



ÇUKUROVA ÜNİVERSİTESİ
MÜHENDİSLİK FAKÜLTESİ
DERGİSİ

CUKUROVA UNIVERSITY
JOURNAL OF THE FACULTY OF ENGINEERING

Cilt/Vol: 39

Sayı/Issue: 2

Haziran/June 2024

ISSN 2757-9255



ÇUKUROVA ÜNİVERSİTESİ
MÜHENDİSLİK FAKÜLTESİ DERGİSİ
Cukurova University,
Journal of the Faculty of Engineering



Sahibi (Owner)

Ali KESKİN

Ç.Ü. Mühendislik Fakültesi Dekanı

Editör (Editor)

Serin MEZARCIÖZ

EDİTÖR KURULU (Editorial Board)

Ali KESKİN (Çukurova Üniversitesi)
Umur ORHAN (Çukurova Üniversitesi)
Mutlu AVCI (Çukurova Üniversitesi)
Mustafa GÖK (Çukurova Üniversitesi)
Hüseyin VAPUR (Çukurova Üniversitesi)
Hüseyin AKILLI (Çukurova Üniversitesi)
Ulus ÇEVİK (Çukurova Üniversitesi)
Ali KOKANGÜL (Çukurova Üniversitesi)
Mesut BAŞIBÜYÜK (Çukurova Üniversitesi)
Hacı Murat ARSLAN (Çukurova Üniversitesi)
Oğuz DEMİRYÜREK (Erciyes Üniversitesi)
Hüsamettin BULUT (Harran Üniversitesi)
Metin GÜRÜ (Gazi Üniversitesi)
Mehmet Emin AYDIN (University of the
West of England, İngiltere)
Azra BİLGİN (University of Colorado Boulder,
ABD)

Serin MEZARCIÖZ (Çukurova Üniversitesi)
Hasan ÇETİN (Çukurova Üniversitesi)
Özen KILIÇ (Çukurova Üniversitesi)
Hüseyin ERTEN (Çukurova Üniversitesi)
Belgin BAYAT (Çukurova Üniversitesi)
Mustafa ÖZCANLI (Çukurova Üniversitesi)
R. Tuğrul OĞULATA (Çukurova Üniversitesi)
Onur ERMAN (Çukurova Üniversitesi)
Yusuf KUVVETLİ (Çukurova Üniversitesi)
Hüseyin R. YERLİ (Çukurova Üniversitesi)
Ergun ERÇELEBİ (Gaziantep Üniversitesi)
Nihan ÇETİN DEMİREL (Yıldız Teknik Üniversitesi)
Serter ATABAY (American University of Sharjah,
United Arab Emirates)
Muammer KOÇ (Hamad Bin Khalifa University,
Qatar)
Tamio ENDO (Mie University-Japonya)

Hakemli Bir Dergidir. Yılda Dört Sayı Basılır. / Refereed Journal. Published Quarterly.

Dergimiz TÜBİTAK ULAKBİM Mühendislik ve Temel Bilimler Veri Tabanı Listesi'nde taranmaktadır.
Indexed by TÜBİTAK ULAKBİM Mühendislik ve Temel Bilimler Veri Tabanı Listesi

Derginin eski adı: Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi
(ISSN: 1019-1011)

YAZIŞMA ADRESİ/CONTACT

Ç.Ü. Mühendislik Fakültesi Dergi ve Yayın Kurulu Başkanlığı Balcalı 01330 Sarıçam/ADANA
Tel : (322) 338 63 57 – (322) 338 70 50 E-posta: cu.mmfergi@gmail.com

AMAÇ ve KAPSAM

Çukurova Üniversitesi Mühendislik Fakültesi Dergisi, yılda dört sayı olarak yayımlanan hakemli bilimsel bir dergidir. Mühendislik alanındaki gelişmeleri takip etmek, meslek kuruluşları ve bireylerin ulusal ve uluslararası gelişimlerine katkıda bulunmak ve bu alanlarda Türkçe bir kaynak oluşturmak amacıyla yayımlanmaktadır. Derginin yazım dili Türkçe/İngilizcedir. Daha önce başka bir yerde yayımlanmamış tüm özgün ve güncel bilimsel araştırma ve uygulamaları kapsayan makaleler kabul edilmektedir. Tüm mühendislik alanları ile ilgili teorik/deneysel ve uygulamaya yönelik çalışmalar Dergi'nin ilgi alanındadır. Çeviri ve derleme makaleler kabul edilmemektedir. **“Araştırma ve uygulama içeren makaleleri”** yayımlanmaktadır.

AIM and SCOPE

Journal of the Engineering Faculty of Cukurova University is a peer-reviewed scientific journal which is currently published quarterly. The journal is published to follow the developments in the field of engineering, to contribute to the national and international development of professional organizations and individuals, and to create a Turkish resource in these areas. The language of the journal is Turkish/English. All original and up to date scientific research and applications articles that have not been published elsewhere are accepted. Theoretical/experimental and practical studies related to all engineering fields are in the scope of the Journal. Translation and compilation articles are not accepted. The journal publishes **“articles of research and practice”**.

İÇİNDEKİLER/CONTENTS

- Wind Speed Prediction Using Deep Recurrent Neural Networks and Farm Platform Features for One-Hour-Ahead Forecast 287**
Derin Tekrarlayan Sinir Ağları ve Çiftlik Platformu Özellikleri Kullanılarak Bir Saat Önceden Rüzgâr Hızı Tahmini
Emre ÖZBİLGE ve Yönel KIRSAL
- Compressive Performance of the PVC Foam Materials used as Sandwich Panel Core 301**
Sandviç Panellerde Çekirdek Malzeme Olarak Kullanılan PVC Köpük Malzemelerin Basınç Yüklerine Karşı Performansı
Ahmet ÇETİN ve Necdet GEREN
- Araçlarda CO₂ Emisyonlarının Farklı Yapay Sinir Ağı Modelleri Kullanılarak Tahminlerinin Karşılaştırılması 309**
Comparison of CO₂ Emissions Prediction in Vehicles Using Different Artificial Neural Network Models
Emrah ASLAN
- AI-Based Model Design for Prediction of COPD Grade from Chest X-Ray Images: A Model Proposal (COPD-GradeNet)..... 325**
Akciğer Grafilerinden KOAH Derecesinin Tahmin Edilmesi için Yapay Zeka Temelli Model Tasarımı: Bir Model Önerisi (COPD-GradeNet)
Serdar ABUT
- Preparation and NO_x Reduction Performance of Ag-Ni-TiO₂/Cordierite Catalyst for HC-SCR System 339**
HC-SCR Sistemi için Ag-Ni-TiO₂/Kordiyerit Katalizörünün Hazırlanması ve NO_x İndirgeme Performansı
Himmet ÖZARSLAN
- Kastabala Antik Kentinde Kullanılan Kayaç Türleri ve Petrografik Özellikleri 349**
Rock Types Used in the Ancient City of Kastabala and Petrographic Features
Mustafa AKYILDIZ, Emrah ŞİMŞEK ve Faris DEMİR

İÇİNDEKİLER/CONTENTS

Artificial Intelligence Predictions of Biomass Power of an Installed Waste Water Treatment Plant	359
<i>Biokütle Tipi Kurulu Atık Su Arıtma Tesisinin Enerji Geri Kazanım Analizi</i>	
Akın İLHAN	
Çok Kriterli Karar Verme Yöntemleri ile Yeni Otobüs Tasarımında Koltuk Modeli Seçimi	375
<i>Multi Criteria Making Methods Approach to Seat Model Selection in Design of New Bus</i>	
Merve ÖZMEN ve Z. Figen ANTMEN	
Toprak Mikrobiyoloji Laboratuvarlarında Güvenlik Önlemlerine göre Tehlikelerin Sıralanması.....	385
<i>Ranking of Hazards According to Safety Precautions in Soil Microbiology Laboratories</i>	
Melek IŞIK	
Kar Erime Optimizasyonu Algoritması ile Çok Katmanlı Yapay Sinir Ağının Eğitimi	391
<i>Training of Multilayer Artificial Neural Network with Snow Ablation Optimizer Algorithm</i>	
Feyza Nur ÖZDEMİR ve Ahmet ÖZKİŞ	
Effects of Adding Pectin to Milk in Varying Amounts on the Rheological Properties of Milk	407
<i>Değişen Miktarlarda Pektinin Süte Eklenmesinin Sütün Reolojik Özelliklerine Etkisi</i>	
Veli ÖZBOLAT	
Kompakt Penye İplik Üretiminde Kopça Türünün İplik Kalitesine ve Kopça Ömrüne Etkileri	415
<i>Effects of Traveller Type on Yarn Quality and Traveller's Life Time in the Spinning of Compact Combed Yarn</i>	
Pınar DURU BAYKAL ve Özgür AKBAŞ	
Yoğun Bakım Ünitesinde Hasta Kalış Süresinin Karma Dağılım ile Modellenmesi.....	427
<i>Modeling the Length of Stay in the Intensive Care Unit by Using Mixture Distribution</i>	
Selin SARAÇ GÜLERYÜZ	

İÇİNDEKİLER/CONTENTS

Using Bigdata for Choosing the Right Forecasting Method, Dataset and Period in a Time Series Analysis	437
<i>Zaman Serisi Analizinde Doğru Tahmin Yöntemini, Veri Kümesini ve Dönemi Seçmek İçin Büyük Veriyi Kullanma</i>	
Serap AKCAN, Murat AKCIL ve Metin ÖZŞAHİN	
Türkiye'deki Depreme Dayanıklı Çelik Çerçevesi Bina Tasarımına Retrospektif Bir Bakış.....	453
<i>A Retrospective View on Earthquake Resistant Design of The Steel Frame Structures in Türkiye</i>	
Altan ZERVENT, Ömer Burak YÜCEL, Alper ALDEMİR ve Barış ERDİL	
Doğaltaş Madencilğinde Ocak-Fabrika Ortamında Titreşim ve Gürültü Maruziyetinin Araştırılması.....	467
<i>Investigation of Vibration and Noise Exposure in the Quarry-Factory Environment in Natural Stone Mining</i>	
Ali Ekrem ARITAN ve Muhammed Fatih CAN	
Comparison of Random Forest and Support Vector Regression Models in Predicting Hydrogen Production Process from Biomass.....	475
<i>Biyokütleden Hidrojen Üretiminde Rastgele Orman ve Destek Vektör Regresyon Modellerinin Kıyaslaması</i>	
Gülbahar BİLGİÇ ve Ali Emre GÖK	
A Comparative Study on Data Balancing Methods for Alzheimer's Disease Classification.....	489
<i>Alzheimer Hastalığı Sınıflandırması için Veri Dengeleme Yöntemlerinin Karşılaştırmalı Bir Çalışması</i>	
Esmâ ÖTER ve Yahya DOĞAN	
Yanmış Orman Alanlarının Uzaktan Algılama Teknikleri ile Araştırılması: Kozan Orman Yangını Örneği.....	503
<i>Investigation of Burned Forest Areas Using Remote Sensing Techniques: The Case of Kozan Forest Fire</i>	
Sevim Yasemin ÇİÇEKLİ	
Pamuklu İpliklerin Köpük Aplikasyon Metodu Kullanılarak İndigo Boyarmadde ile Boyanması.....	515
<i>Dyeing of Cotton Yarns with Indigo Dyestuff Using the Foam Application Method</i>	
Siddik YAVUZ ve Onur BALCI	

İÇİNDEKİLER/CONTENTS

Bir Firmanın Belirsizlik Altında Sürdürülebilirlik Performansının Değerlendirilmesi: Bulanık AHP Yaklaşımı.....	527
<i>Assessment of a Company's Sustainability Performance Under Uncertainty: Fuzzy AHP Approach</i>	
Kübra TÜMAY ATEŞ	
An ERP Based Industry 4.0 Maturity Model Proposal	535
<i>ERP Tabanlı Endüstri 4.0 Olgunluk Modeli Önerisi</i>	
Kerem ELİBAL, Eren ÖZCEYLAN ve Cihan ÇETİNKAYA	
A Numerical Modelling of V-Bending	545
<i>V- Bükmenin Sayısal Modellenmesi</i>	
Ergin KOSA	
MR Görüntülerinden Alzheimer Hastalığının Sınıflandırılması için Inception ve Sıkma-Uyarma Ağı Tabanlı Derin Öğrenme Modeli.....	555
<i>Inception and Squeeze-Excitation Network Based Deep Learning Model for Classification of Alzheimer's Disease from MRI Images</i>	
Hüseyin FIRAT ve Hüseyin ÜZEN	
Natural Dyeing of Cotton, Wool and Viscose Fabrics with Sodium Copper Chlorophyllin	569
<i>Pamuk, Yün ve Viskon Kumaşların Sodyum Bakır Klorofil ile Doğal Boyanması</i>	
Gamze GÜLŞEN BAKICI ve Deniz Mutlu ALA	

Wind Speed Prediction Using Deep Recurrent Neural Networks and Farm Platform Features for One-Hour-Ahead Forecast

Emre ÖZBİLGE¹ ORCID 0000-0002-2295-752X
Yönel KIRSAL^{*2} ORCID 0000-0001-7031-1339

¹Cyprus International University, Faculty of Engineering, Software Engineering Department, TRNC

²European University of Lefke, Faculty of Engineering, Electrical and Electronics Engineering Department, TRNC

Geliş tarihi: 11.01.2024 Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ÖZBİLGE, E., KIRSAL, Y., (2024). Wind Speed Prediction Using Deep Recurrent Neural Networks and Farm Platform Features for One-Hour-Ahead Forecast. Cukurova University, Journal of the Faculty of Engineering, 39(2), 287-300.

Abstract

This paper proposes a deep recurrent neural network (DRNN) approach to model the one-hour-ahead wind speed forecasting by using various meteorological sensory data from the North Wyke farm platform (NWFP). To refine model input, mutual information analysis is applied to eliminate irrelevant sensory data. The DRNN architecture employs three recurrent layers Long-Short Term Memory (LSTM), Gated Recurrent Unit (GRU), and simple Recurrent Neural Network (RNN) to capture temporal relationships. The proposed networks are tested using real-life, one-year data from the NWFP. The results showed a strong correlation between the actual and predicted wind speed for LSTM, GRU, and RNN layers-based DRNN, however, simple RNN slightly outperformed the other two recurrent layers. The distribution of the network errors over the year is also analyzed. Although the observed meteorological data between the years was from different distributions, the proposed network generalized well even though these data were altered due to global warming.

Keywords: Wind speed prediction, Deep recurrent neural network, Intelligent systems, Time-series prediction, Feature selection

Derin Tekrarlayan Sinir Ağları ve Çiftlik Platformu Özellikleri Kullanılarak Bir Saat Önceden Rüzgâr Hızı Tahmini

Öz

Bu makale, Kuzey Wyke çiftliği platformundan (NWFP) çeşitli meteorolojik veriler kullanarak bir saat öncesine yönelik rüzgâr hızı tahmini modellemek için derin tekrarlı sinir ağı (DRNN) yaklaşımını önermektedir. Model girişini iyileştirmek için karşılıklı bilgi analizi kullanılarak ilgisi olmayan veriler elenmiştir. DRNN mimarisi, zamansal ilişkileri yakalamak üzere üç tekrarlı katmanı içerir: Uzun Kısa Vadeli Bellek (LSTM), Kapılı Tekrarlı Birim (GRU) ve basit Tekrarlı Sinir Ağı (RNN). Önerilen ağlar,

*Sorumlu yazar (Corresponding Author): Yönel KIRSAL, ykirsal@eul.edu.tr

NWFP'den gerçek zamanlı, bir yıllık veri kullanılarak test edilmiştir. Sonuçlar, LSTM, GRU ve basit RNN katmanları temelli DRNN için gerçek ve tahmin edilen rüzgâr hızı arasında güçlü bir korelasyon olduğunu göstermiştir; ancak basit RNN, diğer iki tekrarlı katmandan biraz daha iyi performans sergilemiştir. Ayrıca, ağ hatalarının yıl boyunca dağılımı analiz edilmiştir. Gözlemlenen meteorolojik verilerin yıllar arasında farklı dağılımlardan olmasına rağmen, önerilen ağ, bu veriler küresel ısınma nedeniyle değişmiş olsa bile iyi genelleme yapmıştır.

Anahtar Kelimeler: Rüzgâr hızı tahmini, Derin tekrarlayan sinir ağı, Akıllı sistemler, Zaman serisi tahmini, Özellik seçimi

1. INTRODUCTION

Analysis of meteorological variables and weather forecasts is important for clean and renewable energy sources. Wind energy is a significant part of renewable energy and the most promising one among renewable energy sources globally [1]. The prediction of wind speed is an essential feature in terms of wind power generation, agricultural areas, ship route planning, etc. In addition, predicting wind speed is a very important parameter for estimating the energy expected to be produced from wind turbines in the short and long terms. Based on these estimation values, the profitability of power generation plants can also be calculated. Moreover, the agriculture farm platform can be organized according to whether it is profitable to invest in wind energy in a specific region. The accuracy of short-and long-term wind power generation is also of great importance in balancing electricity generation using different resources [2, 3].

Continuous and strong wind speeds are required for the uninterrupted and high-quality electricity generation of wind turbines. However, the chaotic nature and dynamic uncertainty of the wind pose a major obstacle to wind speed prediction. Despite this chaotic structure and uncertainty, there are many methods developed for making predictions in the literature. Wind speed prediction tools are widely categorized into the physics-based model, the statistical-based model, and the hybrid prediction model [4]. The physical-based models require a firm theoretical background, many equations, and a high computational cost. Hence, the physical-based models are widely used in practice [5]. On the other hand, the statistical-based models perform better than the physical-based models in wind speed forecasting [6]. However,

researchers develop statistical-based models for evaluating time series to minimize the error in estimation methods, and they also work on artificial intelligence (AI) methods for prediction. The hybrid prediction model is a combination of both adaptive structure and AI methods.

Hybrid methods achieve better accuracy and better wind prediction results compared to other individual models [7]. AI approaches are the most commonly used methods to predict wind speed based on various data in the literature [8, 9]. The main reason is that these methods can adapt themselves rapidly and accurately to changing trends within the datasets. In addition, AI approaches obtain high precision and better performance output measurements. They also produce algorithms based on input data rather than using a generalized model. Thus, to achieve better accuracy and good wind prediction results, AI models should be considered for such analysis. The artificial neural network (ANN) [10], support vector machines (SVM) [11], fuzzy logic [12], the classification algorithms of random forest (RF) [13], extreme learning machine (ELM) [14], and deep learning architectures of long-short term memory networks (LSTM) [15] are commonly used AI approaches in the literature. Recently, due to the uncertainty and complex structure of the wind speed, deep learning has gained more interest in wind speed prediction due to its imposing features, such as handling big data, solving complex systems, learning the feature hierarchy on its own, avoiding data overfitting problems, and obtaining successful results from unstructured data, etc. On the other hand, it is most suitable for real-world applications. The convolutional neural network (CNN), deep recurrent neural network (DRNN), deep belief network (DBF), gated recurrent unit neural

networks (GRUNNs), ELM, and LSTM are widely used deep learning algorithms rather than the traditional AI approaches [16].

This paper proposes the wind speed prediction model based on a DRNN approach for the first time regarding meteorological input variables from dedicated meteorological sensors from NWFP. The proposed network has been constituted with a five-layered deep architecture that contains convolutional, recurrent, and fully connected dense layers. This type of network is capable of learning the temporal and sequential relationship between the inputs and outputs of the system. Thus, it is capable of predicting future expected wind features in advance for the corresponding regions. Global warming has changed the weather over the past years; hence, all other meteorological features are also believed to have changed, such as precipitation, temperature, humidity, and so on. Therefore, the proposed network does not only receive the most relevant features, that is, the wind features. All other meteorological features were also presented to the network because there was always a causal relationship between these features. The main contributions of this study lie in the following aspects:

1. Relevancy analysis of the sensor readings and the derived features are analyzed and their contributions to the wind speed are also investigated.
2. A DRNN approach is proposed, considering convolutional, recurrent, and fully connected dense layers for the wind speed prediction of the collected data from NWFP.
3. Different recurrent layers such as LSTM, GRU, and Simple RNN are used on the DRNN's architecture, and their performances are compared.

The remainder of this paper is organized as follows: Section 2 presents the other studies about wind speed predictions; Section 3 provides the proposed prediction model and experimental methods; Section 4 presents experimental results and discussions; and finally, some conclusions are drawn in Section 5.

2. RELATED STUDIES

A wind power short-term prediction based on LSTM and discrete wavelet transform (WT) was proposed in [17]. The results showed that the prediction accuracy had been improved by the proposed method. In [18] a novel wind speed multistep prediction model was proposed by combining the variational mode decomposition (VMD), singular spectrum analysis (SSA), LSTM, and ELM. The results showed that the proposed model has the best multi-step prediction performance. In addition, it was also more effective and robust in extracting trend information. A GRUNN-based wind speed error correction model for short-term wind power forecasting was presented in [19]. The feature of wind speed was analyzed, and the standard deviation of wind speed error was also extracted as weights for the numerical weather prediction (NWP) wind speed time series.

The proposed prediction model was compared with existing models such as SVM and ANN. The results show that the proposed model gives better performance results than the existing models. In addition, the GRUNNs-based data-driven approach was also proposed in [20] for wind power forecasting. The proposed model was compared and contrasted with the LSTM algorithm. The results show that the GRUNNs outperformed the LSTM in terms of a faster training process and less sensitivity to noise. In [21] a novel hybrid forecasting system was proposed that is formed by effective data decomposition techniques, DRNN, and error decomposition correction methods. Four different wind farm datasets in China were performed and verified by the proposed model. The results showed that the proposed model obtained a highly accurate wind speed prediction compared to simple and traditional models.

In [22] a new hybrid deep learning model was also proposed for short-term wind speed forecasting. An improved complementary ensemble empirical mode decomposition with adaptive noise (ICEEMDAN) and autoregressive integrated moving average (ARIMA) are combined with the

ELM technique. The experiments focused on pre-processing and post-processing time series data. In [23] a hybrid model based on the crow search algorithm (CSA), WT, feature selection (FS) based on entropy, mutual information (MI), and deep learning time series prediction based on LSTM is proposed for short-term wind speed forecasting. The results showed that the proposed method can outperform the most basic existing wind speed forecasting methods. A deep learning-based approach was proposed in [16] to characterize the probability density function (PDF) of the wind for short-term wind speed forecasting. The proposed model considers CNN and GRU to learn features of wind speed time series. Two actual data sets are used from England and Iran in the analysis. More accurate results have been obtained compared to other deep mixture approaches.

In [24] ELM and LSTM methods have been used to obtain VMD and SSA to complete the prediction. On the other hand, two hybrid models were proposed in [25] where one was formed by the LSTM and DNN and the other was combined with GRU networks and DNN. Moreover, three hybrid models were also proposed in [26] to improve the forecasting accuracy for wind speed. The WT is first mapped into the original wind speed history into several subseries. Then, for the low-frequency sub-series, the RNNs were used to extract the deeper features and involved in suitable machine learning methods for predicting, while others were still predicted by the normal methods. The results show that deep learning models outperform traditional approaches.

3. METHODOLOGY

3.1. Datasets

The NWFP is a globally unique but national UK real-world farming platform established in 2010 [27]. The NWFP is located at North Wyke in the southwest of England to understand grassland management at the systems level [28]. The NWFP

real-time data, as well as the experimental work, are available to the public. In other words, the data provided by the NWFP is open-access and free to download. More information about the NWFP can be found in [27,28]. The experiment data set was used from August 12, 2017, to August 24, 2020. There are 106,944 data points from 1,114 days of data obtained on the farm platform in the given specified period. The dedicated meteorological equipment and sensors were installed to record six different meteorological features as precipitation (mm), air temperature (°C), relative humidity (%), wind speed (m/s), wind direction (°) and solar radiation (W/m²) at 15-min intervals. *p*, *at*, *rh*, *ws*, *wd* and *sr* are the abbreviations used for the precipitation, air temperature, relative humidity, wind speed, wind direction, and solar radiation, respectively, in this paper.

3.2. Feature Engineering

To produce more distinguishability between the sensory data which are received at different dates and times, several input features are generated. First of all, the wind direction received from the sensor is in the range of [0°,360°]. Wind direction is cyclical data so this can cause a problem while training the network. Any two values close to 0° and 360° must be close to each other as well. Otherwise, the large difference makes a large network's update by gradient descent algorithm during training even if these two degrees are close. Due to this reason, wind direction and speed are transformed to the wind vector (*w_x*, *w_y*) as given in Equations (1) and (2). Here, *wd* data has been logged in the unit of degree so that by multiplying this value with $\pi/180$ that is simply converted to radian.

$$w_x = ws * \cos\left(\frac{wd * \pi}{180}\right) \quad (1)$$

$$w_y = ws * \sin\left(\frac{wd * \pi}{180}\right) \quad (2)$$

Each sensory data is received at a specific date and time, therefore, date and time information can also be added to the network training alongside the meteorological sensory data. In this way, the wind

data could be associated with the time of the wind data that occurred. Thus, this association provides additional information to make the wind data more distinguishable along the year by the neural network. However, timestamped data (*e.g.* minutes, hours, seconds, and so on) are all cyclical and repeat in a certain period. In cyclical data, the quantitative between each consecutive data is small depending on the step size, however, this is not true between the first and last values of the cyclical data. To overcome this type of data, time-specific information is transformed into two-dimensional using cosine and sine functions. To do this, the date and time data must be transformed to the total second first. Therefore, each timestamp is represented as the number no seconds that have been passed since the 1st of January, 1970, i.e. the beginning of Unix time. Afterwards, two-dimensional (2D) features are generated by using the date and time information of each perceived sensory reading. Two different 2D features, these are time of day (ds , dc) and time of year (ys , yc), are generated as given in Equations (3) to (6),

$$ds = \sin\left(\frac{t*2*\pi}{d}\right) \quad (3)$$

$$dc = \cos\left(\frac{t*2*\pi}{d}\right) \quad (4)$$

$$ys = \sin\left(\frac{t*2*\pi}{y}\right) \quad (5)$$

$$yc = \cos\left(\frac{t*2*\pi}{y}\right) \quad (6)$$

where $d = 24 \times 60 \times 60$ and $y = 365.2425 \times d$, these are total seconds in a day and a year respectively and t indicates Unix time.

3.3. Feature Selection

After having obtained newly generated features (these are wx , wy , ds , dc , ys and yc) alongside the available sensory data, it is important to analyze all features whether or not they carry relevant information that contributes to the model of wind.

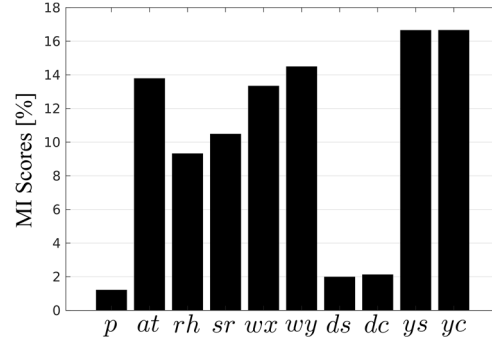


Figure 1. Mutual information analysis between the input features and the target outputs

Therefore, MI analysis is performed between all input features and the target wind speed (ws). Figure 1 shows the MI outcome of each input feature against each target output. The highest MI value implies the most relevant input feature to model the target wind speed. As seen in the figures, the highest MI values are obtained for the time of year features ys and yc . These results are expected because more or less meteorological data are similarly repeated every year with some deviation. Surely, this deviation increases with global warming which changes the climate. On the other hand, time of day and precipitation features have less or about 2% relevancy therefore these features are removed from the inputs of the network which do not contribute to modelling the future wind data. Figure 2 shows the final input-output configuration of the DRNN model, where the network receives the current input features and predicts a one-hour-ahead wind speed.




Figure 2. Inputs and outputs of the DRNN model after MI analysis.

Furthermore, the input data of the DRNN model were normalized by subtracting the mean and dividing by the standard deviation of each feature

before presenting them to the model. This method is also known as data standardization and is given in Equation (7). The target output data (ws) were kept raw during the model training.

$$\hat{x}_i = \frac{x_i - \text{mean}(x_i)}{\text{stdev}(x_i)} \quad (7)$$

where \hat{x}_i and x_i indicate the scaled and raw feature i , respectively.

3.4. Deep Recurrent Neural Network

A deep recurrent neural network consists of multiple different types of layers which are convolutional, recurrent, and fully connected layers. To capture the temporal and sequential information from the data presented to the network, it is important to use recurrent connections-based layers such as LSTM, GRU, or a simple RNN layer on the network. Such a network does not only work on an input space but also on an internal state space which enables one to learn the representation of temporally or sequentially long-term dependencies over unspecified intervals [29]. Otherwise, it is not possible to learn a temporal model to predict the future values of the desired wind speed.




Figure 3. The diagram of a simple RNN cell at time t .

1) *Simple RNN Cell:* Simple RNN (Figure 3) was introduced by Elman [30] where the activation of hidden layer $a^{(t)}$ is computed by feeding the hidden layer with the current inputs $x^{(t)}$ and with the previously hidden activation values $a^{(t-1)}$ as given in Equation (8), this is also known as recurrent connections that create a short-term memory to remember the sequence of data presented to the network. To learn the long-term dependency, the simple RNN cells are connected sequentially to

each other (see Figure 5) and the inputs of the corresponding cell become the output of the previous RNN cell unit, this is also known as unfolding RNN. However, a large number of unfolded simple RNN units can cause vanishing gradient problems [31].

$$a^{(t)} = \sigma_h(\theta_a[a^{(t-1)}, x^{(t)}] + b_a) \quad (8)$$

where σ_h indicates the hyperbolic tangent function, θ is the connection weight matrix, and b is the bias vector.

2) *LSTM Cell:* The LSTM contains a number of the connected LSTM cell which has feedback connections to present a memory behaviour that remembers the values over arbitrary time intervals. Another advantage of using LSTM cells is to overcome the vanishing gradient problem when adding many layers to the deep network [32].

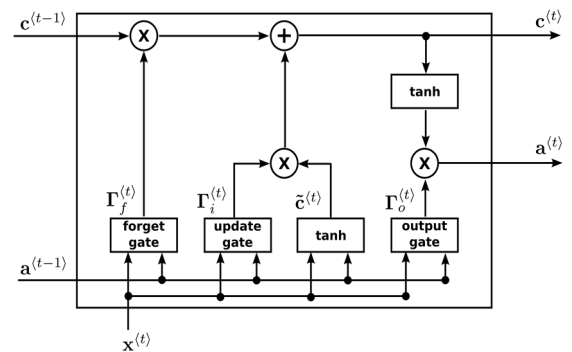


Figure 4. The diagram of an LSTM cell at time t .

LSTM cell is composed of a forget gate, update gate, cell state, output gates, and the hidden state as shown in Figure 4. Forget gate $\Gamma_f^{(t)}$ enables the LSTM cell to reset the memory of the previous cell state $c^{(t-1)}$. The gate receives inputs from the previous hidden state $a^{(t-1)}$ and the current timestep's input $x^{(t)}$ and a sigmoid function are used to keep the output of the gate in the range of $[0,1]$, so that whenever the gate's value closes to 0, the LSTM cell forgets the majority of the previously stored cell state, otherwise the stored cell state is remembered for the next timestep when the gate's output closes to one.

Furthermore, the LSTM cell computes the candidate value $\tilde{c}^{(t)}$ which contains information from the current timestep that may be stored in the current cell state $c^{(t)}$. Then, the update gate $\Gamma_f^{(t)}$ decides which part of the candidate could be passed to the cell state. The sigmoid function is used in the update gate that clamps the gate's output in the range of [0,1]. When the output of the update gate closes to one, the majority of the candidate's value is passed to the cell state, otherwise, the value of the candidate is not passed to the cell state when the output closes to zero. Therefore, the new value of cell state $c^{(t)}$ becomes the combination of the previous cell state and the candidate value. Finally, the current hidden state $a^{(t)}$ is computed by using the output of output gate $\Gamma_o^{(t)}$. The equations of the LSTM cell are given in Equations (9) to (14) [32].

$$\Gamma_f^{(t)} = \sigma_s(\theta_f[a^{(t-1)}, x^{(t)}] + b_f) \quad (9)$$

$$\Gamma_i^{(t)} = \sigma_s(\theta_i[a^{(t-1)}, x^{(t)}] + b_i) \quad (10)$$

$$\tilde{c}^{(t)} = \sigma_h(\theta_c[a^{(t-1)}, x^{(t)}] + b_c) \quad (11)$$

$$\Gamma_o^{(t)} = \sigma_s(\theta_o[a^{(t-1)}, x^{(t)}] + b_o) \quad (12)$$

$$c^{(t)} = \Gamma_f^{(t)} \circ c^{(t-1)} + \Gamma_i^{(t)} \circ \tilde{c}^{(t)} \quad (13)$$

$$a^{(t)} = \Gamma_o^{(t)} \circ \sigma_h(c^{(t)}) \quad (14)$$

where σ_s and σ_h are sigmoid and hyperbolic tangent functions respectively, θ indicates the weight vector of corresponding gates or candidate value, b is the vector of bias term, superscript (t) implies the timestep, $[\cdot]$ is the concatenate operation between two vectors and \circ is the Hadamard product.

3) *GRU Cell*: Similar to the LSTM, the GRU (Figure 5) was also designed to overcome the vanishing gradient problem when the number of timesteps is increased (i.e. unfolding) on the recurrent layer [33]. The only difference between the GRU and from LSTM unit, the GRU does not

have a separate memory cell state like shown in the LSTM cell diagram in Figure 4 with $c^{(t)}$ notation when computing the activation output, instead the activation of the GRU is a linear interpolation between the previous activation $a^{(t-1)}$ and the candidate activation $\tilde{a}^{(t)}$ values as given Equation (18). Here, the candidate activation is computed similarly to the traditional recurrent unit given in Equation (8), unlikely the value of the reset gate Γ_r is also integrated by multiplying the gate's value with the previous state activation value. The reset gate, Equation (17), yields a value in the range of [0,1] because of the sigmoid function. As a result, when the gate's value closes to zero, the majority of the previously computed hidden state is forgotten as given in Equation (15). Finally, the update gate Γ_u , Equation (16), decides how much information from the previous state needs to be passed along to the current state $a^{(t)}$, therefore when the gate's value closes to one, the majority of the current state is forgotten and the current state will mostly depend on the candidate activation. The GRU cell equations are listed as follows [33]:

$$\tilde{a}^{(t)} = \sigma_h(\theta_a[\Gamma_u^{(t)} \circ a^{(t-1)}, x^{(t)}] + b_a) \quad (15)$$

$$\Gamma_u^{(t)} = \sigma_s(\theta_u[a^{(t-1)}, x^{(t)}] + b_u) \quad (16)$$

$$\Gamma_r^{(t)} = \sigma_s(\theta_r[a^{(t-1)}, x^{(t)}] + b_r) \quad (17)$$

$$a^{(t)} = \Gamma_u^{(t)} \circ \tilde{a}^{(t)} + (1 - \Gamma_u^{(t)}) \circ a^{(t-1)} \quad (18)$$

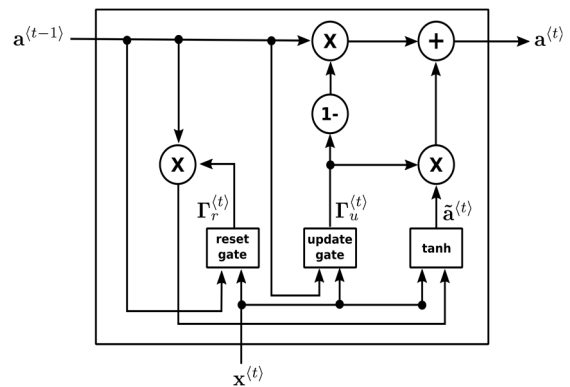


Figure 5. The diagram of a GRU cell at time t.

4) *Deep Network Architecture*: The detailed architecture of the deep recurrent neural network used in the following experiment is given in Figure 6. The network receives an input vector that is constituted with raw meteorological sensory data and the generated input data $x = \{ys, yc, st, rh, wx, wy, sr\}$. To incorporate temporal input data into the network training, the input data vector is arranged and 2,688 input data x back in time are used for the observation of the past input readings, therefore network looks back 40,320 min (2,688 data points \times 15 min), here 15 min is the sampling rate of the meteorological sensors. By dividing 40,320 min with 1,440 (60 min \times 24 hours) results 28 days is the total days back in time where the network uses.

However, instead of using every 15-minute input data, every 2 data points (i.e. every 30 min) are presented to the network, in this way dimensionality of the network inputs is reduced. There is no significant difference between 15- and 30-minute sampled data according to autocorrelation analysis [34]. As a result, 1,344 time-lag presents 28-day data observation in past (see Figure 5, where the 1,344 time-lagged input vector $x^{(t)}$ are shown at the bottom of the figure).

Afterwards, time-lagged inputs are presented to the 1D convolutional layer where 256 filters are used to extract sub-sequences from the input sequences of the network. The convolution operation leads to recognizing the input sequences at different timesteps, therefore the sequences become translation invariant. Then, the outputs from the convolutional layer become the inputs to the first recurrent layer. Here, two recurrent layers are stacked on the network architecture. By stacking multiple recurrent layers on top of each other, all intermediate recurrent layers must return their full-time sequence outputs rather than the output at the last timestep [35]. This is shown in Figure 5 where the outputs from recurrent cells at the first recurrent layer (indicating with superscript ^[2] as the layer number) are all connected to the associated next recurrent cell on the following recurrent layer (i.e. layer number ^[3]).




Figure 6. Deep recurrent network architecture for wind prediction. Superscripts $[n]$ and $\langle t \rangle$ indicate the n^{th} layer and t^{th} timestep, respectively. The dimensions of layers and the recurrent cell types for each model are given in the dashed box

After each layer of the DRNN, a batch normalization (BatchNorm) layer was added. The BatchNorm layer is simply normalized to the outputs from the previous layer which is connected to the BatchNorm layer using the mean and standard deviation of the current batch of input samples during the training. The main advantage of using batch normalization is that it overcomes the accumulation of large error gradients that can cause

the exploiting-gradient problem. In addition, by obtaining normalized outputs, the backpropagation algorithm produces a similar range of gradient values that can help move directly and smoothly to the local minimum of the loss optimisation. The two parameters (γ, λ) are learnable in the BathNorm process which is continuously learned during the training of the model, as given in Equation (18).

$$y_i = \text{BatchNorm}(x_i) = \gamma \hat{x}_i + \lambda \quad (19)$$

where x_i indicates the previous activation outputs, \hat{x}_i is the standardized value of x_i using the batch mean and standard deviation value of the i^{th} connection.

Furthermore, the more layers are added to the network, the network is more prone to become overfitting. To overcome this issue, each node of the network is connected with its corresponding next node by using the dropout rate. Therefore, during the training of the network, randomly selected nodes and their connection weights are disabled from the network's architecture so that the weight balance is spread to all the connection weights in order not to rely on one feature. The last timestamp's output from the last recurrent layer is then connected to a fully connected dense layer, here the dense layer is an ordinary feedforward neural network layer where a hyperbolic tangent activation function is used. Then, another fully connected layer is used at the top of the first dense layer, and finally, the activation outputs from the final dense layer are connected to the output dense layer with linear (identity) activation function to predict one-hour ahead wind speed \widehat{ws} . The network learns to predict $t+4$ timesteps forward of the output data during the training because the sampling rate of the sensory data is 15 min so $t+4$ represents one hour ahead of the information. It is also important to note that only the recurrent layers (layers 2 and 3) in Figure 6 were replaced with one of the recurrent cell approaches (simple RNN, GRU, or LSTM); thus, three different models were generated: DRNN- with a simple RNN, LSTM, and GRU. These models were trained separately, and their validity was compared for this study.

5) *Network Training*: Before the network is trained, the obtained dataset is split into training, validation, and testing sets with the ratio of 70%, 20%, and 10% respectively. The training set is used to learn the model of the relationship between inputs and target outputs presented to the network. A validation set is used to validate the network whether the network's training becomes overfitting, under-fitting, or optimal model therefore depending on the validation results in each run, the selected hyper-parameters can be changed to obtain the optimal model at the end of the training process. The initial learning rate α_0 is selected based on some trial training runs and is found to be the best choice to set 0.001. Generally, it is important not to select a too-large learning rate, it may diverge the learning, or too small may slow the convergence. However, when the network learning is near the local minimum on the loss landscape of the network, the learning algorithm needs to make smaller steps to reach the corresponding minima, so this reason the learning rate is reduced exponentially in each epoch of the training. The current learning rate during the training can be computed as follows [35]:

$$\alpha = \alpha_0 e^{-\tau t} \quad (20)$$

In addition, momentum (β) and discount factor (ρ) parameters for the root mean square propagation (RMSprop) optimizer are also set apart from the learning rate to remove the oscillation on the computed gradients to speed up the network learning. RMSprop optimizer is a more sophisticated version than the ordinary backpropagation algorithm. This algorithm also computes the gradients of the loss function (i.e. mean of squares of errors as given in Equation (21)) for the network's connection weights by simply applying the chain rule to find the derivative from the loss of the output layer backwards to the corresponding layer's connection weights.

$$\xi(ws, \widehat{ws}) = \frac{1}{m} \sum_{i=1}^m (ws_i - \widehat{ws}_i)^2 \quad (21)$$

where m indicates the number of the data in the current batch.

Table 1. Training parameters for proposed DRNN model

Parameter	Description/Value
Optimization algorithm	RMSprop optimizer
Initial Learning Rate (α_0)	0.001
Momentum (β)	0.99
Discount factor (ρ)	0.9
Decay rate (τ)	0.05
Weight initialization	Xavier initialiser
Dropout rate	0.8
Number of epoch	200
Batch size	64

Once the gradients of the corresponding layer's connection weights are computed, then the momentum is applied to the acquired gradients of the connection weight matrix (Θ) and bias vector (b) as given in Equations (22) and (23), and finally, RMSprop is computed by taking the squared gradients of the corresponding connection weights in Equations (24) and (25). In this way, the moving average of the gradients for each connection weight, i.e. smoothed gradients, is used to update the current connection weights of the network. After applying momentum and RMSprop operations, Θ and b of the corresponding layer [l] can be updated as given in Equations (26) and (27) [36].

$$\mathbf{V}_{\partial\theta}^{[l]} = \beta \mathbf{V}_{\partial\theta}^{[l]} + (1 - \beta) \frac{\partial \xi}{\partial \theta^{[l]}} \quad (22)$$

$$\mathbf{V}_{\partial b}^{[l]} = \beta \mathbf{V}_{\partial b}^{[l]} + (1 - \beta) \frac{\partial \xi}{\partial b^{[l]}} \quad (23)$$

$$\mathbf{S}_{\partial\theta}^{[l]} = \rho \mathbf{S}_{\partial\theta}^{[l]} + (1 - \rho) \left(\frac{\partial \xi}{\partial \theta^{[l]}} \right)^2 \quad (24)$$

$$\theta^{[l]} = \theta^{[l]} - \alpha \frac{\mathbf{V}_{\partial\theta}^{[l]}}{\sqrt{\mathbf{S}_{\partial\theta}^{[l]} + \epsilon}} \quad (25)$$

$$b^{[l]} = b^{[l]} - \alpha \frac{\mathbf{V}_{\partial b}^{[l]}}{\sqrt{\mathbf{S}_{\partial b}^{[l]} + \epsilon}} \quad (26)$$

where ϵ is a very small constant number to prevent the denominator from becoming zero, i.e.

$\epsilon = 10^{-7}$. Finally, the summary of all training parameters for DRNN is listed in Table 1.

4. EXPERIMENTAL RESULTS AND ANALYSIS

After three RNN layers-based DRNNs are trained, they are tested by using unseen test data from September 2019 to August 2020.

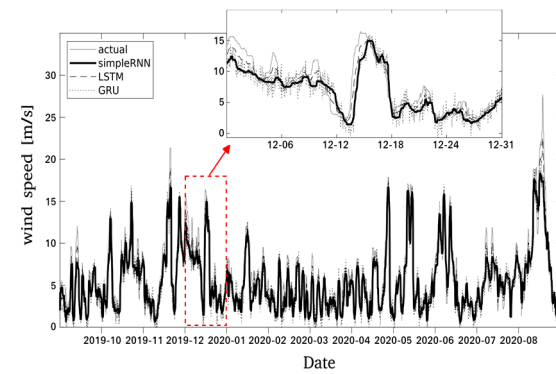


Figure 7. Actual versus predicted values of all DRNN models for one-hour ahead wind speed prediction

As a result, the one-hour-ahead wind speed predictions of the test dataset for the simple RNN, LSTM and GRU-based DRNN are demonstrated in Figure 7. As can be seen, there is some noise in the predicted signals in comparison with true signals. The data from training and testing must come from the same distribution, otherwise, the trained networks' model can struggle to predict true values and could have some fluctuations. These results are expected because of global warming where the seasons are getting changed. The neural network is capable of learning the repeated patterns where there is a correlation between inputs and outputs, however, when the input data changes in the case of global warming and the target output data does not change in the way the inputs changed, it is certainly impossible that the neural network generalizes the altered data well enough because these data are not seen during the network training so that the knowledge of naturally altered data cannot be embedded within the network's weights during the training.




Figure 8. Box plot of the prediction errors over months.

Further analyses are also carried out to examine the network's prediction errors along the months of the year. Figure 8 shows the box plot of the network's prediction error in each month. It can be seen that the highest number of errors were in December 2019 and August 2020. This is shown with the median error values (middle horizontal line in the box) which have the furthest distance to the zero error for the corresponding months.

Furthermore, the difference between the lower and the higher end of the boxes indicates how the variability of the error data from the median error, in other words, this is also called mathematically interquartile range (IQR). The IQR values of these two months are higher than the other months so 50% of the error data (the box indicates the middle 50% of data) are spread out more because the network has high uncertainty on the predictions. In addition, the whiskers of the boxes for the corresponding months indicate that they have the highest positive and negative errors among the other months. There are also lots of outlier data points of the prediction error which are indicated with the (+) symbol for December 2019, May 2020, and June 2020. The network makes these types of outlier predictions whenever the corresponding input data are significantly different from the training data. The data used in the network training are obtained from earlier years than the test data used for the network evaluation. This difference between the years is possible because global warming causes weather shifts over the years.

To clarify whether the occurrence of the high errors in December 2019 and August 2020 whether or not is dependent on the distribution of training and testing datasets, the *Kolmogorov Smirnov* (KS) test is carried out to compare the raw meteorological sensory data of these months in each year from 2017 to 2020. Suppose the relationship between the sensory data of the specific month at the different years is not changed due to global warming. In that case, the acquired model of DRNN can generalise the prediction well, even if the magnitude of those data is changed in the following year. First of all, the training data which belongs to August month from 2017 to 2019 are separately compared with the test data belonging to August 2020.

The results show that only precipitation data in 2019 and 2020 of the August month are from the same distribution at the 5% significance level and the null hypothesis is rejected for the other meteorological sensory data (*i.e.* temperature, humidity, solar radiation, wind speed, and direction). Similar results are also obtained when comparing the test data of December 2019 against the training data of December 2017 and 2018. This is an expected outcome and shows how well the acquired network's model generalizes the meteorological data with an acceptable error rate even if they come from a different distribution.

4.1. Comparison between LSTM, GRU and Simple RNN

To assess the performance of the DRNN using different recurrent layers, various statistical analyses are carried out. Firstly, the correlation coefficient values between the DRNN's predicted wind speed and the actual wind speed are computed by using three different correlation analyses, these are Spearman, Pearson, and Kendall correlation coefficients. The value of the correlation coefficient indicates how correlated predicted outputs are and actual outputs, the value 1 implies perfect correlation, 0 is a random guess and -1 means negative correlation. Furthermore, prediction errors of the network on the test data are also interpreted therefore mean absolute error (MAE), root mean square error (RMSE), and mean absolute percentage error (MAPE) are calculated.

Table 2 shows the statistical results of all recurrent layers using the same test data. As can be seen, there is a strong correlation between the network-predicted and actual wind speed for all RNN layer-based DRNN where their values are over 0.8 for both Spearman and Pearson correlations, however, both GRU and simple RNN-based recurrent layers

on the DRNN architecture presents better than LSTM-based layer. In addition, the simple RNN-based DRNN demonstrates slightly better performance than the GRU-based DRNN according to the Spearman and Kendall coefficients, whereas the GRU-based DRNN shows better performance in terms of the RMSE metric.

Table 2. Correlation coefficient values and overall prediction errors between each RNN layer for 1-hour ahead prediction

	Spearman	Pearson	Kendall	MAE [m/s]	RMSE [m/s]	MAPE [%]
LSTM	0.8312	0.8943	0.6477	1.4819	1.9360	34.3462
GRU	0.8815	0.9237	0.7079	1.3402	1.7863	27.9873
Simple RNN	0.8829	0.9166	0.7089	1.3088	1.8010	26.7737

Similar results are also obtained when prediction errors of the networks are analyzed. Both GRU and simple RNN-based DRNN have close overall prediction error according to MAE and RMSE, however, the accuracy of the Simple RNN has slightly better accuracy than GRU layers according to the MAPE values which are 72.01% and 73.23% (100 - MAPE) for GRU and simple RNN-based layers, respectively. Further analyses are also carried out between GRU and simple RNN-based layers to investigate how widely prediction errors deviate from the mean error, therefore standard errors for both networks are computed as $\bar{\sigma}_{GRU}=0.0002056$ m/s and $\bar{\sigma}_{simpleRNN}=0.0002138$ m/s. This shows that the prediction of using a simple RNN layer on the DRNN is slightly spread out more than the GRU-based layer. On the other hand, the confidence intervals of the prediction errors with a 95% significant level for GRU and simple RNN layers are also reported as [0.6931, 0.6939] m/s and [0.5581, 0.5590] m/s respectively. Although the simple RNN-based DRNN has a higher standard error, its prediction errors lie in the smaller range in comparison with GRU-based DRNN. Consequently, the lower error range yields better network performance.

5. CONCLUSIONS

Due to global warming, weather conditions are changing, and previously obtained forecasting

models may fail to predict wind speed accurately. Previous models that relied only on previous wind speed information are no longer sufficient, as global warming affects multiple meteorological factors such as precipitation, temperature, humidity, and solar radiation. Therefore, a deep recurrent neural network is proposed to model the relationship between multiple meteorological sensory data to produce more robust wind speed predictions. This approach can adapt to changes in weather conditions and is capable of producing accurate wind speed predictions even as wind speeds change each year. The proposed model is designed for one-hour-ahead wind speed predictions in an agricultural area.

To predict future wind speed, raw meteorological sensory readings are transformed into non-cyclical features such as wind vectors and timestamps. The mutual information of these features is analyzed to determine their contribution to the prediction. Three types of recurrent layers (LSTM, GRU, and simple RNN) are tested in a DRNN architecture to model the relationship between sensory data and wind speed. The models are validated using unseen sensory data from September 2019 to August 2020, and statistical analyses are performed to compare their performance. The results show that there is a strong correlation between the predicted and actual wind speeds for all models, which used different types of recurrent layers. Furthermore, the distribution of the mean prediction error along the months of the year is also analyzed using box plot

analyzes to highlight the month in which the highest average error occurred. It is reported that the networks performed worse in December 2019 and August 2020 than in other months. To clarify this, the *Kolmogorov-Smirnov* test is carried out, and it is found that the training and the test sensory data in these two months are not from the same continuous distribution. These results are expected because global warming affects the weather in different ways between consecutive years. Thus, the sensory readings between the years become significantly different. In conclusion, a deep recurrent network is capable of learning very high-degree nonlinear data, and by combining multiple recurrent layers on the network's architecture, it becomes more powerful than an ordinary one-layer recurrent neural network to model the noisy sensory data.

6. REFERENCES

1. Ahmed, A., Khalid, M., 2019. A Review on the Selected Applications of Forecasting Models in Renewable Power Systems, *Renewable and Sustainable Energy Reviews*, 100, 9-21.
2. Chen, Y., Dong, Z., Wang, Y., Su, J., Han, Z., Zhou, D., Zhang, K., Zhao, Y., Bao, Y., 2021. Short-term Wind Speed Predicting Framework Based on the Eemd-ga-lstm Method under Large-scale Wind History. *Energy Conversion and Management*, 227, 113559.
3. Hayes, L., Stocks, M., Blakers, A., 2021. Accurate Longterm Power Generation Model for Offshore Wind Farms in Europe using Era5 Reanalysis. *Energy*, 229, 120603.
4. Deng, X., Shao, H., Hu, C., Jiang, D., Jiang, Y., 2020. Wind Power Forecasting Methods Based on Deep Learning: A Survey. *Computer Modeling in Engineering & Sciences*, 122(1), 273-301.
5. Mi, X., Liu, H., Li, Y., 2019. Wind Speed Prediction Model Using Singular Spectrum Analysis, Empirical Mode Decomposition and Convolutional Support Vector Machine. *Energy Conversion and Management*, 180, 196-205.
6. Lei, M., Shiyan, L., Chuanwen, J., Hongling, L., Yan, Z., 2009. A Review on the Forecasting of Wind Speed and Generated Power. *Renewable and Sustainable Energy Reviews*, 13(4), 915-920.
7. Azimi, R., Ghofrani, M., Ghayekhloo, M., 2016. A Hybrid Wind Power Forecasting Model Based on Data Mining and Wavelets Analysis. *Energy Conversion and Management*, 127, 208-225.
8. Santhosh, M., Venkaiah, C., Vinod K.D.M., 2020. Current Advances and Approaches in Wind Speed and Wind Power Forecasting for Improved Renewable Energy Integration: A Review. *Engineering Reports*, 2(6), e12178.
9. Lipu, M.S.H., Miah, M.S., Hannan, M.A., Hussain, A., Sarker, M.R., Ayob, A., Saad, M. H.M., Mahmud, M.S., 2021. Artificial Intelligence Based Hybrid Forecasting Approaches for Wind Power Generation: Progress, Challenges and Prospects. *IEEE Access*, 9, 102460-102489.
10. Puri V., Kumar, N., 2021. Wind Energy Forecasting Using Artificial Neural Network in Himalayan Region. *Modeling Earth Systems and Environment*, 1-10.
11. Li, L.L., Chang, Y.B., Tseng, M.L., Liu J.Q., Lim, M.K., 2020. Wind Power Prediction Using a Novel Model on Wavelet Decomposition-Support Vector Machines-Improved Atomic Search Algorithm. *Journal of Cleaner Production*, 270, 121817.
12. Sfetsos, A. 2000. A Comparison of Various Forecasting Techniques Applied to Mean Hourly Wind Speed Time Series. *Renewable Energy*, 21(1), 23-35.
13. Lin, W., Wu, Z., Lin, L., Wen, A., Li, J., 2017. An Ensemble Random Forest Algorithm for Insurance Big Data Analysis. *IEEE Access*, 5, 16568-16575.
14. Tian, Z., Li, S., Wang, Y., 2020. A Prediction Approach Using Ensemble Empirical Mode Decomposition-Permutation Entropy and Regularized Extreme Learning Machine for Short-term Wind Speed. *Wind Energy*, 23(2), 177-206.
15. Huang, G.B., Zhu, Q.Y., Siew, C.K, 2006. Extreme Learning Machine: Theory and Applications. *Neurocomputing*, 70(1), 489-501.
16. Afrasiabi, M., Mohammadi, M., Rastegar, M., Afrasiabi, S., 2021. Advanced Deep Learning Approach for Probabilistic Wind Speed Forecasting. *IEEE Transactions on Industrial Informatics*, 17(1), 720-727.

17. Liu, Y., Guan, L., Hou, C., Han, H., Liu, Z., Sun, Y., Zheng, M., 2019. Wind Power Short-term Prediction Based on lstm and Discrete Wavelet Transform. *Applied Sciences*, 9(6).
18. Liu, H., Mi, X., Li, Y., 2018. Smart Multi-step Deep Learning Model for Wind Speed Forecasting Based on Variational Mode Decomposition, Singular Spectrum Analysis, lstm Network and Elm. *Energy Conversion and Management*, 59, 54-64.
19. Ding, M., Zhou, H., Xie, H., Wu, M., Nakanishi, Y., Yokoyama, R., 2019. A Gated Recurrent Unit Neural Networks Based Wind Speed Error Correction Model for Short-term Wind Power Forecasting. *Neurocomputing*, 365, 54-61.
20. Kisvari, A., Lin, Z., Liu, X., 2021. Wind Power Forecasting a Data-driven Method Along with Gated Recurrent Neural Network. *Renewable Energy*, 163, 1895-1909.
21. Duan, J., Zuo, H., Bai, Y., Duan, J., Chang, M., Chen, B., 2021. Short-term Wind Speed Forecasting Using Recurrent Neural Networks with Error Correction. *Energy*, 217, 119397.
22. Wang, L., Li, X., Bai, Y., 2018. Short-term Wind Speed Prediction Using an Extreme Learning Machine Model with Error Correction. *Energy Conversion and Management*, 162, 239-250.
23. Memarzadeh, G., Keynia, F., 2020. A New Short-term Wind Speed Forecasting Method Based on Fine-tuned lstm Neural Network and Optimal Input Sets. *Energy Conversion and Management*, 213, 112824.
24. Liu, H., Mi, X., Li, Y., Duan, Z., Xu, Y., 2019. Smart Wind Speed Deep Learning-based Multi-Step Forecasting Model Using Singular Spectrum Analysis, Convolutional Gated Recurrent Unit Network and Support Vector Regression. *Renewable Energy*, 43, 842-854.
25. Yu, C., Li, Y., Zhang, M., 2017. An Improved Wavelet Transform Using Singular Spectrum Analysis for Wind Speed Forecasting Based on Elman Neural Network. *Energy Conversion and Management*, 148, 895-904.
26. Yu, C., Li, Y., Bao, Y., Tang, H., Zhai, G., 2018. A Novel Framework for Wind Speed Prediction Based on Recurrent Neural Networks and Support Vector Machine. *Energy Conversion and Management*, 178, 137-145.
27. Orr, R.J., Griffith, B.A., Rose, S., Hatch, D., Hawkins, J., Murray, P.J., 2011. Designing and Creating the North Wyke Farm Platform. *Catchment Science*.
28. Hawkin, J., 2015. Design, Establishment and Development, <http://resources.rothamsted.ac.uk/sites/default/files/groups/NorthWykeFarmPlatform/FPUG.Doc.001EstabDeveloper1.5.pdf>, Access date: 11/02/2023.
29. Boden, M., 2002. A Guide to Recurrent Neural Networks and Backpropagation. The Dallas Project.
30. Elman, J.L., 1990. Finding Structure in Time. *Cognitive Science*, 14(2), 179-211.
31. Goodfellow, I., Bengio, Y., Courville, 2016. *Deep Learning*. MIT Press.
32. Hochreiter, S., Schmidhuber, J., 1997. Long Short-term Memory. *Neural Computation*, 9(8), 1735-1780.
33. Chung, J., Gulcehre, C., Cho, K., Bengio, Y., 2014. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modelling. *arXiv Preprint arXiv:1412.3555*.
34. Kaplan, D., Glass, L., 1997. *Understanding Nonlinear Dynamics*. Springer Science & Business Media.
35. Chollet, F., 2017. *Deep Learning with Python*. Manning.
36. Werbos, P.J., 1990. Backpropagation Through Time: What it Does and How to do It. *Proceedings of the IEEE*, 78(10), 1550-1560.

Compressive Performance of the PVC Foam Materials used as Sandwich Panel Core

Ahmet ÇETİN^{*1,2} ORCID 0000-0003-1393-3806
Necdet GEREN² ORCID 0000-0002-9645-0852

¹Adıyaman University, Engineering Faculty, Department of Mechanical Engineering,
Adıyaman, Türkiye

²Cukurova University, Engineering Faculty, Department of Mechanical Engineering, Adana,
Türkiye

Geliş tarihi: 07.01.2024 Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ÇETİN, A., GEREN, N., (2024). Compressive Performance of the PVC Foam Materials used as Sandwich Panel Core. Cukurova University, Journal of the Faculty of Engineering, 39(2), 301-307.

Abstract

PVC foam materials are preferred in many engineering applications because of their lightweight nature and strength/weight ratio. They are mainly used as the core material in the middle of sandwich panels with improved flexural rigidity. The mechanical performances of sandwich panels, such as flexural load-deflection, core shear load, core shear failure load, and indentation failure load, directly depend on the mechanical properties of the core material. In this study, compression tests of AIREX C70 PVC foams with three different densities were performed. The elastic modulus and strength results obtained from the compression tests were compared with the mechanical properties provided in the dataset supplied by the material manufacturer. The core yield loads of a concept sandwich panel were then obtained using the compression mechanical properties of the core, which were obtained from datasets and experimental results. When the core yield loads obtained using both data were compared, it was revealed that the load obtained using the dataset data was 23% inaccurate. Thus, the study explained why compression tests are necessary even though the mechanical properties of PVC foam materials are known in the datasheet.

Keywords: AIREX C70 PVC foam, Sandwich panels, Core yield loads, Compression tests

Sandviç Panellerde Çekirdek Malzeme Olarak Kullanılan PVC Köpük Malzemelerin Basınç Yüklerine Karşı Performansı

Öz

PVC köpük malzemeler, hafiflikleri ve mukavemet/ağırlık oranları nedeniyle birçok mühendislik uygulamasında tercih edilmektedir. Özellikle eğilme rijitliği artırılmış sandviç panellerin ortasında çekirdek malzeme olarak kullanılırlar. Sandviç panellerin eğilme yükü-sapması, çekirdek kesme yükü, çekirdek kesme kırılma yükü ve çentik kırılma yükü gibi mekanik performansları doğrudan çekirdek malzemenin mekanik özelliklerine bağlıdır. Bu çalışmada, üç farklı yoğunluğa sahip AIREX C70 PVC köpüklerin

*Sorumlu yazar (Corresponding Author): Ahmet ÇETİN, acetin@adiyaman.edu.tr

sıkıştırma testleri gerçekleştirilmiştir. Basma testi sonuçlarından elde edilen elastik modül ve mukavemet sonuçları, malzeme tedarikçisi tarafından sağlanan mekanik özellikler veri sayfası verileri ile karşılaştırılmıştır. Daha sonra, konsept bir sandviç panelin çekirdek akma yükleri veri föyündeki ve deneysel sonuçlardaki çekirdeğin basma mekanik özellikleri kullanılarak, elde edilmiştir. Her iki veri ile elde edilen çekirdek akma yükleri karşılaştırıldığında, veri föyündeki verileri ile elde edilen yükün %23 hatalı olduğu ortaya çıkmıştır. Böylece çalışma, PVC köpük malzemelerin mekanik özelliklerinin veri föyünde bilinmesine rağmen basma testlerinin neden gerekli olduğunu açıklamaktadır.

Anahtar Kelimeler: AIREX C70 PVC köpük, Sandviç paneller, Çekirdek akma yükleri, Sıkıştırma testleri

1. INTRODUCTION

The rapid emergence and growth of the use of polymeric foams have been attributed to their numerous advantages. These include their lightweight properties, high strength/weight ratio, and ability to provide excellent insulation [1,2]. Demand for these materials is expected to increase because of the increasing use of lightweight materials such as closed-cell foams, especially in automotive structures. The lightweight nature of these materials can help improve fuel economy and reduce transportation pollution. In addition, the high compressive energy of closed-cell foams can be used to improve the damage tolerance of some automotive structures. Therefore, due to their exceptional lightweight properties, closed-cell PVC foams are widely used in the production of automobile, aerospace, and marine structures [3]. Owing to their high compressive and dimensional stability characteristics, closed-cell foams are also ideal for structural applications [4]. Foam cores from polymers such as PVC have good flammability and chemical resistance [5]. PVC foam is also a core material that produces wind turbine blades [6]. Various engineering products, such as sandwich panel cores, use PVC foams [7,8]. Because of their properties, such as their ability to resist transverse loads, sandwich panels are commonly used in engineering applications [9]. For a sandwich structure, the role of the core in transmitting the shear load between the facesheets is significant. If the core is brittle or has low shear strength, it can cause catastrophic failure. On the other hand, high shear strength can cause delamination because of the failure of the facesheets' adhesion. Although it has a high shear

strength, PVC foam tends to behave non-linearly [10].

The core material directly affects the flexural behavior of sandwich beams, such as core shear deflection, core yield load, and core shear failure mode [11-14]. The core yield load depends on the compressive strength capability of the core material, especially when sandwich beams lose their stiffness properties under bending load. When analytical methods estimate the core yield load values of sandwich beams, the compressive yield strength of the core material is required [11]. Therefore, the compressive strengths of the PVC foam material must also be known to estimate the core yield-bearing load of a sandwich beam made of the PVC foam core material.

This study investigated the compressive strengths of AIREXC70 PVC foam, the preferred core material of sandwich materials. There is a wide range between the average and minimum values in the supplier's strength specifications for PVC foams (Table 1). Therefore, using these values in analytical calculations may increase the error rate in providing reliable estimates. For these reasons, we subjected three different AIREXC70PVC foam materials used as cores in sandwich plates to compression tests. Thus, the authors revealed where the compression properties of the PVC foams they tested fell within the property range in the data sheet provided by the supporting company.

2. MATERIAL AND METHOD

The AIREX C70 foam is made from high-quality closed-cell materials and exhibits exceptional

stiffness and strength. This material is water resistant and has excellent anti-chemical capabilities. Its delicate cell design also helps in bonding. AIREXC70 is suitable for various resins and manufacturing processes. Owing to its exceptional properties, AIREXC70 can be used as a core material for various sandwich structures [15]. Figure 1 shows the three densities and thicknesses of AIREX C70. They are widely chosen as the core material for sandwich beams. The samples exhibited 75, 48, and 130 kg/m³ densities. The manufacturer of AIREXC70 provides the mechanical properties of PVC foams. The mechanical characteristics of the AIREX C70 PVC foams are shown in Table 1.

Compression testing was performed on the three densities of AIREX C70 PVC foams to check their mechanical properties, as shown in Table 1. ASTM C365 is the standard used for determining the compressive modulus and strength of PVC foam used for sandwich structures [16]. According to standard procedures, five AIREX C70 PVC foam samples were prepared with 30 mm thickness and 60X60 mm surface cross-section sizes. The test samples are shown in Figure 2.

Compression tests were performed on PVC foam using ASTM C 365 [16]. The rigid plates, which were 20 mm thick, were fixed to the lower and upper jaws of the machine, as shown in Figure 3. The specimen was then placed between them. The cross-head motion was set at 0.50 mm/min. It was ensured that the load was evenly distributed across the specimen surface. The tests were resumed until the foam was densified.




Figure 1. AIREX C70 foams are used as the core material

Table 1. Mechanical properties of the AIREX C70 foam materials [17]

Properties of the AIREX C70	Unit	C70.48	C70.75	C70.130
Density	kg/m ³	48 (min 43)	80 (min 72)	130 (min 120)
Compressive strength	MPa	0.60 (min 0.50)	1.45 (min 1.10)	3.0 (min 2.6)
Compressive modulus	MPa	48 (min 35)	104 (min 80)	170 (min 145)
Tensile strength in the plane	MPa	0.95 (min 0.80)	2.0 (min 1.6)	4.0 (min 3.0)
Tensile modulus in the plane	MPa	35 (min 28)	66 (min 50)	115 (min 95)
Shear strength	MPa	0.55 (min 0.50)	1.2 (min 1.0)	2.4 (min 2.1)
Shear modulus	MPa	16 (min 14)	30 (min 24)	54 (min 45)



Figure 2. PVC foam specimens prepared for compression testing



Figure 3. Compression test setup of the PVC foam core material

3. RESULTS AND DISCUSSIONS

Table 1 shows the mechanical properties of the three PVC foams. Although the data collected by the supplier company are shown in Table 1, the average and minimum values of the foam materials are not always the same. For instance, a high-density PVC foam with an average density of 48 kg/m³ can have a maximum density of 55 kg/m³ and a minimum density of 43 kg/m³. The variance between the densities at the extremes and the average values is approximately 14.5%. The mechanical properties of the foam are considered to be the basis of its average value at 48 N/mm². However, the minimum value for this material is 35 N/mm². The difference is noteworthy, as it amounts to 27%. Compression tests were performed on the foams to determine their mechanical range. These were compared with the materials used in the study. The force-extension data obtained during the compression tests are shown in the curves in Figure 4. The stress-strain curves presented in Figure 5 were then obtained.

The compressive modulus and strength of the PVC foams were obtained from Figure 5. The mechanical compression properties of the PVC foams obtained from the tests are given in Table 2, with the mechanical compression properties provided by the supporting company. The data presented in the table show that the compression properties of all tested PVC foams are between the minimum and maximum values presented in the data sheet. The experimental compression modulus and strength values of AIREX C70.48 PVC foam with a density of 48 kg/m³ are in the middle of the minimum and average values presented in the data sheet. The experimental compression mechanical properties of 80 kg/m³ density AIREX C70.75 and 130 kg/m³ density AIREX C70.130 PVC foams are close to the minimum values presented in the data sheet.

It can be said that there is agreement between the experimental results and the values presented in the data sheet. However, this wide range in the data sheet may lead to erroneous predictions in application areas. For example, consider a sandwich beam design made of AIREX C70.75 foam among the foams tested in compression and plain woven

fabric composite material. The mechanical properties of the plain woven fabric composite material used as the facesheet material of the designed sandwich material were taken from the literature. Facesheet material has a thickness of 0.82 mm, an elastic modulus of 50.2 (E_f), and tensile strength of 674 MPa, respectively [18]. Let the thickness (c) of the PVC foam material be 30 mm. Also, assume the sandwich beam (b) width is 50 mm. The designer wants to estimate the core yield load of this sandwich beam under bending loads. The designer can predict the core yield loads (P_1) of the sandwich beam with the equations presented below [11].

$$P_1 = \frac{2\sigma_c b}{\lambda} \quad (1)$$

where,

$$\lambda = \left(\frac{k}{4E_f I_f}\right)^{\frac{1}{4}} \quad (2)$$

With the foundation modulus k defined as;

$$k = \frac{E_c b}{c} \quad (3)$$

Using the PVC foam material and facesheet material properties given in the case study and the set of equations, the core yield loads of the sandwich were determined. Two different methods were applied to the solutions. In the first case, P_1 is obtained using the average elastic modulus of PVC foam from Table 2. The second case calculation was made using the experimental compressive elastic modulus. Thus, the error probability for P_1 was determined. The P_1 value obtained from the average value of the data sheet was 1041 N. Otherwise, the value of P_1 obtained using the compression modulus obtained using the experimental result is 843 N. The main mechanical properties are the experimental compression test results for the PVC foam used. Therefore, the force value was obtained with an error of 23% in the first calculation method.

As a result, the PVC foams tested under compression are within the value range given in the datasheet. However, using the datasheet values in analytical applications for design estimations

increases the error rate in obtaining actual values. The core yield loads obtained in the case study are an excellent example.

On the other hand, PVC foam materials used as core materials in sandwich applications do not only require compressive mechanical properties. The shear modulus of the core material of a sandwich beam is required to obtain the force–deflection curve under flexural loading. The maximum load that a sandwich failing in core shear failure mode can carry depends on the shear strength of the PVC

foam. Moreover, the compression modulus and strength are required to determine the maximum load a sandwich with indentation failure can carry. The mechanical properties of the PVC foam used as the core material must be known for accurate and precise estimation of all these parameters applicable to the sandwich design. In this context, this study explains the necessity of determining the mechanical properties of PVC foams from experimental data, although the mechanical properties are given in the foam manufacturers' datasheets.




Figure 4. PVC foams compression load– extension curves a) 48 kg/m³ density b) 80 kg/m³ density c) 130 kg/m³ density

Table 2. Compressive modulus and strength of the AIREX C70 PVC foams

AIREX C70	Data sheet			Experimental results	
	Density (kg/m ³)	Comp. strength (MPa)	Comp. modulus (MPa)	Comp. strength (MPa)	Comp. modulus (MPa)
C70.48	48 (min 43)	0.60 (min 0.50)	48 (min 35)	0.55	42
C70.75	80 (min 72)	1.45 (min 1.10)	104 (min 80)	1.10	82
C70.130	130 (min 120)	3.0 (min 2.6)	170 (min 145)	2.60	145




Figure 5. PVC compression stress-strain curves a) 48 kg/m³ density b) 80 kg/m³ density c) 130 kg/m³ density

4. CONCLUSION

Compression tests of the PVC foam materials used in sandwich panel applications were conducted. Three different densities of PVC foam were used in this study. The mechanical property dataset of these foams obtained from the supplier company is provided in the study. However, the range between the average and minimum values of the mechanical properties is very large. Therefore, the actual compression modulus and strength values of the tested PVC foams were obtained. The compression properties of 48 kg/m³ density foams obtained from the experimental results are between the average and minimum values in the datasheet, whereas the others are close to the minimum values.

A case study was also conducted to emphasize the importance of correctly determining the mechanical properties of PVC foams when designing for

application fields. A sandwich panel was designed, and the core yield load of this panel was obtained by an analytical method using the compressive mechanical properties of the PVC core material. Two different calculations were performed. The first method used the average compression modulus and strength values in the datasheet. Second, compression properties obtained from the experimental data were used. The load value obtained using the dataset data was 23% inaccurate.

