimization processes which is one of their achievements derived.

3. Model Framework

The attributes of a trained isolated forest model imply to different kinds of knowledge about the model. These fall into three categories: (1) architecture, (2) optimization, and (3) training data. Treat this problem as if it were a standard supervised learning task using a model. First, assemble a set of diverse white box models (“meta training sets”) that aim to match the target black box to some extent. Then use the metatraining data to train unique algorithm which is called metamodel, that accepts the model as input and provides the features of the model as output. Because we try to estimate attributes when testing the black box model, the only information you can use for attribute prediction is the query I / O pair. With this combination of inputs and outputs, you can predict model properties very well. Summary (1) Investigate the category and size of internal knowledge and detail about the black box model that can be derived through queries. (2) A new metamodel approach that considers the output from static query input, and in addition to that it actively optimizes the interrogation and survey the input to extract additional information. (3) Investigate issues such as meta-training set size, number and standards which is used in queries, and discrepancy between meta-training model and black box algorithm. (4) Empirical verification that the published knowledge accelerates to an increase in the sensitivity of the black box model to attacks according to the example of the enemy.

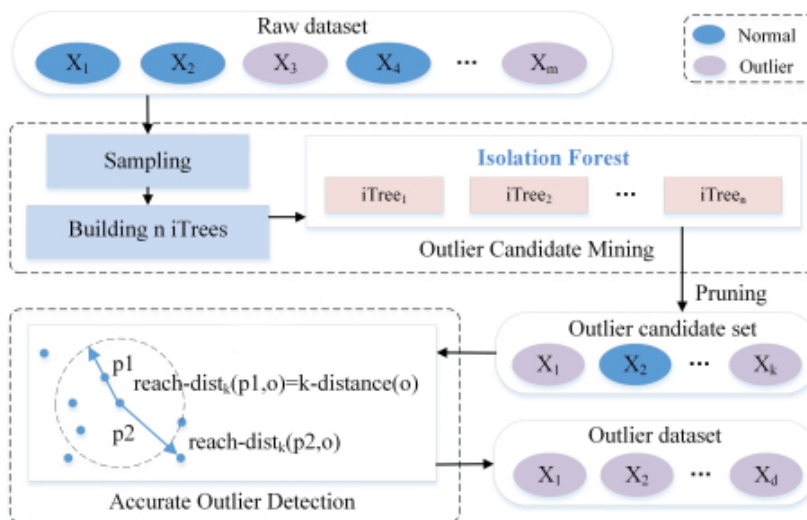


Figure 1: Framework of proposed method

Conclusion

The goal of our research training is to deepen our knowledge of machine learning and its structure, and to present and make a better framework for isolated forests for future research. Isolated forests can be analyzed in an ad hoc way to identify anomalies. You can see if this detection is reliable. In addition, this study provides knowledge about isolated forest structures and architects.

References:

- [1] P. M. Jawandhiya, "A Survey of Mobile Ad Hoc Network Attacks", *International Journal of Engineering Science and Technology*, vol. 2, no. 9, pp. 4063–4071, 2010.
- [2] S. Taneja and A. Kush, "A Survey of Routing Protocols in Mobile Ad Hoc Networks", *International Journal of Innovation Management and Technology (IJIMT)*, vol. 1, no. 3, 2010.
- [3] M. Alikhany and M. Abadi, "A Dynamic Clustering-Based Approach for Anomaly Detection in AODV-Based MANETs", in *Proceedings of the 2011 International Symposium on Computer Networks and Distributed Systems (CNDS)*, Tehran, Iran, 2011.
- [4] B. Wu, J. Chen, J. Wu, and M. Cardei, "A Survey of Attacks and Countermeasures in Mobile Ad Hoc Networks", in Y. Xiao, X. Shen, and D.-Z. Du (Eds.): *Wireless/Mobile Network Security*, Springer, pp. 103–135, 2006.
- [5] Liu, F.T., Ting, K.M. and Zhou, Z.H., 2012. Isolation-based anomaly detection. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 6(1), pp.1-39.
- [6] Carletti, M., Terzi, M. and Susto, G.A., 2020. Interpretable anomaly detection with diffi: Depth-based feature importance for the isolation forest.
- [7] S. J. Oh, Mario Fritz, and Bernt Schiele. Adversarial image perturbation for privacy protection a game theory perspective. In *ICCV*, 2017.
- [8] Florian Tramèr, Fan Zhang, Ari Juels, Michael K. Reiter, and Thomas Ristenpart. Stealing machine learning models via prediction apis. In *USENIX*, 2016.
- [9] Nicolas Papernot, Patrick McDaniel, Ian Goodfellow, Somesh Jha, Z Berkay Celik, and Ananthram Swami. Practical black-box attacks against deep learning systems using adversarial examples. In *ASIACCS*, 2017.
- [10] Reza Shokri, Marco Stronati, Congzheng Song, and Vitaly Shmatikov. Membership inference attacks against machine learning models. In *SP*, 2017.
- [11] Giuseppe Ateniese, Giovanni Felici, Luigi V. Mancini, Angelo Spognardi, Antonio Villani, and Domenico Vitali. Hacking smart machines with smarter ones: How to extract meaningful data from machine learning classifiers. In *IJSN*, 2015.

Satranç Figür Seslendirmelerinin Mel Ölçeği ve Ses Görüntüsü ile Yapay Sinir Ağları Kullanılarak Sınıflandırılması

Classification of Chess Figure Vocalizations Using Artificial Neural Networks with Mel Scale and Speech Image

Vasif NABIYEV ^{1*}, Eyüp Ensar KALAYCI ²

¹ Bilgisayar Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Türkiye, vasif@ktu.edu.tr

² Bilgisayar Mühendisliği Bölümü, Marmara Üniversitesi, Türkiye, eypklyc@gmail.com

Özet

Körleme satranç, insan beyninin hafıza yapısının ve sınırlarının araştırılmasında özellikle ilgi çekicidir. Körleme satrançta, oyuncu tahtayı görememekte, böylece durumu hafızasında görselleştirerek hamlelerini sesli söylemektedir. Bu çalışmada, körleme satranç için sesli komutların tanınmasının ilk adımı, satranç figürü seslendirmelerinin kelime tabanlı belirlenmesi ve sınıflandırılması üzerinde durulmuştur. Mel frekans katsayıları MFCC ve Mel spektrogramları, ses verileri için öznitelik vektörü olarak kullanılmıştır. Bu vektörlerin sınıflandırılması yapay sinir ağları ile yapılmıştır. Yapılan testler sonucunda gürültülü ortamlarda %99 başarı elde edilmiştir.

Anahtar Sözcükler: *Konuşma Tanıma, Körleme satranç, Yapay Sinir Ağları, Mel Frekans Kepstral Katsayıları, Gürültü Azaltma.*

Abstract

Blindfold chess is of particular interest in the research of the memory structure and limits of the human brain. In blindfold chess, the player cannot see the board so the player visualizes the situation and make his moves aloud. In this study, the first step of recognition of voice commands for blindfold chess, word-based determination, and classification of chess figure vocalizations have been emphasized. Mel frequency coefficients and mel spectrograms have been used as the feature vector for audio data. The classification of these vectors has been made by using artificial neural networks. As a result of the tests, 99% success has been obtained in noisy environments.

Keywords: *Speech Recognition, Blindfold chess, Artificial Neural Networks, Mel Frequency Cepstral Coefficients, Noise Reduction.*

1. Giriş

Körleme satranç; bir oyuncunun tahtaya bakmadan, notasyonları kullanarak oynandığı satrançtır[1]. Bu durumda oyuncu satranç tahtasını görmediği için taşları kullanamaz ve hamleleri görmeden, zihninde canlandırarak sesli şekilde söyler. Konuşma tanıma sistemleri sesli komutun bir hamleye çevrimi için kullanılabilir. Örnek olarak Wang ve arkadaşları [2]'de körleme satranç için konuşma tanıma tabanlı bir eğitim sistemi üzerinde çalışmışlardır. Bu nedenle gürültülü ortamlarda notasyona uygun sesli şekilde ifade edilen hamlelerin tanınması önem taşımaktadır.

Günümüzde başarılı konuşma tanıma sistemleri genellikle fonem tabanlı istatistiksel sistemler veya uçtan-uca derin ağların kullanımı ile çalışmaktadır. Geleneksel sistemler olan istatistiksel fonem tabanlı sistemlerde kullanılan akustik modellerin amacı harflere ait fonemleri, kelimelere ait fonem kombinasyonları ile eşleştirilmeye çalışmaktır. Diğer taraftan dil modelleri ise dile ait kurallarla akustik modelin başarısını artırarak sesin tanınmasına yardımcı olmaktadır. Fonemlerin belirlenmesinde ve hizalanmasında Saklı Markov Modeli (HMM), sınıflandırılmasında ise genellikle Gauss Karışım Modeli (GMM) kullanılırken günümüzde sınıflandırma başarısı nedeniyle Derin Sinir Ağları (DNN) tercih edilmektedir. Diğer yandan daha popüler olan uçtan-uca yöntemler ise temelinde Yinelemeli Derin Ağları veya Transformer tabanlı olarak problemi ele almaktadır. [3]'de oluşturulan Türkçe konuşma tanıma sisteminde fonem tabanlı HMM-GMM, HMM-DNN yapıları kullanılarak bunların başarısı kıyaslanmıştır. Bu çalışmada, izole edilmiş satranç seslendirmelerinin sınıflandırılması için kelime tabanlı bir sistem oluşturulmuştur. İnsan kulağının sesi algılama biçimine yakınlığı sebebiyle Mel-Frekans Kepstral Katsayıları (MFCC) öznitelikleri kullanılmıştır. Sınıflandırma için ise DNN tercih edilmiştir. Ahmed [4]'de Çağrı merkezlerine özel olarak konuşma tanıma gerçekleştirmiştir. Çalışmasında

klasik yöntem olan HMM altyapısını kullanmıştır. Kutucu ise [5]'de CNN kullanımı ile Türkçe konuşma tanıma üzerinde çalışmıştır. Fakhan [6]'de dikkat çekici bir çalışma gerçekleştirerek yenilikçi Transformer modelleri ve başarılı diğer modelleri kullanarak İngilizce veri setlerinden öğrenilen bilgiyi Türkçe konuşma tanıma için başarıyı artırıcı yönde uyarlamıştır.

2. Amaç

Çalışmanın amacı körleme satranç için gürültülü ortamlarda sesli komutların tanınmasının ilk adımı olan, satranç figürlerine ait Türkçe seslendirmelerinin kelime tabanlı olarak geleneksel yöntemler ile belirlenmesi ve sınıflandırılmasıdır. MFCC ve Mel spektrogramları, ses verileri için öznitelik vektörü olarak kullanılmıştır. Öznitelik vektörleri yapay sinir ağları yardımıyla sınıflandırılmıştır. Yeni bir yaklaşım olarak satranç figür seslendirmelerine ait spektrogram görüntülerinin başarıya katkısı incelenmiştir. Öte yandan Türkçe hedeflenerek gerçekleştirilen bu çalışmanın gelecekte çok dilli girişler ve uçtan-uca modeller ile araştırılması ise sonraki adım olarak planlanmıştır.

3. Materyal ve Yöntem

3.1. Öznitelik Çıkarma

Öznitelik çıkarımı tüm diğer tanıma sistemlerinde olduğu gibi konuşma tanıma sistemleri için de önemli bir aşamadır. İyi öznitelikler beraberinde iyi tespitleri getirir. Ses verisi zamanla değişen bir yapıya sahip olduğundan geleneksel konuşma tanıma sistemleri sinyalin durağan akustik özelliklere sahip olduğu kısa parçalar üzerinde öznitelik çıkarımına odaklanmışlardır. Literatürde insan algısına benzerlik gösteren yöntemler göze çarpmaktadır. MFCC, Doğrusal Öngörülü Kodlama (LPC), Algısal Doğrusal Öngörü (PLP) bunlardan bazılarıdır [7]. Bu yöntemler arasında yaygın kullanılan MFC temelinde, insan kulağının 1kHz'e kadar lineer 1kHz'den sonrasında logaritmik ses algısına sahip olmasını esas almaktadır [8]. MFC katsayılarının elde edilmesinde aşağıdaki adımlar izlenir.

1) *Ön Vurgulama*: Konuşma spektrumunu düzleştirmek için, spektral analiz öncesinde bir ön-vurgu filtresi kullanılır. Bunun sonucunda, insan ses üretim mekanizması sırasında bastırılan konuşma sinyalinin yüksek frekanslı kısmı telafi edilmektedir [9]. Ön vurgulama Denklem (1) ile gerçekleştirilir. Burada X sinyali, Y ön vurgulanmış sinyali, α ön vurgulama katsayısını belirtir:

$$Y[n]=[n]-\alpha*X[n-1] \quad (1)$$

2) *Çerçeveleme*: Ses sinyalinin çerçevelere bölünme işlemidir. Sabit genişlikteki çerçeve kaydırması yapılarak tüm sinyalden çerçeveler elde edilir. Her bir çerçeve bir önceki çerçevenin bir kısmını içermektedir. Bu örtüşmedeki amaç çerçeveler arasındaki sürekliliği sağlamaktır.

3) *Pencereleme*: Frekans uzayına geçmeden önce her bir çerçeveye pencereleme işlemi uygulanır. Pencerelemenin amacı frekans uzayındaki temsilin daha kesin olmasını sağlamaktır. Pencereleme için genellikle Denklem (2)'deki Hamming penceresi (w) tercih edilmektedir. Sıklıkla α değeri 0.46 olarak alınır.

$$w[n] = (1 - \alpha) - \alpha * \cos\left(\frac{2\pi n}{N-1}\right), \quad 0 \leq n \leq N - 1 \quad (2)$$

4) *FFT Spektrum*: Bilginin sinyal oluşturan sinüzoidlerde kodlanması çok yaygındır. Örneğin, konuşma, insan ses tellerinin titreşiminin bir sonucudur. Burada zaman ve dalga formunun şekli önemli değildir; anahtar bilgi, bileşen sinüzoidlerinin frekansı, fazı ve amplitüdündedir [10]. Bu aşamada frekans uzayına geçmek için pencerelere FFT (Fast Fourier Transform) işlemi uygulanır.

5) *Mel Spektrum*: Mel spektrumunun elde edilmesi için üçgen Mel filtre bankası oluşturulur. Filtre bankası Mel ölçeğinin sabit aralıkları ile kurulduğundan normal frekans ölçeğinde kaymış şekilde gözlemlenir. Üçgen geçişli filtreler büyüklük spektrumunun pürüzsüzleştirilmesi ve elde edilecek özniteliklerin azaltılması için kullanılır [9].

6) *Mel Kepstrum*: Bu işlem DCT (Discrete Cosine Transform) kullanılarak yapılır. Bu sayede frekans bölgesinden zaman bölgesine geçilir.

$$C_m = \sum_{k=1}^N \cos[m * (k - 0.5) * \pi / N] * E_k, \quad m = 1, 2, \dots, L \quad (3)$$

Burada L MFCC sayısını, N üçgen filtre sayısını, E_k logaritmik enerji değerlerini gösterir.

3.2. Sınıflandırma

Ses özneteliklerinin sınıflandırılmasında sıklıkla HMM, VQ ve DNN kullanılmaktadır [7, 11, 12]. Yapay sinir ağlarında yapı taşı nöronlardır. Nöronlar birleşerek katmanları katmanlar birleşerek ağı oluşturur. Genelde girişler yapıyı bozmaması istenerek katman olarak isimlendirilir. Gizli katmandan başlamak üzere her bir katmandaki nöronun giriş sayısı kadar ağırlığı olur. Girişlerden uygulanan değerler bu ağırlıklar ile çarpılarak toplanır. Nöron çıkışı ise aktivasyon fonksiyonu ile belirlenir.

Eğitim aşamasında, girdilerin yanlış sonuç vermesi durumlarında bir hata miktarı hesaplaması yapılır. Her hatada ağırlıklar ilgili nöronlar için güncellenir. Genel olarak kullanılan hata fonksiyonu Denklem (4)'deki gibidir. Denklem 4 ve 5'de d_0 beklenen nöron çıkış değerini, c_0 hesaplanan nöron çıkış değerini verir.

$$E = \frac{1}{2}(d_0 - c_0)^2 \quad (4)$$

Çok katmanlı ağların eğitimi için literatürde sıklıkla kullanılan bir yöntem hatanın geri yayılımı algoritmasıdır. Burada her nöron için bir delta değeri, δ hesaplanır. Güncellemeler bu değerler ve öğrenme katsayıları hesaba katılarak gerçekleştirilir. Denklem (5) çıkış katmandaki, Denklem (6) gizli katmandaki bir nöron için delta değerini gösterir. Denklem 5'de $f'(net)$ ilgili nöron için belirlenen aktivasyon fonksiyonunun giriş değeri net noktasındaki türev değeridir. Denklem 6'da m delta değeri bulunacak nöronu, n bu nörona bağlı bulunan bir sonraki katmandaki nöronları ifade eder. n ise sonraki katmandaki nöronların sayısıdır [13].


$$\delta = (d_0 - c_0) * f'(net) \quad (5)$$

$$\delta_m = f'_m(net_m) \sum_{n=0}^N \delta_n w_{nm} \quad (6)$$

Ağırlık güncellemeleri yapılırken öğrenme sabiti ve delta değerleri dikkate alınır. Bir iyileştirme olarak da türevlerden hesaplanan momentum değerleri değişimlerin izini sürerek sonuca daha hızlı ulaşmak amacıyla kullanılır.

3.3. Gürültü Azaltma

Gürültü azaltmada en bilindik tekniklerden birisi spektral çıkarmadır. Bu yöntemde gürültüsü azaltılmak istenen ses %50 oranında iç içe geçmiş çerçevelere bölünerek FFT sonuçları alınır. Frekans spektrumu üzerinden gürültülü kısımlar için bir ön istatistik çıkarılır. Bu bilgiler kullanılarak spektrumda gürültüye sebep olan frekanslar bir medyan filtresi ile bastırılır. Daha sonra ise ters FFT (IFFT) işlemi yapılarak zamansal uzaya geçilir. Sinyal, örtüşme eklemesi yöntemi ile tekrar inşa edilir. Pencereleme işlemi girişte uygulanıp çıkışta uygulanmayabilir veya her iki tarafta da uygulanabilir. Tüm bu seçenekler frekans bileşenleri değişmiş sesi tekrar inşa ederken kopmaların engellenmesini sağlar. Son aşamada ise örtüşmeye sahip olan çerçeveler uygun şekilde birbirlerinin devamına eklenir. Gürültü azaltma için kullanılacak bu aşamalar Şekil 1'deki gibi özetlenebilir.



Şekil 1. Gürültü azaltma adımları

4. Bulgular

4.1. Veri Setlerinin Oluşturulması

Eğitim seti, 6 satranç figürüne ait seslendirmelerden oluşturulmuştur. Yaklaşık 30 insandan sessiz ortamlarda alınan 460 seslendirme 500ms uzunluklarda senkron edilerek kullanılmıştır. Kayıtlara ait detaylar Tablo 1'deki gibidir. Bu set %60 eğitim, %20 test, %20 doğrulama şeklinde bölünmüştür.


Tablo 1. Veri setlerine ait detaylar.

Veri seti	1
Konuşmacı	30 Erkek ve Kadın
Örnekleme (Hz)	41000
Kayıt	PCM, Wav, 16bit, 1 kanal
Uzunluk	500ms
Veri türleri	Satranç taşlarının isimlerine ait sesler
Eğitim örneği	276 adet
Doğrulama örneği	92 adet
Test örneği	92 adet
Toplam örnek	460 adet

Test setine daha sonradan kalabalık bir ortamdan alınan sesler rastgele eklenerek gürültülü sesler elde edilmiştir. Bu sesler üzerinde gürültü azaltma algoritması uygulanmıştır.

4.2. Gürültü Azaltma

Veri setindeki test örnekleri üzerine eklenen dış sesler gürültü azaltma algoritması kullanılarak bastırılmıştır. Örnek olarak Şekil 2a’da spektrogramı verilen “at” seslendirmesine eklenen gürültü ile oluşturulan kaydın, ilk 500ms’i içerisinde alınan gürültü profili ile algoritma sonuçları gösterilmiştir. Gözlenebileceği gibi gürültülü ortamın gürültü profili alındığında sınıflandırmanın başarısını artırabilecek daha temiz öznitelikler elde etmek mümkün hale gelmektedir.



Şekil 2. Ses görüntüsü- Spektrogramlar.

(a) Soldan sağa sırası ile orijinal “at” seslendirmesi, gürültülü ve filtrelenmiş hallerinin spektrogramı, (b) Satırlarda sırası ile at, fil, kale, piyon, şah, vezir kelimelerinin farklı insanlardan alınan seslendirmelerine ait spektrogram resimleri.

4.3. Özniteliklerin Çıkarılması

Tablo 1’deki veri setlerinden 14 adet MFCC, enerji ve sıfır geçiş özniteliği hesaplanmıştır. Veri seti oluşturulurken kullanılan MFCC parametreleri Tablo 2’deki gibidir. Kullanılan Mel filtreleri ile oluşturulan spektrogramlar resim olarak da kaydedilerek piksel tabanlı öznitelik setleri oluşturulmuştur. Bu ses görüntülerinin bazıları Şekil 2b’de gösterilmiştir.

Tablo 2. MFCC hesabında kullanılan parametreler.


MFCC Parametreleri	
Ön-vurgu katsayısı	0,97
Çerçeve uzunluğu	25 (ms)
Çerçeve adım uzunluğu	10 (ms)
Pencere Fonksiyonu	Hamming
Filtre sayısı	40
Toplam Öznitelik	14

Eğitim

Çalışmada eğitim için çok katmanlı perceptron ağı kullanılmıştır. Ağın topolojisi için öncelikle ağın girdisini belirlemek gerekir. Çerçevelerin uzunluğu ve adım uzunluğu bilindiğinde bir ses örneğinden kaç adet çerçeve elde edileceği Denklem (7) ile belirlenebilir.