Thus, the study proved that even though the dataset presents the mechanical properties of PVC foams, the mechanical properties of the core used in the sandwich panel need to be obtained by testing.

5. ACKNOWLEDGEMENTS

The authors would like to thank the Scientific Research Projects Coordination Unit (BAP) of

Cukurova University in Adana, Turkey for the financial support provided. Project No: FBA-2020-13140.

6. REFERENCES

1. Demir, H., Sipahioğlu, M., Balköse, D., Ülkü, S., 2008. Effect of Additives on Flexible PVC Foam Formation. *Journal of Materials Processing Technology*, 195(1), 144-153.
2. Geren, N., Acer, D.C., Uzay, C., Bayramoglu, M., 2021. The Effect of Boron Carbide Additive on the Low-velocity Impact Properties of Low-density foam Core Composite Sandwich Structures. *Polymer Composites*, 42(4), 2037-2049.
3. Colloca, M., Dorogokupets, G., Gupta, N., Porfiri, M., 2012. Mechanical Properties and Failure Mechanisms of Closed-cell PVC Foams. *International Journal of Crashworthiness*, 17(3), 327-336.
4. Yao, H., Pang, Y., Liu, X., Qu, J., 2022. Experimental Study of the Dynamic and Static Compression Mechanical Properties of Closed-Cell PVC Foams. *Polymers*, 14(17), 3522.
5. Al-Shamary, A.K.J., Karakuzu, R., Özdemir, O., 2016. Low-velocity Impact Response of Sandwich Composites with Different Foam Core Configurations. *Journal of Sandwich Structures & Materials*, 18(6), 754-768.
6. Atas, C., Sevim, C., 2010. On the Impact Response of Sandwich Composites with Cores of Balsa Wood and PVC Foam. *Composite Structures*, 93(1), 40-48.
7. Uzay, Ç., Geren, N., 2020. Effect of Stainless-steel Wire Mesh Embedded Into Fibre-reinforced Polymer Facings on Flexural Characteristics of Sandwich Structures. *Journal of Reinforced Plastics and Composites*, 39(15-16), 613-633.
8. Uzay, Ç., 2021. Enhancing the Out-of-Plane Compressive Performance of Lightweight Polymer Foam Core Sandwiches. *Sakarya University Journal of Science*, 25(6), 1366-1375.
9. Funari, M.F., Spadea, S., Lonetti, P., Lourenço, P.B., 2021. On the Elastic and Mixed-mode Fracture Properties of PVC Foam. *Theoretical and Applied Fracture Mechanics*, 112, 102924.
10. Mostafa, A., Shankar, K., Morozov, E.V., 2013. Insight Into the Shear Behaviour of Composite Sandwich Panels with Foam Core. *Materials & Design*, 50, 92-101.
11. Shuaeib, F.M., Soden, P.D., 1997. Indentation Failure of Composite Sandwich Beams. *Composites Science and Technology*, 57(9), 1249-1259.
12. Steeves, C.A., Fleck, N.A., 2004. Collapse Mechanisms of Sandwich Beams with Composite Faces and a Foam Core, Loaded in Three-point Bending. Part I: Analytical Models and Minimum Weight Design. *International Journal of Mechanical Sciences*, 46(4), 561-583.
13. Steeves, C.A., Fleck, N.A., 2004. Collapse Mechanisms of Sandwich Beams with Composite Faces and a Foam Core, Loaded in Three-point Bending. Part II: Experimental Investigation and Numerical Modelling. *International Journal of Mechanical Sciences*, 46(4), 585-608.
14. Uzay, Ç., Geren, N., 2020. Failure Analysis of Low-density Polymer Foam Core Sandwich Structures under Three-point Bending Loading. *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 35(1), 49-58.
15. Uzay, C., Geren, N., Boztepe, M.H., Bayramoglu, M., 2019. Bending Behavior of Sandwich Structures with Different Fiber Facing Types and Extremely Low-density Foam Cores. 61(3), 220-230.
16. International, A., 2016. Standard Test Method for Flatwise Compressive Properties of Sandwich Cores: Designation: C365/C365M - 16.
17. Metyx, C., 2020. Core materials Airex C70. <https://www.metyx.com/wp-content/uploads/2020/10/TDS-AIREX-C70-E-04.2020.pdf>. Access date: 07.09.2021.
18. Uzay, Ç., Çetin, A., Geren, N., Bayramoğlu, M., Tütüncü, N., (2023). Predicting the Tensile Stiffness and Strength Properties of Plain Woven Carbon Fiber/Epoxy Laminates: A Practical Analytical Approach and Experimental Validations. *Mechanics of Advanced Materials and Structures*, 31(12), 2619-2634.

Araçlarda CO₂ Emisyonlarının Farklı Yapay Sinir Ağı Modelleri Kullanılarak Tahminlerinin Karşılaştırılması

Emrah ASLAN*¹ ORCID 0000-0002-0181-3658

¹Dicle Üniversitesi, Silvan Meslek Yüksekokulu, Bilgisayar Programcılığı Bölümü, Diyarbakır

Geliş tarihi: 14.03.2024 Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ASLAN, E., (2024). Araçlarda CO₂ Emisyonlarının Farklı Yapay Sinir Ağı Modelleri Kullanılarak Tahminlerinin Karşılaştırılması. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 309-324.

Öz

İklim değişikliği, insanlık için en büyük çevresel tehlikelerden biridir. İklim değişikliğinde karbondioksit (CO₂), sera etkisinin başlıca sebeplerindendir. Ulaşım sektörü, büyük CO₂ emisyon kaynaklarından birini oluşturmaktadır. Bu makale, araçlarının anlık CO₂ emisyonlarını tahmin etmek için bir yapay sinir ağı (YSA) modeli sunmaktadır. Araçlarda CO₂ emisyonlarını tahmin etmek için Linear Regresyon, XGBoost Regresör ve K-Nearest Neighbours Regresörü olmak üzere üç regresyon modeli kullanılarak kapsamlı bir yaklaşım kullanılmıştır. Araştırma, araçlardaki CO₂ emisyonlarını tahmin etmek ve analiz etmek için bu yapay sinir ağlarının yeteneklerinden yararlanmaya odaklanmaktadır. Farklı modellerin kullanılması, doğruluk ve verimlilik açısından performanslarının karşılaştırmalı olarak değerlendirilmesine olanak sağlamaktadır. Yüksek doğruluk ve uygulanabilirlik sağlayan bu yöntem, motor hacmi, silindiri, şehir içi ve şehir dışı yakıt tüketimi gibi parametreler ile egzoz emisyonlarının öngörücüleri olarak kullanılmaktadır. Her parametrenin emisyon tahminlerine olan önemi, test ve eğitim doğruluğu, kök ortalama kare hatası, ortalama mutlak hata, R² skor gibi sonuçlar karşılaştırılarak kapsamlı bir şekilde analiz edilmiştir. Bu çalışma, özellikle araç emisyonları bağlamında CO₂ emisyon tahmin metodolojilerinin ilerlemesine katkıda bulunmayı amaçlamaktadır. Bu araştırmanın bulguları, ulaştırma sektöründe karbon ayak izlerini azaltmak için sürdürülebilir çözümler arayan politika yapıcılar, çevreciler ve otomotiv mühendisleri için önem taşımaktadır.

Anahtar Kelimeler: CO₂ emisyonu, Yapay sinir ağı, Yakıt tüketimi

Comparison of CO₂ Emissions Prediction in Vehicles Using Different Artificial Neural Network Models

Abstract

Climate change is one of the greatest environmental threats to humanity. Carbon dioxide (CO₂) is one of the main causes of the greenhouse effect in climate change. The transportation sector is one of the major sources of CO₂ emissions. This paper presents an artificial neural network (ANN) model for estimating the instantaneous CO₂ emissions of vehicles. A comprehensive approach using three regression models, namely

*Sorumlu yazar (Corresponding Author): Emrah ASLAN, emrah.aslan@dicle.edu.tr

Linear Regression, XGBoost Regressor and K-Nearest Neighbors Regressor, is used to predict CO₂ emissions from vehicles. The research focuses on leveraging the capabilities of these artificial neural networks to predict and analyze CO₂ emissions from vehicles. The use of different models allows for a comparative evaluation of their performance in terms of accuracy and efficiency. This method, which provides high accuracy and applicability, uses parameters such as engine displacement, cylinder, urban and non-urban fuel consumption as predictors of exhaust emissions. The importance of each parameter to emission predictions is comprehensively analyzed by comparing results such as test and training accuracy, root mean square error, mean absolute error, R² score. This study aims to contribute to the advancement of CO₂ emission estimation methodologies, especially in the context of vehicle emissions. The findings of this research are important for policy makers, environmentalists and automotive engineers seeking sustainable solutions to reduce carbon footprints in the transportation sector.

Keywords: CO₂ emissions, ANN, Fuel Consumption

1. GİRİŞ

Çoğunlukla insan faaliyetlerinden kaynaklanan CO₂ emisyonları, küresel iklim değişikliğinin giderek artan zorluklarına önemli bir katkıda bulunmaktadır. Bu emisyonların azaltılması zorunluluğu, sera etkisini artırmadaki önemli rollerinden kaynaklanmakta ve ekosistemler, hava durumu ve deniz seviyeleri üzerinde olumsuz etkilere yol açmaktadır. CO₂ emisyonlarının farklı kökenlerinin tanınması, çevrenin korunmasına yönelik bütüncül stratejilerin formüle edilmesi için temel teşkil etmektedir [1].

Çevresel sürdürülebilirlik konusundaki çağdaş söylemde, karbondioksit (CO₂) emisyonlarının doğru tahmin edilmesi ve azaltılması zorunlu hedefler olarak öne çıkmaktadır. Toplumlar iklim değişikliğinin sonuçlarıyla boğuşurken, önemli bir karbon ayak izine sahip olan ulaştırma sektörü, araştırma ve müdahale için bir odak noktası haline gelmiştir [2]. Bu çalışma, etkinliklerini ve nüanslarını ayırt etmek için çeşitli Yapay Sinir Ağı (YSA) modellerinin karşılaştırmalı bir analizini kullanarak araçlarda CO₂ emisyonu tahminini araştırmaktadır.

Karbondioksit (CO₂) emisyonlarının daha geniş bağlamında, ulaşım sektörü önemli bir rol üstlenmekte ve çevresel zorluklara önemli bir katkıda bulunmaktadır [3]. Geleneksel araçlarda yaygın olan ve yakıtın yanması sırasında önemli miktarlarda CO₂ açığa çıkaran içten yanmalı motorlar özellikle dikkat çekmektedir. Bu emisyon

kaynağı, kentleşmenin hızlanması ve buna bağlı olarak küresel ulaşım talebindeki artış göz önüne alındığında daha da önem kazanmaktadır. Bu eğilimlerin kesişmesi, genişleyen kentsel manzara ve artan ulaşım ihtiyaçları, geleneksel araçlardan kaynaklanan CO₂ emisyonlarının etkisini toplu olarak artırdığından, araç emisyonlarını ele alma aciliyeti vurgulamaktadır [4,5].

Araçlardan kaynaklanan CO₂ emisyonlarının kesin bir şekilde anlaşılması çok önemlidir. Böyle bir kavrayış, çevresel etkileri azaltmayı amaçlayan bilinçli karar alma ve stratejik planlama için gereklidir [6]. Ulaşım sektörünün çok önemli rolünü kabul eden bu çalışma, kapsamlı bir karşılaştırma için yapay sinir ağı modelleri kullanarak CO₂ emisyonlarını tahmin etme ve öngörme gibi incelikli bir görevi ele almaktadır. Bu sayede, sürdürülebilir uygulamaların ilerletilmesi ve araç faaliyetleriyle ilişkili çevresel ayak izinin azaltılmasına yönelik devam eden arayışta politika değerlendirmelerinin bilgilendirilmesi için çok önemli iç görüleri katkıda bulunmayı amaçlamaktadır [7].

Yapay zeka (YZ) alanındaki son adımlar, çevresel zorluklara yenilikçi çözümler için yollar açmıştır. Araç emisyonları bağlamında, Yapay Sinir Ağları (YSA'lar) CO₂ emisyonlarını tahmin etmek ve öngörmek için sofistike bir araç sunmaktadır. İnsan beyninin karmaşık mimarisinden esinlenen bu modeller, verilerdeki karmaşık örüntüleri ayırt etmede mükemmeldir. Araştırmacılar, YSA'nın yeteneklerinden yararlanarak, araçlardaki CO₂

emisyonlarını etkileyen çok yönlü faktörleri inceleyebilir, daha doğru tahminler ve bilinçli karar vermeyi kolaylaştırabilir [8].

Bu araştırma, çeşitli YSA modellerinin kapsamlı bir karşılaştırmasını yaparak araçlardaki CO₂ emisyonları hakkındaki söylemlere katkıda bulunmayı amaçlamaktadır. Bu çalışma sayesinde, farklı sinir ağı mimarilerinin güçlü yönlerine ve sınırlamalarına ışık tutmayı ve sürdürülebilir ve çevreye duyarlı bir geleceğe giden yolda ilerlemeye çalışan politika yapımcılar, araştırmacılar ve endüstri paydaşları için değerli bilgiler sağlamayı amaçlamaktadır.

Bu çalışmanın Bölüm 1 kısmında problem hakkında genel bilgilere yer verilmiştir. Çalışmanın ilerleyen kısımları şu şekildedir. Bölüm 2 CO₂ emisyon tahmini için yapılmış literatür çalışmalarını içermektedir. Bölüm 3 uygulamalar için gerekli olan materyal ve metodu, Bölüm 4 yapılan çalışmalar ve tartışmayı kapsamaktadır. Bölüm 5'te ise, sonuçlar ve gelecekteki çalışmalar açıklanmıştır.

2. LİTERATÜR TARAMASI

Zeng ve arkadaşları, çalışmalarında CO₂ tahmini için Yapay Sinir Ağı, Destek Vektör Makinesi (DVM) ve VT-Micro tekniklerini kullanmışlardır. Ayrıca, araçlar için çevresel olarak en uygun rotayı bulmak için, On-Board Diagnostics (OBD) portu aracılığıyla 30 saniye aralıklarla hız, ivme ve gaz verisi kullanmışlardır. Yazarlar tarafından belirtilen sorun, sadece 2 özellikle CO₂ emisyonunun kötü tahmin edilmesidir [9]. Oduro ve ark., çalışmalarında aracın hızı ve ivmesini kullanarak CO₂ tahmininin regresif analizini yapmışlardır. Elde edilen sonuçlar, araç hızı ve ivmesinin CO₂, hız ve ivme arasında lineer bir ilişki gösterdiğini göstermektedir. Hız, ivmeye kıyasla CO₂ emisyon faktörü ile daha güçlü bir ilişkiye sahiptir [10].

Razak ve arkadaşları, çeşitli yüklerde bir dizel motorunun GHG emisyonlarını azaltmak için farklı yakıtların optimal karışımını bulmak için lineer programlama yaklaşımını kullanmıştır. Çalışmaları, %70 dizel, %20 biyodizel ve %10 butanol

karışımının kullanılmasının sülfür ve CO₂ emisyonlarında sırasıyla %35 ve %36 azalmaya yol açtığını göstermiştir [11].

Shim ve arkadaşları, çalışmalarında bir çift yakıtlı dizel motorunun toplu söndürme olayını aşmak için eşdeğerlik oranı ve birincil yükleme sıcaklığının etkisini değerlendirdi. Araştırmaları, şarj sıcaklığının ve hava miktarının kontrolünün düşük yüklerde toplu söndürme olayını hafifletmek için kullanışlı bir teknik olabileceğini ortaya koydu [12].

Prabhu ve arkadaşları, CO₂ ve NO_x gibi kirletici emisyonları ölçmek için bir SCD motorunu ele almıştır. Yakıt ön ısıtılmış biyogaz içeriyordu ve ön ısıtmanın ısı yükünü sağlamak için motordan çıkan ısının bir ısı değiştiricisinde geri kazanılması sağlanmıştır. Sonuçlar, ön ısıtma işleminin %40,5'lik bir fren biyogaz tüketimine yol açtığını kanıtlamıştır [13].

Roy ve arkadaşları, dört zamanlı bir SCD'nin motor performansını ve emisyonlarını tahmin ettiler. Bu çalışmada, ESFC, η_{th} , CO₂, NO_x ve PM gibi parametreler değerlendirildi. Sarace ve ark., AIN kullanarak cerium oksit nanopartiküllerinin dizel motor performansı ve emisyonları üzerindeki etkisini incelediler. Sonuçları, cerium oksit nanopartiküllerinin NO_x ve HC'yi önemli ölçüde azalttığını, CO emisyon oranlarını hafifçe arttırdığını ve yakıt tüketimini azalttığını gösterdi [14].

Alfaseeh ve arkadaşları, uzun-kısa dönem belleği kullanarak kentsel bir alandaki sera gazı emisyonlarını link düzeyinde tahmin etmek için çeşitli sayıda sinir ağı katmanına sahip çoklu modeller geliştirdiler ve daha derin sinir ağı modelinin gelişmiş tahmin performansı sergilediğini buldular [15].

Claudio ve arkadaşları, Dinamik Programlama (DP) algoritması tarafından tahmin edilen tanktan tekerleğe karbondioksit emisyonlarının tahmini için yenilikçi, derin sinir ağlarına dayalı bir model sunulmuştur. Kapsamlı bir simülasyon seti sırasında %91'in üzerinde sınıflandırma

performansları ve %1'in altında ortalama regresyon hataları elde etmişlerdir [16].

Jigu ve Sungwook yüksek derecede doğruluk ve pratiklik sunan YSA kullanarak dizel araçların karbondioksit nitrojen oksit ve karbon monoksit emisyonlarını tahmin etmek için yeni bir yaklaşım sunmuşlardır. Çalışmalarında dikkate alınan altı parametreye ek olarak gaz pedalı konumu, gaz kelebeği konumu, VSP, egzoz gazı sıcaklığı, yol eğimi ve vites konumu gibi diğer parametreler de YSA girişi olarak kullanılmıştır [17].

Natarajan ve arkadaşları, emisyonları tahmin etmek için araç özelliklerinden yararlanan toplu öğrenme modelleri oluşturmak amacıyla, hafif ticari araç tasarımları için karbondioksit emisyonlarını tahmin etmek amacıyla güçlendirme ve diğer regresyon modellerinin geliştirilmesini önermişlerdir. Önerilen güçlendirme modeli Catboost, girdi olarak yalnızca bir araba özelliği olsa bile CO₂ emisyonlarını doğru bir şekilde tahmin etme kapasitesine sahiptir. Catboost, literatürde önerilen diğer algoritmalara göre veri işlemeyi daha kısa sürede ve daha az bellekle gerçekleştirir. Çalışma % 95 bir doğruluk ile çalışmaktadır [18].

Al-Nefae ve arkadaşları, çalışmalarında araçlardaki CO₂ emisyonlarını tahmin etmek için derin öğrenme tabanlı LSTM ve BiLSTM modelleri geliştirerek, bu modellerin performansını Kaggle'dan elde edilen veri setleri üzerinde değerlendirmiştir. BiLSTM modeli, en yüksek doğruluk ve tahmin değerleriyle R² %93.78 en iyi performansı göstermiştir [19].

Dong ve arkadaşları, çalışmalarında hibrid elektrikli araçların soğuk başlangıç emisyonlarını tahmin etmek için genetik algoritma ile optimize edilmiş bir sinir ağı modeli geliştirmiştir. Düşük maliyetli ve yüksek tahmin doğruluğuna sahip olan bu model, farklı soğuk başlangıç sıcaklıkları ve girdi parametreleri altında CO, CO₂, hidrokarbon (THC), NO_x ve partikül madde sayısı (PN) emisyonlarını başarıyla tahmin edebilmişlerdir [20].

Paul ve arkadaşları, yapay zeka modellerinin enerji tüketimine ve CO₂ emisyonlarına olan etkilerini değerlendirerek, bu modellerin olumlu ve olumsuz etkilerini nicelendiren bir yöntem önermişlerdir. Üç farklı YZ modeli üzerinde yapılan değerlendirmeler, modellerin CO₂ emisyonlarında azalmaya katkıda bulunabileceğini, ancak bu azalmanın bağlama bağlı olarak değişkenlik gösterdiğini göstermiştir [21].

Wang ve arkadaşları, çalışmalarında ağır ticari dizel araçların NO_x emisyonlarını tahmin etmek için geliştirilmiş bir çift-gizli-katmanlı BP sinir ağı modeli sunmuştur. Yeni bir özellik mühendisliği işleme yöntemi kullanılarak model, gerçek yol emisyon testlerinde yüksek doğrulukla çalışmaktadır. Çalışma sonucunda test doğruluğunu %87.024 olarak bulunmuştur [22].

Mądziel çalışmasında, start-stop teknolojisiyle donatılmış bir araç için CO₂ emisyonlarını tahmin etmek için yapay zeka teknikleri kullanarak bir hesaplama modeli oluşturma metodolojisini sunmuştur. Üç farklı makine öğrenimi tekniği analiz edilmiş ve en iyi tahmin sonuçları gradyan artırma yöntemiyle elde edilmiştir. Geliştirilen modeller, CO₂ emisyonlarını mikro ölçekte çevresel analiz için yeni bir yöntem sunmaktadır [23].

Literatür taraması, mevcut CO₂ tahmini ve modelleme yöntemlerinin temel olarak hız ve sıkışıklık verileri ile birlikte özel sensörlerden oluştuğunu göstermektedir. Hız ve ivme, CO₂ emisyonu ile yüksek derecede ilişkili olmasına rağmen, aracın emisyon karakteristikleri hakkında sınırlı bilgi sağlayabilir. CO₂ modellemesi için özel sensörler, doğru olabilir ancak geniş ölçekli uygulamalar için çok uygun değildir. Dahası, literatürdeki CO₂ tahmini yöntemleri bireysel araç emisyonlarını etkili bir şekilde izlemekten acizdir. Mevcut literatürün incelenmesi, motorların performansını ve kirliliğini araştıran farklı çalışmalar olduğunu göstermektedir. Ancak, yazarların bilgisine göre, motor performans değerlendirmesi ve kirlilik üzerinde giriş hava ve soğutma suyunun etkisini inceleyen deneysel

çalışmalarda bir eksiklik bulunmaktadır. Başka bir deyişle, literatür hala farklı tasarım değişkenlerinin dikkate alınarak motor performansı ve kirletici emisyonların eş zamanlı olarak değerlendirilmesini ve tahmin edilmesini içeren kapsamlı araştırmalara ihtiyaç duymaktadır. Bu eksikliğin yapay zeka yöntemleri kullanılarak giderilebileceği önerilmektedir.

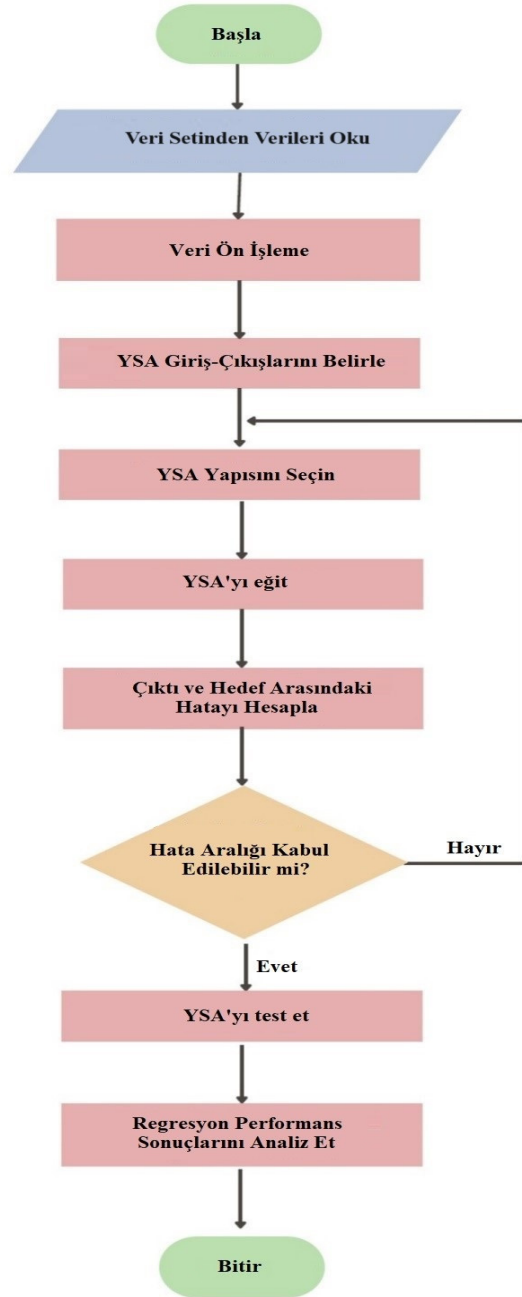
3. YÖNTEM

Araçların oluşturduğu emisyonu tespit etmek için Linear, K-Nearest Neighbours, XGBoost yapay sinir ağları kullanılmıştır. Model geliştirme sürecinin akış diyagramı gösterimi Şekil 1'de sunulmuştur. Çalışmada, gerçek araç verilerinden elde edilen verilerden oluşan bir veri seti kullanılmıştır. Veri setinde yer alan verilerin %80 oranında eğitim ve %20 oranında test kümelerine ayrılmıştır. Eğitim verileri, model girdisi için önemli özellikleri belirlemek üzere korelasyon testi de dahil olmak üzere ön işleme tabi tutulmuştur. Ön işlemenin ardından veriler, CO₂ emisyonlarını tahmin etmek üzere regresyon modellerini eğitmek için kullanılır. Modellerin performansı daha sonra tahmin kabiliyetini doğrulamak için test verileri kullanılarak değerlendirilir. Verilen regresyon algoritmalarıyla karşılaştırmalı analiz yapılmıştır.


3.1. Veri Seti

Veri seti Kanada'da hafif ticari araçların yakıt tüketimlerini ve CO₂ emisyon verilerini içermektedir. CO₂ emisyonu veri seti farklı marka ve modelde araçlar için toplam 7385 satır, 12 sütundan oluşan veri bulundurmaktadır [24]. Veri seti içerisinde vites türü, vites sayısı, yakıt türü, şehir içi kullanım, şehirlerarası kullanım, CO₂ emisyonu, motor hacmi, silindir sayısı gibi teknik bilgilerin yanında marka model, üretim yılı, araç sınıfı gibi araç kimlik bilgileri de yer almaktadır. Veri setinin parametreleri arasındaki ilişkiyi anlamak için, korelasyon testi sonucu Şekil 2'de görselleştirilmiştir. Ardından, her bir giriş parametresinin korelasyonu ve giriş ile hedef parametreler arasındaki ikili korelasyona dayalı olarak ilişki analiz edilmektedir. Şekil 3'de korelasyon matrisi veriler arasındaki ilişki

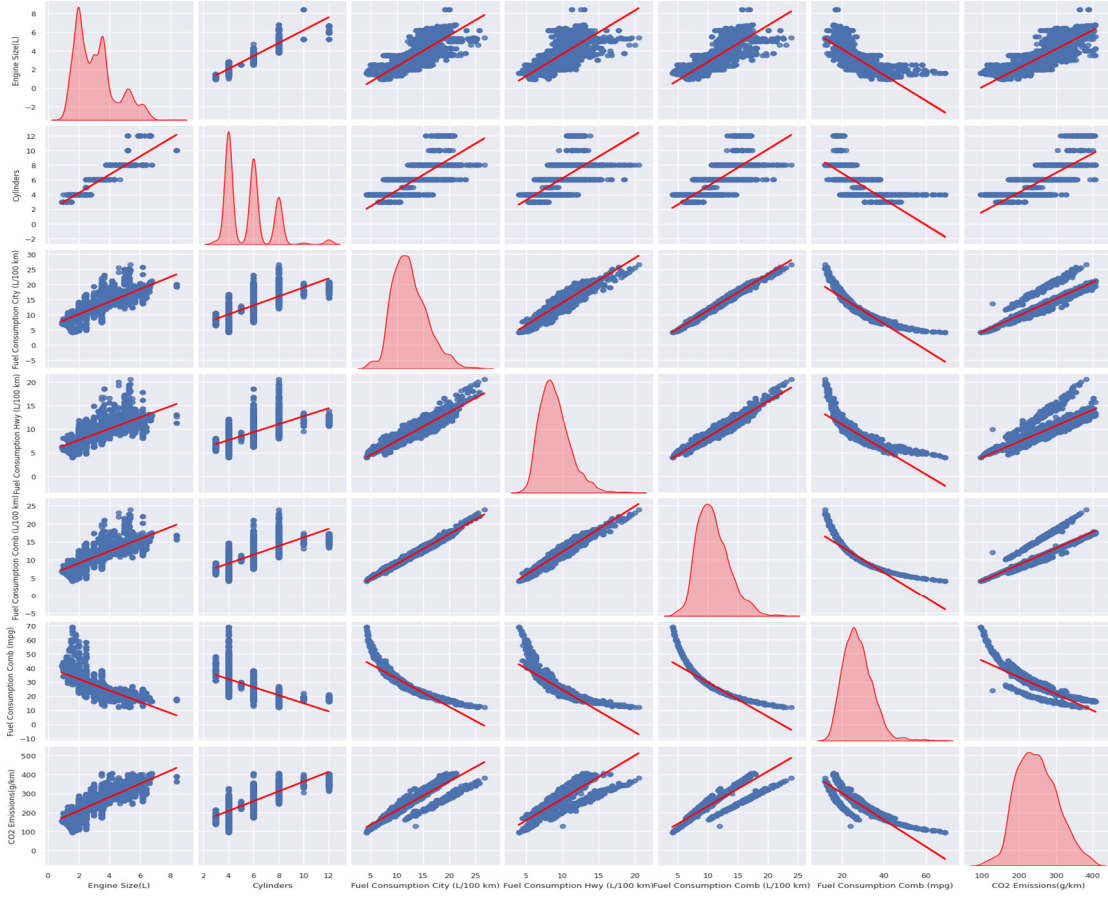
histogram olarak verilmiştir. Şekil 4'te yakıt tipi ve CO₂ emisyon verileri arasındaki ilişki gösterilmiştir.




Şekil 1. Akış diyagramı



Şekil 2. Korelasyon matrisi




Şekil 3. Korelasyon matrisi histogram grafiği


Şekil 4. Yakıt tipi ve CO₂ emisyon grafiği

Şehir içi yakıt tüketiminin CO₂ emisyonu ile arasındaki ilişki Şekil 5'de şehirler arası yakıt tüketiminin CO₂ emisyonu ile ilişkisi Şekil'6 da


verilmiştir. Motor hacmine göre farklı yakıt türlerine sahip araçların oluşturduğu CO₂ emisyonu Şekil 7'de gösterilmiştir.



Şekil 5. Şehir içi yakıt tüketimi ve CO₂ emisyon grafiği



Şekil 6. Şehirlerarası yakıt tüketimi ve CO₂ emisyon grafiği



Şekil 7. Motor hacmine göre farklı yakıt türlerine sahip araçların oluşturduğu CO₂ emisyonu

3.2. Lineer Regresyon

Lineer regresyon, istatistik ve makine öğrenmesinde sıkça kullanılan temel bir modeldir. Bu model, bir bağımlı değişkenin bir veya daha fazla bağımsız değişkenle olan ilişkisini doğrusal bir denklemle modellemeyi amaçlamaktadır. Lineer regresyon, bu ilişkiyi doğrusal bir denklemle temsil etmektedir. Temel lineer regresyon modeli genellikle şu formda ifade edilmektedir:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \epsilon \quad (1)$$

Burada, Y bağımlı değişken veya sonuç, X bağımsız değişken, β modelin katsayısı ve ϵ hata terimidir. Lineer regresyonun temel amacı, bağımlı değişkenle bağımsız değişkenler arasındaki ilişkiyi açıklamak ve bu ilişkiyi temsil eden bir doğru veya düzlem oluşturmaktır. Bu doğru veya düzlem, veri noktalarının dağılımını en iyi şekilde yakalamaya çalışmaktadır.

Lineer regresyon, özellikle bağımsız değişkenlerle bağımlı değişken arasındaki ilişkiyi anlamak ve tahminler yapmak için sıkça kullanılmaktadır. Lineer regresyonun geniş bir uygulama yelpazesi bulunmaktadır. Örneğin, tahmin yapma, korelasyon analizi ve optimizasyon gibi alanlarda sıklıkla kullanılmaktadır. Bu model, bir evin satış fiyatını tahmin etmekten hasta tedavi sonuçlarını analiz etmeye kadar birçok farklı alanda değerli bilgiler sağlayabilmektedir.

Bu modelin avantajları arasında basitlik ve anlaşılabilirlik gelmektedir. Ayrıca, hesaplama açısından verimli olduğu için büyük veri setleri üzerinde hızlı sonuçlar elde etmek mümkündür. Ancak, lineer regresyonun sınırlamaları da bulunmaktadır. Lineer ilişkileri modellemeye uygun olmayan veri setleri için bu modelin kullanılması doğru sonuçlar vermeyebilir. Eksik veya yanıltıcı veriler, modelin performansını olumsuz etkileyebilmektedir.

Sonuç olarak, lineer regresyon istatistik ve makine öğrenmesinde temel bir araç olarak karşımıza çıkmaktadır. Doğru bir şekilde uygulandığında, bu model veri analizi, tahminleme ve karar verme süreçlerinde büyük avantajlar sağlayabilmektedir.

Ancak, her model gibi, lineer regresyonun da sınırlamaları ve dikkat edilmesi gereken noktaları bulunmaktadır.

3.3. K-Nearest Neighbors Regresyon (K-NN)

K-Nearest Neighbors Regresyon (K-NN) algoritması, hem sınıflandırma hem de regresyon problemlerinde sıkça kullanılan temel bir makine öğrenmesi algoritmasıdır. Algoritmanın temel amacı, bir veri noktasını çevresindeki en yakın k komşunun etiketi veya değeri ile tahmin etmektir. KNN algoritmasının çalışma prensibi oldukça basit ve anlaşılırdır. Veri noktası, benzerlik ölçütüne göre diğer tüm veri noktalarına olan mesafeleri hesaplayarak, en yakın k veri noktasını seçmektedir.

Sınıflandırma durumunda, en sık görülen sınıf veya etiket tahmin olarak verilmektedir. Örneğin, bir e-postanın spam olup olmadığını tahmin etmek için kullanılabilir. Regresyon durumunda ise, en yakın k veri noktasının ortalama değeri tahmin olarak kullanılmaktadır.

K-NN algoritmasının avantajları arasında basitlik, kolay uygulanabilirlik ve anlaşılabilirlik bulunmaktadır. Başlangıç seviyesi kullanıcılar için ideal bir tercih olmasını sağlamaktadır. Ancak, büyük veri setleri ve yüksek boyutlu özellik uzaylarında hesaplama maliyeti artabilmektedir. Bu durum, algoritmanın pratikte kullanımını sınırlayabilmektedir.

Ayrıca, K-NN algoritmasının önemli hiperparametreleri vardır. Özellikle k değerinin seçimi ve benzerlik ölçütünün belirlenmesi, modelin performansını önemli ölçüde etkileyebilmektedir. Bu parametrelerin doğru bir şekilde ayarlanması, algoritmanın başarısını artırmak için kritik öneme sahiptir.

Sonuç olarak, K-NN algoritması, veri analizi, tahmin etme ve karar verme süreçlerinde etkili bir araç olarak kullanılabilir. Ancak, doğru bir şekilde uygulanması için hiperparametrelerin dikkatlice seçilmesi ve algoritmanın sınırlamalarının bilinmesi gerekmektedir.

3.4. XGBoost Regresyon

XGBoost (Extreme Gradient Boosting) son zamanlarda makine öğrenimi yarışmalarında ve endüstriyel uygulamalarda büyük başarı elde etmiş bir öğrenme algoritmasıdır. Gradient Boosting yöntemlerine dayanır, ancak özellikle ölçeklenebilirlik, hız ve doğruluk açısından geliştirilmiştir. XGBoost'un temel çalışma prensibi, birçok zayıf tahmin ediciyi bir araya getirerek güçlü bir tahminci oluşturmaktır. Model, önceki tahminlerin hatalarını düzeltmeye odaklanarak ardışık olarak bu tahmin edicileri eğitmektedir. Bu, bir sonraki tahmin ediciyi eğitmek için kullanılan veri setindeki hataları minimize etmek için bir gradyan inişi yaklaşımıdır. XGBoost'un bazı önemli özellikleri şunlardır:

Ölçeklenebilirlik: Büyük veri setleriyle başa çıkabilir ve çoklu işlemcileri veya dağıtılmış sistemleri kullanarak hızlı bir şekilde eğitim yapabilmektedir.

Hız: Optimizasyonları sayesinde diğer gradient boosting kütüphanelerine göre daha hızlıdır.

Regülerizasyon: Aşırı öğrenmeyi önlemek için çeşitli regülerizasyon tekniklerini desteklemektedir.

Esneklik: Sınıflandırma, regresyon, sıralama ve diğer birçok problem türünü desteklemektedir.

XGBoost, endüstriyel uygulamalarda ve makine öğrenimi yarışmalarında liderlik eden modellerin oluşturulmasında yaygın olarak kullanılmaktadır. Özellikle regresyon analizlerinde, XGBoost'un hızlı ve ölçeklenebilir yapısı sayesinde etkileyici sonuçlar alınabilir.

4. ARAŞTIRMA BULGULARI

Bu çalışmada, araçlardaki CO₂ emisyon tahmininde kullanılan regresyon algoritmalarının performansı değerlendirilmiştir. Linear, K-Nearest Neighbours, XGBoost Regressor algoritmaları üzerinde eğitim gerçekleştirilmiştir. Modelin potansiyelini detaylı

bir şekilde incelemek amacıyla regresyon algoritmalarını tanımlayan değişkenler ve hiperparametreler üzerinde kapsamlı bir araştırma gerçekleştirilmiştir. Çalışmada kullanılan Linear Regresyon ile eğitimde kullanılan parametreler Çizelge 1'de verilmiştir.

Çizelge 1. Linear Regresyon Parametreleri


Parametre	Değer
Fit_intercept	true
copy_X	true
n_job	none
positive	true
Max_iter	10
Random_state	10

Linear Regresyonun eğitim sonucunda araçlarda CO₂ emisyonunu tahmin etmede %90.69 eğitim performansı ve %90.76 test performansı elde edilmiştir. RMSE 16.65, MAE 11.06, R² Skoru 90.76'dir. Linear regresyon algoritması ile tahmin edilen araçlardaki CO₂ emisyonu ve gerçek emisyon değerlerinin tahminini gösteren grafik Şekil 8'de verilmiştir.


Çizelge 2. K-Nearest Neighbour Regressor Parametreleri

Parametre	Değer
Probability	True
Epsilon	0.1
Degree	3
Max_iter	10
Random_state	10

K-Nearest Neighbour Regressor ile eğitimde kullanılan parametreler Çizelge 2'de verilmiştir. K-Nearest Neighbour Regresyonun eğitim sonucunda araçlarda CO₂ emisyonunu tahmin etmede %97.76 eğitim performansı ve %97.39 test performansı elde edilmiştir. RMSE 8.84, MAE 3.75, R² Skoru 97.39'dir. K-Nearest Neighbour Regresyon algoritması ile tahmin edilen araçlardaki CO₂ emisyonu ve gerçek emisyon değerlerinin tahminini gösteren grafik Şekil 9'da verilmiştir.



Şekil 8. Linear Regresyon ile gerçek değer ve tahmin edilen değer grafiği




Şekil 9. K-Nearest Neighbour Regresyon ile gerçek değer ve tahmin edilen değer grafiği

Çizelge 3. XGBoost Regresyon Parametreleri

Parametre	Değer
booster	gbtree
verbosity	1
eta	0.3
learning_rate	0.99
max_dept	6
n_estimators	50

XGBoost Regressor ile eğitimde kullanılan parametreler Çizelge 3'te verilmiştir. XGBoost Regresyonun eğitim sonucunda araçlarda CO₂ emisyonunu tahmin etmede %99.64 eğitim performansı ve %98.75 test performansı elde edilmiştir. RMSE 6.45, MAE 2.81, R² Skoru 98.75'tür. XGBoost Regresyon algoritması ile tahmin edilen araçlardaki CO₂ emisyonu ve gerçek emisyon değerlerinin tahminini gösteren grafik Şekil 10'da verilmiştir.



Şekil 10. XGBoost Regresyon ile gerçek değer ve tahmin edilen değer grafiği

Çizelge 4. Regresyon algoritmalarının karşılaştırılması

Regresyon algoritması	Eğitim doğruluğu	Test doğruluğu	RMSE skor	MAE skor	R ² skor
Lineer	90.69	90.76	16.65	11.06	90.76
K-Nearest neighbours	97.76	97.39	8.84	3.75	97.39
XGBoost	99.64	98.75	6.45	2.81	98.75


Çalışmada uygulanan 3 farklı yöntem ile araçlardaki CO₂ emisyon tahmini gerçekleştirilmiştir. Regresyon algoritmalarının performanslarının değerlendirme metrikleri ve algoritmaların başarı ölçeklendirilmesine ait veriler Çizelge 4'da sunulmuştur. Şekil 11 ve Şekil 12'de sırasıyla eğitilen modellerin eğitim ve test doğrulukları her bir regresyon modeli için grafiksel olarak gösterilmiştir. Şekil 13'te ise regresyon modelleri için R² skoru grafik ile gösterilmiştir.

Çizelge 4 incelendiğinde XGBoost Regresyon'un, eğitim doğruluğunda %99.64 ve test doğruluğunda %98.75 ile en yüksek performansı gösterdiğini ortaya koymaktadır. Bu değerler, XGBoost'un yüksek tahmin doğruluğu, düşük hata oranı ve hızlı işlem süresi ile öne çıktığını göstermektedir.


Çalışmanın sonuçlarına göre, XGBoost Regresyon en yüksek tahmin doğruluğu ve en düşük hata oranlarıyla dikkat çekerken, Linear Regresyon daha sınırlı bir performans göstermektedir. K-NN ise esnekliğiyle ve doğrusal olmayan ilişkileri yakalama kapasitesiyle önemli bir alternatif olarak

karşımıza çıkmaktadır. Bu nedenle, tahmin problemi ve veri setinin özelliklerine bağlı olarak en uygun algoritmanın seçilmesi önem arz etmektedir.


Bu çalışma, araçlardaki CO₂ emisyon tahmininde kullanılan regresyon algoritmalarının performansını değerlendiren kapsamlı bir analizi sunmaktadır. Özellikle, Lineer, K-Nearest Neighbours ve XGBoost Regresyon algoritmaları üzerinde gerçekleştirilen eğitim ve test süreçleri, detaylı bir karşılaştırmalı analiz sağlamaktadır. Bu tür bir performans değerlendirmesi, literatürde sıkça karşılaşılan uygulamalardan biri olup, farklı algoritma türlerinin avantajları ve sınırlamaları hakkında önemli bilgiler sağlamaktadır. Ancak, bu çalışmanın özgünlüğü, bu algoritmalara özgü hiperparametrelerin ve değişkenlerin kapsamlı bir şekilde incelenmesi ve bu parametrelerin tahmin performansı üzerindeki etkilerinin derinlemesine değerlendirilmesindedir. Bu yaklaşım, araçlardaki CO₂ emisyon tahmininde kullanılan regresyon algoritmalarının daha etkili bir şekilde seçilmesine ve uygulanmasına katkıda bulunabilecektir.



Şekil 11. Modellerin eğitim doğruluğu



Şekil 12. Modellerin test doğruluğu



Şekil 13. Modellerin R² skoru

5. SONUÇLAR

Araçlardan kaynaklanan CO₂ emisyonlarının eksiksiz bir biçimde anlaşılması son derece önemlidir. Bu anlayış, çevresel etkileri azaltmaya yönelik bilinçli karar alımı ve stratejik planlama için temel bir gerekliliktir. Linear Regresyon, XGBoost Regresör ve K-Nearest Neighbours algoritmaları kullanılarak arabalar için CO₂ emisyonu tahmini sonuçları, bu modellerin tahmin yetenekleri hakkında değerli bilgiler sunmaktadır.

Birincisi, Linear Regresyon modeli %90,69 eğitim doğruluğu ve %90,76 test doğruluğu ile iyi bir performans sergilemektedir. Orta düzeydeki 16,65'lik Ortalama Kareli Hata (RMSE) makul bir hassasiyet düzeyine işaret ederken, 11,06'lık Ortalama Mutlak Hata (MAE) CO₂ emisyonlarının tahmininde makul bir doğruluğa işaret etmektedir. 90,76'lık R² skoru, tahmin edilen ve gerçek değerler arasında güçlü bir korelasyon olduğunu göstermektedir. İkincisi, K-Nearest Neighbours modeli, %97,76'lık dikkate değer bir eğitim

doğruluğu ve %97,39'luk bir test doğruluğu elde ederek üstün performans göstermektedir. Doğrusal Regresyona kıyasla 8,84'lük daha düşük RMSE ve 3,75'lik MAE, gelişmiş doğruluk ve hassasiyete işaret etmektedir. Son olarak, XGBoost algoritması %99,64 gibi yüksek bir eğitim doğruluğu ve %98,75 gibi etkileyici bir test doğruluğu ile etkili algoritma olarak ortaya çıkmaktadır. En düşük 6,45 RMSE, 2,81 MAE ve %98,75 en yüksek R² skoru ile XGBoost modeli, araçlar için CO₂ emisyonlarını tahmin etmede iyi bir doğruluk, hassasiyet ve tahmin yetenekleri sergilemektedir. Sonuç olarak, bu regresyon modellerinin karşılaştırılması, araçlardan kaynaklanan CO₂ emisyonlarının tahmin edilmesinde makine öğrenimi algoritmalarının etkinliğinin altını çizmektedir. Sonuçlar, XGBoost modelinin diğer modellere göre üstünlüğünü vurgulayarak, çevresel araştırma ve politika oluşturma alanlarındaki uygulamalar için potansiyelini ortaya koymaktadır. Bu bulgular, CO₂ emisyonu tahmininin, sürdürülebilir ve çevreye duyarlı ulaşım çözümleri arayışında daha doğru ve bilinçli karar vermenin yolunu açacaktır.

6. KAYNAKLAR

- Özupak, Y., 2024. Evrişimli Sinir Ağı (ESA) Mimarileri ile Hücre Görüntülerinden Sıtmanın Tespit Edilmesi. Çukurova Üniversitesi Mühendislik Fakültesi Dergisi, 39(1), 197-210.
- Zacharof, N., Fontaras, G., Ciuffo, B., Tansini, A., Prado-Rujas, I., 2021. An Estimation of Heavy-duty Vehicle Fleet CO₂ Emissions Based on Sampled Data. Transport. Res. Transport Environ., 94, 102784.
- Ganesan, P., Rajakarunakaran, S., Thirugnanasambandam, M., Devaraj, D., 2015. Artificial Neural Network Model to Predict the Diesel Electric Generator Performance and Exhaust Emissions. Energy, 83, 115-124.
- Çay, Y., 2013. Prediction of a Gasoline Engine Performance with Artificial Neural Network. Fuel, 111, 324-331.
- Hawkes, A.D., 2010. Estimating Marginal CO₂ Emissions Rates for National Electricity Systems. Energy Policy, 38, 5977-5987.
- Labecki, L., Cairns, A., Xia, J., Megaritis, A., Zhao, H., Ganippa, L.C., 2012. Combustion and Emission of Rapeseed Oil Blends in Diesel Engine. Applied Energy, 95, 139-146.
- Tasdemir, S., Saritas, I., Ciniviz, M., Allahverdi, N., 2011. Artificial Neural Network and Fuzzy Expert System Comparison for Prediction of Performance and Emission Parameters on a Gasoline Engine. Expert Systems with Applications, 38, 13912-23.
- Anderson, T.R., Hawkins, E., Jones, P.D., 2016. CO₂, the Greenhouse Effect and Global Warming: From the Pioneering Work of Arrhenius and Callendar to Today's Earth System Models. Endeavour, 40(3), 178-187.
- Zeng, W., Miwa, T., Morikawa, T., 2016. Prediction of Vehicle CO₂ Emission and Its Application to Eco-routing Navigation. Transportation Research Part C: Emerging Technologies, 68, 194-214.
- Odoro, S., Metia, S., Duc, H., Ha, Q., 2013. CO₂ Vehicular Emission Statistical Analysis with Instantaneous Speed and Acceleration as Predictor Variables. In Proceedings of the International Conference on Control, Automation and Information Sciences, 158-163.
- Razak, N.H., Hashim, H., Yunus, N.A., Klemes, J.J., 2022. Integrated Linear Programming and Analytical Hierarchy Process Method for Diesel/Biodiesel/Butanol in Reducing Diesel Emissions. Journal of Cleaner Production, 337, 130297.
- Shim, E., Park, H., Bae, C., 2018. Intake Air Strategy for Low HC and CO Emissions in Dual-fuel (CNG-Diesel) Premixed Charge Compression Ignition Engine. Applied Energy, 225, 1068-77.
- Prabhu, A.V., Avinash, A., Brindhadevi, K., Pugazhendhi, A., 2021. Performance and Emission Evaluation of Dual Fuel CI Engine Using Preheated Biogas-air Mixture. Science of the Total Environment, 754, 142389.
- Soukht, S.H., Taghavifar, H., Jafarmadar, S., 2017. Experimental and Numerical Consideration of the Effect of CeO₂ Nanoparticles on Diesel Engine Performance and Exhaust Emission with the Aid of Artificial Neural Network. Applied Thermal Engineering, 113, 663-72.
- Alfaseeh, L., Tu, R., Farooq, B., Hatzopoulou, M., 2020. Greenhouse Gas Emission Prediction

- on Road Network Using Deep Sequence Learning. *Transport. Res. Transport Environ*, 88, 102593.
16. Claudio, M., Daniela, M., Alessandro, D.M., Ezio S., 2021. A Deep Neural Network Based Model for the Prediction of Hybrid Electric Vehicles Carbon Dioxide Emissions. *Energy and AI*, 5, 100073, 2666-5468.
 17. Jigu, S., Sungwook, P., 2023. Optimizing Model Parameters of Artificial Neural Networks to Predict Vehicle Emissions. *Atmospheric Environment*, 294, 119508, 1352-2310.
 18. Natarajan, Y., Wadhwa, G., Sri, K.R., Paul, A., 2023. Forecasting Carbon Dioxide Emissions of Light-Duty Vehicles with Different Machine Learning Algorithms. *Electronics*, 12, 2288.
 19. Al-Nefaie, A.H., Aldhyani, T.H.H., 2023. Predicting CO₂ Emissions from Traffic Vehicles for Sustainable and Smart Environment Using a Deep Learning Model. *Sustainability*, 15, 7615.
 20. Dong, T., Zhen, Z., Lun, H., Jinchong, P., Yang, X., 2023. Prediction of Cold Start Emissions for Hybrid Electric Vehicles Based on Genetic Algorithms and Neural Networks. *Journal of Cleaner Production*, 420, 138403.
 21. Paul, D., Dieudonné, T., Guillaume, C., 2023. Method and Evaluations of the Effective Gain of Artificial Intelligence Models for Reducing CO₂ Emissions. *Journal of Environmental Management*, 331, 117261, 0301-4797.
 22. Wang, Z., Feng, K., 2024. NO_x Emission Prediction for Heavy-Duty Diesel Vehicles Based on Improved GWO-BP Neural Network. *Energies*, 17, 336.
 23. Maźziel, M., 2024. Instantaneous CO₂ Emission Modelling for a Euro 6 Start-Stop Vehicle Based on Portable Emission Measurement System Data and Artificial Intelligence Methods. *Environ Sci Pollut Res*, 31, 6944-6959.
 24. CO₂ Emission by Vehicles Dataset, <https://open.canada.ca/data/en/dataset/98f1a129-f628-4ce4-b24d-6f16bf24dd64#wb-auto-6>, Erişim tarihi: 02.02.2024.

AI-Based Model Design for Prediction of COPD Grade from Chest X-Ray Images: A Model Proposal (COPD-GradeNet)

Serdar ABUT^{*1,2} ORCID 0000-0002-6617-6688

¹Siirt University, Faculty of Engineering, Department of Computer Engineering, Siirt, Türkiye
²University of Kansas School of Medicine, Department of Office of Research, Wichita, KS, USA

Geliş tarihi: 27.03.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ABUT, S., (2024). AI-Based Model Design for Prediction of COPD Grade from Chest X-Ray Images: A Model Proposal (COPD-GradeNet). Cukurova University, Journal of the Faculty of Engineering, 39(2), 325-338.

Abstract

Chronic Obstructive Pulmonary Disease (COPD) ranks high among the leading causes of death, particularly in middle- and low-income countries. Early diagnosis of COPD is challenging, with limited diagnostic methods currently available. In this study, a artificial intelligence model named COPD-GradeNet is proposed to predict COPD grades from radiographic images. However, the model has not yet been tested on a dataset. Obtaining a dataset including spirometric test results and chest X-ray images for COPD is a challenging process. Once the proposed model is tested on an appropriate dataset, its ability to predict COPD grades can be evaluated and implemented. This study may guide future research and clinical applications, emphasizing the potential of artificial intelligence-based approaches in the diagnosis of COPD.

Keywords: Artificial intelligence, COPD, Deep learning, Transfer learning, Medical image processing

Akciğer Grafilerinden KOAH Derecesinin Tahmin Edilmesi için Yapay Zeka Temelli Model Tasarımı: Bir Model Önerisi (COPD-GradeNet)

Öz

Kronik Obstrüktif Akciğer Hastalığı (KOAH), özellikle orta ve düşük gelirli ülkelerde ölüm nedenleri arasında üst sıralarda yer alır. KOAH'ın erken teşhisi zordur ve mevcut tanı yöntemleri sınırlıdır. Bu çalışmada, radyografi görüntülerinden KOAH derecelerini tahmin etmek için bir yapay zeka modeli olan COPD-GradeNet önerilmektedir. Ancak, model henüz bir veri seti üzerinde test edilmemiştir. KOAH'ın spirometrik test sonuçları ve akciğer röntgen görüntüleri gibi bir veri setinin elde edilmesi zorlu bir süreçtir. Önerilen modelin uygun bir veri setiyle test edilmesi halinde, KOAH derecelerini tahmin etme yeteneğinin değerlendirilip uygulanabileceği düşünülmektedir. Bu çalışma, gelecekteki araştırmalara ve klinik uygulamalara yol gösterebilir, KOAH teşhisinde yapay zeka tabanlı yaklaşımların potansiyelini vurgulayabilir.

Anahtar Kelimeler: Yapay zeka, KOAH, Derin öğrenme, Transfer öğrenme, Medikal görüntü işleme

*Sorumlu yazar (Corresponding Author): Serdar ABUT, serdarabut@siirt.edu.tr

1. INTRODUCTION

Chronic Obstructive Pulmonary Disease (COPD) is among the top three causes of death worldwide, with 90% of these deaths occurring in low- and middle-income countries. According to a report published in 2021, globally, 3 million people died due to COPD in the year 2012 [1]. It has been assessed that COPD is a prevalent, preventable, and treatable disease. COPD, characterized by chronic airflow limitation, is a combination of bronchitis (airway narrowing disease) and emphysema (destruction of small air sacs). COPD causes different types of damage in the lung parenchyma from person to person due to structural differences in the airways [2].

1.1. The Relationship Between COPD and Chest X-Ray Images

In [3], it was stated that chest X-rays alone cannot be used by clinicians to diagnose COPD and that spirometric tests, the patient's symptoms, and health history must be considered among many criteria for COPD diagnosis. The lack of sensitive diagnostic tests for early stages of COPD results in insufficient diagnosis of this treatable disease in an estimated 60-85% of patients [4]. COPD creates a pattern of damage on lung parenchyma [3], which is reflected in chest X-rays through a technique [5,6] currently being tested on mice [7] and cadavers [4]. The findings obtained with this imaging technique suggest that improvements in early diagnosis of COPD can be achieved using X-ray images [4]. Considering that clinicians use biological vision (human vision) and that the human eye tries to understand images more by using shape information while machine vision tries to interpret images using texture information [8,9], we foresee that the high-accuracy diagnosis of COPD from chest X-rays through machine vision will be possible in the near future.

In recent years, artificial intelligence methods, especially deep convolutional neural networks (DCNNs), have been widely used to enable clinicians to automate tasks such as the classification of COVID-19 from CT [10] and chest X-ray images [11-13], determination of the severity

of COVID-19 [14], diagnosis of proximal femur fracture from MR images [15], early detection of pathological changes in bone microstructures [16], disease diagnosis using laboratory test results [17], determination of the effectiveness of Shapley value in identifying low-quality and valuable data for pneumonia detection [18], and localization of common chest diseases on chest X-rays [19], and improving the performance of radiologists in breast cancer screening [20]. With the proliferation of deep learning models, the field of medical image processing has garnered widespread interest, particularly in radiology [21-23]. The results of these studies aimed at solving complex problems suggest that the idea of predicting COPD stages using artificial intelligence methods through chest X-rays will be successful. Therefore, COPD-GradeNet will fill an important gap in the literature.

1.2. Advancements Offered by Deep Learning Tools

In the diagnosis of lung diseases, lung X-rays are frequently used. Artificial intelligence-based studies have been carried out to assist in the diagnosis of emphysema [24], which can be seen in individuals who smoke but do not meet the criteria for COPD, despite being commonly seen in COPD patients [25-28]. In these studies [29-31], Computerized Tomography (CT) used for classifying emphysema or airway-dominant for the classification of COPD disease was used as a model input. Considering that the severity of emphysema may not correlate with the severity of COPD and that lung tissue characteristics of COPD patients in the same stage may show significant changes [31], and given that X-ray images that are more economical and cause less radiation exposure will be used in our project compared to CT, the COPD-GradeNet model with the theoretical infrastructure presented in this study differs from other studies on COPD staging.

Wang et. al. [11] developed a machine learning model using lung X-ray images to identify pneumonia caused by COVID-19. With this deep learning-based model, the diagnosis and severity of pneumonia caused by COVID-19 were determined, whether pneumonia was caused by COVID-19 was

identified, and the lesion areas of pneumonia were color-coded to provide information to radiologists. The results of this deep learning-based artificial intelligence model were reported to have a 98% match with the diagnoses of radiologists [11]. In our study, we aim to determine the disease level of individuals classified into 4 different stages of COPD and 1 control group without COPD, using only lung X-rays, through deep learning models according to the guidelines proposed in [3].

In a study proposing a machine learning-based model to aid expert radiologists in distinguishing COVID-19-induced pneumonia from other types of pneumonia using lung X-ray images, 420 X-ray images were analyzed [13]. Different feature extraction methods were used to represent X-ray images in lower dimensions. Based on these features, a test set consisting of 25 COVID-19, 31 normal, and 28 non-COVID pneumonia X-ray images was classified with an accuracy of 94% (AUC) [13]. Most feature extraction methods used in literature are similarly applied in different applications [32]. For example, the local binary pattern method is used in fingerprint applications [33] as well as iris recognition applications [34]. However, deep learning methods learn problem-specific features and perform data-driven dimensionality reduction. Therefore, deep learning can solve much more complex problems [35]. A study on MR images compared feature extraction methods and reported that deep learning methods were successful compared to classical feature extraction methods [36]. However, deep learning models require a large number of samples [35]. The lack of a large and shared dataset consisting of labeled lung X-ray images for COPD stages is thought to be the reason why this topic has not been studied in the literature. In this study, we plan to perform feature extraction with deep learning methods as we believe COPD staging is a complex problem. We expect that such a COPD-GradeNet model will provide effective results with labeled lung X-ray images of at least 500 individuals from the control group and from each of the four stages of COPD, totaling 2500 individuals.

1.3. The Potential of Deep Learning Tools to Address COPD Issues

With the COPD-GradeNet model, the following issues can be addressed by determining the stage of COPD solely from lung X-rays without the need for challenging spirometric tests. The difficulties of relying on spirometric tests for a COPD diagnosis can be overcome by taking a lung X-ray and analyzing it with an artificial intelligence model. Respiratory tests can be challenging, especially for elderly patients, and depending on the operator and the patient's condition, these tests may not guarantee consistent results. Respiratory function tests cannot be applied to patients with conditions such as hemoptysis (coughing up blood), tuberculosis, pneumothorax, recent heart attack or stroke, Alzheimer's disease, and dementia who are unable to follow commands. In addition, correct measurements cannot be obtained from respiratory function tests due to noncompliance with commands due to factors such as the patient's sociocultural level and mental illnesses [37].

The COPD-GradeNet we propose can provide an alternative method to respiratory tests by being a model based solely on using a lung X-ray for COPD staging. Additionally, a COPD-GradeNet can be created that will help with the diagnosis using a radiography device, which is available in almost every health center, instead of a respiratory function test device that is not available in every center. CT scans are taken to monitor the course of emphysema caused by COPD. The radiation dose that the human body is exposed to during a CT scan is between 10-20mSv [38], and with multiple CT scans performed at different times during a patient's follow-up, the amount of radiation exposure can reach very high levels that can exceed the carcinogenic effect threshold. Therefore, clinicians around the world tend to take fewer CT scans to protect the patient. By creating a diagnostic model using X-ray technology that exposes the body to radiation at a lower level - between 0.02-0.15mSv [38]- with the COPD-GradeNet model, more observations can be made at earlier stages with less harmful approaches. See [39] for a more detailed comparison of CT and X-ray. Considering that CT devices are not available in every center due to costs and needs, but

radiography devices are widely used, the proposed COPD-GradeNet has the potential to reduce issues associated with CT scans.

1.4. The Feature of the COPD-GradeNet Model to Direct the Studies on this Subject

In the COPD-GradeNet, using a deep learning model that performs feature extraction and classification well, regions related to COPD on lung X-rays will be colored. This process is called localization. After localization, radiological images can be analyzed and reported without human intervention, opening the door to applications that can be reported automatically. In addition, coloring areas related to COPD on the image can speed up clinicians' diagnosis and improve the diagnostic abilities of inexperienced physicians for educational purposes. Indeed, it has been noted that such artificial intelligence models increase the success rates and speed of correct diagnoses by medical doctors [11]. While CT images are reported by specialist radiologists in most countries of the world, lung X-rays are not reported by radiologists and are evaluated by clinicians. The proposed model will shed light on the development of systems that will also serve as artificial intelligence-based reporting for major pathologies in the lungs.

1.5. The Aim and Objectives of COPD-GradeNet

The goal of the COPD-GradeNet is to create an artificial intelligence-based model that can predict the stage of Chronic Obstructive Pulmonary Disease (COPD) from lung X-ray images. Receiver Operating Characteristic (ROC) analysis will be used to evaluate the performance of the AI-based model in classifying the four stages of COPD. The accuracy with which each stage of COPD can be distinguished by the model will be determined by the Area Under Curve (AUC) analysis. The model is expected to produce promising results when the mean AUC value of all groups in classifying the stages of COPD reaches at least 0.80.

The dataset required for training the model includes lung X-rays taken simultaneously with spirometry from a total of 2,500 individuals, with at least 500

images from each of the four different stages of COPD and a control group, which have been diagnosed by expert clinicians. This dataset is assumed to have labels indicating the spirometric stage of COPD and accompanying lung pathologies diagnosed by CT, obtained by examining the spirometry test results conducted simultaneously with lung X-rays. Spirometric measurements should be evaluated as the gold standard for COPD staging, while CT images should be used as the gold standard for lung diseases such as emphysema and bronchiectasis.

Preprocessing: The differences caused by uncontrollable factors in X-ray images (brightness, contrast, etc.) must be eliminated and the images must be standardized in the dataset. This new standardized dataset should be divided into subsets of training (train), validation (validation), and testing in an 8:1:1 ratio, respectively.

Distinguishing COPD from other lung diseases and coloring the regions related to diseases: To distinguish COPD from other lung diseases that can be diagnosed with CT (Asthma, Congestive Heart Failure, Bronchiectasis, Tuberculosis, Obliterative Bronchiolitis, Diffuse Panbronchiolitis [3]), a multilabel classifier should be used instead of a multiclass classifier. At this stage, the probability of COPD and other lung diseases can be estimated as a percentage. It can be assumed that this goal has been achieved if the AUC value of the model in distinguishing COPD from other lung diseases is at least 0.80. After the trained model achieves classification accuracy, regions that are effective in distinguishing (discriminative) diseases with the highest probability predicted by the model can be colored and weighted on the X-ray image using the object localization technique [40,41]. Thus, the discriminative regions that are effective in distinguishing the disease with the highest probability predicted by the model can be weighted in the X-ray. As a result, an image that will be used as input for the next stage of COPD staging will be obtained. This image will be a weighted image of the regions related to COPD, with other lung diseases filtered out, which will improve the performance of the COPD-GradeNet

2. MATERIAL AND METHOD

2.1. Creation of Dataset

The lung images that will be used as input for the COPD-GradeNet model, as well as information such as respiratory function test results and the stage of COPD, should be obtained. For this, X-ray images of a total of 2,500 people should be obtained, 500 from each group of non-COPD and COPD with 4 stages, who have been diagnosed by expert physicians. It is important to ensure consistent data as the X-ray films are taken simultaneously with respiratory function tests. It should be noted that an equal number of samples (500 each) should be selected from each stage when selecting the X-ray images.

The dataset should be compiled by gathering information about which stage of COPD the patient is in spirometrically and any accompanying lung pathologies determined by CT. Therefore, classification based on spirometrically determined staging from respiratory function tests should be used as the gold standard for COPD staging. For the detection of other lung diseases such as asthma, congestive heart failure, bronchiectasis, tuberculosis, obliterative bronchiolitis, and diffuse panbronchiolitis, diagnoses made by expert physicians from CT images should be used as the gold standard.

Risk of insufficient dataset: There is a risk of not obtaining at least 500 X-ray images from each of the four levels, or even obtaining at least 500 images from each class, but realizing that the problem is more complex than anticipated (i.e., not being able to obtain any model with $AUC \geq 0.80$ for each class), which may require more examples. To solve these problems, data augmentation techniques [42,43] such as random flipping in the x and y axes for classes with insufficient X-ray images, random rotation in the range of $[\alpha, \beta]$ degrees, and random scaling in the range of $[x, y]$ can be used to derive new data from existing data, which can improve the performance of the COPD-GradeNet model.

2.2. Preprocessing

The dataset should be created from the information of individuals with COPD stages graded as Grade1, Grade2, Grade3, and Grade4, and a control group with the label G0, who do not have COPD (Figure 1-A). When these images are obtained retrospectively, it should be considered that a patient may have multiple follow-ups and multiple finding labels at the same time. To reflect true learning in COPD-GradeNet model's performance metrics, one image should be taken from each patient. Selecting images from the Anterior-posterior (AP) views of these patients, rather than the posterior-anterior (PA) views, is important as lung patterns are clearer in AP images. A data table should be created indicating which of the 6 diseases were seen with COPD by reading each CT report belonging to these individuals. This data table should consist of columns that include a unique random identification number for each sample, the COPD stage of that individual, and whether the six specified diseases were present or not (Figure 1-A). model.

When considering that the X-ray images to be obtained will be used in the training of an artificial intelligence-based model, it is anticipated that standardization processes should be performed on these images at the preprocessing stage to create a robust model. Examining X-ray images is an important step for medical diagnosis, and problems such as low contrast and low color range in these images make it difficult to see information in bright or dark areas [44].

Low contrast and low brightness problems are commonly observed in X-ray images [45]. Deep convolutional neural networks are developed by taking inspiration from human vision [46-48]. In order to improve the classification performance of these deep networks, it is necessary to eliminate the potential tonal differences that may occur in X-ray images. Therefore, histogram equalization [49] will be performed as a preprocessing step on all X-ray images considered as input to the model.

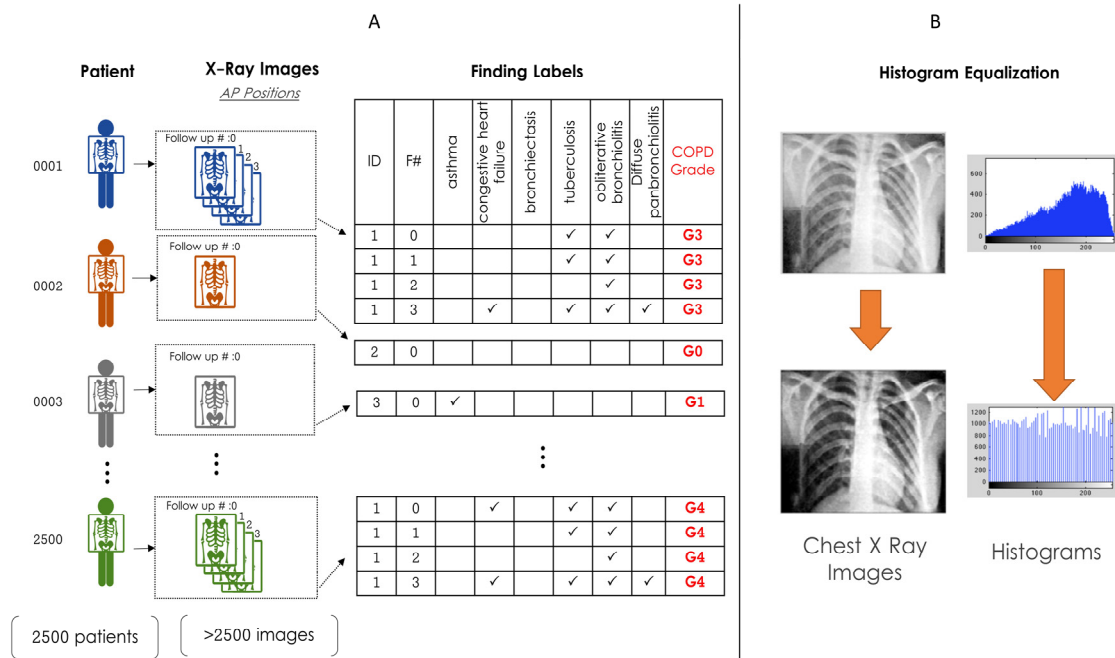


Figure 1. The formation scheme of the dataset. A) A representative data table showing the stages of COPD and accompanying diseases. B) Histogram equalization process to be applied to each image

2.3. Deep Convolutional Neural Networks-DCNNs

A paper by Yann LeCun and his colleagues, which proposed the use of artificial neural networks in computer vision, was rejected from a leading conference in 2008. At the time, it was generally believed that computer vision could not be solved entirely with artificial neural networks, and that there needed to be stages designed by hand. It was assumed that a problem related to object recognition could not be solved simply by using images and labels. Concerns about displacing the skills of programmers in computer vision with a general learning technique procedure are thought to have contributed to this situation [50].

Approaches to object recognition use machine learning methods as a basis. In order to improve the performance of these methods, larger datasets should be collected, and better techniques should be used to avoid overfitting. Before the idea of deep convolutional networks, the datasets used in computer vision (e.g. NORB [51], Caltech-256

[52], etc.) contained relatively few examples, numbering in the tens of thousands. For simple recognition problems, models that use data techniques derived from these relatively small datasets (augmented) have achieved human-like performance and surpassed human performance in traffic sign classification [53].

However, since real-world objects exhibit considerable variability from these datasets, larger training datasets are required to achieve high accuracy in recognizing these objects with computer vision [50]. Recently, it has become possible to create such datasets. ImageNet [54] consists of 15 million labeled images from 22,000 categories, while LabelMe [55] consists of hundreds of thousands of images that have been segmented. Convolutional neural networks have demonstrated high success rates in object recognition and image classification within these datasets [50,56].

To learn (classify) thousands of objects from millions of images, enormous learning capacity

models are required. However, the tremendous complexity of object recognition necessitates predicting the difficulties that will be encountered in classifying such a large number of categories using traditional methods. Therefore, to solve such a problem with classical methods, one must have a lot of prior knowledge. However, deep convolutional neural networks (DCNNs) are able to automatically learn this prior knowledge while solving these types of problems. These networks, whose depths and widths can be changed to control their capacities, make strong and mostly accurate assumptions about the nature of images (i.e., the regularity of statistics and pixel dependencies). As a result, compared to standard feedforward neural networks with layers of similar sizes, DCNNs are easier to train since they have much fewer connections (locally-connected) and parameters [50].

2.4. Differentiating COPD from Other Lung Diseases

In order to design a deep convolutional neural network model that will predict the stages of COPD, which is the aim of our model, it is necessary to distinguish between COPD and comorbid diseases. For this purpose, modules for planned disease differentiation and visualization of lesion sites are shown in Figure 2.

Module-1, shown in Figure 2, has labels to indicate the classes (7 different diseases) that will be the output of the deep convolutional neural network. The properties and weights of the classes at the output of Module -1 become the input of Module-2. The details of these modules are explained in the following subheadings.