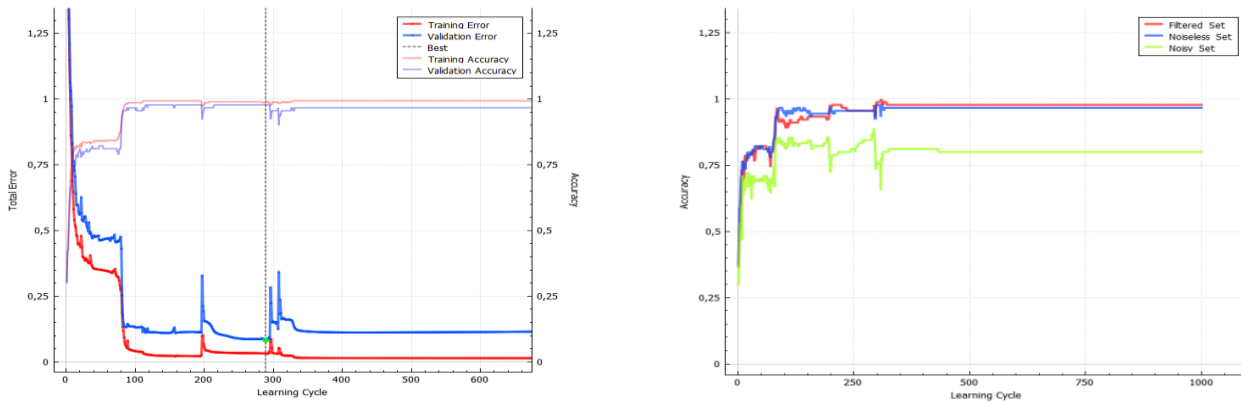
$$f(L_S, L_F, L_{F_s}) = \frac{(L_S - L_F)}{L_{F_s}} + 1 \quad (7)$$

Denklem (7)'de L_S örnek uzunluğu, L_F çerçeve uzunluğu, L_{F_s} çerçeve boşluğu ya da adım uzunluğudur. Buna göre 500ms uzunluk için elde edilecek çerçeve sayısı 48'dir. Bu sebeple 14 öznitelik için kurulacak olan ağın girişi 672 boyutunda olmalıdır. Eğitim için giriş katmandaki nöron sayısını sabit tutarak ara katman sayısı ve nöron kombinasyonları ile yapılan testlerde 4 katmanlı bir ağın yeterli geldiğine karar verilerek girişte 672, ara katmanlarda 10, çıkışta 6 nöron bulunduran 2 ara katmanlı bir perceptron ağı oluşturulmuştur. 40 Mel filtresi ile oluşturulan 40x48 boyutlarında spektrogram resimleri için giriş sayısı 1920 olan aynı ağ topolojisinde farklı bir ağ daha inşa edilmiştir. Oluşturulan ağların eğitiminde kullanılan parametreler: *Maksimum döngü 1000*, *Maksimum hata 0.00001*, *Öğrenme sabiti 0.01*, *Momentum katsayısı 0.01* olarak belirlenmiştir. Bu parametrelerle yapılan eğitime ait hata grafiği Şekil 3'te yer almaktadır.



Şekil 3. MFCC özniteliklerine ait toplam hata ve eğitim grafiği.

Spektrogram resimleri kullanılması ayırık kosinüs dönüşümünde kaybedilen verileri telafi etmek açısından mantıklı olsa da öznitelik sayısının artması ve verilerin dağınık kalması ayrıca veri setinin yetersiz büyüklükte oluşu nedeni ile perceptron eğitimini zorlaştırır. Bu etki eğitimlerde net olarak gözlenebilmektedir. Eğitim grafikleri Şekil 4'de gösterilmiştir.



Şekil 4. Spektrogram özniteliklerine ait toplam hata ve eğitim grafiği.

4.4. Öznitelik Tespiti İçin Yeni Bir Algoritma

Eđitimi tamamlanan ađ, 500 ms uzunluđunda test örneklerini kolayca sınıflandırabilirken bu uzunluđu aşan kayıtlarda kullanmak için uygun deđildir. Bu amaçla çalışmada ařađıdaki şekilde bir yaklařım kullanılmıřtır. Toplam çerçeve sayısı \mathcal{C} , bir çerçeveden çıkarılan öznitelik sayısı T , ađın giriř sayısı G ile gösterilsin. Tüm çerçevelerden çıkarılan öznitelikler D , sonuçlar ise R dizisinde tutulsun. Kayma miktarı S ile gösterilsin. (T 'nin katı olan kayma miktarı amaca göre ayarlanabilir.)

- ❖ *Örnek için çerçeveleri ve öznitelikleri çıkar. D içinde sakla, $k \leftarrow 0$*
- ❖ *$k < \mathcal{C} * T$ iken tekrar et,*
 - *$D + k$ 'dan $D + k + G$ kadar öznitelik al ve enerjileri topla.*
 - *Alunan öznitelikleri ađa verip en büyük nöron tepkisini al.*
 - *Enerji toplamını ve nöron sonucunu R içine at.*
 - *$k \leftarrow k + S$*
- ❖ *R içindeki veriyi enerjiye göre sırala.*
- ❖ *Belirli bir eřik üzerindeki enerjilerden en fazla tekrar edeni sonuç olarak ver.*

5. Sonuçlar ve Öneriler.

MFCC öznitelikleri kullanılarak yapılan eğitimde Şekil 4'te eğitim grafiđi bulunan ađın 92 ses kaydı üzerindeki dođru sınıflandırma başarısı %100'dür. Gürültü eklenmiř kayıtlar üzerindeki başarı %94, filtrelenmiř kayıtlardaki başarı ise %98'dir. Diđer yandan mel filtrelerinin oluřturduđu spektrogram öznitelikleri ile eğitilen ađın (Şekil 4) başarısı gürültülü setlerde %85'e kadar inmiřken filtrelenmiř kayıtlarda %98'e kadar çıkabilmiřtir. Bu iki öznitelik birlikte kullanılarak sistemin başarısı %99 olarak elde edilmiřtir. Mel-Spektrogramlarına ait görüntülerin satranç figür seslendirmelerinin tanınması için kullanılması yeni bir fikirdir. Bu çalışmada bu özniteliklerle yapılan eğitimde çok katmanlı perceptron ađı kullanılmıřtır. Piksel deđerleri bir işleme tabii tutulmadan direkt olarak ađa verilmiřtir. Kullanılan ađ CNN olarak deđiřtirildiđinde piksellerden alınacak bilgi güçlendirilerek gürültülü ortamlarda sonuçlar daha da iyileřtirilebilir.

Referanslar

- [1] <https://www.chess.com/terms/blindfold-chess> (son eriřim 27.05.2022)
- [2] Shuo, Wang, et al. Speech Recognition Based Blind Chess Education System Chinese Chess as an Example. 2021 11th International Conference on Information Technology in Medicine and Education (ITME). IEEE, (2021)
- [3] Ussen K., Buyuk Osman, Turkish Speech Recognition Based On Deep Neural Networks. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi. vol. 22, pp. 10, (2018).
- [4] Ahmed, M. J. "Çađrı merkezleri için derinöđrenme tabanlı interaktif konuřma tanıma." MS Thesis, Selçuk University, Fen Bilimleri Enstitüsü, Konya, Turkey, 2020.
- [5] Kutucu, H., "Derin öđrenme algoritmaları kullanarak bir konuřma tanıma uygulaması." MS Thesis, Sakarya Uygulamalı Bilimler Üniversitesi, Sakarya, Turkey, 2020.
- [6] E. Fakhan, E., "Automatic Speech Recognition System Adaptation For Spoken Lecture Processing." PhD. Thesis, Bođaziçi University, İstanbul, Turkey, 2021.
- [7] NABIYEV, V., YÜCESOY, E., VQ Yöntemiyle Konuřmacı Cinsiyetinin Belirlenmesi, Turkish Journal of Computer and Mathematics Education, vol 1,1 (2009) 35-47
- [8] Stevens, S.S., Volkman, J. ve Newman, E.B. A Scale for the Measurement of the Psychological Magnitude Pitch. The Journal of the Acoustic Society of America, vol. 8, pp. 185-190, (1937)
- [9] Meseguer, N.A., Speech Analysis for Automatic Speech Recognition, Norwegian University of Science and Technology Department of Electronics and Telecommunications, (2009)
- [10] Steven W. Smith, The Scientist and Engineer's Guide to Digital Signal Processing, (1997)
- [11] Réda, A. , Aoued, B., Artificial Neural Network & Mel-Frequency Cepstrum Coefficients Based Speaker Recognition, International Conference: Sciences of Electronic, Technologies of Information and Telecommunications, March 27-31, (2005)
- [12] Das, T. K., Khalid M. O. Nahar, A Voice Identification System using Hidden Markov Model, Indian Journal of Science and Technology, Vol 9(4), (2016).
- [13] Aggarwal, C. C. Neural networks and deep learning. Springer, 10, 978-3, (2018).

Davranışsal Biyometri ve Makine Öğrenmesi Kullanılarak Akıllı Telefon Yetkilendirmesi Üzerine Kısa Bir İnceleme

A Short Review on Smartphone Authorization Using Behavioral Biometrics and Machine Learning

Ensar Arif SAĞBAŞ^{1,*}, Serkan BALLI²

¹ Bilişim Sistemleri Mühendisliği, Muğla Sıtkı Koçman Üniversitesi, Türkiye, arifsagbas@mu.edu.tr

² Yazılım Mühendisliği, Mehmet Akif Ersoy Üniversitesi, Türkiye, serkanballi@mehmetakif.edu.tr

Özet

Herhangi bir güvenlik sisteminin en önemli parçalarından biri kimlik doğrulamadır. Geleneksel metin tabanlı parolalar, farklı türde saldırılara karşı savunmasız olan birçok web sitesi, akıllı telefonlar ve farklı uygulamalarda hala kullanılmaktadır. Günümüzde akıllı telefonlar, gündelik hayatta en popüler ve baskın mobil cihaz haline gelmiştir. Güvenlik her akıllı telefon kullanıcısı için ana sorunlardan biridir. Kimlik doğrulama, gizlilik ve bütünlük, bir akıllı telefonda en çok istenen üç güvenlik özelliğidir. Bu çalışmada davranışsal biyometrik verileri ile akıllı telefon yetkilendirmesi gerçekleştirilen çalışmalar incelenmiştir. Kullanılan veri türleri, makine öğrenmesi yöntemleri, elde edilen sonuçlar karşılaştırmalı bir şekilde tartışılmıştır.

Anahtar Sözcükler: *Davranışsal biyometri; yetkilendirme; akıllı telefon; makine öğrenmesi.*

Abstract

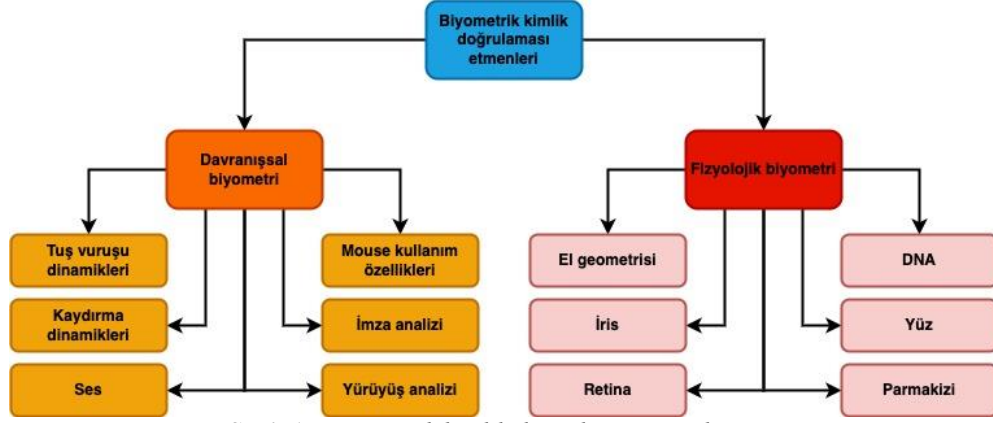
One of the most important parts of any security system is authentication. Traditional text-based passwords are still used in many websites, smartphones, and different applications that are vulnerable to different types of attacks. Today, smartphones have become the most popular and dominant mobile device in daily life. Security is one of the main concerns for every smartphone user. Authentication, privacy, and integrity are the three most demanded security features in a smartphone. In this study, studies that carried out smartphone authorization with behavioral biometrics data were examined. The data types used, machine learning methods, and the results obtained are discussed in a comparative way.

Keywords: *Behavioral biometrics; authorization; smartphone; machine learning.*

1. Giriş

Biyometri kavramı yaşam ve ölçüm kelimelerinden gelmekte olup kişiye ait biyolojik verilerin kullanılması ile bireylerin başkalarından ayrılmasını sağlayan kimlik tanımlama yöntemi olarak adlandırılmaktadır. Biyometrilere, kişilerin fiziksel veya davranışsal özelliklerinin diğer insanlardan ayırt edilmesine olanak sağlayan araçlardır [1]. Biyometrik sistemler, temel olarak fiziksel (pasif) ve davranışsal (aktif) sistemler olmak üzere Şekil 1’de gösterildiği gibi iki gruba ayırmak mümkündür. Fiziksel biyometrik sistemler; parmak izi, el geometrisi, yüz, ses, iris ve retina gibi kişide bulunan ve diğer kişilerden ayrılmasını sağlayan sabit fiziksel özellikler üzerine kurulmuştur. Davranışsal biyometrik sistemler ise; imza, yazma dinamiği, konuşma esnasındaki dudak hareketleri ve yürüyüş şekli gibi belli bir zamanda belli amaçlar için gerçekleştirilmiş ve herkesin birbirinden farklı olarak yaptığı davranışlar olarak sıralanabilir [2].

Davranışsal biyometri, kullanıcı kimlik doğrulama mekanizmaları için ekstra bir güvenlik katmanı sağlamaktadır [3]. En büyük avantajlardan bir tanesi; kopyalanmasının imkânsız olmasıdır. Doğru tanımlamalar ve olumlu sonuçlar için sağlam bir yöntemdir. Ayrıca bu sistemler oldukça güvenlidir ve kullanıcı dostudur. Transferi imkânsız bir anahtar görevi görmektedirler. Biyometrik sistemler aynı zamanda mobil sistemler ile uyumludurlar. Şifre çalınması veya şifre unutulması gibi sorunlar ortadan kalkmaktadır [4].



Şekil 1. Biyometrik kimlik doğrulama etmenleri [5]

Bu çalışmada akıllı telefon yetkilendirmesinde kullanılan yaklaşımlar karşılaştırmalı bir şekilde incelenmiştir. Kullanılan veri türleri, makine öğrenmesi yöntemleri ve geliştirilen sistemin sürekli yetkilendirmeye sahip olup olmama durumları ele alınmıştır. Bu kapsamda bu alanda çalışmaya başlayacak yeni araştırmacılara hızlı bir gözden geçirme imkânı vermektedir.

2. Geçmiş çalışmalar

Barkadehi et al. [6] çeşitli platformlarda farklı türde kimlik doğrulama sistemlerini sınıflandırmıştır. Kullanımları, benzerlikleri, kullanılabilirlikleri, performansları ve dezavantajları tartışılmıştır. Stylios and Thanou [7] davranışsal biyometri kullanarak sürekli kimlik doğrulama konusunda teorik ve pratik yönleri olan kullanıma hazır bir literatür temeli sağlayarak yeni araştırmacılara, bilim insanlarına ve endüstriye yeni sistemler ve teknolojiler geliştirmelerinde yardımcı olmayı amaçlamışlardır. Zhang et al. [8] kimlik doğrulama teknikleri üzerinde etkili olan algoritmik çerçeveyi ve performans endeksini gözden geçirmişlerdir ve Android tabanlı biyometrik doğrulama sistemlerine derinlemesine bir genel bakış sağlamışlardır. Dahia et al. [9] biyometrik doğrulama ve kıyaslamaya fayda sağlayacak internette yeni veri kümelerinin madenciliği potansiyelini ve son zamanlardaki derin öğrenme tekniklerinin alandaki bazı açık zorlukları nasıl ele alabileceğini vurgulamışlardır. Stylios et al. [10] mobil cihazlar için davranışsal biyometri ve sürekli kimlik doğrulama teknolojileri hakkında güncel, kapsamlı ve hedefe yönelik bir anket sunmuşlardır.

3. Metodoloji

Çalışma kapsamında sadece akıllı telefon yetkilendirme sistemleri üzerinde duran bilimsel araştırmalar ele alınmıştır. Ele alınan 16 çalışmadan 10 tanesi sürekli yetkilendirme sağlarken 6 tanesi tek seferlik yetkilendirme gerçekleştirmektedir. Sınıflandırma çalışmaları ele alınırken aşağıdaki ölçütler dikkate alınmıştır.

- Sürekli yetkilendirme durumu
- Kullanılan veri (Algılayıcı kombinasyonu, dokunma vb.)
- Başarı metriği
- Başarı değeri
- Kullanılan makine öğrenmesi yöntemi

İncelenen çalışmalar 4. bölümde sürekli yetkilendirme ve tek seferlik yetkilendirme yaklaşımları bazında ele alınarak açıklanmış ve tablolar ile özetlenmiştir.

4. İnceleme

4.1. Tek seferlik yetkilendirme (Statik mod)

Statik modda, bir öznenin kimliği, bir sisteme ilk erişim anında özne tarafından sağlanan girdiye dayalı olarak doğrulanır. Bu, mobil cihazlarda uygulanan ilk koruma hattı ve en yaygın olarak görülen güvenlik koruma önlemidir. Karakter tabanlı ve rakam tabanlı şifreler, statik modelde en çok kullanılan giriş türleridir [11]. Yüksel et al. [12] akıllı telefon ivmeölçer ve jiroskop algılayıcıları ile kullanıcıların kimlik doğrulaması için telefon tutma ve yazma davranışlarını incelemiştir. Zhu et al. [13] mevcut yöntemlerin eksikliklerine dayanan karmaşık gerçek

dünya mobil kimlik doğrulaması için karma bir derin öğrenme sistemi önermiştir. Zheng et al. [14] kimlik doğrulayan bir kullanıcının akıllı telefonun gerçek sahibi mi yoksa şifreyi bilen başka biri mi olduğunu tespit etmek için bir kullanıcı doğrulama mekanizması önermiştir. Tse and Hung [5] dokunmatik ekranlı mobil cihazlar için şifre, tuş vuruşu dinamikleri ve kaydırma dinamiklerinin bir kombinasyonunu kullanan bir kimlik doğrulama şeması sunmuştur. Shen et al. [15] akıllı telefonlarda kullanıcı kimlik doğrulaması için hareket sensörü davranış verilerini kullanmanın fizibilitesini ve uygulanabilirliğini araştırmıştır. Buriro et al. [16] bir davranışsal biyometri tabanlı akıllı telefon kullanıcı kimlik doğrulama mekanizması sunmuştur. Bu çalışmalar Tablo 1’de karşılaştırmalı olarak özetlenmiştir.

Tablo 1. Tek seferlik yetkilendirme çalışmaları özeti

Yazar	Yıl	Veri	Metrik	Değer	Yöntem
Buriro et al.	2019	İvmeölçer, Jiroskop, Manyetometre, Yer çekimi, Dokunmatik ekran	True Acceptance Rate (TAR)	%99.35	Random Forest
Tse and Hung	2019	Tuş vuruş dinamikleri, Dokunmatik ekran için kaydırma dinamikleri	Doğruluk oranı	%94.05	LDA
Shen et al.	2016	İvmeölçer, Jiroskop	False Acceptance Rate (FAR) False Rejection Rate (FRR)	%3.92 %4.97	Support Vector Machines (SVM)
Zhu et al.	2020	İvmeölçer, Yer çekimi	Doğruluk oranı	%95.01	CNN+SVM
Zheng et al.	2014	Ekrana dokunma verileri, İvmeölçer	Equal Error Rate (EER)	%3.65	Decision Maker
Yuksel et al.	2019	İvmeölçer, Jiroskop	Doğruluk oranı	%100	kNN

4.2. Sürekli yetkilendirme (Dinamik mod)

Dinamik modda, bir mobil cihazın aktif oturumu boyunca bir öznenin kimliği sürekli olarak doğrulanır. Dinamik modunda dağıtılan bir kimlik doğrulama, bir öznenin mobil cihazı başka biri tarafından kullanıldığında tanınmayan dokunma dinamiği modellerini algılayabilir. Tanınmayan herhangi bir dokunma dinamiği modeli algılandığında, hassas uygulamaya kısıtlama getirilebilir ve/veya ek yeniden kimlik doğrulama talebi tetiklenebilir [11]. Acien et al. [17] akıllı telefonda elde ettikleri veriler ile dokunma hareketlerine dayalı bir biyometrik kimlik doğrulama sistemini değerlendirmiştir. Acien et al. [18] dokunma hareketleri ve tuş vuruşu gibi dokunma dinamikleri, ivmeölçer, jiroskop, WiFi, konumu ve uygulama kullanımı bilgilerinin tümünü kullanıcıların kimliğini doğrulamak amacı ile kullanmıştır. Lu et al. [19] kullanıcı kimlik doğrulaması için akıllı telefonlarda dudak okuma tabanlı bir kullanıcı kimlik doğrulama sistemini önermiştir. Yang et al. [20] mobil uygulamalar için dokunmaya dayalı davranışsal biyometri kullanan bir sürekli kimlik doğrulama yöntemi olan BehaveSense’i önermiştir. Incel et al. [21] bir mobil bankacılık uygulamasında belirli bir performansla davranışsal biyometri aracılığıyla kullanıcıları sürekli olarak doğrulamanın mümkün olup olmadığını araştırmıştır. Abuhamad et al. [22] akıllı telefonlardaki sensörlerden yararlanan, derin öğrenmeye dayalı bir aktif kimlik doğrulama yaklaşımı önermiştir. Feng et al. [23] mobil cihazlarda yeni bir dokunmatik ekran tabanlı kimlik doğrulama yaklaşımı sunmuştur. Lu and Liu [24] ekrandaki parmak hareketlerine dayalı akıllı telefon kullanıcı kimlik doğrulama sistemi önermiştir. Xu et al. [25] birden fazla dokunmatik veri türünün nasıl modelleneceğini ve buna göre sürekli kimlik doğrulamanın nasıl gerçekleştirileceğini incelemiştir. Ramadan et al. [26] farklı kullanıcıların farklı dokunma desenleri sergilediklerini göstermişlerdir. Bu çalışmalar Tablo 2’de karşılaştırmalı olarak özetlenmiştir.

Tablo 2. Sürekli yetkilendirme çalışmaları özeti

Yazar	Yıl	Veri	Metrik	Değer	Yöntem
Yang et al.	2019	Dokunmatik işlemler	Doğruluk oranı	%95.85	Expectedprob
Acien et al.	2019	Dokunmatik işlemler, İvmeölçer, Jiroskop, WiFi, GPS, Uygulama kullanımı	Doğruluk oranı	%82.2-%97.1	SVM
Abuhamad et al.	2020	İvmeölçer, Jiroskop, Manyetometre, Ekrana dokunma dinamikleri	F1-Score	%98	LSTM
Feng et al.	2012	Ekrana dokunma verileri	False Acceptance Rate (FAR)	%4.66	BayesNet
İncel et al.	2021	Dokunmatik ekran, İvmeölçer, Jiroskop, Manyetometre	Equal Error Rate (EER)	%3.5	SVM
Lu et al.	2019	Ses	Doğruluk oranı	%90.2	SVM
Lu and Liu	2015	Dokunmatik ekran parmak hareketleri	False Acceptance Rate (FAR) False Rejection Rate (FRR)	%0.03 %0.05	SVM
Acien et al.	2020	Dokunmatik ekran verileri	Equal Error Rate (EER)	%13	Recurrent Neuronal Network
Xu et al.	2014	Dokunmatik ekran verileri	Average Error Rate	<%1	SVM
Ramadan et al.	2017	Dokunmatik ekran verileri	Doğruluk oranı	%90-%94	YSA

4. Sonuç

Bu çalışma, akıllı telefonlar için gerçekleştirilen yetkilendirme çalışmalarını kısaca incelemektedir. Bu kapsamda ele alınan 16 çalışmadan 10'u sürekli, 6'sı ise tek seferlik yetkilendirme üzerinedir. Yapılan çalışmalarda kimliklerin tespit edilebilmesi için makine öğrenmesi yöntemlerinden faydalanılmıştır. Sınıflandırma performansları; doğruluk oranı, FAR, FRR, TAR, EER gibi çeşitli metrikler kullanılarak değerlendirilmiştir. Ele alınan çalışmalarda SVM yönteminin bu alanda sıklıkla kullanıldığı ve başarılı sonuçlar elde edildiği görülmektedir. Bununla birlikte çalışmaların çoğunda ekrana dokunma bilgilerinin yanında hareket algılayıcılarından faydalanılmıştır. Elde edilen bulgular davranışsal biyometri verilerinin akıllı telefon yetkilendirmesinde başarılı sonuçlar sergilediğini göstermektedir.

Referanslar

- [1] F. Evliyaoğlu, "The Success of Biometric Identification Techniques for Preventing Healthcare Abuse". Sosyal Güvençe, vol. 8, pp. 96-118, 2015.
- [2] R. Şamlı, & M.E. Yüksel, "Biometric Security Systems". Academic Computing, pp. 683-689, 2009.
- [3] M. Antal, & N. Fejér, "Mouse dynamics based user recognition using deep learning". Acta Universitatis Sapientiae, Informatica, vol. 12, no. 1, pp. 39-50, 2020.
- [4] Perkotek, Biyometrik tanıma sistemleri nedir?, <https://www.perkotek.com/biyometrik-tanima-sistemleri-nedir>, Accessed 15.03.2021
- [5] K.W. Tse, & K. Hung, "Behavioral biometrics scheme with keystroke and swipe dynamics for user authentication on mobile platform. In 2019 IEEE 9th Symposium on Computer Applications & Industrial Electronics (ISCAIE), '04, 2019, pp. 125-130.
- [6] M. Barkadehi, M. Nilashi, O. Ibrahim, A.Z. Fardi, & S. Samad, "Authentication systems: A literature review and classification". Telematics and Informatics, vol. 35, no. 5, pp. 1491-1511, 2018
- [7] I. Stylios, O. Thanou, I. Androulidakis, & E. Zaitseva, "A review of continuous authentication using behavioral biometrics". South-East European Design Automation, Computer Engineering, Computer Networks and Social Media Conference, '09, 2016, pp 72-79.
- [8] X. Zhang, T. He, & X. Xu, "Android-based smartphone authentication system using biometric techniques: A review". In 2019 4th International Conference on Control, Robotics and Cybernetics (CRC), '09, 2019, pp. 104-108.
- [9] G. Dahia, L. Jesus, & M. Pamplona Segundo, "Continuous authentication using biometrics: An advanced review". Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, vol. 10, no. 4, e1365, 2020
- [10] I. Stylios, S. Kokolakis, O. Thanou, & S. Chatzis, "Behavioral biometrics & continuous user authentication on mobile devices: A survey". Information Fusion, vol. 66, pp. 76-99, 2021.
- [11] P. S., Teh, N., Zhang, A. B. J., Teoh, & K. Chen. "A survey on touch dynamics authentication in mobile devices". Computers & Security, 59, pp. 210-235, 2016.
- [12] A.S. Yuksel, F.A. Senel, & I.A. Cankaya, "Classification of soft keyboard typing behaviors using Mobile device sensors with machine learning". Arabian Journal for Science and Engineering, vol. 44, no. 4, pp. 3929-3942, 2019.
- [13] T. Zhu, Z. Weng, G. Chen, & L. Fu, "A hybrid deep learning system for real-world mobile user authentication using motion sensors". Sensors, vol. 20, no. 14, 3876, 2020.
- [14] N. Zheng, K. Bai, H. Huang, & H. Wang, "You are how you touch: User verification on smartphones via tapping behaviors". In 2014 IEEE 22nd International Conference on Network Protocols, '10, 2014, pp. 221-232.
- [15] C. Shen, T. Yu, S. Yuan, Y. Li, & X. Guan, "Performance analysis of motion-sensor behavior for user authentication on smartphones". Sensors, vol. 16, no. 3, pp. 345, 2016.
- [16] A. Buriro, B. Crispo, & M. Conti, "AnswerAuth: A bimodal behavioral biometric-based user authentication scheme for smartphones". Journal of information security and applications, vol. 44, pp. 89-103, 2019.
- [17] A. Acien, A. Morales, R. Vera-Rodriguez, & J. Fierrez, "Smartphone sensors for modeling human-computer interaction: General outlook and research datasets for user authentication". In 2020 IEEE 44th Annual Computers, Software, and Applications Conference (COMPSAC), '07, 2020, pp. 1273-1278.
- [18] A. Acien, A. Morales, R. Vera-Rodriguez, J. Fierrez, & R. Tolosana, "Multilock: Mobile active authentication based on multiple biometric and behavioral patterns". In 1st International Workshop on Multimodal Understanding and Learning for Embodied Applications, '10, 2019, pp. 53-59.
- [19] L. Lu, J. Yu, Y. Chen, H. Liu, Y. Zhu, L. Kong, & M. Li, "Lip reading-based user authentication through acoustic sensing on smartphones". IEEE/ACM Transactions on Networking, vol. 27, no. 1, pp. 447-460, 2019.
- [20] Y. Yang, B. Guo, Z. Wang, M. Li, Z. Yu, & X. Zhou, "BehaveSense: Continuous authentication for security-sensitive mobile apps using behavioral biometrics". Ad Hoc Networks, vol. 84, pp. 9-18, 2019.
- [21] Ö. Incel, S. Günay, Y. Akan, Y. Barlas, O.E. Basar, G.I. Alptekin, & M. Isbilen, "DAKOTA: Sensor and Touch Screen-Based Continuous Authentication on a Mobile Banking Application". IEEE Access, vol. 9, pp. 38943-38960, 2021.
- [22] M. Abuhamad, T. Abuhmed, D. Mohaisen, & D. Nyang, "AUToSen: Deep-learning-based implicit continuous authentication using smartphone sensors". IEEE Internet of Things Journal, vol. 7, no. 6, pp. 5008-5020, 2020.
- [23] T. Feng, Z. Liu, K.A. Kwon, W. Shi, B. Carbanar, Y. Jiang, & N. Nguyen, "Continuous mobile authentication using touchscreen gestures". In 2012 IEEE conference on technologies for homeland security (HST), '11, 2012, pp. 451-456.
- [24] L. Lu, & Y. Liu, "Safeguard: User reauthentication on smartphones via behavioral biometrics". IEEE Transactions on Computational Social Systems, vol. 2, no. 3, pp. 53-64, 2015.
- [25] H. Xu, Y. Zhou, & M.R. Lyu, "Towards continuous and passive authentication via touch biometrics: An experimental study on smartphones". In 10th Symposium On Usable Privacy and Security, pp. 187-198, 2014.
- [26] A. Ramadan, H. Hemedat, & A. Sarhan, "Touch-input based continuous authentication using gesture-level and session-level features". In 2017 8th IEEE Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON), '10, 2017, pp. 222-229.

Task Activation Latency Characteristics on Real Time System Schedulers

Umut ATAKUL ^{1*}, Mustafa Cem ORHAN ²

¹ TTTech Auto Turkey, umut.atakul@tttech-auto.com

² TTTech Auto Turkey, mustafa-cem.orhan@tttech-auto.com

Abstract

Scheduler in real time systems rely on the underlying timer mechanism. The expiration of these timers may happen later than expected due to the factors which are uncontrollable by scheduler. In this paper, the characteristics of these latency values are investigated. In this study, the predictability of these latency values is analyzed by experimenting with different prediction algorithms. According to the results, the latency introduced by timers can be predicted by modelling past latency values. This prediction can be used to improve the performance of real time system schedulers.

Keywords: ARIMA; LSTM; Prediction; Random Forest Regressor; Real Time Scheduler

1. Introduction

Scheduler in real time systems is responsible for running periodic tasks, whose periods, and execution times are known statically before the system starts. It uses timers to trigger execution of these periodic tasks. These periodic tasks are triggered according to a schedule table which is periodically executed. Scheduler may be implemented in kernel space or user space (Figure 1).

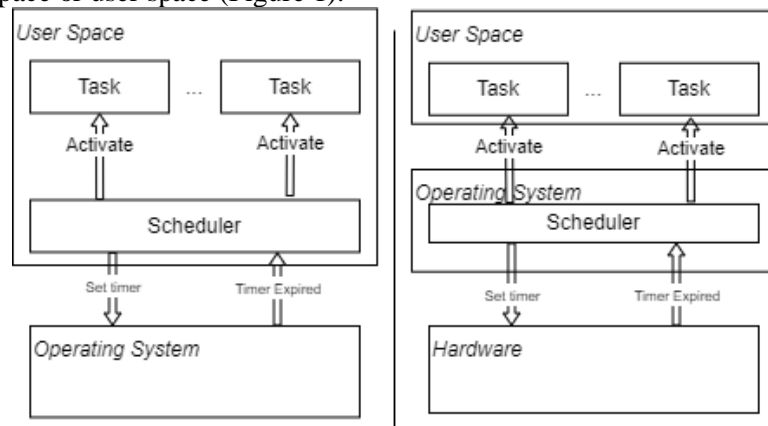


Figure 1. An example of typical scheduler using timers for task activations

Figure 2 shows an example of schedule table which includes execution of tasks A-B-C-B, respectively in its schedule table. This schedule table is executed continuously.




Figure 2. An example of simple task schedule that Scheduler application shall fulfil

In some cases, even if the hardware timer expires on time, some unexpected latency may be introduced by the underlying system (timer server) while notifying the client which expects the timer expiry notification. This latency may be caused by many reasons, such as concurrent interrupt requests or the design of the underlying interrupt handling mechanism. Because of this latency, the scheduler must be designed to compensate this latency.

An example of a problem this latency may cause on the Scheduler is depicted in Figure 3: Suppose that task A is a time triggered task which is activated by scheduler after a timer interrupt and supposed to start at time T1 and finish its execution at T2. Also suppose that there is another time triggered task, task B which is supposed to start execution at time T2. If there is a latency of timer interrupt for time t, the execution of task A may end at T2+t, which may cause a conflict with task B for a duration of t.

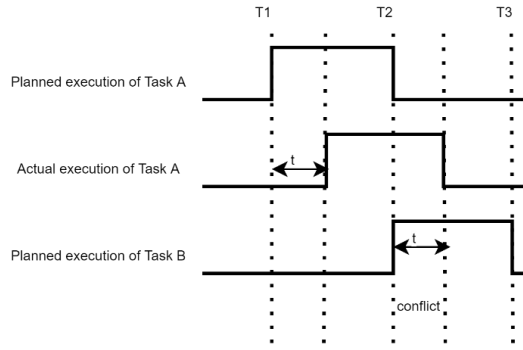


Figure 3. *Temporal conflict caused by task activation latency*

Because of these circumstances with a timer interrupt delay of t , caused by the timer server, the scheduling of tasks is designed to include a buffer of duration t . This duration is an overhead and is not planned to be used by the CPU. Although Task A and Task B take $T3-T1$ of CPU time to complete, the system design should spare an extra duration of t , i.e $T3-T1+t$, to finish execution of these two tasks (Figure 4).

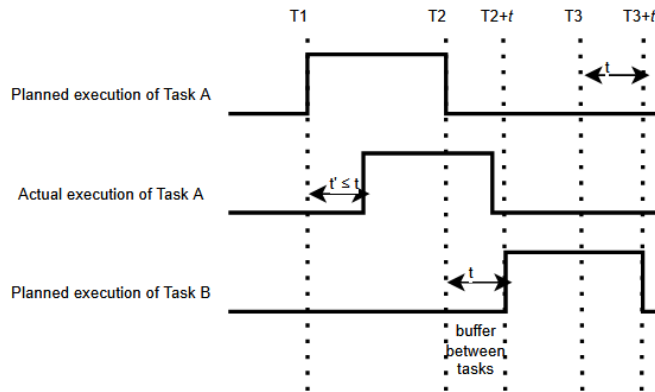


Figure 4. *Spare CPU time which shall be reserved to avoid conflict*

In our work, we investigated the behavior of the execution delay of tasks and analyze their characteristics. In section 2 we analyze the predictability of these values. In section 3 different prediction methods are discussed and compared. We used two different datasets in our analysis: First of them contains 4272 actual task activation latency values taken from a real time system. This dataset will be referred as “latency dataset” in next chapters. The second dataset contains a subset of the first dataset, consisting of 1000 activation latency values. This dataset will be referred as “reduced dataset”.

2. Background

In this study, predictability of Task Activation Latency was investigated. Predictability of a series depends on regularities of the dataset. The more regular and repeatable patterns a series has, the easier it to be forecasted. Therefore, in this section, periodicity features of the dataset analyzed by using Fourier Transform and autocorrelation. Also, to degrade the predictability of the series into a metric, sample entropy (SampEn) which is proposed by Richman and Moorman [1] is calculated for reduced dataset.

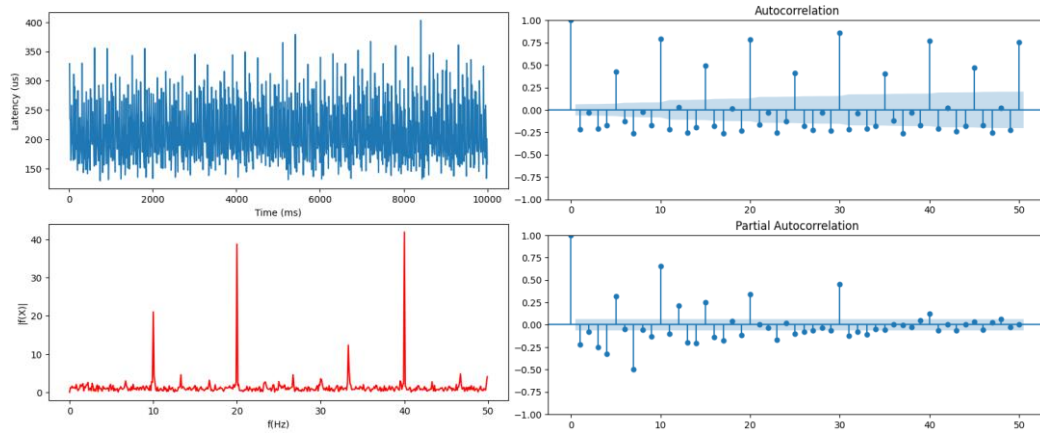


Figure 5. Autocorrelation, Partial autocorrelation, reduced dataset in time domain (top left) and latency dataset in frequency domain (bottom left)

In Figure 5, latency vs time, frequency domain representation with removed DC component, autocorrelation and partial autocorrelation plots are given. In time domain representation, there is no visually recognizable pattern observed. However, frequency domain representation of the series shows that it has dominant harmonics at 10, 20, 33 and 40 Hz. Also, to define relation between the series and its lags, autocorrelation of the series is given in the figure above. There are significantly high spikes each 10 lags in the autocorrelation plots which means that the series is highly correlated with every 10th lag of its own. In addition to the graphical analysis, sample entropy of the series, which is a measurable property associated to randomness, is measured. As the sample entropy decreases, regularity and predictability of the series increases. Since measured sample entropy is 0.405 for reduced dataset, it is possible to make consistent future predictions with appropriate forecasting model.

2.1. ARIMA

ARIMA short for ‘Auto Regressive Integrated Moving Average’ is a forecasting model that analyses any non-seasonal time series based on the series’ own past values (lags) and lagged forecast errors. Therefore, ARIMA equation can be used to predict future values [4]. This model is identified by p, d and q terms which are the AR (Auto Regressive) [5] term, number of differencing and MA (Moving Average) [5] term respectively. By looking at the results of Augmented-Dickey Fuller test, it can be observed that the time series is stationary and no need to difference it. Therefore, d value is chosen as 0. Considering the autocorrelation and partial autocorrelation plots in section 2, p and q terms can be roughly determined as (10, 10). Eqs. (1), (2) and (3) denote AR, MA and ARIMA model respectively [4]:

$$Y_t = \alpha + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \epsilon_t \quad (1)$$

$$Y_t = \alpha + \epsilon_t + \phi_1 \epsilon_{t-1} + \phi_2 \epsilon_{t-2} + \dots + \phi_q \epsilon_{t-q} \quad (2)$$

$$Y_t = \alpha + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} \epsilon_t + \phi_1 \epsilon_{t-1} + \phi_2 \epsilon_{t-2} + \dots + \phi_q \epsilon_{t-q} \quad (3)$$

Where β is the coefficient of corresponding lag, α is the intercept term, ϵ is the lagged forecast error and ϕ is the coefficient of lagged forecast error.

Also, by using auto_arima algorithm, which fits different models and calculates AIC and returns the model that minimizes AIC, more confident results are achieved. However, output of the auto_arima results higher p and q value which yields much more computational complexity during the fitting process.

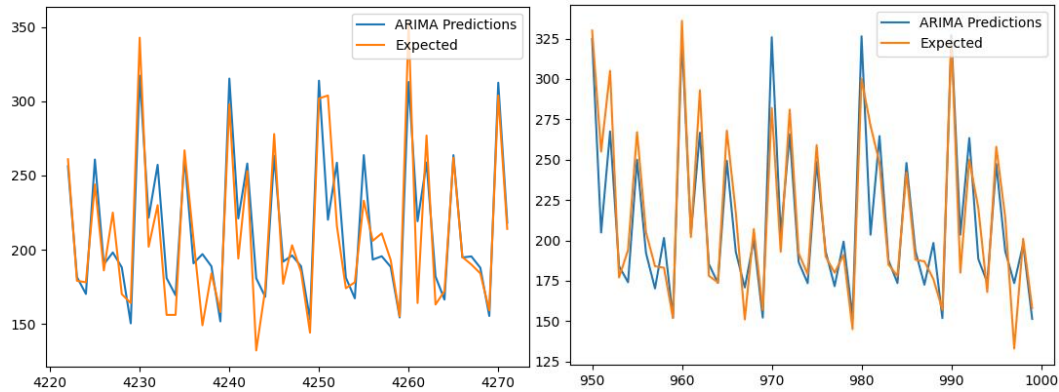


Figure 6. ARIMA prediction plots for latency (left) and reduced dataset (right)

In Figure 6, test datasets and ARIMA predictions are plotted for last 50 samples. Although difference between sizes of datasets is about 3000 samples, prediction accuracies are just slightly different from each other.

It is observed that, time complexity and accuracy of the model increases when p and q values are increased. Therefore, seasonal ARIMA model would be a better to obtain reasonable tradeoff between time complexity and accuracy. Since the series has periodic components as seen in FFT and correlation, seasonal ARIMA model may result in a higher accuracy than the ARIMA model for smaller p and q orders.

2.2. LSTM

LSTM (Long-Short Term Memory) is a widely used recurrent neural network (RNN) structure for time series forecasting published by [3] S. Hochreiter and J. Schmidhuber. LSTM basically memorizes previous outputs and feed the input layer in the training process with a feedback structure. LSTM differs from traditional RNNs by remembering only significant information of previous outputs, which results, gradient doesn't vanish through backpropagation process of training.