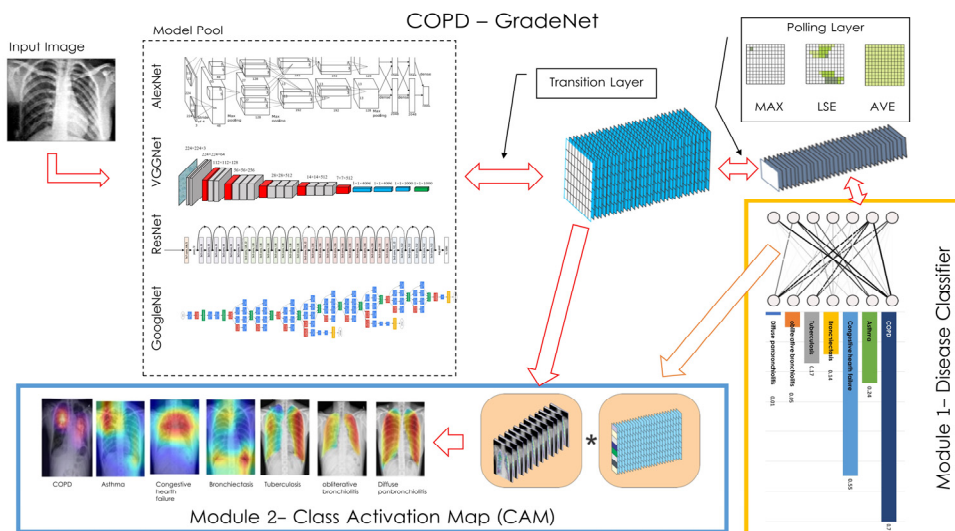


Figure 2. Modules of the COPD-GradeNet model (Module 1 & Module 2)

2.4.1. Model Pool

The learning processes of deep convolutional neural networks are affected by costs such as time and hardware, so in order to facilitate the learning process, the transfer learning technique based on the principle of reusing the information obtained from past tasks will be applied [57]. Because fine-tuning a network with transfer learning is often much faster

and easier than training a network with weights randomly started from scratch. We predict that COPD-GradeNet will be successful with the use of this technique, which provides high classification performance using a small number of training images [58-60]. Since it is not known in advance which trained network will have high performance, the model pool consists of 4 networks such as AlexNet [50], GoogLeNet [61], VGGNet-16 [62],

ResNet-50 [63], which have proven themselves in the literature. The models can be trained by removing the final classification layers of these networks and adding the classification layer suitable for the purpose of COPD-GradeNet (Figure 2).

2.4.2. Module 1&2- Disease Classifier

In the classification of diseases, the development of a standard terminology is very important in terms of epidemiological studies, calculations of healthcare costs, and national/international comparisons of diseases, and according to a study [64] done to make this standard classification by machines, deep learning networks make great contributions to the solution of multi-label classification problems. provides. In a study [65] conducted to evaluate the classification performance of COVID-19 using two different datasets of labeled chest X-ray images of 16 different deep learning models, AUC 0.83-0.89 for the CheXpert dataset and AUC 0.983-0.988 for the COVID-19 Image Data Collection dataset. reported to have excellent performance. In the same study, it was reported that even a certain amount of shallow network models used approached high performance. From this point of view, we think that it will be possible to find a suitable deep mesh model according to the complexity of the problem to be solved as a result of the COPD-GradeNet model.

The aim of a classifier model is to assign one or multiple labels to each instance in a sample space [66]. Most classification problems associate each instance with only one class [67]. This is referred to as a multiclass classification problem, where an instance belongs to only one of multiple classes. However, there are many classification problems in

which each instance can be associated with one or more classes. Such problems are known as multilabel classification problems [67]. For example, each patient can be simultaneously diagnosed with multiple classified diseases, which is an instance of a multilabel classification problem. Since COPD, which is the disease the COPD-GradeNet model is trying to solve, is often seen with other diseases [3], it is necessary to distinguish these diseases before staging COPD. The patterns of the identified 7 different diseases can be seen simultaneously in a person's lung X-ray, so a multilabel classification approach will be used instead of a multiclass classifier model. This will allow for overlapping between different diseases, and predictions will be made separately for each disease instead of making a single final prediction.

The deep learning network created in the disease classifier module should have approximately 2500 preprocessed lung X-ray images as training input. The process for creating the database of these images, including how the other 6 diseases that can be seen with COPD will be labeled and how preprocessing will be applied, has been explained above. After these stages, a deep learning classifier model will be designed to predict the class of these diseases, which have been labeled by expert physicians based on X-ray images (Figure 3). The predicted class labels and pre-determined COPD stages can be used as input for the task of coloring the lesion regions in the next stage (Figure 2).

The activation function used in the output layer that concerns Module-1 will be the sigmoid function. Thus, the values calculated between (0,1) for each of the 7 diseases will also indicate the probability of having that disease (Figure 3).




Figure 3. Module-1: A diagram showing the input image, the deep network, and the output layer consisting of 7 neurons

At this stage, it is impossible to know in advance what ratios of examples with diseases accompanying COPD will be in the dataset. The situation where at least 3 of the 6 diseases accompanying COPD are below 5% can be considered as an important risk criterion. In order to solve this problem, the risks that will arise from data insufficiency can be minimized by using a multiclass classifier model that separates 3 groups as “COPD”, “not COPD” and “at least one of the other diseases” instead of modifying the multi-label classifier model, since only COPD staging is aimed to be performed in the next stage according to the objectives of COPD-GradeNet model, and there will be no internal evaluation on other diseases.

In the COPD-GradeNet model, after the disease classification process is completed, the regions

belonging to that disease will be colored on the X-ray. In this coloring process, the original image will be used in the form of grayscale and only the area corresponding to the disease will be colored. Thus, it will be ensured that the radiologist focuses on the area where the disease is located.

The block diagram of the entire model to be developed for COPD-GradeNet is roughly shown in Figure 4. In this diagram, the COPD image is transferred to another classifier for COPD staging from 7 images, which have been colored (weighted) with respect to the regions related to the disease as the output of Module-2. The outputs of Module-3 consist of 5 classes: patients without G0 COPD, and stages determined according to the severity of COPD between G1 and G4.

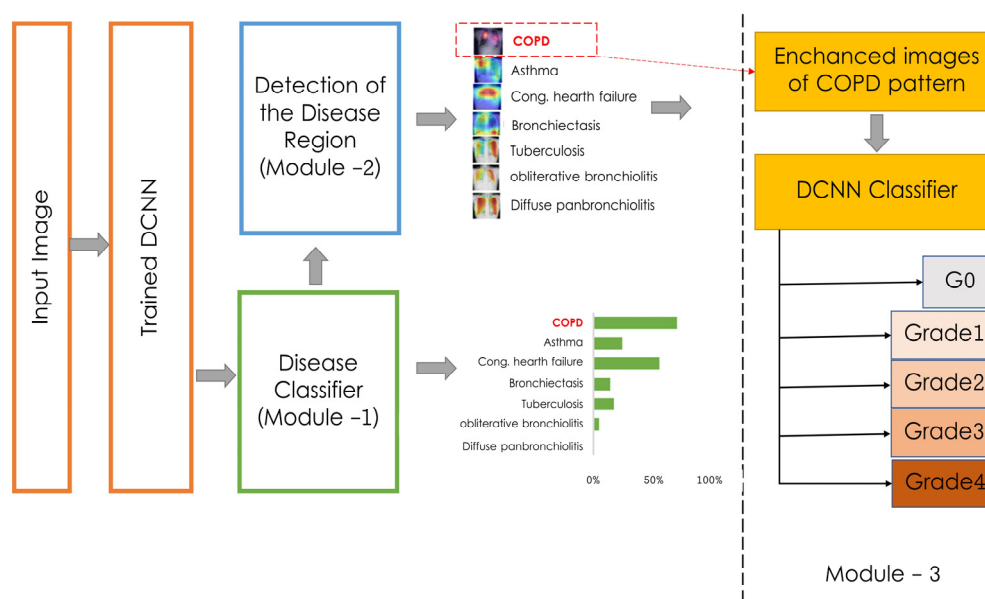


Figure 4. Transfer of the image related to COPD from the localized images, which are the output of Module-2, to Module-3

2.4.3. Module 3 – Prediction of COPD Stage

In Module-2, the effects of non-COPD diseases on the X-ray images will be removed by weighting the regions related to COPD. This way, the COPD staging task will be executed in a healthy manner. Similar to Module-1, a model pool will be created

with AlexNet [50], GoogLeNet [63], VGGNet-16 [62], and ResNet-50 [63] networks that have completed training on large datasets for the DCNN model that will perform COPD staging. The model that performs the best with transfer learning approach from these networks will be selected and the classification problem will be solved for COPD

staging. Transfer learning-based DCNNs have been successfully used in fields such as bioinformatics [68], biomedical image processing [69], recommender systems [70], autonomous vehicle technology [71], natural language processing [72]. Transfer learning aims to enable systems to quickly adapt themselves to new situations, tasks, and environments. It provides machine learning systems with the ability to leverage auxiliary data and models to help solve target problems when there is only limited data available in the target domain. The technique of transfer learning makes these systems more reliable and robust, ensuring that the machine learning model achieves its expected performance [73,74].

3. DISCUSSION

The lack of sensitive diagnostic tests, especially for early stages of COPD, leads to insufficient diagnosis of a treatable disease. With our proposed COPD-GradeNet, it is believed that early diagnosis, which will allow possible treatments, will be greatly contributed, especially by being able to classify Grade1 from lung X-rays.

The advantages that deep learning models like COPD-GradeNet can provide are as follows:

More Accurate and Reliable Results: Deep learning methods enable accurate prediction of disease levels by analyzing and learning from large amounts of data, resulting in more accurate and reliable results.

Fast and Automatic Analysis: Deep learning algorithms make data analysis fast and automatic, allowing for faster detection of COPD levels.

Personalized Treatment: Deep learning algorithms can help create personalized treatment plans by accurately detecting the disease level. This can improve the effectiveness of the treatment.

Reduced Risk of Death: Deep learning methods can analyze various features used to predict COPD levels and can predict the patient's risk of death. This can increase the patient's chances of survival by enabling earlier intervention in the treatment plan.

Data-Driven Decision Making: Deep learning methods provide an objective approach to decision-making by analyzing large amounts of data. This helps doctors make data-driven decisions and contributes to better management of disease levels.

4. CONCLUSION

This study being a theoretical model proposal, no experimental results have been presented. The model to be developed integrates a series of techniques for the automatic use of the progression of future Chronic Obstructive Pulmonary Disease (COPD) with Deep Convolutional Neural Networks (CNNs). By laying out the theoretical foundations of COPD-GradeNet, the potential impact on early diagnosis services and resource optimization in primary healthcare has been emphasized when implementing the model. Any specific limitations related to the model's performance have not been discussed. Consequently, the importance of leveraging deep learning for COPD diagnosis has been underscored, and further validation and testing are encouraged to assess the real-world applicability of COPD-GradeNet. Future data-driven studies are recommended to explore the integration of the model into clinical practice for improved COPD management.

5. ACKNOWLEDGEMENTS

Author acknowledges a Postdoctoral grant from the Scientific and Technical Research Council of Turkey (TUBITAK, 2219 - International Postdoctoral Research Scholarship Programme, 1059B192100853).

6. REFERENCES

1. Roman-Rodriguez, M., Kaplan, A., 2021. GOLD 2021 Strategy Report: Implications for Asthma-COPD Overlap. *Int J Chron Obstruct Pulmon Dis*, 16, 1709-1715.
2. Halpin, D.M.G., Criner, G.J., Papi, A., Singh, D., Anzueto, A., Martinez, F.J., Agusti, A.A., Vogelmeier, C.F., 2021. Global Initiative for the Diagnosis, Management, and Prevention of Chronic Obstructive Lung Disease. *The 2020*

- GOLD Science Committee Report on COVID-19 and Chronic Obstructive Pulmonary Disease, *Am J Respir Crit Care Med*, 203, 24-36.
3. GOLD, 2021 Global Strategy for Prevention, Diagnosis and Management of COPD, 2021. 1-164.
 4. Willer, K., Fingerle, A.A., Gromann, L.B., De Marco, F., Herzen, J., Achterhold, K., Gleich, B., Muenzel, D., Scherer, K., Renz, M., Renger, B., Kopp, F., Kriner, F., Fischer, F., Braun, C., Auweter, S., Hellbach, K., Reiser, M.F., Schroeter, T., Mohr, J., Yaroshenko, A., Maack, H.I., Pralow, T., van der Heijden, H., Proksa, R., Koehler, T., Wieberneit, N., Rindt, K., Rummeny, E.J., Pfeiffer, F., Noel, P.B., 2018. X-ray Dark-Field Imaging of the Human Lung-A Feasibility Study on a Deceased Body. *PLoS One*, 13, e0204565.
 5. Bech, M., Bunk, O., Donath, T., Feidenhans'l, R., David, C., Pfeiffer, F., 2010. Quantitative X-ray Dark-Field Computed Tomography. *Physics in Medicine and Biology*, 55, 5529-5539.
 6. Pfeiffer, F., Bech, M., Bunk, O., Kraft, P., Eikenberry, E.F., Bronnimann, C., Grunzweig, C., David, C., 2008. Hard-X-ray Dark-Field Imaging Using a Grating Interferometer, *Nat Mater*, 7, 134-137.
 7. Meinel, F.G., Yaroshenko, A., Hellbach, K., Bech, M., Muller, M., Velroyen, A., Bamberg, F., Eickelberg, O., Nikolaou, K., Reiser, M.F., Pfeiffer, F., Yildirim, A.O., 2014. Improved Diagnosis of Pulmonary Emphysema Using in Vivo Dark-Field Radiography. *Invest Radiol*, 49, 653-658.
 8. Baker, N., Lu, H., Erlikhman, G., Kellman, P.J., 2018. Deep Convolutional Networks do Not Classify Based on Global Object Shape, *PLOS Computational Biology*, 14, e1006613.
 9. Tuli, S., Dasgupta, I., Grant, E., Griffiths, T.L., 2021. Are Convolutional Neural Networks or Transformers More Like Human Vision?, *arXiv preprint arXiv:2105.07197*.
 10. Afshar, P., Heidarian, S., Enshaie, N., Naderkhani, F., Rafiee, M.J., Oikonomou, A., Fard, F.B., Samimi, K., Plataniotis, K.N., Mohammadi, A., 2021. COVID-CT-MD, COVID-19 Computed Tomography Scan Dataset Applicable in Machine Learning and Deep Learning. *Scientific Data*, 8, 121.
 11. Wang, G., Liu, X., Shen, J., Wang, C., Li, Z., Ye, L., Wu, X., Chen, T., Wang, K., Zhang, X., Zhou, Z., Yang, J., Sang, Y., Deng, R., Liang, W., Yu, T., Gao, M., Wang, J., Yang, Z., Cai, H., Lu, G., Zhang, L., Yang, L., Xu, W., Wang, W., Olvera, A., Ziyar, I., Zhang, C., Li, O., Liao, W., Liu, J., Chen, W., Chen, W., Shi, J., Zheng, L., Zhang, L., Yan, Z., Zou, X., Lin, G., Cao, G., Lau, L. L., Mo, L., Liang, Y., Roberts, M., Sala, E., Schonlieb, C.B., Fok, M., Lau, J.Y., Xu, T., He, J., Zhang, K., Li, W., Lin, T., 2021. A Deep-learning Pipeline for the Diagnosis and Discrimination of Viral, Non-viral and COVID-19 Pneumonia from Chest X-ray Images. *Nat Biomed Eng*, 5, 509-521.
 12. Elaziz, M.A., Hosny, K.M., Salah, A., Darwish, M.M., Lu, S., Sahlol, A.T., 2020. New Machine Learning Method for Image-Based Diagnosis of COVID-19. *PLoS One*, 15, e0235187.
 13. Zargari Khuzani, A., Heidari, M., Shariati, S. A., 2021. COVID-Classifier: an Automated Machine Learning Model to Assist in the Diagnosis of COVID-19 Infection in Chest X-ray Images. *Sci Rep*, 11, 9887.
 14. Patel, R.K., Kashyap, M., 2022. Automated Diagnosis of COVID Stages from Lung CT Images Using Statistical Features in 2-dimensional Flexible Analytic Wavelet Transform. *Biocybern Biomed Eng*, 42, 829-841.
 15. Deniz, C.M., Xiang, S., Hallyburton, R.S., Welbeck, A., Babb, J.S., Honig, S., Cho, K., Chang, G., 2018. Segmentation of the Proximal Femur from MR Images Using Deep Convolutional Neural Networks. *Sci Rep*, 8, 16485.
 16. Jakaite, L., Schetinin, V., Hladuvka, J., Minaev, S., Ambia, A., Krzanowski, W., 2021. Deep Learning for Early Detection of Pathological Changes in X-ray Bone Microstructures: Case of Osteoarthritis. *Sci Rep*, 11, 2294.
 17. Park, D.J., Park, M.W., Lee, H., Kim, Y.J., Kim, Y., Park, Y.H., 2021. Development of Machine Learning Model for Diagnostic Disease Prediction Based on Laboratory Tests. *Sci Rep*, 11, 7567.
 18. Tang, S., Ghorbani, A., Yamashita, R., Rehman, S., Dunnmmon, J.A., Zou, J., Rubin, D.L., 2021. Data Valuation for Medical Imaging Using

- Shapley Value and Application to a Large-scale Chest X-ray Dataset. *Sci Rep*, 11, 8366.
19. Chen, Y., Wan, Y., Pan, F., 2023. Enhancing Multi-disease Diagnosis of Chest X-rays with Advanced Deep-learning Networks in Real-World Data. *J Digit Imaging*, 36, 1332-1347.
 20. Shen, Y., Wu, N., Phang, J., Park, J., Liu, K., Tyagi, S., Heacock, L., Kim, S.G., Moy, L., Cho, K., Geras, K.J., 2021. An Interpretable Classifier for High-resolution Breast Cancer Screening Images Utilizing Weakly Supervised Localization. *Med Image Anal*, 68, 101908.
 21. Abut, S., Okut, H., Kallail, K.J., 2024. Paradigm Shift from Artificial Neural Networks (ANNs) to Deep Convolutional Neural Networks (DCNNs) in the Field of Medical Image Processing. *Expert Systems with Applications*, 244, 122983.
 22. Abut, S., Okut, H., Zackula, R., James Kallail, K., 2024. Deep Neural Networks and Applications in Medical Research, in: D.M.J.D.-M. Ph. C.-M. Dr. Javier, M.-S. Mr. Luis, D. Dr. Robertas (Eds.) *Deep Learning-Recent Findings and Research*. IntechOpen, Rijeka, Ch. 1.
 23. Abut, S., Okut, H., 2024. The Importance of Artificial Neural Networks in Decision Making for the Field of Medicine, in: G.A. Indrajit, Mittal; Hemlata, Jain (Ed.) *The Future of Artificial Neural Networks*. Nova Science, New York, 1-24.
 24. Mouronte-Roibás, C., Fernández-Villar, A., Ruano-Raviña, A., Ramos-Hernández, C., Tilve-Gómez, A., Rodríguez-Fernández, P., Díaz, A.C.C., Vázquez-Noguerol, M.G., Fernández-García, S., Leiro-Fernández, V., 2018. Influence of the Type of Emphysema in the Relationship Between COPD and Lung Cancer. *International Journal of Chronic Obstructive Pulmonary Disease*, 13, 3563.
 25. Humphries, S.M., Notary, A.M., Centeno, J.P., Strand, M.J., Crapo, J.D., Silverman, E.K., Lynch, D.A., Genetic Epidemiology of COPD Investigation, 2020. Deep Learning Enables Automatic Classification of Emphysema Pattern at CT. *Radiology*, 294, 434-444.
 26. Germán, G., George, R.W., Raúl San José, E., 2018, Deep Learning for Biomarker Regression: Application to Osteoporosis and Emphysema on Chest CT Scans. *Proc. SPIE*, 10574
 27. Campo, M.I., Pascau, J., Estépar, R.S.J., 2018. Emphysema Quantification on Simulated X-rays Through Deep Learning Techniques. 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), 273-276
 28. Mohammadreza, N., David, B., 2019. Lung Tissue Characterization for Emphysema Differential Diagnosis Using Deep Convolutional Neural Networks. *Proc. SPIE*, 10950.
 29. Boschetto, P., Miniati, M., Miotto, D., Braccioni, F., De Rosa, E., Bononi, I., Papi, A., Saetta, M., Fabbri, L.M., Mapp, C.E., 2003. Predominant Emphysema Phenotype in Chronic Obstructive Pulmonary Disease Patients. *European Respiratory Journal*, 21, 450.
 30. Snoeck-Stroband, J.B., Lapperre, T.S., Gosman, M.M., Boezen, H.M., Timens, W., ten Hacken, N.H., Sont, J.K., Sterk, P.J., Hiemstra, P.S., Groningen Leiden Universities Corticosteroids in Obstructive Lung Disease Study, G., 2008. Chronic Bronchitis Sub-phenotype Within COPD: Inflammation in Sputum and Biopsies. *Eur Respir J*, 31, 70-77.
 31. Makita, H., Nasuhara, Y., Nagai, K., Ito, Y., Hasegawa, M., Betsuyaku, T., Onodera, Y., Hizawa, N., Nishimura, M., Hokkaido, C.C.S.G., 2007. Characterisation of Phenotypes Based on Severity of Emphysema in Chronic Obstructive Pulmonary Disease. *Thorax*, 62, 932-937.
 32. Ergen, B., Abut, S., 2013. Gender Recognition Using Facial Images. *Proceedings of International Conference on Agriculture and Biotechnology IPCBEE*, IACSIT Press, Singapore, 60(22), 112-117
 33. Masmoudi, A.D., Masmoudi, D.S., 2010. Implementation of a Fingerprint Recognition System Using LBP Descriptor. *Journal of Testing and Evaluation*, 38, 369-382.
 34. Shams, M., Rashad, M., Nomir, O., El-Awady, R., 2011. Iris Recognition Based on LBP and Combined LVQ Classifier. *ArXiv*, abs/1111.1562.
 35. Haibo, W., Angel, C.-R., Ajay, B., Hannah, G., Natalie, S., Mike, F., John, T., Fabio, G., Anant, M., 2014, Cascaded Ensemble of Convolutional Neural Networks and Handcrafted Features for Mitosis Detection. *Proc.SPIE*, 9041.

36. Lin, W., Hasenstab, K., Moura Cunha, G., Schwartzman, A., 2020. Comparison of Handcrafted Features and Convolutional Neural Networks for Liver MR Image Adequacy Assessment. *Sci Rep*, 10, 20336.
37. Abut, S., Doğanay, F., Yeşilova, A., Buğa, S., 2021. Analysis of Pulmonary Function Test Results By Using Gaussian Mixture Regression Model. *Journal of Clinical Medicine of Kazakhstan*, 18, 23-29.
38. Kuru, L.İ., Günay, O., Palacı, H., Yarar, O., 2019. Bilgisayarlı Tomografilerde Hastanın Aldığı Efektif Radyasyon Dozunun Belirlenmesi. *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 21, 436-443.
39. Işık, Z., Selçuk, H., Albayram, S., 2010. Bilgisayarlı Tomografi ve Radyasyon. *Klinik Gelişim*, 23, 16-18
40. Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., Torralba, A., 2016. Learning Deep Features for Discriminative Localization, 2921-2929
41. Oquab, M., Bottou, L., Laptev, I., Sivic, J., 2015. Is Object Localization for Free?-Weakly-Supervised Learning with Convolutional Neural Networks, 685-694
42. Perez, L., Wang, J., 2017. The Effectiveness of Data Augmentation in Image Classification using Deep Learning. *ArXiv*, abs/1712.04621.
43. Shorten, C., Khoshgoftaar, T.M., 2019. A Survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6, 60.
44. Huang, C.C., Nguyen, M.H., 2019. X-Ray Enhancement Based on Component Attenuation, Contrast Adjustment, and Image Fusion. *IEEE Trans Image Process*, 28, 127-141.
45. Liu, Y., Zhang, P.C., Gui, Z.G., 2021. An Enhancement Framework Based on Gradient Domain Tone Mapping and Fuzzy Logical for X-ray Image of Complex Workpiece. *Ndt & E International*, 121, 102455.
46. Fukushima, K., Miyake, S., 1982. Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Visual Pattern Recognition, Competition and Cooperation in Neural Nets. *Springer Berlin Heidelberg, Berlin, Heidelberg*, 267-285.
47. Hubel, D.H., Wiesel, T.N., 1968. Receptive Fields and Functional Architecture of Monkey Striate Cortex. *J Physiol*, 195, 215-243.
48. Matsugu, M., Mori, K., Mitari, Y., Kaneda, Y., 2003. Subject Independent Facial Expression Recognition with Robust Face Detection Using a Convolutional Neural Network. *Neural Netw*, 16, 555-559.
49. Jaiswal, R., Rao, A.G., Shukla, H.P., 2010. Image Enhancement Techniques Based on Histogram Equalization. *International Journal of Electrical and Electronics Engineering*, 1, 69-78.
50. Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012. Imagenet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25, 1097-1105.
51. LeCun, Y., Fu Jie, H., Bottou, L., 2004. Learning Methods for Generic Object Recognition with Invariance to Pose and Lighting. *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2004.*, 2 II-104, 102.
52. Griffin, G., Holub, A., Perona, P., 2007. Caltech-256 Object Category Dataset, 1-20.
53. Ciregan, D., Meier, U., Schmidhuber, J., 2012. Multi-column Deep Neural Networks for Image Classification. *2012 IEEE Conference on Computer Vision and Pattern Recognition*, 3642-3649
54. Deng, J., Dong, W., Socher, R., Li, L., Kai, L., Li, F.-F., 2009. ImageNet: A Large-scale Hierarchical Image Database. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 248-255
55. Russell, B.C., Torralba, A., Murphy, K.P., Freeman, W.T., 2008. LabelMe: A Database and Web-based Tool for Image Annotation. *International Journal of Computer Vision*, 77, 157-173.
56. Zeiler, M.D., Fergus, R., 2014. Visualizing and Understanding Convolutional Networks. *Computer Vision-ECCV 2014*, Springer International Publishing, Cham, 818-833
57. Ventura, D., Warnick, S., 2007. *A Theoretical Foundation for Inductive Transfer*. *Brigham*

- Young University, College of Physical and Mathematical Sciences, 19.
58. Jeff, D., Yangqing, J., Oriol, V., Judy, H., Ning, Z., Eric, T., Trevor, D., 2014. DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition. PMLR, 647-655.
 59. Sharif Razavian, A., Azizpour, H., Sullivan, J., Carlsson, S., 2014. CNN Features Off-the-shelf: an Astounding Baseline for Recognition, 806-813
 60. Yosinski, J., Clune, J., Bengio, Y., Lipson, H., 2014. How Transferable are Features in Deep Neural Networks? ArXiv, abs/1411.1792.
 61. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A., 2015, Going Deeper with Convolutions, 1-9.
 62. Simonyan, K., Zisserman, A., 2015. Very Deep Convolutional Networks for Large-Scale Image Recognition. CoRR, abs/1409.1556.
 63. He, K., Zhang, X., Ren, S., Sun, J., 2016, Deep Residual Learning for Image Recognition, 770-778.
 64. Sammani, A., Bagheri, A., van der Heijden, P.G.M., Te Riele, A., Baas, A.F., Oosters, C.A. J., Oberski, D., Asselbergs, F.W., 2021. Automatic Multilabel Detection of ICD10 Codes in Dutch Cardiology Discharge Letters Using Neural Networks. NPJ Digit Med, 4, 37.
 65. Bressemer, K.K., Adams, L.C., Erxleben, C., Hamm, B., Niehues, S.M., Vahldiek, J.L., 2020. Comparing Different Deep Learning Architectures for Classification of Chest Radiographs. Scientific Reports, 10, 13590.
 66. Ofer, D., Ohad, S., 2010. Multiclass-Multilabel Classification with More Classes than Examples. PMLR, 137-144.
 67. de Carvalho, A.C.P.L.F., Freitas, A.A., 2009. A Tutorial on Multi-label Classification Techniques, in: A. Abraham, A.-E. Hassanien, V. Snášel (Eds.) Foundations of Computational Intelligence Volume 5, Springer Berlin Heidelberg, Berlin, Heidelberg, 177-195.
 68. Xu, Q., Yang, Q., 2011. A Survey of Transfer and Multitask Learning in Bioinformatics. Journal of Computing Science and Engineering, 5, 257-268.
 69. Shin, H.C., Roth, H.R., Gao, M., Lu, L., Xu, Z., Nogues, I., Yao, J., Mollura, D., Summers, R. M., 2016. Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. IEEE Trans Med Imaging, 35, 1285-1298.
 70. Liu, B., Wei, Y., Zhang, Y., Yan, Z.X., Yang, Q., 2018. Transferable Contextual Bandit for Cross-Domain Recommendation. Thirty-Second Aaai Conference on Artificial Intelligence/Thirtieth Innovative Applications of Artificial Intelligence Conference/Eighth Aaai Symposium on Educational Advances in Artificial Intelligence, 32, 3619-3626.
 71. Tai, L., Paolo, G., Liu, M., 2017. Virtual-to-real Deep Reinforcement Learning: Continuous Control of Mobile Robots for Mapless Navigation,. 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 31-36
 72. Devlin, J., Chang, M.-W., Lee, K., Toutanova, K., 2019. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, In Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 1, 4171-4186, Minneapolis, Minnesota.
 73. Yang, Q., Zhang, Y., Dai, W., Pan, S.J., 2020. Transfer Learning, Cambridge University Press, Cambridge.
 74. Atasever, S., Azginoglu, N.U.H., Terzi, D.S., Terzi, R., 2023. A Comprehensive Survey of Deep Learning Research on Medical Image Analysis with Focus on Transfer Learning, Clinical Imaging, 94, 18-41.

Preparation and NO_x Reduction Performance of Ag-Ni-TiO₂/Cordierite Catalyst for HC-SCR System

Himmet ÖZARSLAN*¹ ORCID 0000-0002-1614-3343

¹Siirt University, Faculty of Engineering, Department of Mechanical Engineering, Siirt, Türkiye

Geliş tarihi: 08.03.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ÖZARSLAN, H., (2024). Preparation and NO_x Reduction Performance of Ag-Ni-TiO₂/Cordierite Catalyst for HC-SCR System. Cukurova University, Journal of the Faculty of Engineering, 39(2), 339-347.

Abstract

Selective catalytic reduction (SCR) technology in diesel engines is an exhaust after treatment system used for abatement of nitrogen oxide (NO_x) emissions. In order to synthesize Ag-Ni-TiO₂/Cordierite catalyst in the conducted study, a solution including silver nitrate (AgNO₃), titanium dioxide (TiO₂), and nickel (II) nitrate hexahydrate (Ni(NO₃)₂·6H₂O) were used in the coating of the cordierite (2Al₂O₃-5SiO₂-2MgO) main carrier structure. The prepared catalyst was characterized for morphological characteristics via scanning electron microscope (SEM) and energy dispersive spectroscopy (EDS) analysis. The NO_x reduction measurements as catalytic was carried out at 20 °C intervals in the temperature range from 190 to 270°C at 1 kW and 3 kW motor loads and under 30000 h⁻¹ space velocity (SV). Ethanol was used as a reductant during the experiments. As a results of the measurements, it was seen that the Ag-Ni-TiO₂/Cordierite catalyst exhibited a good NO_x conversion efficiency with 93.8 % at 270°C at 3 kW.

Keywords: Selective catalytic Reduction, Catalyst, Cordierite, NO_x emission

HC-SCR Sistemi için Ag-Ni-TiO₂/Kordiyerit Katalizörünün Hazırlanması ve NO_x İndirgeme Performansı

Öz

Dizel motorlardaki seçici katalitik indirgeme (SCR) teknolojisi, nitrojen oksit (NO_x) emisyonlarının azaltılması için kullanılan bir egzoz son arıtma sistemidir. Yapılan çalışmada Ag-Ni-TiO₂/Kordiyerit katalizörünü sentezlemek amacıyla kordiyerit (2Al₂O₃-5SiO₂-2MgO) ana taşıyıcı yapının kaplanması gümüş nitrat (AgNO₃), titanyum dioksit (TiO₂) ve nikel (II) nitrat heksahidrat (Ni(NO₃)₂·6H₂O) içeren bir çözelti kullanıldı. Hazırlanan katalizör, taramalı elektron mikroskobu (SEM) ve enerji dağılım spektroskopisi (EDS) analizi yoluyla morfolojik özellikler açısından karakterize edildi. Katalitik olarak NO_x azaltım ölçümleri, 190 ila 270 °C sıcaklık aralığında 20°C aralıklarla, 1 kW ve 3 kW motor yüklerinde ve 30000 h⁻¹ alan hızında (SV) gerçekleştirildi. Deneysel sırasında indirgeyici olarak etanol kullanıldı. Yapılan ölçümler sonucunda Ag-Ni-TiO₂/Kordiyerit katalizörünün 270°C'de 3 kW'ta %93.8 ile iyi bir NO_x dönüşüm verimi sergilediği görülmüştür.

Anahtar Kelimeler: Seçici katalitik indirgeme, Katalizör, Kordiyerit, NO_x emisyonu

*Sorumlu yazar (Corresponding Author): Himmet ÖZARSLAN, hozarslan@siirt.edu.tr

1. INTRODUCTION

Nitrogen oxide (NO_x) gases are harmful waste gases released into the external environment as a result of the combustion of fuel in diesel engines. It has negative effects on the environment such as acid rain, photochemical smog and ozone depletion [1]. Moreover, it also causes pneumonia, hay fever, bronchitis and cancer [2-3]. To eliminate these drawbacks of diesel engines, many systems are being tried to reduce NO_x. The most efficient and effective among these systems is selective catalytic reduction (SCR) system. In SCR system, ammonia (NH₃) as reductant and V₂O₅-(WO₃ or MoO₃)/TiO₂ catalyst as catalyst are commonly used. However, having a narrow temperature range of 300-400°C and the toxic effects of vanadium species prevent these catalysts from being a satisfactory option [4]. Moreover, in usage of NH₃, there are also negative effects such as ammonia slip and catalyst deterioration [5]. Therefore, recent efforts have been made by researchers to improve the system and overcome these problems. Among these endeavors, various types of reductants and different catalyst structures have been tested in the SCR system. Thirupathi [6] reported that in the NH₃-SCR, the addition of Ni could expand the active temperature range of the Mn/TiO₂ catalyst and improve the NO_x conversion performance. Ning et. al. [7] informed that the addition of Ni on MIL-100 (Fe) catalyst significantly improved the NO_x conversion of C₃H₆-SCR. Ning et. al. [8] reported that the addition of Ni on MIL-100(Fe) catalyst exhibited a 96.6 % NO conversion at 250°C under 2 %O₂ in CO-SCR. Shi et. al. [9] reported that almost 100 % NO conversion performance of Ni_{0.65}Mn_{0.35}-MOF-74 catalyst reached at 175 °C in CO-SCR. It also reported that compared with monometallic Ni-MOF-74 or Mn-MOF-74, bimetallic NiMn-MOF-74 catalyst achieved a significant improvement in NO conversion performance. Zhang et. al. [10] reported achieving almost 100% NO conversion in CO-SCR for Ag₁-Ni-MOF-74 catalyst in the temperature range of 200°C to 300°C.

In this study, active nano materials were coated on the cordierite main carrier structure. As a consequence of the coating procedure, Ag-Ni-

TiO₂/Cordierite catalyst was prepared. In conducted studies so far in the literature, NO_x abatement studies of nickel with ethanol reductant have been restricted limited. Therefore, the NO_x reduction performances of the cordierite structure-supported catalysts were performed in experiments in the SCR test system with ethanol reductant at low temperatures under real exhaust gas.

2. MATERIAL AND METHODS

2.1. Catalyst Preparation and Characterization

Cordierite material as a main carrier structure is of 400 cells per square inch (cps). In this study, 200 cm³ volume was cut from cordierite and used for catalyst production. First, in the powder catalyst preparation stage, silver nitrate (AgNO₃), Nickel (II) Nitrate Hexahydrate (Ni(NO₃)₂ • 6H₂O) and titanium dioxide (TiO₂) nanoparticles were added to 200 mL of distilled water at 2.5%, 1% and 96.5% by weight, respectively. The resulting solution was stirred by heating to evaporate the water. The remaining mud-like structure was dried in the oven at 130°C for 3 hours. Then, calcination was carried out in a muffle furnace at 550°C for 3 hours. The completely dried catalyst was ground into powder. The obtained powder catalyst and silicon dioxide (SiO₂), which is 1% of its weight, were added to 500 mL of distilled water and mixed for 1 hour. The cordierite main carrier was immersed in the powder catalyst solution to be completely wetted. Afterwards, drying at 130°C for 3 hours and subsequently calcination at 550°C for 3 hours were carried out. Thus, the catalyst was made ready for experiments in the SCR test system. The main steps of the catalyst preparation process are demonstrated in Figure 1.

Scanning electron microscopy-energy dispersive X-ray spectroscopy (SEM-EDS) method was used to analyze morphologically the surface of the coated cordierite catalyst. In this way, the surface of the catalyst was examined. The produced sample was observed using the FEI Quanta 650 Field Emission model SEM device at 20kV acceleration voltage. The device has the magnification capacity in the range of 6-1.000.000 x times (Figure 2). Before being used in SEM, the non-conductive surface of

the catalyst was overlaid with gold material of 2 Å/s by using the Q150R ES spray coating device. The

device used for the gold plating process is displayed in the Figure 3.

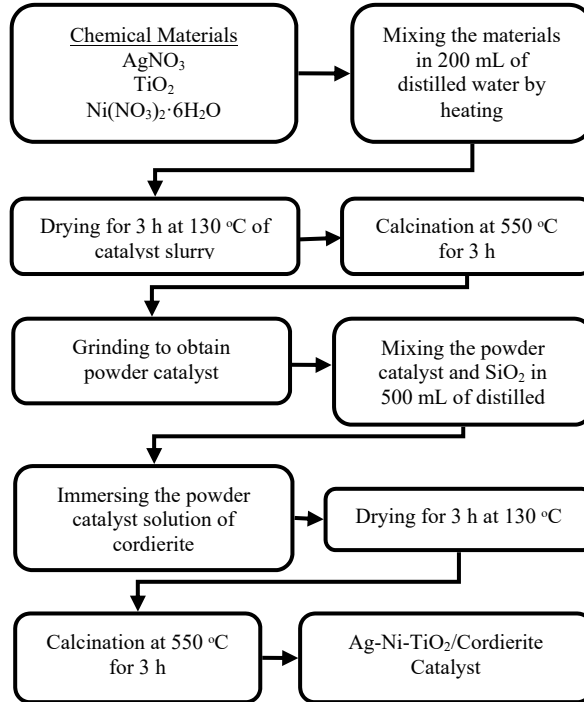


Figure 1. Steps in catalyst preparation



Figure 2. SEM analysis device




Figure 3. Gold plating process device

2.2. Performance Test of Catalyst

A diesel engine whose technical specifications are given in Table 1 was used in this section. A performance testing system was used to investigate

the NO_x conversion rate with the use of ethanol as reductant on Ag-Ni-TiO₂/Cordierite catalyst. The experimental test system is elaborated upon schematically in Figure 4. An orifice plate and manometer in the exhaust system was used in order to evaluate the exhaust gas flow rate within the system. Space velocity (SV) for the gas flow is named as the ratio of the catalyst volume [V_c (m³)] to the volume flow of the exhaust gas [V_f (m³/h)]

and is expressed as h⁻¹. During the experiment, the desired SV has been adjusted with the help of two valves. An electric loading system of 1 and 3 kW was used to load the engine. The exhaust gas temperatures were adjusted with a heater added to the system. Also, a k-type thermocouple was employed for temperature measurement. Finally, NO_x emission measurements were carried out through a pair of continental model NO_x sensors.

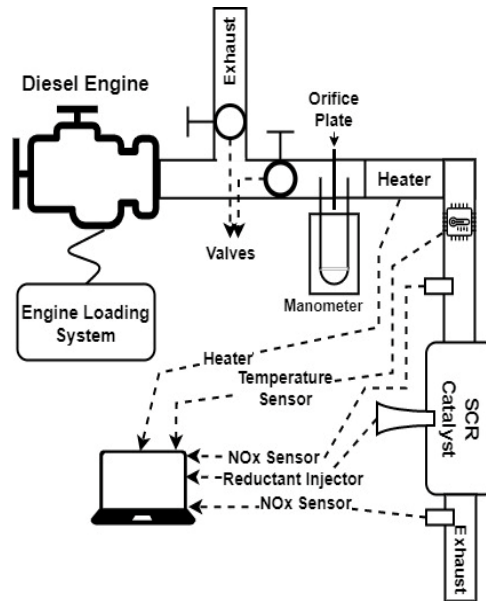


Figure 4. Schematic view of the SCR performance test system

Table 1. Diesel engine technical specifications

Model	AKSA A2CRX08
Number of cylinders	2
Stroke	79 mm
Bore	80 mm
Cylinder volume	830 cm ³
Compression ratio	23/1
Engine speed	3000 rpm
Cooling system	Water-cooled

The experiments were carried out under the utilization of ethanol reductant and a SV value of 30000 h⁻¹. Moreover, in order to evaluate the efficacy of the catalyst in NO_x reduction, particularly at lower temperatures, measurements of NO_x conversion ratios were conducted at 20°C intervals within the temperature range of 190°C to 270°C.


3. RESULTS AND DISCUSSIONS

3.1. Catalyst Characterization Results

Figure 5 indicates the SEM-EDS image of the catalyst synthesized at 500x magnification. The SEM-EDS results provided information about the

change of its surface after coating of the cordierite surface. SEM-EDS analysis was used to scan the entire surface area of catalyst. Peaks of Ag, Ni, and Ti metals on the cordierite structure surface after scanning were observed. Additionally, Mg, Al, and Si elements, which form the main cordierite

structure, were also observed. Figure 5 displays the percentages of atomic and weight of the elements in the surface area of the catalyst analyzed. Based on these results of the analysis, it can be concluded that the active components with catalytic effects are distributed on the surface.



Element	Weight %	Atomic %	Net Int.
O K	45.39	60.87	341.16
Mg K	4.82	4.26	108.08
Al K	10.44	8.3	268.47
Si K	29.19	22.3	759.3
Ag L	0.21	0.04	2.44
Ti K	7.19	3.22	114.21
Ni K	2.76	1.01	20.16

Figure 5. Energy-dispersive X-ray spectroscopy of Ag-Ni-TiO₂/Cordierite catalyst

The SEM images at 5000x, and 10000x magnification in order to determine the morphological properties of the catalyst were illustrated in Figure 6. The images demonstrate that the cordierite has a porous and rough surface. It can be clearly demonstrated at the images of the catalyst that the active coating elements with catalytic effects were irregularly distributed over uneven surface of the cordierite. Besides, the catalytic

active elements did not cause clogging of the pores of the cordierite structure, after the coating process. Clustered forms of catalytic active substances were visualized on the surface of the coated cordierite. The images clearly demonstrate the distribution of silver, nickel and titanium nanoparticles on the coated cordierite surface. The catalytic active substances were an irregular structure and different appearance morphologically.




Figure 6. SEM image results of Ag-Ni-TiO₂/Cordierite catalyst (a:5000x, b:10000x)

The SEM mapping image of the catalyst sample is displayed at 500x magnification in Figure 7. It has been observed that the coating elements (Ag, Ni,

and Ti) that are assumed to show catalytic activity on the surface are distributed equally or homogeneously on the surface. The turquoise spots,

the green spots, and the red spots in the mapping image correspond to silver (Ag), nickel (Ni), and

titanium (Ti) particles, respectively.



Figure 7. SEM mapping result of Ag-Ni-TiO₂/Cordierite catalyst

3.2. NO_x Conversion Test Results

Figure 8 shows the NO_x conversion rates obtained with ethanol depending on temperature, space velocity, and engine load for the Ag-Ni-TiO₂/Cordierite catalyst. As seen in the figure, the NO_x activity of the catalyst rised with the increment in temperature, and the maximum NO_x conversion ratios were obtained at 270°C. In the experiments, the catalyst activity increased depending on the increment in exhaust gas temperature. It was observed that temperature

had a significant effect on catalytic activity in this temperature range. Similar results were available in the literature [11-14]. Additionally, the tests showed that the NO_x conversion rates of the catalyst increased with increment of the engine load. In the experiments, the maximum NO_x conversion rate was obtained under 3 kW engine load. It is thought that this situation occurs because the concentration of O₂ in the exhaust gas decreases due to increased engine loads. Similar results were also found in the literature [15-16].

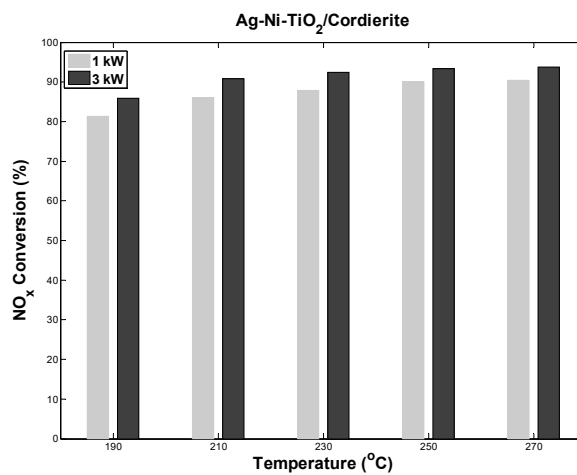


Figure 8. The NO_x conversion results of the catalyst

4. CONCLUSION

The findings obtained in the research are listed as follows.

- SEM images of the catalyst show that the synthesis process was successful.
- Increasing the exhaust gas temperature from 190°C to 270°C enhances the NO_x conversion performance.
- The catalyst has demonstrated promising results. When test results were compared, NO_x conversion efficiencies were achieved as 90.48% at 1 kW and 93.8% at 3 kW for the Ag-Ni-TiO₂/Cordierite catalyst.
- The maximum NO_x conversion rate was obtained at 270°C at 3 kW, reaching 93.8%.

5. REFERENCES

1. Boningari, T., Smirniotis, P.G., 2016. Impact of Nitrogen Oxides on the Environment and Human Health: Mn-based Materials for the NO_x Abatement. *Current Opinion in Chemical Engineering*, 13, 133-141.
2. Kampa, M., Castanas, E., 2008. Human Health Effects of air Pollution. *Environmental Pollution*, 151, 362-367.
3. Kagawa, J., 2002. Health Effects of Diesel Exhaust Emissions-A Mixture of Air Pollutants of Worldwide Concern. *Toxicology*, 181-182, 349-353.
4. Busca, G., Lietti, L., Ramis, G., Berti, F., 1998. Chemical and Mechanistic Aspects of the Selective Catalytic Reduction of NO_x by Ammonia over Oxide Catalysts: A Review. *Applied Catalysis B: Environmental*, 18, 1-36.
5. Dumestic, J.A., Topsøe, N.Y., Topsøe, H., Chen, Y., Slabiak, T., 1996. Kinetics of Selective Catalytic Reduction of Nitric Oxide by Ammonia over Vanadia/Titania. *Journal of Catalysis*, 163, 409-417.
6. Thirupathi, B., Smirniotis, P.G., 2012. Nickel-doped Mn/TiO₂ as an Efficient Catalyst for the Low-temperature SCR of NO with NH₃: Catalytic Evaluation and Characterizations. *Journal of Catalysis*, 288, 74-83.
7. Ning, S., Kashif, M., Deng, W., Zhao, B., Su, Y., 2024. Reactivity of Ni-modified MIL-100(Fe) Catalysts for C₃H₆-SCR and Reaction Mechanism. *Catalysis Communications*, 187, 106854.
8. Ning, S., Su, Y., Yang, H., Zhao, B., 2024. Ni-Modified MIL-100(Fe) Catalysts for CO-SCR of NO and Reaction Mechanism. *Fuel*, 359, 130452.
9. Shi, Y., Chu, Q., Xiong, W., Gao, J., Huang, L., Zhang, Y., Ding, Y., 2021. A New Type Bimetallic NiMn-MOF-74 as an Efficient Low-temperatures Catalyst for Selective Catalytic Reduction of NO by CO. *Chemical Eng.& Processing: Process Intensification*, 159, 108232.
10. Zhang, Y., Chu, Q., Shi, Y., Gao, J., Xiong, W., Huang, L., Ding, Y., 2021. Synthesis of Bimetallic Ag-Ni-MOF-74 Catalyst with Excellent CO-SCR Performance in Low Temperature Range. *Acta Chimica Sinica*, 79(3), 361-368.
11. Du X., Gao X., Fu Y., Gao F., Luo Z., Cen K. (2012). The Co-effect of Sb and Nb on the SCR Performance of the V₂O₅/TiO₂ Catalyst. *Journal of Colloid and Interface Science*, 368, 406-412.
12. Liu, F., W. Shan, D. Pan, T. Li, and H. He. 2014. Selective Catalytic Reduction of NO_x by NH₃ for Heavy-duty Diesel Vehicles. *Chinese Journal of Catalysis* 35(9), 1438-45.
13. Zhao B., Ran R., Guo X., Cao L., Xu T., Chen Z., Wu X., Si Z., Weng D. (2017). Nb-Modified Mn/Ce/Ti Catalyst for the Selective Catalytic Reduction of NO with NH₃ at Low Temperature. *Applied Catalysis A: General*, 545, 64-71.
14. Kang, W., Choi, B., Jung, S., Park, S., 2018. PM and NO_x Reduction Characteristics of LNT/DPF +SCR/DPF Hybrid System. *Energy* 143 (January), 439-47.
15. Keskin, A., Yaşar, A., Candemir, O.C., Özarslan, H., 2020. Influence of Transition Metal Based SCR Catalyst on the NO_x

- Emissions of Diesel Engine at Low Exhaust Gas Temperatures. *Fuel*, 273, 117785.
16. Keskin, Z., Özgür, T., Özarslan, H., Yakaryılmaz, A.C., 2021. Effects of Hydrogen Addition into Liquefied Petroleum Gas Reductant on the Activity of Ag-Ti-Cu/Cordierite Catalyst for Selective Catalytic Reduction System. *International Journal of Hydrogen Energy*, 46, 7634-7641.

Kastabala Antik Kentinde Kullanılan Kayaç Türleri ve Petrografik Özellikleri

Mustafa AKYILDIZ*¹ ORCID 0000-0002-0371-8646

Emrah ŞİMŞEK¹ ORCID 0000-0001-7861-0480

Faris DEMİR² ORCID 0000-0001-8370-4350

¹Çukurova Üniversitesi, Mühendislik Fakültesi, Jeoloji Mühendisliği Bölümü, Adana

²Osmaniye Korkut Ata Üniversitesi, Arkeoloji Bölümü, Osmaniye

Geliş tarihi: 15.04.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: AKYILDIZ, M., ŞİMŞEK, E., DEMİR, F., (2024). Kastabala Antik Kentinde Kullanılan Kayaç Türleri ve Petrografik Özellikleri. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 349-357.

Öz

Kastabala Antik Kenti Türkiye'nin güney kesiminde Osmaniye şehrinin merkezine 25 kilometre mesafede bulunmaktadır. Antik kentte bulunan kayalardan yapılan petrografik incelemeler neticesinde olivinli mikro-gabro, granit, karbonatlı kumtaşı, breşik kireçtaşı, fosilli kireçtaşı, mikritik kireçtaşı, konglomera, çakıltaşı birimleri tanımlanmıştır. Bu kayalardan olivinli mikro gabro, granit ve breşik kireçtaşları genellikle sütunlarda kullanılmıştır. Amfi tiyatrodaki fosilli kireçtaşı, mikritik kireçtaşı ve amfi tiyatro kenarlarındaki duvarlarda karbonatlı kumtaşı kullanılmıştır. Bu kayaların bölgesel jeoloji ile uyumluluk gösterdiği tespit edilmiş olup, antik kentin bulunduğu tepe ile yakınlardan getirilerek kullanılmıştır. Granit olarak tanımlanan kayaların ise bölge jeolojisi içerisinde yer almamakta olup dışarıdan getirildiği sonucuna varılmıştır.

Anahtar Kelimeler: Kastabala antik kenti, Osmaniye, Petrografi, Mineral, Kayaç, Arkeoloji

Rock Types Used in the Ancient City of Kastabala and Petrographic Features

Abstract

Kastabala Ancient City is located 25 kilometers from the center of Osmaniye city in the southern part of Turkey. Petrographic studies of the rocks found in the ancient city have defined olivine micro-gabbro, granite, carbonate sandstone, brecciated limestone, fossiliferous limestone, micritic limestone, conglomerate, and gravelstone units. Among these rocks, olivine micro-gabbro, granite, and brecciated limestones were generally used in columns. Fossiliferous limestone and micritic limestone were used in the amphitheater and carbonate sandstone was used in the walls around the amphitheater. It has been determined that these rocks are compatible with the regional geology, and they were brought from the hill where the ancient city is located and used. It has been concluded that the rocks defined as granite are not part of the regional geology and were brought in from outside.

Keywords: Kastabala ancient city, Osmaniye, Petrography, Mineral, Rock, Archaeology

*Sorumlu yazar (Corresponding Author): Mustafa AKYILDIZ, akyildizm@cu.edu.tr

1. GİRİŞ

Kastabala Antik Kenti Türkiye'nin güneyinde Osmaniye kent merkezinin 25 km kuzeyinde yer almaktadır (Şekil 1). Antik Dönem'de Ovalık Kilikya bölgesinin en önemli ve en eski tek kutsal kenti olarak bilinmektedir. Kastabala ismi MÖ 5-4. yüzyıllara tarihlenen Aramice yazıtlarda Kastabaliya/Kastabalaya olarak geçmektedir [1]. Luwi ve Hurri kültür bölgesi ve Kizzuwatna Ülkesinin merkezinde yer alan Kastabala'nın Hititler Dönemi'ndeki ismi Kummanni olduğu düşünülmektedir. Hititler Dönemi'nde Kizzuwatna Ülkesinin kutsal kenti olan Kummanni Luwice kumani-, kumma- kutsal anlamına gelmektedir [2]. Bu nedenle Kastabala, Hellenistik Dönem IV. AntiochosEpiphanes (MÖ 175-164) sikkelerinde Hierapolis (Kutsal Kent) olarak geçmiştir. Kentin kutsal olmasını sağlayan Kubaba Pirvaşua kültü Hellenistik ve Roma Dönemlerinde Artemis Perasia kültü olarak devam etmiştir. Antik yazarlardan Ptolemaeus, Plinius ve Strabon kent hakkında bilgiler vermişlerdir. Artemis Perasia Tapınağı'nın rahibeleri çıplak ayakla hiç acı duymadan kızgın korlar üzerinde yürümüşlerdir [3]. Kastabala Antik Kentinin buluntu geçmişi Neolitik ve Kalkolitik dönemlere uzanmakla birlikte kentte Arkaik, Klasik, Hellenistik, Roma İmparatorluk ve Ortaçağ dönemlerine ait mimari kalıntılar bulunmaktadır(Şekil 2). Bu mimari kalıntılar sütunlu caddeler (Şekil3), tonozlu kompleks yapı, tiyatro (Şekil4), hamamlar, kutsal alanlar, nekropol alanları, anıt mezarlar, su kemerleri, nympheum, sarnıçlar, ışıklar, kale ve kiliselerdir. Şehir plancılığı açısından sütunlu cadde yerleşmenin ana aksını belirlemektedir. Sütunlu cadde batı-doğu yönünde eğimli araziye uygun biçimde basamaklandırılarak uzanmaktadır. İki yanda kaldırımlı, tabanı taş döşeli sütunlu caddenin doğu ucunda bir propylon mevcuttur. Sütunlu caddenin doğu ucunda tiyatro yer almaktadır. Kademeli taş sıralardan oluşan oturma basamaklarından meydana gelen seyirciler kısmı, oyuncuların üzerinde oynadıkları sahne binası ve bunların arasında dairesel meydan olmak üzere üç bölümden oluşmaktadır.

Kastabala antik kentinin bulunduğu bölge jeolojisi incelendiğinde Doğu Toros otkton kayaçları ile ilişkisi görülemeyen ve Adana Baseni ile Amanoslar arasında kalan Misis grubu; Dokuztekne, Andırın ve Karataş Formasyonlarından oluşmaktadır. Yüksek kesimlerdeki kireçtaşı blokları Eosen-Oligosen yaşlı Bulgurkaya Olistostromu içerisinde yer almakta olup, bu birim bölgede Alt-Orta Miyosen yaşlı türbiditik Karataş Formasyonu üzerinde bindirmelidir [6]. Kuvaterner yaşlı alüvyonlarla örtülü durumda gözlemlenmektedir. Çoğunlukla serpantinlerden oluşmuş moloz akması özelliğindeki Andırın Formasyonu (melanj) içerisinde, çakıl boyutundan çok büyük olistolitlere kadar değişik boyutta Paleozoyik yaşlı rekristalize kireçtaşı, Mesozoyik ve Eosen yaşlı kireçtaşları, volkanik ve ofiyolit blokları yer alır. Melanj içinde en çok göze çarpan kayaç birimi, aşınmaya karşı olan dayanımından dolayı kireçtaşlarıdır. Özellikle Mesozoyik yaşlı kireçtaşları ve dolomitik kireçtaşları oldukça sert yapıda olduğundan yükselim içerisindeki en yüksek kesimleri oluşturmaktadır. Misis uzanımı boyunca Bulgurkaya olistostromu, Jura'dan Oligosen'e kadar değişen yaş aralıklarında yüzlerce metre boyutlara varabilen breşleşmiş kireçtaşı blokları ile temsil edilmekte olup Şekil 5'de görülmektedir [7, 8].



Şekil 1. Kastabala Antik Kenti bölgesinin yer bulduru haritası [4]

Bu çalışmanın amacı Kastabala Antik Kentini oluşturan amfi tiyatro, kemer, sütunlar ve hamam

bölgelerinden malzemenin orijinal özelliklerini tahrip etmeden örnekler derlemektir. Derlenen örnekler üzerinde petrografik incelemeler yapılarak mineral ve kayaç tanımlamalarının yapılması ve bölge jeolojisi ile uyumluluğunun denetlenmesi hedeflenmiştir.



Şekil 2. Kastabala antik kenti yerleşim yerleri [4]



Şekil 3. Sütunlu yol [5]



Şekil 4. Tiyatro alanı [5]

YAŞ	GRUP	FORMASYON	KALINLIK	İLİME	LİTOLOJİ	AÇIKLAMA
LANGIYEN		HOKKADAĞ	1500 2000	Mh-Mid		Çakıltaşı
ANTIKYEN SUBORDİNASYON		GEBENKÖY	300 - 600	Tgb		Kumtaşı - Şeyl Kumtaşı bantlı kumlu marn Çakıltaşı (Kanal dolgusu) Kumlu marn
ÜST EÖSEN - OLGİÖSEN		BULGURKAYA FORMASYONU	500 - 700	Tbaf		OLİSTOSTROM: Bloklar (Olistolitler): Ardırın Kireçtaşı Üst Kretase Fliş Metamorfik kayalar Olistostromal Fasiyeler: Mozozlu Çakıltaşı (Debris flow) Kumlu-Çakıllı Çamurtaşı (Mud flow) Breşik Çakıltaşı (Mass Flow) Matriks: Kumtaşı ara bantlı kumlu Marn Killi Kireçtaşı-Marn-Çörtlü Kçt. Kalsi-Türbidit
ÜST KRETASE - PALİÖSEN ORTA EÖSEN	CAMLIBEL	BODRUMKALE DOKUZTEPE FORMASYONU	20 - 80	Tgb-KTçb		Çakıltaşı - Kumtaşı (Volkanik Elemanlı) Volkanit-Aglomera Tüf-Tüfit Çörtlü Kireçtaşı-Mikrit Killi Kireçtaşı-Marn
MIYÖSEN ALT		ASLANTAŞ FORMASYONU	50 - 500	Kçb-KTçb		Tektonik Dokanak Bloklu Çakıltaşı (Denizaltı Yalpaze çökeli)
MIYÖSEN ORTA		KARATAŞ FORMASYONU	800	Ta		Kumlu Marn Kumtaşı-Şeyl-Marn Aralanması (Tektonize Fliş) Tektonik Dokanak
			2000	Tmk		Kumtaşı-Şeyl Ardışı (Türbiditler) Kalsi-Türbidit

Şekil 5. Çalışma alanı çevresindeki birimlerin stratigrafik ilişkilerini gösteren ölçeksiz dikme kesit [9]

2. MATERYAL VE METOT

Çalışmamızın ana materyalini Kastabala Antik Kentinden alınan kayaç örnekleri oluşturmaktadır. Derlenen kayaç örneklerinin mineral ve kayaç tanımlamaları hazırlanan ince kesitler üzerinde polarizan mikroskop altında gerçekleştirilmiştir. İnce kesit analizleri Çukurova Üniversitesi Jeoloji Mühendisliği Bölümü Laboratuvarlarında yapılmıştır. İnce Kesit için alınan kayaç örnekleri ilk önce kaba kesme makinasında kibrit kutusu büyüklüğünde dıştan içe doğru tüm yapısını gösterecek şekilde kesilir. Örnek hazırlandıktan sonra polarizan mikroskopla inceleme yapılmaktadır. Araştırmalar Jeoloji Mühendisliği Bölümünde Olympus BX51 polarizan mikroskopla yapılmıştır.

3. BULGULAR VE TARTIŞMA

Kastabala Antik Kentinden alınan kayaç örnekleri üzerinde detaylı olarak petrografik incelemeler yapılmıştır. İncelemeler sonucunda elde edilen veriler aşağıda detaylı olarak anlatılacaktır

3.1. Petrografi

Çalışma kapsamında K-1, K-2, K-5, K-10, K-12, K-13, K-18, K-23, K-24, K-25, K-33 ve K-35 numaralı örneklerin petrografik incelemeleri yapılmıştır.

K-1: K-1 numaralı örnek amfi tiyatronun doğu kesiminde bulunan alandan alınmıştır. Örnek olivinli mikro-gabro olarak tanımlanmış olup Şekil 6a'da görülmektedir. Kayaç ofitkdoku göstermekte olup, mineralojik bileşimini plajiyoklas, piroksen, olivin ve opak mineraller oluşturmaktadır. Plajiyoklas mineralleri kayaç içerisinde yaklaşık olarak % 57-60 oranında bulunmaktadır. Plajiyoklas mineralleri özşekilli-yarı özşekilli olup polisentetik ikizlenmeler belirgin olarak gözlemlenmektedir. Polarizan mikroskop altında çift nikolde gri tonlarında polarizasyon renkleri göstermekte ve küçük-orta taneler halinde bulunmaktadır. Bazı plajiyoklas kristalleri magmanın soğuma hızına bağlı olarak kayaç içerisinde fenokristaller halinde Şekil 7'de görülmektedir. Klinopiroksen mineralleri kayaç içerisinde yaklaşık olarak % 25-30 oranında bulunmaktadır. Klinopiroksen mineralleri yarı özşekilli-özşekilsiz olarak gözlenmekte ve polarizan mikroskop altında sarı-yeşilin tonlarında polarizasyon renkleri göstermektedir. Küçük-orta tanelerden oluşmakta olup, kayaç içerisine plajiyoklas minerallerinin arasını doldurur vaziyette bulunmaktadır. Tek yönde dilinimleri bazı klinopiroksen kristallerinde gözlenmekte olup dilinime göre eğik sönme göstermeleri nedeniyle klinopiroksen olarak tanımlanmış ve Şekil 7'de gösterilmektedir. Olivin mineralleri kayaç içerisinde çok küçük taneler halinde bulunmakta ve demirli ayrışım (iddingsitleşme) göstermektedir. Kayaç içerisinde % 5-10 arasında bulunmaktadır. Opak mineraller kayaç içerisinde yaklaşık olarak %

2-3 oranında bulunmakta olup Şekil 7'de görülmektedir.

K-2: K-2 numaralı örnek mikritik kireçtaşı olarak tanımlanmıştır. Mikritik kireçtaşının arazi görünümü Şekil 6b'de verilmektedir. Bağlayıcı malzemeyi mikritik ve sparitikkalsit çimento oluşturmakta olup Şekil 7'de görülmektedir.

K-5: K-5 numaralı örnek karbonatlı kumtaşı örneğidir. Örneğin arazi görünümü Şekil 6c'de verilmektedir. Kayaç içerisinde taneleri birbirlerine bağlayan bağlayıcı malzemeyi başlıca kalsit çimento ve taneler arasındaki boşlukları dolduran kil matriks oluşturmakta olup Şekil 7'de görülmektedir.

K-10: K-10 numaralı örnek fosilli kireçtaşı olarak tanımlanmıştır. Örneğin arazi görünümü Şekil 6d'de verilmektedir. Kayaç başlıca kalsit minerali ve fosillerden oluşmaktadır. Bağlayıcı malzemeyi sparitik ve mikritik kalsit çimento oluşturmakta olup Şekil 7'de görülmektedir.

K-12: K-12 numaralı örnek biresşik kireçtaşı olarak tanımlanmıştır. Örneğin arazi görünümü Şekil 6e'de verilmektedir. Kayaç başlıca kalsit mineralinden oluşmakta olup bağlayıcı malzemeyi sparitik kalsit çimento oluşturmakta ve Şekil 7'de görülmektedir.

K-13: K-13 numaralı örnek konglomera olarak tanımlanmıştır. Örneğin arazi görünümü Şekil 6f'de verilmektedir. Kayaç içerisinde magmatik kayaç parçacıkları, kalsit minerali ve *Numulit* bulunmaktadır. Bağlayıcı malzemeyi taneleri birbirlerine bağlayan kalsit çimento ve taneler arasındaki boşlukları dolduran kil matriks oluşturmakta olup Şekil 7'de görülmektedir.

K-18: K-18 numaralı örnek çakıltaşı olarak tanımlanmıştır. Örneğin arazi görünümü Şekil 8'de verilmektedir. Çakılları plajiyoklas, kuvars, kalsit, muskovit, opak mineraller ve magmatik kayaç parçacıkları oluşturmaktadır. Kayaç içerisinde taneleri birbirlerine bağlayan kalsit çimento ve

taneler arasındaki boşlukları dolduran kil matriks bulunmakta olup Şekil 12'de görülmektedir.

K-23: K-23 numaralı örnek granit olarak tanımlanmış olup granüler doku göstermektedir. Örneğin arazi görünümü Şekil 9'da verilmektedir. Kayacın mineral bileşimini kuvars, plajiyoklas, potasyumlu feldispat, amfibol ve opak mineraller oluşturmaktadır. Kuvars mineralleri kayaç içerisinde yaklaşık olarak % 33-40 oranında bulunmaktadır. Kuvars mineralleri öz şekilsiz olup orta-iri kristaller halinde gözlemlenmektedir. Polarizan mikroskop altında çift nikolde grinin tonlarında polarizasyon renkleri göstermektedir. Plajiyoklas mineralleri kayaç içerisinde yaklaşık % 27-36 oranında bulunmakta olup özşekilli-yarı özşekilli kristaller halindedir. Polisentetik ikizlenmeler bazı plajiyoklas kristallerinde belirgin olup, orta-büyük kristaller halindedir. Polarizan mikroskop altında çift nikolde grinin tonlarında polarizasyon renkleri göstermektedir. Potasyumlu feldispat mineralleri kayaç içerisinde yaklaşık olarak % 24-41 oranında bulunmakta olup orta-iri kristaller halindedir. Bazı potasyumlu feldispat minerallerinde pertitleşmeler gözlemlenmiştir. Polarizan mikroskop altında çift nikolde grinin tonlarında polarizasyon renkleri göstermektedir. Amfibol mineralleri kayaç içerisinde yaklaşık % 4-5 oranında bulunmakta olup özşekilsiz kristaller halindedir. Bazı amfibol kristallerinde kloritleşmeler gözlemlenmiştir. Polarizan mikroskop altında tek nikolde yeşilin tonlarında net pleokroizma göstermektedir. Opak mineraller kayaç içerisinde yaklaşık olarak % 1-2 oranında bulunmakta olup Şekil 12'de görülmektedir.


K-24: K-24 numaralı örnek granit olarak tanımlanmış olup granüler doku göstermektedir. Örneğin arazi görünümü Şekil 9'da verilmektedir. Kayacın mineral bileşimini kuvars, plajiyoklas, potasyumlu feldispat, amfibol ve opak mineraller oluşturmaktadır. Kuvars mineralleri kayaç içerisinde yaklaşık olarak % 36-43 oranında bulunmaktadır. Kuvars mineralleri öz şekilsiz olup

orta-iri kristaller halinde gözlemlenmektedir. Polarizan mikroskop altında çift nikolde grinin tonlarında polarizasyon renkleri göstermektedir. Plajiyoklas mineralleri kayaç içerisinde yaklaşık % 23-38 oranında bulunmakta olup özşekilli-yarı özşekilli kristaller halindedir. Polisentetik ikizlenmeler fazla belirgin olmayıp bazı kristallerde kaolenleşme gözlenmekte ve orta-büyük kristaller halinde bulunmaktadır. Polarizan mikroskop altında çift nikolde grinin tonlarında polarizasyon renkleri göstermektedir. Potasyumlu feldispat mineralleri kayaç içerisinde yaklaşık olarak % 22-38 oranında bulunmakta olup orta-iri kristaller halindedir. Bazı potasyumlu feldispat minerallerinde pertitleşmeler gözlemlenmiştir. Polarizan mikroskop altında çift nikolde grinin tonlarında polarizasyon renkleri göstermektedir. Amfibol mineralleri kayaç içerisinde yaklaşık % 2-3 oranında bulunmakta olup özşekilsiz kristaller halindedir. Polarizan mikroskop altında tek nikolde yeşilin tonlarında net pleokroizma göstermektedir. Opak mineraller kayaç içerisinde yaklaşık olarak % 1-2 oranında bulunmakta olup Şekil 12'de görülmektedir.


K-25: K-25 numaralı örnek konglomera olarak tanımlanmıştır. Örneğin arazi görünümü Şekil 10'da verilmektedir. Kayaç içerisinde kalsit ve demir oksitler bulunmaktadır. Bağlayıcı malzemeyi taneleri birbirlerine bağlayan kalsit çimento ve taneler arasındaki boşlukları dolduran kil matriks oluşturmakta olup Şekil 12'de görülmektedir.

K-33: K-33 numaralı örnek karbonatlı kumtaşı olarak tanımlanmıştır. Kayaç içerisinde kavkı parçacıkları bulunmaktadır. Bağlayıcı malzemeyi kalsit çimento ve taneler arasındaki boşlukları dolduran kil matriks oluşturmakta olup Şekil 12'de görülmektedir.

K-35: K-35 numaralı örnek fosilli kireçtaşı olarak tanımlanmıştır. Kayaç içerisindeki bağlayıcı malzemeyi sparitik ve mikritik kalsit çimento oluşturmakta olup Şekil 12'de görülmektedir.



Şekil 6. a) Olivinli mikro-gabro, b) Mikritik kireçtaşı, c) Karbonatlı kumtaşı d) Fosilli kireçtaşı, e) Bireşik kireçtaşı ve f) Konglomera örneğinin arazi görünümü



Şekil 7. K-1, K-2, K-5, K-10, K-12 ve K-13 numaralı örneklerin ince kesitte ÇN görünümü (ÇN: Çift Nikol, Pl: Plajiyoklas, Px: Piroksen, Ol: Olivin, Cal: Kalsit, Op: Opak mineral)



Şekil 8.Çakıltaş örneğinin arazi görünümü



Şekil 9. Granit örneğinin arazi görünümü




Şekil 10. Konglomera örneğinin arazi görünümü

Kastabala Antik Kentinden alınan örnekler üzerinde yapılan petrografik incelemeler neticesinde olivinli mikro-gabro, karbonatlı kumtaşı, breşik kireçtaşı, fosilli kireçtaşı, mikritik kireçtaşı, konglomera, çakıltası ve granit birimleri tanımlanmıştır. Bunlarla ilgili eski dönemlere ait ocak kanıtları bulunamamış olup, jeolojik verilere göre kullanılan mikritik

kireçtaşlarının Kastabala kalesinin yanında bulunan Ali kesigi olarak adlandırılan bölgeden (Şekil 11), breşik kireçtaşı ve karbonatlı kumtaşının Aslantaş (Osmaniye)-Misis (Ceyhan), gabro örneklerinin ise Osmaniye kuzey kesiminde yer alan Ofiyolitik birimlerden alınmış olabileceği düşünülmektedir.



Şekil 11. Kastabala kale kısmının yakınında bulunan kesik alanı [4]



Şekil 12. K-18, K-23, K-24, K-25, K-33 ve K-35 numaralı örneklerin ince kesitte ÇN görünümü (ÇN: Çift Nikol, Pl:Plajiyoklas, Qtz: Kuvars, Kfs: Potasyumlu feldispat, Ms: Muskovit, Am: Amfibol, Cal: Kalsit, Op: Opak mineral)

4. SONUÇLAR

Çalışma alanını da içerisine alan bölgesel jeoloji incelendiğinde Kastabala Antik Kentin'den alınan örneklerin ince kesitlerinde saptanan olivinli mikrogabro, karbonatlı kumtaşı, breşik kireçtaşı, fosilli kireçtaşı, mikritik kireçtaşı, konglomera ve çakıltası bölgeyi oluşturan jeolojik birimlerle ile uyumaktadır. Ancak Kastabala Antik Kentin'den alınan ve granit olarak tanımlaması yapılan örneklerin bölge jeolojisi içerisinde bulunmadığı tespit edilmiştir. Bunların bölgeye dışarıdan getirildiği düşünülmektedir. Ayrıca Kastabala kale kısmının yanında bulunan kesik alanından malzeme alındığı saptanmıştır.

5. KAYNAKLAR

1. Dupont-Sommer, A., Robert, L., 1964. Le Deesse de Hierapolis Castabala (Cilicie), Paris.
2. Demir, F., 2021. Karatepe Azatiwataya: Tarihi Olaylar, Mimari Buluntular ve Yazıtlar Üzerine Notlar. Arkeoloji ve Sanat Yayınları, İstanbul.
3. Strabon, Geographika Antik Anadolu Coğrafyası, 12.2.7.
4. <http://www.googleearth.com>.
5. <http://www.arkeolojikhaber.com/galeri-kastabla>.
6. Ünlügenç, U.C., Akıncı, A.C., 2017. Kızıldere-Güveleolu (Ceyhan-Adana) Civarının Tektono-Stratigrafisi. Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 32(2), 85-100.
7. Perinçek, D., Kozlu, H., 1984. Afşin-Elbistan Doğanşehir Dolayının Stratigrafisi ve Bölgedeki Birliklerin Yapısal İlişkileri. TPAO Arama Grubu, Rapor No: 1909, 28.
8. Gökçen, S.U., Kelling, G., Gökçen, N., Floyd, P.A., 1988. Sedimentology of a Late Cenozoic Collision Sequencethe Misis Complex. Adana, Southern Turkey.
9. Kozlu, H., 1997. Doğu Akdeniz Bölgesinde yer alan Neojen Basenlerinin (İskenderun-Misis-Andırın) Tektono-Stratigrafi Birimleri ve Bunların Tektonik Gelişimi, Doktora Tezi.

Artificial Intelligence Predictions of Biomass Power of an Installed Waste Water Treatment Plant

Akın İLHAN*¹ ORCID 0000-0003-3590-5291

¹Ankara Yıldırım Bayezit University, Faculty of Engineering and Natural Sciences, Department of Energy Systems Engineering, Ankara, Türkiye

Geliş tarihi: 12.01.2024 Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: İLHAN, A., (2024). Artificial Intelligence Predictions of Biomass Power of an Installed Waste Water Treatment Plant. Cukurova University, Journal of the Faculty of Engineering, 39(2), 359-374.

Abstract

In the current study, the power generations obtained from gas turbines of an installed waste water treatment plant were predicted, utilizing artificial intelligence method consisting of artificial neural network (ANN). In this regards, a cumulative of 445 data, found in the power generation data cluster and found in the physical and chemical data clusters has been used in the predictions based on the artificial intelligence association method. Each instant data of these total 445 data corresponds to daily average power generation (P) obtained from gas turbines of the facility and corresponds to physical and chemical parameters including the temperature (T), degree of acidity (pH), conductivity (σ), as well as the daily total volumetric flow of the waste gas to be burned at the gas generator (Q). Accordingly, the best prediction obtained by ANN approach was concluded to generate the statistical accuracy results corresponding to 6.1279% mean absolute percentage error (MAPE), 2.1540 MWh/day root mean square error (RMSE), and 0.9730 correlation coefficient (R) for power generation parameter.

Keywords: Artificial intelligence, Artificial neural network (ANN), Waste water treatment

Biokütle Tipi Kurulu Atık Su Arıtma Tesisinin Enerji Geri Kazanım Analizi

Öz

Bu çalışmada, kurulu bir atık su arıtma tesisinin gaz türbinlerinden elde edilen enerji üretimleri, yapay sinir ağlarından (YSA) yararlanılarak yapay zekâ yöntemi kullanılarak tahmin edilmiştir. Bu doğrultuda, yapay zekâ ilişkilendirme yöntemine dayalı tahminlerde, elektrik üretimi veri kümesinde bulunan ve fiziksel ve kimyasal veri kümelerinde bulunan 445 verinin tamamı kullanılmıştır. Bu toplam 445 verinin her bir anlık verisi, tesisin gaz türbinlerinden elde edilen günlük ortalama elektrik üretimine (P) karşılık gelmekte olup; ayrıca, sıcaklık (T), asitlik derecesi (pH), iletkenlik (σ), ve ilaveten gaz jeneratöründe yakılacak atık gazın günlük toplam hacimsel akışını (Q) da içermektedir. Buna göre, güç üretim parametresi kapsamında, YSA yaklaşımıyla elde edilen en iyi tahminin; %6.1279'luk ortalama mutlak yüzde hata (MAPE) değerine, 2,1540 MWh/gün ortalama karekök hata (RMSE) ve 0,9730 korelasyon katsayısına (R) karşılık gelen istatistiksel doğruluk sonuçlarını ürettiği sonucuna varılmıştır.

Anahtar Kelimeler: Yapay zekâ, Yapay sinir ağları (YSA), Atık su arıtma

*Sorumlu yazar (Corresponding Author): Akın İLHAN, akinilhan@aybu.edu.tr

1. INTRODUCTION

The increase of fossil fuel powered devices and machines used in many engineering applications has caused increase of greenhouse gas emissions and unfortunately in parallel the global warming in all over the World. Unlike renewable power sources, fossil fuel sources will be depleted soon in the near future. Accordingly, energy production using renewable sources has demonstrated a significant increase in all of the World. As such, nearly whole of the World countries have at least one type of energy plant that operates using a renewable source [1]. Therefore, especially in the last decades, energy plants powered by renewable sources have an exceeding spreading potential against the energy plants powered by conventional fossil fuels. On the other hand, energy generation obtained from biomass sources is among these types, and biomass is one of the most substantial renewable type today and it is utilized in energy production in many countries of the World.

In this regards, the share of the World total installed biomass power is exhibited in Figure 1, presented as annual distributions starting from 2010 to present day, and as well its 2025 projections are also included. This figure also provides a projection of the other energy sources in the near future, i.e., by 2025. It is indicated in this figure that reaching 2025, installations of the fossil fuels will significantly decline back in terms of the percentages. Even hydropower, which is one of the leading types of renewable energy and which has been applied for the first time in the World as a renewable source and has a very large amount of installation capacity considering all over the World, has decreased considerably in percent today. Today, the power generation capacities belonging to hydraulic sources and solar sources are almost equalized. Besides, by 2025, it is obvious that other renewable energy types, especially solar and wind energies, will result hydraulic energy installations to decline further in percentage due to the increase of those in installations all around the World. As indicated in Figure 1, although bio-power constitutes a low amount in total percentage; the energy generation potential of plant and animal waste, which is the source of bio power, is quite

high and only a small amount can be converted into useful energy yet. This situation will make bio power a very important and widely used fuel type in the future.




Figure 1. 2025 projections of the renewables compared to fossil energy sources




Figure 2. The biomass and total power installations of Türkiye [2]

This situation manifests itself in this way, in Türkiye as well. Renewable power plant installations also in Türkiye, have accelerated in the last few decades. However, the biomass installations of the country also boosted around 20 times in the last twelve years. As presented in Figure 2, while total installed power of the country has increased twice in the considered time range, reaching 101,495 MW at the end of 2022, from 52,273 MW by 2011; whereas, the biomass installations of the country have increased approximately 20 times in the same year range, reaching 2,172 MW at the end of 2022, from only 115 MW by 2011 [2].

The scientific studies taking part in the literature include estimation implementations of physical and engineering problems conducted mainly in three different ways. Those consist of physical ways,

statistical approaches, and machine learning or artificial intelligence tools [3,4]. Physical methods are also referred as the plain methods and those use some physical information. The physical information could be topographic data, roughness, temperature, pressure, and even obstacles [5]. Besides, the certainties of the statistical approaches are rather limited. In the study of Liu et al. [6], the developed autoregressive integrated moving average model was suggested in order to obtain predictions of wind speed, considered in the railway strong wind warning system. Besides, future wind speed values that have not yet realized, i.e., one day later's or two day later's wind speed data of a chosen location of North Dakota were predicted using fraction-ARIMA, which is again a type of statistical models [7].

On the other hand, recent novel techniques including ANN (artificial neural network) as well as different machine learning methods are also implemented in data forecasting. Especially, ANN and machine learnings have been widely applied to predictions of wind speed, until now [3]. Also, solar energy being a more recent technology fairly utilizes predictions performed by machine learning. In this regards, Khosravi et. al. [8] have implemented an algorithm of machine learning for hourly solar irradiance estimations of the selected region. Besides, LSTM approach was exerted on predictions of the experimental results of wind power, in the study of Shi et. al. [9]. The LSTM estimation results had presented sufficient accuracy compared against the measured data [9].

Waste-water is formed of clean water which was used by people and later became to be dirty. As soon as it becomes dirty, it may consist of many undesired substances such as bacteria, food waste, chemicals, and maybe some other undesired substances. For instance, at every place of the houses, waste water could be produced. These locations may include the sinks, dishwashers, and washing machines. In this context, the target of obtaining treatment of the waste-water is to obtain removal of undesired biological or chemical substances dissolved inside the water as much as possible [10].

Exclusively, in the last decades, data predictions have become significantly important. Among those, the estimations of the future atmospheric conditions can be given as an example. This is actualized in order to determine future values of air temperature or pressure, the wind speed and direction, the precipitation conditions, else the humidity. Those are rather helpful, for instance, in order to take measures against natural disaster including floods or hurricanes. During the travel of airplanes or road vehicles, the information related with the precipitation data or air temperature are certainly required. Besides, to obtain safe travels of ferries or ships in the sea, ocean, or rivers; predictions performed on the wind speed, water wave height, or water flow speed are generally utilized. In this study, as an innovation, the prediction of the data consisting of the gas generator daily power output (P), with regards to the gas generator daily gas consumption (Q), wastewater temperature (T), wastewater conductivity (σ) and the degree of the acidity (pH) of waste-water of the past time-series of an established wastewater treatment plant, was executed. Although this study is not a hydrological study; it includes the estimation of the energy production obtained in gas turbines by the combustion of methane gas, which is formed and emerged as a result of hydrological wastewater streams. On the other hand, data estimations have the same general principles, as in the case of predicting hydraulic data. In this regards, an establishment of 7 different models was performed, and in this way, the aforementioned physical and chemical properties of the past wastewater data and the daily power output (P) data are functionally related. Accordingly, a total of 7 main different models was tried and the best model was demonstrated, in obtaining best predictions of the power generation (P) obtained from the combustion of the methane gas of the waste-water. In this way, the estimation quality was compared between these seven main models formed of inputs including the historical time series of the gas generator power output (P), compared against the inputs including the physical and chemical properties of the waste-water.

2. MATERIALS AND METHODS

2.1. ANN

Artificial neural networks are mainly and widely used in computational processes, and they resemble a network of nerve cell of biological systems. The neural network is a recently utilized computer architecture. It is a novel algorithmic structure and has a rapid and a superior learning capability, compared to conventional computers or calculators. It provides some basic computational operations to easily solve or numerically converge to a solution of complex or nonlinear problems, that are usually impossible to be solved by analytical means [11, 12]. A neuron is the basic processing element of a neural network. The back-propagation (BP) algorithm necessarily starts with the calculation of the output layer, which is the only layer where the desired outputs are available but no intermediate layer outputs, as demonstrated below in Figure 3 [13];




Figure 3. A perceptron of multilayer

2.2 Statistical Error Analysis

The quality test of the artificial intelligence estimations has been executed using three different statistical error parameters. As required, the predicted outcomes are compared with the real measured or observed data, using the mean absolute percentage error (MAPE), the correlation coefficient (R), and the root mean square error (RMSE). As the name implies, depending on the prediction accuracy, MAPE can take values in between 0% and 100%. Besides, RMSE can take any values in the positive real data set. However, the approach of MAPE and RMSE close to zero indicate higher accuracy and quality of the

computations. Finally, the correlation coefficient can take any real value in the data range of $0 \leq R \leq 1$, else also including the boundary integers of 0 and 1. However, while the correlation coefficient (R) approaching to zero exhibits lower correlations between the real data cluster and the predicted data cloud, whereas, the correlation coefficient (R) approaching to unity (one) shows higher correlations between two data sets.

Following three equations give the mathematical definitions of MAPE, RMSE, else R , respectively [14]:

$$MAPE = 100x \frac{\sum_{i=1}^N \frac{|o(i)-p(i)|}{o(i)}}{N} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N [p(i) - o(i)]^2} \quad (2)$$

$$R = \frac{(\sum_{i=1}^N [p(i)-\bar{p}][o(i)-\bar{o}])}{(\sqrt{\sum_{i=1}^N [p(i)-\bar{p}]^2} \sqrt{\sum_{i=1}^N [o(i)-\bar{o}]^2})} \quad (3)$$

In Equations (1), (2), and (3), i is used as the data sequence in the data cloud to call any instantaneous data. Again in these three equations, N corresponds to the cumulative amount of the members of all data set. Besides, the functions $o(i)$ and $p(i)$ are utilized to call any instantaneous data, respectively in the observed data cloud and the predicted data cloud, in these three equations. Multiplying the error by 100 in Equation (1) makes the error value obtained in percentage. In Equation (3), the abbreviation \bar{o} indicates the average value of all real observed data called between $i=1$ to $i=N$ found in the real observed data cloud. Finally, the denotation \bar{p} shows the mean value of whole predicted or simulated data called between $i=1$ to $i=N$ found in the predicted data cloud [14].

3. RESULTS AND DISCUSSIONS

Machine learning or artificial intelligence data estimation finds a lot of use in both physical and engineering applications. In this way, unrealized future value of the physical data that is in

consideration could be predicted with low margins of errors, using machine learning, in the case of having or forming a continuous data function. The advantage of such types of modelling involves the input data to be only the historical past time series of the considered physical parameter, or some other physical input parameters, without any detailed technical knowledge of the measurement device that is used or without performing to find solutions to complex mathematical problems.

This study was executed using a total of 445 daily average physical and chemical type of data of an installed waste water treatment plant. The data consisted of power generation (P) data of gas turbines of installed waste water treatment plant as well as the physical and chemical properties of waste water of water treatment plant. As such, the physical parameters include the temperature (T) and the conductivity of wastewater (σ), whereas, the chemical properties include the degree of the acidity of the wastewater (pH); besides, the wastewater was evaluated in the wastewater treatment plant for treatment processes as well as energy generation in the gas generators. The energy generation from the gas turbines is obtained by the generated methane gas due to the decay of the biomass. Namely, the methane (CH_4) and stabilized biomass are generated by the biomass digestions [15,16].

Among the total of 445 daily average data; 80% of the cumulative data was utilized in order to obtain proper trainings of the algorithms, whereas the rest of 20% was used in testing of the algorithms. Accordingly, in the simulations of the artificial intelligence, ANN tool was used. Figure 4 illustrates all temperature (T) data cloud allocated for training and testing, shown in orange and purple colours, respectively. As shown in this figure, the temperature (T) of the waste water is in the range of $12.400\text{ }^{\circ}\text{C} \leq T \leq 26.820\text{ }^{\circ}\text{C}$. Else, the data analysis has demonstrated that mean value of the waste-water temperature is 21.061°C , in this data range.




Figure 4. The training and testing data clouds of temperature (T) parameter

Figure 5 exhibits the entire electrical conductivity (σ) data cloud separated for training and testing, shown respectively with grey and yellow colours. In this regards, the conductivity (σ) of the waste water is in the range of $540.000\text{ }\mu\text{S}/\text{cm} \leq \sigma \leq 1,741.000\text{ }\mu\text{S}/\text{cm}$. The waste-water conductivity (σ) data analysis had revealed that the average value of data in this range is $1,315.250\text{ }\mu\text{S}/\text{cm}$.




Figure 5. The training and testing data clouds of conductivity (σ) parameter

The mean value of the degree of the acidity (pH) was observed to correspond 7.493 in the data range of $6.410 \leq pH \leq 8.570$. Since mean value of the degree of the acidity (pH) is over the value of 7.00, the analysis has revealed that the general structure of the solution is alkaline. It is also already observed from Figure 6 that instantaneous values of the measured pH data are generally over $pH=7$ line, implying this alkalinity chemical structure. Ultimately, Figure 6 indicates whole degree of acidity (pH) data cluster discretized for training and testing presented in blue and green colours, respectively.




Figure 6. The training and testing data clouds of degree of acidity (pH) parameter

The average value of the daily average values of gas generator gas consumptions (Q) was determined to be $11,767.110 \text{ m}^3$. Besides, the gas consumption (Q) data cluster included values in the range of $0.000 \text{ m}^3 \leq Q \leq 18,832.000 \text{ m}^3$. Accordingly, Figure 7 presents the value distributions belonging to whole gas generator daily gas consumptions (Q), in which this cluster is similarly discretized for training and testing presented in brown and red colours, respectively. This figure involves only the quantity of the consumed methane gas at the gas turbines, to generate electricity, not all of the quantity of the generated gas due to the decay of biomass forming methane gas. In reality, the total methane gas amount produced at the wastewater treatment plant is greater than the total amount of methane gas burned in the gas turbines, given in this figure as daily distributions. However, some of them escape or being lost from the facility without being burned in the gas turbines. Under these conditions, the total amount of methane gas burned in the gas turbines to generate electricity is reported to be 5.236 hm^3 , in this 445 days' time interval.

Finally, the analysis of the data has exhibited that the data range for the gas generator daily total energy generation (P) to be in the range of $0 \text{ MWh} \leq P \leq 48.780 \text{ MWh}$. Else, the medium value of the power generation (P) was shown to be 31.911 MWh . All in all, Figure 8 demonstrates whole gas generator daily total energy generation (P) data cluster split for training and testing displayed light grey and purple colours, respectively. In gas generators, this energy produced by the combustion of methane gas can be considered as recovered energy. Because the facility needs a serious amount of energy consumption to carry out the wastewater treatment

activity. This energy obtained from burning of methane gas in the gas generators, meets a significant part of the energy required for the facility to continue its function, and as a result, it is possible to significantly reduce the energy drawn from the network or produced by diesel generators in case of power outage. Because the energy drawn from the electricity network or the diesel fuel used for burning in diesel generators constitute a serious expense item. In this way, the expense items constituting high costs would be greatly diminished. Besides, in the analysed 445 days, it is reported and shown that total energy generations by burning of the methane gas in the gas turbines correspond to 14.200 GWh of power.




Figure 7. The training and testing data clouds of the gas generator daily gas consumption (Q)




Figure 8. The training and testing data clouds of the gas generator daily total energy generation (P)

Regarding the predictions of the generated power (P) of the facility that is executed by the artificial neural network (ANN), in this context, the daily total energy generation (P) of the gas turbine is defined according to the mathematical exponential functional relation with respect to the waste water temperature (T), the degree of acidity of the waste water (pH), the conductivity of the waste water (σ), as well as the daily total volumetric flow of the waste gas to be burned at the gas generator (Q).

Among these 4 physical and chemical parameters that were used as inputs; the waste water temperature (T) was considered in “Kelvins” to construct a better functional relation between inputs and output, the degree of the acidity (pH) was considered as usual as a dimensionless quantity to be in between 0 and 14, the conductivity (σ) was handled in $\mu S/\mu m$, whereas gas generator daily gas consumption (Q) was taken with the unit of m^3/day . Finally, gas generator daily total power generation (P) which is the dependent functional parameter was obtained at the unit of MWh/day. But, the instantaneous data points in Figures 4-8 were provided in “degree Celcius”, $\mu S/cm$, non-dimensional, m^3/day , and MWh/day, respectively for T , σ , pH , Q , and P . Accordingly, two units of “degree Celcius” and $\mu S/cm$ were considered slightly different in ANN computations compared to the demonstrated ones, respectively in Figures 4 and 5 for T and σ . Namely, the instantaneous “degree Celcius” temperature data were simply converted to Kelvin by adding the value of 273.15 to each instantaneous data, and the instantaneous conductivity $\mu S/cm$ data were simply converted to $\mu S/\mu m$ by dividing each instantaneous data by the value of 10^4 . In this way, better quality algorithms were created between inputs and outputs. Shortly, the average daily values of the parameters such as temperature (T), the degree of acidity (pH), the conductivity (σ), as well as the daily total flow of the methane gas (Q) were either used directly or modified with respect to the formerly defined ranges of these physical and chemical parameters; and those were finally processed with the exponential function to obtain the correspondence output power generation (P) of the gas generator of the facility.

The ANN algorithm was structured at the epoch number of 500 and the goal of the training parameters was adjusted to 5×10^{-19} , implying that the iterations would stop as soon as it converges below this numerical value. In ANN computations, as similar to computations of historical time-series, for 4 inputs and 1 output; a total of 356 waste water data was considered as averages or cumulative in training stage, whereas, a total of 89 data was considered as averages or cumulative in the testing stage.

The schematic representation of configured structures of ANN models is exhibited in Figure 9. Accordingly, a total of 7 main ANN models were designed and explained in this figure. Besides, the names of these main models are indicated in this figure, with green color. The desired output in all models is the output power (P) of the gas turbine, in which the gas turbine generates power by consuming methane gas that was obtained by the decay of the ingredients of the waste-water. This situation is depicted by P designation in these 7 main models, shown in Figure 9. Actually, power generation (P) forms the output of these models. Besides, two bias are required in each main model to relate the inputs and outputs with a proper equation. Those are shown as Bias 1 defined at the hidden layer and Bias 2 defined at the output layer, and indicated in this figure in this direction. At each main model, as presented in this figure, a total of 8 different sub-models were created. Accordingly, the hidden layer (HL) number was chosen in the range of $3 \leq HL \leq 10$, with an increment of $\Delta HL = 1$, between each consecutive sub-models, i.e., constituting a total of 8 different sub-models, for each main model. To describe the inputs for the main models; initially, Model 1 was generated according to the inputs of waste-water temperature (T) and the daily gas consumption of the methane gas (Q). Secondly, Model 2 was formed again using two inputs, however this time, the degree of the acidity (pH) and the daily gas consumption of the methane gas (Q). This was followed by Model 3, including the inputs of the electrical conductivity of the waste-water (σ) as well as the daily gas consumption of the methane gas (Q). Up to Model 3 and including this model, only two inputs were considered as indicated in Figure 9. But, between Model 4 and Model 6, three inputs were composed to relate the inputs with the output parameter of the power generation (P). In this regards, in Model 4, the temperature of the waste-water (T), the degree of the acidity (pH), and the daily gas consumption of the methane gas (Q) were considered as inputs of ANN algorithm. Whereas, in Model 5, the temperature of the waste-water (T), the electrical conductivity of the waste-water (σ), and the daily gas consumption of the methane gas (Q) were selected as inputs of the output power generation (P). Model 6, the final build with 3 inputs consists

of the degree of the acidity (pH), the electrical conductivity (σ), and the daily gas consumption of the methane gas (Q). Eventually, Model 7 is the single model formed of four inputs. In this context, it is designed to imply the temperature of the wastewater (T), the degree of the acidity (pH), the electrical conductivity (σ), and the daily gas consumption of the methane gas (Q), in order to functionally relate these inputs with the output parameter of power generation (P). All in all, 8 models were created for each main model, that have been obtained by the alteration of HL number in the range of $3 \leq HL \leq 10$; that resulted a total of 56 models for 7 main models and the input to output simulations were performed accordingly. All of the models include the forecasts at training and testing stages together. Accordingly, total of 445 data has been shown together with its corresponding predictions in these models.

In this study; the ANN artificial intelligence algorithm was developed using daily gas consumption of the methane gas (Q), the acidity level of the wastewater (pH), the electrical conductivity of the wastewater (σ) and the temperature values of the wastewater (T). In physics, a considered type of energy per unit mass has a certain amount of energy content. For example, air blowing as wind at a certain amount of speed has a certain energy content per unit kg, whereas water flowing as river again at a certain amount of speed has a certain energy content per unit kg. If their units are expressed as J/kg, and if these values of the energy content are multiplied by the amount of the substances belonging to the relevant energy type displaced per unit time, the amount of the energy rate at a certain mass flow rate from the expression of $(J/kg) \cdot (kg/s)$ will be obtained. In other words, the energy produced in physics has an inseparable connection with the substance flow rate. This also applies to methane gas entering to the gas generator. In other words, the methane gas energy produced from the gas generator has a directly proportional relationship with the methane gas flow rate entering to the gas generator. For this reason, in all 56 tested models in total, that are obtained consisting of built 7 main models and 8 intermediate models created for each main model, the parameter of daily gas

consumption of the methane gas (Q) was used continuously, without any change, considered in training, testing stages as well as during the creation of the ANN algorithm. As a result, the predictions of the energy production of methane gas formed from the wastewater have been performed by considering three other parameters such as wastewater temperature (T), acidity level of wastewater (pH), and electrical conductivity of wastewater (σ), with the methodology of selecting any of those three alone or by randomly selecting two of the three, or by considering all three together; however, at all conditions always using the daily gas consumption of the methane gas (Q).

Figure 10 exhibits the results of main Model 1, formed of two inputs, including the output of the real measured data of gas generator daily total power generation (P), and its counterpart output ANN predictions obtained at $HL=3$, $HL=4$, $HL=5$, $HL=6$, $HL=7$, $HL=8$, $HL=9$, and $HL=10$. The selected input parameters are both physical ones including temperature (T) and the daily consumption of the methane gas (Q). Therefore, this main Model 1 includes the results of a total of 8 sub-models, shown at the same figure. In this figure, the light blue, pink, black, yellow, red, green, dark blue, brown and grey colors were used to indicate functional distribution curves of real power (P) data as well as its estimations obtained at $HL=3$, $HL=4$, $HL=5$, $HL=6$, $HL=7$, $HL=8$, $HL=9$, and $HL=10$, respectively.

On the other hand, Figures 11 and 12 show the output power generation (P) results of main Models 2 and 3, formed of two inputs, again considering same ranges of hidden layers (HL). In this regards, one input parameter is chemical, while the other is physical in main Model 2; respectively corresponding to the degree of the acidity (pH) and the daily consumption of the methane gas (Q). On the other hand, both parameters are physical in main Model 3. I.e., the electrical conductivity (σ) as well as the daily consumption of the methane gas (Q) were selected as inputs to obtain output parameter of power generation (P). Same logic of coloring was also taken into account in both figures for the functional curves belonging to real measured data

and corresponding estimates at different hidden layers (HL). Similarly, Figures 11 and 12, each involve the results of 8 sub-models obtained for main Models 2 and 3.

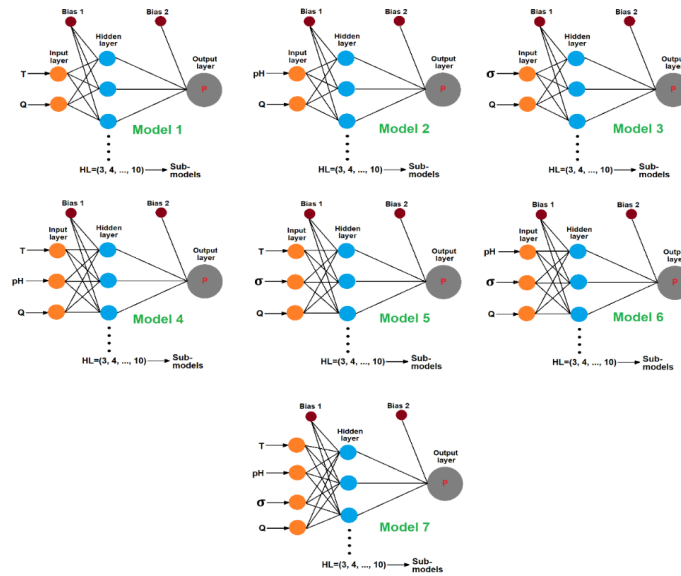


Figure 9. Seven main models of ANN structure




Figure 10. Model 1 results for gas generator daily total energy generation (P)




Figure 11. Model 2 results for gas generator daily total energy generation (P)

Figure 13 presents main Model 4 data distributions, now formed of three inputs, including the real output power (P) data function given with respect

to the predictions obtained considering different hidden layers (HL) studied in the range of $3 \leq HL \leq 10$. The inputs are formed of two physical and one chemical parameter. While the degree of the acidity (pH) was chosen as the chemical parameter, whereas, the temperature (T) as well as the daily consumption of the methane gas (Q) were selected as the physical parameters. Again 8 sub-models are included in this figure as well as the real data function is included. As similar to former main models, the same colors and patterns have been taken into account to indicate the real data function and the estimations obtained at different hidden layer (HL) numbers.




Figure 12. Model 3 results for gas generator daily total energy generation (P)




Figure 13. Model 4 results for gas generator daily total energy generation (P)

The data distributions of main Model 5 consisting of real output power (P) data set versus the predictions at different hidden layer numbers, formed of again three inputs, are exhibited in Figure 14. All of the studied parameters in this main model are physical parameters, and no chemical parameter was considered in this main model. In this regards, the temperature (T), the electrical conductivity (σ), as well as the daily consumption of the methane gas (Q) are used as physical parameters of the inputs to obtain the output of power generation (P). Again comparison of 8 sub-models has been revealed in this figure. Same curve colors and curve patterns were utilized for different hidden layers (HL), considered in the range of $3 \leq HL \leq 10$, as similar to previous four main models.




Figure 14. Model 5 results for gas generator daily total energy generation (P)

Figure 15 displays results of main Model 6 involving real output power (P) data cloud given according to the estimations obtained at 8 distinct hidden layer numbers. Model 6 was constituted of three inputs to obtain power generation (P) which is the output parameter. Apart from the chemical parameter of the degree of the acidity (pH); the

electrical conductivity (σ), and the daily consumption of the methane gas (Q) were selected as the physical parameters. In main Model 6, the study of 8 different hidden layer numbers resulted again the comparison of the estimated power generation results of 8 different sub-models that were compared to the real measured output power (P). In parallel to the former implemented main models, same curve colors and curve patterns were used in this main Model 6 for different hidden layers (HL), considered in the range of $3 \leq HL \leq 10$.

Final main model, i.e., Model 7 is the only one formed of 4 inputs, in which one is the chemical, the rest are the physical parameters. Eventually, the outcomes of this model are demonstrated in Figure 16. In main Model 7, the degree of the acidity (pH) was used as chemical parameter input, whereas, the temperature (T), the electrical conductivity (σ) and the daily consumption of the methane gas (Q) were utilized as the physical parameter inputs. In this way, the advantages or disadvantages of using all four of the inputs were tested in main Model 7, according to the incomplete use of some of the inputs which were tested in the former main models. On the other hand, as similar to the former main models; again the outcomes of 8 different hidden layer (HL) numbers were studied and compared with respect to the real measured data cloud of the gas generator daily total energy generation (P). To indicate the real or estimated data cloud function curves, both same colors and same patterns of the previous main models were taken into account as denoted in Figure 16.




Figure 15. Model 6 results for gas generator daily total energy generation (P)




Figure 16. Model 7 results for gas generator daily total energy generation (P)

The statistical accuracy results of 7 main models as well as 56 sub-models have been presented in Tables 1 and 2, including MAPE, RMSE, and R . In this regards, while Table 1 gives the statistical errors of main Models 1, 2, 3, and 4; whereas, Table 2 provides the statistical errors of main Models 5, 6, and 7. In both tables, the best results for each main model giving the superior statistical accuracy outcomes are indicated by bold color to be distinguished from other sub-models provided at different hidden layer numbers (HL). Besides, the best result of all 7 main models is exhibited with both bold and italic patterns. In this context, MAPE, RMSE, and R results of main Model 5 at 9 HL found in Table 2 generates the best outcomes, respectively corresponding to 6.1279%, 2.1540 MWh/day, and 0.9730. The estimation function of this result is reported as the function that converges most to the real observed values of the gas generator daily total energy generation (P), among 56 ANN models tested in this ANN study.

Apart from the best result of all ANN computations, the simulation performed at 5 HL of main Model 1 found in Table 1, the computation executed at 9 HL of main Model 2 found in Table 1, the study actualized at 6 HL of main Model 3 found in Table 1, as well as the trial conducted at 10 HL of main Model 4 found in Table 1, performed better results than their counterparts found in the same main models. Similarly, in Table 2, sub-model results at 9 HL of main Model 5, sub-model outcomes at 8 HL of main Model 6, else statistical error results of 5 HL of main Model 7 have generated relatively preferable results than their counterparts found in the same main models.

Although, the estimated data function distribution belonging to the sub-model of 9 HL of main Model 5 was shown in Figure 14 with brown color, since this result outcome with the best convergence to the real observed values of the gas generator daily total energy generation (P); for this reason, to obtain a better visualization of the prediction quality of this model, the data distributions of the actual function and the predicting function at this model are displayed in Figure 17. In this figure, while the real observed value distributions are indicated with a curve of continuous orange color, whereas, its corresponding estimations performed at 9 HL of main Model 5 are demonstrated with dashed type curve of light blue color. When the distributions of the actual production data given in Figure 17 are compared with the forecast distributions that provide the best estimate and obtained in 9 HL of main Model 5; it is seen that two function curves overlap each other quite well and the estimated curve captures the real production curve well, even including the sudden break points. The correlation coefficient of 0.9730 R for this superior model also indicates the high compatibility of this implemented model. On the other hand, the real measured data set was indicated in Figure 8, to be in the range of $0 \text{ MWh} \leq P \leq 48.780 \text{ MWh}$. Besides, the forecasting data set of the model performed at 9 HL of main Model 5, had generated the predicting range to be in between $0.544 \text{ MWh} \leq P \leq 47.430 \text{ MWh}$. In this context, the discrepancy errors of the boundary values of this predicting range with respect to the real data cluster are reported to be significantly small.

Although it is thought that using more input parameters will strengthen the relationship with the output, and accordingly, generate better prediction results when associating a physical parameter with mathematical equations by connecting it to other physical parameters utilizing the artificial intelligence method, this is not always the true. During the introduction of an additional parameter to the artificial intelligence while ensuring the correlation of the relationship provides sometimes higher success, this is true up to a certain threshold value. Namely, introducing additional parameters to artificial intelligence above the threshold value,

may reduce the success of the algorithm. When the studied main models are evaluated, during together utilization situation of the parameters consist of wastewater temperature (T), wastewater electrical conductivity (σ) and daily gas consumption of the methane gas (Q) taking part in the framework of the 5th main model; in addition to these in the 7th main model, adding the acidity level (pH) parameter of wastewater to the artificial intelligence, does not improve the modeling, on the contrary, it worsens it. In this case, it is observed that the acidity degree (pH) parameter of the wastewater, in addition to the electrical conductivity (σ) parameter, does not actually provide a further prediction improvement, on the contrary, it relatively worsens the prediction error parameters. This is due to the fact that the electrical conductivity (σ) parameter and the


wastewater acidity (pH) parameter, all in all, are directly related to each other in a physical aspect. The more electrical conductivity (σ) occurs in the wastewater environment, the further the wastewater gets away from its pH neutral environment and more increase will occur in the acidity level (pH) of the wastewater in the acidic or basic direction. For this reason, during algorithm training with the artificial intelligence, as in Model 7, simultaneous utilization of two parameters consisting of electrical conductivity (σ) and the degree of acidity (pH) along with the other two parameters consisting of temperature of the waste-water (T) and the daily consumption of the methane gas (Q); does not further improve the mathematical learning between the instantaneous values of the artificial intelligence's data cloud, conversely worsens it.

Table 1. Statistical accuracy results of ANN computations for Main Models 1, 2, 3, and 4

Main model number	Sub-model (HL)	MAPE (%)	RMSE (MWh/day)	R
1	3	7.5360	2.4845	0.9642
	4	6.8609	2.3955	0.9664
	5	6.7281	2.2849	0.9696
	6	6.8729	2.3934	0.9665
	7	6.6590	2.3414	0.9678
	8	6.8875	2.3453	0.9673
	9	7.9915	2.5423	0.9615
2	10	6.7889	2.2590	0.9689
	3	6.9177	2.3609	0.9661
	4	6.9086	2.3718	0.9658
	5	6.9107	2.3743	0.9657
	6	6.6623	2.2931	0.9682
	7	6.7451	2.3305	0.9671
	8	6.4806	2.3313	0.9670
3	9	6.1985	2.2516	0.9695
	10	6.5529	2.2445	0.9695
	3	6.4294	2.3052	0.9677
	4	6.4940	2.3098	0.9676
	5	6.4935	2.3119	0.9675
	6	6.1689	2.2574	0.9691
	7	6.3413	2.2815	0.9687
4	8	6.4656	2.3025	0.9680
	9	6.4177	2.3050	0.9677
	10	6.3311	2.2704	0.9689
	3	6.7890	2.3103	0.9681
	4	6.6291	2.3197	0.9677
	5	6.8251	2.3460	0.9671
	6	6.7508	2.3487	0.9667
4	7	6.7897	2.3346	0.9677
	8	7.0165	2.4263	0.9651
	9	6.7995	2.3430	0.9667
	10	6.3995	2.2848	0.9693

Table 2. Statistical accuracy results of ANN computations for Main Models 5, 6, and 7

Main model number	Sub-model (HL)	MAPE (%)	RMSE (MWh/day)	R
5	3	6.9356	2.4015	0.9656
	4	6.9742	2.4134	0.9665
	5	7.1193	2.4268	0.9647
	6	6.7679	2.3788	0.9670
	7	6.7910	2.3468	0.9682
	8	6.7640	2.3550	0.9672
	9	6.1279	2.1540	0.9730
	10	7.2975	2.5900	0.9633
6	3	6.9145	2.3581	0.9663
	4	6.6185	2.2525	0.9693
	5	6.5877	2.2697	0.9689
	6	6.8438	2.3049	0.9680
	7	6.4537	2.3227	0.9673
	8	6.5098	2.2350	0.9697
	9	6.7482	2.3250	0.9674
	10	6.5699	2.2501	0.9694
7	3	6.8162	2.3623	0.9665
	4	9.0479	2.9186	0.9550
	5	6.4265	2.2466	0.9706
	6	8.9553	2.8297	0.9532
	7	6.8448	2.3971	0.9670
	8	7.1917	2.4647	0.9628
	9	8.9645	2.8446	0.9528
	10	6.8151	2.3540	0.9668

**Figure 17.** The results of 9 HL of 5th main Model for gas generator daily total energy generation (P)

Artificial neural network (ANN) type of artificial intelligence (AI) on the data prediction is related with the physical algorithmic interpretation of input data to obtain corresponding magnitudes of the output data with an acceptable error range. Here, the amount and the type of selected input parameter and even their physical units are important in capturing the relationship between input and output variables.

On the other hand, it also becomes important as the number of the hidden layers (HL) selected will increase and decrease the mathematical relationships in the equation that captures the output value in the mathematical modeling. In the study, appropriate mathematical models were created by selecting the input parameters in different combinations, that is, by creating different main models; during the generation of the relationship between all existing physical input parameters found in the data cluster and the power output (P) parameter. In addition, in order for the computer to make the best calculations and simulate as quick as possible; considering the physical units of input and output parameters, the most appropriate physical units were chosen. In this regard, the unit for the temperature (T) parameter of the wastewater was selected as Kelvin (K), the unit for its conductivity was chosen as $\mu\text{S}/\mu\text{m}$, the unit for the degree of acidity was considered as dimensionless, the unit

for the daily cumulative flow of the methane gas to the gas generator was taken into account as m^3/day , and the power (P) obtained from the gas generator was distinguished as MWh/day , and the simulation calculations were carried out accordingly. Another important factor that affects the sensitivity of the study and increases the prediction success by reducing error values or bringing the correlation coefficient (R) value closer to 1 is the percentage and number of the test data used in the training of the algorithm. Generally, 80% of the total data in the dataset is used for training, while the remaining 20% of the cumulative data is used for testing. Although the percentages are adjusted in this way, the large number of the total data considered in estimations is important for the creation, development and the improvement of the mathematical algorithm. In case of insufficient data, mathematical modeling is usually not sufficient for simulation and unqualified predictions with high error values or low correlation coefficients (R) may occur. For this purpose, the number of the samples of actual observed experimental training and testing data should be increased as much as possible in order to further reduce the error rates or to increase the correlation coefficient values. In this way, different physical input parameters in the data cloud are learned and associated better by the artificial intelligence algorithm, with respect to the output parameter; and as a result, highly successful prediction results that are closely approaching to the real values could be obtained. In the current study, different types of modelling combinations were created, a variety of different numbers of hidden layers (HL) were tested, as well as best physical units of the physical parameters were adjusted. The remaining regulation would be only on the increase of the total number of the data samples, considered in the computations, in order to obtain more accurate predictions.

It may be necessary to deal with complex relationships and differential equations in analytically relating an important physical quantity such as power output (P) to other known physical parameters. In some cases, it may not be possible to solve these equations using analytical methods. Whereas, in many of the cases, complex, analytical and non-stochastic problems cannot be solved

directly. Besides, to solve these numerically, advanced computers are needed and it is usually quite time consuming. On the other hand, in some cases, a direct relationship cannot even be established between input and output parameters. In determining the relationship between them, artificial neural networks (ANNs) provide fast, precise and highly sensitive results. In the ANNs, generally, the output parameter is easily obtained by a mathematical relationship in which the input parameters are substituted to their proper places in an exponential function. The algorithm is easier to design and use than the other methods. For example, in this study, technical information of the facility is not needed in estimating the power output (P) obtained by combusting the methane gas in the gas generators, in which the methane gas was acquired due to the decay of the wastes of the waste-water in the considered wastewater treatment facility. On the other hand, in complex analytical relations or empirical equations, either further technical knowledge of the facility is required or more physical input parameters and measurements on those are needed. Whereas here, in the current study, with artificial intelligence (AI), the output power (P) parameter is only and rapidly associated with the available physical and chemical parameters found in the data cluster including temperature (T), degree of acidity (pH), conductivity (σ), and the methane gas daily consumption (Q).




Figure 18. Taylor diagram for the output power predictions (P)

The correlation coefficient (R) values and the standard deviations of the best sub-models, in which the best sub-models of each main models were presented in Tables 1 and 2 using the bold

color, are demonstrated in Taylor diagram, which is shown in Figure 18. In this regards, the results of 5 HL of Main Model 1, 9 HL of Main Model 2, 6 HL of Main Model 3, 10 HL of Main Model 4, 9 HL of Main Model 5, 8 HL of Main Model 6 and 5 HL of Main Model 7 have been indicated in this figure. It is concluded that the results of the standard deviations and the correlation coefficients (R) are more or less close to each other for these best sub-models. Accordingly, the correlation coefficient range for these best sub-models were reported to be in the range of $0.9691 \leq R \leq 0.9730$, as shown in Tables 1 and 2 as well as on Figure 18. On the other hand, for the cited best sub-models of main Models 1, 2, 3, 4, 5, 6, and 7; the standard deviation values were reported to correspond respectively to 9.3186 MWh/day, 9.1563 MWh/day, 9.0878 MWh/day, 9.2934 MWh/day, 9.3248 MWh/day, 9.0284 MWh/day, and 9.3278 MWh/day. Besides, the standard deviation of the real measured output power (P) was concluded to be 9.0987 MWh/day. The standard deviation values of all these best prediction sub-models being close to each other as well as being close to the standard deviation value of the real observed output power (P) data represent the high accuracy of the predictions. Besides, high correlation coefficients (R) dispersed so close to each other on the Taylor diagram show the high compatibility of the power data estimations with respect to the real observed power (P) data.

4. CONCLUSION

In this study, data predictions on the daily total energy generation (P) of a gas generator of an installed waste water treatment plant, using the physical and chemical parameters of the waste water of this installed waste water treatment plant were performed; using the techniques of artificial intelligence methods.

In this context, a cumulative of 7 main models and 56 sub-models were created. The ANN predictions indicated that best prediction outcome was obtained with the utilization of 9 HL of main Model 5. This best model was obtained by adjusting three parameters as input, in which three of them were selected as physical parameters, and no chemical

parameter was utilized. Among those physical parameters, the temperature (T), the electrical conductivity (σ), and the daily consumption of the methane gas (Q) of the facility are taken into account. Besides, this superior model of ANN had given statistical error outcomes of 6.1279% MAPE, 2.1540 MWh/day RMSE, and 0.9730 R , for the prediction of the physical parameter of the gas generator daily total energy generation (P).

Accordingly, when three statistical error parameters are taken into account, it was observed and concluded that at this best model of artificial intelligence tool of ANN, close and accurate results of predictions could be acquired for power generations (P) of the gas generator of the facility.

5. ACKNOWLEDGEMENTS

Thanks to the facility of the waste-water treatment plant and the staff providing this data, in conducting of this study.

6. REFERENCES

1. İlhan, A., 2022. Forecasting of River Water Flow Rate with Machine Learning. *Neural Computing and Applications*, 34, 20341-20363.
2. IEA, 2023. International Energy Agency 2023, <https://www.iea.org/>.
3. Zhang, J., Yan, J., Infield, D., Liu, Y., Lien, F., 2019. Short-term Forecasting and Uncertainty Analysis of Wind Turbine Power Based on Long Short-term Memory Network and Gaussian Mixture Model. *Applied Energy*, 241, 229-244.
4. Jung, J., Broadwater, R.P., 2014. Current Status and Future Advances for Wind Speed and Power Forecasting. *Renewable and Sustainable Energy Reviews*, 31, 762-777.
5. Tascikaraoglu, A., Uzunoglu, M., 2014. A Review of Combined Approaches for Prediction of Short-term Wind Speed and Power. *Renewable and Sustainable Energy Reviews*, 34, 243-254.
6. Liu, H., Tian, H., Li, Y., 2015. An EMD-recursive ARIMA Method to Predict Wind Speed for Railway Strong Wind Warning

- System, *Journal of Wind Engineering and Industrial Aerodynamics*, 141, 27-38.
7. Kavasseri, R.G., Seetharaman, K., 2009. Day-Ahead Wind Speed Forecasting Using F-ARIMA Models. *Renewable Energy*, 34(5), 1388-1393.
 8. Khosravi, A., Koury, R.N.N., Machado, L., Pabon, J.J.G., 2018. Prediction of Hourly Solar Radiation in Abu Musa Island Using Machine Learning Algorithms. *Journal of Cleaner Production*, 176, 63-75.
 9. Shi, X., Lei, X., Huang, Q., Huang, S., Ren, K., Hu, Y., 2018. Hourly Day-ahead Wind Power Prediction Using the Hybrid Model of Variational Model Decomposition and Long Short-term Memory. *Energies*, 11(11).
 10. Zhang, Z., Ye, L., Qin, H., Liu, Y., Wang, C., Yu, X., Yin, X., Li, J., 2019. Wind Speed Prediction Method Using Shared Weight Long Short-term Memory Network and Gaussian Process Regression. *Applied Energy*, 247, 270-284.
 11. Ilhan, A., Bilgili, M., Sahin, B., Akilli, H., 2015. Estimation of Aerodynamic Characteristics for a Horizontal Axis Wind Turbine. *International Journal of Engineering and Natural Sciences*, 9(2), 51-57.
 12. Bilgili, M., 2010. Prediction of Soil Temperature Using Regression and Artificial Neural Network Models. *Meteorology and Atmospheric Physics*, 110(1), 59-70.
 13. Graupe, D., 2007. *Principles of Artificial Neural Networks*. World Scientific Publishing Co. Pte. Ltd., 2nd ed., USA.
 14. Bilgili, M., Sahin, B., 2010. Comparative Analysis of Regression and Artificial Neural Network Models for Wind Speed Prediction. *Meteorology and Atmospheric Physics*, 109(1), 61-72.
 15. Tchobanoglous, G., Burton, F.L., Stensel, H.D., 2003. *Wastewater Engineering: Treatment and Reuse*. Metcalf & Eddy, Inc., McGraw-Hill, 4th ed., New York, USA.
 16. Ilhan, A., 2023. Energy Recovery Analysis of a Biomass Type of Installed Waste Water Treatment Plant. *Cukurova University Journal of the Faculty of Engineering*, 38(1), 169-183.

Çok Kriterli Karar Verme Yöntemleri ile Yeni Otobüs Tasarımında Koltuk Modeli Seçimi

Merve ÖZMEN*¹ ORCID 0009-0002-1971-4751

Z. Figen ANTMEN¹ ORCID 0000-0001-8475-1300

¹Çukurova Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Adana

Geliş tarihi: 05.02.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ÖZMEN, M., ANTMEN, Z.F., (2024). Çok Kriterli Karar Verme Yöntemleri ile Yeni Otobüs Tasarımında Koltuk Modeli Seçimi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 375-384.

Öz

Dünyada bireyleri bir yerden diğer bir yere taşıyan karayolu taşımacılığı ülkelerin ekonomisinin gelişmesi anlamında üzerinde durulması gereken önemli bir araştırma konusudur. Günümüzde her alanda olduğu gibi rekabet taşımacılık sektöründe de kendini göstermektedir. Otobüs üreticisi firmalar bu rekabet koşullarından dolayı tasarım ve model değişikliği çalışmalarında pek çok kriteri göz önünde bulundurmaya zorlanmaktadır. Özellikle pek çok kriterin olduğu problemlerin çözümünde Çok Kriterli Karar Verme (ÇKKV) yöntemlerinden yararlanılmaktadır. Bu çalışmada otomotiv sektöründe üretim faaliyetinde bulunan yerli bir firmada, yeni bir otobüs tasarımında Analitik Hiyerarşi Prosesi (AHP) ve Technique for Order Preference by Similarity to Ideal Solution (TOPSIS) yöntemlerinden faydalanılarak ideal yolcu koltuk modeli seçimi sağlanmıştır.

Anahtar Kelimeler: Çok kriterli karar verme, Otomotiv, Tedarikçi seçimi, AHP, TOPSIS

Multi Criteria Making Methods Approach to Seat Model Selection in Design of New Bus

Abstract

Road transportation which carries people from a place to another place in the World, is an important research subject that should be emphasized in terms of the development of the economy of countries. Under the current global conditions, competition shows its importance in the transportation industry as in every industry. Because of these competition conditions, bus manufacturers have to consider about many criteria in their design and facelift projects. In order to solve the problems which there are multi-criteria, Multi Criteria Making Methods Approach, as in this study, are using. In this study, seat model selection was provided by using Analytic Hierarchy Process (AHP) and Technique for Order Preference by Similarity to Ideal Solution (TOPSIS), considering all criteria in a new bus design project which have been worked from a bus manufacturer which is working in domestic automotive industry in Turkey.

Keywords: Multi criteria making methods Approach, Automotive, Supplier selection, AHP, TOPSIS

*Sorumlu yazar (Corresponding Author): Merve ÖZMEN, mervebatarlar@gmail.com

1. GİRİŞ

Rekabetin her sektörde kendini gösterdiği günümüzde, işletmeler varlıklarını sürdürmeyi ve başarılı olmayı ancak müşteri beklentilerini karşılayan ürün ve hizmetleri sunarak sağlayabilmektedir. Bu başarı da ancak doğru proje ve fizibilite çalışmaları ile mümkün kılınabilmektedir.

Hemen her sektörde olduğu gibi otomotiv sektöründe de pek çok yerli ve yabancı üretici bulunmaktadır. Bu alternatif üreticiler ve ürün çeşitliliği müşteriler için pek çok avantaj doğururken üreticiler için araç projelerinin önemini de arttırmaktadır.

Günümüz piyasa şartlarında yatırım ve proje maliyetleri göz önünde bulundurulduğunda yeni bir otobüs tasarım projesinde doğru fizibilite çalışmasının önemi daha net anlaşılabilir [1].

Doğru proje çalışmaları için öncelikle pazar analizlerinin çok iyi yapılması ve doğru pazara hizmet edecek doğru aracın sunulmasının önemi çok büyüktür. Doğru pazara, müşteri beklentisini karşılayan doğru ürün sunulması proje başarısını getirecektir [2].

Bu çalışmayı gerçekleştirdiğimiz işletme, otomotiv sektöründe hizmet veren yerli bir otobüs üreticisidir. Firma, pazar ve müşteri ihtiyaçlarına ve stratejik planlamalarına göre yeni otobüs tasarımlarını ve mevcut otobüslerin “model yüz değişimi” çalışması olarak adlandırılan mevcut modelden benzetimle yüz değişikliği ya da modifikasyon olarak değerlendirebileceğimiz otobüs ve midibus projelerini Türkiye’deki tesisinde gerçekleştirmektedir.

Yeni araç tasarım veya model yüz değişimi çalışmalarında genellikle Satış&Pazarlama, Ar-Ge, Satın Alma, Üretim, Maliyetlendirme, Kalite, Homologasyon (Onay ve Yürürlük) ve Planlama birimlerinden üyeler yer almaktadır. Bu çalışma kapsamında, Çok Kriterli Karar Verme (ÇKKV) yöntemlerinden Analytic Hierarchy Process (AHP) ve Technique for Order Preference by Similarity To

Ideal Solution (TOPSIS) metodlarından yararlanılarak yurt dışı pazarına yeni tasarlanan bir otobüs için otobüs yolcu koltuklarının seçimi gerçekleştirilmiştir.

Çalışmanın çıkış noktası yeni bir regülasyon kapsamında Avrupa pazarında yürürlüğe geçecek olan okul otobüsü modelidir. Dolayısı ile yasal düzenleme-regülasyona bağlı bir ihtiyaç söz konusudur. Bu ihtiyaç doğrultusunda Fransa bayisi tarafından iletilen talebe istinaden yeni otobüs çalışması ihtiyacı Üst Yönetim ile paylaşılmıştır. Yönetim Kurulu kararına istinaden fizibilite çalışmaları başlatılmıştır.

Okul otobüsleri, araştırma konusu olan işletmenin şehir içi otobüs hattında üretilmektedir. Okul otobüsleri, tasarım ve üretim konsepti olarak şehir içi otobüsler ile çok benzer araçlardır. Okul otobüsleri ile şehir içi otobüsler, yolcu koltukları açısından farklılık göstermektedir. Ek olarak okul otobüslerinde, otobüs arkasındaki “Duracak lambası” ve yolcu koltuk kolçağı gibi bazı aksesuarların bulundurulması zorunluluğu vardır. Dolayısı ile çalışma kapsamındaki okul otobüsleri için yeni bir üretim alanı ihtiyacı ya da tesiste herhangi bir farklı yatırım ihtiyacı söz konusu değildir. Yeni otobüs üretimi mevcut kaynaklara göre çalışılmış ve planlanmıştır.

İşletmenin benzer konseptte yurt içi pazarına ürettiği yerli bir okul aracı modeli bulunmaktadır. Bu nedenle benzer tecrübeye sahip olunan bir modeli, Avrupa pazarına göre yeniden dizayn edecek şekilde yol haritası çıkarılmıştır.

2. MATERYAL VE METOT

2.1. Materyal

Toplu taşımının en çok tercih edilen araçlarından biri otobüslerdir. Hem şehir içi hem de şehirler arası yolcu taşımada maliyet, süre ve hizmet ulaşım kolaylığı gibi çeşitli etkenlerle otobüs taşımacılığı uzun yıllardır tercih edilir olmuştur. Bu büyük pazarda günümüz koşullarında otobüs markaları arasında da ciddi bir rekabet söz konusudur.

Otobüsün iç tasarımı, en az dış tasarımı ve mekanik özellikleri kadar önemlidir. Yolcu memnuniyeti ve

yolculuk kalitesini doğrudan etkileyen iç alanların doğru tasarımı konusu otobüs üreticileri için kritik konulardandır. Bir yolcu, bir otobüse bindiği zaman önce koltukların konforuna, yatma açısı, ayak dayama ve kol dayama gibi fonksiyonlarına ve monitör kullanım durumuna bakmaktadır. Araç koltuklarının rahatlığı, ergonomisi, dayanıklılığı, döşeme kalitesi, kol dayama, ayak dayama opsiyonları, koltuk yatma açısı, koltuk genişliği, monitör olup olmaması gibi kriterler seçimleri doğrudan etkilemektedir.

Çalışmanın yapıldığı yerli otobüs üreticisi uzun yıllardır piyasanın önde gelen firmalarından biridir. Yeni regülasyon kuralları gereği Fransa pazarından ihtiyaç olarak bildirilen okul otobüsü için çalışma yapılmıştır. Bu çalışmada söz konusu yeni otobüs modelinde yolcu koltuk setlerinin seçimi değerlendirilmiştir.

2.2. Metot

Yeni araç tasarımında koltuk seti seçimi için ÇKKV yöntemlerinden AHP ve TOPSIS yöntemlerinden faydalanılmıştır. İlgili seçim çalışmasında ilgili departmanlarda çalışanların uzmanlık alanları doğrultusunda bazı kriterler belirlenmiştir. Belirlenen kriterler doğrultusunda mevcut tedarikçi havuzundan seçilen tedarikçiler ve bu tedarikçilerin uyabilecek yolcu koltuk modelleri belirlenmiştir. Alternatifler için öncelikle AHP metoduna göre en uygun alternatif belirlenmiştir. Sonrasında da aynı kriterlere göre ilgili modeller TOPSIS yöntemine göre değerlendirilmiştir.

Bu çalışmaya konu olan kriterler Çizelge 1’de belirtilmiştir.

Çizelge 1. Kriterler

No	Kriter kategorisi	Kriter
K1	Tasarım	Koltuk ağırlığı
K2	Tasarım	Koltuk genişliği
K3	Tasarım	Opsiyon seçenekleri
K4	Tedarik	Maliyet
K5	Tedarik	Lojistik avantaj
K6	Tedarik	Teslimat performansı
K7	Tedarik	Üretim kapasitesi
K8	Kalite	Ürün iade oranı

Çalışmaya konu olan koltuk üreticileri ve koltuk modelleri Çizelge 2’de belirtilmiştir.

Çizelge 2. Alternatifler

No	Üretici	Alternatif model
X1	X	M3350NG
X2	X	M3350
X3	X	M3320L
Y1	Y	Star30
Y2	Y	Star40

2.2.1. AHP

AHP, ÇKKV yöntemlerinden en yaygın olarak kullanılan ve en popüler yöntemlerin başında gelmektedir. AHP’nin temelleri 1968 yılında Myers ve Alpert tarafından atılmıştır. 1977’de ise Saaty tarafından bir model olarak geliştirilmiştir. Zamanla çok kriterli karar verme problemlerinin çözümünde uygulanabilir bir yöntem haline gelmiştir [3].

AHP yönteminde karar vericiler, karar vermede önemli olduğu belirlenen kriterler, karara etkisi olduğu düşünülen kısıtlar ve alternatifler söz konusudur. İlk adımda problem tanımlanır. Bu aşamada görüşleri alınan uzmanlar ile beraber kriterler ve alternatifler belirlenmiştir.

İkinci aşamada belirlenen kriterler doğrultusunda karşılaştırma matrisleri oluşturulur. Köşegenleri 1 olacak şekilde ikili karşılaştırmalara dayanan n sayıda kriterin olduğu A matris örneği Eşitlik 1’de belirtilmiştir.

$$A_{ij} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix} \quad (1)$$

Her bir kriter için alternatiflerin ikili karşılaştırmaları ve kriterlerin kendi arasında ikili karşılaştırmaları yapılır. Karşılaştırma matrislerinde kullanılan önem derecelendirmesi ölçeği Çizelge 3’te belirtilmiştir [4].

Çizelge 3. Önem derecelendirme ölçeği [5]

Önem değerleri	Değer açıklamaları
1	İki seçeneğin önemlerinin eşit olması durumu
3	1.seçeneğin 2.seçenekten biraz daha önemli olmasının karşılığı
5	1.seçeneğin 2.seçeneğe göre oldukça önemli olmasının karşılığı
7	1.seçeneğin 2.seçeneğe göre çok önemli olmasının karşılığı
9	1.seçeneğin 2.seçeneğe göre ciddi bir baskınlık ile önemli olmasının karşılığı
2.4.6.8	Seçeneklerin denk olması durumunda kullanılan ara değerler

Her bir kriterin alternatiflere göre tek tek kendi içerisinde birebir karşılaştırmalarına dayalı değerlendirme yapılmaktadır. Hem kriterler hem de alternatiflerin değerlendirmelerine göre matris elemanlarının sütun toplamına bölünmesi ile ağırlık matrisleri elde edilir.

Sonraki adımda elde edilen ağırlık matrislerinin satır ortalaması alınır. Satır ortalamalarının bir araya getirilmesi ile özet ağırlıklandırma tablosu elde edilir. Alternatifler için elde edilen özet ağırlıklandırma matrisi elemanları ile elde edilen kriter ağırlıkları matrisinin elemanlarının çarpılması ile değerlendirme matrisi elde edilmiş olur. Son aşamada elde edilen bu matris, alternatifler arasındaki sıralamayı verecek ve bu şekilde ideal alternatif bulunmuş olacaktır [6].

2.2.2. TOPSIS

TOPSIS olarak adlandırılan yöntemin temelleri 1981 yılında Yoon ve Hwang tarafından atılmıştır. 1992 yılında Chen ve Hwang tarafından yöntem ortaya konmuştur. Yöntem var olan alternatiflerin, belirlenen pozitif ve negatif ideal çözüm merkezlerine uzaklığının değerlendirilmesine dayanır [6].

Yöntemde ilk olarak alternatifler ve kriterlerden oluşan karar matrisi oluşturulur. Eşitlik 1’de belirtildiği üzere alternatiflerin n adet kritere göre oluşturulduğu örnek A karar matrisi oluşturulur. A

karar matrisine göre normalizasyon matrisi oluşturulmaktadır. Normalize matris oluşturulurken karar matrisi değerlerinin karelerinin sütun toplamı alınarak bu değerlerin kareleri alınır. Karar matrisi elemanlarının bu elde edilen değerlere bölünmesi ile normalize karar matrisi değerlerine ulaşılır.

Bir sonraki adımda değerlendirme kriterlerine ilişkin ağırlık değerleri ile normalize matrisinde elde edilen ilgili sütun elemanlarının her birinin çarpımı ile ağırlıklandırılmış normalize matris elde edilir. Eşitlik 2’de w_i ağırlık değerlerinin belirlenen V ağırlıklandırılmış normalize matris gösterilmiştir.

Bir sonraki adımda ideal (A+) ve negatif ideal (A-) çözümleri belirlenir. İdeal çözüm değerleri belirlenirken V ağırlıklandırılmış matris değerlerinin en büyüğü alınır. Negatif çözüm değeri için ise V matrisinin en küçük değeri alınmaktadır. İdeal ve negatif ideal çözüm değerlerinin formülü Eşitlik 3 ve Eşitlik 4’teki gibi belirtilmiştir [8].

$$V_{ij} = \begin{bmatrix} w_1 r_{11} & w_2 r_{12} & \dots & w_n r_{1n} \\ w_1 r_{21} & w_2 r_{22} & \dots & w_n r_{2n} \\ \vdots & \vdots & \dots & \vdots \\ w_1 r_{m1} & w_2 r_{m2} & \dots & w_n r_{mn} \end{bmatrix} \quad (2)$$

$$A^+ = \left\{ \left(\max_i V_{ij} \mid j \in J \right), \left(\min_i V_{ij} \mid j \in J' \right) \right\} \quad (3)$$

$$A^- = \left\{ \left(\min_i V_{ij} \mid j \in J \right), \left(\max_i V_{ij} \mid j \in J' \right) \right\} \quad (4)$$

Yukarıdaki formüllerde J değeri fayda değerini gösterirken J' değeri ise kayıp değeri göstermektedir.

İdeal ve negatif ideal çözümler belirlendikten sonra alternatiflerin çözüm noktalarına uzaklığı belirlenmektedir. Bunun için Eşitlik 5 ve Eşitlik 6’da belirtildiği gibi sapma değerleri hesaplanmaktadır. Eşitlik 5, ideal sapma değerini veya gösterirken Eşitlik 6 negatif sapma değerini göstermektedir [7].

$$S_i^+ = \sqrt{\sum_{j=1}^n (V_{ij} - V_j^+)^2} \quad (5)$$

$$S_i^- = \sqrt{\sum_{j=1}^n (V_{ij} - V_j^-)^2} \quad (6)$$

Son olarak formüllerle elde edilen sapma değerlerine göre ideal çözüme yakınlık değeri hesaplanır. İdeal çözüme yakınlık Eşitlik 7'ye göre hesaplanır. Bu değer 0 ile 1 arasında bir değer olmaktadır. Değerin maksimum değer olan 1'e eşit olması durumunda mutlak ideal çözüm değerinde

olduğu, 0'a eşit bulunması durumunda mutlak negatif ideal çözüm değerinde olduğu anlamına gelmektedir.

$$C_i^+ = \frac{s_i^+}{s_i^- + s_i^+} \quad (7)$$

Çalışmada kullanılacak tüm firmalara ait alternatif tüm koltuk modelleri ve kriterlerin özeti Şekil 1'de belirtilmiştir.

		KRITERLER							
		Koltuk ağırlığı (K1)	Koltuk genişliği (K2)	Opsiyon Seçenekleri (K3)	Maliyet (K4)	Lojistik Avantaj (K5)	Teslimat Performansı (K6)	Üretim Kapasitesi (K7)	Ürün lade Oranı (K8)
A L T E R N A T İ F L E R	M3350NG (X1)	18 kg	430 mm	-2 ve 3 nokta emniyet kemeri -Sabit ve Hareketli Kolçak -Çanta Dayama -Plastik Arkalık -Koltuk sensör ped uyumu	₺ 18.585.000,00	Günlük sevkiyat	97%	Tesis, personel ve ekipman kapasitesi yeni projeye uygun	1,50%
	M3350 (X2)	28 kg	440 mm	-2 nokta emniyet kemeri, -Sabit Kolçak -Çanta Dayama -Plastik Arkalık	₺ 15.930.000,00	Günlük sevkiyat	97%	Tesis, personel ve ekipman kapasitesi yeni projeye uygun	1,50%
	M3320L (X3)	22 kg	430 mm	-2 ve 3 nokta emniyet kemeri -Sabit ve Hareketli Kolçak -Çanta Dayama -Plastik Arkalık	₺ 16.992.000,00	Günlük sevkiyat	97%	Tesis, personel ve ekipman kapasitesi yeni projeye uygun	1,50%
	Star30 (Y1)	17 kg	430 mm	-2 ve 3 nokta emniyet kemeri -Sabit ve Hareketli Kolçak -Çanta Dayama -Plastik Arkalık	₺ 16.107.000,00	Haftada 2 gün sevkiyat	95%	Tesis, personel ve ekipman kapasitesi	0,90%

Şekil 1. Model ve kriterlerin özeti

3. BULGULAR VE TARTIŞMA

3.1. Çalışmanın AHP ile Değerlendirilmesi

Analitik Hiyerarşi Prosesi çalışma metodolojisine göre çalışmada kullanılacak Tasarım, Tedarik ve Kalite olmak üzere 3 ana kriter ve bunların altında koltuk ağırlığı, koltuk genişliği, opsiyon seçenekleri, maliyet, lojistik performans, üretim kapasitesi ve ürün iade oranı olmak üzere 8 alt kriter belirlenmiştir. Bu kriterler seçilen 2 tedarikçiye ait

M3350NG, M3350, M3320L, Star30 ve Star40 olmak üzere 5 modelin seçiminde kullanılmıştır. AHP analizinde önce her bir kriter için modellerin değerlendirilmesi ve ağırlıklandırılmaları yapılmıştır. Kriter ve modellerin karşılaştırmalarında Çizelge 3'te paylaşılan önem dereceleri kullanılmıştır. Kriterlerin birbirlerine göre derecelendirme ve ağırlıklandırılmaları yapılmıştır. Belirlenen kriter ağırlıklandırılmalarına göre alternatif modellerin kriter değerlendirmeleri yapılarak optimum sonuç elde edilmiştir.

3.1.1 K1 Kriterine Göre Alternatiflerin Ağırlıklandırılması

Koltuk ağırlığı kriterine göre koltuk modellerinin birbirlerine göre önem dereceleri karşılaştırması sonucu elde edilen matris Çizelge 4'te belirtilmiştir.

Çizelge 4. K1 kriteri için alternatiflerin ağırlıkları

	X1	X2	X3	Y1	Y2	Satır ortalaması
X1	0,21	0,26	0,29	0,18	0,29	0,25
X2	0,03	0,04	0,02	0,06	0,02	0,03
X3	0,07	0,19	0,10	0,11	0,10	0,11
Y1	0,62	0,33	0,49	0,54	0,49	0,50
Y2	0,07	0,19	0,10	0,11	0,10	0,11

3.1.2. K2 Kriterine Göre Alternatiflerin Ağırlıklandırılması

Koltuk genişliği kriterine göre koltuk modellerinin birbirlerine göre önem dereceleri karşılaştırması sonucu elde edilen matris Çizelge 5'de belirtilmiştir.

Çizelge 5. K2 kriteri için alternatiflerin ağırlıkları

	X1	X2	X3	Y1	Y2	Satır ortalaması
X1	0,27	0,27	0,27	0,27	0,27	0,27
X2	0,09	0,09	0,09	0,09	0,09	0,09
X3	0,27	0,27	0,27	0,27	0,27	0,27
Y1	0,27	0,27	0,27	0,27	0,27	0,27

3.1.3. K3 Kriterine Göre Alternatiflerin Ağırlıklandırılması

Opsiyon seçenekleri kriterine göre koltuk modellerinin birbirlerine göre önem dereceleri karşılaştırması sonucu elde edilen matris Çizelge 6'da belirtilmiştir.

Çizelge 6. K3 kriteri için alternatiflerin ağırlıkları

	X1	X2	X3	Y1	Y2	Satır ortalaması
X1	0,31	0,26	0,32	0,31	0,31	0,30
X2	0,03	0,03	0,01	0,03	0,03	0,03
X3	0,04	0,20	0,05	0,04	0,04	0,08
Y1	0,31	0,26	0,32	0,31	0,31	0,30
Y2	0,31	0,26	0,32	0,31	0,31	0,30

3.1.4. K4 Kriterine Göre Alternatiflerin Ağırlıklandırılması

Maliyet kriterine göre koltuk modellerinin birbirlerine göre önem dereceleri karşılaştırması sonucu elde edilen matris Çizelge 7'de belirtilmiştir.

Çizelge 7. K4 kriteri için alternatiflerin ağırlıkları

	X1	X2	X3	Y1	Y2	Satır ortalaması
X1	0,04	0,04	0,03	0,04	0,04	0,04
X2	0,36	0,39	0,41	0,39	0,39	0,39
X3	0,20	0,13	0,14	0,13	0,22	0,16
Y1	0,36	0,39	0,41	0,39	0,30	0,37
Y2	0,04	0,04	0,03	0,06	0,04	0,04

3.1.5. K5 Kriterine Göre Alternatiflerin Ağırlıklandırılması

Lojistik avantaj kriterine göre koltuk modellerinin birbirlerine göre önem dereceleri karşılaştırması sonucu elde edilen matris Çizelge 8'de belirtilmiştir.

Çizelge 8. K5 kriteri için alternatiflerin ağırlıkları

	X1	X2	X3	Y1	Y2	Satır ortalaması
X1	0,25	0,25	0,25	0,25	0,25	0,25
X2	0,25	0,25	0,25	0,25	0,25	0,25
X3	0,25	0,25	0,25	0,25	0,25	0,25
Y1	0,13	0,13	0,13	0,13	0,13	0,13
Y2	0,13	0,13	0,13	0,13	0,13	0,13

3.1.6. K6 Kriterine Göre Alternatiflerin Ağırlıklandırılması

Teslimat performansı kriterine göre koltuk modellerinin birbirlerine göre önem dereceleri karşılaştırması sonucu elde edilen matris Çizelge 9'da belirtilmiştir.

Çizelge 9. K6 kriteri için alternatiflerin ağırlıkları

	X1	X2	X3	Y1	Y2	Satır ortalaması
X1	0,25	0,25	0,25	0,25	0,25	0,25
X2	0,25	0,25	0,25	0,25	0,25	0,25
X3	0,25	0,25	0,25	0,25	0,25	0,25
Y1	0,13	0,13	0,13	0,13	0,13	0,13
Y2	0,13	0,13	0,13	0,13	0,13	0,13

3.1.7. K7 Kriterine Göre Alternatiflerin Ağırlıklandırılması

Üretim kapasitesi kriterine göre koltuk modellerinin birbirlerine göre önem dereceleri karşılaştırması sonucu elde edilen matris Çizelge 10'da belirtilmiştir.

Çizelge 10. K7 kriteri için alternatiflerin ağırlıkları

	X1	X2	X3	Y1	Y2	Satır ortalaması
X1	0,20	0,20	0,20	0,20	0,20	0,20
X2	0,20	0,20	0,20	0,20	0,20	0,20
X3	0,20	0,20	0,20	0,20	0,20	0,20
Y1	0,20	0,20	0,20	0,20	0,20	0,20
Y2	0,20	0,20	0,20	0,20	0,20	0,20

3.1.8. K8 Kriterine Göre Alternatiflerin Ağırlıklandırılması

Ürün iade oranı kriterine göre koltuk modellerinin birbirlerine göre önem dereceleri karşılaştırması

Çizelge 12. Kriterlerin ağırlıkları

	K1	K2	K3	K4	K5	K6	K7	K8	Ortalama
K1	0,33	0,25	0,32	0,33	0,32	0,32	0,21	0,36	0,30
K2	0,04	0,03	0,02	0,04	0,02	0,02	0,05	0,02	0,03
K3	0,05	0,09	0,05	0,05	0,05	0,05	0,12	0,04	0,06
K4	0,33	0,25	0,32	0,33	0,32	0,32	0,21	0,36	0,30
K5	0,05	0,09	0,05	0,05	0,05	0,05	0,12	0,04	0,06
K6	0,05	0,09	0,05	0,05	0,05	0,05	0,12	0,04	0,06
K7	0,04	0,02	0,01	0,04	0,01	0,01	0,02	0,02	0,02
K8	0,11	0,18	0,16	0,11	0,16	0,16	0,16	0,12	0,15

Tüm kriterlere göre tüm koltuk modellerinin önem derecelendirmeleri ve ağırlıkları yapılmıştır. Koltuk

sonucu elde edilen matris Çizelge 11'de belirtilmiştir.