According to the size of the datasets, two different LSTM models are created. Structure of the models are given below:

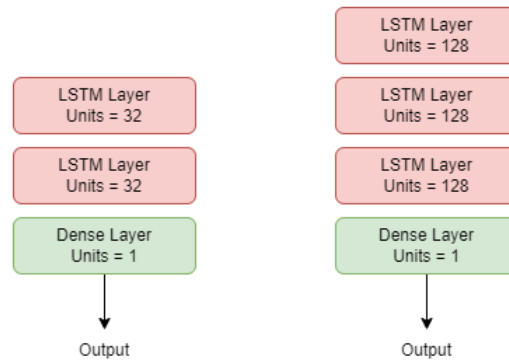


Figure 7. LSTM Network architecture for latency (right) and reduced dataset (left)

In Figure 7, two different LSTM model architectures are shown. The model on the left is trained with a small size of dataset with 'adam' optimizer in 150 epoch and 32 batch size. The model on the right is fed by the latency dataset by using 'adam' optimizer with 50 epochs and 64 batch size.

Through the training of the network, loss function was decreasing very slowly. To solve this problem, learning rate of the optimizer is updated to 0.003 (default learning rate for 'adam' optimizer is 0.001).




Figure 8. LSTM predictions for latency (left) and reduced dataset (right)

In figure 8, plots for predictions and expected values are given. It is clearly seen that the effect of dataset size on the accuracy is much higher in LSTM than ARIMA and Random Forest models.

2.3. Random Forest Regressor

Random forest is an ensemble supervised learning algorithm that combines predictions of multiple decision trees for classification and regression problems proposed by L. Breiman [2]. Each tree is individually trained with a subset of original dataset which are created by bootstrapping technique. Therefore, each decision tree points different feature of input data. However, some trees can be a bad learner that can misguide to the final prediction. To overcome this problem, optimal values of estimators and random state for the random forest model is found out by iterating the model parameters in a range and calculating evaluation metrics (mean absolute percentage error (MAPE) [6] and r2 score. The model that minimizes MAPE and maximizes r2 score is selected as best model.

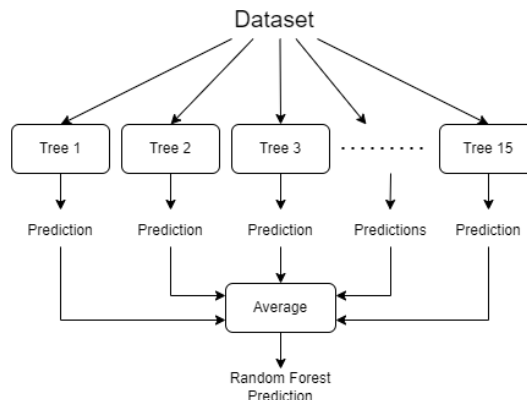


Figure 8. Random forest regressor model

In figure 8, empirically found optimal model is given. According to experiments, model that minimizes MAPE has 15 estimators with random state 16.

Through evaluating the model, walk forward validation method is used to increase accuracy of the regressor. As an advantage of the model beyond the accuracy, training time is much less than the LSTM network and ARIMA method. In the runtime, random forest regression model can be more practical for changing dataset samples over short time intervals.




Figure 9. Random forest predictions for latency (left) and reduced (right) dataset

In figure 9, predictions of random forest models are plotted for 50 samples. Although the size of latency dataset has 3 times more samples, difference between MAPE of the predictions is around 0.6%. Therefore, smaller dataset is enough to train a consistent random forest regressor.

3. Results and Recommendations

<i>Model</i>	<i>latency dataset</i>		<i>reduced dataset</i>	
	<i>MAPE (%)</i>	<i>r2_score</i>	<i>MAPE (%)</i>	<i>r2_score</i>
<i>ARIMA</i>	7.6	0.76	7.0	0.84
<i>Random Forest</i>	7.8	0.83	7.2	0.83
<i>LSTM</i>	6.4	0.89	10.0	0.75

Table 1. Evaluation results for latency and reduced datasets

In the table above, performance of the models for different datasets is summarized. Due to MAPE and *r2_score* results, it can be clearly seen that most accurate model is LSTM which was trained with latency dataset. However, as training and prediction times are one of the primal considerations beside the accuracy, it is impractical to use LSTM model because of long training time. Also, test results show that tradeoff between time complexity and accuracy is more reasonable for Random Forest model compared to the LSTM and ARIMA. Because of high *p* and *q* orders, fitting time for ARIMA is intolerably high to train in runtime. Seasonal ARIMA may have better accuracy for lower *p* and *q* orders.

4. Conclusion

Scheduler in real time systems is responsible for activating tasks periodically. It uses timers to fulfill this job. Some latency caused by many uncontrollable reasons may be introduced by timers. According to the results shared in the previous section, the latency on timer expiry may be predicted by modelling the past values. This modelling can be done statically, and scheduler runtime behavior may be adjusted according to these predicted latency values. Moreover, some prediction methods can be used during runtime of the scheduler to learn from the past values and continuously modify the model, which allows scheduler to be more robust for different runtime conditions.

References

- [1] J. S. Richman and J. R. Moorman, "Physiological time-series analysis using approximate entropy and sample entropy," *American Journal of Physiology-Heart and Circulatory Physiology*, vol. 278, no. 6, 2000.
- [2] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [3] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [4] S. Prabhakaran, "Arima model - complete guide to time series forecasting in python: ML+," *Machine Learning Plus*, 08-Mar-2022. [Online]. Available: <https://www.machinelearningplus.com/time-series/arima-model-time-series-forecasting-python/>. [Accessed: 28-Apr-2022].
- [5] K. W. Hipel, A. I. MacLeod, and A. I. McLeod, *Time series modelling of Water Resources and Environmental Systems*. Amsterdam: Elsevier, 1996.
- [6] A. Botchkarev, "A new typology design of performance metrics to measure errors in machine learning regression algorithms," *Interdisciplinary Journal of Information, Knowledge, and Management*, vol. 14, pp. 045–076, 2019.

Non-destructive Contactless Quality Control in the Agroalimentary Supply Chain

Farid BAGHERI ¹, Derya EREN AKYOL ^{2,*},

¹ Industrial Engineering, Dokuz Eylul University, Turkey, farid.bagheri@ogr.deu.edu.tr

² Industrial Engineering, Dokuz Eylul University, Turkey, derya.eren@deu.edu.tr

Abstract

Currently, there have done lots of studies and efforts to device an algorithm for non-destructive and supply chain spoilage detection so it is critical and essential to have such system nowadays which if done it might result to a profitable and efficient agro-alimentary goods along the supply chain. To satisfy this demand, in this research project we shall provide a computer vision system. In this model we used Image processing techniques and related machine learning algorithm to invent a system that uses pictures of products as input and its output is a computer vision system to categorize the products in supply chain which is considerably less configuration and tuning, making it easier to deploy in real-world applications.

Keywords: *Image Processing; Machine Learning; Quality Control; Supply chain;*

1.Introduction and Literature Review

It is a well-known fact that a fast, without contact ecologically genial, and accurate methods for controlling quality of agro-alimentary products have been the topic of study [1]. Computer vision systems (CVSs) are one of them that utilized to enhance quality control and discrimination during the supply chain period, from gathering the products to markets where consumers buy them. CVS [2] is a technology that merges mechanics, optical equipment, electromagnetic sensing, and digital image processing. Computer vision methods are so popular and their methods have been applied for fruit and vegetable quality control [3]. As stated by several researchers, In [4] survey CVS was manipulated to control the quality and merchandisableness of tomatoes [4], artichokes [5], fresh-cut nectarines [6], fresh-cut lettuce [7], fresh-cut radicchio [8] and rocket leaves [9].

2. Materials and methods

Agro-alimentary items which will be surviving on them are delivered by a farm at the same maturity stage (according to the maturity requirements for agro-alimentary products as we need to achieve global visual quality and assess these visions) and transferred to laboratory. The fertilizer and amount of water and also type of soil in which items are grown is indicated. In this method we can test the sustainability of their cultivation tactics in terms of utilization of vital resources and these resources will be employed as input feature in neural network to identify target value and also get result and vision about resources. At least One hundred held at different temperatures for particular amount of time for computer vision. The period of the time that product stored will be definition for duration of the time and days needed to get the minimum quality level (QL) at each temperature. Thus, storage period, for each product and storage temperature, products are evaluated, in order to assign a QL and we need to define categories that will be consider to

assign each product into special category to estimate some of their internal characteristics that determine nutraceutical and organoleptic properties.




Figure 1. Quality level rating scale (using grape as an example)

Using a Computer vision system (CVS) to get a contactless and non-destructive evaluation of product quality entails many tasks: collection of a data that contain calibrated color pictures tagged with the product's QL; adequate image pre-processing; identification and extraction of color characteristics; training, tweaking, and testing of a Random Forest Classifier and also reinforcement learning. Since, we need to employ reinforcement learning in evaluating different agro-alimentary products it has this power to adjust itself in varied circumstance which may be applied in many agro-alimentary items. For each product, calibrated color photographs will be collected and processed; in total, the data set for each product is made up of particular number of images, formed by capturing each bunch four times in different locations.



Figure 2.The X-Rite color-chart

In the section on feature extraction, suitable characteristics will be extracted from each calibrated photo related to each QL and cultivar. Two sets of characteristics were used: the first was represented by statistical measures assessed throughout the complete foreground on the channels in the CIELAB color space [9], and the second was constructed using a centroid-based color segmentation algorithm [8]. clustering technique was performed on the calibrated color photos This unsupervised machine learning approach creates a dendrogram, which arranges all of the colors into hierarchical groupings based on a distance metric [10].

3.Conclusion

Defect product identification is an urgent and serious issue affecting the health and finances of customers globally. It is obvious from the history of contamination that the methods employed to avoid detection have gotten more sophisticated and complicated and increasingly necessitate the employment of current non-destructive means of determination best. The type of the product and contaminant, as well as the distribution of contamination across samples and within samples, are critical in selecting the most appropriate and successful analytical method. New speedy and precise non-destructive analytical procedures capable of analyzing individual product units are needed and are becoming increasingly crucial. The purpose of this system is to non-destructively assess the quality level of an item. In particular, the proposed methods include new techniques that reduce the human effort and subjectivity required to build the method and maximize its performance. The settings that manage the image processing algorithm are automatically determined using data-driven techniques rather than being specified by an experienced operator. A new approach has been proposed to automatically identify the colormap in the image. This is an important step in analyzing and reducing color measurement inaccuracies.

References:

- [1] Liu, Y., Pu, H., Sun, D.W., 2017. Hyperspectral imaging technique for evaluating food quality and safety during various processes: a review of recent applications. *Trends Food Sci. Technol.* 69, 25–35.
- [2] Patel, K.K., Kar, A., Jha, S.N., Khan, M.A., 2012. Machine vision system: a tool for quality inspection of food and agricultural products. *J. Food Sci. Technol.* 49, 123–141.

- [3] Blasco, J., Munera, S., Aleixos, N., Cubero, S., Moltó, E., 2017. Machine vision-based measurement systems for fruit and vegetable quality control in postharvest. In: Hitzmann, B. (Ed.), *Measurement, Modeling and Automation in Advanced Food Processing*. Advances in Biochemical Engineering/Biotechnology. Springer, Berlin, Heidelberg, Germany, pp. 71–92.
- [4] Arias, R., Lee, T.C., Logendra, L., Janes, H., 2000. Correlation of lycopene measured by HPLC with the L*, a*, b* colour readings of a hydroponic tomato and the relationship of maturity with colour and lycopene content. *J. Agr. Food Chem.* 48, 1697–1702.
- [5] Amodio, M.L., Cabezas-Serrano, A.B., Peri, G., Colelli, G., 2011. Post-cutting quality changes of fresh-cut artichokes treated with different anti-browning agents as evaluated by image analysis. *Postharvest Biol. Technol.* 62, 213–220.
- [6] Pace, B., Cefola, M., Renna, F., Attolico, G., 2011. Relationship between visual appearance and browning as evaluated by image analysis and chemical traits in fresh-cut nectarines. *Postharvest Biol. Technol.* 61 (2), 178–183.
- [7] Pace, B., Cefola, M., Da Pelo, P., Renna, F., Attolico, G., 2014. Non-destructive evaluation of quality and ammonia content in whole and fresh-cut lettuce by computer vision system. *Food Res. Int.* 64, 647–655.
- [8] Pace, B., Cavallo, D.P., Cefola, M., Colella, R., Attolico, G., 2015. Adaptive self-configuring computer vision system for quality evaluation of fresh-cut radicchio. *Innov. Food Sci. Emerg. Technol.* 32, 200–207.
- [9] Cavallo, D.P., Cefola, M., Pace, B., Logrieco, A.F., Attolico, G., 2017. Contactless and nondestructive chlorophyll content prediction by random forest regression: a case study on fresh-cut rocket leaves. *Comput. Electron. Agric.* 140, 303–310.
- [10] Dario Pietro Cavallo 2019, Non-destructive and contactless quality evaluation of table grapes by a computer vision system, *Computers and Electronics in Agriculture* Volume 156, January 2019, Pages 558-564

Meteorolojik Parametrelere Dayalı NARX Yapay Sinir Ağı Kullanarak Yağış Tahmini Precipitation Forecast Using NARX Artificial Neural Network Based On Meteorological Parameters

Serkan ANSAY¹, Bayram KÖSE²

¹ Akıllı Sistemler Mühendisliği, Bakırçay Üniversitesi, Türkiye, serkanansay@gmail.com

² Elektrik – Elektronik Mühendisliği, Bakırçay Üniversitesi, Türkiye, bayram.kose@bakircay.edu.tr

Özet

Günümüzde tatil planlamasından enerji yönetimine, enerji dağıtımından tarımsal sulamaya, hayatın çok çeşitli alanlarında, özellikle yapay zeka uygulamaları ve akıllı sistemlerde yağış tahminine ihtiyaç vardır. Yağış tahminlerinde yapay zeka teknikleri ve istatistiksel yöntemler kullanılmaktadır. Bu çalışmada geçmiş rüzgâr, yağış, nem, sıcaklık verileri kullanılarak Fitting ve NARX (Nonlinear Otoregresif Eksojen) yapay sinir ağı yöntemleriyle yağış tahminleri yapılmıştır. En randımanlı model determinasyon katsayısı ve ortalama kare hata bakımından NARX ağıyla elde edilen model olmuştur.

Anahtar Sözcükler: NARX; yağış tahmini; yapay sinir ağları.

Abstract

Today, there is a need for precipitation forecasting in many areas of life, from holiday planning to energy management, from energy distribution to agricultural irrigation, especially in artificial intelligence applications and smart systems. Artificial intelligence techniques and statistical methods are used in precipitation forecasts. In this study, precipitation predictions were made by using the past wind, precipitation, humidity and temperature data using Fitting and NARX (Nonlinear Autoregressive Exogenous) artificial neural network methods. The most efficient model was the model obtained with the NARX network in terms of coefficient of determination and mean square error.

Keywords: NARX; precipitation forecast; artificial neural networks.

1. Giriş

Yağışın gözlem altında tutulmasıyla su rezervlerinin kontrol altında tutulabilecek, ekolojik dengenin devamını sağlanacaktır. Hidrolojik modelleme kapsamında bu yeterlilikte meteorolojik tahminler önem arz etmektedir. Geçmiş rüzgâr, yağış, nem, sıcaklık gibi verilerin matematiksel işlemlerden geçirilmesiyle oluşacak tahmin modeli sayesinde daha az veriyle daha hızlı ve daha doğru sonuca ulaşmanın yolu açılmış olacaktır[1].

Havacılık, tarım, erken uyarı sistemleri, spor müsabakaları, enerji üretim-planlaması, can-malın korunması, hidroelektrik santrallerinin üretimi, baraj doluluk oranı gibi alanlarda yağış tahmininden faydalanılmaktadır[2]. Bir çalışmada güneş ışınım verisi tahmini için sıcaklık, nem ve yağış verileri girdi olarak alınmış, NARX ağları ile veri setinin daha uzun bir zamanı kapsaması durumunda hatanın ve benzerliklerin artacağı öngörülmüştür[3]. Farklı bir çalışmada NARX sinir ağı modeli ile rüzgar hızı tahmini yapılmıştır. Kullanılan yöntemin yüksek performans gösterdiği, sonraki çalışmalara ışık tutacağı öngörülmüştür[4]. Bir çalışmada ise Venedik Lagünü gelgit seviyesi tahmini NARX yöntemiyle yapılmış, yöntemin tahmin etmede güvenilir olduğu görülmüştür[5].

Literatürde yağış tahmini alanında Yapay Sinir Ağları (YSA) (Fitting app) ile yapılan birçok çalışma olmasına karşın NARX yapay sinir ağları (Time Series app) ile yapılan çalışmalar araştırdığımız kadarıyla nadirdir. Çalışmada Aydın Meteoroloji Müdürlüğünden sağlanan saatlik verilerden boş olan saatler elenmiş, korelasyonu yüksek olanlardan oluşturulan modeller içinden en iyi model elde edilerek yağış tahmini yapılmıştır. Yapılan tahminler performans ölçütlerine bağlı olarak değerlendirilmiştir.

2. Materyal ve Yöntem

2.1. Kullanılan veriler

Çalışmada Aydın Meteoroloji Müdürlüğünden tedarik edilen saatlik verilerin (sıcaklık, nem, rüzgar ve yağış) özet bilgileri ve korelasyon analizleri tabloda verilmiştir.

Tablo 1. Verilerin analizi.

Yıllar	2016	2017	2018	2019	2020	2021
Ortalama Yağış ($mm=kg/m^2$)	1,689	1,537	1,469	1,234	1,367	1,315
En Fazla Yağış ($mm=kg/m^2$)	12,10	44,40	17,90	20,70	17,90	19,00
Standart Sapma (kg/m^2)	2,491	3,039	2,382	1,793	1,793	2,151
Çarpıklık	2,660	7,789	3,638	4,354	3,873	3,922
Basıklık	7,623	94,27	16,59	32,76	25,50	20,80
Toplam Veri Sayısı (Saatlik)	282	1921	1939	2174	1555	1768

Tablo 1 incelendiğinde 2016-2021 yıllarında ortalama yağışın 1,3 – 1,7 mm arasında seyrettiği görülmektedir. Öte yanda ilgili yıllar içinde en çok yağışın 2017 yılında ve en az yağışın 2016 yılında gerçekleştiği görülmektedir. Aşağıdaki denklemlerde \bar{x} ortalamayı, x veri setindeki her bir veriyi, n örneklem boyutunu, s standart sapmayı temsil etmektedir. Denklem (1)' de aritmetik ortalamanın formülü verilmiştir.

$$\bar{x} = \frac{1}{n} \sum x_j \quad (1)$$

Standart sapmanın formülü Denklem (2)' de gösterilmiştir. Tablo 1' de yıllara göre yağış miktarı değerlendirildiğinde 2017' de daha fazla olduğu, 2019 ve 2020' de ortalamaya yakın olduğu anlaşılmaktadır.

$$s = \sqrt{\frac{\sum(x-\bar{x})^2}{n-1}} \quad (2)$$

Çarpıklık, bir dağılımın ortalaması etrafındaki asimetri derecesini belirtir. Pozitif çarpıklık, asimetric ucu daha yüksek pozitif değerlere doğru genişleyen bir çarpıklığı belirtirken negatif çarpıklık, asimetric ucu daha düşük negatif değerlere doğru genişleyen bir dağılımı belirtir. Sıfıra yaklaşan durumda çarpıklığın azaldığından bahsedilebilir. Çarpıklık katsayısı Denklem (3) ile verilmiştir. Tablo 1' de normalliğe en yakın yıl 2016 iken, çarpıklığın en fazla olduğu yılın 2017 olduğu, tüm verilerde pozitif bir çarpıklık olduğu görülebilir.

$$\frac{n}{(n-1)(n-2)} \sum \left(\frac{x_j - \bar{x}}{s} \right)^3 \quad (3)$$

Basıklık, normal dağılıma göre bir dağılımın göreceli dikliğini veya düzlüğünü verir. Pozitif basıklık, dik bir dağılımı belirtirken negatif basıklık düz bir dağılımı belirtir. Basıklık katsayısı Denklem (4)' de verilmiştir. Tablo 1' de pozitif basıklıktan dolayı dik dağılım olduğu, en dik dağılımın 2017' de olduğu görülmektedir.

$$\left\{ \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum \left(\frac{x_j - \bar{x}}{s} \right)^4 \right\} - \frac{3(n-1)^2}{(n-2)(n-3)} \quad (4)$$

2.2. Yapay sinir ağları

Geri yayılım sinir ağının ortaya çıkışı, daha aktif, çabuk öğrenen algoritmalar ile modelleme, öğrenme, benzetim, tanımlama, tahminde bulunma gibi birçok alanda uygulamaların yapıldığı bir model olarak türetilmiştir[9]. Çalışmada veriler Matlab 'Fitting app' ile YSA' ya uygulanarak yağış tahmini yapılmıştır.

YSA' da giriş verileriyle elde edilen ağırlıklı giriş verilerinin transfer fonksiyonu ile toplamları alınır. Ağ değeri aktivasyon fonksiyonunda işleme tâbi tutulur, böylece aktivasyon tamamlanır veriler çıkışa aktarılır.

$$z_i = \sum_{i=1}^n (w_{ij}x_i + b_j) \quad (5)$$

Transfer fonksiyonunda hücreye gelen girdiler Denklem (5)' deki formül ile hesaplanır. n girdilerin sayısını; w ağırlıklarını; x girdilerini ve b eşik değerini temsil etmektedir. Aktivasyon fonksiyonu girdi-çıkı arasında eğrisel eşleşmeyi sağlayarak ağırlık performansını önemli düzeyde etkilemektedir. Hatayı minimumda tutması sebebiyle en çok kullanılan aktivasyon fonksiyonu sigmoid fonksiyonu olup Denklem (6)' de yer almaktadır.


$$f(z_i) = \frac{1}{1+e^{-z_i}} \quad (6)$$

Denklem (5)' de toplam fonksiyonu sonucu elde edilen değer doğrusal olan veya olmayan türevlenebilir bir aktivasyon fonksiyonundan geçirilir ve Denklem (7)' de gösterildiği gibi bir sonuç değer elde edilir[6].

$$y = f(z_i) = f\left(\sum_{i=1}^n (w_{ij}x_i + b_j)\right) \quad (7)$$

2.3. NARX yapay sinir ağı modeli

NARX, klasik geri beslemeli ağ yapılarına kıyasla daha hızlı, etkili bir performans sergiler[7]. Girdiler arasındaki bağlantıların optimal ağırlıklarına ulaşmada daha hızlı yakınsaması, diğer YSA' lara göre daha etkili olması sebebiyle bu çalışmada tercih edilmiştir[8], [9]. Çok katmanlı geri beslemeli, ileri hesaplamalı dinamik bir YSA' dır. NARX' te yer alan "X" eksojen, dışsal değişkenlerin modele dahil edilebilmesini ifade eder[10]. Model Şekil 1' de gösterilmiştir, giriş katmanında geçmiş yağış verileri (y(t)) ile sıcaklık, nem ve yağış verileri (x(t)) ayrı ayrı giriş olarak kullanılmıştır. Ara katmanda belirlenen nöron sayısı ile çalışan sigmoid fonksiyonuna ek olarak, belirlenen öteleme miktarı kadar parametre değeri ötelenerek eğitime dahil edilir.