Çizelge 11. K8 kriteri için alternatiflerin ağırlıkları

	X1	X2	X3	Y1	Y2	Satır ortalaması
X1	0,11	0,11	0,11	0,11	0,11	0,11
X2	0,11	0,11	0,11	0,11	0,11	0,11
X3	0,11	0,11	0,11	0,11	0,11	0,11
Y1	0,33	0,33	0,33	0,33	0,33	0,33
Y2	0,33	0,33	0,33	0,33	0,33	0,33

3.1.9. Kriterlerin Ağırlıklandırılması ve Değerlendirme

Uzmanların değerlendirme ve ortak kararlarına istinaden belirlenen değerlendirme kriterlerinin önem dereceleri ve elde edilen ağırlıkları Çizelge 12'de belirtilmiştir.

Çizelge 13. Özet ağırlıklandırma

Alternatifler	Kriterler							
	K1	K2	K3	K4	K5	K6	K7	K8
X1	0,25	0,27	0,30	0,04	0,25	0,25	0,20	0,11
X2	0,03	0,09	0,03	0,39	0,25	0,25	0,20	0,11
X3	0,11	0,27	0,08	0,16	0,25	0,25	0,20	0,11
Y1	0,50	0,27	0,30	0,37	0,13	0,13	0,20	0,33
Y2	0,11	0,09	0,30	0,04	0,13	0,13	0,20	0,33

Her bir kriter ağırlığının ilgili modelin kriter ağırlığının ilgili modelin kriter ağırlığı ile çarpılması sonucu değerlendirme matrisi

oluşturulmuştur. AHP değerlendirme sonuçları Çizelge 14'te belirtildiği gibi bulunmuştur.

Çizelge 14. AHP sonuçları

	K1	K2	K3	K4	K5	K6	K7	K8	Toplam	%
X1	0,075	0,007	0,019	0,012	0,016	0,016	0,004	0,016	0,1675	16,75%
X2	0,010	0,002	0,001	0,118	0,016	0,016	0,004	0,016	0,1853	18,53%
X3	0,034	0,007	0,004	0,049	0,016	0,016	0,004	0,016	0,1491	14,91%
Y1	0,151	0,007	0,019	0,112	0,008	0,008	0,004	0,048	0,3602	36,02%
Y2	0,034	0,002	0,019	0,012	0,008	0,008	0,004	0,048	0,1379	13,79%

Belirlenen kriterler doğrultusunda Analitik Hiyerarşi Prosesi metoduna göre oluşturulan matrisler sonucunda Y1 firmasına ait Star30 modeli en ideal alternatif olarak belirlenmiştir (Çizelge 14).

3.2. Çalışmanın TOPSIS ile Değerlendirilmesi

Uzmanlar tarafından belirlenen ana kriterler ve bunlara bağlı alt kriterlere göre 5 farklı alternatif arasından seçim yapmak üzere bir diğer ÇKKV yöntemi olan TOPSIS yönteminden yararlanılmıştır.

3.2.1. Kriterlerin ve Alternatiflerin Ağırlıklandırılması

TOPSIS yöntemi ile değerlendirme sırasında bir önceki yöntem AHP’de elde edilen alternatif ve kriterlerin ağırlıklandırma ve önem derecelendirmeleri kullanılmıştır. Bir önceki metot AHP’de olduğu gibi tüm alternatiflerin kriterlere göre karşılaştırmaları ve ağırlıklandırılmaları yapılmıştır. Aynı şekilde kriterlerin de birbirlerine göre karşılaştırma ve değerlendirmelerine göre ağırlıklandırılmaları yapılmıştır. TOPSIS metodunda

Kriterlerin ağırlıkları (Çizelge 12) ve Özet Ağırlıklandırma (Çizelge 13) verileri kullanılmıştır.

3.2.2. TOPSIS Normalize ve Ağırlıklandırılmış Normalize Matrisin Oluşturulması

TOPSIS yöntemine göre çalışma yapılırken ilk adım olarak belirlenen alternatif değerlerinin kareleri alınarak bir matris elde edilir. Bu matriste elde edilen değerlere göre sütunların toplamı alınır ve bu sütun toplamının karekök değerleri alınarak normalizasyon değerleri aşağıdaki formülle belirlenmiş olur.

$$\sqrt{\sum_{i=1}^m a_{ij}^2} \quad (8)$$

Çizelge 13’teki özet ağırlıklandırma verileri elde edilen karekök değerlerine bölünerek normalize matris değerlerine ulaşılmıştır. Bu değerlerin de Çizelge 12’deki kriter ağırlıkları ile tek tek çarpılmasıyla Çizelge 15’te gösterildiği gibi ağırlıklandırılmış normalize matris değerleri elde edilmiştir.

Çizelge 15. Ağırlıklandırılmış normalize matrisi

Alternatifler/ kriterler	K1	K2	K3	K4	K5	K6	K7	K8
X1	0,1306	0,0162	0,0370	0,0214	0,0347	0,0347	0,0090	0,0319
X2	0,0176	0,0054	0,0034	0,2099	0,0347	0,0347	0,0090	0,0319
X3	0,0591	0,0162	0,0093	0,0881	0,0347	0,0347	0,0090	0,0319
Y1	0,2620	0,0162	0,0370	0,2005	0,0173	0,0173	0,0090	0,0958
Y2	0,0591	0,0054	0,0370	0,0227	0,0173	0,0173	0,0090	0,0958

3.2.3. TOPSIS Pozitif İdeal ve Negatif İdeal Çözüm Değerlerinin Bulunması

İdeal çözüm değerleri için her bir sütundaki en

yüksek değer, negatif çözüm değerleri için sütunlardaki en küçük değerler alınmıştır. Çizelge 16’da pozitif ve negatif ideal çözüm değerleri belirtilmiştir.

Çizelge 16. İdeal çözüm değerleri

	K1	K2	K3	K4	K5	K6	K7	K8
Pozitif ideal çözüm	0,2620	0,0162	0,0370	0,2099	0,0347	0,0347	0,0090	0,0958
Negatif ideal çözüm	0,0176	0,0054	0,0034	0,0214	0,0173	0,0173	0,0090	0,0319

3.2.4. Kriterlerin ve Alternatiflerin Ağırlıklandırılması

Ağırlıklandırılmış normalize matris değerlerinin pozitif ideal ve negatif ideal çözüm değerlerine olan farkın karesi alınır. Daha sonra elde edilen matristeki satırlar toplanır ve toplam değerlerin

karekökleri alınır. Böylece her bir değer için pozitif ideal ve negatif ideal çözüm değerine olan uzaklıkları elde edilir. Elde edilen pozitif ideal uzaklık değerleri Çizelge 17’de belirtilmiştir. Elde edilen negatif ideal uzaklık değerleri ise Çizelge 18’de belirtilmiştir.

Çizelge 17. Pozitif ideal çözüm değerlerine uzaklık verileri

Alternatifler/ kriterler	K1	K2	K3	K4	K5	K6	K7	K8
X1	0,0173	0,0000	0,0000	0,0355	0,0000	0,0000	0,0000	0,0041
X2	0,0598	0,0001	0,0011	0,0000	0,0000	0,0000	0,0000	0,0041
X3	0,0412	0,0000	0,0008	0,0148	0,0000	0,0000	0,0000	0,0041
Y1	0,0000	0,0000	0,0000	0,0001	0,0003	0,0003	0,0000	0,0000
Y2	0,0412	0,0001	0,0000	0,0350	0,0003	0,0003	0,0000	0,0000

Çizelge 18. Negatif ideal çözüm değerlerine uzaklık verileri

Alternatifler/ kriterler	K1	K2	K3	K4	K5	K6	K7	K8
X1	0,0128	0,0001	0,0011	0,0000	0,0003	0,0003	0,0000	0,0000
X2	0,0000	0,0000	0,0000	0,0355	0,0003	0,0003	0,0000	0,0000
X3	0,0017	0,0001	0,0000	0,0045	0,0003	0,0003	0,0000	0,0000
Y1	0,0597	0,0001	0,0011	0,0321	0,0000	0,0000	0,0000	0,0041
Y2	0,0017	0,0000	0,0011	0,0000	0,0000	0,0000	0,0000	0,0041

3.2.5. TOPSIS Sonuçları

İdeal ve negatif ideal uzaklık değerlerine uzaklıklar bulunduğundan sonra negatif ideal çözüm değerlerine uzaklıkların ideal ve negatif ideal çözüm değerlerine uzaklıklara oranlanması ile elde edilen sıralamaya göre optimum sonuç bulunmaktadır.

Elde edilen sonuçlar ve yüzdeler oranları Çizelge 19’deki gibi belirtilmiştir.

Yüzdeler sonuç çizelgesinde belirtildiği üzere %53,02 oranla Y tedarikçisine ait Y1 modeli ideal çözüme en yakın alternatif olarak belirlenmiştir.

Çizelge 19. TOPSIS Sonuçları

ALTERNATİF	S_i^+	S_i^-	C_i^+	Yüzde
X1	0,2385	0,1209	0,3365	19,34%
X2	0,2551	0,1901	0,4270	24,55%
X3	0,2467	0,0832	0,2522	14,50%
Y1	0,0263	0,3117	0,9222	53,02%
Y2	0,2774	0,0833	0,2309	13,27%

4. SONUÇLAR

Bir işletmenin başarısı doğru kaynak ve yatırımların, doğru proje ve işletme yönetimi ile doğru pazara, doğru ve ihtiyaca yönelik ürün ve hizmet sunulması ile sağlanabilir. Bu nedenle çalışmanın yapıldığı otobüs üreticisi firmanın yeni otobüs çalışmalarının önemi ve ne kadar titizlikle çalışılması gerektiği bir kez daha anlaşılmıştır. Bu da yapılan çalışmanın hem ekonomiye hem de topluma sunacağı faydaları göz önüne çıkartmaktadır [9].

Bu çalışmada yeni okul otobüsünde kullanılmak üzere seçilecek yolcu koltuk modellerine karar verilmesi incelenmiştir. Çalışma kapsamında koltuk modelini seçebilmek için ilgili departmanların uzmanlarından oluşan karar vericiler tarafından 8 kriter belirlenmiştir. Yeni otobüs tasarımında yolcu koltuklarının seçimi için belirlenen 8 kriter çerçevesinde 2 farklı koltuk tedarikçisine ait toplam 5 koltuk modeli alternatifinin değerlendirilmesi incelenmiştir.

ÇKKV yöntemlerinden AHP ve TOPSIS yöntemlerinden faydalanılan çalışmada yapılan değerlendirmelere göre Y koltuk tedarikçisine ait Star30 koltuk modelinin yeni otobüs için en uygun model alternatifi olduğuna karar verilmiştir.

5. KAYNAKLAR

1. Pamuk, K. Ç., 2015. Yeni Ürün Geliştirme Sürecinde Tedarik Zinciri Tasarımı ve Bütünleşik AHP ve ORESTE Yöntemi ile Tedarikçi Seçimi. Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, Kocaeli.
2. Doğan, A., 2006. Tedarik Zincirinde Stok Yönetimi. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
3. Işık, E., 2019. Depo Yerleşimi Problemi için Çok Kriterli Karar Verme Yaklaşımları: Bir Otomotiv İşletmesi Uygulaması. Yüksek Lisans Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, Adana.
4. Supçiler, A.A., Çapraz, O., 2011. AHP-TOPSIS Yöntemine Dayalı Tedarikçi Seçimi Uygulaması. İstanbul Üniversitesi İktisat Fakültesi Ekonometri ve İstatistik Dergisi, 13(1), 22.
5. Dağdeviren, M., Akay, D., Kurt, M., 2004. İş Değerlendirme Sürecinde Analitik Hiyerarşi Prosesi ve Uygulaması. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 19, 131-138.
6. Büyükkız, Ş., 2019. Türkiye’de Yenilenebilir Enerji Kaynaklarının AHP ve Bulanık TOPSIS Yöntemleri ile Değerlendirilmesi. Yüksek Lisans Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, Adana.
7. Çelik, C., Alkan, A., Aladağ, Z., 2016. Otomotiv Sektöründe Faaliyet Gösteren Bir Firmada Tedarikçi Seçimi: AHP-Bulanık AHP ve TOPSIS Uygulaması. Beykent Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 9, 43-83.
8. Garagozi, F., 2016. Tedarikçi Seçiminde Analitik Hiyerarşi Prosesi ve TOPSIS Karar Modellerinin Kullanımı ve Bir Uygulama. Yüksek Lisans Tezi, Gazi Üniversitesi Sosyal Bilimler Enstitüsü, Ankara.
9. Güneş, H., 2019. Otomotiv Sektöründe Yeşil Tedarikçi Seçimi İçin Yeni Bir Çok Kriterli Karar Verme Yaklaşımı. Yüksek Lisans Tezi, Atatürk Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, Erzurum.

Toprak Mikrobiyoloji Laboratuvarlarında Güvenlik Önlemlerine göre Tehlikelerin Sıralanması

Melek IŞIK*¹ ORCID 0000-0001-6078-7026

¹Çukurova Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Adana

Geliş tarihi: 13.03.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: IŞIK, M., (2024). Toprak Mikrobiyoloji Laboratuvarlarında Güvenlik Önlemlerine göre Tehlikelerin Sıralanması. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 385-390.

Öz

Laboratuvar faaliyetleri gerçekleştiren kurum ve kuruluşlarda güvenlik önlemleri önemli hale gelmektedir. Güvenlik önlemleri için fiziksel, kimyasal ve biyolojik tehlikelerin sıralanması tedbirler açısından önemlidir. Bu çalışmada, toprak mikrobiyoloji laboratuvarı için güvenlik önlemlerinin Analitik Hiyerarşi Prosesi (AHP) yöntemiyle ağırlıklandırılması yapılmıştır. Güvenlik önlemleri biyogüvenlik kabini, çıkışa yakın el yıkama için lavabo, otoklav, laboratuvar güvenlik personeli, kendiliğinden kapanan kapı ve korumalı penceredir. Sonrasında, bu güvenlik önlemleri için fiziksel, kimyasal ve biyolojik tehlikeler Gerçekliği Yansıtan Eleme ve Seçim (ELECTRE-Elimination and Choice Translating Reality) yöntemiyle sıralanmıştır. Sonuç olarak, fiziksel tehlikelerin en çok dikkat edilmesi gerektiği sonucuna ulaşılmıştır.

Anahtar Kelimeler: Toprak mikrobiyoloji laboratuvarı, Analitik hiyerarşi prosesi (AHP), Gerçekliği yansıtan eleme ve seçim (ELECTRE)

Ranking of Hazards According to Safety Precautions in Soil Microbiology Laboratories

Abstract

Security measures are becoming important in institutions and organizations that carry out laboratory activities. Listing physical, chemical and biological hazards is important for safety precautions. In this study, safety measures for the soil microbiology laboratory were weighted using the Analytical Hierarchy Process (AHP) method. Safety measures include a biosafety cabinet, a sink for hand washing near the exit, an autoclave, laboratory security personnel, a self-closing door and a protected window. Afterwards, physical, chemical and biological hazards for these security measures were listed using the Elimination and Choice Translating Reality (ELECTRE) method. As a result, it was concluded that physical hazards should be paid the most attention.

Keywords: Soil microbiology laboratory, Analytical hierarchy process (AHP), Elimination and choice translating reality (ELECTRE)

*Sorumlu yazar (Corresponding Author): Melek IŞIK, demirtasm@cu.edu.tr

1. GİRİŞ

Günlük hayatta pek çok tehlike ile karşı karşıya kalınmaktadır. Bazı tehlikeler hafif şiddette önlenebilir bazıları ise önlenemese de hafifletilebilir tehlikelerdir. Tehlikelerin sonucunda güvenlik önlemleri alınmadığında maddi veya manevi hasarlar olmaktadır. Kurallar koyularak tehlikelerden korunmak ve önlemler almak gerekmektedir. Kurallara uymak ve tehlikeleri yönetebilmek laboratuvar faaliyetleri için önemli hale gelmektedir.

Analiz hizmeti veren bir laboratuvarın doğru ve güvenilir sonuç elde etmesi yanında laboratuvar çalışmasının ve çevrenin güvenliğinin sağlanması gerekmektedir. Özellikle, toprak mikrobiyoloji laboratuvarında standartları ortaya koyan ve yeni standartların geliştirilmesi için gelecekte gerçekleştirilecek olası araştırma çabalarına ışık tutulmaktadır [1]. Tıbbi mikrobiyoloji laboratuvarları ise hastalık riski yaratabilecek önemli bir çalışma çevresi olmaktadır [2]. Günay ve arkadaşları [3], ergonomik farkındalığı sağlamak için mikrobiyoloji laboratuvarı personeline yönelik çalışma sırasında ortaya çıkan sorunları belirleyip en aza indirmek için önerilerde bulunmuşlardır. Pipetle çalışma, mikroskop ile çalışma ve biyogüvenlik kabin ile ilgili sorular yöneltilmiş mikrobiyoloji laboratuvarlarında esas olan, sorunlar ve nedenleri ile ilgili değerlendirmelerde bulunulmuştur. Şahin ve arkadaşları [4], yapay zeka çalışma prensip ve yöntemleri gözden geçirilerek klinik mikrobiyoloji ve antibiyotik direncinin işlenmesi konusunu irdeleyen klinik çalışmalar incelenmiştir.

Karar sürecini kriterlere göre modelleme ve karar vericinin süreç sonunda elde edeceği faydayı analiz etme sürecine dayanan çok kriterli karar verme teknikleri mevcuttur. Analitik Hiyerarşi Prosesi (AHP) ve ELECTRE bu yöntemler içerisinde popülerdir. Kaya ve Kahraman [5], çevresel etki kentsel endüstriyel planlama bağlamında entegre bulanık AHP-ELECTRE yaklaşımına dayanan bir çevresel etki değerlendirme metodolojisi önermektedir. Önerdikleri metodolojide kriter ağırlıkları bulanık bir AHP prosedürü ile üretilmektedir. Alternatifleri en riskliden en az

riskliye doğru sıralamak için bulanık baskınlık ilişkisi metodolojisi kullanmışlardır. Aziz ve arkadaşları [6], Loukkos havzasının sınıflandırılmış uydu görüntülerini çıkarmışlar, bu uydu görüntülerinin sınıflandırılması, yığılma, barajlar, su yolları, ekili alanlar, çıplaklık gibi veri setinin çeşitli sınıflarını yeniden gruplandırmışlardır. Bu çalışmanın temel amacı, on alternatifin dikkate alındığı ELECTRE TRI aracını kullanarak çevresel göstergeleri sıralamaktır. Altıntaş [7], küresel yeşil büyüme endeksi boyutlarına ait değerler için dünya ekonomisinin büyük çoğunluğuna hâkim olan G7 ülkelerinin en son ve güncel olan 2019 yılı yeşil büyüme performanslarını Entropi tabanlı ELECTRE yöntemi ile ölçmüştür. Küresel yeşil büyüme endeksi boyutlarının önemlilik dereceleri ölçülmüş ve bu derecelere göre yeşil ekonomik fırsatlar, sosyal içerik, doğal sermayenin korunumu ve sürdürülebilir enerji kullanımı olarak sıralanmıştır.

Laboratuvar güvenliğinin temel ilkelerini güvenlik faaliyetleri oluşturmaktadır. Genel olarak, laboratuvarında her personel, kendisine verilen görevleri yerine getirmek ve prosedürü izlemek için rol ve uzmanlıklarına göre mümkün olan her şeyi yapmakla yükümlüdür. Bu çalışmada, toprak mikrobiyoloji laboratuvarı için güvenlik önlemlerinin AHP yöntemiyle ağırlıklandırılması biyogüvenlik kabini, çıkışa yakın el yıkama için lavabo, otoklav, laboratuvar güvenlik personeli, kendiliğinden kapanan kapı ve korumalı pencere olmak üzere incelenmiştir. Güvenlik önlemleri için fiziksel, kimyasal ve biyolojik tehlikeler ELECTRE yöntemiyle sıralanmıştır.

2. YÖNTEM

Bu çalışmada, toprak mikrobiyoloji laboratuvarı için güvenlik önlemleri AHP yöntemiyle ağırlıklandırılmış tehlikeler ise ELECTRE yöntemiyle sıralanmıştır. AHP, orijinal olarak Thomas L. Saaty tarafından geliştirilen çok kriterli karar verme yöntemlerinden biridir [8]. AHP uygulamasının adımları aşağıdaki gibidir;

- Karar verme problemi tanımlanır.
- Faktörler arası karşılaştırma matrisi oluşturulur.

- Faktörlerin yüzde önem dağılımları belirlenir.
- Faktör kıyaslamalarındaki tutarlılık ölçülür.
- Her bir faktör için karar noktasındaki yüzde önem dağılımları bulunur.

ELECTRE yöntemi ilk olarak 1966 yılında Benayoun ve ark. [9] tarafından kullanılmıştır. Aşağıda, ELECTRE yönteminin adımları yer almaktadır [10].

- Karar matrisi oluşturulur.
- Standart karar matrisi Eşitlik (1) kullanılarak hesaplanır. Örneğin, Y matrisinin y₁₁ elemanını hesaplamak için, B matrisinin b₁₁ elemanı, matrisin bir sütun elemanlarının karelerinin toplamının kareköküne bölünerek elde edilir.

$$y_{ij} = \frac{b_{ij}}{\sqrt{\sum_{k=1}^r b_{kj}^2}} \quad (1)$$

- Ağırlıklı standart karar matrisi, standart karar matrisinin her bir sütunundaki elemanlara karşılık gelen ağırlık değerlerinin çarpılmasıyla oluşturulur. AHP yöntemi bu ağırlıklar için en popüler olanıdır.
- Kümelerin uyum ve uyumsuzluk değerleri belirlenir. Değerlendirme faktörü için karar noktaları bir diğeri ile karşılaştırılır.
- Uyum ve uyumsuzluk matrisi hesaplanır.

Uyum indeksi (m_{kl}) uyum kümesinde yer alan kriterlerle ilişkili ağırlıkların toplamıdır.

Uyumsuzluk matrisi endeksi (n_{kl}) Eşitlik (2)'de tanımlanmıştır.

$$n_{kl} = \frac{\max_{j \in N_{kl}} |z_{kj} - z_{lj}|}{\max_j |z_{kj} - z_{lj}|} \quad (2)$$

- Uyum ve uyumsuzluk üstünlük matrislerinin boyutu r*c'dir. Uyum eşik değeri Eşitlik (3) ve uyumsuzluk eşik değeri Eşitlik (4) ile elde edilir.

$$\underline{m} = \frac{1}{r(r-1)} \sum_{k=1}^r \sum_{l=1}^r m_{kl} \quad (3)$$

$$\underline{n} = \frac{1}{r(r-1)} \sum_{k=1}^r \sum_{l=1}^r n_{kl} \quad (4)$$

- Baskınlık matrisi, uyum ve uyumsuzluk matrisleri eşik değerinden daha fazla veya daha az olmasına bağlı olarak 1 veya 0 değerlerine göre oluşturulur.
- Karar noktalarının önem sırası belirlenir.

3. ARAŞTIRMA BULGULARI

Toprak mikrobiyoloji laboratuvarlarında kurallara uyulması önemlidir. Bu çalışmada güvenlik önlemleri, biyogüvenlik kabini, çıkışa yakın el yıkama için lavabo, otoklav, laboratuvar güvenlik personeli, kendiliğinden kapanan kapı ve korumalı pencere olarak belirlenmiştir [11]. Biyogüvenlik uygulamalarında, laboratuvara giriş-çıkış sınırlamasına uyulması önemlidir. Laboratuvar da elleri dezenfekte amacıyla el yıkama lavabosu yer almalıdır. Otoklav ile basınç yardımıyla arındırma işlemi yapılmalıdır. Laboratuvar güvenlik personeli süreci takip etmelidir. Laboratuvar ana girişinden otomatik kapılar bulunmalıdır ve temiz alan ile kirli alan sınırlandırılmalıdır. Ayrıca, tedbir amaçlı korumalı pencere olmalıdır.

Güvenlik önlemleri belirlendikten sonra hangi tehlikelerin neden olduğu incelenmiştir. Fiziksel tehlikeler, elektrik, yangın, düşme – kayma ve gürültü olarak düşünülmektedir. Mikrobiyoloji laboratuvarlarında bazı maddeler içerisinde kimyasal tehlikeler içermektedirler. Biyolojik tehlikeler, numunelerin analiz çalışmaları sırasında tüplerin açılması veya kesici delici alet kullanılması durumları biyolojik risklere neden olmaktadır (Şekil 1).



Şekil 1. Laboratuvar tehlike ve önlemleri

Çizelge 1’de, toprak mikrobiyoloji laboratuvarı için güvenlik önlemlerinin ağırlık değerleri gösterilmiştir. AHP yöntemi kullanılarak beyin fırtınası tekniği ile puanlar belirlenmiştir ve ikili karşılaştırma matrisi oluşturulmuştur. Laboratuvarlarda deneyimli uzmanlar tarafından skorlar verilmiştir. Ağırlıklar sırayla, biyogüvenlik kabini 0,49, çıkışa yakın el yıkama için lavabo 0,22, otoklav 0,15, laboratuvar güvenlik personeli 0,07, kendiliğinden kapanan kapı 0,05 ve korumalı

pencere için 0,03 olarak belirlenmiştir. Bu sonuçlara göre, biyogüvenlik kabini en önemli güvenli önlem olarak karşımıza çıkarken korumalı pencere en düşük önlem olarak sonuçlanmıştır. Tutarlılık indeksi 0,08 değeri ile 0,1’den küçük olduğu için değerler tutarlı sonucuna varılmıştır.

Çizelge 1. Güvenlik önlemlerinin ağırlık değerleri

Güvenlik Önlemleri	Ağırlık
Biyogüvenlik kabini	0,49
Çıkışa yakın el yıkama için lavabo	0,22
Otoklav	0,15
Laboratuvar güvenlik personeli	0,07
Kendiliğinden kapanan kapı	0,05
Korumalı pencere	0,03

ELECTRE yöntemini uygulayabilmek için Çizelge 2’de karar matrisi oluşturulur. Fiziksel, kimyasal ve biyolojik tehlikelere karşı alınacak önlemler için skorlar belirlenmiştir. Değerler, Eşitlik (1) formülüne göre hesaplanarak standart karar matrisi elde edilmiştir (Çizelge 3). Ağırlıklı standart karar matrisi, standart karar matrisinin her bir sütunundaki elemanlara karşılık gelen ağırlık değerlerinin çarpılmasıyla Çizelge 4 oluşturulmuştur.

Çizelge 2. Karar matrisi

Ağırlık	0,49	0,22	0,15	0,07	0,05	0,03
Önlemler/tehlikeler	Biyogüvenlik kabini	Çıkışa yakın el yıkama için lavabo	Otoklav	Laboratuvar güvenlik personeli	Kendiliğinden kapanan kapı	Korumalı pencere
Fiziksel	3	9	7	9	8	9
Kimyasal	9	8	6	7	9	7
Biyolojik	8	7	8	5	6	8

Çizelge 3. Standart karar matrisi

Önlemler/tehlikeler	Biyogüvenlik kabini	Çıkışa yakın el yıkama için lavabo	Otoklav	Laboratuvar güvenlik personeli	Kendiliğinden kapanan kapı	Korumalı pencere
Fiziksel	0,24	0,65	0,57	0,72	0,59	0,65
Kimyasal	0,73	0,57	0,49	0,56	0,67	0,50
Biyolojik	0,64	0,50	0,66	0,40	0,45	0,57

Çizelge 4. Ağırlıklı standart karar matrisi

Ağırlık	0,49	0,22	0,15	0,07	0,05	0,03
Önlemler/tehlikeler	Biyogüvenlik kabini	Çıkışa yakın el yıkama için lavabo	Otoklav	Laboratuvar güvenlik personeli	Kendiliğinden kapanan kapı	Korumalı pencere
Fiziksel	0,12	0,14	0,09	0,05	0,03	0,02
Kimyasal	0,36	0,13	0,07	0,04	0,03	0,02
Biyolojik	0,32	0,11	0,10	0,03	0,02	0,02

Değerlendirme faktörü için karar noktaları bir diğeri ile karşılaştırılması ile Çizelge 5’de gösterilmiştir. Uyum ve uyumsuzluk kümesi satırların her bir kriter için değerlendirilmesiyle bulunmaktadır. Uyum kümesinde olan değerlerin dışında kalanlar uyumsuzluk kümesi elemanı içerisinde yer almaktadır.

Çizelge 5. Değerlerin karşılaştırılması

Uyum kümesi		Uyumsuzluk kümesi	
c12	2,3,4,5,6	d12	1
c13	2,4,5,6	d13	1,3
e21	1,5,6	d21	2,3,4
e23	1,2,4,5,6	d23	3
c31	1,3,6	d31	2,4,5
c32	3,6	d32	1,2,4,5

Çizelge 6’da oluşturulan uyum kümelerinden seçilen kriterlerin AHP ağırlıkları toplanarak oluşturulmuştur. Sırayla, fiziksel tehlikelerin, 0,52 ve 0,37, kimyasal tehlikeler için, 0,57 ve 0,86 ve son olarak biyolojik tehlikede 0,67 ve 0,18 çıkmıştır.

Çizelge 6. Uyum matrisi

Tehlikeler	Fiziksel	Kimyasal	Biyolojik
Fiziksel	-	0,52	0,37
Kimyasal	0,57	-	0,86
Biyolojik	0,67	0,18	-

Uyumsuzluk matrisi, uyumsuzluk kümesi içinden Eşitlik (2) ile oluşturulmuştur. Fiziksel tehlikelerin, 1, kimyasal tehlikeler için, 0,08 ve 0,75 ve son olarak biyolojik tehlikede 0,15 ve 1 bulunmuştur (Çizelge 7).

Çizelge 7. Uyumsuzluk matrisi

Tehlikeler	Fiziksel	Kimyasal	Biyolojik
Fiziksel	-	1	1
Kimyasal	0,08	-	0,75
Biyolojik	0,15	1	-

Eşitlik (3) ve Eşitlik (4) ile hesaplanan uyum üstünlük değeri 0,52 ve uyumsuzluk üstünlük değeri 0,66 çıkmıştır. Çizelge 6’da gösterilen uyum matrisinde 0,52 değerine büyük veya eşit değerler Çizelge 8’de 1 olarak, küçük olan değerler de 0 olarak belirtilmiştir.

Çizelge 8. Uyum üstünlük matrisi

Tehlikeler	Fiziksel	Kimyasal	Biyolojik
Fiziksel	-	1	0
Kimyasal	1	-	1
Biyolojik	1	0	-

Çizelge 7’de gösterilen uyumsuzluk matrisinde 0,66 değerine büyük veya eşit değerler Çizelge 9’da 1 olarak, küçük olan değerler de 0 olarak belirtilmiştir.

Çizelge 9. Uyumsuzluk üstünlük matrisi

Tehlikeler	Fiziksel	Kimyasal	Biyolojik
Fiziksel	-	1	1
Kimyasal	0	-	1
Biyolojik	0	1	-

Çizelge 8 ve Çizelge 9’daki hücrelere karşılık gelen sayılar ile çarpılarak toplam baskınlık matrisi elde edilir (Çizelge 10).

Çizelge 10. Toplam baskınlık matrisi

Tehlikeler	Fiziksel	Kimyasal	Biyolojik
Fiziksel	-	1	0
Kimyasal	0	-	1
Biyolojik	0	0	-

Çizelge 10’ da verilen toplam baskınlık matrisinde fiziksel tehlikelerin kimyasal tehlikelere göre 1 değerini alarak daha üstün olduğu görülmektedir. Kimyasal tehlikelerin biyolojik tehlikelere göre 1 değerini alarak daha üstün olduğu görülmüştür.

Sonuç olarak, güvenlik önlemleri için fiziksel>kimyasal>biyolojik tehlikeler olarak sıralanmıştır.

4. SONUÇLAR

Toprak mikrobiyoloji laboratuvarı için tehlikeler ve bu tehlikelere karşı alınması gerek güvenlik önlemleri büyük önem arz etmektedir. Bu çalışmada, güvenlik önlemlerinin AHP yöntemiyle ağırlıklandırılması yapılmıştır. Biyogüvenlik kabini 0,49, çıkışa yakın el yıkama için lavabo 0,22, otoklav 0,15, laboratuvar güvenlik personeli 0,07, kendiliğinden kapanan kapı 0,05 ve korumalı pencere için 0,03 olarak belirlenmiştir. Bu güvenlik önlemleri için fiziksel, kimyasal ve biyolojik tehlikeler ELECTRE yöntemiyle sıralanmıştır. Güvenlik önlemleri için fiziksel>kimyasal>biyolojik tehlikeler olarak sırasıyla sonuç elde edilmiştir. Fiziksel tehlikelerin öncelikli dikkat edilmesi gerektiği belirlenmiştir.

5. KAYNAKLAR

1. Philippot, L., Ritz, K., Pandard, P., Hallin, S., Martin-Laurent, F., 2012. Standardisation of Methods in Soil Microbiology: Progress and Challenges. *FEMS Microbiology Ecology*, 82(1), 1-10.
2. Şeker, E., Yardımcı, H., 2003. Mikrobiyoloji Laboratuvarlarında Biyogüvenlik. *Orlab On-Line Mikrobiyoloji Dergisi*, 1(04), 3-32.
3. Günay, İ.C., Alayunt, F.N., Çakmak, B., 2017. Mikrobiyoloji Laboratuvarlarında Ergonomi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 5, 41-47.
4. Şahin, A.R., Selma, A., Günay, M., 2019. Klinik Mikrobiyoloji Laboratuvarlarında Yapay Zekanın Temel İşleyiş Modelleri. *Journal of Biotechnology and Strategic Health Research*, 3(2), 66-71.
5. Kaya, T., Kahraman, C., 2011. An Integrated Fuzzy AHP-ELECTRE Methodology For Environmental Impact Assessment. *Expert Systems with Applications*, 38(7), 8553-8562.
6. Aziz, L., Achki, S., Chalh, R., 2021. The Classification of the Environmental Indicators using ELECTRE TRI Method for Loukkos

Basin in Morocco. *Journal of Physics: Conference Series*, IOP Publishing.

7. Altıntaş, F.F., 2022. G7 Ülkelerinin Yeşil Büyüme Performanslarının Analizi: Entropi Tabanlı Electre Yöntemi ile Bir Uygulama. *Atlas Journal*, 8(46), 2502-2519.
8. Saaty, T.L., 1977. A Scaling Method for Priorities in Hierarchical Structures. *Journal of Mathematical Psychology*, 15(3), 234-281.
9. Benayoun, R., Roy, B., Sussman, B., 1966. Une Méthode Pour Guider le Choix Enprésence de Points Devue Multiples. *Notedetravail49*, Sema-Metra Direction-Scientifique.
10. Triantaphyllou, E., 2000. *Multi-Criteria Decision Making Methods*, Springer.
11. Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü, 2009. *Laboratuvar Güvenliği El Kitabı*, Ankara.

Kar Erime Optimizasyonu Algoritması ile Çok Katmanlı Yapay Sinir Ağının Eğitimi

Feyza Nur ÖZDEMİR¹ ORCID 0000-0001-7803-7725
Ahmet ÖZKİŞ^{*2} ORCID 0000-0002-1899-5494

¹Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Konya

²Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya

Geliş tarihi: 25.01.2024 Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ÖZDEMİR, F.N., ÖZKİŞ, A., (2024). Kar Erime Optimizasyonu Algoritması ile Çok Katmanlı Yapay Sinir Ağının Eğitimi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 391-406.

Öz

Kar erime optimizasyonu (snow ablation optimizer, SAO) algoritması, karın erimesinden ilham alınarak 2023 yılında önerilen yeni bir metasezgisel algoritmadır. Bu çalışmada, yapay sinir ağının ağırlıklarının güncellenmesi amacıyla SAO algoritması ile hibrit bir model geliştirilmiştir. Geliştirilen hibrit model aggregation, balance, liver, pathbased ve wine adlı beş farklı veri seti üzerinde gri kurt, sürüngen arama, guguk kuşu ve sinüs kosinüs algoritmaları ile oluşturulan hibrit modeller ile karşılaştırılmıştır. Modellerin başarısını ölçmek için duyarlılık, özgüllük, kesinlik ve f1-puanı adı verilen dört farklı metrik kullanılmıştır. Modellerin her veri seti için başarı sıralaması ve tüm veri setleri için ortalama başarı sıralaması verilmiştir. Sonuçlar incelendiğinde, SAO modelinin tüm metrikler için wine veri setinde 2., diğer tüm veri setlerinde 1. olduğu görülmektedir. Ortalama başarı sırası açısından ise SAO modeli tüm metriklerde 1.2 değeri ile en iyi sonucu elde etmiştir. Ayrıca hibrit modellerin, eğitim aşamasındaki ortalama karesel hata değerlerinin yakınsama grafikleri çizdirilmiş ve SAO hibrit modelinin wine hariç diğer tüm veri setlerinde karşılaştırılan modellerden daha hızlı bir yakınsama performansına sahip olduğu gözlenmiştir. Son olarak popülasyondaki parçacık sayısının hibrit SAO modelinin başarısına etkisi analiz edilmiş ve birey sayısının 100 olması durumunda başarının arttığı gözlenmiştir.

Anahtar Kelimeler: Kar erime optimizasyonu algoritması, Yapay sinir ağları, Makine öğrenmesi, Danışmanlı öğrenme, Sınıflandırma

Training of Multilayer Artificial Neural Network with Snow Ablation Optimizer Algorithm

Abstract

The snow ablation optimizer (SAO) is a new metaheuristic algorithm proposed in 2023, inspired by snow melting. In this study, a hybrid model was developed with the SAO algorithm to update the artificial neural

*Sorumlu yazar (Corresponding Author): Ahmet ÖZKİŞ, aozkis@erbakan.edu.tr

network weights. The developed hybrid model was compared with hybrid models created with gray wolf, reptile search, cuckoo and sine cosine algorithms on five different data sets named aggregation, balance, liver, pathbased and wine. Four different metrics called sensitivity, specificity, precision and f1-score were used to measure the success of the models. The success ranking of the models for each data set and the average success ranking for all data sets are given. When the results are examined, it is seen that the SAO model ranks 2nd in the wine data set and 1st in all other data sets for all metrics. Regarding average success rank, the SAO model achieved the best result with a value of 1.2 in all metrics. In addition, convergence graphs of the mean square error values of the hybrid models in the training phase were drawn and it was observed that the SAO hybrid model had a faster convergence performance than the compared models in all other data sets except Wine. Finally, the effect of the number of particles in the population on the success of the hybrid SAO model was analyzed and it was observed that the success increased when the number of individuals was 100.

Keywords: Snow ablation optimizer algorithm, Artificial neural networks, Machine learning, Supervised learning, Classification

1. GİRİŞ

İnsanlık var olduğundan beri çok çeşitli problemlerle karşı karşıya kalmıştır. Yakın geçmişimize kadar bu problemlerin çözümü için sadece kendi akıl ve zekasını kullanabilen insanoğlu, dijitalleşme ile adeta çağ atlayarak çoğu problemin çözümünde bilgisayarları kullanmaya başlamıştır. Teknolojinin ilerlemesiyle beraber depolanabilen veri miktarının da çok hızlı bir şekilde artması, Turing [1] başta olmak üzere bilim insanlarına şu soruyu sordurmuştur: “İnsanın yapabildiği bazı görevler makinelerle öğretilbilir mi?” Bu soru, günümüzdeki yapay zekâ kavramına giden yolu açmıştır. Yapay zekâ, insan ve hayvan gibi biyolojik canlılardaki karar verme, tahmin etme ve çözüm bulma kabiliyetlerinin makinelerle öğretilmesidir [2]. Bu amacı gerçekleştirmek için bilim insanları çeşitli çalışmalar yapmıştır. Rosenblatt [3] tarafından geliştirilen basit algılayıcı modeli yapay zekâ alanının öncü çalışmalarından biri olmuştur. Rumelhart ve arkadaşları [4] ise perceptron modelinin doğrusal olmayan problemleri çözmesini sağlayarak yapay sinir ağları (YSA) algoritmasının geliştirilmesine katkı sunmuştur. YSA algoritması günümüzde görüntü işleme [5-7], zaman serisi tahmini [8-10], regresyon analizi [11-14], sınıflandırma [15-17] ve kümeleme [18-20] gibi pek çok gerçek dünya probleminin çözümünde başarıyla uygulanmaktadır.

YSA mimarisi, nöron denilen yapılardan oluşur. Nöronlar ile girdi, ara ve çıktı katmanları

oluşturulur. YSA mimarisi üzerinde hesap edilen hata değerlerinin girdi katmanından çıktı katmanına doğru aktarılmasına *ileri yayılım* denir. İleri yayılım sonucunda hesaplanan hatanın azaltılması için nöronlardaki *ağırlık* adı verilen sayısal değerlerin güncellenmesi işlemine ise *geri yayılım* denilmektedir. YSA modelinde, geri yayılım esnasında ağırlıkların güncellenmesi için genellikle türev tabanlı teknikler kullanılmaktadır [21]. Ancak türev tabanlı teknikler zorlayıcı problemlerle karşılaştıklarında ağırlık değerlerinin başarıyla güncellenmesi mümkün olamamakta ve ağırlık değerleri yerel minimum noktalara takılabilmektedir [2]. Bu sorunun üstesinden gelmek için, araştırmacılar pek çok çalışmada [21-24] ağırlık geri yayılımı aşamasında metasezgisel algoritmalar kullanmışlardır.

Metasezgisel yaklaşımlar, canlıların besin arama ve hayatta kalma davranışlarından ilham alınarak bilim insanları tarafından geliştirilen doğa esinli algoritmalarlardır. Bu algoritmalar hızlı, esnek ve kolay uygulanabilir yapılarından dolayı sayısal optimizasyon [25], kapasitesiz tesis yerleştirme [26, 27], rüzgâr türbini yerleştirme [28], knapsack [29] ve YSA'nın eğitilmesi [30] gibi birçok gerçek dünya probleminin çözümünde başarı ile uygulanabilmektedir. Günümüze kadar çok sayıda metasezgisel algoritma geliştirilmiş olsa da No Free Lunch (NFL) [31] teoremindeki, hiçbir algoritma tüm problem türlerinde en başarılı sonuca ulaşmayı garanti edemez düşüncesinden hareketle halen yeni algoritmalar önerilmektedir. Deng ve arkadaşları

[25] tarafından önerilen kar erime optimizasyonu (snow ablation optimizer, SAO) algoritması da NFL teoreminden hareketle önerilen yeni bir metasezgisel algoritmadır. Bu çalışmada, YSA'nın geri yayılımında ağırlıkların yerel minimuma takılma sorununu ortadan kaldırmak için SAO algoritması tabanlı hibrit bir yöntem geliştirilmiştir. Yöntemin performans testi için aşağıdaki adımlar uygulanmıştır:

- Geliştirilen hibrit model literatürde iyi bilinen aggregation, balance, liver, pathbased ve wine sınıflandırma veri setleri üzerinde çalıştırılmıştır.
- Eğitim ve test aşamalarında elde edilen sonuçlar için sensitivity, specificity, precision ve f1-score metrikleri hesaplanmıştır.
- Geliştirilen modelin metrik sonuçları, guguk kuşu arama (cuckoo search, CS) algoritması, gri kurt optimizasyonu (grey wolf optimizer, GWO), sürüngen arama algoritması (reptile search algorithm, RSA) ve sinüs kosinüs algoritması (sine cosine algorithm, SCA) ile oluşturulan hibrit modellerin sonuçlarıyla karşılaştırılmıştır.
- Modellerin, YSA'nın eğitimi esnasında her iterasyondaki ortalama karesel hata (mean squared error, MSE) değerleri üzerinden yakınsama grafikleri verilmiştir.

Elde edilen sonuçlar SAO tabanlı hibrit modelin karşılaştırılan diğer modellerden çok daha üstün bir performans elde ettiğini göstermiştir.

Çalışmanın geri kalanı şu şekilde organize edilmiştir: Bölüm 1.1'de literatür özeti sunulmuştur. Bölüm 2'de materyal ve metot hakkında bilgilere yer verilmiştir. Bölüm 3'te yapılan deneysel çalışmalar ve sonuçları verilmiştir. Bölüm 4'te ise tartışma ve sonuç kısmına yer verilmiştir.

1.1. Literatür Özeti

Gerçek dünyada, YSA ve metasezgisel algoritmaların hibrit kullanımıyla ilgili pek çok çalışma vardır. Singh ve arkadaşları [32] yeşil hindistan cevizi kabuklarının antioksidan aktivitesini maksimuma taşıyabilmek için YSA ve

parçacık sürü optimizasyonu (particle swarm optimization, PSO) algoritmasını kullanmıştır. Bendine ve arkadaşları [33] düzgün olmayan fonksiyonel derecelendirilmiş piezoelektrik ışının enerji hasadının geliştirilmesinde YSA ve Lichtenberg algoritmasını kullanmışlardır. Yang ve arkadaşları [34], maya fermantasyonundaki çok aşamalı gözenekli hidrojellerin hazırlama koşullarını optimize etmek için YSA ve genetik algoritma (genetic algorithm, GA)'dan faydalanmıştır. Wang ve arkadaşları [35], katı oksit yakıt hücresinde iç sıcaklık farkını azaltmak amacıyla YSA ve GA tabanlı bir model önermişlerdir. Cinar ve arkadaşları [36], beş şehrin 38 yıla ait saatlik rüzgâr verileri ile Hindistan'daki saatlik rüzgâr hızını tahmin etmek için YSA ve GWO algoritmasını birlikte kullanmıştır. Bernard ve arkadaşları [37] ise öğrencilerin öğrenme stillerini belirlemek için YSA ve karınca kolonisi optimizasyonu (ant colony optimization, ACO) algoritmasını kullanarak hibrit bir model geliştirmişlerdir. Zhang ve arkadaşları [38] YSA ile ACO algoritmasını birlikte kullanarak açık ocak madencilik projelerinin sermaye maliyetini tahmin etmek için bir model önermişlerdir.

Yukarıdaki çalışmaların yanı sıra sınıflandırma veri setleri üzerinde test edilmiş pek çok çalışma da vardır. Mirjalili [39], GWO algoritmasını 5 sınıflandırma ve 3 benchmark veri seti üzerinde test etmiştir. Gülcü [40], YSA'nın ağırlıklarını yusufçuk algoritması (dragonfly algorithm, DA) ile optimize etmiştir. Önerdiği yöntemi 8 farklı sınıflandırma problemi ve bir inşaat mühendisliği probleminde uygulamıştır. Turkoglu ve arkadaşları [41], yapay alg algoritması (artificial algae algorithm, AAA) ile YSA'yı eğitmiş ve önerdikleri yöntemi 10 farklı sınıflandırma veri seti üzerinde test etmişlerdir.

2. MATERYAL VE METOT

2.1. Veri Setleri

Çalışmada, literatürde sıklıkla kullanılan [42] aggregation, balance, liver, pathbased ve wine veri setleri kullanılmıştır. Veri setlerinin %75'i eğitim, %25'i test aşaması için ayrılmıştır. Veri setleriyle ilgili diğer bilgiler Çizelge 1'de sunulmuştur.

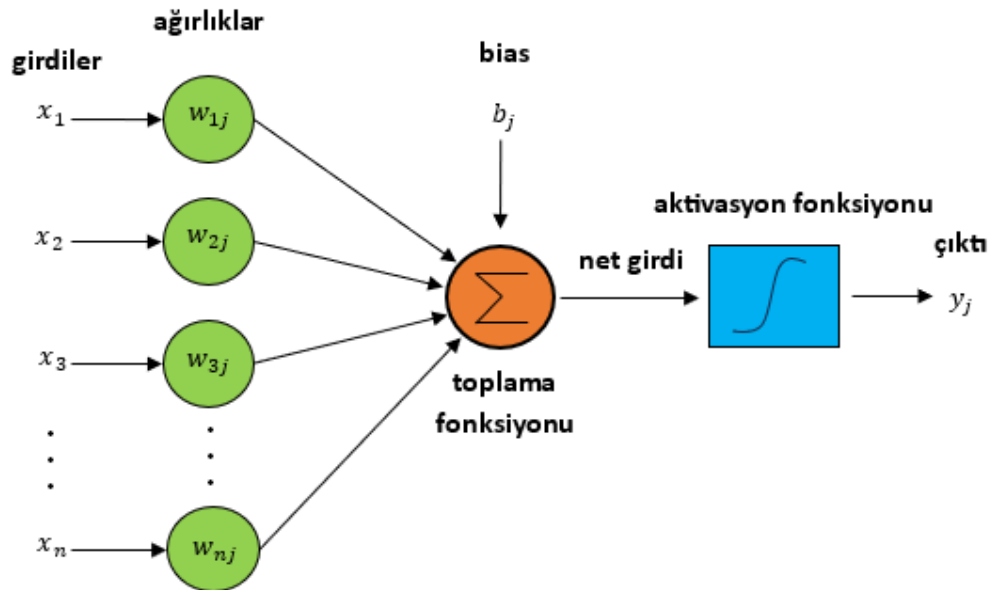
2.2. Yapay Sinir Ağları (YSA)

Yapay sinir ağları, insan beynindeki sinir hücrelerinin öğrenme yöntemini taklit eden bir algoritmadır. YSA, mevcut verilerden öğrenebilme, öğrendiği bilgilerden genellemeler yapabilmeye, çok fazla değişkenle çalışabilme gibi avantajlara sahiptir. Doğrusal ve doğrusal olmayan problemleri çözebilmektedir. Performansını kesin olarak neyin

etkilediği hakkında tam olarak bilgi sahibi olunamasa da birçok çalışmada eğitim algoritması, veri kümesinin düzenlenmesi, kestirim dönemi uzunluğu gibi faktörlerin performansını etkileyebileceği belirtilmiştir [43]. YSA'nın en küçük birimi yapay sinir hücresi olarak adlandırılır. Şekil 1'de bir yapay sinir hücresinin; girdi, çıktı, toplama fonksiyonu, aktivasyon fonksiyonu, ağırlık ve bias değerleri görülmektedir [2].

Çizelge 1. Veri setleri ve özellikleri

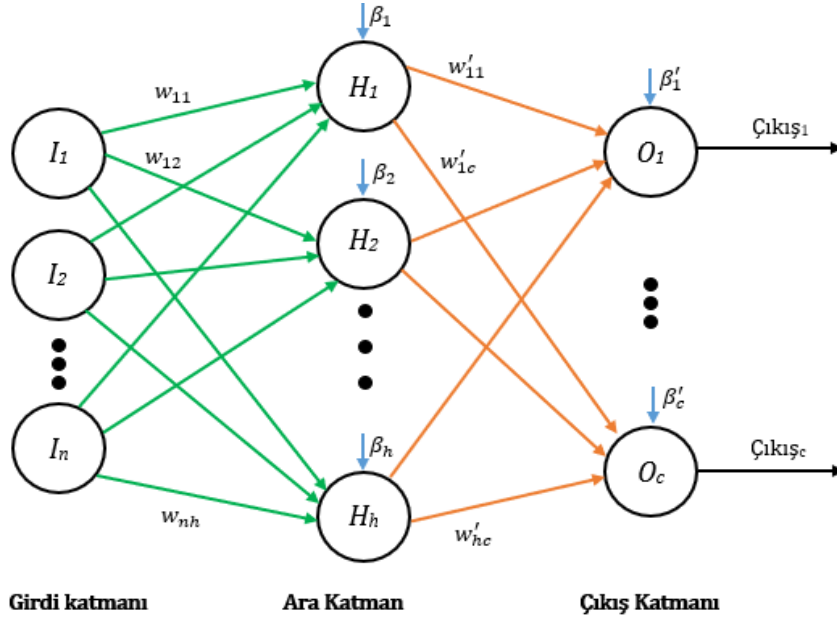
	Örnek sayısı	Eğitim örneği sayısı	Test örneği sayısı	Öznitelik sayısı	Sınıf sayısı
aggregation	788	594	194	2	7
balance	625	469	156	4	3
liver	345	259	86	6	3
pathbased	400	226	74	2	3
wine	178	133	45	13	3



Şekil 1. Yapay sinir hücresi

YSA'nın yapısı, tek katmanlı algılayıcı (TKA) ve çok katmanlı algılayıcı (ÇKA) olarak ikiye ayrılmaktadır. YSA hakkındaki ilk çalışmalar TKA mimarileri üzerine olmuştur. Ancak TKA'ların sadece doğrusal problemleri öğrenebildiğinin anlaşılması üzerine, doğrusal olmayan problemleri de öğrenebilen ÇKA mimarisi doğmuştur. ÇKA'lar girdi ve çıktı katmanının yanı sıra ara (gizli) katman

adı verilen bir katmana daha sahiptir. ÇKA mimarisinin öğrenme kuralı, ileriye doğru hesaplama ve geriye doğru hesaplama olarak ikiye ayrılır. İleriye doğru hesaplama ağın çıktısını oluşturma, geriye doğru hesaplama ise ağırlıkları güncelleme safhasıdır [2]. Şekil 2'de ÇKA mimarisinin görüntüsü verilmiştir.




Şekil 2. Çok katmanlı algılayıcı modeli

YSA mimarisi eğitilirken, ileri yayılım yaptıktan sonra veri setindeki gerçek sınıf etiketleri ve tahmin edilen sınıf etiketlerine bakar. Buna göre her bir örneklem için bir hata değeri hesaplar. Bu çalışmada, hata hesabı için Eşitlik (1)'de verilen MSE yöntemi kullanılmıştır.

$$MSE = \frac{1}{m} \sum_{i=1}^m \sum_{j=1}^n (y_j - \hat{y}_j)^2 \quad (1)$$

Burada m eğitim setindeki örnek sayısını, n sınıf etiketi sayısını, y_j çıktı için beklenen değeri ve \hat{y} ise j . çıktı için YSA tarafından tahmin edilen değeri ifade etmektedir.



Şekil 3. Ağırlıkların vektör olarak modellenmesi

Vektör uzunlukları veri setindeki öznitelik sayısına, ara katmandaki nöron sayısına ve veri setinin sınıf sayısına göre değişmektedir. Öznitelik ve sınıf sayısı veri setine bağlı olduğu için sabittir ve değiştirilemez. Ara katmandaki nöron sayısı ise

2.3. YSA ve Metasezgisel Algoritmaların Hibrit Kullanımı

İleri yayılım aşamasında hesaplanan MSE değerinin en aza indirilmesi için ağırlıkların güncellenmesi gerekir. Geri yayılım olarak adlandırılan bu aşama için standart YSA'da türev tabanlı teknikler kullanılır. Çalışmanın Giriş bölümünde detaylıca bahsedildiği üzere türev tabanlı teknikler yerel minimuma takılma sorunu yaşayabilmektedir. Bu sorunu ortadan kaldırmak için ağırlıkların güncellenmesi aşamasında metasezgisel algoritmalarından faydalanılmıştır. Şekil 3'te YSA'daki ağırlıkların vektör olarak modellenmesi görülmektedir.

YSA mimarisini oluşturan kullanıcının tercihi göre tasarlanabilir. Bu çalışmada standart olması açısından ara katmandaki nöron sayısı Eşitlik (2)'ye göre belirlenmiştir.

$$araKatmandakiNöronSayisi = (oznitelikSayisi \times 2) + 1 \quad (2)$$


Bu vektörler metasezgisel algoritmalar tarafından üretilen aday çözümleri temsil eder. Vektördeki ağırlıkların güncellenmesi işlemi, seçilen metasezgisel algoritmanın konum güncelleme stratejisine bağlı olarak gerçekleştirilecektir. Metasezgisel algoritmadaki her bireyin uygunluğu, o bireye ait ağırlık vektörünün ileri yönü hareketi sonucunda hesaplanan *MSE* değerine eşittir. Sonuç olarak, ileri yayılım aşamasında standart YSA yapısından, hatanın geri yayılımı aşamasında ise seçilen metasezgisel algoritmanın işlem adımlarından faydalanan hibrit bir model geliştirilmiş olur.

Bu araştırma makalesinde, 2023 yılında önerilen SAO algoritması kullanılarak hibrit bir YSA modeli geliştirilmiştir. Bu model sayesinde SAO algoritmasının yerel minimumlardan kurtulmak için

sahip olduğu stratejilerden YSA modelinin de faydalanması sağlanmıştır.

2.4. Kar Erime Optimizasyonu Algoritması

Kar Erime Optimizasyonu (snow ablation optimizer, SAO) algoritması, karın süblimleşme ve erime davranışını taklit eden metasezgisel bir algoritmadır. Şekil 4'te gösterildiği gibi kar, fiziksel olarak sıvı su ve buhar olmak üzere iki forma dönüşebilmektedir. Bu iki forma karşılık gelen süreçler de erime ve süblimleşme sürecidir veya eriyen su buharlaşarak buhar haline de gelebilmektedir [25]. Süblimleşme eylemi, katı maddelerin ısı ile eriyip sıvı hale geçmeden gaz hale geçmesi anlamına gelmektedir. SAO, karın erime ve süblimleşme süreçlerini taklit eder.



Şekil 4. Algoritmanın geliştirilmesinde ilham alınan kar erime olayı [25]

Metasezgisel algoritmalarındaki en büyük sorunlardan biri keşif ve sömürü arası oluşan dengesizlik halidir. SAO bu iki durumu dengelemek için oluşturulmuş bir algoritmadır [25]. SAO algoritmasının işleyişinde yer alan i) *başlatma*, ii) *keşif* ve iii) *sömürü* aşamaları ve *ikili popülasyon oluşturma* mekanizması aşağıda anlatılmaktadır.

i) *Başlatma aşaması*: popülasyon Eşitlik (3) kullanılarak arama uzayı sınırları içinde rastgele başlatılır. Burada Z , popülasyonu temsil eden bir matristir. N popülasyondaki ajan sayısını, Dim problemin boyutunu, L arama uzayının alt sınır değerini, U arama uzayının üst sınır değerini ve θ ise $[0, 1]$ aralığında rastgele sayılardan oluşan $N \times Dim$ boyutlu bir matrisi ifade eder.

$$Z = L + \theta \times (U - L) = \begin{bmatrix} Z_{1,1} & Z_{1,2} & \dots & Z_{1,Dim-1} & Z_{1,Dim} \\ Z_{2,1} & Z_{2,2} & \dots & Z_{2,Dim-1} & Z_{2,Dim} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ Z_{N-1,1} & Z_{N-1,2} & \dots & Z_{N-1,Dim-1} & Z_{N-1,Dim} \\ Z_{N,1} & Z_{N,2} & \dots & Z_{N,Dim-1} & Z_{N,Dim} \end{bmatrix}_{N \times Dim} \quad (3)$$

ii) Keşif aşaması: kar veya su buharlaştığında düzensiz bir şekilde dağılmaya başlar. Eşitlik (4)'te verilen Brownian hareketi bu düzensiz dağılımı taklit eder.

$$f_{BM}(x; 0,1) = \frac{1}{\sqrt{2\pi}} \times \exp\left(-\frac{x^2}{2}\right) \quad (4)$$

$$Z_i(t+1) = Elite(t) + BM_i(t) \otimes (\theta_1 \times (G(t) - Z_i(t)) + (1 - \theta_1) \times (Z(t) - Z_i(t))) \quad (5)$$

Burada, $i = 1, 2, \dots, N$ konumu güncellenen ajanın indisini, t o anki iterasyonu, $BM_i(t)$ Brownian hareketini, \otimes girdilerin çarpımını, θ_1 $[0,1]$ aralığında rastgele oluşturulan bir sayıyı, $G(t)$ o ana kadar elde edilen en iyi çözümü, $Z(t)$ popülasyonun sütun bazında ağırlıklarının ortalamasını içeren vektörü temsil etmektedir. En iyi uygunluğa sahip üç birey ve en iyi uygunluğa sahip $N/2$ bireyin

Popülasyondaki arama ajanlarının konumları Brownian hareketinden faydalanılarak Eşitlik (5)'teki gibi güncellenir.

konumlarının ortalaması *EliteHavuzu* adı verilen bir matriste tutulur. *Elite(t)*, *EliteHavuzu* içinden rastgele seçilen bir çözümü ifade eder.

iii) Sömürü aşaması: karın su haline geçme davranışını taklit eder. Ajanlarının konumları, popülasyondaki en iyi çözümlerin etkisiyle Eşitlik (6) kullanılarak güncellenir.

$$Z_i(t+1) = M \times G(t) + BM_i(t) \otimes (\theta_2 \times (G(t) - Z_i(t)) + (1 - \theta_2) \times (Z(t) - Z_i(t))) \quad (6)$$

Burada, M parametresi kar erime oranını, θ_2 $[-1, 1]$ aralığında rastgele bir sayıyı ifade etmektedir.

SAO algoritmasının tam konum güncelleme denklemi Eşitlik (7)'de verilmiştir.

İkili popülasyon oluşturma aşaması: bu aşamada keşif ve sömürü arasında denge oluşturmak amaçlanır. Su haline gelen karın bir kısmı arama esnasında buharlaşarak merkezîyetçiliğini kaybeder. Bu dengenin sağlanması için ikili popülasyon yapısı oluşturulmuştur. Popülasyon arama sürecinin başlarında eşit sayıda arama ajanından oluşacak şekilde rastgele iki alt popülasyona ayrılır. Alt popülasyonlardan ilki keşiften, ikincisi sömürüden sorumludur. Her iterasyonda ikinci alt popülasyonun ajan sayısı birer azaltılırken, ilkinin ajan sayısı birer artırılır. Bu mekanizmanın sözde kodu Şekil 5'te sunulmuştur.

İkili popülasyon oluşturma mekanizması

N : popülasyondaki ajan sayısı

Başlatma: $t = 0, t_{\max}, N_a = N_b = N/2$

While ($t < t_{\max}$)

If $N_a < N$

$N_a = N_a + 1$

$N_b = N_b - 1$

End if

$t = t + 1$

End while

Şekil 5. İkili popülasyon oluşturma mekanizması

$$Z_i(t+1) = \begin{cases} Elite(t) + BM_i(t) \otimes (\theta_1 \times (G(t) - Z_i(t)) \\ + (1 - \theta_1) \times (Z(t) - Z_i(t))), i \in index_a \\ M \times G(t) + BM_i(t) \otimes (\theta_2 \times (G(t) - Z_i(t)) \\ + (1 - \theta_2) \times (Z(t) - Z_i(t))), i \in index_b \end{cases} \quad (7)$$

Eşitlik (3)'te açıklandığı gibi, tüm popülasyon bir konum matrisidir. Dolayısıyla Eşitlik (7)'deki $index_a$ ve $index_b$, tüm konum matrisinde alt

popülasyonlardaki bireylerin satır numaralarını içeren bir dizi indeksi belirtir. SAO algoritmasının sözde kodu Şekil 6'da sunulmuştur.

```
Başlangıç için sürüdeki birey sayısı, ağırlık, tolerans değeri belirlenir:  
     $Z_i (i = 1, 2, \dots, N), t = 0, t_{max}, N_a = N_b = \frac{N}{2}$   
Uygunlukları hesaplanır.  
Mevcut en iyi birey kaydedilir.  
While ( $t < t_{max}$ )  
    Kar erime hızı hesaplanır.  
    Tüm popülasyon rastgele iki alt popülasyona ayrılır.  
    ForEach birey  
        Eşitlik 7 ile her ajanın konumu güncellenir.  
    End foreach  
    Uygunluk fonksiyonu değerlendirme yapılır.  
    En iyi ajan güncellenir.  
End while  
En iyi ajan alınır.
```

Şekil 6. SAO algoritmasının sözde kodu [25]

2.5. Karşılaştırma Algoritmaları

2.5.1. Guguk Kuşu Arama (CS) Algoritması

CS algoritması, Yang ve arkadaşları [44] tarafından geliştirilmiş bir algoritmadır. Bu algoritma, guguk kuşlarının yuva parazitliğine dayanır [45]. Yang ve arkadaşları [44] bu algoritmayı, aşağıdaki üç kuralla açıklamışlardır:

- Dişi guguk kuşu öncelikle rastgele bir yuva seçerek yumurtasını bırakır.
- En kaliteli yumurtalara sahip, en iyi yuvalar bir sonraki nesillere aktarılır.
- Ev sahibi kuş genellikle guguk kuşu tarafından bırakılan yumurtayı tespit ederek konakçı yumurtayı yuvasından atar ya da kendi yuvasını terk ederek yeni bir yuva kurar.

2.5.2. Gri Kurt Optimizasyonu (GWO) Algoritması

GWO algoritması, Mirjalili ve arkadaşları [46] tarafından, gri kurtların avlanma ve liderlik özelliklerinden ilham alınarak oluşturulmuş metasezgisel bir algoritmadır. Alfa, beta, delta, omega olarak isimlendirilen dört tür gri kurt ile liderlik özellikleri simüle edilmiştir [46]. Alfa en iyi, beta ikinci en iyi, delta üçüncü en iyi çözümleri ifade ederken, omega popülasyonun geriye kalan çözümlerini ifade eder.

2.5.3. Sürüngen Arama Algoritması (RSA)

RSA, Abualigah ve arkadaşları [47] tarafından timsahların davranışlarından ilham alınarak geliştirilmiş metasezgisel bir algoritmadır. Bu algoritmanın iki ana aşaması vardır. Bunlar, avın kuşatılması ve avlanması olmaktadır. Bu iki aşamanın da ikişer arama stratejisi vardır. Keşif aşamasına ait iki strateji, yüksek yürüyüş ve göbek yürüyüşü arama yöntemleridir. Sömürü aşamasının stratejileri ise av koordinasyonu ve av iş birliğidir.

2.5.4. Sinüs Kosinüs Algoritması (SCA)

SCA, Mirjalili [48] tarafından, matematikte aynı isme sahip olan sinüs ve kosinüs fonksiyonlarından ilham alınarak önerilmiş metasezgisel bir algoritmadır. Keşif aşaması için sinüs, sömürü aşaması için kosinüs fonksiyonu kullanılmıştır.

2.6. Karmaşıklık Matrisi (Confusion Matrix)

Karmaşıklık matrisi, modelin doğruluğunu, veri setlerinin sınıflandırma başarısını ölçmeye yarayan ve literatürde sıklıkla kullanılan bir performans ölçüm yöntemidir. Karmaşıklık matrisinde tahmin edilen sınıf etiketi ve gerçek sınıf etiketi üzerinden Şekil 7'de verilen durumlara göre çeşitli hesaplamalar yapılır.

		Tahmin	
		Negatif	Pozitif
Gerçek Durum	Negatif	Doğru Negatif (True Negative, TN)	Yanlış Pozitif (False Pozitive, FP)
	Pozitif	Yanlış Negatif (False Negative, FN)	Doğru Pozitif (True Pozitive, TP)

Şekil 7. Karmaşıklık matrisi

Tahmini sınıf *pozitif* ve gerçek sınıf *pozitif* ise doğru pozitif (True Positive, TP), tahmini sınıf *negatif* ve gerçek sınıf *negatif* ise doğru negatif (True Negative, TN), tahmini sınıf *pozitif* ve gerçek sınıf *negatif* ise yanlış pozitif (False Positive FP), tahmini sınıf *negatif* ve gerçek sınıf *pozitif* ise yanlış negatif (False Negative, FN) olarak isimlendirilir. Bu bilgiler kullanılarak aşağıdaki metrikler elde edilmiştir.

$$\text{Sensitivity} = \frac{TP}{TP + FN}$$

$$\text{Specificity} = \frac{TN}{TN + FP}$$

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{F1-score} = 2 * \frac{\text{Sensitivity} * \text{Precision}}{\text{Sensitivity} + \text{Precision}}$$

- Sensitivity, doğru pozitif değerlerin toplam gerçek pozitif değerlerine bölünmesi ile elde edilir. Pozitif sınıfa ait değerlerden doğru tahminlerin oranının ne olduğu hakkında bilgi verir.

- Specificity, gerçek negatif değerlerin, toplam gerçek negatif değerlere bölünmesi ile elde edilir.
- Precision, doğru pozitif değerlerin toplam tahmini pozitif değerlerine bölünmesiyle elde edilir. Bu metrik, doğru tahminlerin ne oranda olduğu hakkında bilgi verir.
- F1-score ise, sensitivity ve precision metriklerinin harmonik ortalamasıdır. Eşit dağılmayan veri setleri için hatalı modeller oluşturmanın önüne geçmesi bakımından önemli bir metriktir.

Tüm metrikler en kötü 0, en iyi 1 değerini alırlar.

3. DENEYSEL ÇALIŞMALAR

Bu çalışmada geliştirilen SAO hibrit modeli, CS, GWO, RSA ve SCA algoritmaları ile geliştirilen hibrit modellerle karşılaştırılmıştır. Deneysel çalışmalar aggregation, balance, liver, pathbased ve wine veri setleri üzerinde yapılmıştır. Veri setleri %75 eğitim, %25 test verisi olarak ayrılmıştır. Ağırlık değerleri [-10, 10] arama uzayında oluşturulmuştur. Her bir yöntem, her bir veri setinde 50 birey ve 400 iterasyon için 30 kez çalıştırılmıştır. Elde edilen sonuçlar için hesaplanan sensitivity, specificity, precision ve f1-score metriklerinin ortalama, standart sapma ve başarı sırası değerleri verilmiştir. Ayrıca çizelgelerin en alt satırında, yöntemlerin ortalama başarı sırası (*OBS*) verilmiştir.

Çizelge 2. SAO, CS, GWO, RSA ve SCA algoritmalarının sensitivity metriğine göre ortalama, standart sapma ve başarı sırası değerleri

Veri seti	SAO			GWO			RSA			CS			SCA		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,355	0,122	1	0,340	0,121	2	0,220	0,058	5	0,294	0,050	3	0,257	0,031	4
balance	0,684	0,084	1	0,605	0,017	2	0,542	0,083	5	0,604	0,037	3	0,565	0,073	4
liver	0,396	0,033	1	0,377	0,034	3	0,355	0,037	5	0,377	0,031	2	0,359	0,032	4
pathbased	0,600	0,076	1	0,540	0,053	3	0,384	0,160	5	0,554	0,065	2	0,458	0,155	4
wine	0,683	0,077	2	0,701	0,119	1	0,594	0,145	5	0,663	0,057	3	0,638	0,059	4
<i>OBS</i>			1,2 (1)			2,2 (2)			5 (5)			2,6 (3)			4 (4)

Çizelge 2’deki sensitivity sonuçları incelendiğinde, SAO hibrit modelinin 5 veri setinin 4’ünde ilk sırayı elde ettiği, wine veri setinde ise GWO hibrit

modelinin ardından 2.sırada yer aldığı gözlenmektedir. *OBS* değerlerine bakıldığında SAO hibrit modelinin 1.2 ortalama ile diğer

algoritmaların üstün bir performansa sahip olduğu değerlerine bakıldığında ise başarı sıraları GWO görülmektedir. Karşılaştırma modellerinin OBS (2.2), CS (2.6), SCA (4) ve RSA (5) şeklindedir.

Çizelge 3. SAO, CS, GWO, RSA ve SCA algoritmalarının specificity metriğine göre ortalama, standart sapma ve başarı sırası değerleri

Veri seti	SAO			GWO			RSA			CS			SCA		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,911	0,025	1	0,910	0,026	2	0,883	0,021	5	0,903	0,008	3	0,895	0,011	4
balance	0,919	0,016	1	0,899	0,014	2	0,845	0,071	5	0,895	0,026	3	0,865	0,062	4
liver	0,729	0,032	1	0,710	0,034	3	0,688	0,036	5	0,711	0,030	2	0,693	0,031	4
pathbased	0,795	0,039	1	0,764	0,025	3	0,685	0,082	5	0,772	0,031	2	0,723	0,0789	4
wine	0,855	0,031	2	0,863	0,052	1	0,800	0,076	5	0,845	0,025	3	0,833	0,0310	4
OBS			1,2 (1)			2,2 (2)			5 (5)			2,6 (3)			4 (4)

Çizelge 3'teki specificity sonuçları incelendiğinde, sensitivity metriğiyle aynı performans sonuçlarına ulaşıldığı gözlenmiştir. SAO hibrit modelinin 5 veri setinin 4'ünde ilk sırayı elde ettiği, wine veri setinde GWO hibrit modelinin ardından 2.sırada yer aldığı ve OBS açısından 1.2 ortalama ile diğer

algoritmaların daha iyi bir performansa sahip olduğu görülmektedir. Karşılaştırma modellerinin OBS değerlerine bakıldığında ise başarı sıraları GWO (2.2), CS (2.6), SCA (4) ve RSA (5) şeklindedir.