Şekil 1. NARX modeli ve iç yapısı.

Denklem (8)' de zaman serisi t . değeri daha önce zaman serisinde bulunan p tane değer bir fonksiyonu olarak işleme dahil olmaktadır. Burada ε_t epsilon t anındaki model hatasını ifade etmektedir.

$$y_t = f(y_{t-1}, \dots, y_{t-p}) + \varepsilon_t \quad (8)$$

Denklem (9)' da zaman serisi t . değerine ait bir hesaplama yapılmakta, nöronlar arası ağırlık değerleri w_j ve v_{ij} , gizli katmanda nöron sayısı p ve gizli katman aktivasyon fonksiyonu f ile gösterilmektedir.

$$y_t = w_0 + \sum_{j=1}^p w_j f(v_{0j} + \sum_{i=1}^n v_{ij} y_{t-1}) + \varepsilon_t \quad (9)$$

2.4. Performans kriterleri

2.4.1. Ortalama kare hata (OKH)

Hata değerlerinin büyüklüklerinin benzer olduğu durumlarda kullanılan bir ölçütdür. MSE (Mean Squared Error) olarak da bilinir. Denklem (10)' da gerçek çıkış ($y_{i(gerçek)}$), beklenen çıkış ($y_{i(tahmin)}$) ' dir[11], [12].

$$MSE = OKH = \frac{1}{N} \sum_{i=1}^N (y_{i(tahmin)} - y_{i(gerçek)})^2 \quad (10)$$

2.4.2. Determinasyon (belirlilik) katsayısı (R^2)

Regresyon hesabı sonrası, determinasyon katsayısı uyum iyiliği performansı için yapılır ve bu katsayı (R^2) hesabı Denklem (11)' de gösterilmiştir[13]. (R^2) 0 ile 1 arasında değer alıp 1'e yakınlığı tahmin gücünü artırır.

$$R^2 = 1 - \frac{\sum_i^n (y_{i(gerçek)} - y_{i(tahmin)})^2}{\sum_i^n (y_{i(gerçek)} - ortalama(y_{gerçek}))^2} \quad (11)$$

3. Bulgular

Tablo 2' de yer alan n; nispi nem (%), s; sıcaklık (c°), r; rüzgâr hızı (m/s) ve y; yağış (mm=kg/m²) verilerini temsil etmekte olup (y-1) ifadesindeki -1 ötelenen saat sayısıdır. Tablo 2 incelendiğinde y ile y-1, n ile n-1 ve y ile y-1 arasında yüksek korelasyon olduğu, doğrusal modelde iyi sonuç verebileceği söylenebilir.

Tablo 2. Verilerin korelasyonu.

	n	n-1	s	r	r-1	y	y-1
n	1						
n-1	0.762	1					
s	-0.695	-0.568	1				
r	0.040	0.043	-0.023	1			
r-1	0.040	0.040	-0.021	0.667	1		
y	0.194	0.189	-0.101	0.081	0.083	1	
y-1	0.199	0.194	-0.104	0.085	0.080	0.956	1

Tablo 3’ te, yüksek korelasyona sahip parametrelerden oluşan modeller ve denklemleri verilmiştir.

Tablo 3. NARX ve Fitting YSA için hazırlanmış modeller.

Model	Giriş Katmanı	Giriş Katmanlarına Göre Elde Edilen Denklemler
1	n, n-1, s, r, y-1	$0.0004x_1 + 0.0002x_2 + 0.0004x_3 + 0.0061x_4 + 0.941x_5 - 0.0472$
2	n, s, r, r-1, y-1	$0.0005x_1 + 0.0004x_2 + 0.0102x_3 - 0.0061x_4 + 0.9415x_5 - 0.0399$
3	n, s, r	$0.0006x_1 + 0.0005x_2 + 0.6665x_3 + 0.3998$

MATLAB Fitting uygulaması YSA modelinde, sigmoid fonksiyonunu içeren gizli katman 10 nörondan oluşmakta, zaman serisi uygulaması ile oluşturulan YSA modelinde ise gecikme sayısı 2 olup gizli katman 10 nörondan oluşmaktadır. 9639 verinin %70’ i (6747) eğitim için, %15’ i (1446) doğrulama için, %15’ i test için (1446) kullanılmıştır. Ağın eğitimi Levenberg-Marquard eğitim algoritması ile yapılmıştır.

Tablo 4. NARX ve Fitting YSA ile elde edilen verilerin R^2 ve OKH değerleri.

Model	NARX YSA		Fitting YSA	
	R^2	OKH	R^2	OKH
1	0.91	0.0003	0.88	0.0384
2	0.90	0.0392	0.90	0.0382
3	0.46	0.2550	0.45	0.2552

Tablo 4’ te yer alan veriler incelendiğinde NARX ağının determinasyon katsayısı yüksek ve hata miktarının düşük olduğu anlaşılmakta, en iyi modelin 1. model olduğu görülmektedir.

4. Sonuçlar

Sıcaklık, nem, rüzgâr hızı ve yağış miktarı verileriyle yağış tahmininde bulunabilmek için NARX ve Fitting YSA kullanılmıştır. Anlamlı sonuçlar alabilmek için verilerin 1 saate kadar kaydırılmasıyla, arasındaki korelasyon katsayısına dikkat edilerek, 3 farklı model oluşturulmuştur. Modeller NARX ve Fitting YSA ile hesaplamalara tabi tutulmuş, işlemler sonucu performans ölçütleri (R^2 ve OKH) elde edilmiş, bu ölçütlere göre en randımanlı modelin 1. model olduğu görülmüştür. Aynı zamanda NARX ağının hem determinasyon katsayısı hem de ortalama kare hata bakımından Fitting YSA’ dan daha iyi sonuç çıkardığı görülmektedir.

Referanslar

- [1] A. Yıldırım ve S. Y. Kandemir, “Yağış miktarının yapay sinir ağları ile tahmini,” Bilecik Şeyh Edebali Üniversitesi Fen Bilim. Derg., vol. 5, no. 2, Aralık, pp. 97–104, 2018.
- [2] MGM, “Hava Tahmini - Meteoroloji Genel Müdürlüğü.” [Çevrimiçi]. Erişim : <https://www.mgm.gov.tr/genel/meteorolojinedir.aspx>. [Son erişim : 15 Nisan 2022].
- [3] A. Sarı, M. Aktaş, A. Yönetken ve R. Doğan, “Güneş Işınım Tahmininde NARX Modelinin Uygulanması,” Int. J. Eng. Technol. Appl. Sci., vol. 4, no. 1, Jun. pp. 1–6, 2021.
- [4] S. Karasu, A. Altan, Z. Saraç ve R. Hacıoğlu, “Estimation of fast varied wind speed based on narx neural network by using curve fitting,” Int. J. Energy Appl. Technol., vol. 4, no. 3, Oct., pp. 137–146, 2017.
- [5] F. Di Nunno, G. de Marinis, R. Gargano, and F. Granata, “Tide prediction in the Venice Lagoon using nonlinear autoregressive exogenous (NARX) neural network,” Water, vol. 13, no. 9, Apr., p. 1173, 2021.
- [6] S. Yavuz ve M. Deveci, “İstatistiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi,” Erciyes Üniversitesi İktisadi ve İdari Bilim. Fakültesi Derg., no. 40, May, pp. 167–187, 2015.
- [7] D. Aşkın, İ., İskender ve A. Mamızadeh, “Farklı yapay sinir ağları yöntemlerini kullanarak kuru tiptransformatör sargısının termal analizi,” Gazi Üniversitesi Mühendislik ve Mimar. Fakültesi Derg., vol. 26, no. 4, pp. 905–913, 2011.
- [8] A. Tatlı and S. Kahvecioğlu, “Narx neural networks based time series predictionfor amount of airworthiness time, in: Electrical, Electronics and BiomedicalEngineering (ELECO),” 2016 Natl. Conf. IEEE, 2017.
- [9] E. Diaconescu, “The use of narx neural networks to predict chaotic timeseries,” WSEAS Trans. Comp. Res., vol. 3, no. 3, pp. 182–191, 2008.
- [10] A. Karaaltı, M. Demirci, E. Baykaldı, “Ticari kredi faiz oranlarının YSA NARX ve VAR Modelleri ile öngörülmesi,” İşletme Araştırmaları Derg., vol. 12, no. 3, pp. 2327–2343, 2020.
- [11] B. Köse, “Saatlik ve günlük rüzgâr hızını tahmin için yeni bir analitik yöntem yaklaşımı ve yapay sinir ağları ile karşılaştırması,” Karabük Üniversitesi, 2016.
- [12] V. Ceyhan, “Performans ölçümleri ve seçim kriterleri.” [Çevrimiçi]. Erişim: <https://avys.omu.edu.tr/storage/app/public/vceyhan>. [Son erişim : 25 Mart 2022].
- [13] F. Gökğöz, “Çoklu regresyon modeli.” [Çevrimiçi]. Erişim: [https://acikders.ankara.edu.tr/pluginfile.php/117326/mod_resource/content/1/11-Coklu Regresyon 1.pdf](https://acikders.ankara.edu.tr/pluginfile.php/117326/mod_resource/content/1/11-Coklu%20Regresyon%201.pdf). [Son erişim : 28 Mart 2022].

Data Driven Modelling of Dual Band Microstrip G-Shape Radiator Antenna

Cem Göçen¹, Mehmet A. Belen², Peyman Mahouti³, Adnan Kaya⁴, Merih Palandöken⁵, Ömür Ceran⁶, Ozan Tanerğec⁷

¹Department of Electrical and Electronics Eng., Izmir Katip Çelebi University, Izmir, Turkey, cem.gocen@ikcu.edu.tr

²Department of Electrical and Electronics Eng., Iskenderun Technical University, Hatay, Turkey, mali.belen@iste.edu.tr

³Department of Avionics Electronic, Yıldız Technical University, Istanbul, Turkey pmahouti@yildiz.edu.tr

⁴Department of Electrical and Electronics Eng., Izmir Katip Çelebi University, Izmir, Turkey, adnan.kaya@ikcu.edu.tr

⁵Department of Electrical and Electronics Eng., Izmir Katip Çelebi University, Izmir, Turkey, merih.palandoken@ikcu.edu.tr

⁶Invgarden Bilişim Teknolojileri Arge Yenilenebilir Enerji Elk.Tur.Ve Tic.Ltd.Şti, omur.ceran@bilicra.com

⁷Invgarden Bilişim Teknolojileri Arge Yenilenebilir Enerji Elk.Tur.Ve Tic.Ltd.Şti, ozan.tanergec@bilicra.com

Abstract—Data-Driven modelling is a commonly used technique for optimization of models with expensive computational needs such as antenna designs. In this work, by using Artificial Intelligence algorithms and simulated data obtained from full-wave simulators, data driven modelling of a microstrip patch antenna with a G shape radiator element is taken under study. The main aim of this process is to use the generated data driven model as a fast and efficient surrogate model to assist the optimization process of geometrical design parameters of the antenna for achieving a characteristic for dual band antenna applications. Different types of regression algorithms such as Artificial Neural Networks, Support Vector Regression Machine, Ensemble Learning, and Gaussian Process Regression has been used to create a mapping between the input and outputs of the training data. After that, via the use of the meta-heuristic algorithm Invasive Weed Optimization, the G shaped microstrip antenna for dual-band applications had been optimally designed. The obtained design operates at 0.9 & 1.8 GHz frequencies which is a suitable candidate for GSM band applications. The obtained results of data driven model are compared with the full-wave simulation results. As a result, the proposed study achieves a computationally efficient optimization for inexpensive and computationally efficient optimization of dual band antennas.

Keywords—Data driven modeling, Artificial Intelligence, Dual band, optimization.

I. INTRODUCTION

Thanks to the fast and continuous improvement in wireless communication applications, systems with different standards such as GSM, UMTS, and WLAN [1] are developed and each of them has different operating frequencies. As such, it is more convenient to have an antenna with broadband or multi-band characteristics [2-11] instead of using many different antenna stages. In literature, there are many works on the design and modelling of multi band or broadband antenna stages [12-15]. Although each of the mentioned works provides a different approach to achieving a high-performance antenna design, each of the faces a challenging problem. Design and optimization of models with mentioned performance criteria is a challenging quest due to the increased number of design variables, a more complex inner relationship of parameters etc. This challenge push designers to decide on either using a fast and computationally efficient coarse model or a fine model with high accuracy but not good or acceptable computational efficiency [16]. The most used technique for having an accurate, fast data model for optimization of microwave antenna is the usage of data-driven surrogate modelling. The most used technique is Artificial Neural Networks [16-24].

In this study for having a fast, accurate and reliable model to be used for the optimization of aimed dual-band antenna design, Artificial Neural Networks algorithms and their counterpart methods had been deployed to create data-driven surrogate models of the studied antenna design. First, with getting help from a full-wave electromagnetic simulator, training data for the surrogate model is generated. After that, Modified Multi-Layer Perceptron (M2LP) [18-19] a regression algorithm based on both shallow and deep neural networks is used for creating the data-driven surrogate model between the input and output of the data set. The last step of the proposed method is to use the generated data-driven surrogate model and a meta-heuristic optimization algorithm to achieve the studied optimization problem of dual band antenna.

II. DATA DRIVEN SURROGATE MODELLING OF ANTENNA

Herein, a microstrip patch antenna design (Fig. 1) with G shaped radiator and a semi defected ground structure is taken into study. The antenna consists of a G shape rectangular radiator, and a semi defected ground plane. The lower and upper limit of the variable space for this problem is presented in Table 1, for domain reduction of the problem some parameters are simplified as follows $L3 = L2/2$, $W3 = W1 + W2$, $L1 = L5$. Latin-Hyper cube Sampling (LHS) is chosen as the sampling method for generating training and test samples based on the given input domain in Table I. A total of 1000 data samples (800 for

training and 200 for hold-out) are used to evaluate the performance of the data driven models. Here, each generated data sample has the response of scattering parameters between 0.5-2.5 GHz with a step size of 0.1 GHz.




Fig. 1 Schematic of the G shape dual-band antenna.

TABLE I. DESIGN VARIABLES AND THEIR VARIATION LIMITS

Parameter	Lower	Upper	Parameter	Lower	Upper
L1	60	70	W1	2	5
L2	20	40	W2	15	30
L4	1	6	W4	5	30

In this study, some of the most used Artificial Intelligence algorithms for data-driven surrogate modelling are used where their results are presented (Table II). The presented results are obtained via a k-fold validation with $k = 5$, alongside the additional hold-out data set with 200 samples using Relative Mean Error (RME) (Eq. 1).

$$RME = \frac{1}{N} \sum_{i=1}^N \frac{|T_i - P_i|}{|T_i|} \quad (1)$$

T: targeted value, P: predicted value, N total number of samples for the inspected frequency band.

TABLE II. PERFORMANCE RESULTS OF ALGORITHMS

Model	Hyper-Parameters	K-fold/Holdout
SVRM	Epsilon=0.2, Kernel function: Radial basis	7.2% / 9.2 %
Gradient Boosted Tree	Learning rate : 0.035 N. of estimators : 4700 depth of model : 4	6.9% / 8.4%
M2LP	depth of model : 3 N. initial Neuron: 64	4.9% / 5.7 %

As it can be seen from the Table II results, although all models achieve similar k-fold validation which can be accepted based on the sensitivity of the problem, their Hold-out performance, however, has a higher difference which directly indicates that both SVRM, and Gradient Boosted Tre algorithms tend to have a higher level of over-fitting compared to the M2LP which has almost half error rate compared to these algorithms. Thus, due to the lowest error value both in k-fold validation and hold out data sets, M2LP will be used as the optimal model for this problem.

III. STUDY CASE

In this work, Invasive Weed Optimization (IWO) is selected as an efficient meta-heuristic optimization tool for the optimization of antenna geometries [25-28] where Eq. (2) is the cost function that is used to guide the search process.

$$Cost = \sum_{f_{min1}}^{f_{max1}} \frac{C_1}{|S_{11_i}(f)|} + \sum_{f_{min2}}^{f_{max2}} \frac{C_2}{|S_{11_i}(f)|} \quad (2)$$

The weighting coefficients are taken as $C_1 = C_2 = 1$. The cost function is aimed to maximize S_{11} values in the given frequency ranges of (I) 0.9 GHz, and (II) 1.8 GHz. As a result of the IWO optimization process using the cost function in Eq. 2, obtained M2LP surrogate model using the limitation given in Table I, the values presented in Table III had been obtained as an optimal model for selected operation bands of 0.9 and 1.8 GHz. Here it must have empathized that in literature there are many other types

of meta-heuristic optimization methods which might have better or worse convergence speed than the used IWO algorithm in this work, which designers is also must make a study for further improvements in their problem, however, for two reasons this topic is not studied in this work (I) for the sake of simplification of the studied problem, (II) with the usage of data-driven surrogate models, the function evaluation of each candidate solution is extremely accelerated where the convergence speed of the used search protocol can be neglected.

TABLE III. OPTIMAL DETERMINING DESIGN PARAMETERS OF THE G SHAPE ANTENNA IN [MM]

L1	66.3	W1	4.0
L2	31.3	W2	20.2
L4	4.0	W4	14.4

To justify the obtained results of the optimally selected parameter using M2LP based the obtained scattering characteristics of M2LP are compared with the simulated result of a full wave EM simulator (Fig. 2). From Fig. 2 it can be said that the obtained results are in a good agreement where the scattering characteristic of the obtained result from M2LP shows that the antenna is operates at the aimed to operation frequencies of 0.9 and 1.8 GHz that is also seen in results of full-wave simulator.

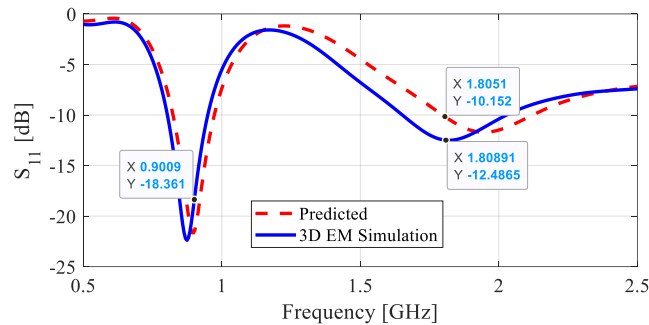


Fig. 2 simulated results of full-wave simulator and M2LP surrogate model

IV. CONCLUSION

Via the use of surrogate modelling techniques, computationally efficient optimization of dual-band antenna is studied. For this mean, a modified multi-layer perceptron regression model had been used alongside a meta-heuristic optimization IWO to find optimal values for design parameters of the studied antenna for the given search limitations of lower and upper values and requested operation frequencies of 0.9 & 1.8 GHz. The antenna model obtained from the M2LP surrogate model is compared with the result of the full-wave simulator for justification of the proposed work and as a result, the proposed technique is in good agreement with full-wave results.

ACKNOWLEDGEMENT

This work has been supported by Project 121N412 of TUBITAK (Scientific and Technological Research Council of Turkey).

REFERENCES

- [1] Fallahpour, M., Ghasr, M. T., & Zoughi, R. (2014). Miniaturized reconfigurable multiband antenna for multiradio wireless communication. *IEEE Transactions on Antennas and Propagation*, 62(12), 6049-6059.
- [2] Gangwar, A. K., & Alam, M. S. (2019). A miniaturized quad-band antenna with slotted patch for WiMAX/WLAN/GSM applications. *AEU-International Journal of Electronics and Communications*, 112, 152911.
- [3] Liu, H., Wen, P., Zhu, S., Ren, B., Guan, X., & Yu, H. (2015). Quad-band CPW-fed monopole antenna based on flexible pentangle-loop radiator. *IEEE Antennas and Wireless Propagation Letters*, 14, 1373-1376.
- [4] B. K. Yu, B. Jung, H. J. Lee, F. J. Harackiewicz, and B. Lee, "A folded and bent internal loop antenna for GSM/DCS/PCS operate of mobile handset applications," *Microw. Opt. Technol. Lett.*, vol. 48, no. 3, pp. 463-467, 2006.
- [5] İ. Akdağ, C. Göçen, M. Palandöken and A. Kaya, "Estimation of the Scattering Parameter at the Resonance Frequency of the UHF Band of the E-Shaped RFID Antenna Using Machine Learning Techniques," 2020 4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), 2020, pp. 1-5.
- [6] Belen, A., Tari, O., Mahouti, P., Belen, M. A., & Çalışkan, A. (2022). Surrogate-Based Design Optimization of Multi-Band Antenna. *The Applied Computational Electromagnetics Society Journal (ACES)*, 34-40.
- [7] Wa'il, A., Shaaban, R. M., & Duffy, A. P. (2022). Design, simulation, and fabrication of a double annular ring microstrip antenna based on gaps with multiband feature. *Engineering Science and Technology, an International Journal*, 29, 101033.
- [8] Lavadiya, S. P., Sorathiya, V., Kanzariya, S., Chavda, B., Naweed, A., Faragallah, O. S., ... & Rashed, A. N. Z. (2022). Low profile multiband microstrip patch antenna with frequency reconfigurable feature using PIN diode for S, C, X, and Ku band applications. *International Journal of Communication Systems*, e5141.