Çizelge 4. SAO, CS, GWO, RSA ve SCA algoritmalarının precision metriğine göre ortalama, standart sapma ve başarı sırası değerleri

Veri seti	SAO			GWO			RSA			CS			SCA		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,301	0,111	1	0,296	0,110	2	0,155	0,059	5	0,233	0,048	3	0,197	0,029	4
balance	0,670	0,100	1	0,578	0,009	3	0,543	0,033	5	0,599	0,090	2	0,559	0,031	4
liver	0,431	0,038	1	0,378	0,098	3	0,287	0,117	5	0,407	0,066	2	0,347	0,104	4
pathbased	0,647	0,116	1	0,527	0,131	3	0,334	0,202	5	0,624	0,095	2	0,473	0,228	4
wine	0,591	0,135	2	0,606	0,171	1	0,513	0,212	5	0,566	0,114	3	0,528	0,084	4
OBS			1,2 (1)			2,4 (2)			5 (4)			2,4 (2)			4 (3)

Çizelge 4'teki precision sonuçları incelendiğinde, SAO hibrit modelinin 5 veri setinin 4'ünde ilk sırayı elde ettiği, wine veri setinde GWO hibrit modelinin ardından 2.sırada yer aldığı gözlenmektedir. OBS değerlerine bakıldığında SAO hibrit modelinin 1.2 ortalama ile diğer algoritmaların üstün bir

performansa sahip olduğu görülmektedir. Karşılaştırma modellerinin OBS değerlerine bakıldığında GWO (2.4) ve CS (2.4) aynı başarı sırasıyla SAO modelinin ardından 2. olmuşlardır. SCA (3) ve RSA (4) modelleri ise performans açısından diğer modellerin gerisinde kalmıştır.


Çizelge 5. SAO, CS, GWO, RSA ve SCA algoritmalarının fl-score metriğine göre ortalama, standart sapma ve başarı sırası değerleri

Veri seti	SAO			GWO			RSA			CS			SCA		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,294	0,120	1	0,288	0,116	2	0,153	0,057	5	0,237	0,041	3	0,200	0,029	4
balance	0,663	0,083	1	0,582	0,016	3	0,509	0,100	5	0,582	0,041	2	0,536	0,080	4
liver	0,377	0,049	1	0,342	0,064	3	0,290	0,073	5	0,350	0,055	2	0,318	0,062	4
pathbased	0,525	0,103	1	0,456	0,046	3	0,305	0,135	5	0,467	0,077	2	0,372	0,132	4
wine	0,613	0,097	2	0,634	0,148	1	0,514	0,175	5	0,587	0,071	3	0,560	0,069	4
OBS			1,2 (1)			2,4 (2)			5 (4)			2,4 (2)			4 (3)

Çizelge 5'teki f1-score sonuçları incelendiğinde, precision metriğiyle aynı performans sonuçlarına ulaşıldığı gözlenmiştir. SAO hibrit modelinin 5 veri setinin 4'ünde ilk sırayı elde ettiği, wine veri setinde GWO hibrit modelinin ardından 2.sırada yer aldığı, OBS değerlerine bakıldığında ise SAO hibrit modelinin 1.2 ortalama ile diğer algoritalardan üstün bir performansa sahip olduğu görülmektedir. Karşılaştırma modellerinin OBS değerlerine bakıldığında GWO (2.4) ve CS (2.4) aynı başarı sırasıyla SAO modelinin ardından 2. olmuşlardır.

SCA (3) ve RSA (4) modelleri ise performans açısından diğer modellerin gerisinde kalmıştır.

Şekil 8'de ise hibrit modellerin eğitim aşamasındaki MSE değerleri üzerinden hata yakınsama grafikleri çizdirilmiştir. Yakınsama grafikleri incelendiğinde SAO hibrit modelinin wine veri setinde GWO hibrit modelinin ardından ikinci olduğu, diğer tüm veri setlerinde ise en hızlı yakınsama performansını elde ettiği gözlenmiştir.



Şekil 8. MSE yakınsama grafikleri

3.1. Önerilen Hibrit Modelde Popülasyon Genişliğinin Etkisi

Bu bölümde, çalışmada önerilen SAO hibrit modelinin başarısında metasezgisel algoritmanın sahip olduğu parçacık sayısının etkisi incelenmiştir. Bu amaçla SAO'daki parçacık sayısı 10, 20, 30, 40, 50, 100, 150 ve 200 olarak ayarlanmış ve adil karşılaştırma yapmak amacıyla her bir model 20000 uygunluk sayısı için çalıştırılmıştır. Modeller tarafından elde edilen metrik değerleri, başarı sıraları ve OBS değerleri Çizelge 6-9'da sunulmuştur.

Çizelge 6, 7 ve 8'deki sensitivity, specificity ve precision metrik değerleri incelendiğinde, parçacık sayısı 100 olduğunda 2.8 OBS değeri ile en başarılı sonuçlara ulaşıldığı gözlenmiştir. Çizelge 9'da verilen F1-score metriğinde ise parçacık sayısı 40 olduğunda 2.8 OBS değeri ile en başarılı sonuçlar elde edilirken, parçacık sayısının 30, 50 ve 100 olarak ayarlandığı durumlarda 3.2 OBS değeri elde edilmiştir. Elde edilen sonuçlar birlikte değerlendirildiğinde, parçacık sayısının 10, 20 gibi düşük değerler ya da 150, 200 gibi yüksek değerler almasının modelin başarısını olumsuz etkilediği, 50, 100 gibi değerlerin ise modelin başarısını artırdığı görülmektedir.

Çizelge 6. SAO hibrit modelinin 10, 20, 30, 40, 50, 100, 150 ve 200 parçacık sayıları için elde ettiği sensitivity metrik değerleri

Parçacık sayısı	10			20			30			40		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,329	0,103	7	0,333	0,089	6	0,362	0,100	2	0,333	0,095	5
balance	0,644	0,050	7	0,684	0,076	1	0,679	0,090	4	0,681	0,087	3
liver	0,390	0,039	5	0,389	0,033	6	0,381	0,036	8	0,401	0,031	1
pathbased	0,529	0,093	7	0,578	0,087	5	0,616	0,100	1	0,579	0,091	4
wine	0,659	0,070	6	0,679	0,089	5	0,712	0,116	1	0,693	0,094	3
<i>OBS</i>			6,4			4,6			3,2			3,2
Parçacık sayısı	50			100			150			200		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,355	0,122	4	0,391	0,107	1	0,356	0,085	3	0,310	0,081	8
balance	0,684	0,084	2	0,670	0,076	5	0,666	0,090	6	0,604	0,040	8
liver	0,396	0,033	4	0,398	0,026	3	0,399	0,027	2	0,386	0,033	7
pathbased	0,600	0,076	2	0,585	0,062	3	0,399	0,027	8	0,567	0,056	6
wine	0,683	0,077	4	0,693	0,097	2	0,399	0,027	8	0,650	0,063	7
<i>OBS</i>			3,2			2,8			5,4			7,2

Çizelge 7. SAO hibrit modelinin 10, 20, 30, 40, 50, 100, 150 ve 200 parçacık sayıları için elde ettiği specificity metrik değerleri

Parçacık sayısı	10			20			30			40		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,905	0,021	8	0,906	0,021	5	0,911	0,023	3	0,906	0,022	6
balance	0,913	0,015	6	0,921	0,020	1	0,919	0,022	4	0,920	0,018	2
liver	0,724	0,039	5	0,722	0,033	6	0,715	0,036	8	0,734	0,031	1
pathbased	0,761	0,047	7	0,784	0,045	5	0,805	0,052	1	0,785	0,046	4
wine	0,843	0,032	6	0,851	0,038	5	0,867	0,048	1	0,859	0,039	3
<i>OBS</i>			6,4			4,4			3,4			3,2
Parçacık sayısı	50			100			150			200		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,911	0,026	2	0,921	0,022	1	0,911	0,018	4	0,905	0,021	7
balance	0,919	0,017	3	0,916	0,017	5	0,912	0,023	7	0,895	0,020	8
liver	0,729	0,033	4	0,731	0,026	3	0,732	0,027	2	0,720	0,033	7
pathbased	0,796	0,040	2	0,787	0,032	3	0,732	0,027	8	0,778	0,028	6
wine	0,855	0,031	4	0,860	0,044	2	0,732	0,027	8	0,838	0,032	7
<i>OBS</i>			3			2,8			5,8			7

Çizelge 8. SAO hibrit modelinin 10, 20, 30, 40, 50, 100, 150 ve 200 parçacık sayıları için elde ettiği precision metrik değerleri

Parçacık sayısı	10			20			30			40		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,272	0,103	7	0,276	0,078	6	0,313	0,115	2	0,291	0,084	5
balance	0,654	0,108	6	0,683	0,098	1	0,663	0,097	5	0,667	0,099	4
liver	0,420	0,093	6	0,430	0,063	4	0,405	0,077	8	0,426	0,066	5
pathbased	0,536	0,160	7	0,607	0,130	5	0,692	0,101	1	0,617	0,137	3
wine	0,565	0,128	7	0,578	0,139	5	0,632	0,169	1	0,623	0,159	2
OBS			6,6			4,2			3,4			3,8
Parçacık sayısı	50			100			150			200		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,302	0,111	3	0,338	0,105	1	0,295	0,089	4	0,254	0,056	8
balance	0,670	0,100	3	0,673	0,109	2	0,645	0,104	7	0,580	0,031	8
liver	0,432	0,038	3	0,445	0,031	2	0,448	0,036	1	0,408	0,062	7
pathbased	0,647	0,116	2	0,598	0,116	6	0,448	0,036	8	0,616	0,116	4
wine	0,591	0,136	4	0,596	0,148	3	0,448	0,036	8	0,570	0,119	6
OBS			3			2,8			5,6			6,6

Çizelge 9. SAO hibrit modelinin 10, 20, 30, 40, 50, 100, 150 ve 200 parçacık sayıları için elde ettiği fl-score metrik değerleri

Parçacık sayısı	10			20			30			40		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,268	0,105	7	0,274	0,083	5	0,298	0,104	2	0,270	0,089	6
balance	0,632	0,065	7	0,672	0,081	1	0,662	0,091	4	0,665	0,088	2
liver	0,360	0,069	7	0,366	0,055	6	0,353	0,062	8	0,383	0,051	1
pathbased	0,444	0,111	7	0,495	0,110	5	0,548	0,138	1	0,502	0,115	3
wine	0,583	0,091	6	0,607	0,112	5	0,651	0,141	1	0,633	0,117	2
OBS			6,8			4,4			3,2			2,8
Parçacık sayısı	50			100			150			200		
	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra	ort.	std.	sıra
aggregation	0,294	0,120	3	0,336	0,110	1	0,284	0,078	4	0,252	0,074	8
balance	0,663	0,083	3	0,655	0,078	5	0,640	0,086	6	0,581	0,034	8
liver	0,378	0,049	4	0,381	0,036	3	0,382	0,044	2	0,367	0,052	5
pathbased	0,525	0,104	2	0,501	0,079	4	0,382	0,044	8	0,478	0,069	6
wine	0,614	0,097	4	0,623	0,122	3	0,382	0,044	8	0,579	0,084	7
OBS			3,2			3,2			5,6			6,8

4. TARTIŞMA VE SONUÇ

Bu çalışmada, yakın zamanda önerilen SAO algoritması ile YSA'daki ağırlık değerlerinin eğitilmesi için hibrit bir model geliştirilmiştir. Geliştirilen model 5 farklı veri seti (aggregation, balance, liver, pathbased ve wine) üzerinde 4 farklı metasezgisel algoritma (GWO, RSA, CS ve SCA) ile oluşturulan hibrit modeller ile karşılaştırılmıştır. Modellerin başarısı sensitivity, specificity, precision ve fl-score metrikleri üzerinden karşılaştırılmıştır. SAO algoritmasının dört metriğin tamamında ortalama başarı sırası açısından en iyi performansı elde ettiği gözlenmiştir. Ayrıca

hibrit modellerin, eğitim aşamasındaki ortalama karesel hata değerlerinin yakınsama grafikleri çizdirilmiş ve SAO hibrit modelinin wine hariç diğer tüm veri setlerinde karşılaştırılan modellerden daha hızlı bir yakınsama performansına sahip olduğu gözlenmiştir. Parçacık sayısı ile ilgili yapılan deneysel çalışmalar ise 100 birey kullanılması durumunda SAO modelinin başarısının arttığını göstermiştir. Özetle, bu çalışmada elde edilen bulgular, SAO algoritmasının YSA'daki ağırlık değerlerinin güncellenmesinde önemli bir başarıya sahip olduğu gözlenmiştir. SAO'nun elde ettiği başarıda yerel minimumlardan kurtulma stratejilerinin önemli bir payı olduğu

düşünülmektedir. Bu sebeple ileriki çalışmalarda SAO'nun; derin öğrenme, sınıflandırma, kümeleme gibi yerel minimumlara sahip çeşitli gerçek dünya problemlerinin çözümünde tek başına veya hibrit olarak kullanılması önerilmektedir. Ayrıca sürekli problemlerin yanı sıra SAO'nun ikili veya kombinatoryal problemlerin çözümüne uyarlanması ve performansının test edilmesi de önemli katkılar sağlayabilir. Son olarak SAO'nun wine veri setinde diğer veri setlerinde olduğu kadar başarılı olamaması dikkat çekicidir. Bu duruma wine veri seti için oluşturulan modelin boyut sayısının diğer veri setleri için oluşturulan modellerden daha çok boyuta sahip olması yol açmış olabilir. SAO'nun yüksek boyutlu problemlerde performansının iyileştirilmesi de ayrı bir araştırma konusu olabilir.

5. KAYNAKÇA

1. Turing, A.M., 2009. Computing Machinery and Intelligence. Springer.
2. Öztemel, E., 2003. Yapay Sinir Ağları. Papatya Yayıncılık.
3. Rosenblatt, F., 1958. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. Psychological review, 65(6), 386.
4. Rumelhart, D.E., Hinton, G.E., Williams, R.J., 1986. Learning Representations by Back-Propagating Errors. Nature, 323(6088), 533-536.
5. Ciregan, D., Meier, U., Schmidhuber, J., 2012. Multi-Column Deep Neural Networks for Image Classification. In 2012 IEEE Conference on Computer Vision and Pattern Recognition, Providence, RI, USA, 3642-3649.
6. Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012. Imagenet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems, 25, 1-9.
7. Liu, X., Zeng, S., Namaiti, A., Xin, R., 2023. Comparison between Three Convolutional Neural Networks for Local Climate Zone Classification Using Google Earth Images: A Case Study of the Fujian Delta in China. Ecological Indicators, 148, 110086.
8. Bas, E., Egrioglu, E., Cansu, T., 2024. Robust Training of Median Dendritic Artificial Neural Networks for Time Series Forecasting. Expert Systems with Applications, 238, 122080.
9. Dalal, A.-A., AlRassas, A.M., Al-qaness, M.A., Cai, Z., Aseeri, A.O., Abd Elaziz, M., Ewees, A.A., 2023. Tlia: Time-Series Forecasting Model Using Long Short-Term Memory Integrated with Artificial Neural Networks for Volatile Energy Markets. Applied Energy, 343, 121230.
10. Egrioglu, E., Baş, E., Chen, M.-Y., 2022. Recurrent Dendritic Neuron Model Artificial Neural Network for Time Series Forecasting. Information Sciences, 607, 572-584.
11. Ergun, U., Tayfun, D., 2020. Jaya Algoritması ile Optimize Edilmiş Yapay Sinir Ağlarını Kullanarak Türkiye'de Elektrik Enerjisi Tüketiminin Tahmini. Gazi University Journal of Science Part C: Design Technology, 8(3), 511-528.
12. Jayasimha, S., Lingaraju, K., Raju, H., 2022. Prediction of Surface Finish in Extrusion Honing Process by Regression Analysis and Artificial Neural Networks. Applications in Engineering Science, 10, 100105.
13. Selim, A., Shuvo, S.N.A., Moniruzzaman, M., Islam, M., Shah, S., Ohiduzzaman, M., 2023. Predictive Models for Dissolved Oxygen in an Urban Lake by Regression Analysis and Artificial Neural Network. 1-11.
14. Tam, V.W., Butera, A., Le, K.N., Da Silva, L.C., Evangelista, A.C., 2022. A Prediction Model for Compressive Strength of Co2 Concrete Using Regression Analysis and Artificial Neural Networks. Construction Building Materials, 324, 126689.
15. Ghiassi, M., Burnley, C., 2010. Measuring Effectiveness of a Dynamic Artificial Neural Network Algorithm for Classification Problems. Expert Systems with Applications, 37(4), 3118-3128.
16. Xu, B., Su, J., Dale, D., Watson, M., 2000. Cotton Color Grading with a Neural Network. Textile Research Journal, 70(5), 430-436.
17. Yaman, S., Karakaya, B., Köküm, M., 2024. A Neural Network Approach for Classification of Fault-Slip Data in Geoscience. Ain Shams Engineering Journal, 15(1), 102325.

18. Elangasinghe, M., Singhal, N., Dirks, K., Salmond, J., Samarasinghe, S., 2014. Complex Time Series Analysis of Pm10 and Pm2.5 for a Coastal Site Using Artificial Neural Network Modelling and K-Means Clustering. *Atmospheric Environment*, 94, 106-116.
19. Erilli, N.A., Yolcu, U., Eğrioğlu, E., Aladağ, Ç.H., Öner, Y., 2011. Determining the Most Proper Number of Cluster in Fuzzy Clustering by Using Artificial Neural Networks. *Expert Systems with Applications*, 38(3), 2248-2252.
20. Nithya, A., Appathurai, A., Venkatadri, N., Ramji, D., Palagan, C.A., 2020. Kidney Disease Detection and Segmentation Using Artificial Neural Network and Multi-Kernel K-Means Clustering for Ultrasound Images. *Measurement*, 149, 106952.
21. Jiadong, Q., Ohl, J.P., Tran, T.-T., 2024. Predicting Clay Compressibility for Foundation Design with High Reliability and Safety: A Geotechnical Engineering Perspective Using Artificial Neural Network and Five Metaheuristic Algorithms. *Reliability Engineering System Safety*, 243, 109827.
22. Alameer, Z., Abd Elaziz, M., Ewees, A.A., Ye, H., Jianhua, Z., 2019. Forecasting Gold Price Fluctuations Using Improved Multilayer Perceptron Neural Network and Whale Optimization Algorithm. *Resources Policy*, 61, 250-260.
23. Du, W., Zhang, Q., Chen, Y., Ye, Z., 2021. An Urban Short-Term Traffic Flow Prediction Model Based on Wavelet Neural Network with Improved Whale Optimization Algorithm. *Sustainable Cities Society*, 69, 102858.
24. Ouladbrahim, A., Belaidi, I., Khatir, S., Magagnini, E., Capozucca, R., Wahab, M.A., 2022. Experimental Crack Identification of Api X70 Steel Pipeline Using Improved Artificial Neural Networks Based on Whale Optimization Algorithm. *Mechanics of Materials*, 166, 104200.
25. Deng, L., Liu, S., 2023. Snow Ablation Optimizer: A Novel Metaheuristic Technique for Numerical Optimization and Engineering Design. *Expert Systems with Applications*, 225, 120069.
26. Karakoyun, M., Özkış, A., 2021. Transfer Fonksiyonları Kullanarak İkili Güve-Alev Optimizasyonu Algoritmalarının Geliştirilmesi ve Performanslarının Karşılaştırılması. *Necmettin Erbakan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 3(2), 1-10.
27. Özkış, A., Karakoyun, M., 2023. A Binary Enhanced Moth Flame Optimization Algorithm for Uncapacitated Facility Location Problems. *Pamukkale University Journal of Engineering Sciences*, 29(7), 737-751.
28. Çelik, İ., Yıldız, C., Şekkel, M., 2018. Rüzgâr Enerji Santrali Kurulumunda Rüzgâr Türbinlerinin Mikro Yerleşimi İçin Bir Optimizasyon Modeli. *Gazi University Journal of Science Part C: Design Technology*, 6(4), 898-908.
29. Kong, M., Tian, P., Kao, Y., 2008. A New Ant Colony Optimization Algorithm for the Multidimensional Knapsack Problem. *Computers Operations Research*, 35(8), 2672-2683.
30. Irmak, B., 2022. Yapay Sinir Ağlarının Eğitimi İçin Kelebek Optimizasyonu Algoritmasının İyileştirilmesi. Yüksek Lisans Tezi, Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Konya, Türkiye, 75.
31. Wolpert, D.H., Macready, W.G., 1997. No Free Lunch Theorems for Optimization. *IEEE Transactions on Evolutionary Computation*, 1(1), 67-82.
32. Singh, P., Pandey, V.K., Chakraborty, S., Dash, K.K., Singh, R., Béla, K., 2023. Ultrasound-Assisted Extraction of Phytochemicals from Green Coconut Shell: Optimization by Integrated Artificial Neural Network and Particle Swarm Technique. *Heliyon*, 9(12).
33. Bendine, K., Pereira, J.L.J., Gomes, G.F., 2023. Energy Harvesting Enhancement of Nonuniform Functionally Graded Piezoelectric Beam Using Artificial Neural Networks and Lichtenberg Algorithm. *Structures*, 105271.
34. Yang, S., Tian, X., Zhang, Q., Jiang, J., Dong, P., Tan, J., Meng, Y., Liu, P., Bai, H., Song, J., 2023. Microorganism Inspired Hydrogels: Optimization by Response Surface Methodology and Genetic Algorithm Based on Artificial Neural Network. *European Polymer Journal*, 201, 112497.
35. Wang, C., He, Q., Li, Z., Yu, J., Bello, I.T., Zheng, K., Han, M., Ni, M., 2024. A Novel in-

- Tube Reformer for Solid Oxide Fuel Cell for Performance Improvement and Efficient Thermal Management: A Numerical Study Based on Artificial Neural Network and Genetic Algorithm. *Applied Energy*, 357, 122030.
36. Cinar, A.C., Natarajan, N., 2022. An Artificial Neural Network Optimized by Grey Wolf Optimizer for Prediction of Hourly Wind Speed in Tamil Nadu, India. *Intelligent Systems with Applications*, 16, 200138.
37. Bernard, J., Popescu, E., Graf, S., 2022. Improving Online Education through Automatic Learning Style Identification Using a Multi-Step Architecture with Ant Colony System and Artificial Neural Networks. *Applied Soft Computing*, 131, 109779.
38. Zhang, H., Nguyen, H., Bui, X.-N., Nguyen-Thoi, T., Bui, T.-T., Nguyen, N., Vu, D.-A., Mahesh, V., Moayedi, H., 2020. Developing a Novel Artificial Intelligence Model to Estimate the Capital Cost of Mining Projects Using Deep Neural Network-Based Ant Colony Optimization Algorithm. *Resources Policy*, 66, 101604.
39. Mirjalili, S., 2015. How Effective Is the Grey Wolf Optimizer in Training Multi-Layer Perceptrons. *Applied Intelligence*, 43, 150-161.
40. Gülcü, Ş., 2022. Training of the Feed Forward Artificial Neural Networks Using Dragonfly Algorithm. *Applied Soft Computing*, 124, 109023.
41. Turkoglu, B., Kaya, E., 2020. Training Multi-Layer Perceptron with Artificial Algae Algorithm. *Engineering Science Technology, an International Journal*, 23(6), 1342-1350.
42. Qaddoura, R., Faris, H., Aljarah, I., Castillo, P.A., 2021. Evocluster: An Open-Source Nature-Inspired Optimization Clustering Framework. *SN Computer Science*, 2, 1-12.
43. Ataseven, B., 2013. Yapay Sinir Ağları ile Öngörü Modellemesi. *Öneri Dergisi*, 10(39), 101-115.
44. Yang, X.-S., Deb, S., 2009. Cuckoo Search Via Lévy Flights. 2009 World Congress on Nature & Biologically inspired computing (NaBIC), Coimbatore, India, 210-214.
45. Pu, Y., Song, J., Wu, M., Xu, X., Wu, W., 2023. Node Location Using Cuckoo Search Algorithm with Grouping and Drift Strategy for Wsn. *Physical Communication*, 59, 102088.
46. Mirjalili, S., Mirjalili, S.M., Lewis, A., 2014. Grey Wolf Optimizer. *Advances in Engineering Software*, 69, 46-61.
47. Abualigah, L., Abd Elaziz, M., Sumari, P., Geem, Z.W., Gandomi, A.H., 2022. Reptile Search Algorithm (RSA): A Nature-Inspired Meta-Heuristic Optimizer. *Expert Systems with Applications*, 191, 116158.
48. Mirjalili, S., 2016. Sca: A Sine Cosine Algorithm for Solving Optimization Problems. *Knowledge-Based Systems*, 96, 120-133.

Effects of Adding Pectin to Milk in Varying Amounts on the Rheological Properties of Milk

Veli ÖZBOLAT*^{1,2,3} ORCID 0000-0002-1757-3054

¹Cukurova University, Ceyhan Engineering Faculty, Mechanical Engineering Department, Adana, Türkiye

²Cukurova University, Institute of Natural and Applied Sciences, Tissue Engineering Department, Adana, Türkiye

³Cukurova University, Biotechnology Research and Application Center, Adana, Türkiye

Geliş tarihi: 09.01.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ÖZBOLAT, V., (2024). Effects of Adding Pectin to Milk in Varying Amounts on the Rheological Properties of Milk. Cukurova University, Journal of the Faculty of Engineering, 39(2), 407-414.

Abstract

Pectin, which is used as an additive in the food, cosmetics, pharmaceutical, and health sectors due to its safety, non-toxicity, low production cost, and high availability, is used as a thickener, gelling agent, brightener, stabilizer, emulsifier, and fat and sugar replacer in low-calorie foods. It is also used in milk and dairy products as a stabilizer to prevent proteins from clumping. In this study, the rheological properties of pectin and milk mixtures with pectin/milk powder (w/w) ratios of 0.1, 0.25, 0.5, 0.75, 1 and 1.5 were examined. First, a flow curve test was applied in the range of 0,01-1000 s⁻¹ to obtain the viscosity curves and yield stress values of the samples. Then, an amplitude sweep test was performed at a fixed frequency of 10 rad/s and in the strain range of 0.01-100% to determine the linear viscoelastic range (LVR) of the samples and the solid and liquid structure of the samples. To determine the time-dependent behavior of the samples in non-destructive deformation, frequency sweep tests were performed at constant strain (0.01%) in the LVR range obtained from the amplitude sweep test and in the range of 0.1-100 rad/s. Finally, three interval thixotropy tests (3ITT) were performed to observe the structural recovery of the samples. As a result of rheological tests, it was determined that pectin-free milk showed Newtonian properties, other samples showed shear thinning properties, and viscosity values increased as the pectin rate increased. While all samples are solid at low strains, the liquid feature becomes dominant at high strains. It has been observed that as the pectin ratio in milk increases, the strain values at the yield point, where the liquid feature becomes dominant, also increase. Except for the sample with the highest pectin content, it was observed that the dominance of the storage modulus over the loss modulus was greater at low frequencies than at high frequencies. As a result of 3ITT, it was determined that the percentage of recovery at the 600th second increased as the pectin rate increased.

Keywords: Pectin, Milk, Rheology, Food

*Sorumlu yazar (Corresponding Author): Veli ÖZBOLAT, vozbolat@cu.edu.tr

Değişen Miktarlarda Pektinin Süte Eklenmesinin Sütün Reolojik Özelliklerine Etkisi

Öz

Güvenli olması, toksik olmaması, düşük üretim maliyeti ve yüksek bulunabilirliği ile gıda, kozmetik, ilaç ve sağlık sektörlerinde katkı maddesi olarak kullanılan pektin; bu alanlarda kıvamlaştırıcı, jelleştirici, parlaticı, stabilizatör, emülgatör olarak ve düşük kalorili gıdalarda yağ ve şeker ikamesi olarak kullanılmaktadır. Süt ve süt ürünlerinde kıvam arttırıcı olarak kullanılmasının yanında proteinlerin topaklanmasını önlemek amacıyla stabilizatör olarak da kullanımı mevcuttur. Bu çalışmada, pektin/süt tozu (a/a) oranı 0,1, 0,25, 0,5, 0,75, 1 ve 1,5 olan pektin ve süt karışımların reolojik özellikleri incelenmiştir. İlk olarak, numunelerin viskozite eğrilerini ve akma gerilmesi değerlerini elde etmek için $0,01-1000\text{ s}^{-1}$ aralığında akış eğrisi testi uygulanmıştır. Daha sonra, numunelerin doğrusal viskoelastik aralığını (LVR) ve numunelerin katı ve sıvı yapısını belirlemek için 10 rad/s sabit frekansta ve $\%0.01-100$ gerinim aralığında genlik tarama testi yapılmıştır. Numunelerin tahribatsız deformasyonda zamana bağlı davranışını belirlemek için genlik tarama testinden elde edilen LVR aralığındaki sabit gerinimde ($\%0.01$) ve $0.1-100\text{ rad/s}$ aralığında frekans tarama testleri yapılmıştır. Son olarak, numunelerin yapısal yenilenmesini gözlemlenmesi amacıyla üç aralıklı tiksotropi testi (3ITT) yapılmıştır. Reolojik testler sonucunda pektin içermeyen sütün Newtonian özellik gösterdiği, diğer örneklerin kesme incelmeye özelliği gösterdiği ve pektin oranı arttıkça viskozite değerlerinin arttığı belirlenmiştir. Tüm örnekler düşük gerinimlerde katı özelliğe iken, yüksek gerinimlerde sıvı özellik baskın hale gelmektedir. Sütteki pektin oranı arttıkça sıvı özelliğin baskın hale geçtiği akma noktasındaki gerinim değerlerinin de yükseldiği görülmüştür. Pektin oranı en yüksek örnek hariç diğer örneklerde depolama modülünün kayıp modülüne baskınlığının düşük frekanslarda yüksek frekanslara göre daha fazla olduğu gözlemlenmiştir. 3ITT sonucunda, 600 . saniyedeki yapısal yenilenmenin pektin oranı arttıkça arttığı belirlenmiştir.

Anahtar Kelimeler: Pektin, Süt, Reoloji, Gıda

1. INTRODUCTION

Pectin, the structural component of plant cell walls, is an excellent carbohydrate polymer produced from natural sources [1]. Today, the main source of pectin, which is used commercially as a thickener, gelling agent, brightener, stabilizer, and emulsifier, is citrus peel (85.5%), although apple pulp (14%) and sugar beet pulp (0.5%) are also used as sources [2]. Extracted pectin is included as a functional food ingredient in numerous food products because it is a safe, non-toxic substance with low production costs and high availability [3,4]. Pectin has many health and nutritional benefits. As a soluble dietary fiber, it has various beneficial gastrointestinal and physiological effects. With a diet rich in pectin, it is possible to reduce total cholesterol and low-density lipoprotein (LDL) level in the blood without affecting high-density lipoprotein (HDL) levels [5]. Pectin has shown chemoprotective properties

against metastasis [6] of cancer and the growth of primary tumors [7] in many types of cancer, such as colon cancer [8], prostate cancer [9], pancreatic cancer [10], and breast cancer [11].

Rheology studies the flow and deformation of matter under the influence of force. When an external force is applied, the ideal solids deform while the ideal liquids flow. Materials between these two exhibit viscoelastic properties. For the materials to have the desired flow properties, materials called rheology modifiers are added to the fluid [12]. Rheology modifiers are added to many products used in sectors such as food, pharmacy, and cosmetics, according to the requirements of the application, such as food packaging and storage conditions, aroma release, and 3D food printing [13]. In the present study, the effect of adding pectin to milk at different rates on rheological properties, which is essential in the food industry, was examined.

2. MATERIALS AND METHODS

2.1. Materials

Lean milk powder was purchased from Bagdat Baharat (Ankara, Türkiye), and apple pectin (E440) originating from France was purchased from Alfasol (İstanbul, Türkiye). Medium-gelling apple pectin was used in this study. The nutritional values of lean milk powder used in the experiments are given in the table below.

Table 1. Nutrition facts of lean milk powder.

Nutrition facts per 100 g	
Energy	383kcal/1603kJ
Total fat	1.61g
Saturated fat	1.08g
Total carbohydrate	52.10g
Total sugars	48.63g
Fiber	0g
Protein	38.6g
Salt	0.58g

2.2. Sample Preparation

Milk was obtained by adding milk powder to distilled water in a milk powder-to-water ratio of 1:9 (w/v) and mixing at 300 rpm for 40 min. Then, various weights of pectin were added to the resulting milk and mixed at 1000 rpm for 20 min to obtain pectin milk mixtures. The amounts of materials used in the preparation of samples are given in Table 2 and samples are henceforth referred to as MP1, MP2, MP3, MP4, MP5, and MP6.

Table 2. Water, milk powder, and pectin amounts in the samples.

Sample	Distilled water (ml)	Milk powder (g)	Pectin (g)
MP1	18	2	0.2
MP2	18	2	0.5
MP3	18	2	1
MP4	18	2	1.5
MP5	18	2	2
MP6	18	2	3

2.3. Rheological Measurements

Rheological measurements were performed using an MCR 302e rheometer (Anton Paar, Austria) with a 50-mm diameter parallel-plate tool. On the other hand, a 26-mm cup and bob double gap measuring system was used to measure the rheological properties of milk. The flow and viscosity curves were obtained from the rotational test, which was performed at shear rates ranging from 0.01 to 1000 s^{-1} for pectin and milk mixtures and from 1 to 1000 s^{-1} for milk. The duration of a data point decreased logarithmically from 30 s to 1 s for mixtures and linearly from 10 s to 1 s for milk. The rheological tests were preceded by a pre-shear of 20 s at 1 s^{-1} . The amplitude sweep test was carried out at a constant angular frequency of 10 rad/s in a strain range of 0.01 to 100% to record the storage module (G') and loss module (G''). The frequency sweep was performed to obtain G' , G'' and complex viscosity ($|\eta^*|$) in the frequency range of 100 rad/s to 0.1 rad/s and at a constant strain of 0.01%, which was within the linear viscoelastic range determined in the amplitude sweep test. A three interval thixotropy test (3ITT) was conducted to observe the structural breakdown and recovery of samples. In this test, a constant frequency of 10 rad/s and a constant strain of 0.5% (within the linear viscoelastic range) were chosen at intervals of 1 and 3. In interval 2, the sample was sheared for 120 s at a shear rate of 100% and a constant frequency of 10 rad/s. A constant temperature of 25°C was chosen for all experiments. A peltier-controlled temperature system with an active hood was used to control the temperature very precisely and to ensure that the temperature gradient in the samples was $<0.1^\circ C$. RheoCompass (Anton Paar, Austria) software was used to process the results and draw the graphics.

3. RESULTS AND DISCUSSIONS

3.1. Viscosity Measurements

The viscosity curves of the samples obtained from the rotational tests are shown in Figure 1. Samples MP1, MP2, MP3, MP4, MP5 and MP6 showed shear thinning behavior of viscoelastic solids. That is, as the shear rate increased, the viscosity of the

samples decreased. This behavior is an important feature desired in the 3D printing of foods. However, milk that does not contain any pectin showed Newtonian behavior. The viscosity of milk at 25 °C was found to be around 1.9 mPa.s. Compared to the viscosity of water, there was no significant increase in the viscosity of milk obtained by adding milk powder to water with a milk powder/water (w/v) ratio of 1/9. On the other hand, adding pectin to milk, even in low amounts, appears to significantly increase viscosity, and viscosity values increased by increasing the amount of added pectin.

3.2. Amplitude Sweep Tests

Amplitude sweep tests were also applied to obtain the storage modulus (G') and loss modulus (G'') of samples as a function of shear strain (%). G' represents the solid component and G'' represents the liquid component of the sample. As can be seen

from Figure 2, G' is more dominant than G'' in all samples, which shows that the samples have viscoelastic solid properties. The solid feature is most dominant in MP6 and the magnitude of this dominance decreases as the amount of pectin in the samples decreases. Using this test, the linear viscoelastic regions (LVER) of the samples were also determined. The region in the graph where G' exhibits a plateau is referred to as the LVER. In the LVER, the applied stress is not large enough to cause structural distortion of the structure. Beyond the LVER boundary, the sample begins to deform permanently, and the sample stability is not at a level that prevents precipitation within the sample. Therefore, it is of great importance to know the LVER limit of the samples. As the pectin amounts increased, the linear viscoelastic regions of the samples lengthened. While the LVER limit for MP6 was 7.02%, it was 5.37%, 2.91%, 2.07%, and 1.07 for MP5, MP4, MP3, and MP2, respectively. This limit was below 1% for MP1.




Figure 1. Viscosity vs shear rate graph of the samples

Yield stress is the minimum stress required to initiate flow [14]. Yield stress is essential in the design of food packaging and applications such as 3D food printing. For food to come out of its package, it is necessary to apply more stress than shear stress. In extrusion-based 3D printing, the applied stress must exceed the shear stress. While the yield stress of MP6 was found to be 426 Pa, this value was determined to be 93.2 Pa for MP5, 16.89 Pa for MP4, 3.778 Pa for MP3, 0.5543 Pa for MP2, and 0.05347 Pa for MP1. As can be seen, as the pectin ratio in the samples increases, the yield stress

increases. A larger yield stress indicates that the structure is more stable, the layer thickness is higher, and the character is more gel-like. When stress is applied to materials below the yield stress, no significant change is observed in their internal structure. At stresses below the yield stress value, the material exhibits reversible viscoelastic behavior. However, as the shear rate increases, non-covalent interactions in the gel under shear stress are broken, causing the material to exhibit viscous flow.




Figure 2. Amplitude sweep test results of the samples

The point where G' curve intersects with G'' curve is called the flow point. Beyond this point, the G'' value exceeds the G' value and it flows like a liquid. Table 3. shows the shear strain, shear stress, and storage modulus values of the samples at their flow points. While a shear stress of 2229.1 Pa is required for MP6 to flow like a liquid, this value decreases as the pectin rate in the samples decreases. In particular, for MP2 and MP1, the required shear stress reaches values very close to 0.

3.3. Frequency Sweep Tests

Frequency sweep tests were also performed to determine the time-dependent changes in the storage and loss modulus of samples at constant shear strains. The tests were performed between 0.1 and 100 rad/s, and the constant shear strains were within the linear viscoelastic region determined as a result of the amplitude sweep tests. As seen in Figure 3A, because G' values of MP6, MP5, MP4,

and MP3 were higher than their G'' values, the samples exhibited typical gel-like behavior.

Table 3. Shear strain, shear stress, and storage modulus values of the samples at flow points.

Sample	Shear strain (%)	Shear stress (Pa)	Storage modulus (Pa)
MP1	1.38	0.030031	1.5342
MP2	2.08	0.4752	16.151
MP3	10.8	9.8738	64.484
MP4	29.3	99.599	240.48
MP5	49.4	491.67	704.82
MP6	71.9	2229.1	2195.7

The dominance of G' over G'' is higher at low frequencies, except for MP6, and is lower at high frequencies. For MP2, G'' became dominant over G' after a crossover point ($\omega=12.6$ rad/s and $G'=G''=12.99$ Pa), indicating that the sample behaved as a viscoelastic liquid after this point. As the frequency increased, this feature became more evident. Figure B shows the shear-thinning behavior of the samples. As can be seen from Figure 3C, samples with low pectin amounts have more liquid character, while MP6 has the least liquid feature because the more the elastic modulus depends on frequency, the more liquid-like the material is.




Figure 3. Frequency sweep test results: A) storage and loss modulus vs. angular frequency, B) complex viscosity vs. angular frequency and, C) loss factor vs. angular frequency.

3.4. Thixotropy Tests

Under high force, the structural strength of the materials decreases and recovers over a certain period when the force is reduced or removed. In this

study, low shear strain (0.5%) was first applied for 120 s, then high shear strain (100%) was applied for 120 s to ensure that the material undergoes structural deformation, and finally, its regeneration

was investigated by applying 0.5% shear strain for 600 seconds. While all samples showed solid properties in the first interval, i.e., at low shear strain, they exhibited liquid properties when high shear strain was applied in the second interval (Figure 4). As the shear strain is reduced again in the third interval, the G' values of the samples

increase more than G' . While MP1 and MP2 still showed liquid properties in the third region at 600 s, MP3 started to exhibit solid properties again after 435 s. When the shear strain applied in MP4, MP5, and MP6 is reduced to 0.5%, the G' value immediately exceeds G'' . This indicates that these samples exhibit solid properties in the third interval.

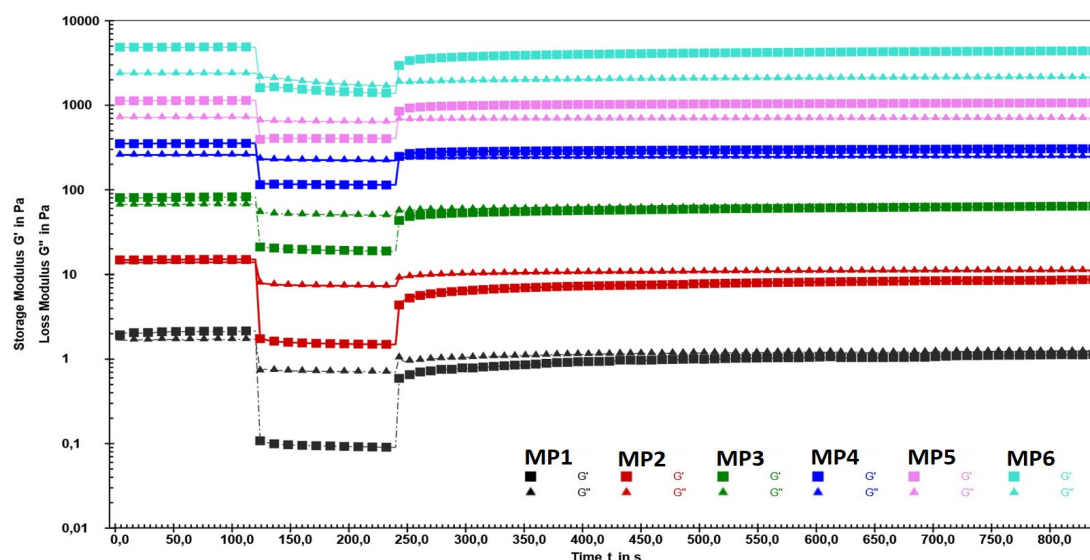


Figure 4. Three interval thixotropy test (3ITT) results of the samples

Recovery values calculated as the percentage of the G' value at the 600th second in the third region corresponding to the G' value at the 120th second, the last data point of the first interval, are given in Table 4. While MP1 had 52.56% recovery at the 600th second, this value increased as the pectin rate increased in the samples, and the recovery value became 89.70% in MP6. Recovery values at 600 s were calculated as 57.75%, 77.38%, 86.37%, and 88.36% for MP2, MP3, MP4, and MP5, respectively.

Table 4. Recovery values of the samples at 600 s.

Sample	Recovery (%) at 600 s
MP1	52.56
MP2	57.75
MP3	77.38
MP4	86.37
MP5	88.36
MP6	89.70

4. CONCLUSION

In this study, flow curve, amplitude and frequency sweep, and thixotropy tests were applied to examine the rheological properties of samples obtained by mixing milk and pectin in different ratios. From the flow curve test, it was observed that the milk had Newtonian properties and, with the addition of pectin, it exhibited shear thinning, which is a desired feature in applications such as 3D printing. It was observed that viscosity values increased significantly as the amount of pectin added increased. Yield stress, which is important for applications such as food packaging design and 3D printing, was calculated to be highest in MP6 with 426 Pa. As the amount of pectin mixed into the same amount of milk increased, the flow point, which is the point where the material turns into liquid, was observed at higher shear strain values. Shear strain and storage modulus values also

increase with the amount of pectin. This means that samples with high pectin content must be exposed to more stress to show liquid properties. While samples containing low pectin appear to have liquid character at high frequencies, all samples are solid-like at low frequencies. This shows that it will exhibit solid properties during shelf waiting time, which is especially important for food products. While the recovery percentages at 600 s increased as the pectin amounts in the samples increased and reached 86.37% in MP4, the addition of more pectin increased the recovery value slightly and reached 89.70% in MP6.

5. ACKNOWLEDGEMENTS

This research was supported by the Çukurova University Scientific Research Projects Coordination Unit (Project Numbers: FAY-2022-14493 and FBA-2019-12182).

6. REFERENCES

1. Mishra, S. K., Agrawal, D., 2012. Introduction A Concise Manual of Pathogenic Microbiology, 1-7.
2. Ciriminna, R., Fidalgo, A., Delisi, R., Ilharco, L.M., Pagliaro, M., 2016. A Pectin Production and Global Market. *Agro Food Industry Hi Tech*, 27(5), 17-20.
3. Willats, W.G.T., Knox, J.P., Mikkelsen, J.D., 2006. Pectin: New insights Into an Old Polymer are Starting to Gel. *Trends Food Sci Technol*, 17, 97-104.
4. Martau, G.A., Mihai, M., Vodnar, D.C., 2019. The use of Chitosan, Alginate, and Pectin in the Biomedical and Food Sector-biocompatibility, Bioadhesiveness, and Biodegradability Polymers, 11, 1837.
5. Gunness, P., Gidley, M.J., 2010. Mechanisms Underlying the Cholesterol-lowering Properties of Soluble Dietary Fibre Polysaccharides. *Food Funct*, 1, 149-155.
6. Cheewatanakornkool, K., Niratisai, S., Dass, C.R., Sriamornsak, P., 2018. Redox-responsive Microbeads Containing Thiolated Pectin-doxorubicin Conjugate Inhibit Tumor Growth and Metastasis: An in Vitro and in Vivo Study. *Int J Pharm*, 545, 1-9.
7. Lara-Espinoza, C., Carvajal-Millán, E., Balandrán-Quintana, R., López-Franco, Y. Rascón-Chu, A., 2018. Pectin and Pectin-based Composite Materials: Beyond Food Texture. *Molecules*, 23(4), 942.
8. Prado, S.B.R., do Santos, G.R.C., Mourão, P.A.S., Fabi, J.P., 2019. Chelate-soluble Pectin Fraction from Papaya Pulp Interacts with Galectin-3 and Inhibits Colon Cancer Cell Proliferation. *Int J Biol Macromol*, 126, 170-178.
9. Keizman, D., Frenkel, M., Peer, A., Kushnir, I., Rosenbaum, E., Sarid, D., Leibovitch, I., Mano, R., Yossepowitch, O., Margel, D., Wolf, I., Geva, R., Dresler, H., Rouvinov, K., Rapoport, N., Eliaz, I., 2021. Modified Citrus Pectin Treatment in Non-metastatic Biochemically Relapsed Prostate Cancer: Results of a Prospective Phase II Study. *Nutrients*, 13(12), 4295.
10. He, F., Zhang, S., Li, Y., Chen, X., Du, Z., Shao, C., Ding, K., 2021. The Structure Elucidation of Novel Arabinogalactan LRP1-S2 Against Pancreatic Cancer Cells Growth in Vitro and in Vivo. *Carbohydr Polym*, 267, 118172.
11. Delphi, L., Sepehri, H., 2016. Apple Pectin: A Natural Source for Cancer Suppression in 4T1 Breast Cancer Cells in Vitro and Express p53 in Mouse Bearing 4T1 Cancer Tumors, in Vivo. *Biomedicine & Pharmacotherapy*, 84, 637-644.
12. Braun, D.D., Rosen, M.R., 2000. *Rheology Modifiers Handbook-Practical use and Application*, New York.
13. Freitas, C.M.P., Coimbra, J.S.R., Souza, V.G.L., Sousa, R.C.S., 2021. Structure and Applications of Pectin in Food, Biomedical, and Pharmaceutical Industry: A Review. *Coatings*, 11(8), 922.
14. Ozbolat, V., Dey, M., Ayan, B., Ozbolat, I.T., 2019. Extrusion-based Printing of Sacrificial Carbopol Ink for Fabrication of Microfluidic Devices. *Biofabrication*, 11(3), 034101.

Kompakt Penye İplik Üretiminde Kopça Türünün İplik Kalitesine ve Kopça Ömrüne Etkileri

Pınar DURU BAYKAL*¹ ORCID 0000-0003-1461-2203
Özgür AKBAŞ² ORCID 0009-0002-3650-2697

¹Çukurova Üniversitesi, Mühendislik Fakültesi, Tekstil Mühendisliği Bölümü, Adana
²Palmiye Tekstil, Adana

Geliş tarihi: 05.03.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: DURU BAYKAL, P., AKBAŞ, Ö., (2024). Kompakt Penye İplik Üretiminde Kopça Türünün İplik Kalitesine ve Kopça Ömrüne Etkileri. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 415-426.

Öz

Ring iplik manikalarının en önemli elemanlarından olan kopçalar, iplik kopuşlarını doğrudan etkilediği için maliyete ve kaliteye etki eden bir faktör olarak göz önünde tutulmalıdır. Bu çalışmada kaplama malzemesi, tel profili ve ağırlık bakımından farklı kopçalar kullanılarak üretim parametreleri sabit tutularak ring kompakt penye iplik üretimi gerçekleştirilmiştir. Üretilen ipliklerin kalite testleri yapılarak, sonuçlar kopça türlerine göre değerlendirilmiştir. Üretim esnasında kopça ömürleri de tespit edilmiştir. Kopçalar genel olarak değerlendirildiğinde; tel profili UDR olan safir kaplama kopça en uzun ömürlü kopça olmuştur. Bu kopçanın, bilezik hareket yolundaki genişletilmiş temas yüzeyi ve kaplama türü, yüksek iğ devrinde yüksek performans sağlamıştır.

Anahtar Kelimeler: Ring iplik, Kopça, Kopça ömrü, İplik kalitesi, Penye iplik, Kompakt iplik

Effects of Traveller Type on Yarn Quality and Traveller's Life Time in the Spinning of Compact Combed Yarn

Abstract

Travellers, one of the most important elements of ring spinning machines, should be taken into consideration as a factor affecting cost and quality, as they directly affect yarn breaks. In this study, ring compact combed cotton yarn was produced by using different travellers in terms of coating material, wire profile and weight, keeping the production parameters constant. Quality tests of the produced yarns were carried out and the results were evaluated according to traveller types. Traveller's life time was also determined during production. When the travellers are evaluated in general; the sapphire coated traveller with UDR wire profile has become the longest life time traveler. The extended contact surface on the ring movement path and coating type of this traveler provide high performance at high spindle speed.

Keywords: Ring yarn, Traveller, Traveller's life time, Yarn quality, Combed yarn, Compact yarn

*Sorumlu yazar (Corresponding Author): Pınar DURU BAYKAL, pduru@cu.edu.tr

1. GİRİŞ

1828’de icat edilen ring eğirme teknolojisi, 1800’lü yıllardan bu yana iplik üretiminde kullanılmakta ve günümüzde kısa elyaf iplikçiliğinde pazar payı en yüksek teknoloji olarak varlığını korumaktadır. 1970’lerin sonlarından bu yana ring iplik makinasının verimliliği % 40 arttırılmıştır. Bu artış; daha küçük bilezikler ve kopslar kullanılarak, bileziklerde ve kopçalarda önemli gelişmeler sağlanarak ve otomasyonun arttırılması ile gerçekleştirilmiştir [1,2].

Ring iplik makinelerinde ipliğe verilen büküm, iğ-bilezik-kopça üçlüsü ile sağlanmaktadır. İpliğin masuraya sarılırken içinden geçtiği, ipliğe gerginlik veren ve aynı zamanda iğle birlikte bükümü sağlayan metalik veya plastik parçaya **kopça** adı verilmektedir. Bilezik, ring iplik makinesinde iğ etrafındaki halkadır ve kopçanın dönüş yolunu oluşturmaktadır. Kopça bileziğe takılıdır ve iplik aracılığı ile sürüklenerek dönmektedir. Kopça-bilezik arasındaki sürtünme, iğ devrini sınırlamakta ve yüksek hızlara çıkılmasına engel olmaktadır. Çelik kopçalara yüzey kaplama işlemleri uygulanarak sürtünmeye ve aşınmaya karşı direnç kazandırılmaktadır. Kullanılan elyaf özelliklerine, iplik numarasına, üretim hızına bağlı olarak kullanılan kopça türü değişebilmektedir. Kopça türü; şekil, tel profili, kütle ve kaplama bakımından farklılık göstermektedir [3].

Kopçada olması gereken temel özellikler aşağıda verilmiştir.

- Mevcut bilezik formuna uygun olmalı, bilezik ile iyi bir temas yüzeyi bulunmalı,
- Mümkün olduğunca az ısı oluşturmali, iyi bir ısı transferine sahip olmalı (sürtünmeden kaynaklanan sıcaklığın çabucak bileziğe ve havaya transfer edebilmeli),
- Pürüzsüz çalışma yüzeyi olmalı,
- Kopçanın bileziğin üzerine kırılmadan bastırabilmesi için elastik olmalı,
- Bileziği aşındırmaması için bilezikten biraz daha yumuşak malzemedan yapılmış olmalı,
- Kopçayı elyaf uçtusundan koruyan, doğru ayarlanmış olan uygun kopça temizleyicileri kullanılmalı,
- Yüksek aşınma dayanımına sahip olmalıdır [3].

Kopçanın kütlesi, bilezik ile kopça arasındaki sürtünme kuvvetini ve balon gerginliğini belirleyen önemli bir etkidir. Eğer kopça belirli bir iplik numarası için çok hafifse iplik üzerinde oluşturulan gerilim düşük olacak ve bu da gevşek, yumuşak bir şekilde sarılmış kops ile sonuçlanacak ve ayrıca iplik balonu da geniş olacaktır. Diğer yandan çok yüksek kopça kütlesi yüksek iplik gerginliğine ve daha sık iplik kopuşlarına neden olur. Kopça numarası ISO’ya göre 1000 adet kopçanın gram olarak ağırlığıdır [3].

Kopça, ring iplik makinelerinin en önemli elemanlarından biridir. Kopçalar, iplik kopuşlarını doğrudan etkilediği için maliyete ve kaliteye etki eden bir faktör olarak göz önünde tutulmalıdır. Literatürde ring iplik üretiminde kopça ile ilgili yapılmış birçok çalışma vardır. Bunlardan bazıları aşağıda verilmiştir.

Farklı ağırlık, tip ve kaplamalardaki kopçaların mikroliflerden eğrilen akrilik ipliklerin tüylülüğüne etkileri araştırılmıştır [4]. Farklı büküm seviyelerinde ve farklı kopça ağırlıklarında üretilen ring ve kompakt ipliklerin performans özellikleri karşılaştırılmıştır [5]. Çalışmada Flanş1 ve Flanş2 bileziklerle, farklı ağırlık ve farklı kaplama türünde, M tipi, dr ve f olmak üzere 2 ayrı tel kesitinde kopçalar kullanılarak iplik üretimi gerçekleştirilmiş ve ipliklerin fiziksel testleri yapılmıştır. Kopça ağırlık artışı genel olarak iplik özelliklerini iyileştirmiştir. Ayrıca f profilli kopçalarda tüylülük genel olarak dr kesitli kopçalardan daha yüksek çıkmıştır [6]. İki farklı ağırlıkta kopça kullanılarak ve 5 farklı karışım oranında Ne 16/1 PES/CO karışımı ipliklerin üretildiği çalışmada, değişen karışım oranlarının ve değişen kopça ağırlıklarının iplik tüylülüğü üzerine etkileri incelenmiştir. Kopça ağırlığının artışıyla iplik tüylülüğünün azaldığı ve diğer iplik özelliklerinin ise pek değişmediği görülmüştür [7]. Farklı inceliklerde pamuklu çorap iplikleri için uygun kopça numarasının seçimine yönelik olarak yapılan çalışmada, iplik tüylülüğü, düzgünsüzlük, iplik hataları ve 1000 iğ-saat başına uç kopma oranı değerlendirilmiştir [8]. İplik numarası, büküm faktörü, iğ hızı, kopça ağırlığı ve ön silindir çapının iplik kesitindeki lif paketleme yoğunluğu üzerindeki etkisi analiz edilmiştir [9]. Ring iplik eğirme sisteminde üretim hattı ve kopça

ağırlığının iplik özelliklerine etkisi incelenmiştir. Nikel kaplama, 3 farklı ağırlıkta, El 1 hd EM kopçalar kullanılmıştır. Kopça ağırlığının artması penye ipliklerin hata sayısı ve tüylülük değerlerini, karde ipliklerde de tüylülük ve kopma kuvveti değerlerini olumlu etkilemiştir [10]. Her bir katlanmış iplik tipini (ring/ring, kompakt/kompakt ve ring/kompakt) üretmek için, üç büküm (TPM) seviyesi ve üç kopça ağırlığı seviyesi seçilerek yürütülen çalışmada, katlanmış iplikten süprem örgülerin iplik bükümüne ve kopça ağırlığına bağlı olarak termal özelliklerindeki değişimler tartışılmıştır [11].

Çalışmada, Cr kaplamalı ve kaplamasız olmak üzere iki tür kopçanın yüzey özellikleri SEM görüntüleri ile incelenmiştir. Ayrıca kopça kaplamanın iplik özellikleri üzerindeki etkilerini görmek amacıyla bu kopçalar kullanılarak üretilen ipliklerin tüylülüğü ölçülmüştür [12]. Kısa elyaf ring iplik makinelerinde enerji tüketimini etkileyen faktörlerden biri olarak öngörülen kopça ömrünün enerji tüketimine etkisinin incelendiği çalışmada, kopçanın 12-13 günlük kullanım ömrü boyunca 1 kg iplik üretimi için tüketilen enerji miktarı analiz edilmiştir. Yapılan değerlendirmeler sonucunda; kopça kullanım süresinin artmasıyla birlikte enerji tüketiminin, kopçanın 1. günü ile son günü arasında %7,7-13,3 civarında artış gösterdiği gözlemlenmiştir [13]. Farklı markalara ait iki adet aynı numarada kopça kullanılarak ve üretim sırasında tüm işlem parametreleri aynı tutularak Ne 30 numarada iplikler üretilmiştir. Kopça yapısı ve

malzeme özelliklerinin iplik özellikleri üzerinde etkili olduğu belirtilmiştir [14]. Ne 30 numara karde iplik için uygun kopça seçimine yönelik olarak yapılan çalışmada, iplik kalite parametrelerinin uygun kopça ağırlığı seçimiyle iyileştirilebileceği ifade edilmiştir. 5/0 kopçanın, 4/0 kopçaya göre optimum tüylülük, düzgünlük, mukavemet ve uzama değerleri verdiği vurgulanmıştır [15]. Bir başka çalışmada, ring eğirme sırasında kopça ağırlığı, iplik numarası, büküm seviyesi ve iğ hızının kopça ve bilezik sıcaklıkları üzerindeki etkisi modellenmiştir. Aşırı kopça ısısının, iğ hızını ve iplik üretiminin verimliliğini sınırlayacağı vurgulanmıştır [16].

Bu çalışmanın amacı; ring kompakt penye iplik üretimi için seçilen üç farklı kopça türünün hem iplik kalite özelliklerine etkilerini araştırmak hem de bu kopçaların kullanım ömürlerini değerlendirerek karşılaştırmaktır. Böylece kompakt iplik üretiminde, yüksek iğ devirlerinde optimum bilezik-kopça eşleşmesi ile aynı zamanda maksimum kopça ömrü hedeflenmiştir.

2. MATERYAL VE METOT

2.1. Materyal

Çalışmada hammadde olarak Yunanistan sawgin pamuğu kullanılmıştır. Dört ayrı balyadan alınan pamuk numunelerinin, Premier Art2 High Volume Cotton Tester cihazı ile ölçülen kalite değerleri Çizelge 1’de verilmiştir.

Çizelge 1. Pamuk kalite değerleri

Numune no	UHML	UI	STR	ELG	MIC	Rd	+b	CG	T.CNT	T.AREA
1	29,06	84,5	31,0	6,8	4,08	76,4	9,4	21 4	66	0,43
2	29,67	84,6	33,3	6,8	3,78	76,2	9,4	21 4	72	0,55
3	29,19	83,1	32,0	6,9	3,95	76	9,4	31 3	90	0,55
4	29,52	82,5	31,6	6,8	4,02	76,4	9,4	21 4	84	0,54
Ortalama	29,36	83,68	31,98	6,83	3,96	76,3	9,4	21 4	78	0,52

Test sonuçlarına göre çalışmada kullanılan pamuk elyafı, mikroner değerine göre ince, lif uzunluğuna göre orta uzunlukta, renk ve temizlik derecesi bakımından ise beyaz ve temiz sınıfta yer almaktadır. Ayrıca lif mukavemetine göre çok sağlam, üniformite indeksi yüksek, kopma uzaması yüksektir.

2.2. Metot

Ring kompakt penye iplik üretim hattı aşağıda özetlenmiştir.

- Harman-Hallaç
- Tarak


- I.Pasaj Cer
- Votka
- Penyöz
- II. Pasaj Cer
- Fitol
- Ring-Kompakt

Ring Kompakt K-45 iplik makinesinin üretim parametreleri Çizelge 2’de verilmiştir.

Çizelge 2. İplik makinası üretim parametreleri

İplik No	Ne 30/1
İplik Türü	Penye triko
İğ Devri (d/dk)	20800
Büküm katsayısı (a_e)	3,10
Fitol No	Ne 0,74
Bilezik Türü	Flanş 1, T
Bilezik Çapı (mm)	38
Kopça Türü	C1 HD TW 3/0
	C1 HR TW 3/0
	C1 EL UDR 4/0

Çalışmada kullanılan bilezik, Bräcker Titan olup yüzey alanı Flanş 1 ve T tipidir. Kopça şekli seçimi son derece önemli olup, bilezik şekli ve iplikle tam olarak koordine edilmesi gerekir. T şeklinde bilezik ile C şeklinde kopçalar yaygın olarak kullanıldığından ve C kopçalar, çok düşük ağırlık merkezi sayesinde düzgün çalışma sağladığından bu çalışmada C tipi kopça seçilmiştir. T flanşlı bilezik için C şeklinde kopçaların, bilezik yüzeyine temas alanı nokta şeklindedir (Şekil 1). Kopça, çalışma sırasında kendisini yüke göre optimum şekilde ayarlar [17].




Şekil 1. T flanşlı bilezik ve C kopça

Özellikle yüksek performanslı kopçalarda şeklin yanı sıra tel profili, malzeme ve yüzey kaplaması seçimi de önemlidir. Yanlış seçim yapılırsa iplikte istenmeyen düzeyde gerilme meydana gelmekte ve

bu durum iplik tüylülüğüne, kalın yer oluşumuna, iplik kopuşlarına yol açabilmektedir [17].

Çalışmada kullanılan kopçaların tel profilleri HD, HR ve UDR olarak isimlendirilmekte ve Şekil 2’de gösterilmektedir [18]. Seçilen tel profilleri, bilezik hareket yolunda genişletilmiş temas yüzeyine sahiptir ve bu nedenle yüksek performans öngörülmektedir. Ayrıca söz konusu tel profilleri, çalışılan hammaddeye de uygun olarak seçilmiştir.



Şekil 2. Çalışmada kullanılan kopçaların tel profilleri

Tüm kopçaların hammaddesi çelik olup, C1 HD TW ve C1 HR TW kopçalara özel nikel kaplama, C1 EL UDR kopçalara ise özel safir kaplama yapılmıştır.

Kopça numaraları 3/0 (ISO’ya göre 40 mg) ve 4/0 (ISO’ya göre 35.5 mg) olarak çalışılan hıza ve iplik numarasına göre seçilmiştir.

Üretilen kopslardan numuneler alınarak iplik testleri yapılmıştır. Numuneler, aynı ring kompakt iplik makinasının 817–826 arasındaki 10 iğinden alınmış olup, bu iğlerin günlük kontrolleri ve rutin bölgesel temizlikleri yapıлып, dış etkenlerin çalışmaya etkisi minimuma indirilmeye çalışılmıştır. Kullanılan kopçaların rodaj süresi 16 saattir. Rodaj bittikten sonra kopslar alınarak kalite kontrol testleri yapılmıştır.

İplik mukavemet ve uzama testleri “Premier TensoMaxx5” cihazı ile 500 mm test uzunluğunda ve 5000 mm/dk test hızında ölçülmüştür. İplik düzgünlüğü (CVm), iplik hataları ve tüylülük (HI) testleri ise “Premier IQ5” cihazıyla 400 m/dk test hızında yapılmıştır.

3. ARAŞTIRMA BULGULARI

3.1. C1 HD TW 3/0 Kopça ile Yapılan Üretim Sonuçları

Tüm kopçaların rodajı bittikten sonra 2.günden itibaren üretilen kopslardan numune alınarak testler

yapılmıştır. 7. günde C1 HD TW 3/0 kopçalar incelendiğinde; kopça üzerinde çizikler, kılcal çatlamlar, elyaf toplanması ve hatta kaplamanın ayrılması görülmüştür. Üretimde çok fazla kopuşa sebebiyet verdiği için deneme 7. günde sonlandırılmıştır. İplik test sonuçları her gün için 10 kopsun ortalaması olarak Çizelge 3'te verilmiştir.

Çizelge 3. C1 HD TW 3/0 kopça için 7 günlük ortalama kalite değerleri

Kopça çalışma süresi	% CVm	İnce yer (-30%) /Km	İnce yer (-50%) /Km	Kalın yer (+35%) /Km	Kalın yer (+50%) /Km	Neps (+200%) /Km	HI	% Uzama	Rkm
2.gün	11,44	504,7	0,3	123,9	6,7	10,3	2,46	4,76	17,46
3.gün	11,43	517,9	0,3	137,4	6,8	8,6	2,47	4,74	17,09
4.gün	11,48	528,6	0	141,7	7,4	10,1	2,47	4,72	17,45
5.gün	11,37	482,0	0,3	127,8	7,1	11,2	2,66	4,82	17,39
6.gün	11,62	557,9	0	151,7	7,4	12,3	2,57	4,59	17,10
7.gün	11,54	508,5	0	149,3	7,3	10,3	2,47	4,38	17,11
Ortalama	11,48	516,6	0,15	138,63	7,12	10,47	2,52	4,67	17,27
St.sapma	0,09	25,52	0,16	11,22	0,31	1,23	0,08	0,16	0,18

Ayrıca tüm günlerin ortalaması ve standart sapması da çizelgede gösterilmiştir. C1 HD TW 3/0 kopça ile üretilen ipliklerin kalite değerleri 2.günden 7.güne genel olarak benzer eğilim göstermiştir.

3.2. C1 HR TW 3/0 Kopça ile Yapılan Üretim Sonuçları

C1 HR W 3/0 kopça ile üretilen ipliklerin test sonuçları 2. günden 9. güne olmak üzere Çizelge 4'te verilmiştir.

Çizelge 4. C1 HR TW 3/0 kopça için 9 günlük ortalama kalite değerleri

Kopça çalışma süresi	% CVm	İnce yer (-30%) /Km	İnce yer (-50%) /Km	Kalın yer (+35%) /Km	Kalın yer (+50%) /Km	Neps (+200%) /Km	HI	% Uzama	Rkm
2.gün	11,27	524,5	0	148,4	14,2	19,3	2,05	5,07	17,83
3.gün	11,26	543,3	0	138,5	10,8	23,0	2,00	4,94	17,50
4.gün	11,28	553,8	0	155,6	10,4	19,3	2,01	5,09	17,43
5.gün	11,27	547,8	0	136,2	10,1	17,8	1,67	5,09	17,67
6.gün	11,21	516,6	0	129,9	6,3	15,4	1,88	5,30	17,99
7.gün	11,43	576,1	0,8	163,3	12,6	21,8	1,87	4,94	17,38
8.gün	11,34	558,5	0	156,0	11,5	25,8	1,89	5,09	17,31
9.gün	11,27	545,8	0	158,5	11,1	20,8	1,75	5,08	17,56
Ortalama	11,29	545,8	0,1	148,3	10,88	20,4	1,89	5,08	17,58
St.sapma	0,07	18,75	0,28	12,09	2,28	3,21	0,13	0,11	0,23

Dokuzuncu günde, kopçalar incelendiğinde; kopça üzerinde çizikler, kılcal çatlamlar, elyaf toplanması ve hatta kaplamanın ayrılması görülmüş, bu durum çok fazla kopuşa sebebiyet

verdiği için deneme sonlandırılmıştır. C1 HR W 3/0 kopça ile üretilen ipliklere yapılan kalite testleri sonucunda 2. ve 9. günler arasındaki değerlerde çok büyük farklılıklar görülmemiştir.

3.3. C1 EL UDR 4/0 Kopça ile Yapılan Üretim Sonuçları

C1 EL UDR 4/0 kopça ile üretilen ipliklerin test sonuçları 2. günden 11. güne olmak üzere Çizelge 5'te verilmiştir. Kopçanın 11. gününden itibaren iplik kopuşlarında artışlar olmuş ve deneme 11. gününde sonlandırılmıştır. Ancak diğer kopçalarda görülen deformasyonlara rastlanmamıştır.

C1 EL UDR 4/0 kopça ile üretilen ipliklere yapılan

kalite testleri sonucunda bazı değerlerde bir miktar artış gözlenmekle birlikte sonuçlar benzerdir.

Kopçalar genel olarak değerlendirildiğinde; C1 EL UDR 4/0 en uzun ömürlü (11 gün) kopça olmuştur. Bu kopçanın tel profili (udr), bilezik hareket yolundaki genişletilmiş temas yüzeyi ile yüksek iş devrinde yüksek performans sağlamıştır. Yine bu kopçada kullanılan safir kaplama yüksek performanslı kopçalar için geliştirilmiştir.


Çizelge 5. C1 EL UDR 4/0 kopça için 11 günlük ortalama kalite değerleri

Kopça çalışma süresi	% CVm	İnce yer (-30%) /Km	İnce yer (-50%) /Km	Kalın yer (+35%) /Km	Kalın yer (+50%) /Km	Neps (+200%) /Km	HI	% Uzama	Rkm
2.gün	11,48	732,1	0	160,4	9,7	19,3	2,37	4,89	17,20
3.gün	11,55	767,8	0,6	165,4	10,7	15,6	2,38	4,96	17,68
4.gün	11,46	717,4	0	175,9	12,3	20,1	2,36	4,72	17,48
5.gün	11,49	723,8	0,3	167,1	13,2	18,3	2,34	4,72	17,45
6.gün	11,51	751,2	0,3	166,8	10,5	17,1	2,38	4,72	16,83
7.gün	11,62	806,2	0	189,7	10,7	20,7	2,39	4,74	16,82
8.gün	11,59	747,7	0,6	196,9	14,8	22,7	2,38	4,81	16,77
9.gün	11,61	774,4	0,3	180,2	13,1	20,0	2,37	4,63	16,60
10.gün	11,65	777,6	0,9	195,9	11,9	23,3	2,36	4,73	16,88
11.gün	11,69	816,5	0	189,6	10,3	23,1	2,37	4,73	17,01
Ortalama	11,57	761,47	0,3	178,79	11,72	20,02	2,37	4,77	17,07
St.sapma	0,08	33,36	0,32	13,60	1,62	2,57	0,01	0,10	0,36

Kopçanın iplik kalite parametrelerine, özellikle tüylülük üzerine büyük etkisi vardır [8]. Çalışmada kullanılan kopçalar ile elde edilen tüylülük değerleri düşük ve birbirine yakındır. İş devri arttıkça iplik tüylülüğünün arttığı bilinmektedir. Çalışmadaki iş devri yüksektir ancak kompakt sistem sayesinde tüylülük azaltılmıştır.

3.4. İplik Düzgünsüzlüğü (%CV) Bakımından Genel Değerlendirme

Kopça türlerinin ölçülen iplik düzgünsüzlüğü değerleri kopça ömürlerine göre Şekil 3'te toplu olarak verilmiştir.



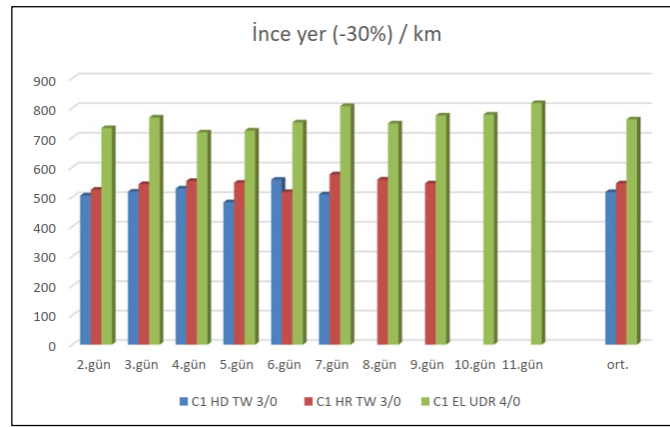
Şekil 3. Kopça türünün iplik düzgünsüzlüğü üzerindeki etkisi

Şekilde, kopça türleri arasında ve ayrıca kopçaların çalışma günleri arasında düzgünlük değerleri açısından farklılıklar olduğu açıkça görülmektedir. Genel olarak çalışma süreleri arttıkça düzgünlük değerlerinde bir miktar artış gözlenmektedir. Ortalama olarak en düşük düzgünlük değerini veren kopça C1 HR TW 3/0 olmuştur. Ortalama düzgünlük değerleri **Uster İstatistikleri 2023**'e göre değerlendirildiğinde, C1 HD TW 3/0 kopçalar %54, C1 HR TW 3/0 kopçalar %49, C1 EL UDR

4/0 kopçalar %57 kalite seviyesinde çıkmıştır. Buna göre tüm kopçaların Uster kalite değerleri birbirine yakındır.