- [9] Benkhadda, O., Ahmad, S., Saih, M., Chaji, K., Reha, A., Ghaffar, A., ... & Limiti, E. (2022). Compact Broadband Antenna with Vicsek Fractal Slots for WLAN and WiMAX Applications. *Applied Sciences*, 12(3), 1142.
- [10] Czyz, M., Olencki, J., & Bekasiewicz, A. (2022). A compact spline-enhanced monopole antenna for broadband/multi-band and beyond UWB applications. *AEU-International Journal of Electronics and Communications*, 154111.
- [11] Laguna, A. P., Cavallo, D., Baselmans, J. J., & Llombart, N. (2022). Focused Connected Array Antenna as a Broadband Beam-Steering Feed for Quasi-Optical Systems. *IEEE Transactions on Antennas and Propagation*.
- [12] Bakytbekov, A., Nguyen, T. Q., Huynh, C., Salama, K. N., & Shamim, A. (2018). Fully printed 3D cube-shaped multiband fractal rectenna for ambient RF energy harvesting. *Nano Energy*, 53, 587-595.
- [13] R.M. David, T. Ali, P.A. Kumar, "Multiband Antenna Stacked with Novel Metamaterial SCSRR and CSSRR for WiMAX/WLAN Applications," *Micromachines* 2021, vol. 12, pp. 113.
- [14] Kingsly, S., Thangarasu, D., Kanagasabai, M., Alsath, M. G. N., Thipparaju, R. R., Palaniswamy, S. K., & Sambandam, P. (2018). Multiband reconfigurable filtering monopole antenna for cognitive radio applications. *IEEE Antennas and Wireless Propagation Letters*, 17(8), 1416-1420.
- [15] Lu, J. H., & Huang, B. J. (2010). Planar multi-band monopole antenna with L-shaped parasitic strip for WiMAX application. *Electronics Letters*, 46(10), 671-672. <https://doi.org/10.1007/s11277-020-07061-3>
- [16] P. Mahouti, "Design optimization of a pattern reconfigurable microstrip antenna using differential evolution and 3D EM simulation-based neural network model," *Int J RF Microw Comput Aided Eng*. 2019; 29:e21796.
- [17] J.E. Rayas-Sanchez and V. Gutierrez-Ayala, "EM-based statistical analysis and yield estimation using linear-input and neural-output space mapping," *IEEE MTT-S Int. Microwave Symp. Digest (IMS)*, pp. 1597-1600, 2006.
- [18] N. Calik, M.A. Belen, P. Mahouti, "Deep learning base modified MLP model for precise scattering parameter prediction of capacitive feed antenna," *Int J Numer Model*. 2020; 33:e2682.
- [19] T. Mahouti, T. Yıldırım, N. Kuşkonmaz, "Artificial intelligence-based design optimization of nonuniform microstrip line band pass filter," *Int J Numer Model*. 2021;e2888.
- [20] Mahouti, T., Kuşkonmaz, N., Yıldırım, T. Surrogate-assisted optimization of 3D printed ceramic nonuniform nonplanar microstrip filter. *Microw Opt Technol Lett*. 2022; 1- 6. doi:10.1002/mop.33295
- [21] Ambigapathy, Sivabalan, and Jothilakshmi Paramasivam. "2.4 GHz and 5.2 GHz frequency bands reconfigurable fractal antenna for wearable devices using ANN." *The Applied Computational Electromagnetics Society Journal (ACES)* (2021): 354-362.
- [22] Xiao, Li-Ye, Wei Shao, Fu-Long Jin, Bing-Zhong Wang, and Qing Huo Liu. "Inverse Artificial Neural Network for Multiobjective Antenna Design." *IEEE Transactions on Antennas and Propagation* 69, no. 10 (2021): 6651-6659.
- [23] Kumar, Anurag K., Medhavi Kirti, Shuchishmita Pani, and Sanjeev Saxena. "Optimization of Antenna Parameters Using Neural Network Technique for Terahertz Band Applications." In *Recent Trends in Electronics and Communication*, pp. 41-56. Springer, Singapore, 2022.
- [24] Zhou, Wen-Ying, Zhong-Lei Mei, Mai Lu, and Ya-Bo Zhu. "Improved fully-connected neural network approach for decoupling microstrip antenna array design." *Journal of Electromagnetic Waves and Applications* (2022): 1-14.
- [25] Movassagh, Ali Akbar, Jafar A. Alzubi, Mehdi Gheisari, Mohamadtaghi Rahimi, Senthilkumar Mohan, Aaqif Afzaal Abbasi, and Narjes Nabipour. "Artificial neural networks training algorithm integrating invasive weed optimization with differential evolutionary model." *Journal of Ambient Intelligence and Humanized Computing* (2021): 1-9.
- [26] Ibrahim, Alasmer, Fatih Anayi, Michael Packianather, and Osama Ahmad Alomari. "New hybrid invasive weed optimization and machine learning approach for fault detection." *Energies* 15, no. 4 (2022): 1488.
- [27] Kenane, Elhadi, Haddi Bakhti, Miloud Bentoumi, and Farid Djahli. "A Dynamic Invasive Weeds Optimization Applied to Null Control of Linear Antenna Arrays with Constrained DRR." (2021).
- [28] A. Belen, P. Mahouti, F. Güneş, F., Ö. Tari, "Gain Enhancement of a Traditional Horn Antenna using 3D Printed Square-Shaped Multi-layer Dielectric Lens for X-band Applications," *Applied Comp. Electromagnetics Society (ACES) J.*, vol.36, no. 2, 2021.

2.4 GHZ ANTENNA DESIGN FOR NEW GENERATION WIRELESS COMMUNICATION

Gökçen DEMİRBAŞ¹

¹ Electrical and Electronics Engineering, Izmir Katip Celebi University, Turkey,
gokcen_demirbas@hotmail.com

Abstract

With the rapid development of digital technology in recent years, the need for products to be used in accessing technology has been increased. Antennas are at the forefront of these products. Antennas are in the first step of the products that enable to reach technology. Since there is almost no area where digital technology is not used, the need for studies in this field has increased day by day. In this study, a Wi-Fi antenna with 2.4 GHz operating frequency to be used in digital technology has been designed. While design the antenna, support has been taken from artificial intelligence and machine learning, which are indispensable for the new world. While designing the antenna, CST Microwave Studio program is used and numerical computations are done. Double sided copper plated FR-4 substrate with a dielectric coefficient of 4.3 and a thickness of 1.6 mm is used. After the antenna design is completed, necessary changes are done and parametric analysis is conducted for the machine learning assisted S11 estimation. As a result of this study, an antenna with a return loss value of 41 dB and a bandwidth value of operating between the frequencies of 2.37 GHz -2.42 GHz has been designed. The designed antenna is acceptable according to IEEE 802.11 standards.

Keywords: *Wi-Fi Antenna; Microstrip; Machine Learning; IEEE 802.11; Antenna Design.*

1. Introduction

With the increasing technical demands in wireless communication technology which has been initiated by the evolving digitalization, the microwave components in this technology field have started to be improved in comparison to the conventional microwave components [1-5]. Antenna is one of these important technological components [6]. In this study, an antenna with high return loss value and 2.4 GHz operating frequency is designed and the results are examined. Many studies have been carried out in this area from the past to the present. Antenna designs have been continuously improved [7]. Dimensional changes are at the beginning of the studies [8]. Have been to design an antenna in a small size will make it cost-effective and compact. In line with this definition, microstrip antenna, which is the most advantageous option that meets the demand, is discussed [9]. Rachmansyah et al designed the flattest microstrip patch antenna known. The gain value of this antenna is 11 dBi. Another main problem of microstrip antennas is narrow bandwidth. The most important task to solve this problem to change the supply line [10]. Haydar Ahmet, Y. Teşneli and N. Berna Teşneli compared the results uses different feeding methods and analyzed the most appropriate feeding to be used in the designed model. Coplanar feeding the best feeding method with 60% bandwidth. Another development work is to modify the antenna geometry and make slots on the antenna [11]. Raad H. Thaher and Zainab S. Jamil conducted parametric studies on the antenna and opened slots in certain areas. The antenna which is they designed works in 2.4/5.8 GHz bands for Wi-Fi/WiMAX applications. The results of return loss is 32.77 dB at 2.4 GHz at 7.4% bandwidth and 25.955 dB at 5.8 GHz with 8.17% bandwidth [12]. All these studies have been carried out takes into account certain protocols. This protocol is IEEE 802.11. IEEE 802.11 standards are the general name of the developed wireless networks. This standard has been also taken into account in this study. In the designed antenna, it is aimed to design the most suitable microstrip antenna in terms of return loss and antenna gain.

The paper is structured as follows. In Section 2, a discussion will be made about the design of the designed antenna, its dimensions, and the preferred application for simulation. In Section 3, simulation results of the designed antenna are presented. In the last section, section 4, the general summary of the study is explained.

2. Material and Methods

2.1. Proposed Antenna Design

While designing the antenna, micro strip antenna has been preferred due to its geometry, lightness, low production cost and compactness [13]. Microstrip antenna has 3 important layers. These are Ground - Patch - Substrate. The

ground part of the designed antenna is made of copper and its thickness is 0.035 mm. This layer is conductive. The substrate layer is the second layer. FR4 material has been chosen for this layer. Its dielectric coefficient is 4.3 and its thickness is 1.6 mm. This material is generally preferred in antenna designs. The last layer where the radiation takes place is the patch part [14]. In this part, it should be conductive like ground. Copper is used in the patch part of the designed antenna and its thickness is taken as 0.035 mm. While the data have been taken for machine learning, the parameters that have been modified on the Patch are determined from this section. The optimum values obtained after machine learning are shown in Figure 1 of the generated antenna.

2.2. Simulation of Proposed Antenna

The CST microwave studio program has been used to design the antenna. The antenna designed as a result of the simulation is shown in figure 1.




Figure 1: Proposed Antenna Design Front and Back View

2.3 Machine Learning Algorithms in Proposed Antenna

Machine learning algorithms act as computers' minds, promoting learning and improve. More data means more algorithms are triggered, leads to the computer learning and improves its output. If the prediction does not come true, the algorithm is retrained until the desired outcome is achieved. This allows the machine learning system to self-train and provide the greatest possible response, which will increase in correctness over time. Machine learning is predicted to speed up the antenna design process while retains high accuracy levels, reduces errors and speeds up the process, as well as predicted antenna performance, improves computing efficiency, and reduces the number of iterations required [15].

In the antenna to be designed, 3 different parameters are changed over 5 values, and 125 parameters are examined as 5x5x5. Changes have been made on the patch and ground, and the most effective values at 2.4 GHz operating frequency has been examined. The parametric results are put into the machine learning code and the results are analyzed in different regression models and the best prediction algorithm is found.

Machine learning regression algorithms have been used in this study. Regression algorithms have been chosen because machine learning will be used on the prediction process. Analysis has been done on 4 different regression algorithms. These algorithms are Polynomial Linear Regression, Random Forest Regression, SVR and KNN. According to the value received from the user, the algorithm that makes the closest estimation has been determined.

3. Results

The results of the simulations of the antenna designed in the CST microwave studio program are examined. The return loss, gain and radiation pattern graph required for the antenna are given below. Machine learning regression results are shown.




Figure 2: Return loss of proposed antenna

The S parameter result of the designed antenna is shown in Figure 2. The bandwidth value is shown on the S11 result graph. The Wi-Fi antenna operating frequency has a return loss value of 41 dB. This return loss value is accepted in antenna design and is a good value by standards. The operating frequency range of the designed antenna is 2.37 GHz - 2.42 GHz.




Figure 3: Radiation Pattern of proposed antenna

The gain of the designed antenna has been obtained as 0.832 dBi as seen in Figure 3.

For machine learning algorithms, 3 effective parameters are chosen to replace the places with the greatest effect on the antenna. First, the width of the antenna feed line (P1), then the size of the rear slot (P2), and finally the length of the lower arms (P4) are given. Parametric analysis has been performed for 5 different results of each value. As a result of this analysis, after the necessary code has been written, a value has been taken from the user for the estimation and the algorithm made an estimation accordingly. The values received from the user are shown in Table 1. Estimation results are shown in table 2. The algorithms estimated the return loss value of the antenna.

Table 1: Proposed Antenna Selected Parameters Values

SELECTED PARAMETERS	SELECTED PARAMETERS VALUES
P1	3
P2	1
P4	0

Table 2: Proposed Antenna Machine Learning Results

Machine Learning Algorithms	Prediction of Return Loss Value
Polynomial Linear Regression	-21.516 dB
Random Forest Regression	-35.73622 dB
SVR	-4.61723 dB
KNN	-12.55028 dB

125 parameters received for the designed antenna has been put into machine learning. 30% of the data has been used for learning and 70% for testing. After the data put into machine learning, the results have been examined on 4 different algorithms Selected 4 different algorithms are shown in Table 2. Machine learning gave that the regression model that gave the best result for the selected value after performing the necessary learning and testing stages. Many observes have been made to confirm that this regression model works better than others. According to the results, the best estimation algorithm for the parameters in this design is Random Forest Regression.

Acknowledgements

This study has been carried out using the laboratory facilities of İzmir Katip Celebi University Smart Factory Systems Application and Research Center (AFSUAM). This study is supported by TUBITAK 2209-A University Students Research Projects Support Program within the scope of project numbered 1919B012102519.

References

- [1] Montero-de-Paz, J., Oprea, I., Rymanov, V., Babel, S., García-Muñoz, L. E., Lisauskas, A., ... & Carpintero, G. (2013). Compact modules for wireless communication systems in the E-band (71–76 GHz). *Journal of Infrared, Millimeter, and Terahertz Waves*, 34(3), 251-266.
- [2] Rymanov, V., Palandöken, M., Lutzmann, S., Bouhlal, B., Tekin, T., & Stöhr, A. (2012, September). Integrated photonic 71–76 GHz transmitter module employing high linearity double mushroom-type 1.55 μm waveguide photodiodes. In 2012 IEEE International Topical Meeting on Microwave Photonics (pp. 253-256). IEEE.
- [3] Palandöken, M., Rymanov, V., Stöhr, A., & Tekin, T. (2012, August). Compact metamaterial-based bias tee design for 1.55 μm waveguide-photodiode based 71–76GHz wireless transmitter. In Progress in Electromagnetics Research Symposium, PIERS.
- [4] Palandöken, M., & Sondas, A. (2014). Compact Metamaterial Based Bandstop Filter. *Microwave Journal*, 57(10).
- [5] Palandoken, M. (2012). Metamaterial-based compact filter design. In Metamaterial. IntechOpen.
- [6] Balanis, C. A. (2015). *Antenna theory: analysis and design*. John Wiley & sons.
- [7] Özkaya, U., Yiğit, E., Seyfi, L., Öztürk, Ş., & Singh, D. (2021). Comparative regression analysis for estimating resonant frequency of c-like patch antennas. *Mathematical Problems in Engineering*, 2021.
- [8] Wegmuller, M., Von Der Weid, J. P., Oberson, P., & Gisin, N. (2000, January). High resolution fiber distributed measurements with coherent OFDR. In Proc. ECOC'00 (Vol. 11, No. 4, p. 109).
- [9] ICSLMS Committee. (1997). Wireless LAN medium access control (MAC) and physical layer (PHY) specifications. IEEE Std, 802, 50.
- [10] Rachmansyah, A. I., & Mutiara, A. B. (2011). Designing and manufacturing microstrip antenna for wireless communication at 2.4 GHz. *International Journal of Computer and Electrical Engineering*, 3(5), 670-675.
- [11] Küçük, H., Teşneli, A. Y., & Teşneli, N. B. (2000). 3.3 GHz mikroşerit anten tasarımı ve farklı besleme yöntemleri için analizi. *Sakarya University Journal of Science*, 17(1), 119-124.
- [12] Thaher, R. H., & Jamil, Z. S. (2018). Design of dual band microstrip antenna for Wi-Fi and WiMax applications. *Telkommnika*, 16(6), 2864-2870.,
- [12] BAYTÖRE, C., GÖÇEN, C., PALANDÖKEN, M., Kaya, A., & ZORAL, E. Y. (2019). Compact metal-plate slotted WLAN-WIMAX antenna design with USB Wi-Fi adapter application. *Turkish Journal of Electrical Engineering & Computer Sciences*, 27(6), 4403-4417.
- [13] Demirbas, G. & Akar, E. (2022). Design and Interpretation of Microstrip Patch Antenna Operating at 2.4GHz for Wireless WI-FI Application. *Avrupa Bilim ve Teknoloji Dergisi , Ejosat Special Issue 2022 (ICAENS-1) , 672-675 . DOI: 10.31590/ejosat.1084151*
- [14] Akar, E., Akdag, I., & Gocen, C. (2022). Wi-Fi Antenna Design For E-Health Kit Based Biotelemetry Module. *ICONTECH INTERNATIONAL JOURNAL*, 6(1), 63-67. <https://doi.org/10.46291/ICONTECHvol6iss1pp63-67>
- [15] Demirbas, G., Gocen, C., & Akdag, I. (2022). Micro-strip Patch 2.4 GHz Wi-Fi Antenna Design For WLAN 4G- 5G Application . *ICONTECH INTERNATIONAL JOURNAL*, 6(1), 68-72. <https://doi.org/10.46291/ICONTECHvol6iss1pp68-72>

Machine Learning to Predict Ultimate Pressure Load for Concrete-Filled Steel Tube Columns

Aybike ÖZYÜKSEL ÇİFTÇİOĞLU¹

¹ Department of Civil Engineering, Faculty of Engineering, Manisa Celal Bayar University, Türkiye,
aybike.ozyuksel@cbu.edu.tr

Abstract

Machine learning (ML) is a subset of artificial intelligence that uses computers to learn from data. It is an essential tool for analyzing and predicting patterns in large data sets. Regression algorithms are used in ML to predict the value of a given input for a set of data points. Regression analysis is a statistical technique that helps determine the cause of an output variable. Complex predictions about future values for previously unseen data can be produced by understanding the underlying relationships between input and output variables. Concrete-filled steel tube (CFST) columns have a unique combination of properties that none of the materials used alone can provide. Steel, a strong and dense material, provides tensile strength to support the weight of the structure. Concrete, a material with great compressive strength, provides the load-bearing capacity to hold the weight of the structure. When used together, CFST provides improved qualities, such as fire resistance, load-bearing capacity, and corrosion resistance, that neither material alone can provide. The ultimate compressive load of these columns is known to be very critical in engineering applications, as they are very often used to support high-rise buildings and other structures where considerable loads are expected to fall directly on columns. Hence, it becomes very important to estimate the ultimate compressive loads of these columns with high accuracy so that loads can be safely supported. This paper examines the ultimate compressive loads of CFST rectangular columns under eccentric loading using ML techniques.

Keywords: *concrete-filled steel tube; machine learning; ultimate pressure load*

1. Introduction

The characteristics of CFST members are fascinating. They improve numerous attributes, including load-bearing capacity, fire resistance, and earthquake resistance, by combining the tensile strength of the steel tube with the compressive strength of the concrete core. CFST members have recently been used in projects such as buildings, bridges, and underground stations due to their resistance to moments as well as simple beam-column joints [1]. It is well known that concrete-filled steel tubes have complicated and nonlinear behavior under axial compression. Theories, numerical calculations, and experiments are being used to gain more insight into the axial behavior of rectangular concrete-filled steel tubular members. However, in most cases, a small number of column samples is not enough to accurately determine the properties of the materials and understand their behavior. The limited number of test specimens and the costs required to perform experiments are the main reasons to use artificial intelligence techniques [2].

ML is being used more and more in the data-driven world. It is able to predict various outcomes and trends based on data analysis [3, 4]. In general, ML models can be used to learn about data, create predictions about unseen data, or train a model to make predictions about new data [5].

The main advantage of using CFST columns is their high load-bearing capacity. Estimating the ultimate pressure load for concrete-filled steel tube columns is critical for the safety of the structure. Ultimate pressure load is the maximum pressure that a column can withstand without buckling or collapsing. In addition, the strength of the CFST columns can be further improved by estimating the ultimate pressure load [6]. This research tries to forecast the ultimate compressive load, one of the most crucial engineering characteristics for composite structures on rectangular CFST columns under eccentric loading, using four different ML methods.

2. Data Processing

This study makes use of experimental data from 622 CFST columns gathered from the literature [7]. Table 1 displays the preliminary assessment of all variables in the database, including notation, unit, minimum, maximum, average, and standard deviation. Variables in the data can be categorized into two broad groups, independent and dependent variables. Independent variables are not dependent on any variable, while dependent variables are those that depend on the behavior of independent variables. Among these variables, H , B , t , L , f_y , f_c' , and et are identified as independent variables for ML models, whereas Nu is the dependent variable to be estimated.

Table 1. Statistics of the dataset

	Cross section height	Cross section width	Steel tube thickness	Column's length	Steel yield stress	Concrete compressive strength	Loading eccentricity	Ultimate load
Notation	H	B	t	L	f_y	f_c'	et	N_u
Unit	mm	mm	mm	mm	Mpa	Mpa	mm	kN
min.	60.00	60.00	0.70	60.00	194.00	10.00	0.00	105.40
max.	360.00	324.00	12.50	4500.00	835.00	183.00	75.00	14116.00
mean	149.57	139.59	4.73	1425.58	432.85	60.25	10.14	1996.37
st dv	56.72	52.71	2.11	1074.19	178.32	35.62	17.71	2037.71

The correlation matrix is used to get additional information about the relationship between variables (see Figure 1). A positive correlation means that when one variable rises, so does the other. A negative correlation, on the other hand, shows that when one variable rises, the other variable declines. According to the correlation coefficient, the strength of association between the variables is high (high correlation coefficient) if the variables have a positive relationship with each other. In addition, they have a low degree of association (low correlation coefficient) if the variables have a negative relationship with each other.