3.5. İplikte İnce Yer Hatası Bakımından Genel Değerlendirme

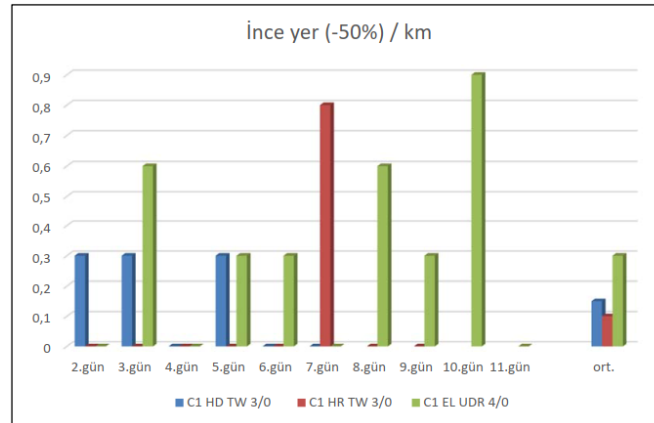
Farklı kopçalar ile üretilen ipliklerin ince yer hataları kopça ömürlerine göre Şekil 4 ve 5'te verilmiştir.



Şekil 4. Kopça türünün iplikte ince yer hatası (-30%) üzerindeki etkisi

Ortalama olarak en düşük ince yer sayısını veren kopça -30% için C1 HD TW 3/0 olurken, -50% için ise C1 HR TW 3/0 olmuştur. Ortalama ince yer hataları (-50%) **Uster İstatistikleri 2023**'e göre değerlendirildiğinde, C1 HD TW 3/0 kopçalar %25, C1 HR TW 3/0 kopçalar %5, C1 EL UDR

4/0 kopçalar %38 kalite seviyesinde çıkmıştır. Buna göre C1 HR TW 3/0 kopçalar, ince yer hatası bakımından en kaliteli iplikleri üretmektedir. Uster İstatistiklerinde, -30% ince yer hatası için değerlendirme bulunmamaktadır




Şekil 5. Kopça türünün iplikte ince yer hatası (-50%) üzerindeki etkisi


3.5. İplikte Kalın Yer Hatası Bakımından Genel Değerlendirme

Kalın yer hataları, kopça türlerine ve kopça ömürlerine göre Şekil 6 ve 7’de verilmiştir. Ortalama olarak en düşük kalın yer sayısını veren kopça C1 HD TW 3/0 olurken, en yüksek kalın yer hatası C1 EL UDR 4/0 kopça ile elde edilmiştir. Ortalama kalın yer hataları (+35%) Uster İstatistikleri 2023’e göre değerlendirildiğinde, C1

HD TW 3/0 kopçalar %44, C1 HR TW 3/0 kopçalar %47, C1 EL UDR 4/0 kopçalar %58 kalite seviyesinde çıkmıştır ve genel olarak yakın kalite seviyelerindedirler. Uster İstatistikleri 2023’e göre (+50%) kalın yer hataları değerlendirildiğinde, C1 HD TW 3/0 kopçalar %15, C1 HR TW 3/0 kopçalar %38, C1 EL UDR 4/0 kopçalar %42 kalite seviyesinde olup, burada C1 HD TW 3/0 kopçalar, ilk %15’lik kalite dilimi ile diğerlerinden belirgin olarak ayrılmaktadır.



Şekil 6. Kopça türünün iplikte kalın yer hatası (+35%) üzerindeki etkisi




Şekil 7. Kopça türünün iplikte kalın yer hatası (+50%) üzerindeki etkisi

3.6. İplikte Neps Hatası Bakımından Genel Değerlendirme

Neps hataları, kopça türlerine ve kopça ömürlerine göre Şekil 8’de verilmiştir. Ortalama olarak en düşük neps sayısını veren kopça C1 HD TW 3/0 olmuştur. Ortalama neps sayıları Uster

İstatistikleri 2023’e göre değerlendirildiğinde, C1 HD TW 3/0 kopçalar %12, C1 HR TW 3/0 kopçalar %38, C1 EL UDR 4/0 kopçalar %37 kalite seviyesinde çıkmıştır. C1 HD TW 3/0 kopçalar neps bakımından en kaliteli iplikleri üretmiştir, diğer kopçaların Uster kalite dilimleri arasında fark yoktur.




Şekil 8. Kopça türünün iplikte neps hatası (+200%) üzerindeki etkisi

3.7. İplik Tüylülüğü Bakımından Genel Değerlendirme

Farklı kopça türleri ile üretilen kompakt penye ipliklerin tüylülük değerleri kopça ömürlerine göre Şekil 9'da verilmiştir. Ortalama olarak en düşük tüylülük değerini veren kopça C1 HR TW 3/0

olmuştur. Ancak kopçaların ortalama iplik tüylülüğü değerleri Uster İstatistikleri 2023'e göre değerlendirildiğinde, tüm kopçalar %5'lik kalite seviyesinde çıkmıştır. Bu durumda kopça türü tüylülük kalite parametresi açısından fark yaratmamıştır.

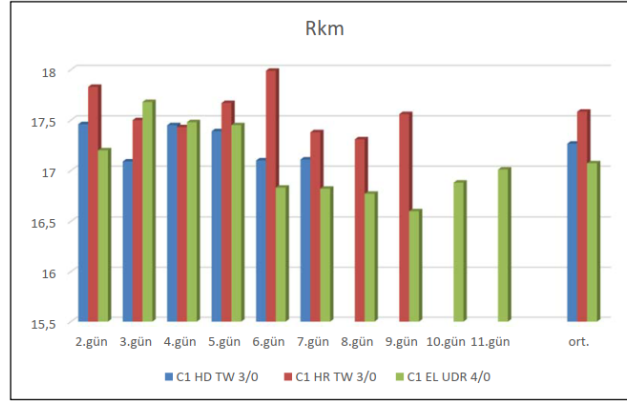


Şekil 9. Kopça türünün iplik tüylülüğü üzerindeki etkisi

3.8. İplik Kopma Mukavemeti Bakımından Genel Değerlendirme

Kopça türlerinin kopma mukavemeti değerleri kopça ömürlerine göre Şekil 10'da verilmiştir. Ortalama olarak en yüksek mukavemet değerini veren kopça C1 HR TW 3/0 olmuştur. Ancak

kopçaların ortalama iplik mukavemeti değerleri Uster İstatistikleri 2023 esas alınarak değerlendirildiğinde, tüm kopçalar %95'lik kalite seviyesinin üzerinde çıkmıştır. Bu durumda kopça türü mukavemet açısından fark yaratmamış olup, iplikler Uster istatistiklerine göre en düşük kalite diliminde yer almıştır.




Şekil 10. Kopça türünün iplik kopma mukavemeti üzerindeki etkisi

3.9. İplik Kopma Uzaması Bakımından Genel Değerlendirme

Kopça türlerinin kopma uzaması değerleri kopça ömürlerine göre Şekil 11'de verilmiştir. Ortalama uzama değerleri Uster İstatistikleri 2023'e göre

değerlendirildiğinde, C1 HD TW 3/0 kopçalar %74, C1 HR TW 3/0 kopçalar %55, C1 EL UDR 4/0 kopçalar %69 kalite seviyesinde çıkmıştır. Ortalama olarak en yüksek uzama değerini ve en iyi kalite dilimini veren kopça C1 HR TW 3/0 olmuştur.



Şekil 11. Kopça türünün iplik kopma uzaması üzerindeki etkisi

3.10. Kopça Ömrü Bakımından Genel Değerlendirme

Çalışmada kullanılan C1 EL UDR 4/0, en uzun ömürlü kopça olurken onu sırasıyla C1 HR TW 3/0 ve C1 HD TW 3/0 izlemiştir (Şekil 12).


Kısa elyaf iplikçiliğinde, bilezik/kopça sistemi, aktif bir yağlama maddesinin eklenmediği "kuru yağlama" koşulları altında çalışır. Bilezik ve kopça arasındaki gerekli yağlama maddeleri elyaf

tarafından sağlanır. Pamukta, elyaf parçaları ve doğal pamuk mumu, yağlama filmi oluşturur. Düşük (dar) iplik boşluğuna sahip kopçalar iyi yağlama sağlarken geniş iplik boşluğu daha az yağlama oluşturur. Yetersiz yağlamada ise kopça aşınması artar [17].

Kompakt ipliklerde, iplik tüylülüğü son derece düşük olduğundan yağlama için gereksinim duyulan elyaf uçları büyük ölçüde mevcut değildir. Elyaf yağlama filminin yetersiz olmasından dolayı,

kompakt iplik eğrilmesinde bilezik-kopça sürtünmesi geleneksel ipliklerdekinden yüksektir. Bu nedenle kompakt iplik eğirmede yağlama için yararlanılacak az sayıdaki elyafı bilezik ve kopça arasındaki temas bölgesine yaklaştırmak için daha alçak kemerli ve daha dar kopçaların kullanılması önerilir [18].

Bilezik hareket yolundaki genişletilmiş temas yüzeyi ile dar iplik boşluğuna sahip C1 EL UDR kopça, eğirme sırasında gerçekleşen iyi yağlama nedeniyle en uzun ömürlü kopça olmuştur. Ayrıca bu kopçada kullanılan ve yüksek performanslı kopçalar için geliştirilmiş olan safir kaplama da kopça ömrünün artmasında etken olmuştur.



Şekil 12. Kopça türlerinin kopça ömürleri

4. SONUÇLAR

Kopçanın iplik kalite parametreleri, özellikle tüylülük üzerinde büyük etkisi vardır [8]. Çalışmada kullanılan kopçalar ile üretilen ipliklerin tüylülük değerleri Uster İstatistikleri 2023'e göre %5'lik kalite seviyesindedir. Bu durumda kopça türü iplik tüylülük kalite parametresi açısından fark yaratmamış olup kompakt iplik üretimi için seçilen kopçalar uygundur.

Çalışma sonuçları genel olarak değerlendirildiğinde, yüksek iş devrinde çalışılan 3 farklı kopça ile üretilen kompakt penye ipliklerin kalite parametreleri arasında büyük farklılıklar görülmemiştir.

Eğirme sırasında kopça, temas bölgesinde yüksek mekanik ve termal gerilime maruz kalmakta; ortaya çıkan hasar (çatlaklar, çizikler ve kaplamaların ayrılması) kopçanın daha hızlı bozulmasına yol açmaktadır [12]. Kopça ömürleri, ortalama 4 – 25 gün arası değişkenlik göstermektedir. Kopça ömrü

iplik kalitesine ve kopuşlara etki ettiği gibi bilezik-kopça arasındaki sürtünme her geçen gün artmakta, bu da enerji tüketiminin yükselmesine sebep olmaktadır. Enerji tüketiminin optimizasyonu bakımından kopça kullanım ömrünün çok dikkatli seçilmesi gerekmektedir [13].

Üretimi yapılacak iplik numarası için mümkün olan en hafif kopça seçimi enerji tüketiminin azaltılması bakımından önemlidir [13]. Ayrıca hız ne kadar artarsa kopçanın o kadar hafif olması önerilmektedir [18]. Kompakt iplik üretiminde bilezik / kopça yağlamasının az olması nedeniyle 1-2 numara daha hafif kopçalarla çalışılması tavsiye edilmektedir [18]. Çalışmada kullanılan C1 EL UDR 4/0 kopça, diğerlerinden 1 numara daha hafiftir.

Tüm değerlendirmeler ışığında, çalışmada kullanılan C1 EL UDR 4/0, Ne 30 penye kompakt iplik üretimi için en uygun kopça olarak belirlenmiştir.

5. KAYNAKLAR

1. Klein, W., Stalder, H., 2021. Rieter İplikçilik El Kitabı, 4, ISBN 10 3-9523173-4-9 / ISBN 13 978-3-9523173-4-1.
2. Lord, P.R., 2003. Handbook of Yarn Production. Technology, Science and Economics, Woodhead Publishing Ltd., 504s.
3. Textile Spinning, Textile Technology Knowledge Series II, TEXCOMS Textile Solutions, April 21, 2019.
4. Usta, İ., Canoğlu, S., 2002. Influence of Ring Traveller Weight and Coating on Hairiness of Acrylic Yarns. Fibres and Textiles in Eastern Europe, 10(4), 20-24.
5. Dhamija, S., Manshahia, M., 2007. Performance Characteristics of Mercerized Ring-and Compact-Spun Yarns Produced at Varying Level of Twist and Traveller Weight, Indian Journal of Fibre & Textile Research, 32, 295-300.
6. Uzun, M., 2007. Ring İplikçiliğinde Kopça Özellikleri ile İplik Özellikleri İlişkisi. Yüksek Lisans Tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
7. Tanır, S.K., 2007. Karışım Ring İpliklerinde Karışım Oranlarına Bağlı Olarak Tüylülük ve Çeşitli İplik Özelliklerinin İncelenmesi. Yüksek Lisans Tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
8. Hossen, J., Saha, S.K., 2011. Selection of Appropriate Ring Traveller Number for Different Count of Cotton Hosiery Yarn. International Journal of Engineering & Technology, 11(6), 70-76.
9. Salehi, M., Johari, M.S., 2011. Study of Fiber Packing Density of Lyocell Ring-spun Yarns. The Journal of the Textile Institute, 102(5), 389-394.
10. Ayan, H.E., Sabır, E.C., 2013. Eğirme Parametrelerinin İplik Kalitesine Etkisi. Çukurova Üniversitesi Mühendislik Fakültesi Dergisi, 28(1), 111-118.
11. Raja, D., Prakash, C., Gunasekaran, G., Koushik, C.V., 2015. A Study on Thermal Properties of Single-Jersey Knitted Fabrics Produced from Ring and Compact Folded Yarns. The Journal of the Textile Institute, 106(4), 359-365.
12. Çukul, D., Beceren, Y., 2016. Yarn Hairiness and the Effect of Surface Characteristics of the Ring Traveller. Textile Research Journal, 86(15), 1668-1674.
13. Coşkun, E., Oğulata, R.T., 2019. Kopça Ömrünün Ring İplik Makinasının Enerji Tüketimine Etkisinin İncelenmesi. Ulusal Çukurova Tekstil Kongresi-UÇTEK'2019, 26-27 Eylül 2019, Adana, Türkiye, Bildiriler Kitabı, 72-79, ISBN: 978-975-487-201-9.
14. Siddiqua, T., Iqbal, S.F., 2019. Analysis of Ring Yarn Properties Produced from Different Traveller Brands. European Scientific Journal, June edition Vol.15, No.18 ISSN: 1857 – 7881.
15. Dey, P. K., Das, B., Islam, S., Das, P. K., Chowdhury, N., Das, A., 2021. Determination of Suitable Traveller for Definite Yarn Count: A Comparative Study. Global Journal of Engineering and Technology Advances, 9(01), 036-049.
16. Wu, X., Li, W., Hurren, C., Wang, X., 2023. Modeling the Temperatures of Traveler and Ring in Ring Spinning. Textile Research Journal, 00405175231170312.
17. Kısa Elyaf El Kitabı: Ürünler, Teknoloji ve Uygulama, Bräcker AG.
18. Reiners + Fürst GmbH u. Co. KG, Rings and Travellers; İplik Eğirme Süreçlerini İyileştirecek Bilezikler ve Kopçalar.

Yoğun Bakım Ünitesinde Hasta Kalış Süresinin Karma Dağılım ile Modellenmesi

Selin SARAÇ GÜLERYÜZ*¹ ORCID 0000-0002-4729-0637

¹Toros Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Mersin

Geliş tarihi: 18.03.2024 Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: SARAÇ GÜLERYÜZ, S., (2024). Yoğun Bakım Ünitesinde Hasta Kalış Süresinin Karma Dağılım ile Modellenmesi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 427-436.

Öz

Yoğun bakım üniteleri sağlık sisteminde merkezi bir rol oynamaktadır. Hastanede kalış süresi, hastane yönetimi kalitesinin önemli bir göstergesidir. Simülasyon, çizelgeleme, planlama gibi alanlarda hasta kalış sürelerinin istatistiksel olarak tanımlanması gerekir. Ancak bu veriler oldukça çarpıktı ve bu nedenle istatistiksel modelleme zorlu bir iş olabilir. Karma dağılım modelleri, bu zorluğun üstesinden gelebilecek kabiliyete sahip modellerdir. Bu çalışmada, iki farklı yoğun bakım ünitesinde (genel cerrahi, koroner) gözlemlenen oldukça çarpık hasta kalış süresi verilerinin modellenmesi için karma dağılım yaklaşımı kullanılmıştır. Karma dağılım modellerini geliştirmek için dört farklı dağılım (normal, Weibull, gamma, lognormal) kullanılmıştır. Karma dağılımının optimal bileşen sayısı Bayes bilgi kriteri değeri yardımıyla belirlenmiş ve dağılım parametreleri beklenti-maksimizasyon algoritması kullanılarak tahmin edilmiştir. Bileşen ve parametre tahmini yapılan karma dağılımın model geçerliliği, ortalama mutlak yüzde hata ve R^2 değeri kullanılarak değerlendirilmiş ve gerçek veri setlerini oldukça yüksek doğrulukla temsil ettiği görülmüştür.

Anahtar Kelimeler: Kalış süresi, Performans metrikleri, Karma dağılım, Tahmin, Yoğun bakım ünitesi

Modeling the Length of Stay in the Intensive Care Unit by Using Mixture Distribution

Abstract

Intensive care units play a central role in the healthcare system, and the length of stay in hospitals serves as a significant indicator of hospital management quality. Statistical characterization of patient lengths of stay is essential in areas such as simulation, scheduling, and planning. However, these data are often highly skewed, making statistical modeling a challenging task. Mixture distribution models are capable of overcoming this challenge. In this study, a mixture distribution approach was employed to model the highly skewed patient length of stay data observed in two different intensive care units (general surgery, coronary). Four different distributions (normal, Weibull, gamma, lognormal) were used to develop mixture distribution models. The optimal number of components for the mixture distribution was determined using the Bayesian information criterion value, and distribution parameters were estimated using the expectation-maximization algorithm. The validity of the mixture distribution was evaluated using mean absolute

*Sorumlu yazar (Corresponding Author): Selin SARAÇ GÜLERYÜZ, selin.sarac@toros.edu.tr

percentage error and R-squared value, demonstrating its ability to represent real datasets with high accuracy.

Keywords: Length of stay, Performance metrics, Mixture distribution, Prediction, Intensive care unit

1. GİRİŞ

Kalış süresi, hastanın hastaneye ilk yatışından taburculuk tarihine kadar geçen süre olarak tanımlanır [1]. Hasta kalış süresi, bakım hizmetlerinin kalitesini, hastane performansını ve hastane kaynak tüketimini değerlendirmek için temel göstergelerden biri olarak kabul edilir [2-6]. Hastanenin yatak kapasitesi, ekipman, personel ve zaman gibi kısıtlamalarını yönetmek için hasta kalış süresinin doğru bir şekilde belirlenmesi gerekir. Sadece hastane yönetimi değil, hasta ve sigorta şirketleri de bu öngörüyle bütçelerini yönetmek için kullanılabilir [7].

Yoğun bakım üniteleri (YBÜ), kritik durumdaki hastalara yoğun ve özel tıbbi bakım sağlar [8]. Son on yılda, yoğun bakım ünitesine olan ihtiyaç artmıştır [9]. Hastane bütçesinin yaklaşık %15 - %20'si yoğun bakım hastalarına aittir [10]. Bu nedenle yoğun bakım ünitelerinden en verimli şekilde yararlanılmalıdır. Hasta kalış süresi için iyi bir tahmin, yatak kapasitesi, ekipman, personel ve zaman gibi ciddi şekilde sınırlı kaynakların daha iyi operasyonel planlaması anlamına gelir [6]. Ayrıca, hasta kalış süresi tahmini hastaların bekleme sürelerini azaltmaya yardımcı olur. Sonuç olarak, yoğun bakım ünitesindeki hasta kalış sürelerini önceden tahmin etmek hastane yönetimi, sigorta şirketleri ve hasta ailesi için son derece faydalıdır. Hasta kalış süresi genellikle çeşitli faktörlere bağlı olan oldukça çarpık veriler olması nedeniyle modellemeyi zorlaştırır [11]. Esneklikleri sayesinde, çarpık dağılımlar ve rastgele olaylar, karma dağılımlar ile modellenen olabilir [12]. Ancak, sınırlı sayıda çalışma, yoğun bakım ünitesinde hasta kalış süresini tahmin etmek için karma dağılım modeli kullanmıştır. Karma dağılımlar bileşenleri kısa, orta veya uzun vadeli hasta kalış süresini tanımlayabilir, böylece hastane yönetimi yatarak tedavi üzerindeki baskıyı takip edebilir [13]. Yoğun bakım ünitesinde uzun süreli kalış süresi, iyi geliştirilmiş bir hasta kalış süresi tahmin modelinin

yardımıyla belirlenebilir. Böylece, tahmin modeli klinik karar vermeyi geliştirmeye yardımcı olabilir. Bu çalışmada, her bir yoğun bakım ünitesi için hasta kalış süresini tahmin eden karma dağılım modeli oluşturmayı amaçlamaktadır. Bu amaçla dört farklı sürekli karma dağılım (normal, Weibull, gamma, lognormal) ele alınmıştır ve sonuçlar karşılaştırılmıştır.

Son on yılda sağlık verilerinin tahmini ve modellenmesi için çeşitli yöntemler kullanılmıştır. Bazı çalışmalar, makine öğrenimi yöntemlerine dayalı olarak hasta sayısı veya hastaların kalış süresini tahmin etmeye çalışmıştır [6,9,14-16]. Ancak karma dağılım modelleri, çarpık dağılımlardan oluşan verilerin modellenmesinde de oldukça etkili olduğu görülmüştür [17]. Karma dağılım modelleri, sadece ekonomi ve pazarlamada değil, aynı zamanda sağlık alanında; anatomi, biyoinformatik, hücre biyolojisi, kronik hastalıklar, genetik, geriatri, enfeksiyon hastalıkları, görüntü işleme, ortopedi, farmakoloji, beslenme, kadın hastalıkları, psikiyatri gibi bilim dallarının yanı sıra hastanede iş gücü ve sigorta bütçesinin planlanmasında da kullanılmıştır [18-21]. Hasta kalış süresi verileri bazı çalışmalarda normal, negatif binom, üstel, Weibull, Poisson ve lognormal karma dağılımlarına uyarlanmıştır [23-29].

2. YÖNTEM

Bu çalışmada, Adana'da bir araştırma hastanesinin bilgi sistemi veri tabanından toplanan bir yıllık kabul ve taburcu süresi verileri kullanılarak iki farklı yoğun bakım ünitesinin gün cinsinden hasta kalış süresini hesaplanmıştır. Planlama açısından, günlük tahmin modeli, saatlik tahminlerden daha faydalıdır [6]. Bu nedenle, bu çalışmada günlük tahmin modelleri benimsenmiştir. Tüm işlemler, 64 bit Windows 10 işletim sistemine sahip dizüstü bilgisayarda, RStudio (sürüm 4.1.2) kullanılarak hesaplanmıştır.

Karma oranı $(\pi_1, \pi_2, \dots, \pi_k)$, bileşen sayısı (k) ve dağılım parametreleri $f_1(x; \theta_1), f_2(x; \theta_2), \dots, f_k(x; \theta_k)$ olmak üzere üç komponent ile tanımlanır.

$$f(x) = \pi_1 f_1(x; \theta_1) + \pi_2 f_2(x; \theta_2) + \dots + \pi_k f_k(x; \theta_k) \quad (1)$$

$$0 \leq \pi_i \leq 1 \quad i=1, 2, \dots, k \quad (2)$$

$$\sum_{i=1}^k \pi_i = 1 \quad (3)$$

Karma dağılımların genel bir gösteriminde parametreler için ψ sembolünü kullanılabilir. Karma dağılımlar için genelleştirilmiş gösterim Eşitlik 4'te verilmiştir.

$$f(x, \psi) = \sum_{i=1}^k \pi_i f(x; \theta_i) \quad (4)$$

Karma dağılım il veri modellemenin ilk zorluğu, k ile ifade edilen optimal bileşen sayısını belirlemektir. Optimal k sayısını bulmanın ana hedefi, verileri iyi ayrılmış kümelere bölmektir. Başka bir deyişle, heterojen veri setini, homojen parçalara ayırmaktır [31]. Akaike Bilgi Kriterleri (AIC) ve Bayesian Bilgi Kriterleri, modelin doğruluğu optimal bileşen sayısını olan k değerini belirlemen için yaygın olarak kullanılmaktadır [28,32].

AIC, $2k - 2\ln L(\psi)$, BIC ise $-\ln(n)k - 2\ln L(\psi)$ formülüyle hesaplanır [33,34]. Her iki formülde de $L(\psi)$ karma dağılım modelinin olabilirlik tahminindeki değer ve k aday bileşen sayısını gösterir. BIC, AIC'den farklı olarak gözlem sayısı olan n değerini de hesaba katar ve daha tutarlı bir model seçimi yapabilir. Her iki yöntemde de en küçük değer en uygun modeli temsil etmektedir.

En uygun karma dağılım türü ve optimal bileşen sayısı bulunduğundan sonra karma dağılım parametreleri tahmin edilmelidir. Maksimum olabilirlik veya Beklenti Maksimizasyonu (EM) yöntemi, olasılığı maksimize eden veri seti parametrelerini bulmaya çalışan ve Dempster tarafından 1977 yılında önerilen bir algoritmadır. n gözlem tarafından oluşturulan k bileşenli bir karma dağılım modelinin tüm değerlerinde $L(\psi)$ 'yi maksimize eden $\theta(x_1, \dots, x_n)$ değerine θ 'nin maksimum olabilirlik tahmini denir [35].

Tüm karma dağılım modelleri, farklı doğruluk dereceleriyle hasta kalış süresini tahmin edebilir. Önemli olan en yüksek doğrulukla hasta kalış süresini modelleyebilmektedir. Ortalama mutlak yüzde hatası (MAPE), tahmin performansını değerlendirmek için kullanılır [36]. MAPE, gerçek (y_i) ve tahmin edilen değerler (\hat{y}_i) arasındaki yüzde hatayı temsil eder ve $100/n \sum_{i=1}^n |y_i - \hat{y}_i| / y_i$ formülüyle hesaplanır. MAPE değerinin düşük olması, daha doğru bir tahmine işaret eder. MAPE'nin %10 değerinin altında olması, oldukça doğru bir tahmin sonucu olarak kabul edilir [37]. R-kare (R^2), gerçek ve tahmin edilen değerler arasındaki ilişkinin benzerliği ve gücü ile değerlendirilir [38]. R^2 , 0-1 arası değer alır ve 1'e ne kadar yakınsa model uyumu o kadar yüksektir. y_i gerçek, \hat{y}_i tahmin edilen ve \bar{y} hesaplanan gerçek ortalama değer olmak üzere; $1 - \sum (y_i - \hat{y}_i)^2 / (y_i - \bar{y})^2$ formülüyle hesaplanır.

3. ARAŞTIRMA BULGULARI

Çalışmamızda bir Araştırma Hastanesi'nin genel cerrahi (GC) ve koroner (K) yoğun bakım üniteleri (YBÜ) olmak üzere iki farklı birim ele alınmıştır ve bir yıl boyunca kaydedilen geliş ve bu birimlerden çıkış zamanları kullanılmıştır. Veri içeriğinde hasta gizliliğinin sağlanması amacıyla kişisel bilgiler bulunmamaktadır. Çıkış ve giriş zamanları arasındaki fark alınarak ilgili birimde her bir hastanın kalış süresi hesaplanarak yeni bir veri seti oluşturulmuş ve bu veri seti çalışmada analiz edilmiştir.

Çizelge 1'de gözlem sayısı (n), ortalama değer (μ), medyan, standart sapma (σ) çarpıklık ve basıklık değerleri hesaplanmıştır ve genel cerrahi ve koroner yoğun bakım ünitelerinde hasta kalış süresinin betimleyici istatistikleri olarak Çizelge 1'de özetlenmiştir.


Genel Cerrahi YBÜ'de toplam 730, Koroner YBÜ'de ise 1421 hasta kaydedilmiştir. GC YBÜ'de hastaların ortalama kalış süresi 6.2 gün iken K YBÜ'de bu süre 3.6 gündür. Her iki YBÜ'de de standart sapma değerleri ortalama değerlere oldukça yakındır. Ortalama ve standart sapma değerlerine göre her iki YBÜ'de de hasta kalış

sürelerinin oldukça farklılık gösterdiği yorumu yapılabilir. Çarpıklık ve basıklık değerleri bir veri setinin değişkenliğini ölçmek için kullanılan önemli karakteristiklerden birisidir. İncelenen iki YBÜ’de de çarpıklık ve basıklık değerlerine göre, verilerin oldukça asimetrik olduğu görülmektedir. Asimetrik

davranışın izlenebileceği bir diğer kıyaslama ise ortalama ve medyan değerleridir. Bu iki değer eşit olması durumunda, gözlemlerin simetrik dağılım olduğu yorumu yapılabilir. Ancak ele alınan iki YBÜ’de de bu durum söz konusu değildir ve asimetrik bir davranış beklenmektedir.

Çizelge 1. Betimleyici istatistikler

YBÜ	Gözlem sayısı	Ortalama	Medyan	Standart sapma	Çarpıklık	Basıklık
Genel cerrahi	730	6.22	3.9	6.05	1.8	3.05
Koroner	1421	3.66	2.7	3.12	2.8	11.8



Şekil 1. Kalış süresi histogram ve kutu grafikleri

Şekil 1’de, çarpıklığı vurgulamak için histogramlar ve kutu grafikleri çizilmiştir. Ortalama ve medyan değerler arasındaki farklar kutu grafiklerinde açıkça görülür ve verilerin çarpıklığını destekler. Ayrıca kutu grafiklerinde gözlemlenen uzun kuyruklar

hasta kalış süresi dağılımlarının, her iki yoğun bakım hasta kalış süreleri için sağa çarpık dağılımı doğrular. Kutu dağılımında görülen siyah noktalar aykırı değerleri temsil eder. Betimleyici istatistikler, histogramlar ve kutu grafiklerinden

elde edilen bilgiler ışığında, her iki yoğun bakım ünitesinden elde edilen kalış süresi değerlerinin asimetrik, aykırı değerler içeren ve sağa çarpık dağılıma sahip olduğunu söylenebilir.

Bu özelliklere sahip bir veri setinin bilinen herhangi bir teorik saf dağılıma uyması genellikle mümkün değildir. Ancak zaman seri modelleme, simülasyon, çizelgeleme, planlama gibi pek çok uygulamada verilerin istatistiksel olarak temsil edilmesi gerekir [39,40].

Genel cerrahi ve koroner yoğun bakım ünitelerinde hastaların kalış süresi bilinen saf dağılımlarla uygunluğu ki-kare (χ^2) testiyle sınanmıştır. H_0 hipotezi verilerin seçilen aday saf dağılımla uyumlu olduğunu kabul eder. χ^2 testiyle hesaplanan p değeri seçilen anlamlılık düzeyinin ($\alpha = 0.05$) altında ise H_0 reddedilir [41]. χ^2 testi; Weibull, gamma, lognormal ve normal dağılımlar için test edilmiş ve test edilen tüm aday dağılımlar için p değeri 0.00 olarak hesaplanmıştır.

Bilinen herhangi bir saf dağılıma uymayan çarpık verilerin temsilinde oldukça iyi sonuçlar verdiği literatür ile desteklenmiş karma dağılım yaklaşımı kullanılabilir [27,39].

Karma dağılım ile modellemede ilk adım bileşen sayısı k değerinin belirlenmesidir ve AIC ile BIC değerleri kullanılır. Keribin makalesinde [42], BIC'nin karma dağılımlarının model seçiminde AIC'den daha doğru bir tahmin sağladığını göstermiştir. Bu bilgiler ışığında, bu çalışmada en uygun karma dağılım modellerini seçmek için BIC değeri kullanılmıştır. Çizelge 2.'de $k = 2,3,4,5$ değerleri için model uygunluğu dört aday karma dağılım ile değerlendirilmiş ve en küçük BIC değerine sahip kombinasyon en uygun model olarak seçilmiştir. Buna göre, hem genel cerrahi hem de koroner yoğun bakım üniteleri için en uygun karma dağılım modeli üç bileşenli lognormal karma dağılımdır.

Çizelge 2. BIC değerine göre en iyi model seçimi

Model	BIC (Genel cerrahi)			
	$k = 2$	$k = 3$	$k = 4$	$k = 5$
Normal	4712.11	3974.394	4124.87	4137.91
Weibull	3987.09	3941.879	3937.54	3944.28
Gamma	3941.39	3921.717	3920.50	3933.23
Lognormal	3914.89	3907.893*	3908.87	3924.80
Model	BIC (Koroner)			
	$k = 2$	$k = 3$	$k = 4$	$k = 5$
Normal	6206.80	6010.978	5891.41	5897.27
Weibull	5990.96	5939.896	5887.64	5902.89
Gamma	5892.25	5711.206	5684.03	5709.576
Lognormal	5826.12	5659.703*	5663.96	5687.55

Çizelge 3'te karma dağılımlarının uygun parametrelerinin tahminlerini gösterilmiştir. Genel cerrahi yoğun bakımda kısa süreli yatan hastalar, yılda ortalama 2.04 gün ile nüfusun %36.9'unu oluşturmaktadır. Orta süreli yatan hastalar, yılda 7.47 gün, yani bir haftadan fazla olmak üzere, nüfusun %58.5'i ile yarıdan fazlasını oluştururken, uzun süreli yatan hastalar, üç haftanın üzerinde

24.07 gün, ve kalan popülasyon olan %4.6'yı oluşturmaktadır.

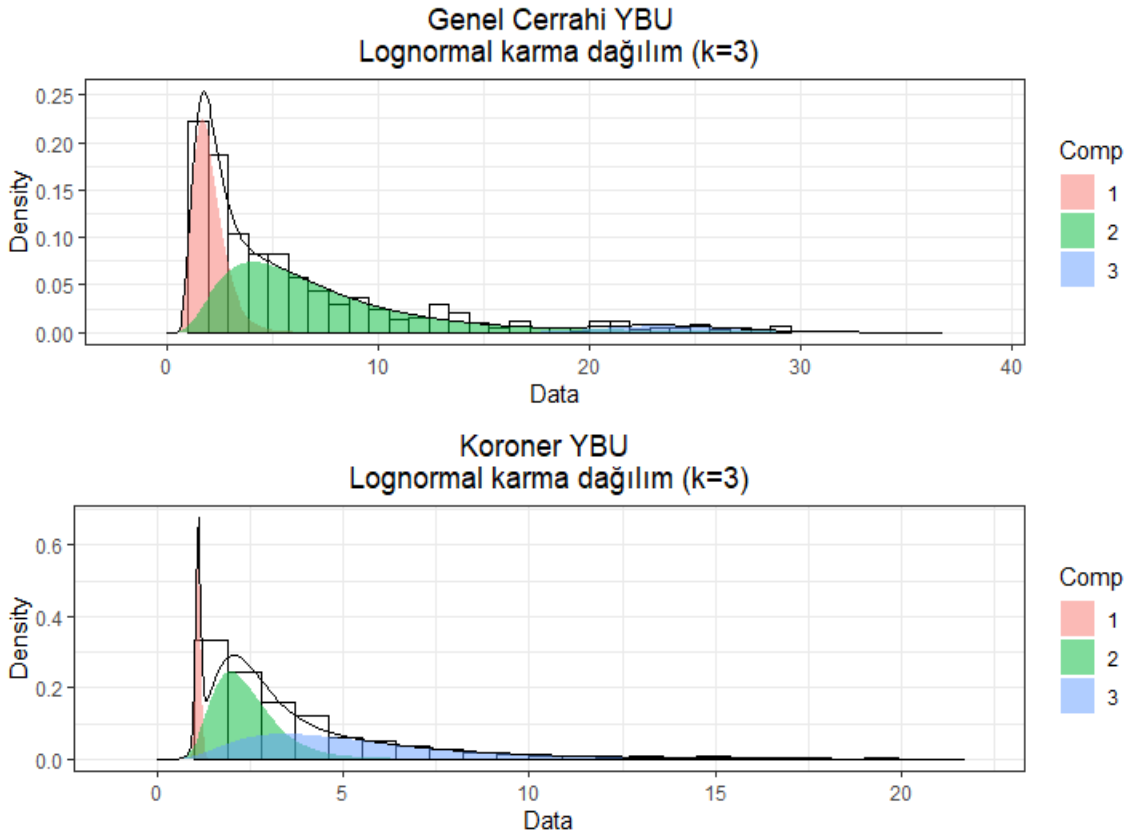
Benzer şekilde koroner yoğun bakımda popülasyon sırasıyla %11.8, %46.7 ve %41.4 kısa (1.11 gün), orta (2.41 gün) ve uzun (5.74 gün) yatan hastalar olmak üzere üç bölüme ayrılmıştır. Genel cerrahi yoğun bakımdan farklı olarak, koroner yoğun bakımda hastaların kalış süresi daha kısadır.

Çizelge 3. EM algoritması kullanılarak tahmin edilen parametreler

	Model	Parametreler			
		k	π_k	μ_k	σ_k
Genel cerrahi	Lognormal	3	0.369	2.04	0.77
			0.585	7.47	5.23
			0.046	24.07	3.03
Koroner	Lognormal	3	0.118	1.11	0.077
			0.467	2.41	0.88
			0.414	5.74	3.66

Şekil 2’de BIC yardımıyla seçilen en uygun karma dağılım modeline göre yoğunluk grafikleri çizilmiş ve veriyle kıyaslanmıştır. Yoğunluk grafiklerine

bakılarak veri setinin karma dağılım ile oldukça iyi bir uyum yakaladığı görülmektedir.




Şekil 2. Genel cerrahi ve koroner YBÜ karma dağılım yoğunluk grafikleri

Hem Genel cerrahi YBÜ’de hem de Koroner YBÜ’de kaydedilen hasta kalış süresi üç bileşenli karma dağılım ile temsil edilmiştir. Verinin karma dağılım yaklaşımıyla temsil gücünün test edilmesi için MAPE ve R^2 değeri hesaplanmış ve sonuçlar Şekil 3’te paylaşılmıştır.

Açıkça görülebildiği gibi, karma dağılım modeli kullanılarak YBÜ kalış süresi modellemede yüksek doğruluk elde edilmiştir. MAPE, genel cerrahide %2.77, koronerde ise %1.92’dir ve bu da oldukça doğru tahmin olarak kabul edilir. Benzer şekilde, R^2 değerlerine bakarak (genel cerrahide 0.991,

koronerde 0.995) karma dağılım ile kalış süresinin modellenmesinin yüksek güvenilirlikte olduğu söylenebilir.



Şekil 3. Genel cerrahi ve koroner YBÜ karma dağılım tahmin performansı

4. SONUÇLAR

Yoğun bakım ünitesi hastanede pahalı ve sınırlı bir kaynaktır. Bir birimdeki hastaların kalış süresi yapısını anlamak, kaynak tahsisi de dahil olmak üzere planlama için oldukça önemlidir. Hastaların ünitelerdeki kalış sürelerinin doğru tahmini, hastane kaynaklarının daha iyi planlanmasına önemli ölçüde yardımcı olabilir. Ancak kalış süresi dağılımının oldukça çarpık olması istatistiksel olarak uymayı zorlaştırır.

Verilerin modellenmesinde karma dağılımının kullanılması, gerçek zamanlı verilerin daha doğru temsil edilmesine olanak tanır. Simülasyon modelinde girdi parametresi olarak karma dağılımını kullanarak hastaların kaynak tüketimini daha doğru bir şekilde takip edilebilir.

Karma dağılım modelinin temel faydası, bir birimdeki kalış süresi dönemlerini tanımlama yeteneğinde yatmaktadır. Karma dağılımının bileşenleri hastaların kalış süresi ortalamasının, standart sapmasının ve grup büyüklüğünün tanımlanmasını sağlar. Bu istatistikler daha sonra yönetim tarafından planlama için kullanılabilir. Ayrıca, karma dağılım yardımıyla, popülasyonu tek bir beklenen grup olarak ele almak yerine kısa, orta veya uzun dönemler daha doğru bir şekilde temsil edilebilir.

Bu makale iki yoğun bakım ünitesinde (genel cerrahi ve koroner) hastaların kalış süresini tahmin etmek için karma dağılım modellerini kullanmaktadır. İlk olarak bileşen sayısı BIC değeri

kullanılarak seçilmiş daha sonra bileşen parametreleri EM algoritması yardımıyla hesaplanmıştır. MAPE ve R^2 , karma dağılım modellerinin tahmin gücünü ölçmek için performans kriterleri olarak kullanılmıştır.

Sonuçlardan da anlaşılacağı üzere, yüksek derecede çarpık veriler, karma dağılım modelleri kullanılarak yüksek doğrulukla modellenebilmektedir.

Bu makale, sağlık hizmetlerinde verilerin modellenmesinin ve kaynak planlamasının geliştirilmesine katkıda bulunmaktadır. Gelecekteki araştırmalarda optimal personel ve ekipmanı belirlemek için karma dağılım yaklaşımı sağlık hizmetleri verilerine uygulanabilir. Ayrıca karma dağılım modeli simülasyon modellerinde girdi parametresi olarak kullanılabilir. Karma dağılım parametreleri cinsiyet, hasta öyküsü, sosyo-ekonomik durum, yaş gibi hasta özellikleri dikkate alınarak güncellenebilir ve hesaplanabilir.

5. KAYNAKLAR

1. Burchardi, H., Moerer, O., 2001. Twenty-four Hour Presence of Physicians in the ICU. *Critical Care*, 5(3), 131-137.
2. Mekhaldi, R.N., Caulier, P., Chaabane, S., Chraïbi, A., Piechowiak, S., 2020. Using Machine Learning Models to Predict the Length of Stay in a Hospital Setting. *Trends and Innovations in Information Systems and Technologies*, 202-211.
3. Arkin, N., Zhao, T., Wang, L., 2024. Development and Validation of a Novel Risk Classification Tool for Predicting Long Length of Stay in NICU Blood Transfusion Infants. *Scientific Reports*, 4, 6877.
4. Lequertier, V., Wang, T., Fondrevelle, J., Augusto, V., Polazzi, S., Duclos, A., 2024. Length of Stay Prediction with Standardized Hospital Data from Acute and Emergency Care using a Deep Neural Network. *Medical Care* 62(4), 225-234.
5. Vasilakis, C., Marshall, A.H., 2005. Modelling Nationwide Hospital Length of Stay: Opening the Black Box. *Journal of the Operational Research Society*, 56(7), 862-869.
6. Johnson, K., Orfanos, A., Chen, E., Cohen, E., 2024. Machine Learning to Predict Length of Stay Following Revision Hip Arthroplasty. *Journal of Hip Surgery*.
7. Abd-Elrazek, M.A., Eltahawi, A.A., Abd Elaziz, M.H., Abd-Elwhab, M.N., 2021. Predicting Length of Stay in Hospitals Intensive Care Unit using General Admission Features. *Ain Shams Engineering Journal*, 12(4), 3691-3702.
8. Bahalkeh, E., Hasan, I., Yuehwern, Y., 2022. The Relationship between Intensive Care Unit Length of Stay information and its Operational Performance. *Healthcare Analytics* (2).
9. Meyer, A., Zverinski, D., Pfahringer, B., Kempfert, J., Kuehne, T., Sündermann, S., Eickhoff, C., 2018. Machine Learning for Real-Time Prediction of Complications in Critical Care: A Retrospective Study. *Lancet Respiratory Medicine*, 6(12), 905-914.
10. Marlene Gyldmark, C., 1995. A Review of Cost Studies of Intensive Care Units: Problems with the Cost Concept. *Critical Care Medicine*, 23(5), 964-972.
11. Shea, S., Sideli, R.V., Dumouchel, W., Pulver, G., Arons, R.R., Clayton, P.D., 1995. Computer-Generated Informational Messages Directed to Physicians: Effect on Length of Hospital Stay. *Journal of the American Medical Informatics Association*, 2(1), 58-64.
12. Quarmalah, N.M., Einbeck, J., Coolen, F.P., 2017. Mixture Models for Prediction Form Time Series with Application to Energy Use Data. *Archives of Data Science. Series A*, 2(1), 1-15.
13. Xiao, J., Lee, A., Vemuri, S., 1999. Mixture Distribution Analysis of Length of Hospital Stay for Efficient Funding. *Socio-Economic Planning Sciences*, 33(1), 39-59.
14. Wu, J., Lin, Y., Li, P., Hu, Y., Zhang, L., Kong, G., 2021. Predicting Prolonged Length of ICU Stay through Machine Learning. *Diagnostics*, 11(12), 2242.
15. Maharlou, H., Niakan Kalhori, S., Shahbazi, S., Ravangard, R., 2018. Predicting Length of Stay in Intensive Care Units after Cardiac Surgery: Comparison of Artificial Neural Networks and

- Adaptive Neuro-fuzzy System. *Healthcare Informatics Research*, 24(2), 109-117.
16. Çiftçi, S., Batur Sir, G.D., 2023. Acil Servise Başvuru Sayısının Zaman Serisi Analiz ve Makine Öğrenmesi Yöntemleri ile Tahmin Edilmesine Yönelik Bir Uygulama. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 29(7), 667-679.
 17. Papi, M., Pontecorvi, L., 2015. Hospital Resource Consumption Modelling. *Research in Business and Management*, 1(1), 105-122.
 18. Frühwirth-Schnatter, S., 2011. Markov Chain Monte Carlo Estimation of Classical and Dynamic Switching and Mixture Models. *Journal of the American Statistical Association*, 96(453), 194-204.
 19. Ng, S.K., Xiang, L., Yau, K.K., 2019. *Mixture Modelling for Medical and Health Sciences*. CRC Press, Boca Raton, 314.
 20. Millard, P., 1988. *Geriatric Medicine: A New Method of Measuring Bed Usage a Theory for Planning*. Yüksek Lisans Tezi. Londra Üniversitesi.
 21. Lee, A., Xiao, J., Codde, J., Ng, A., 2002. Public Versus Private Hospital Maternity Length of Stay: A Gamma Mixture Modelling Approach. *Health Services Management Research*, 15(1), 46-54.
 22. Deb, P., Trivedi, P., 1998. Demand for Medical Care by the Elderly: A Finite Mixture Approach. *Journal of Applied Econometrics*, 12(3), 313-336.
 23. Cleary, P.G., 1991. Variations in Length of Stay and Outcomes for Six Medical and Surgical Conditions in Massachusetts and California. *JAMA*, 266(1), 73-79.
 24. McClean, S., Millard, P., 1993. Patterns of Length of Stay after Admission in Geriatric Medicine: An Event History Approach. *Statistician*, 42(3), 263-274.
 25. Quantin, C., Entezam, F., Brunet-Lecomte, P., Lepage, E., Guy, H., Duserre, L., 1999. High Cost Factors for Leukaemia and Lymphoma Patients: A New Analysis of Costs within these Diagnosis Related Groups. *Journal of Epidemiology and Community Health*, 53(1), 24-31.
 26. Wang, K., Yau, K., Lee, A., 2002. A Hierarchical Poisson Mixture Regression Model to Analyse Maternity Length of Hospital Stay. *Statistics in Medicine*, 21(23), 3639-3654.
 27. Atienza, N., Garcia-Heras, J., Munoz-Pichardo, J., Villa, R., 2008. An Application of Mixture Distributions in Modelization of Length of Hospital Stay. *Statistics in Medicine*, 27(9), 1403-1420.
 28. Garg, L., McClean, S., Meenan, B., El-Darzi, E., Millard, P., 2009. Clustering Patient Length of Stay using Mixtures of Gaussian Models and Phase Type Distributions. *22nd IEEE International Symposium on Computer-Based Medical Systems*, 1-7.
 29. Singh, C., Ladusingh, L., 2010. Inpatient Length of Stay: A Finite Mixture Modeling Analysis. *The European Journal of Health Economics*, 11(2), 119-126.
 30. Titterton, D., Smith, A., Makov, U., 1985. *Statistical Analysis of Finite Mixture Distributions*. Wiley, New York, 243.
 31. Fraley, C., Raftery, A.E., 1998. How Many Clusters? Which Clustering Method?-Answers via Model-Based Cluster Analysis. *The Computer Journal*, 41(8), 578-588.
 32. Sin, C.Y., White, H., 1996. Information Criteria for Selecting Possibly Misspecified Parametric Models. *Journal of Econometrics*, 71(1-2), 207-225.
 33. Akaike, H., 1974. A New Look at the Statistical Model Identification. *IEEE Transactions on Automatic Control*, 19(6), 716-723.
 34. Schwarz, G., 1978. Estimating the Dimension of a Model. *Annals of Statistics*, 6(2), 461-464.
 35. Dempster, A., Laird, N., Rubin, D., 1977. Maximum Likelihood from Incomplete Data via the EM Algorithm (with Discussion). *Journal of the Royal Statistical Society Series B (Methodological)* 39(1), 1-38.
 36. McLachlan, G., Peel, D., 2000. *Finite Mixture Models*. John Wiley & Sons, Inc, New York, 464.
 37. Lewis, C.D., 1982. *Industrial and Business Forecasting Methods*. Butterworths, Londra, 40.

38. Steel, R.G, Torrie, J.H., 1960. Principles and Procedures of Statistics with Special Reference to the Biological Sciences. McGraw Hill, New York, 481.
39. Nas, S., Koyuncu, M., 2019. Emergency Department Capacity Planning: A Recurrent Neural Network and Simulation Approach. Computational and Mathematical Methods in Medicine.
40. Antmen, F.Z., Oğulata, S.N., 2013. The Capacity Planning of Intensive Care Units via Simulation: A Case Study in University Hospital. International Journal of Applied Mathematics and Statistics, 51(21), 214-235.
41. Snedecor, G.W., Cochran, W.G., 1991. Statistical Methods, 8th Edition. Iowa State University Press, Ames, 524.
42. Keribin, C., 2000. Consistent Estimation of the Order of Mixture Models. The Indian Journal of Statistics, Series A, 62(1), 49-66.

Using Bigdata for Choosing the Right Forecasting Method, Dataset and Period in a Time Series Analysis

Serap AKCAN*¹ ORCID 0000-0003-2621-9142

Murat AKCIL² ORCID 0000-0003-4963-1826

Metin ÖZŞAHİN³ ORCID 0000-0001-9989-526X

¹Tarsus University, Faculty of Engineering, Department of Industrial Engineering, Mersin, Türkiye

²Süleyman Demirel University, Faculty of Engineering, Department of Industrial Engineering, Isparta, Türkiye

³Osmaniye Korkut Ata University, Faculty of Economics and Administrative Sciences, Department of Management Information Systems, Osmaniye, Türkiye

Geliş tarihi: 05.01.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: AKCAN, S., AKCIL, M., ÖZŞAHİN, M., (2024). Using Bigdata for Choosing the Right Forecasting Method, Dataset and Period in a Time Series Analysis. Cukurova University, Journal of the Faculty of Engineering, 39(2), 437-452.

Abstract

Nowadays especially production companies gathering a huge data due to their daily transactions on the own systems. Production companies should handle this raw data as handling the raw materials too. Today, scientific studies carried out for this purpose are gathered under the title of BigData. The BigData creates many helps to companies' competitive advantages according to their competitors. For this view, the purpose of this study was to determine the best demand forecasts method and forecasting period by using BigData at forest production industry. Using the time series analysis module of the WEKA program, the algorithm and data set providing the most accurate estimate for each of the selected decor papers were determined. As a result, it is thought that this study will provide a route map for about choosing right data period and forecasting method for the forest products.

Keywords: Big data, Data mining, Time series analysis, Demand forecasting, Forest products sector

Zaman Serisi Analizinde Doğru Tahmin Yöntemini, Veri Kümesini ve Dönemi Seçmek İçin Büyük Veriyi Kullanma

Öz

Günümüzde özellikle üretim firmaları kendi sistemleri üzerinde yaptıkları günlük işlemlerden dolayı büyük miktarda veri toplamaktadır. Üretim şirketleri, ham maddeyi ele aldığı gibi bu ham veriyi de ele almalıdır. Günümüzde bu amaçla yapılan bilimsel çalışmalar büyük veri başlığı altında toplanmaktadır. Büyük veri, şirketlerin rakiplerine göre rekabet avantajı sağlamasına birçok katkı sağlamaktadır. Bu doğrultuda bu çalışmanın amacı, orman ürünleri sektöründe büyük veri kullanarak en iyi talep tahmin yöntemini ve tahmin dönemini belirlemektir. Çalışmada, WEKA programının zaman serisi analiz modülü kullanılarak seçilen dekor kağıtlarının her biri için en doğru tahmini sağlayan algoritma ve veri seti belirlenmiştir. Sonuç olarak

*Sorumlu yazar (Corresponding Author): Serap AKCAN, serapakcan@tarsus.edu.tr

bu çalışmanın orman ürünlerine ilişkin doğru veri periyodu seçimi ve tahmin yöntemi konusunda bir yol haritası oluşturacağı düşünülmektedir.

Anahtar Kelimeler: Büyük veri, Veri madenciliği, Zaman serisi analizi, Talep tahmini, Orman ürünleri sektörü

1. INTRODUCTION

Thanks to technological developments and Industry 4.0, competition among the companies in the production sector has been increasing. Due to this increased competition, companies wanting to maintain their market share produce products of higher quality and lower cost compared to their competitors, and try to shorten delivery times. In this age of online shopping, it is also imperative to stand out in an environment where customers can search for products instantly and find suppliers instantly. Manufacturers want to reduce their product costs as much as possible in order to increase their profitability and make a difference without sacrificing quality, but they have to give their customers timely deadlines. Although it varies by sector, raw material costs are at the top of the product costs in many sectors. Thus, in order to reduce product costs, first the purchase costs of raw materials must be reduced. There are various solutions that manufacturers can use to reduce raw material costs and these solutions can be grouped under three distinct categories. The first of these is improvements in the production process and R&D studies. Manufacturers can examine solutions such as R&D studies, substitute raw material trials, and reduction of waste rates aiming to reduce the raw material usage rates in a way that does not change the quality characteristics of the products. The second category is related to suppliers. Solutions such as increasing the number of companies supplying raw materials, establishing good communication with suppliers, and avoiding purchases with foreign currency payments since the exchange rate is unbalanced in developing countries can be listed under this heading. Thirdly, when determining purchasing strategies, an accurate demand forecast can be made and the determination of raw material order sizes, order frequency, and cost can be presented as a solution. Preparing an accurate budget plan and making the right amount of raw material connections at the right time are

among the strategies that can be done at the purchasing stage to reduce raw material costs [1].

In today's world where the competition is so high, it is not only sufficient to lower the prices in order to retain customers, but it is also of great importance to deliver the desired product to the customer on time. Purchasing strategy and demand forecasting are of great importance for companies in order to give accurate deadlines and to comply with the given deadline. The vast majority of companies today benefit from big data. In order for companies to gain competitive advantage, big data needs to be analyzed in a way that will reduce costs and increase customer satisfaction. Machine learning techniques are frequently used in big data analysis.

2. LITERATURE REVIEW

When we evaluate the studies in the literature; It is useful to group and interpret the demand forecasting studies made about i) production and materials, ii) fashion products, and iii) non-fashionable products.

2.1. Studies Related Demand Forecasting of Production

Much research has been carried out on demand forecasting in recent years. Kaes and Azeem (2009) [2] conducted a demand forecasting and supplier selection study at a knitted composite factory which produces fabrics for export. The most suitable model for the selected raw material was scanned by applying different demand forecasting techniques. By examining the results of an analytic hierarchy process (AHP) for demand forecasting and supplier selection, suggestions were made to improve the level of material management and increase profits by reducing waste. Kim et. al. [3] investigated why mass customization is needed in Smart Manufacturing and looked for appropriate demand prediction techniques by comparing the traditional linear analysis method ARIMA time series analysis

with the nonlinear analysis method LSTM neural network model. Arif et. al. [4] examined product demand forecasting in production facilities using machine learning methods. They used KNN, Random Forest, FNN, ANN, and the Holt-Winters model algorithms.

In their study, Gupta and Sihag [5] used the Gaussian process, MSP model, random forest and random tree techniques to predict which materials should be used in which proportions of concrete mixes with the highest concrete strength. As a result of the comparisons, it is seen that the results obtained with the Gaussian process technique are better. Panarese et. al. [6] developed a machine learning-based platform for sales forecasting using a gradient boosting approach. In this study, it is presented that XGBoost regression model is more accurate in predicting future sales in terms of various error metrics, such as MSE, MAE, MAPE and WAPE. Nasser et. al. [7] applied machine learning in retail demand prediction. In this study, they used over six years of historical demand data from a retail entity. The dataset included daily demand metrics for more than 330 products with 5.2 million records. It is presented in this study that spanning three perishable product categories, reveals that the ETR model outperforms LSTM in metrics including MAPE, MAE, RMSE, and R^2 .

2.2. Studies Related Demand Forecasting of Fashionable Products

Aksoy et. al. [8] developed a decision support system for demand forecasting in the clothing industry. Yunishafira [9] conducted a demand forecasting study by using the historical sales data of a store in the clothing industry that buys and sells ready-made products. In the study, time series methods including moving average, simple exponential smoothing, and the holt-winters model were used. While the simple moving average made the most accurate estimates, the results of the study indicated that interpreting the results would better help company managers determine both supply chain and operations management. Ren et. al. [10] conducted an extensive literature review on demand forecasting methods for trendy products and examined how the fashion retailer's future demand

forecasting and inventory planning problem was handled in practice through a real-life case study.

2.3. Studies Related Demand Forecasting of Non-fashionable Products

Yadav and Ghosh [11] used MSARIMA and ARMAX forecasting models to forecast monthly demand for farm tractors in India. As a result of their research, it was seen that the ARMAX model made better predictions than the MSARIMA model. Their belief was that accurate monthly forecasts of farm tractors would help manufacturers better manage raw materials, inventory and supply chains.

Huber and Stuckenschmidt [12] presented a daily retail demand forecasting using machine learning methods. Spiliotis et. al. [13] compared statistical and machine learning methods for daily SKU demand forecasting. Panigrahi and Behera [14] focused on a model that can determine the near-optimal structure for artificial neural networks used in time series forecasting in their study using a large number of experimental data sets. As a result of this study, they developed an adaptive DE-based modelling scheme (DEMS) to determine the near-optimal architecture of ANN for a time series. Moroff et. al. [15] presented a study for assessing innovative demand forecasting models. They used the Holt Winters - Triple exponential smoothing (ETS), Seasonal Auto-Regressive Integrated Moving Average Extended (SARIMAX), Extreme Gradient Boosting (XGBoost), Random Forest (RF), Long-term short-term memory (LSTM), and Multilayer Perceptron (MLP) for demand forecasting. Ngo et. al. [16] made demand prediction for the electricity consumption forecasts of buildings, which is one of the important study areas in the literature. In this study, the ANNs, SVR, and M5Rules were applied to predict future building energy consumption. As a result of the study ML models can be proposed as an effective method for forecasting energy consumption in buildings. The ML for an ensemble approach has proved predictive performance in predicting the next 24-h energy consumption.

Pham et. al. [17] used the machine learning algorithms such as random tree (RT), random forest (RF), decision stump, M5P, support vector machine (SVM), locally weighted linear regression (LWLR), and reduce error pruning tree (REP Tree) in their study. Estimation was made using datasets containing data such as groundwater level, average temperature, precipitation and relative humidity for the period 1981-2017 obtained from two wells in the northwest region of Bangladesh. Bagging-RT and Bagging-RF models gave the best results by making the most accurate estimation in the study, where the whole data set was used as the training (1981–2008) and test (2008–2017) dataset.

2.4. Evaluation of the Literature and the Contribution of the Study to the Literature

This study, which we think will make an important contribution to the literature will complete the following deficiencies according to the literature review.

- i. As we examined no research related to decor paper in which demand estimations were made using time series analyses could be found.
- ii. Forecasting demand using big data is a difficult problem to solve. In the present study, monthly and annual real sales bigdata from 2009-2021 for Melamine-Faced Chipboard (MFC) were obtained and analyzed from a company operating in the forest products sector.
- iii. The topic of demand forecasting for fashion products in the clothing industry is a trending research area. But home fashion or forest industry demand forecasting are areas that are rarely studied. Fashionable demand forecasting, especially for forest products, is a needed and important research area for manufacturing companies.
- iv. As far as the studies in the literature are examined, in order to decide on the best

forecasting method, the importance of choosing the right data set and the right forecast period in demand forecasting in general emerges. For this reason, there is a great need for a guide to help decision makers in this regard. In this study, the demand forecasting problem was examined to help guide the strategic decisions of the company providing the huge sales data. This BigData has divided 3 parts as all data (2009-2019), last 6 years data (2015-2021) and last 3 years data (2019-2021). For these purposes, future demand forecasts for decor papers used in the production of MFC, which changes according to the current trend, were made using the time series analysis module of the WEKA program in an effort to help determine the purchasing strategy of the business.

3. METHODOLOGY

Today, almost all companies use an enterprise resource planning (ERP) software. This type of software is an important structure used in all departments of a company from accounting and purchasing to production and planning and is a tool used to connect all units and processes [18]. Thanks to these types of software systems, records of all work done can be kept. But this unprocessed and raw data is just a chunk of data unless properly analyzed and made sense of. This is where the concepts of data mining and big data come into play. Data mining is defined as making a large number of data interpretable in line with desired targets or categorizing the desired data from big data [19]. The tools used in the development and dissemination of data analysis are important. Some of the most used data analysis tools are open source RapidMiner, WEKA, R Tool, and KNIME [20]. WEKA is a preferred analysis tool in data mining applications due to its ease of use, compatibility with every operating system, algorithms, and the fact that it is open source. In this study, the time series analysis module of WEKA program was used. The flow chart of the methodology used in the study is shown in Figure 1.

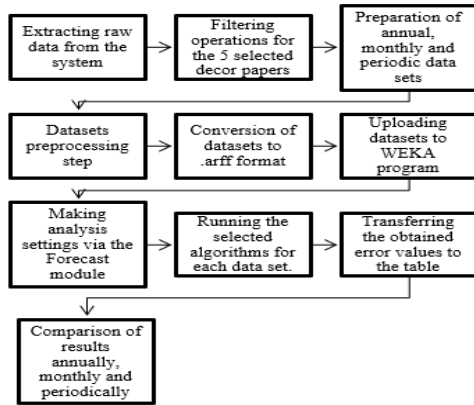


Figure 1. Flow chart of the research methodology

3.1. Time Series Analysis

Algorithms that analyze historical data within a time series enable this data to make predictions for the future by analyzing which trend the data moves on, how seasonal natural conditions are a factor, what effect long-term trends create, and whether there are exceptions in certain periods within the data.

In this study, the following WEKA time series algorithms were used: RandomSupSpace, CVParemeterSelection, MultiScheme, WIHW, InputMappedClassifier, Zeror, RepTree, DecisionStump, LWL, RondonCommitte, RandomForest, M5P, Randonmtree, DecisionTable, Bagging, Regression, InputMappedClassifier, Zeror, RepTree, DecisionStump, LWL, RondonCommitte, RandomForest, M5P, Randonmtree, DecisionTable, Bagging, Regression, DecisionClassifier, RegressionClassifier, SMO, Regression, and Rules. While running these algorithms, the settings in WEKA and used by default were left constant. In this section, definitions of the SMOreg, LinearRegression, M5Rules, M5P, RandomizableFilteredClassifier, MultilayerPerceptiron, RondonCommitte, RandomForest, and AdditiveRegression algorithms, which are some of the most used algorithms in the literature, are given.

The *SMOreg* (Sequential Minimal Optimization Regression) algorithm uses the support vector machines method [21].

LinearRegression is a method used to examine the numerical relationship between variables. Linear regression analysis is used to explain the relationship between the variables and to create a model that describes this relationship. Simple Linear Regression is also known as Multiple Linear Regression according to whether the variables are dependent or not [22].

The *M5Rules* algorithm divides the data from the whole into parts to create a model tree. Then, the best branches are chosen to create a rule. For the remaining samples, the algorithm continues to work through this branch [23].

The *M5P* algorithm is an improved version of the previously produced M5 algorithm. It creates a regression tree model using experimental data and then a linear regression analysis is performed on each branch within the tree model. First, the data is separated according to the determined features and the standard deviation value is used at the nodes to break up the dataset and find which attribute is the best [23].

Randomizable Filtered Classifier is actually a variant that uses RandomProjection and IBk algorithms with a filter that can bring random selection functionality to the FilteredClassifier algorithm [24].

The *MultilayerPerceptiron* algorithm is used for classification by the back propagation method and learning a multilayer perceptron as the name suggests. One of the most important features is that the created network can also be created manually [25].

The *RondonCommitte* algorithm is used to generate a collection of randomly selected classifiers [26].

The *RandomForest* algorithm is a supervised classification algorithm. As the name suggests, it randomly creates a forest. There is a direct relationship between the number of trees in the algorithm and the result it can achieve. The higher the number of trees, the higher the chance of obtaining accurate results [27].

The *AdditiveRegression* algorithm is used to obtain more accurate results in non-linear values and in cases where linear regression fails [28].

3.2. Performance Statistics

Error tests are essential for measuring the accuracy of the predictions made by the prediction models created by the estimation algorithms and to express them numerically. The main task of these tests is to numerically show the difference between the actual values of the predictions made with the help of models created by prediction algorithms. The smaller this difference, the better the prediction. When using prediction algorithms, the aim is to determine which will make the most accurate prediction. Error measurement techniques are used to determine which algorithm, that is, the model produced by which algorithm, makes the best prediction.

In prediction algorithms, the error is calculated by subtracting the estimated value from the actual value (eq.1). To examine the adequacy of the proposed models, their errors should be investigated. For this purpose, mean absolute error (MAE) (eq. 2), mean square error (MSE) (eq. 3), root mean square error (RMSE) (eq. 4), and mean absolute percentage error (MAPE) (eq. 5) are used as performance statistics.

$$E_t = A_t - F_t \quad (1)$$

$$MAE = (\sum_{t=1}^n |A_t - F_t|) / n \quad (2)$$

$$MSE = (\sum_{t=1}^n (A_t - F_t)^2) / n \quad (3)$$

$$RMSE = \sqrt{(\sum_{t=1}^n (A_t - F_t)^2) / n} \quad (4)$$

$$MAPE = \frac{\sum_{t=1}^n \frac{|A_t - F_t|}{A_t}}{n} 100 \quad (5)$$

where, n = number of observations, A_t = actual value at observation t, F_t = estimate value for observation t, E_t = error value at observation t and t = time period. The aim of the present study was to determine the algorithms that make predictions with

the least error and the best data set in the time series analysis method. For the 5 selected decor papers, monthly and annual purchase amounts from 2009 to 2021 were analyzed separately and the values realized in 2021 were compared with the estimates made by the algorithms, and the algorithms with the lowest error rate, that is, the most accurate estimation, were determined together with the data sets. Estimations were made with the forecast module of the WEKA analysis tool. As it is predicted that the effect of the pandemic and the raw materials crisis will continue beyond 2021, this year was chosen for the test data. A further aim of this study was to guide the business in issues such as determining order lots, order frequency, and the annual total cost of decor paper, all of which are important aspects of the decor paper purchasing strategy (considering supplier constraints).

4. IMPLEMENTATION

In this study, 5 different decor papers were selected from among the raw materials purchased by a company operating in the forest products sector. Decor paper was chosen as it affects costs the most, is used extensively in production, and is difficult to plan for due to the diversity in selection. To prepare the data set for the 5 selected decor papers, the company's real MFC sales data from the years 2009 to 2021 were taken over the SAP system and transferred to Excel. This study was implemented by using these steps;

- i. All data preprocessing was carried out in Excel. The data set consisted of 391,845 rows and 20 columns after noisy data and erroneous entries were removed.
- ii. The calculations made on the annual and monthly sales amounts of the 5 decor papers selected in this big data, and the monthly and annual usage amounts for each type of paper were calculated using in Excel using the previously mentioned formulas and new data sets were created.
- iii. These new datasets are broken down into 2009-2021, 2015-2021, 2019-2021. Then, in order to process the data in WEKA, the Excel files were converted to .arff using the ExceltoArff application.

iv. In the data set, the Year or Month attribute was formatted as "Date" and Amount as "Numeric". On the time series data set, the attributes in the "Date" format were taken as independent variables and the "Amount" attribute that occurred over time was evaluated depending on time.

The annual and monthly usage amounts of 5 decor papers selected from the big data were used as test data, while the data from the other years were used as training data.

5. RESULTS AND DISCUSSION

5.1. Computational Results

The data set was analyzed together with the time series prediction algorithms in the forecast module of the 3.9.5 version of the WEKA program. The time series prediction algorithms used in this analysis were the RandomSupSpace, CVParemeterSelection, MultiScheme, WIHW, InputMappedClassifier, Zeror, RepTree, DecisionStump, LWL, RondonCommitte, RandomForest, M5P, Randonmtree, DecisionTable, BaggingMappedClassifier, RegressionBy5Discretative, and the Kstar RegressionByRegress MultilayerPerceptiron. The data sets created for 4 different periods for 5 selected decors were run with time series prediction algorithms, and the algorithms with the least MAPE, MAE, RMSE, and MSE error values were determined. In the analysis, the default settings for WEKA's prediction algorithms were utilized. The prediction values of the training data for the test data period were compared with the actual values in the test data and are provided below in tables 1 through 5 along with their demand forecasting performance values. As indicated in Table 1, the MultilayerPerceptron algorithm yielded the best estimate for decor1 on an

annual basis with a MAPE error rate of 1.54% using the 2019-2021 dataset. Figure 2 shows the predictive value and the actual value of the MultilayerPerceptiron algorithm. Again, the algorithm that gives the second-best estimation is the DecisionTable algorithm with a MAPE error rate of 1.80% on an annual basis and using the 2009-2021 data set. The best estimate on a monthly basis was the DecisionStump algorithm with the 2019-2021 data set and a MAPE error rate of 34.15%. In Figure 3, the graph showing the actual value and the predicted value of the DecisionStump algorithm is given. As seen in Table 2, the RandomSupSpace algorithm gave the best estimate for decor2 on an annual basis with a MAPE error rate of 11.13% using the 2009-2021 dataset. Figure 4 shows the predictive value and the actual value of the RandomSupSpace algorithm. Again, the algorithm that gives the 2nd best estimation is the Kstar algorithm with a MAPE error rate of 16.79% on an annual basis and using the 2015-2021 data set. The best estimate on a monthly basis was the M5Rules algorithm with the 2019-2021 data set and the MAPE error rate of 24.19%. In Figure 5, the graph showing the actual value and the estimated value of the M5Rules algorithm is given. Table 3 indicates that the RegressionByDiscretization algorithm gave the best estimation for decor3 on an annual basis, with the same result as the 2009-2021 and 2015-2021 datasets, with a MAPE error rate of 1.61%. Figure 6 shows the predictive value and the actual value of the RegressionByDiscretization algorithm. Again, the algorithm that gives the 2nd best estimation is the SMOreg algorithm with a MAPE error rate of 5.68% on an annual basis and using the 2019-2021 data set. The best estimate on a monthly basis was the 2009-2021 data set and the RepTree algorithm with a 29.68% MAPE error rate. In Figure 7, the graph showing the actual value and the estimated value of the RepTree algorithm is given.