Figure 1. Correlation matrix of features in the dataset

Cross-section width, cross-section height, steel tube thickness, and steel yield stress strength are the independent factors that have the strongest association with the ultimate load, as can be shown in Figure 1. The ultimate load has the strongest inverse relationship with column length and load eccentricity.

3. Machine Learning Models

ML is an area of artificial intelligence that uses computer algorithms to learn and make decisions based on past experiences. It is a growing field that uses statistical models and large amounts of data to achieve predictive results. This research tries to forecast the ultimate compressive load on rectangular CFST columns under eccentric loading, using four different ML methods: Support Vector Regression (SVR), Extreme Gradient Boost (XGBoost), Random Forest (RF), and Decision Tree (DT).

3.1 Support Vector Regression Model

The support vector machine [8] is a supervised ML technique used for classification and regression [9]. It is used in fields such as data science, artificial intelligence, computer vision, and ML [10].

Support Vector Regression (SVR) determines the best-fitting hyperplane with the maximum number of points. SVR model attempts to fit the best line within a given threshold value. This contrasts with conventional regression models, which try to limit the gap between the real and estimated values [11]. SVR not only has the advantage of strong generalization ability but also provides fast convergence speed. There are unique advantages in dealing with small samples and nonlinear problems [12].

3.2 XGBoost Regression Model

Extreme gradient boost (XGBoost), a technique that has recently been developed and used in many fields, is a versatile tool [13]. This technique's well-organized, portable and flexible approach will be suitable for all kinds

of applications. It also employs the first-order Taylor expansion of the loss function while combining Cause Based Decision Tree with Gradient Boosting Machine to create an algorithm that will efficiently process all types of data without overfitting [14]. With such unique capabilities, this algorithm can be successfully employed for developing forecasting models being regression or classification processes are executed on the targeted dataset. Moreover, XGBoost is ideal when working with big datasets containing a considerable number of attributes [15].

3.3 Random Forest Regression Model

The Random Forest (RF) model, an extension of a classification and regression tree (CART), is a popular ML approach that predicts outcomes from a collection of predictors using an ensemble of decision trees [16]. Each independent tree is run with its own "bootstrap" sample from the training dataset and produces an individual forecast as well as a combined forest forecast. The underlying idea of RF models is that weaker performing but still, reliable trees can be used in combination to generate accurate forecasts by aggregating their votes together rather than relying on just one tree or even a few highly predictive ones alone [17, 18]. Furthermore, it can be used to analyze either classifications or regressions, with informative results that may give statistical probabilities in their predictions.

3.4 Decision Tree Regression Model

Decision Tree (DT) is a nonparametric model of supervised learning that is used for both classification and regression analysis. It splits the dataset into smaller classes and uses the resulting tree structure to predict results. DT model contains three different types of nodes, namely root nodes, interior nodes, and leaf nodes. The first split in the tree root node leads to more types of internal trees, called the interior tree. These are represented by data features and decision rules while leaves represent final results from decisions made on them by intermediate trees before leading to one result at last after completing all the branches in this part of the tree (root) [19].

4. Results

Scaling is the process of converting values from their original scale to a standardized scale. Scaling data involves taking each variable in a dataset and mapping it to a value between “-1” and “1”. The data in this study are standardized in preparation for modeling and analysis.

During the process of developing the four regression models, 80% of the data is determined as training data and 20% as test data. The algorithm is trained using training data, which accounts for the vast bulk of the data, and test data is used to evaluate model accuracy. The ultimate compression load of CFST columns is then predicted using training dataset employing four ML regression models.

Figure 2 shows the scatter plots between the estimated and real values for each ML model.




Figure 2. The distributions of the observed ultimate load vs predicted ultimate load

The best models are those in which the points are as close to the 45-degree line as possible. Figure 2 demonstrates that the points in the DT and RFR models have a wide distribution and are slightly further away from the 45-degree line than the other models. A close distribution of points and proximity to the 45-degree line for the SVR and XGBoost regression models, respectively, indicates that these models are stronger predictors.

Table 2. Performance measurements for the test dataset.

ML method	RMSE	R ²	MAE
SVR	243.52	0.98	168.52
XGB	403.45	0.95	246.91
RFR	474.35	0.93	247.84
DTR	528.48	0.91	285.40

This study evaluates the prediction accuracy of each ML model by looking at three performance metrics: Mean absolute error (MAE), root mean square error (RMSE), and coefficient of regression (R²). MAE is a measurement of how far the predictions of a model are from the actual numbers. It is the average of the absolute values of the differences between estimated and real values. RMSE is the square root of the average of the squared prediction errors and is more sensitive to large errors than MAE. R² is a statistical measure of how well a regression model fits the data. A score of 1 means that the model exactly fits the data, whereas a value of 0 shows that the model does not fit the data. Furthermore, the lower the RMSE and MAE, the better the accuracy of a regression model.

Table 2 shows RMSE, R², and MAE of each ML regression model for forecasting the ultimate compression load of CFST columns. The results show that SVR, XGBoost, RFR, and DTR all have an R² value of over 0.9. SVR and XGBoost models have better R² values than other models, and the R² value of SVR model is higher than XGBoost with 0.98. In addition, SVR achieved the lowest RMSE (243.52) and MAE (168.52), indicating better performance when predicting the ultimate compressive load on rectangular CFST columns under eccentric loading.

The outcomes show that SVR and XGBoost models provide more accurate predictions for future compressive loads than RFR and DTR models do.

References

- [1] S. Thai, H.-T. Thai, B. Uy, and T. Ngo, -Concrete-filled steel tubular columns: Test database, design and calibration, Journal of Constructional Steel Research. vol. 157, pp. 161–181, 2019.
- [2] T.-T. Le and H.C. Phan, -Prediction of Ultimate Load of Rectangular CFST Columns Using Interpretable Machine Learning Method, Advances in Civil Engineering. vol. 2020, p. 8855069, 2020.
- [3] M.Z. Naser and A.H. Alavi, -Error Metrics and Performance Fitness Indicators for Artificial Intelligence and Machine Learning in Engineering and Sciences, Architecture, Structures and Construction. p. 2021.
- [4] S. Khalilpourazari and M. Mohammadi, -A new exact algorithm for solving single machine scheduling problems with learning effects and deteriorating jobs, <https://arxiv.org/abs/1809.03795>, 2018.
- [5] S. Khalilpourazari and H. Hashemi Doulabi, -Designing a hybrid reinforcement learning based algorithm with application in prediction of the COVID-19 pandemic in Quebec, Annals of Operations Research. p. 2021.
- [6] M.J. Moradi, K. Daneshvar, D. Ghazi-nader, and H. Hajiloo, -The prediction of fire performance of concrete-filled steel tubes (CFST) using artificial neural network, Thin-Walled Structures. p. 2021.
- [7] S. Nguyen Thi Mai, Dataset of 622 Rectangular Concrete-filled steel tube columns, 2021.
- [8] C. Cortes and V. Vapnik, -Support-vector networks, Machine Learning. vol. 20, no. 3, pp. 273–297, 1995.
- [9] C.-N. Ko and C.-M. Lee, -Short-term load forecasting using SVR (support vector regression)-based radial basis function neural network with dual extended Kalman filter, Energy. vol. 49, pp. 413–422, 2013.
- [10] M.Z. Naser, -Observational Analysis of Fire-Induced Spalling of Concrete through Ensemble Machine Learning and Surrogate Modeling, Journal of Materials in Civil Engineering. vol. 33, no. 1, p. 2021.
- [11] M. Lin, C. Yan, J. Meng, W. Wang, and J. Wu, -Lithium-ion batteries health prognosis via differential thermal capacity with simulated annealing and support vector regression, Energy. vol. 250, p. 123829, 2022.
- [12] W. Woldemariam, -A framework for transportation infrastructure cost prediction: a support vector regression approach, Transportation Letters. vol. 00, no. 00, pp. 1–7, 2021.
- [13] T. Chen and C. Guestrin, -XGBoost: A Scalable Tree Boosting System, In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. pp. 785–794. Association for Computing Machinery, New York, NY, USA (2016).
- [14] H. Nasiri and S. Hasani, -Automated detection of (COVID)-19 cases from chest X-ray images using deep neural network and {XGBoost}, Radiography. p. 2022.
- [15] J.-C. Huang, Y.-C. Tsai, P.-Y. Wu, et al., -Predictive modeling of blood pressure during hemodialysis: a comparison of linear model, random forest, support vector regression, XGBoost, LASSO regression and ensemble method, Computer Methods and Programs in Biomedicine. vol. 195, p. 105536, 2020.
- [16] L. Breiman, -Random Forests, Machine Learning. vol. 45, no. 1, pp. 5–32, 2001.
- [17] F. Wang, Y. Wang, K. Zhang, M. Hu, Q. Weng, and H. Zhang, -Spatial heterogeneity modeling of water quality based on random forest regression and model interpretation, Environmental Research. vol. 202, p. 111660, 2021.
- [18] T. Boonchoo, X. Ao, Y. Liu, W. Zhao, F. Zhuang, and Q. He, -Grid-based DBSCAN: Indexing and inference, Pattern Recognition. vol. 90, pp. 271–284, 2019.
- [19] M.Z. Naser, -Mechanistically Informed Machine Learning and Artificial Intelligence in Fire Engineering and Sciences, Fire Technology. pp. 1–44, 2021.

Street Fighter için Genetik Programlama Kullanarak Yapay Oyuncu Geliştirme Creating Artificial Game Players using Genetic Programming for Street Fighter

Şevket Umut ÇAKIR¹, Vasif NABİYEYEV²

¹ Bilgisayar Mühendisliği, Pamukkale Üniversitesi, Türkiye, sucakir@pau.edu.tr
² Bilgisayar Mühendisliği, Karadeniz Teknik Üniversitesi, Türkiye, vasif@ktu.edu.tr

Özet

Günümüzde oyunlar yapay zekâ yöntemleri geliştirenler için bir kıyaslama ortamı olarak kullanılmaktadırlar. Bu çalışmada eski eğlence salonu oyunlarından olan Street Fighter oyunu için genetik programlama kullanılarak yapay oyuncular geliştirilmiştir. Oyunculara oyun hakkında çok az bilgi verilmesine rağmen oyunu başarılı bir şekilde öğrenmişler ve tüm rakipleri eleyerek oyunu bitirmişler.

Anahtar Sözcükler: *Genetik programlama; yapay oyuncu; oyun yapay zekâsı*

Abstract

Recently games are being used as a testbed for artificial intelligence algorithm developers. In this work, artificial players for an old arcade game, Street Fighter, are developed using strongly typed genetic programming. Players have successfully learned the game in despite of too little information provided to them and been able to eliminate all of the opponents and finish the game.

Keywords: *Genetic programming; artificial player; game artificial intelligence*

1. Giriş ve Amaç

Video oyunları karmaşık gerçek dünya ortamlarının eğlence amaçlı olarak basitleştirilmiş halleridir ve içlerinde birçok küçük problem bulunmaktadır. Bu problemlere çözüm üretecek yapay zekâ algoritmaları, oyunları bir test ortamı olarak kullanarak algoritmanın verimliliğine ışık tutabilir. Simülasyon imkanlarının kısıtlı olduğu gerçek dünya yerine oyun ortamlarının kullanılması, algoritmaların daha fazla örnek üzerinde test edilmesi imkanını sağlar.

Oyunlarda yapay zekâ yöntemlerinin test edilebilmesi için, Atari 2600 oyun konsolundaki oyunların bulunduğu *Arcade Learning Environment(ALE)*[1], genel yapay zekâ uygulamalarının geliştirilmesini mümkün kılan ve klasik atari oyunlarının benzerlerinden oluşturulan *GVGAI*[2], klasik pekiştirmeli öğrenme problemlerinin bulunduğu *Gym*[3] ve eski oyun konsollarındaki oyunların kullanılabilceği bir ortam olan *Gym-retro*[4] gibi platformlar oluşturulmuştur. Bu platformlar pekiştirmeli öğrenmeye uygun olarak tasarlanmıştır. Platform yapay oyuncuya, oyunun o anki durumunu sunar ve oyuncunun bir eylem gerçekleştirmesini bekler, eylem gerçekleştikten sonra oyunun yeni durumu ve ödül değerini sunar. Platformların bu özelliği oyunun yapısı hakkında ön bilgi sahibi olmadan oyunların öğrenilebilmesini mümkün kılar.

Mnih vd., derin pekiştirmeli öğrenme kullanarak, sonrasında birçok çalışmayı tetikleyen, ALE platformundaki birçok oyunda insanların elde ettiği skor değerlerini alt etmişlerdir[5]. Samothrakis vd., GVGAI platformunda nöroevrim yöntemini kullanarak on farklı oyunun sekizinde eğitimdeki başlangıç skorunu artırarak öğrenme gerçekleştirmişler[6]. Sadavarte vd., *Gym* platformundaki fizik tabanlı bir aya iniş simülasyonu için iki farklı pekiştirmeli öğrenme algoritmasının performansını karşılaştırmıştır[7].

Oyunlardaki problemleri çözmek için pekiştirmeli öğrenme yöntemlerinin yanı sıra evrimsel hesaplama algoritmaları da sıklıkla kullanılmaktadır. Alhejali ve Lucas, *Ms. Pac-Man* oyunu için genetik programlama kullanarak hayaletlerden kaçan ve elle kodlanmış yapay oyuncuları alt eden rekabetçi yapay oyuncular geliştirmişler[8]. Jia ve Ebner, *GVGAI* platformundaki üç oyun için genetik programlama kullanarak yapay oyuncular geliştirmişler ve geliştirilen oyuncuların bu üç oyunda verimli çözümler ürettiğini gözlemlemişler[9]. Kelly ve Heywood, doğrusal genetik programlama ve program çizgeleri kullanarak *ALE* platformundaki yirmi oyunun on beşinde pekiştirmeli öğrenme ve nöroevrim yöntemlerinden, yedisinde de gerçek oyunculardan daha iyi skorlar elde etmişler[10]. Reid vd., bahsedilen platformların aksine, güncel bir bilgisayar oyunu olan ve birbirine bağlantılı problemleri dengeli bir şekilde çözmeyi gerektiren, bir fabrikadaki üretimi simüle eden *Factorio* için bir ara yüz geliştirmişler ve çeşitli boyutlardaki problemleri genetik programlama, pekiştirmeli öğrenme ve benzetim tavlama gibi yöntemlerle çözmeye çalışmışlar[11]. Kelly vd., bir genetik programlama türü olan girişik program çizgelerini, görsel bir pekiştirmeli öğrenme problemi olan *VIZDoom* 'u ve zaman-serisi tahmini problemlerini çözmek için kullanmışlar[12].

Bu çalışmada Sega Mega Drive oyun konsolunda bir dövüş oyunu olan *Street Fighter II Special Champion Edition*(SF2) için kısıtlı bilgi sağlandığında yerleşik kodlamaya sahip bilgisayar oyuncuları ile dövüşebilecek genetik programlama kullanan bir yapay oyuncu gerçekleştirmek amaçlanmıştır.

2. Materyal ve Yöntem


Bu bölümde SF2 oyununun yapısı, *gym-retro* platformu ve güçlü türlü genetik programlama anlatılmaktadır.

2.1. *Street fighter* oyunu

SF2, eğlence salonlarında büyük başarı elde etmiş *Street Fighter* oyun serisinin 1993 yılında *Sega Mega Drive* oyun konsolu için çıkarttığı sürümüdür. SF2, bire bir dövüşlerin gerçekleştiği rekabetçi bir dövüş oyunudur. Oyunun vur-kır (arcade) tarzında, zorlukları giderek artan 12 rakip dövüşçü ve 3 ödül bölümü bulunmaktadır. Oyun içinden bir görüntü Şekil 1’de verilmiştir.



Şekil 1. *Street Fighter II* oyun içi görüntüsü



Şekil 2. Örnek bir ağaç yapısı

2.2. *Gym-retro* platformu

Gym-retro platformu, dokuz farklı oyun konsolunun emülatörünü barındırır ve oyunları bir pekiştirmeli öğrenme ortamına dönüştürebilir[4]. Platformdaki oyunlar kartuşlarda bulunan salt-okunur bellekteki veri ve programların emülatör üzerinde çalıştırılması ile oyun konsollarındaki gibi çalıştırılabilir. Bir konsol oyununu *gym-retro* platformuna entegre etmek için sağlanan entegre aracı ile oyunun bellek haritasından filtrelenerek bulunan çeşitli değişkenler, bir başlangıç durumu ve bitiş durumu belirlemek gereklidir. *Gym-retro* içinde birçok oyun ön tanımlı olarak entegre edilmiş biçimde gelmektedir, diğer oyunlar da entegrasyon aracı kullanılarak entegre edilebilir. Bunun yanı sıra entegrasyon aracı ile oyunun bitiş durumunu belirleyen değişkenler dışında çeşitli değişkenler de (dövüşçünün konumu, rakibin konumu, kalan sağlık miktarları gibi) oyuna dahil edilebilir ve oyunun her adımında bilgi olarak alınabilir.

2.3. Genetik programlama

Genetik programlama, fonksiyon kestirimi ve sınıflandırma gibi makine öğrenmesi problemlerine çözüm üretebilen bir evrimsel hesaplama yöntemidir[13]. Genetik programlamada popülasyonu oluşturan bireyler ağaç yapısındaki programlardır. Klasik genetik programlamada düğüm türlerinin birbirleri ile uyumlu olması gerekir, bir başka deyişle her düğümün türünün aynı olması gereklidir ki bir düğümün ürettiği değer bir başka düğüme girdi olarak verilebilsin. Güçlü türlü genetik programlamada ise düğümler farklı türlerde olabilmektedir. Bir bilgisayar programında farklı veri türlerine (boole, tam sayı vb.) ihtiyaç duymaktadır ve güçlü türlü genetik programlama kullanmak programlardaki çeşitliliği artıracaktır. Şekil 2’de SF2 oyununda eylem üretebilen güçlü türlü bir ağaç örneği verilmiştir.

Genetik programlamada bireyleri oluşturan ağaçların düğümleri; ebeveyn olan fonksiyon ve yapraklarda yer alan terminal düğümler olmak üzere iki tür bileşen içerir. Terminal düğümler boole türler ve tam sayılar gibi değerlerden oluşur. Çalışmada, terminal olarak geçici rastgele değerler ve oyunun bir anındaki değişkenler (sağlık, süre gibi) kullanılmıştır. Kullanılan fonksiyonlar, parametre türleri ve geri dönüş değerleri Tablo 1’de verilmiştir. Örneğin *if_then_else* fonksiyonu girdi olarak bir boole değer, iki tane eylem alır ve koşula bağlı olarak geriye eylemlerden bir tanesini döndürür.

Algoritma 1 Eğitim için kullanılan genetik programlama algoritması

```

1:  $\vec{P} \leftarrow$  Popülasyonu rastgele olarak başlat
2:  $\vec{f}_p \leftarrow \text{degerlendir}(\vec{P})$   $\triangleright$  Uygunluk hesapla
3: for  $g \leftarrow 1$  to  $N$  do  $\triangleright$   $N$  nesil boyunca çalışacak
4:    $\vec{y} \leftarrow \emptyset$   $\triangleright$  Yavrular, başlangıçta boş küme
5:   for  $i \leftarrow 1$  to  $\lambda$  do  $\triangleright$   $\lambda$  tane yavru üretecek
6:      $r \leftarrow [0, 1]$  arasında rastgele bir sayı
7:     if  $r \leq p_m$  then  $\triangleright$  Mutasyon olasılığı
8:        $b \leftarrow \vec{P}$ 'den rastgele 1 tane örnekle
9:        $b \leftarrow \text{mutasyon}(b)$ 
10:    else if  $r \leq p_m + p_c$  then  $\triangleright$  Çaprazlama olasılığı
11:       $b, b_2 \leftarrow \vec{P}$ 'den rastgele 2 tane örnekle
12:       $b, _ \leftarrow \text{caprazla}(b, b_2)$ 
13:    else
14:       $b \leftarrow \vec{P}$ 'den rastgele 1 tane örnekle
15:     $\vec{y} \leftarrow \vec{y} \cup b$ 
16:   $\vec{f}_y \leftarrow \text{degerlendir}(\vec{y})$   $\triangleright$  Uygunluk hesapla
17:   $\vec{P} \leftarrow \text{sec}(\vec{P} \cup \vec{y}, \vec{f}_p \cup \vec{f}_y)$   $\triangleright$  Seçme algoritması NSGA-II

```

Şekil 3. Kullanılan genetik programlama algoritması

Genetik programlamada ağaçlar oluşturulurken tüm yaprakların aynı seviyede olduğu *dolu yöntemi* veya ağaçların dengede olmadığı *büyüme yöntemi* kullanılabilir. Dolu yönteminde düğümler, ağacın en alt seviyesine ulaşana kadar fonksiyon kümesinden, en alt seviyede ise terminal kümesinden rastgele olarak seçilir. Büyüme yönteminde ise düğümler, tüm seviyelerde fonksiyon veya terminal kümesinden rastgele olarak seçilir. *Artımlı yarı yarıya yöntemi*, popülasyon oluşturulurken ağaçların yarısının dolu, diğer yarısının da büyüme yöntemi ile seçilmesidir [14].

Popülasyondaki bireylerin çözüm uzayını keşfetmesini ve iyi çözümleri sömürmesini sağlayan mutasyon ve çaprazlama çeşitlilik operatörleri bulunmaktadır. Çaprazlama işlemi iki ağaçtan rastgele olarak seçilen iki düğümün alt ağaçlarıyla birlikte yer değiştirmesi, mutasyon ise bir ağaçta rastgele seçilen bir düğümün yeni bir alt ağaçla değiştirilmesi şeklinde olur.

Seçme işlemi popülasyonun sonraki neslini belirlemek için kullanılır. Yapılan eğitimler 10 farklı başlangıç durumunu öğrenebilecek şekilde tasarlanmıştır, bu da uygunluk değerinin skaler bir değer değil de vektörel bir değer olması yol açar. Bu türdeki eğitim çok amaçlı optimizasyon olarak geçer ve buna uygun olan seçme algoritması NSGA-II kullanılmıştır [15]. Kullanılan evrimsel hesaplama algoritması Şekil 3’de verilmiştir.

2.3. Oyun modellenmesi

Gym-retro platformu oyunun herhangi bir anında ekran görüntüsünü anlık durum olarak kullanıcıya sağlar. Bunun yanı sıra oyunun bittiğini algılamak için kullanılan değişkenler de bilgi olarak sunulur. 256x200x3 boyutundaki resim girdisini işlemek zor olduğu için entegrasyon aracı yardımıyla standart değişkenlerin yanında başka değişkenler de bellek uzayından elde edilmiştir¹. SF2 oyununda tüm tuş kombinasyonları düşünüldüğünde ayrı ayrı 126 farklı eylem olabilmektedir ve bir ağacın ürettiği değer bu eylemleri gösteren bir tam sayıdır. Bir ağacın uygunluk değeri hesaplanırken, oyunun her anı için ağaca bir girdi verilir ve bir eylem elde edilir. Bu eylem *gym-retro* platformundaki oyuna gönderilip bir sonraki durum ve ödül (SF2 için skor) elde edilir. Oyun bitene kadar toplanan toplam ödül değeri (toplam skor) ağacın uygunluğunu verir.

3. Bulgular


Genetik programlama eğitim işlemi Intel Xeon E5-2620 işlemciye sahip bir bilgisayar üzerinde Python DEAP kütüphanesi kullanılarak paralel şekilde gerçekleştirilmiştir [16]. *Gym-retro* platformu deterministik olduğundan rastgele başlangıç için bir tohum değeri verilememektedir. Oyunun başlangıç durumunda eylemler hep aynı sırayla verirse aynı tepkiler elde edilecektir. Rastgele tohum değerleri vermek yerine farklı durumları ele alabilmesi için 10 farklı başlangıç durumu oluşturulmuştur. Bu durumlarda başlangıç rakipleri değişmektedir. Eğitim parametreleri Tablo 2’de verilmiştir. Bu parametrelerle başlangıç popülasyonunu çözüm uzayının farklı konumlarında oluşturmak için 4 farklı çalıştırma gerçekleştirilmiştir. En iyi skorun elde edildiği 3. çalıştırmanın eğitim grafiği Şekil 4’de verilmiştir. Bu çalıştırmadaki en iyi birey 12 rakibin tamamını eleyip oyunu bitirmiş ve

¹ Kullanılan değişkenler: sağlık, düşman sağlığı, dövüşçüler arası yatay ve dikey uzaklık, kalan süre, çerçeve ve son eylem

Tablo 1. Genetik programlama fonksiyon türleri

Fonksiyonlar	Açıklama	Parametreler	Dönüş değeri
main	Kök fonksiyonu	int, int, int, int, int, int, Action	Action
Action	Eylem türü	int	Action
if_then_else	Koşul	bool, Action, Action	Action
lt, eq	Karşılaştırma operatörü	int, int	bool
add, sub, mul, mod	Aritmetik operatörler	int, int	int
and, or	Mantıksal op.	bool, bool	bool
not	Mantıksal değil op.	bool	bool

530000 skor elde etmiştir. 4 farklı çalıştırma için elde edilen eğitim sonuçları Tablo 3’de verilmiştir. Buna göre en iyi sonuçlar 2. çalıştırmada elde edilmiştir.



Şekil 4. 10 farklı başlangıç durumu için eğitim grafiği

Tablo 2. Genetik programlama parametreleri

Parametre	Değer
Popülasyon boyutu	300
Çaprazlama olasılığı(p_c)	0.5
Mutasyon olasılığı(p_m)	0.1
Popülasyon başlatma	Artımlı yarı yarıya
Seçme algoritması	NSGA-II
Seçme süreci	$(\mu + \lambda)$
Maksimum derinlik	17

Tablo 3. Eğitim sonuçları, $\mu_1(\sigma)$: durumlardaki en iyi bireylerin skorlarının ortalaması ve standart sapması, μ_2 : ortalaması en iyi bireyin ortalama skoru

Çalıştırma	Nesil	Süre(saat)	$\mu_1(\sigma)$	μ_2
1	50	29.41	332070(± 44744)	168920
2	100	82.61	453240(± 33773)	227800
3	100	49.26	339530(± 79059)	149370
4	100	39.48	358050(± 358050)	169880

4. Sonuçlar ve Tartışma

Bu çalışmada genetik programlama kullanarak SF2 oyunu için yapay oyuncular geliştirilmiştir. Oyuncular kendilerine sağlanan kısıtlı bilgilere rağmen oyunu başarı ile bitirebilmiştir. SF2 oyunundaki başarıyı karşılaştıracak bir başka çalışma bulunmamaktadır ama SF2 oyununda elde edilebilecek en yüksek skor 1.55 milyondur. Bu skorun yaklaşık üçte birini alarak oyunu bitirebilen bir oyuncu başarılı sayılabilir. Oluşturulan yapı sadece SF2 oyununa özgü değildir, pekiştirmeli öğrenme ortamı ve değişkenleri sağlayan her oyuna uygulanabilir.

Eğitim süreleri çalışmada kullanılacak parametrelerde bir kısıt oluşturmaktadır. Yöntemin makul sürelerde sonuç üretmesini sağlamak amacıyla popülasyon boyutu ve eğitim adım sayısı kısıtlanmıştır. Adım sayısını artırmak eğitim sonuçlarını iyileştirebilir. Genetik programlamada mutasyon genellikle önerilmemektedir ya da olasılığının düşük olması beklenir[13], bu nedenle mutasyon olasılığı düşük tutulmuştur. Belirsiz oyunlarda olası sonuçların tahmini için başka bir alternatif olarak Monte Carlo simülasyonu kullanılabilir.

Referanslar

- [1] M. G. Bellemare, Y. Naddaf, J. Veness, and M. Bowling, "The Arcade Learning Environment: An Evaluation Platform for General Agents," *J. Artif. Intell. Res.*, vol. 47, pp. 253–279, 2013.
- [2] D. Perez-Liebana, J. Liu, A. Khalifa, R. D. Gaina, J. Togelius, and S. M. Lucas, "General Video Game AI: a Multi-Track Framework for Evaluating Agents, Games and Content Generation Algorithms," Feb. 2018.
- [3] G. Brockman *et al.*, "OpenAI Gym," *CoRR*, vol. abs/1606.0, 2016.
- [4] A. Nichol, V. Pfau, C. Hesse, O. Klimov, and J. Schulman, "Gotta Learn Fast: A New Benchmark for Generalization in RL," Apr. 2018.
- [5] V. Mnih *et al.*, "Human-level control through deep reinforcement learning," *Nature*, vol. 518, 2015.
- [6] S. Samothrakis, D. Perez-Liebana, S. M. Lucas, and M. Fasli, "Neuroevolution for General Video Game Playing," in *2015 IEEE Conference on Computational Intelligence and Games (CIG)*, 2015, pp. 200–207.
- [7] R. S. Sadavarte, R. Raj, and B. Sathish Babu, "Solving the Lunar Lander Problem using Reinforcement Learning," in *2021 IEEE International Conference on Computation System and Information Technology for Sustainable Solutions (CSITSS)*, 2021, pp. 1–6.
- [8] A. M. Alhejali and S. M. Lucas, "Evolving diverse Ms. Pac-Man playing agents using genetic programming," in *2010 UK Workshop on Computational Intelligence (UKCI)*, 2010, pp. 1–6.
- [9] B. Jia and M. Ebner, "A strongly typed GP-based video game player," in *2015 IEEE Conference on Computational Intelligence and Games (CIG)*, 2015, pp. 299–305.
- [10] S. Kelly and M. I. Heywood, "Emergent Tangled Graph Representations for Atari Game Playing Agents," in *Genetic Programming*, 2017, pp. 64–79.
- [11] K. N. Reid, I. Miralavy, S. Kelly, W. Banzhaf, and C. Gondro, "The factory must grow," in *Proceedings of the Genetic and Evolutionary Computation Conference Companion*, 2021, pp. 243–244.
- [12] S. Kelly, R. J. Smith, M. I. Heywood, W. Banzhaf, ; R J Smith, and M. I. Heywood, "Emergent Tangled Program Graphs in Partially Observable Recursive Forecasting and ViZDoom Navigation Tasks," *ACM Trans. Evol. Learn. Optim.*, vol. 1, no. 3, pp. 1–41, Aug. 2021.

- [13] J. R. Koza, *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. Cambridge, MA, USA: MIT Press, 1992.
- [14] R. Poli, W. B. Langdon, and N. F. McPhee, *A Field Guide to Genetic Programming*, no. March. Lulu Enterprises, UK Ltd, 2008.
- [15] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," *IEEE Trans. Evol. Comput.*, vol. 6, no. 2, pp. 182–197, Apr. 2002.
- [16] F.-A. Fortin, F.-M. De Rainville, M.-A. Gardner, M. Parizeau, and C. Gagné, "DEAP: Evolutionary Algorithms Made Easy," *J. Mach. Learn. Res.*, vol. 13, pp. 2171–2175, Jul. 2012.

Machine Learning Based WLAN Antenna Design For 5.2 GHz Frequency Band

Ekrem Akar ¹,

¹ Electrical and Electronics Engineering, Izmir Katip Celebi University, Turkey, sekremakar@gmail.com

Abstract

Today, wireless internet access provides serious convenience. Wi-Fi is a new generation wireless networking technology. This technology provides high-speed, broadband access over a larger area. Wi-Fi technology, which is currently used to offer wireless internet access, works at a range of 30 m to 100 m and is based on the IEEE 802.11 standard. The aim behind machine learning is to create general algorithms that can tell important things about a dataset without requiring to write code. Machine learning aims to make predictions based on known properties from learnt data. In this paper 0.33 of all datasets is taken for making predictions. There are 448 iterations of 3 parameters. With using them machine learning test and train data. The FR-4 substrate with a dielectric coefficient of 4.3 is utilized in this antenna design. Copper has been utilized as the material for the ground and patch components. 5.2 GHz working frequency, the return loss is 31.24 dB, bandwidth range is 4.88-5.38, gain is 0.798 dBi. In order to find the best values required for this antenna, machine learning and artificial intelligence method has been applied.

Keywords: *Antenna Design; WLANs; Wireless; Machine Learning; Microstrip*

1. Introduction

With the development of modern communication systems for the Wireless Local Area Network (WLAN), the microwave components that have been dedicated to this technological field have been introduced as improved alternative designs to the conventional microwave components [1-4]. Wi-Fi has been designed to offer wireless high-speed internet [5]. It's been aimed to provide wireless connection within a short distance, in small public areas such as home, office, and cafeteria. Attempts have been made to expand the area and even make it usable across a city. However, to achieve this, hundreds of radio stations are needed for even a few kilometers of coverage. This results in an incredible increase in the cost of the paper [6].

Machine learning, which allows digital assistants like Siri to infiltrate lives, is a semi of computer science that is born out of numerical learning and pattern recognition research in artificial intelligence in 1959 [7]. Machine learning is a system that looks at the research and development of algorithms that can learn as a structural function and make data predictions [8]. Rather than rigidly obeying static program instructions, such algorithms build a model to generate data-based predictions and judgments from sample inputs [9]. There are five primary branches of machine learning research. Supervised learning, unsupervised learning, semi-supervised learning, reinforcement learning, and intensive learning are the different types of learning. The machine learning algorithm's learning mechanism is broken down into three pieces. The choice process, the error function, and the optimization process are the three of them. Zhang et al have been worked on 2.4 and 5.2 and 60 GHz frequency values [10]. By the way its gains are 1.9 dBi for 2.4 GHz 2.4 dBi for 5.2 GHz frequency and 16 dBi for 60 GHz. Wang et al have been worked on 2.4 and 5.2 and 5.8 GHz and 60 GHz frequency values [11]. By the way its gains are 0 dBi for 2.4 GHz 2.5 dBi for 5.2 GHz frequency and 2.5 dBi for 5.8 GHz and 6 dBi for 60 GHz frequency. Sun et al have been worked on 2.4 and 5.2 and 5.8 GHz frequency values [12]. By the way its gains are 1.66 dBi for 2.4 GHz 4.75 dBi for 5.2 GHz frequency and 5.1 dBi for 5.8 GHz. Deng et al have been worked on 2.4 and 3 and 3.5 GHz frequency values [13]. By the way its gains are 1 dBi for 2.4 GHz 2 dBi for 3 GHz frequency and 2.5 dBi for 3.5 GHz. Ding et al have been worked on 2.4 and 5.2 and 60 GHz frequency values [14]. By the way its gains are 3.97 dBi for 2.4 GHz 4.07 dBi for 5.2 GHz frequency and 12.29 dBi for 60 GHz.

The paper has been structured as follows. In section 2, a discussion will be made about the design of the designed antenna, its dimensions, feeding methods, and the preferred application for simulation. In section 3, simulation results of the design antenna are presented. In section 4, the general summary of the study has been explained.

2. Material and Method

2.1 Design of Antenna

Figure 1 depicts the general design of the Wi-Fi antenna. The size of the antenna parameters are shown in the Figure 1.




Figure 1: Proposed Antenna Design

When building a micro-strip antenna, there are three key components to consider. Patch – Substrate – Ground. The ground layer, also known as the conducting layer, is created initially when creating an antenna. Copper is used as the antenna's ground material, and it has a thickness of 0.035 mm. This layer must be electrically conductive. The substrate layer is the second layer. For this layer, the material FR4 is used. It has a dielectric coefficient of 4.3 and is 1.6 mm thick. In most antenna designs, FR4 material is employed. The patch layer is the other layer. The patch layer is the one that the antenna radiates from. This component must be conductive. Copper has been chosen because it has been regarded as acceptable. It has a thickness of 0.035 mm.

3. Findings

In Table 1, it has been observed that regression types and their mean square errors and R^2 values. Table 2 shows that machine learning results from using Python. It can be seen that random forest regression has been determined as the best value. P1 is the variation in the vertical length of the slot located at the rear. P2 is the change of feed line length. P3 is the vertical change of the slot on the upper part of the front. For the values of P1 is 0, P2 is 1, and P3 is 1, these values are the best values which give the most correct antenna return loss value. By the way, it can be predicted values outside of the database. Machine learning algorithm takes values from the database and makes predictions with using them. 0.33 of the database is used for training the set.

Polynomial linear regression, random forest regression, SVR and KNN, which are regression types in machine learning, are discussed.

Table 1: Regressions and MSE- R^2 Values

	Mean Square Error	R^2
POLYNOMIAL LINEAR REGRESSION	42.48	0.47
RANDOM FOREST REGRESSION	0.0025	0.999
SVR	48.85	0.40
KNN	18.48	0.77

Table 2: Machine Learning the Best Results

P1	0
P2	1
P3	1
POLYNOMIAL LINEAR REGRESSION	-29.48
RANDOM FOREST REGRESSION	-31.12
SVR	-3.43
KNN	-21.64

Machine learning algorithms are like brains for computers, allowing them to learn and become smarter. More data implies more algorithms have been activated, causing the computer to learn and improve its output. If the prediction does not turn out as predicts, the algorithm has been retrained until the intends result has been obtained. This enable the machine learning algorithm to train on its own and deliver the best possible response, which will improve in accuracy over time. Figure 2a shows the S parameter value of the antenna. 31.24 dB return loss have been determined in the range of 4.89-5.38. Figure 2b shows that radiation pattern of proposed antenna with 0.798 dBi gain value. Table 3 shows some selects machine learning assists antenna designs in the literature has been based on antenna type, algorithm, has been compared type and result section.




Figure 2: S Parameter and radiation pattern of proposed antenna

Table 3: Literature Review for machine learning assisted antenna designs

REF NO	ANTENNA TYPE	ALGORITHM	COMPARED	RESULT
15	Reflectarrays	SVM	MoM&ANN	Design process is sped up while keeping high accuracy levels.
16	Rectangular Microstrip Antenna	SVM	ANN	With a quicker convergence rate, the calculation efficiency improves.
17	E-Shaped Antenna	Linear Regression	Conventional Simulations	The best outcomes discovered without the use of any simulations.
18	Microstrip Antenna	Gaussian Process ML	Differential Evolution	The speed of the design and optimization procedure by more than four times compared with differential evolution

4. Results

As a consequence, in terms of both aesthetics and efficiency, this 5.2 GHz antenna is one step ahead of its competitors on the market. Because of its efficient functioning in the range of 4.89-5.38 and inexpensive cost, it is more suiter than its competitors. By the way, the return loss is 31.24 dB and gain value is 0.798 dBi. Because this product is already expensive, an antenna that is less expensive in terms of pricing is built with a

smaller surface area rather than a higher gain in this sort of antenna. The s parameter graph of the antenna obtains by trying 448 iterations of 3 parameters. Then it inserts into machine learning and the best value, Random Forest Regression, have been observed.

Acknowledgements

This study has been carried out using the laboratory facilities of İzmir Katip Celebi University Smart Factory Systems Application and Research Center (AFSUAM).

References

- [1] Montero-de-Paz, et.al. (2013). Compact modules for wireless communication systems in the E-band (71–76 GHz). *Journal of Infrared, Millimeter, and Terahertz Waves*, 34(3), 251-266.
- [2] Rymanov, V., Palandöken, M., Lutzmann, S., Bouhlal, B., Tekin, T., & Stöhr, A. (2012, September). Integrated photonic 71–76 GHz transmitter module employing high linearity double mushroom-type 1.55 μm waveguide photodiodes. In 2012 IEEE International Topical Meeting on Microwave Photonics (pp. 253-256). IEEE.
- [3] Palandöken, M., Rymanov, V., Stöhr, A., & Tekin, T. (2012, August). Compact metamaterial-based bias tee design for 1.55 μm waveguide-photodiode based 71–76GHz wireless transmitter. In Progress in Electromagnetics Research Symposium, PIERS..
- [4] Palandöken, M., & Sondas, A. (2014). Compact Metamaterial Based Bandstop Filter. *Microwave Journal*, 57(10).
- [5] BAYTÖRE, C., GÖÇEN, C., PALANDÖKEN, M., Kaya, A., & ZORAL, E. Y. (2019). Compact metal-plate slotted WLAN-WIMAX antenna design with USB Wi-Fi adapter application. *Turkish Journal of Electrical Engineering & Computer Sciences*, 27(6), 4403-4417.
- [6] Demirbas, G. & Akar, E. (2022). Design and Interpretation of Microstrip Patch Antenna Operating at 2.4GHz for Wireless WI-FI Application. *Avrupa Bilim ve Teknoloji Dergisi* , Ejosat Special Issue 2022 (ICAENS-1) , 672-675 . DOI: 10.31590/ejosat.1084151
- [7] Akar, E., Akdag, I., & Gocen, C. (2022). Wi-Fi Antenna Design For E-Health Kit Based Biotelemetry Module. *ICONTECH INTERNATIONAL JOURNAL*, 6(1), 63-67. <https://doi.org/10.46291/ICONTECHvol6iss1pp63-67>
- [8] Demirbas, G., Gocen, C., & Akdag, I. (2022). Micro-strip Patch 2.4 GHz Wi-Fi Antenna Design For WLAN 4G- 5G Application . *ICONTECH INTERNATIONAL JOURNAL*, 6(1), 68-72. <https://doi.org/10.46291/ICONTECHvol6iss1pp68-72>
- [9] Gocen, C., & Palandoken, M. (2021). Machine Learning Assisted Novel Microwave Sensor Design for Dielectric Parameter Characterization of Water-Ethanol Mixture. *IEEE Sensors Journal*.
- [10] Zhang, L., See, K. Y., Zhang, B., & Zhang, Y. P. (2012). Integration of dual-band monopole and microstrip grid array for single-chip tri-band application. *IEEE transactions on antennas and propagation*, 61(1), 439-443.
- [11] Wang, D., & Chan, C. H. (2015). Multiband antenna for WiFi and WiGig communications. *IEEE antennas and wireless propagation letters*, 15, 309-312.
- [12] Sun, X. L., Liu, L., Cheung, S. W., & Yuk, T. I. (2012). Dual-band antenna with compact radiator for 2.4/5.2/5.8 GHz WLAN applications. *IEEE transactions on Antennas and Propagation*, 60(12), 5924-5931.
- [13] Deng, J., Li, J., Zhao, L., & Guo, L. (2017). A dual-band inverted-F MIMO antenna with enhanced isolation for WLAN applications. *IEEE Antennas and Wireless Propagation Letters*, 16, 2270-2273.
- [14] Ding, Y. R., & Cheng, Y. J. (2019). A tri-band shared-aperture antenna for (2.4, 5.2) GHz Wi-Fi application with MIMO function and 60 GHz Wi-Gig application with beam-scanning function. *IEEE Transactions on Antennas and Propagation*, 68(3), 1973-1981.
- [15] Prado, D. R., López-Fernández, J. A., Arrebola, M., & Goussetis, G. (2018, September). Efficient shaped-beam reflectarray design using machine learning techniques. In 2018 48th European Microwave Conference (EuMC) (pp. 1545-1548). IEEE.
- [16] Tokan, N. T., & Gunes, F. (2008). Support vector characterisation of the microstrip antennas based on measurements. *Progress In Electromagnetics Research B*, 5, 49-61.
- [17] Silva, C. R., & Martins, S. R. (2013). An adaptive evolutionary algorithm for UWB microstrip antennas optimization using a machine learning technique. *Microwave and Optical Technology Letters*, 55(8), 1864-1868.
- [18] Liu, B., Aliakbarian, H., Ma, Z., Vandenbosch, G. A., Gielen, G., & Excell, P. (2013). An efficient method for antenna design optimization based on evolutionary computation and machine learning techniques. *IEEE transactions on antennas and propagation*, 62(1), 7-18.