Table 1. Performance comparison for Decor1 dataset

Algorithms (Decor1)	MAE	MAPE	RMSE	MSE	Data set	t
MultilayerPerceptiron	215.82	1.54	215.82	46,577.49	2019-2021	Year
DecisionTable	252.00	1.80	252.00	63,504.00	2009-2021	Year
DecisionStump	252.00	1.80	252.00	63,504.00	2015-2021	Year
DecisionStump	441.30	34.15	563.04	317,009.00	2019-2021	Month
M5Rules	471.70	37.73	666.52	444,252.76	2009-2021	Month
DecisionTable	518.20	43.72	739.06	546,207.34	2015-2021	Month




Figure 2. The best predicted value on an annual basis for Decor1




Figure 2. Actual and best forecast values on a monthly basis for Decor1

Table 2. Performance comparison for Decor2 dataset

Algorithms (Decor2)	MAE	MAPE	RMSE	MSE	Date set	t
RandomSupSpace	3,447.74	11.13	3,447.74	11,886,903.03	2009-2021	Year
Kstar	5,202.14	16.79	5,202.14	27,062,294.94	2015-2021	Year
M5Rules	668.50	24.19	851.69	725,376.07	2019-2021	Month
RondomCommitte	850.28	28.07	1,058.70	1,120,846.93	2009-2021	Month
Kstar	9,62900	31.08	9,629.00	92,717,641.00	2019-2021	Year
RepTree	938.94	31.70	1,088.69	1,185,253.43	2015-2021	Month




Figure 4. The best predicted value on an annual basis for Decor2




Figure 5. Actual and best forecast values on a monthly basis for Decor2

Table 3. Performance comparison for Decor3 dataset

Algorithms (Decor3)	MAE	MAPE	RMSE	MSE	Data Set	t
RegressionByDiscretization	436.33	1.61	436.33	190,386.78	2009-2021	Year
RegressionByDiscretization	436.33	1.61	436.33	190,386.78	2015-2021	Year
SMOreg	1,54060	5.68	1,540.60	2,373,441.49	2019-2021	Year
RepTree	729.60	29.68	929.04	863,114.35	2009-2021	Month
RegressionByDiscretization	737,33	29.83	938.81	881,358.00	2015-2021	Month
RandomSupSpace	749.01	30.33	951.69	905,722.83	2019-2021	Month




Figure 6. The best predicted value on an annual basis for Decor3




Figure 7. Actual and best forecast values on a monthly basis for Décor3

Table 4. Performance comparison for Decor4 dataset

Algorithms (Decor4)	MAE	MAPE	RMSE	MSE	Data set	t
M5P	4,626.05	4.66	2,286.42	5,227,706.14	2009-2021	Year
RepTree	5,988.33	12.19	5,988.33	35,860,136.11	2015-2021	Year
RandomForest	6,916.00	14.08	6,916.00	47,831,056.00	2019-2021	Year
Bagging	1,418.26	30.85	1,730.82	2,995,754.47	2019-2021	Month
RandomSupSpace	1,384.38	30.98	1,730.65	2,995,150.81	2009-2021	Month
Bagging	1,371.72	31.13	1,731.58	2,998,364.29	2015-2021	Month




Figure 8. The best predicted value on an annual basis for Decor4




Figure 9. Actual and best forecast values on a monthly basis for Decor4

Table 5. Performance comparison for Decor5 datasets

Algorithms (Decor5)	MAE	MAPE	RMSE	MSE	Data set	T
Kstar	162.00	2.02	162.00	26,244.00	2015-2021	Year
Bagging	316.35	3.95	316.35	100,076.69	2009-2021	Year
SMOreg	3,416.05	42.66	3,416.05	11,669,393.09	2019-2021	Year
Bagging	473.46	51.33	839.88	705,406.72	2019-2021	Month
M5Rules	490.53	56.02	866.33	750,528.29	2015-2021	Month
IBK	608.27	61.92	925.73	856,981.00	2009-2021	Month

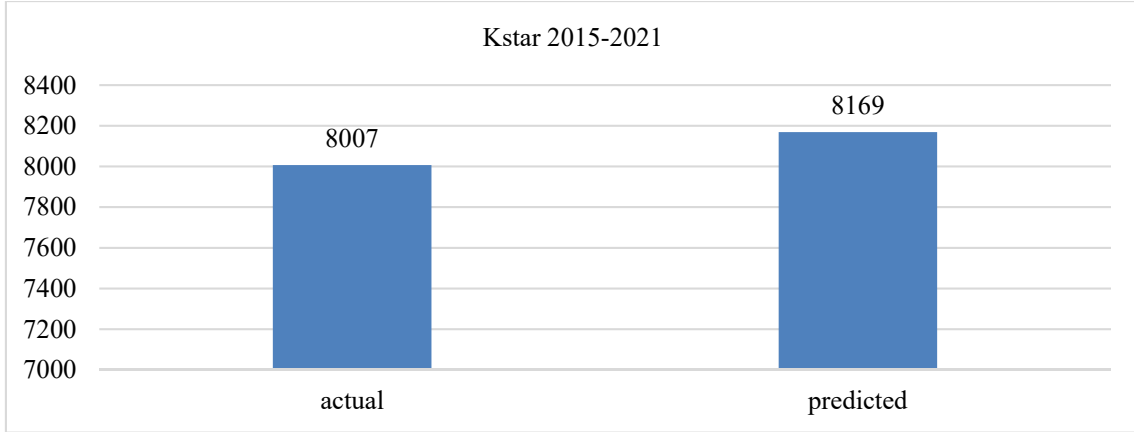


Figure 10. The best predicted value on an annual basis for Decor5




Figure 11. Actual and best forecast values on a monthly basis for Decor5

Table 6. Best Method and Period for Periodic data set according to MAE results

Data Set	Décor 1	Décor 2	Décor 3	Décor 4	Décor 5
2009-2021 (All Data)	Decision Tree, Yearly	Random Committee, Monthly	Regression By Discretization, Yearly	RandomSup Space, Monthly	Bagging, Yearly
2015-2021 (Last 6 years)	Decision Tree, Monthly	RepTree, Monthly	Regression By Discretization, Yearly	Bagging, Monthly	KStar, Yearly
2019-2021 (Last 3 years)	Decision Stump, Yearly	M5Rules, Monthly	RandomSup Space, Monthly	Bagging, Monthly	Bagging, Monthly

Table 7. Best periodic data set and method for decors according to MAE results

Decor	2009-2021	2015-2021	2019-2021
Décor 1	Multi-Layer Perceptron, Yearly		
Décor 2			M5Rules, Monthly
Décor 3		Regression By Discretization, Yearly	
Décor 4		Bagging, Monthly	
Décor 5			Bagging, Monthly

Table 4 indicates that the the best estimate for decor4 was the M5P algorithm with a MAPE error rate of 4.66% on an annual basis and using the 2009-2021 data set (Table 4). Figure 8 shows the estimated value and the actual value of the M5P algorithm. Again, the algorithm that gives the 2nd best estimation is RepTree algorithm with a MAPE error rate of 12,19% on an annual basis and using the 2015-2021 data set. On a monthly basis, the Bagging algorithm gave the best estimate with the 2019-2021 data set and a MAPE error rate of 30.85%. In Figure 9, the graph showing the actual value and the estimated value of the Bagging algorithm is given. Table 5 shows that the Kstar algorithm gave the best estimate for decor5 on an annual basis with a MAPE error rate of 2.02% using the 2015-2021 data set (Table 5). Figure 10 shows the predictive value and the actual value of the Kstar algorithm. Again, the algorithm that gives the 2nd best estimation is Bagging algorithm with 3.95% MAPE error rate on an annual basis and using the 2009-2021 data set. On a monthly basis, the Bagging algorithm gave the best estimate with the 2019-2021 data set and the MAPE error rate of 51.33%. Figure 11 shows the actual value and the estimated value of the Bagging algorithm.

5.2. Determining the Best Forecasting Method and Period

Using the data related to the 5 selected decors, the most appropriate estimation method and estimation period for the decor papers are examined here. For this purpose, all results are summarized in Table 6 and Table 7 by looking at the results of the MAE, that is, the average absolute error performance variable. When the data in the table is examined, it is not seen that there is a dominant method in all

decor papers. Considering the average absolute error value performance according to the selected data set and period, it is seen that the method differs. On the other hand, when we take the data of the last 3 years as a basis, it is seen that the best results are with the monthly period selection, and in longer periods, the annual and monthly distributions are approximately equally. In general, it is seen that both monthly and annual period selections can be made. In Table 7, the best method and data set, period matching was made on all decor pages, again according to the MAE value. When Table 7 is examined, it is seen that the best performances are realized when data from the last 3 or 6 years are used in all décor papers except Decor 1. In these decors, the weight was also obtained from the monthly estimates. There is no common best practice for all décor papers. This result also makes sense. Demand behavior may differ across all products of a firm, which comes from the nature of demand. On the other hand, in this sense, it is possible to conclude that it is more accurate for decision makers to use the data of the last 3 or 6 years and to make monthly forecasts while using them at forest industry like this study.

Validation of our results according to near literature, we can see that likely results were founded. Yildirim et all [29] were studied about forecasting on production of Non-Wood Forest Products (NWFP) using Turkey import and export value between 1989 and 2011 years. They used MAPE and RMSE values as accuracy of prediction by using ANN models. They founded best results by using yearly import and export values when two hidden ones and one output layer, providing the closest results to the real values. Their MAPE value for test data was reached to 4.66.

Another work was studied by Lin et al. [30]. In their study, they presented forecasting supply and demand of the wooden furniture industry in China. They used ARIMA model as forecasting algorithm. They found the MAPE value as 5.2666 for forecasting accuracy value future among 2018 and 2023 years. An also they took in account yearly data as period.

6. CONCLUSION

Due to various reasons such as energy and shipping container crises and fluctuations in exchange rates, there are constant changes in raw material prices and difficulties in raw material supply. This has made it difficult to prepare an accurate budget at the purchasing stage and to create the right purchasing strategies at the right time. Purchasing strategies made with only experience and foresights from the market are not sufficient in a period when technology is so prominent, and competition is so intense. It is an undeniable reality that companies need to use technology and data science in order to stay one step ahead of their competitors and make a difference. Using ERP Systems like SAP, companies create huge raw data. Today companies and decision makers come across a question, how I can handle this data to produce beneficial results according to competition. At Forest industry like all other industries when it comes to competition, demand comes to mind. Therefore, accurately predicting future demand is closely related to many corporate activities, including purchasing and sales. Scientific studies about this topic are related to nearly Big Data. For this reason, applications where decision makers can see how they will process Big Data will be of great benefit.

For all purposes in this study 5 different decor papers were selected from among the raw materials used in production in order to determine the purchasing strategies of an enterprise operating in the forest products sector. Specific to these decors, time series analyses were carried out using the monthly and annual real sales data of the enterprise from the years 2009 to 2021 together with quantity attributes, and the test data for 2021. Looking at the estimation results, it is seen that different

algorithms give the best estimates for different data sets. Considering that the data sets were prepared according to certain time periods, it can be concluded that the estimates vary according to time periods. The importance of not only the algorithms, but also the periodic data sets used are revealed in order to obtain the best estimation results in time series analysis techniques performed on products such as decor paper that change according to current trends and tastes. As a result of the estimation results obtained from this study, the company will be able to make future estimations by considering the best algorithms and data sets for the selected decor papers while making their future purchasing plans and will be able to develop a more efficient purchasing strategy by considering the results that will occur while making its plans. In addition, using the workflow developed in this study, the company will be able to create an integrated strategy by determining the best dataset, period and algorithms for the decor papers that are not covered in the study. Using an artificial intelligence application, it will be possible to automatically run the data on SAP over this flow and display the current best estimates for next month or year.

7. REFERENCES

1. Ferguson, W.C., Hartley, M.F., Turner, G.B., Pierce, E.M., 1996. Purchasing's Role in Corporate Strategic Planning. *International Journal of Physical Distribution & Logistics Management*, 26(4), 51-62.
2. Kaes, I., Azeem, A., 2009. Demand Forecasting and Supplier Selection for Incoming Material in RMG Industry: A Case Study. *International Journal of Business and Management*, 4(5), 149-157.
3. Kim, M., Jeong, J., Bae, S., 2019. Demand Forecasting Based on Machine Learning for Mass Customization in Smart Manufacturing. In *Proceedings of the 2019 International Conference on Data Mining and Machine Learning*, 6-11.
4. Arif, M.A.I., Sany, S.I., Nahin, F.I., Rabby, A.S.A., 2019. Comparison Study: Product Demand Forecasting with Machine Learning for Shop. In *2019 8th International Conference*

- System Modeling and Advancement in Research Trends (SMART), 171-176.
5. Gupta, S., Sihag, P., 2022. Prediction of the Compressive Strength of Concrete Using Various Predictive Modeling Techniques. *Neural Computing and Applications*, 34(8), 6535-6545.
 6. Panarese, A., Settanni, G., Vitti, V., Galiano, A., 2022. Developing and Preliminary Testing of a Machine Learning-Based Platform for Sales Forecasting Using a Gradient Boosting Approach. *Applied Sciences*, 12, 11054.
 7. Nasserri, M., Falatouri, T., Brandtner, P., Darbanian, F., 2023. Applying Machine Learning in Retail Demand Prediction—A Comparison of Tree-Based Ensembles and Long Short-Term Memory-Based Deep Learning. *Applied Sciences*, 13, 11112.
 8. Aksoy, A., Ozturk, N., Sucky, E., 2012. A Decision Support System for Demand Forecasting in the Clothing Industry. *International Journal of Clothing Science and Technology*, 24(4), 221-236.
 9. Yunishafira, A., 2018. Determining the Appropriate Demand Forecasting Using Time Series Method: Study Case at Garment Industry in Indonesia. *KnE Social Sciences*, 553-564.
 10. Ren, S., Chan, H.L., Siqin, T., 2020. Demand Forecasting in Retail Operations for Fashionable Products: Methods, Practices, and Real Case Study. *Annals of Operations Research*, 291(1), 761-777.
 11. Yadav, A., Ghosh, S., 2019. Forecasting Monthly Farm Tractor Demand for India Using MSARIMA and ARMAX Models. *Indian Journal of Agricultural Research*, 53(3), 315-320.
 12. Huber, J., Stuckenschmidt, H., 2020. Daily Retail Demand Forecasting Using Machine Learning with Emphasis on Calendric Special Days. *International Journal of Forecasting*, 36(4), 1420-1438.
 13. Spiliotis, E., Makridakis, S., Semenoglou, A.A., Assimakopoulos, V., 2020. Comparison of Statistical and Machine Learning Methods for Daily SKU Demand Forecasting. *Operational Research*, 22, 3037-3061.
 14. Panigrahi, S., Behera, H.S., 2020. Time Series Forecasting Using Differential Evolution-Based ANN Modelling Scheme. *Arab J Sci Eng*, 45, 11129–11146.
 15. Moroff, N.U., Kurt, E., Kamphues, J., 2021. Machine Learning and Statistics: A Study for Assessing Innovative Demand Forecasting Models. *Procedia Computer Science*, 180, 40-49.
 16. Ngo, N.T., Pham, A.D., Truong, T.T.H., 2022. An Ensemble Machine Learning Model for Enhancing the Prediction Accuracy of Energy Consumption in Buildings. *Arab J Sci Eng*, 47, 4105–4117.
 17. Pham, Q.B., Kumar, M., DiNunno, F., Elbeltagi, A., Granata, F., Islam, A.R.M., Anh, D.T., 2022. Groundwater Level Prediction Using Machine Learning Algorithms in a Drought-Prone Area. *Neural Computing and Applications*, 34, 10751-10773.
 18. Shi, Z., Wang, G., 2018. Integration of Big-Data ERP and Business Analytics (BA). *The Journal of High Technology Management Research*, 29(2), 141-150.
 19. Han, J., Kamber, M., 2006. *Data Mining: Concepts and Techniques*, 2nd. Ed. University of Illinois at Urbana Champaign: Morgan Kaufmann, 735.
 20. Dwivedi, S., Kasliwal, P., Soni, S., 2016. Comprehensive Study of Data Analytics Tools (Rapidminer, WEKA, R Tool, Knime). In 2016 Symposium on Colossal Data Analysis and Networking (CDAN), 1-8.
 21. Shevade, S.K., Keerthi, S.S., Bhattacharyya, C., Murthy, K.R.K., 2020. Improvements to the SMO Algorithm for SVM Regression. *IEEE Transactions on Neural Networks*, 11(5), 1188-1193.
 22. Witten, I.H., Frank, E., 2002. *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations*. *Acm Sigmod Record*, 31(1), 76-77.
 23. El-Bendary, N., Elhariri, E., Hazman, M., Saleh, S.M., Hassanien, A.E., 2016. Cultivation-Time Recommender System Based on Climatic Conditions for Newly Reclaimed Lands in Egypt. *Procedia Computer Science*, 96, 110-119.
 24. Asaju, L.A.B., Shola, P.B., Franklin, N., Abiola, H.M., 2017. Intrusion Detection System on a Computer Network Using an Ensemble of

- Randomizable Filtered Classifier, K-Nearest Neighbor Algorithm. *FUW Trends in Science & Technology Journal*, 2(1), 550-553.
25. Pal, S.K., Mitra, S., 1992. Multilayer Perceptron, Fuzzy Sets, Classification. *IEEE Transactions on Neural Networks*, 3(5), 683-697.
 26. Mirmozaffari, M., Alinezhad, A., Gilanpour, A., 2017. Data Mining Classification Algorithms for Heart Disease Prediction. *Int'l Journal of Computing, Communications & Inst. Engg.*, 4(1), 11-15.
 27. Lin, W., Wu, Z., Lin, L., Wen, A., Li, J., 2017. An Ensemble Random Forest Algorithm for Insurance Big Data Analysis. *IEEE Access*, 5, 16568-16575.
 28. Pratola, M.T., Chipman, H.A., Gattiker, J.R., Higdon, D.M., McCulloch, R., Rust, W.N., 2014. Parallel Bayesian Additive Regression Trees. *Journal of Computational and Graphical Statistics*, 23(3), 830-852.
 29. Yildirim, I., Ozsahin, S., Okan, O.T., 2014. Prediction of Non-Wood Forest Products Trade Using Artificial Neural Networks. *J. Agr. Sci. Tech.*, 16, 1493-1504.
 30. Lin, M., Zang, Z., Cao, Y., 2019. Forecasting Supply and Demand of the Wooden Furniture Industry in China. *Forest Products Journal*, 69 (3), 228-238.

Türkiye’deki Depreme Dayanıklı Çelik Çerçevesel Bina Tasarımına Retrospektif Bir Bakış

Altan ZERVENT*¹ ORCID 0009-0006-9035-1710

Ömer Burak YÜCEL² ORCID 0000-0001-9297-2939

Alper ALDEMİR³ ORCID 0000-0003-2425-9685

Barış ERDİL⁴ ORCID 0000-0001-5282-3568

¹Mitaş Endüstri ARGE Bölümü, Ankara

²DAS Construction Experts, Ankara

³Hacettepe Üniversitesi İnşaat Mühendisliği Bölümü, Ankara

⁴Van Yüzüncü Yıl Üniversitesi İnşaat Mühendisliği Bölümü, Van

Geliş tarihi: 29.03.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ZERVENT, A., YÜCEL, Ö.B., ALDEMİR, A., ERDİL, B., (2024). Türkiye’deki Depreme Dayanıklı Çelik Çerçevesel Bina Tasarımına Retrospektif Bir Bakış. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 453-466.

Öz

Bu çalışma, 6 Şubat 2023 Kahramanmaraş Pazarcık (Mw=7.7) ve Kahramanmaraş Elbistan (Mw=7.6) depremlerinin, bölgedeki çelik yapı stokunun üzerindeki etkilerini incelemeyi amaçlamıştır. Bu maksatla, depremlerden en çok etkilenen illerden olan Hatay pilot il olarak seçilmiştir. Bu doğrultuda, beş katlı bir çelik çerçeve bina, Çevre ve Şehircilik Bakanlığı tarafından yayınlanan “Deprem Bölgelerinden Yapılacak Binalar Hakkında Yönetmelik Eğitimi Ders Notları” kitabından temsili olarak seçilmiş olup, 2007 Deprem Yönetmeliği ile 1980 Çelik Standardına (TS648) uygun olarak tasarlanmıştır. Ardından; bu çerçevelerin sayısal modelleri oluşturulmuştur. Tasarlanan binalar Hatay ilindeki 11 farklı konumda tanımlanmıştır. Hatay ilinde seçilen farklı konumlar, kaydedilen yer hareketlerinin konumlar arası taşıma işlemine tabi tutulmaması için AFAD’a bağlı TADAS istasyonlarıyla aynı pozisyonda seçilmiştir. İvmeölçerlerden alınan 11 adet kayıt uygulanırken kaydedilen düşey ivmeler de numerik analizlerde dikkate alınmıştır. Her bir bina tipi için seçilen 11 farklı konum ve doğrultu dikkate alınarak, doğrusal olmayan zaman tanım alanında analizler yapılmıştır. Çalışma kapsamında toplam 11 adet deprem senaryosu için, sismik performanslar elde edilmiştir. Sonuçlar incelendiğinde, ülkemizde geçmiş yıllarda kullanılmış olan tasarım ve deprem yönetmeliklerine uygun olarak tasarlanmış çelik çerçevesel orta yükseklikteki binaların sismik dayanımlarının Kahramanmaraş merkezli depremlerde ele alınan 11 farklı konumun hepsinde yetersiz kaldığı ve göçme durumunun önlenmesinin mümkün olmadığı ortaya konmuştur.

Anahtar Kelimeler: Deprem, Çelik, Bina tasarımı, Sismik dayanım

*Sorumlu yazar (Corresponding Author): Altan ZERVENT, azervent@mitasindustry.com

A Retrospective View on Earthquake Resistant Design of The Steel Frame Structures in Türkiye

Abstract

This study aims to investigate the effects of the February 6, 2023 Kahramanmaraş Pazarcık ($M_w=7.7$) and Kahramanmaraş Elbistan ($M_w=7.6$) earthquakes on the steel building stock in the region. For this purpose, Hatay, one of the most affected provinces by these earthquakes, was selected as the pilot province. Accordingly, a five-story steel frame building taken from the book "Training Lecture Notes for the Buildings in Earthquake Zones" published by Ministry of Environment and Urbanization was designed in accordance with the 2007 Earthquake Regulations and the 1980 steel standards (TS648). Subsequently, numerical models of these frames were generated. The designed buildings were defined at 11 different locations in Hatay province. The different locations selected in Hatay province were chosen in the same positions as the TADAS stations affiliated with AFAD to avoid the process of transferring recorded ground motions from the positions of stations to the building sites. A total of 11 records obtained from accelerometers were individually applied, while the recorded vertical accelerations were considered in the numerical analyses. Nonlinear time history analyses were performed considering the 11 different positions and directions for each building type. In the scope of this study, seismic performances were obtained for a total of 11 different earthquake scenarios. The results indicate that medium-rise steel frame buildings designed in accordance with the design and earthquake regulations used in the past years in our country are all inadequate in terms of seismic resistance during earthquakes centered in Kahramanmaraş and the collapse cannot be prevented.

Keywords: Earthquake, Steel, Structural design, Seismic performance

1. GİRİŞ

06 Şubat 2023 tarihinde saat 04:17'de Doğu Anadolu Fay Zonu (DAFZ) üzerinde merkez üssü Kahramanmaraş Pazarcık olan büyük bir deprem meydana gelmiştir. 7.7 ve 7.6 büyüklüğünde iki depremin aynı bölgede ve yaklaşık 9 saat arayla meydana gelmesi dünyada örneğine pek rastlanmayan bir durumdur [1,2]. Depremin moment büyüklük (M_w) cinsinden büyüklüğü Afet ve Acil Durum Yönetimi Başkanlığı (AFAD) tarafından 7.7 olarak açıklanmıştır (Enlem: 37.288° N, Boylam: 37.043° E). İlk verilere göre depremin derinliği yaklaşık 8.6 km olarak belirlenmiştir [3,4]. Depremlerden sonra yürütülen birçok saha hasar çalışmalarına göre ağır hasar alan veya yıkılmış oldukça fazla miktarda yığma ve betonarme bina bulunduğu [5,6] gözlemlenmiştir. Fakat, çelik yapıların veya çelikte güçlendirilmiş prefabrik yapıların görece olarak daha az hasar aldığı gözlemlenmiştir [7-10]. Kahramanmaraş'ta meydana gelen depremler; birçok ili etkileyerek altyapı ve binalarda önemli hasara yol açmış ve çok

sayıda can kaybına neden olmuştur. Depremlerde kaydedilen en büyük yer ivmeleri Hatay, Kahramanmaraş ve Gaziantep illerindedir [3]. Ölçülen yer hareketi kayıtlarının bazı bölgelerde Deprem Yönetmeliği'nde öngörülen değerlerin çok üzerinde olduğu ifade edilmiştir [1].

Ülkemizde Deprem Yönetmelikleri sırasıyla 1940, 1944, 1949, 1953, 1962, 1968, 1975, 1998, 2007 ve 2018 yıllarında; Çelik Yapıların Hesap ve Yapım Kuralları ise 1980 ve 2016'da yayınlanmıştır. Aralık 1980'de yayınlanan TS 648 "Çelik Yapıların Hesap ve Yapım Kuralları" Amerikan AISC/ASD (1978) yönetmeliğinin esaslarına dayanmaktadır. Şubat 2016'da yayınlanıp, Eylül 2016'da yürürlüğe giren "Çelik Yapıların Tasarım, Hesap ve Yapım Esaslarına Dair Yönetmelik" AISC 360-10 yönetmeliğinin esaslarına dayanmaktadır. [11,12]. 6 Şubat 2023 Kahramanmaraş Pazarcık ($M_w=7.7$) ve Kahramanmaraş Elbistan ($M_w=7.6$) depremlerinden etkilenen bölgelerdeki çelik binalar bu yönetmeliklerdeki kurallar çerçevesinde tasarlanmıştır. Bu sebepten dolayı yaşadığımız bu

yıkıcı depremlerin etkilerinin ve sonuçlarının geçmişe yönelik bir bakış açısıyla teorik düzlemde değerlendirilmesi büyük önem arz etmektedir. Bu çalışma 2007 deprem yönetmelikleri (TDY 2007) ile 1980 çelik standardına (TS648) uygun olarak tasarlanmış ve deprem yüklerinin tamamının çerçevelerle taşındığı bir binanın sismik yeterliliklerini Hatay bölgesindeki 11 ivme ölçerlerden alınan kayıtların özelinde değerlendirmeyi amaçlamaktadır.

Bu çalışmada TDY 2007 [13] ve TS 648 yönetmeliklerine uygun yapılmış 5 katlı bir çelik bina ele alınacaktır. İlgili 5 katlı çelik bina 2012'de Zekai Celep, Erkan Özer ve Nuray Aydınolu tarafından yazılmış olan "Deprem Bölgelerinde Yapılacak Binalar Hakkında Yönetmelik Açıklamalar ve Örnekler Kitabı" isimli eserde hesabı yapılmış bir yapıdır [14]. Belirtilen şartname ve standarda uygun olarak bu çalışma kapsamında dizayn edilmiş olan çelik yapı, en yoğun yıkımın gerçekleştiği Hatay bölgesindeki ivmeölçerlerden alınan ivme kayıtları kullanılarak zaman tanım alanında doğrusal olmayan hesap yöntemine göre SAP2000 V.25.1 programı ile analiz edilmiştir [15]. Boyutlandırması ve detaylandırılması yapılmış ve tamamen projesine göre inşa edildiği varsayılan binanın deprem etkisi altında değerlendirilmesi, Türkiye Bina Deprem Yönetmeliği 2018

(TBDY2018) kuralları çerçevesinde yapılmıştır [16].

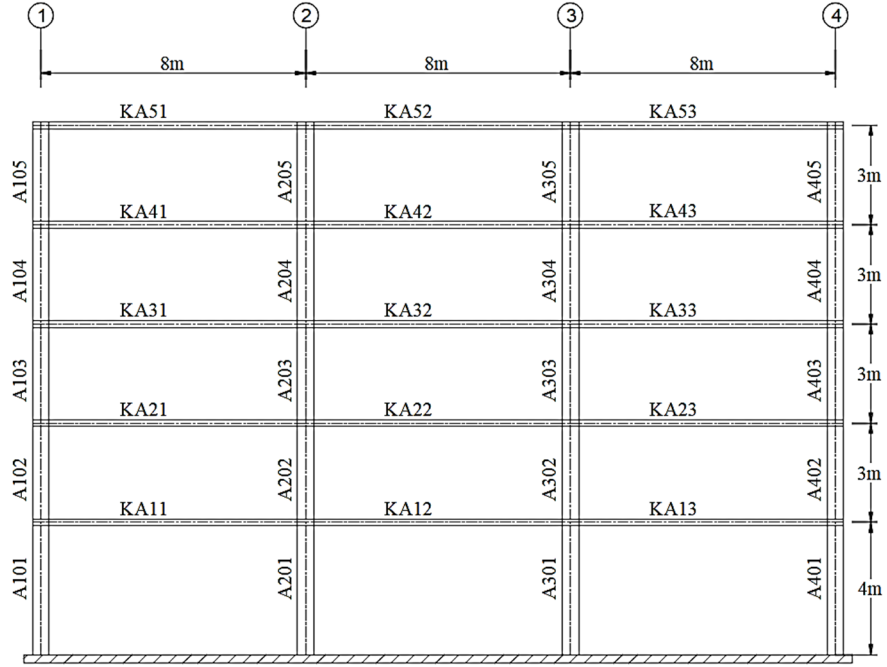
2. MATERYAL VE YÖNTEM

2.1. Bina Özellikleri


Binanın Hatay'da TDY 2007 esas alınarak Z2 zemin sınıfına sahip bir arazide inşa edildiği varsayılmış olup yapının kullanım amacının konut olduğu düşünülmüştür. Etkin yer ivmesi katsayısı $A_0=0.4$, bina önem katsayısı $I=1.0$, spektrum karakteristik periyotları $T_A=0.15s$ $T_B=0.40s$, taşıyıcı sistem davranış katsayısı $R=8$, hareketli yük katılım katsayısı, $n=0.30$ olarak dikkate alınmıştır [8]. Bina, 6'şar metrelik beş açıklıklı, 8'er metrelik üç açıklıklı ve yükseklikleri, ilk katı 4m sonraki katları 3'er metre olan, beş katlı kolon ve kirişlerden oluşan çelik bina olarak TDY 2007 ve TS 648 kriterlerine göre tasarlanmıştır. Çerçeve doğrultusuna dik düzlemdeki akslar arası mesafe 8 m'dir. Çalışmada binayı temsilen dikkate alınan çerçeveler Şekil 1 ve 2'de, kat planı ise Şekil 3'te görülebilir. Ayrıca, binanın taşıyıcı elemanlarının kesitleri Şekil 1-3'te belirtilmektedir. Çizelge 1'de katlara etkiyen deprem yükleri verilmiştir. Çizelge 2'de ise tasarım sonucunda bulunan yapı elemanlarının profilleri ve malzemeleri verilmiştir.



Şekil 1. Taşıyıcı sistem geometrisi- 1 Aksı



Şekil 2. Taşıyıcı sistem geometrisi – A aksı



Şekil 3. Bina kat planı (İkincil kirişler gösterilmemiştir)

Çizelge 1. Katlara etkiyen deprem kuvvetleri TDY2007+TS648-1980

Deprem doğrultusu	1.Kat (kN)	2.Kat (kN)	3.Kat (kN)	4.Kat (kN)	5.Kat (kN)	Toplam (kN)
F_{ix}	98.51	172.37	246.11	319.97	349.04	1186.0
F_{iy}	91.72	160.48	229.14	297.90	324.96	1104.2

Çizelge 2. Taşıyıcı sistem elemanlarının enkesit profilleri ve malzemesi (TDY2007+TS648-1980)

Taşıyıcı sistem elemanı	Enkesit profili	Yapı çeliği
İkincil kirişler (tüm katlarda)	IPE 360	Fe37
Ana kirişler (tüm katlarda)	HE 400 A	Fe37
+0.00 / + 7.00 kotları arasındaki tüm kolonlar	HE 550 B	Fe37
+7.00 / + 16.00 kotları arasındaki tüm kolonlar	HE 550 A	Fe37

2.2. Model Detayları

Yapının sonlu elemanlar modelleme ve analizi 3 boyutlu olarak SAP2000 v.25.1 programı kullanılarak gerçekleştirilmiştir. Kolonlar, birincil ve ikincil kirişler ilgili kesit boyutları programa girilerek çubuk eleman olarak modellenmiştir. Bütün kolonlar zemine rijit bir şekilde bağlanmıştır.

Kat döşemeleri, çelik kirişlere mesnetlenen ve trapez profil sac levhalar üzerinde yerinde dökme betonarme olarak inşa edilen kompozit döşeme sisteminden meydana gelmektedir. Düzlemi içinde rijit bir diyafram oluşturan betonarme döşemelerin çelik kirişlere bağlantısı için, boyutları ve yerleşimi konstrüktif olarak seçilen kayma çivilerinden faydalanılmıştır. Döşeme yükleri normal katlarda zati yükler (çelik konstrüksiyon hariç) $g=3.8\text{kN/m}^2$, hareketli yükler $q=2.0\text{kN/m}^2$ olarak; çatı katında ise zati yükler (çelik konstrüksiyon hariç) $g=4.1\text{kN/m}^2$, hareketli yükler $q=1.0\text{kN/m}^2$ olarak alınmıştır. Normal katlardaki duvar yükleri 3.0kN/m olarak dikkate alınmıştır. Katlara etkiyen deprem yükleri ise yönetmeliklerin ilgili maddelerine uygun olarak hesaplanmış ve bu değerler Çizelge 1’de sunulmuştur. [8]

2.3. Yer Hareketleri

İncelenen çelik çerçevelerin deprem performansları zaman tanım alanında analizler yoluyla belirleneceğinden yer hareketlerine ihtiyaç duyulmaktadır. Bu çalışmada, 6 Şubat 2023

depremlerinde, Şekil 4’te gösterildiği üzere, Hatay bölgesinde 11 istasyonda doğu-batı ve kuzey-güney doğrultusunda kaydedilen yatay ivme kayıtları ile düşey doğrultuda kaydedilen ivme kayıtları kullanılmıştır [11]. Bütün ivme kayıtlarının tasarım ivme spektrumları doğu-batı yönü için Şekil 5’te, kuzey-güney yönü için Şekil 6’da ve düşey doğrultu için Şekil 7’de karşılaştırmalı olarak verilmiştir. Şekil 5’te görüleceği üzere doğu-batı yönünde incelenen binanın salınım periyodunun bulunduğu aralıkta (0.2-0.4s) gerçekleşen en büyük spektral ivme 3129 nolu istasyonda $4.69g$, en düşük spektral ivme ise 3124 nolu istasyonda $1.09g$ ile hesaplanmıştır. Kuzey-güney doğrultusu dikkate alındığında ise en büyük spektral ivme yine 3129 nolu istasyonda $5.35g$ olarak, en düşük spektral ivme ise 3136 nolu istasyonda $1.08g$ olarak hesaplanmıştır. Spektrum görsellerinde ayrıca istasyonların ortalama, ortalama+standart sapma ve ortalama-standart sapma grafikleri de gösterilmektedir. Sunulan spektrumlardan görüleceği üzere ilgili bölgede 2007 Deprem Yönetmeliği’nin 1.5 kat artırılmış spektrum eğrisi ile 2018 Deprem Yönetmeliği’nin DD1 düzeyi için belirlediği tasarım spektrumları 11 ivme kaydının ortalama-standart sapma değerine karşılık gelmektedir. DD2 düzeyi dikkate alındığında ise Deprem Yönetmeliklerinin tasarım spektrumlarının ivme kayıtlarından elde edilen spektrumların altında olduğu belirlenmiştir. 1975 Deprem Yönetmeliği’nin tasarım spektrumlarının hem 6 Şubat 2023 depremlerinin ivme spektrumlarından, hem de 2007 ile 2018 Deprem Yönetmeliği’nin


tasarım spektrumlarının altında kaldığı gözlenmiştir. Ayrıca, kıyaslamak amacıyla 1995 yılında gerçekleşmiş olan Kobe Depremi'ne ait kayıtlar da [12] spektrumlarına eklenmiş olup, 6 Şubat depremlerine ilişkin ivme değerlerinin büyük kısmının Kobe Depremi'nde ortaya çıkan değerlerden daha büyük olduğu ortaya koyulmuştur.




Şekil 4. Çalışmada kullanılan istasyonlar

2.4. Yöntem


3 boyutlu çerçeve olarak modellenen yapı TBDY2018 Bölüm 5.7 kurallarına göre [10] daha önce belirtilen 11 adet ivme kaydı kullanılarak zaman tanım alanında doğrusal olmayan yöntem ile analiz edilmiş ve TBDY2018 Bölüm 15 ile Ek 5C kurallarına göre her bir taşıyıcı elemanın deprem performans analizleri yapılmıştır.



Şekil 5. Doğu-Batı yatay deprem spektrumları



Şekil 6. Kuzey-Güney yatay deprem spektrumları




Şekil 7. Düşey Deprem Spektrumları

3. BULGULAR VE TARTIŞMA

Analiz sonuçları kat bazlı olarak Çizelge 3 ile 7 arasında özetlenmiş, Şekil 8 ile 13 arasında ise grafiksel olarak gösterilmiş ve detaylı analiz sonuçları ise ekte verilmiştir. Şekil 13'te TDY 2007 ve TS 648-1980'e göre tasarlanmış binanın tüm elemanlarının deprem performans özeti her bir istasyon verisi için ayrı ayrı verilmiştir. Sonuçlar, 11 istasyon verisine göre yapılan değerlendirmede kolonların bir kısmının Göçme bölgesinde yer aldığını göstermektedir. Birinci kat kiriş performansları dikkate alındığında ise sadece 3123 nolu istasyon verisine göre kirişlerin %5.3'ü Göçme bölgesinde, geri kalanı ise Belirgin Hasar ve Sınırlı Hasar bölgesinde bulunmaktadır. 3139 nolu istasyonda %31.6'sı Göçme bölgesinde; geri kalanı ise, İleri Hasar, Belirgin Hasar ve Sınırlı Hasar bölgelerinde bulunmaktadır. Diğer istasyon kayıtlarına göre yapılan analizlerde ise kirişlerde göçme görülmemektedir. Birinci kat kolonlarında ise tüm istasyonlarda göçme performansına ulaşan kolonlar bulunmaktadır.

Çizelge 3. Birinci kat sonuçları (TDY2007+TS648-1980)

	Deprem Kaydı	3123	3124	3125	3126	3129	3135	3136	3139	3141	3142	3145
KİRİŞ %	Göçme	5.3	0.0	0.0	0.0	0.0	0.0	0.0	31.6	0.0	0.0	0.0
	İleri Hasar	10.5	5.3	0.0	5.3	5.3	0.0	0.0	5.3	0.0	0.0	21.1
	Belirgin Hasar	36.8	52.6	36.8	21.1	47.4	15.8	10.5	0.0	42.1	15.8	26.3
	Sınırlı Hasar	47.4	42.1	63.2	73.7	47.4	84.2	89.5	63.2	57.9	84.2	52.6
KOLON %	Göçme	66.7	50.0	33.3	33.3	66.7	20.8	8.3	58.3	33.3	16.7	50.0
	İleri Hasar	0.0	16.7	4.2	16.7	0.0	0.0	25.0	25.0	16.7	4.2	16.7
	Belirgin Hasar	33.3	25.0	45.8	29.2	33.3	45.8	16.7	0.0	50.0	45.8	16.7
	Sınırlı Hasar	0.0	8.3	16.7	20.8	0.0	33.3	50.0	16.7	0.0	33.3	16.7


**Şekil 8.** Birinci Kat Kolon ve kirişlerin deprem performans özetleri (TDY2007+TS648-1980)

İkinci kat kiriş performansları dikkate alındığında ise sadece 3129 nolu istasyon verisine göre kirişlerin %36.8'i İleri Hasar bölgesinde, geri kalanı ise Belirgin Hasar ve Sınırlı Hasar bölgesinde bulunmaktadır. Diğer istasyon kayıtlarına göre

yapılan analizlerde ise kirişlerde göçme veya ileri hasar görülmemektedir. İkinci kat kolonlarında 3123, 3126, 3129, 3139 ve 3145 istasyonlarında kolonların bir kısmı göçme performansına ulaşmaktadır.

Çizelge 4. İkinci kat sonuçları (TDY2007+TS648-1980)

	Deprem Kaydı	3123	3124	3125	3126	3129	3135	3136	3139	3141	3142	3145
KİRİŞ %	Göçme	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	İleri Hasar	5.3	0.0	0.0	0.0	0.0	0.0	0.0	36.8	0.0	0.0	0.0
	Belirgin Hasar	47.4	52.6	36.8	26.3	39.5	15.8	10.5	0.0	42.1	15.8	47.4
	Sınırlı Hasar	47.4	47.4	63.2	73.7	60.5	84.2	89.5	63.2	57.9	84.2	52.6
KOLON %	Göçme	4.2	0.0	0.0	33.3	16.7	0.0	0.0	16.7	0.0	0.0	16.7
	İleri Hasar	12.5	4.2	0.0	0.0	4.2	0.0	0.0	8.3	16.7	0.0	0.0
	Belirgin Hasar	16.7	29.2	20.8	0.0	20.8	4.2	0.0	8.3	0.0	0.0	0.0
	Sınırlı Hasar	66.7	66.7	79.2	66.7	58.3	95.8	100	66.7	83.3	100	83.3




Şekil 9. İkinci Kat Kolon ve kirişlerin deprem performans özetleri (TDY2007+TS648-1980)

Üçüncü kat kirişlerindeki hasar seviyeleri tüm istasyonlarda Belirgin Hasar ve Sınırlı Hasar bölgesindedir. Üçüncü kat kolonlarında ise 3123, 3124, 3125, 3126, 3129, 3139 ve 3145 istasyonlarında göçme performansına ulaşanlar vardır.

Çizelge 5. Üçüncü kat TDY2007+TS648-1980 sonuçları

	Deprem Kaydı	3123	3124	3125	3126	3129	3135	3136	3139	3141	3142	3145
KİRİŞ %	Göçme	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	İleri Hasar	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	Belirgin Hasar	36.8	36.8	15.8	18.4	26.3	15.8	5.3	36.8	21.1	5.3	26.3
	Sınırlı Hasar	63.2	63.2	84.2	81.6	73.7	84.2	94.7	63.2	78.9	94.7	73.7
KOLON %	Göçme	16.7	16.7	4.2	29.2	12.5	0.0	0.0	33.3	0.0	0.0	16.7
	İleri Hasar	4.2	4.2	8.3	4.2	20.8	0.0	0.0	0.0	0.0	0.0	0.0
	Belirgin Hasar	33.3	25.0	20.8	0.0	16.7	12.5	16.7	41.7	50.0	0.0	16.7
	Sınırlı Hasar	45.8	54.2	66.7	66.7	50.0	87.5	83.3	25.0	50.0	100	66.7



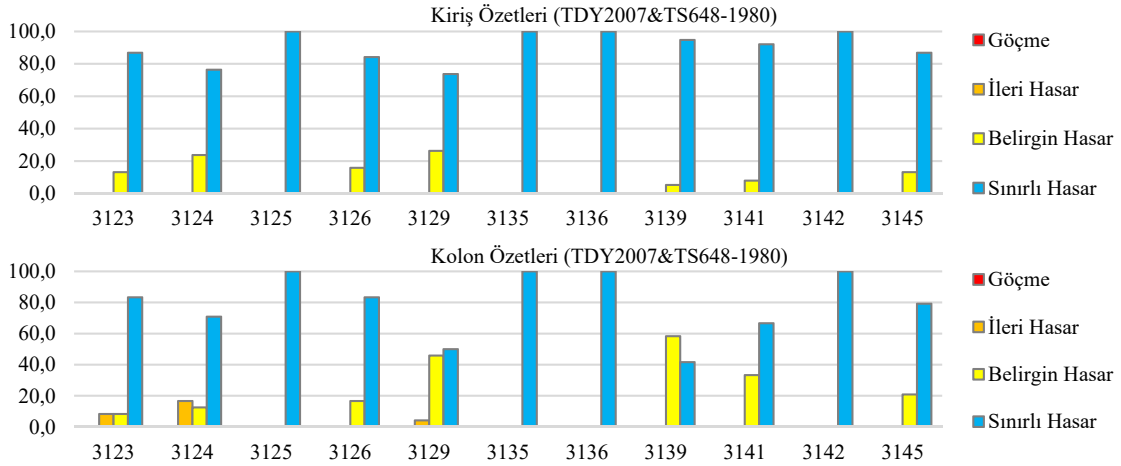
Şekil 10. Üçüncü kat kolon ve kirişlerin deprem performans özetleri (TDY2007+TS648-1980)

Dördüncü kat kiriş performansları incelendiğinde, tüm istasyonlarda kirişlerin Belirgin Hasar ve Sınırlı Hasar bölgesinde bulunduğu tespit edilmiştir. Dördüncü kat kolonlarında sadece 3123,

3124 ve 3129 istasyonunda kolonların bir kısmının İleri Hasar performansına ulaştığı gözlemlenmektedir. Diğer kolonlar ise Belirgin Hasar ve Sınırlı Hasar bölgelerindedir.

Çizelge 6. Dördüncü kat TDY2007+TS648-1980 sonuçları

Deprem Kaydı		3123	3124	3125	3126	3129	3135	3136	3139	3141	3142	3145
KİRİŞ %	Göçme	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	İleri Hasar	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	Belirgin Hasar	13.2	23.7	0.0	15.8	26.3	0.0	0.0	5.3	7.9	0.0	13.2
	Sınırlı Hasar	86.8	76.3	100	84.2	73.7	100	100	94.7	92.1	100	86.8
KOLON %	Göçme	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	İleri Hasar	8.3	16.7	0.0	0.0	4.2	0.0	0.0	0.0	0.0	0.0	0.0
	Belirgin Hasar	8.3	12.5	0.0	16.7	45.8	0.0	0.0	58.3	33.3	0.0	20.8
	Sınırlı Hasar	83.3	70.8	100	83.3	50.0	100	100	41.7	66.7	100	79.2




Şekil 11. Dördüncü kat kolon ve kirişlerin deprem performans özetleri (TDY2007+TS648-1980)

Beşinci kat kiriş performansları dikkate alındığında tüm istasyonlarda kirişler Belirgin Hasar ve Sınırlı Hasar bölgesinde bulunmaktadır. Beşinci kat kolonları incelendiğinde ise sadece 3129

istasyonunda kolonların bir kısmının Belirgin Hasar performansına ulaştığı, diğerlerinin ise Sınırlı Hasar bölgesinde kaldığı tespit edilmiştir.

Çizelge 7. Beşinci kat TDY2007+TS648-1980 sonuçları


Deprem Kaydı		3123	3124	3125	3126	3129	3135	3136	3139	3141	3142	3145
KİRİŞ %	Göçme	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	İleri Hasar	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	Belirgin Hasar	5.3	0.0	0.0	0.0	5.3	0.0	0.0	0.0	0.0	0.0	0.0
	Sınırlı Hasar	94.7	100	100	100	94.7	100	100	100	100	100	100
KOLON %	Göçme	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	İleri Hasar	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	Belirgin Hasar	0.0	0.0	0.0	0.0	16.7	0.0	0.0	0.0	0.0	0.0	0.0
	Sınırlı Hasar	100	100	100	100	83.3	100	100	100	100	100	100



Şekil 12. Beşinci kat kolon ve kirişlerinin deprem performans özetleri (TDY2007+TS648-1980)

Sonuçlara göre, 1998 ve 2007 yılı Deprem Yönetmelikleri kullanılarak TS 648'deki minimum koşullara göre tasarlanan kolonların, 3136 istasyonu hariç, tamamının 6 Şubat 2023 Depremlerinde Göçme Performans Seviyesinde yer alacağı ve 6 Şubat 2023 Depremlerinde yeterli performansı gösteremediği ortaya çıkmıştır. Kirişlerin kolonlardan çok daha iyi davranış

sergilediği, bu durumun deprem yönetmeliklerinin tasarım ilkesine uygun olmadığı, çünkü ele alınan çerçevelerde öncelikli olarak kolonların uç bölgelerinde plastik mafsalların oluştuğu ve global deprem performansının bu sebeple yeterli seviyede olmadığı gözlenmiştir. Ekler bölümünde örnek olarak bir kolon hesabı sunulmuştur.



Şekil 13. Tüm bina elemanları

4. SONUÇLAR

Bu çalışmada 2007 Deprem Yönetmeliği ile TS 648 kullanılarak minimum koşullarda tasarlanmış 5 katlı çelik binanın 6 Şubat 2023 depremlerinde

Hatay Bölgesi'nde kaydedilen 11 adet ivme kaydı altındaki deprem performansı ayrıntılı bir biçimde irdelenmiştir. Yapılan analizler sonucunda aşağıdaki sonuçlara ulaşılmıştır:

• 6 Şubat 2023 Depremlerinde Hatay'da 11 istasyonda kaydedilen ivme kayıtları kullanılarak yapılan analizlerin tüm istasyonlar için global performans değerlendirmesi yapıldığında ele alınan çerçevenin Göçme Performans Seviyesinde olduğu ve hedeflenen Kontrollü Hasar Performans Seviyesini karşılayamadığı belirlenmiştir.

• Hatay'da kaydedilen 11 adet ivme kaydından tümünde yapılan zaman tanım alanında doğrusal olmayan analizlerde kolonların bir bölümünün göçme bölgesinde yer aldığı gözlenmiştir. 3129 ve 3123 istasyonları kaydı ile yapılan analizlerde bina en kötü performansı sergilemiştir.

• Kuvvetli kolon - zayıf kiriş felsefesine göre tasarlanan binalarda göçme performans seviyesinin meydana gelmesinin sebeplerinden biri olarak 6 Şubat 2023 Depremlerinde ortaya çıkan ivmelerin deprem yönetmeliklerinin öngördüğü ivmelerden büyük olması ve moment taleplerinin karşılanmasında mevcut yapısal elemanların yetersiz kalması gösterilebilir.

• Deprem kayıtlarında görülen çok yüksek düzey ivme değerlerinin, güçlü kolon – zayıf kiriş davranışı oluşmaksızın, kolonların eksenel yük altında plastikleşmesiyle göçme durumu oluşmasına yol açtığı gözlemlenmiştir.

Sonuç olarak deprem yönetmeliğinin ve çelik yapılar standardının minimum koşulları gözetilerek deprem yüklerinin sadece çerçeveye taşındığı yapılarda yeterli deprem performansı sergileyemeyeceği görülmüştür. Kolon boyutları belirli bir kapasiteyi garanti etse de kolonların yeterli deprem performansını sağlayamadığı, bu hususun kolon boyutlarından kaynaklı olduğu belirlenmiştir. Kolon boyutları çerçeve rijitliğini etkileyen en önemli parametrelerden biri olduğundan çerçevenin yatay deplasmanlarının artması ile kolonların moment taleplerinde artışlar olmaktadır. Bu taleplerin bu çalışmada ele alınan yeterli minimum kesitlerle karşılanamayacağı gözlenmiştir. 1. ve 2. derece deprem bölgelerinde yapılan orta yükseklikteki çelik yapılara, çelik çapraz kullanıma zorunluluğu yönetmeliklere eklenmelidir.

5. KAYNAKLAR

1. Yakut, A., Binici, B., 2023. Ülkemizdeki Riskli Yapıların Genel Özellikleri ve Deprem Performansı. Çevre, Şehir ve İklim Dergisi Deprem ve Kentsel Dönüşüm, 4, 220-237.
2. Türkiye Cumhuriyeti Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı. 2023 Kahramanmaraş ve Hatay Depremleri Raporu (Mart 2023), 142.
3. Hacettepe Üniversitesi İnşaat Mühendisliği Bölümü, 2023. 06 Şubat 2023-Kahramanmaraş Pazarcık (Mw=7,7) ve Kahramanmaraş Elbistan (Mw=7,6) Depremleri İnceleme Raporu (Mart 2023), 170.
4. Afet ve Acil Durum Yönetimi Başkanlığı (AFAD), 2020. 06 Şubat 2023 Pazarcık (Kahramanmaraş) Mw 7.7 ve Elbistan (Kahramanmaraş) Mw 7.6 Depremlerine İlişkin Ön Değerlendirme Raporu, 12.
5. Vuran, E., Serhatoğlu, C., Timurağaoğlu, M.Ö., Smyrou, E., Bal, İ.E., Livaoğlu, R., 2024. Damage Observations of RC Buildings From 2023 Kahramanmaraş Earthquake Sequence and Discussion on the Seismic Code Regulations. Bulletin of Earthquake Engineering.
6. Oztürk, S., Altunsoy, E., Günes, O., Sarı, A. 2024. Investigation of Industrial Structure Performances in the Hatay and Gaziantep Provinces During the Türkiye Earthquakes on February 6, 2023. Soil Dynamics and Earthquake Engineering, 179(1).
7. Altunsoy, E., Günes, O., Oztürk, S., Sorosh, S., Sarı, A., Beeson, S.T., 2024. Investigating the Structural Damage in Hatay Province after Kahramanmaraş,-Türkiye Earthquake Sequences. Engineering Failure Analysis 157(1).
8. Atmaca, B., Arslan, M.E., Emiroğlu, M., Altunışık, A.C., Adanur, S., Demir, A., Günaydın, M., Kırtel, O., Tatar, T., Kahya, V., Sunca, F., Okur, F.Y., Hacıfendioğlu, K., Dok, G., Öztürk, H., Vural, İ., Güleş, O., Genç, A.F., Demirkaya, E., Yurdakul, M., Nas, M., Akbulut, Y.E., Baltacı, A., Temel, B.A., Başağa, H.B., Sarıbıyık, A., Şen, F., Aykanat, B., Öztürk, İ.Ş., Navdar, M.B., Aydın, F., Öntürk, K., Utkucu, M., Akgül, T., 2023. On the Earthquake-Related Damages of Civil Engineering Structures within

- the Areas Impacted by Kahramanmaraş Earthquakes. *Journal of Structural Engineering & Applied Mechanics*, 6(2).
9. Arslan, M.H., Dere, Y., Ecemiş, A.S., Doğan, G., Öztürk, M., Korkmaz, S.Z. 2024. Code-Based Damage Assessment of Existing Precast Industrial Buildings Following the February 6th, 2023 Kahramanmaraş Earthquakes (Pazarcık Mw 7.7 and Elbistan Mw7.6). *Journal of Building Engineering*, 86(1).
 10. Demir, A., Celebi, E., Ozturk, H., Ozcan, Z., Ozocak, A., Bol, E., Sert, S., Sahin, F.Z., Arslan, E., Yaman, Z.D., Utkucu, M., Mert, N., 2024. Destructive Impact of Successive High Magnitude Earthquakes Occurred in Türkiye's Kahramanmaraş on February 6, 2023. *Bulletin of Earthquake Engineering*.
 11. TS 648 (Türk Standartları). (Aralık 1980). Çelik Yapıların Tasarım ve Yapım Kuralları, 49.
 12. Yorgun C., Topkaya C., Vatansever C., 2016. Çelik Yapıların Tasarım, Hesap ve Yapım Esasları Yönetmeliği-2016 Eğitim Notları. T.C Çevre ve Şehircilik Bakanlığı, 472.
 13. DBYBHY, 1997. Deprem Bölgelerinde Yapılacak Binalar Hakkında Yönetmelik. (Mayıs 2007), Resmi Gazete.
 14. Aydınöğlü N., Celep Z., Özer E., Sucuoğlu H., 2009. Deprem Bölgelerinde Yapılacak Binalar Hakkında Yönetmelik Açıklamalar ve Örnekler Kitabı. Bayındırlık ve İskân Bakanlığı, 643.
 15. Computers and Structures Inc., 2023. SAP 2000 Advanced Version 25.1.0.
 16. TBDY, 2018. Türkiye Bina Deprem Yönetmeliği. Resmi Gazete, Sayı: 30364.
 17. AFAD Türkiye İvme Veri Tabanı ve Analiz Sistemi. <https://tadas.afad.gov.tr>, Erişim Tarihi: 01.03.2023.
 18. PEER-NGA Strong Motion Database. <https://ngawest2.berkeley.edu/>, Erişim Tarihi: 01.02.2023.

6. EKLER

Eksenel yüklerdeki yüksek basınç değerlerinden biri B301 numaralı kolondaki 3129 İstasyon kayıtlarının analizinden ölçülen 3223.32 kN'dur. Kolonun eksenel yük kapasitesi 5112.5 kN'dur. Kolonun kuvvetli yönünde oluşan plastik dönmesi 0.014 radyan, zayıf yönde oluşan plastik dönmesi ise 0.047 radyandır. TBDY2018 Ek 5C.1.2'deki kurala göre çelik elemandaki eksenel yük, plastikleşme anında çelik elemanın beklenen eksenel basınç dayanımının yarısından fazla ise kolonlarda doğrusal olmayan şekil değiştirmelere müsaade edilmemektedir.

$$K_x = 1.0$$

$$\frac{K_x * L}{i_x} = \frac{1.0 * 4000mm}{232mm} = 17.24 < 4.71 * \sqrt{\frac{E}{F_y}}$$

$$= 4.71 * \sqrt{\frac{200000MPa}{235MPa}}$$

$$= 137.4$$

$$F_{ex} = \frac{\pi^2 * E}{\left(\frac{L}{i_x}\right)^2} = \frac{\pi^2 * 200000MPa}{\left(\frac{4000mm}{232mm}\right)^2}$$

$$= 6633.5MPa$$

$$\frac{F_y}{F_{ex}} = \frac{235MPa}{6633.5MPa} = 0.035 \leq 2.25$$

$$F_{crx} = \left[0.658 \frac{F_y}{F_{ex}}\right] * F_y$$

$$= \left[0.658 \frac{235MPa}{6633.5MPa}\right] * 235MPa$$

$$= 231.5MPa$$

$$K_y = 1.0$$

$$\frac{K_y * L}{i_y} = \frac{1.0 * 4000mm}{71.7mm} = 55.78 < 4.71 * \sqrt{\frac{E}{F_y}}$$

$$= 4.71 * \sqrt{\frac{200000MPa}{235MPa}} = 137.4$$

$$F_{ey} = \frac{\pi^2 * E}{\left(\frac{L}{i_y}\right)^2} = \frac{\pi^2 * 200000MPa}{\left(\frac{4000mm}{71.7mm}\right)^2} = 633.5MPa$$

$$\frac{F_y}{F_{ey}} = \frac{235MPa}{633.5MPa} = 0.37 \leq 2.25$$

$$F_{cry} = \left[0.658 \frac{F_y}{F_{ey}}\right] * F_y$$

$$= \left[0.658 \frac{235MPa}{633.5MPa}\right] * 235MPa = 201.2MPa$$

$$K_z = 1.0$$

$$F_{ez} = \left[\frac{\pi^2 * E * C_w}{(L)^2} + G * J \right] * \frac{1}{I_x + I_y}$$

$$F_{ez} = \left[\frac{\pi^2 * 200000MPa * 8.856 * 10^{12}mm^6}{(4000mm)^2} + 77200MPa * 6003000mm^4 \right]$$

$$* \frac{1}{(1367 + 130.8)10^6 * mm^6} = 1038MPa$$

$$\frac{F_y}{F_{ez}} = \frac{235MPa}{1038MPa} = 0.226 \leq 2.25$$

$$F_{crz} = \left[0.658 \frac{F_y}{F_{ez}}\right] * F_y$$

$$= \left[0.658 \frac{235MPa}{1038MPa}\right] * 235MPa = 213.7MPa$$

$$P_n = A_g * F_{cr,min} = 25410mm^2 * 201.2MPa$$

$$= 5112.5kN$$

$$P = 3223.32 kN > \frac{P_n}{2} = \frac{5112.5kN}{2}$$

$$= 2556.25kN$$

olduğundan dolayı doğrusal olmayan şekil değiştirmelere müsaade edilmez. Dolayısı ile kolon göçme bölgesindedir.

Türkiye'deki Depreme Dayanıklı Çelik Çerçevesiz Bina Tasarımına Retrospektif Bir Bakış

Ek Çizelge: Yapısal bileşenlerin tüm kayıtlar altında gösterdikleri performans seviyeleri

Eleman Tipi	Eleman	Kat	Deprem										
			3123	3124	3125	3126	3129	3135	3136	3139	3141	3142	3145
Kiriş	K211	1	KH	KH	KH	KH	KH	SH	SH	GÖÇME	KH	SH	GÖ
Kiriş	K212	1	KH	KH	KH	SH	KH	SH	SH	GÖÇME	KH	KH	GÖ
Kiriş	K214	1	KH	KH	KH	KH	KH	SH	SH	GÖÇME	KH	SH	GÖ
Kiriş	K215	1	KH	KH	KH	SH	KH	SH	SH	GÖÇME	KH	KH	GÖ
Kiriş	K311	1	KH	KH	KH	KH	KH	SH	SH	GÖÇME	KH	SH	GÖ
Kiriş	K312	1	KH	KH	KH	SH	KH	SH	SH	GÖÇME	KH	KH	GÖ
Kiriş	K314	1	KH	KH	KH	KH	KH	SH	SH	GÖÇME	KH	SH	GÖ
Kiriş	K315	1	KH	KH	KH	SH	KH	SH	SH	GÖÇME	KH	KH	GÖ
Kiriş	KC11	1	GÖ	KH	KH	KH	KH	SH	SH	GÖÇME	SH	SH	KH
Kiriş	KC12	1	GÖÇME	GÖ	KH	GÖ	GÖ	SH	KH	GÖÇME	KH	KH	KH
Kiriş	KC13	1	GÖ	KH	KH	KH	KH	SH	SH	GÖ	SH	SH	SH
Kiriş	KD11	1	GÖ	KH	KH	KH	KH	SH	SH	GÖÇME	SH	SH	KH
Kiriş	KD12	1	GÖÇME	GÖ	KH	GÖ	GÖ	SH	KH	GÖÇME	KH	KH	KH
Kiriş	KD13	1	GÖ	KH	KH	KH	KH	SH	SH	GÖ	SH	SH	SH
Kiriş	K221	2	KH	KH	KH	KH	SH	SH	SH	GÖ	KH	SH	KH
Kiriş	K222	2	KH	KH	KH	SH	SH	SH	SH	GÖ	KH	KH	KH
Kiriş	K224	2	KH	KH	KH	KH	KH	SH	SH	GÖ	KH	SH	KH
Kiriş	K225	2	KH	KH	KH	SH	SH	SH	SH	GÖ	KH	KH	KH
Kiriş	K321	2	KH	KH	KH	KH	KH	SH	SH	GÖ	KH	SH	KH
Kiriş	K322	2	KH	KH	KH	SH	SH	SH	SH	GÖ	KH	KH	KH
Kiriş	K324	2	KH	KH	KH	KH	KH	SH	SH	GÖ	KH	SH	KH
Kiriş	K325	2	KH	KH	KH	SH	SH	SH	SH	GÖ	KH	KH	KH
Kiriş	KC21	2	KH	KH	KH	KH	KH	SH	KH	GÖ	SH	SH	KH
Kiriş	KC22	2	GÖ	KH	KH	KH	KH	SH	SH	GÖ	KH	KH	KH
Kiriş	KC23	2	KH	KH	KH	KH	KH	SH	SH	GÖ	SH	SH	SH
Kiriş	KD21	2	KH	KH	KH	KH	KH	SH	SH	GÖ	SH	SH	KH
Kiriş	KD22	2	GÖ	KH	KH	KH	KH	SH	KH	GÖ	KH	KH	KH
Kiriş	KD23	2	KH	KH	KH	KH	KH	SH	SH	GÖ	SH	SH	SH
Kolon	A201	1	KH	KH	KH	KH	KH	SH	SH	GÖ	KH	SH	GÖÇME
Kolon	A301	1	KH	KH	KH	KH	KH	SH	SH	GÖÇME	KH	SH	GÖÇME
Kolon	B101	1	GÖÇME	GÖÇME	KH	KH	GÖÇME	KH	SH	GÖ	KH	KH	GÖ
Kolon	B201	1	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖ	GÖÇME	GÖÇME	GÖÇME	GÖÇME
Kolon	B301	1	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME
Kolon	B401	1	GÖÇME	GÖÇME	KH	KH	GÖÇME	KH	SH	GÖ	GÖ	KH	GÖ
Kolon	C101	1	GÖÇME	GÖ	KH	GÖ	GÖÇME	KH	SH	GÖÇME	KH	KH	KH
Kolon	C201	1	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖ	GÖÇME	GÖÇME	KH	GÖÇME
Kolon	C301	1	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	KH	GÖ	GÖÇME	GÖÇME	KH	GÖÇME
Kolon	C401	1	GÖÇME	GÖ	KH	GÖ	GÖÇME	KH	KH	GÖÇME	KH	KH	KH
Kolon	D101	1	GÖÇME	GÖ	KH	GÖ	GÖÇME	KH	KH	GÖÇME	KH	KH	KH
Kolon	D201	1	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	KH	GÖ	GÖÇME	GÖÇME	GÖ	GÖÇME
Kolon	D301	1	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	KH	GÖ	GÖÇME	GÖÇME	KH	GÖÇME
Kolon	D401	1	GÖÇME	GÖ	KH	GÖ	GÖÇME	KH	KH	GÖÇME	KH	KH	KH
Kolon	E101	1	GÖÇME	GÖÇME	KH	KH	GÖÇME	KH	SH	GÖ	GÖ	KH	GÖ
Kolon	E201	1	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖ	GÖÇME	GÖÇME	GÖÇME	GÖÇME
Kolon	E301	1	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖÇME
Kolon	E401	1	GÖÇME	GÖÇME	GÖ	KH	GÖÇME	KH	SH	GÖ	GÖ	KH	GÖ
Kolon	F201	1	KH	KH	KH	SH	KH	SH	SH	GÖ	GÖ	SH	GÖÇME
Kolon	F301	1	KH	KH	KH	KH	KH	SH	SH	GÖÇME	KH	SH	GÖÇME
Kolon	B202	2	KH	KH	KH	GÖÇME	GÖÇME	SH	SH	KH	GÖ	SH	GÖÇME
Kolon	B302	2	KH	KH	SH	GÖÇME	GÖÇME	SH	SH	GÖ	GÖ	SH	GÖÇME
Kolon	C202	2	GÖ	KH	SH	GÖÇME	KH	SH	SH	GÖÇME	SH	SH	SH
Kolon	C302	2	GÖ	KH	SH	GÖÇME	GÖ	SH	SH	GÖÇME	SH	SH	SH
Kolon	D202	2	GÖÇME	KH	KH	GÖÇME	KH	SH	SH	GÖÇME	SH	SH	SH
Kolon	D302	2	GÖ	GÖ	KH	GÖÇME	KH	SH	SH	GÖÇME	SH	SH	SH
Kolon	E202	2	KH	KH	KH	GÖÇME	GÖÇME	SH	SH	KH	GÖ	SH	GÖÇME
Kolon	E202	2	KH	KH	KH	GÖÇME	GÖÇME	KH	SH	GÖ	GÖ	SH	GÖÇME
Kolon	B203	3	KH	KH	KH	GÖ	GÖ	KH	SH	GÖÇME	KH	SH	GÖÇME
Kolon	B303	3	KH	GÖ	KH	GÖÇME	GÖ	SH	SH	GÖÇME	KH	SH	GÖÇME
Kolon	C203	3	GÖÇME	GÖÇME	KH	GÖÇME	GÖÇME	SH	KH	GÖÇME	KH	SH	KH
Kolon	C303	3	GÖÇME	GÖÇME	GÖ	GÖÇME	GÖ	SH	KH	GÖÇME	KH	SH	KH
Kolon	D203	3	GÖÇME	GÖÇME	GÖ	GÖÇME	GÖÇME	SH	KH	GÖÇME	KH	SH	KH
Kolon	D303	3	GÖÇME	GÖÇME	GÖÇME	GÖÇME	GÖ	SH	KH	GÖÇME	KH	SH	KH
Kolon	E203	3	GÖ	KH	KH	GÖÇME	GÖ	KH	SH	GÖÇME	KH	SH	GÖÇME
Kolon	E303	3	KH	KH	KH	GÖÇME	GÖÇME	KH	SH	GÖÇME	KH	SH	GÖÇME
Kolon	B204	4	SH	KH	SH	SH	GÖ	SH	SH	KH	KH	SH	KH
Kolon	C204	4	KH	GÖ	SH	KH	KH	SH	SH	KH	SH	SH	SH
Kolon	C304	4	KH	GÖ	SH	KH	KH	SH	SH	KH	SH	SH	SH
Kolon	D204	4	GÖ	GÖ	SH	KH	KH	SH	SH	KH	SH	SH	KH
Kolon	D304	4	GÖ	GÖ	SH	KH	KH	SH	SH	KH	SH	SH	SH

Not: Üstteki tabloda kayıtların tamamında Sınırlı Hasar ve Kalıcı Hasar performansı gösteren bileşenler sunulmamıştır.

Doğaltaş Madenciliğinde Ocak-Fabrika Ortamında Titreşim ve Gürültü Maruziyetinin Araştırılması

Ali Ekrem ARITAN*¹ ORCID 0000-0002-4967-3877

Muhammed Fatih CAN¹ ORCID 0000-0001-6527-1336

¹Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Maden Mühendisliği Bölümü,
Afyonkarahisar

Geliş tarihi: 05.02.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ARITAN, A.E., CAN, M.F., (2024). Doğaltaş Madenciliğinde Ocak-Fabrika Ortamında Titreşim ve Gürültü Maruziyetinin Araştırılması. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 467-474.

Öz

Bu çalışmada; Ülkemiz madenciliğinde önemli yer tutan doğaltaş ocak-tesislerinde, standart/yönetmeliklere uygun alınan titreşim ve gürültü ölçümleri alınmıştır. Elde edilen sonuçlar Gürültü ve Titreşim Yönetmeliğine göre değerlendirilmiştir. Ocaklardan alınan ölçümlerde, sondaj makinesi kullanan operatörlerinin hem tüm vücut titreşimi ($4,8 \text{ m/s}^2$) hem de gürültü maruziyetinin (89,3 dBA) yüksek olduğu görülmüştür. Fabrikadan alınan gürültü ölçüm değerlerinde ise S/T makinelerinin (90,6 dBA), ebatlama makinelerinden (85,5 dBA) daha fazla gürültüye yol açtıkları ortaya çıkmıştır. Elmas tel kesme makinesi kullanan çalışanların el-kol titreşimi ölçümlerinde elde edilen değerlerde her ne kadar günlük maruziyet sınır değeri olan 5 m/s^2 değerinin aşılmadığı görülmüş ise de günlük maruziyet eylem değeri olan $2,5 \text{ m/s}^2$ 'nin iki ocakta aşıldığı görülmüştür. Çalışmada son olarak, yapılan ölçümler sonucunda elde edilen verilerdeki sınır değerlerin üzerindeki değerlerle ilgili olarak ocaklar/fabrikada alınabilecek önlemler sunulmuştur.

Anahtar Kelimeler: Doğaltaş madenciliği, İş sağlığı ve güvenliği, Titreşim, Gürültü

Investigation of Vibration and Noise Exposure in the Quarry-Factory Environment in Natural Stone Mining

Abstract

In this study, vibration and noise measurements were carried out in accordance with the standards/regulations in natural stone quarries, which are an important part of the mining industry in our country. The results obtained were evaluated according to the Noise and Vibration Regulation. Measurements taken in the quarries showed that both whole-body vibration (4.8 m/s^2) and noise exposure (89.3 dBA) of the operators using the drills were high. Noise measurements from the factory showed that S/T machines (90.6 dBA) were noisier than sizing machines (85.5 dBA). Although it was found that the daily exposure limit value of 5 m/s^2 was not exceeded in hand-arm vibration measurements of workers

*Sorumlu yazar (Corresponding Author): Ali Ekrem ARITAN, aritan@aku.edu.tr

using diamond wire cutting machines, the daily exposure action value of 2.5 m/s² was exceeded in two natural stone quarries. Finally, the study presents the precautions that can be taken in the quarries/factory in relation to the exceedances of the limit values in the data obtained as a result of the measurements.

Keywords: Natural stone mining, Occupational health and safety, Vibration, Noise

1. GİRİŞ

İnsanlar yerleşik hayata başladıkları andan itibaren, yaşadıkları yerlerde, yaptıkları yapılarda, ibadethanelerde ve sanatsal çalışma ve tasarımlarında doğaltaş kullanımı bir uygarlık simgesi olmuştur. İçinde bulunduğumuz zaman diliminde de yapıların dış ve iç dekorasyonlarında, süs eşyalarının yapımlarında, kent mobilya ve kaldırım taşlarında, yapıların dış cephe kaplamaları gibi yerlerde bolca kullanıldığı görülmektedir. Şehirlerin büyümesi, insan nüfusunun artması dolayısıyla doğaltaş talebi de artmaktadır.

Ülkemiz doğaltaş rezervleri bakımından dünya sıralamasında üst sıralarda bulunmaktadır. Türkiye'nin dünya üzerinde bulunduğu coğrafi konumu rezervlerimizin fazla olmasının sebebi olarak karşımıza çıkmaktadır. Türkiye Alp kuşağında yer almaktadır ve doğaltaşlar da mineral ve renk zenginliğine sahiptir. Ülkemizde yaygın olarak doğaltaş rezervleri mevcuttur. Türkiye'nin doğaltaş muhtemel rezerv toplamı 5,1 milyar m³'tür. Bu rezerv miktarı dünya rezervinin yaklaşık olarak üçte birini oluşturmaktadır [1]. Afyonkarahisar İli de bu zengin rezervlerden nasibini almıştır. Artan doğaltaş talebinin karşılanması için Ülkemizde son yıllarda üretim de artmıştır. Bu artışla birlikte sektör çalışanların meslek hastalıkları ve iş kazalarına uğrama riskleri de artmaktadır.

Ülkemizde 2012 yılında çıkarılan 6331 Sayılı İş Sağlığı ve Güvenliği Kanunu ile birlikte bu risklerle mücadele konusunda çalışmalar hız kazanmıştır. Burada hem çalışanın sağlığı-güvenliği garanti altına alınmaya çalışılırken hem de iş gücü verimliliği artırılmaya çalışılmaktadır. Bu önemli çalışmaların yapılması sektör çalışanlarının işlerine motive olabilmelerini, sağlamak açısından da ayrı bir önem taşımaktadır. Motivasyonun gereğince

sağlanamaması hem iş kazalarını hem de sağlık açısından problemleri artıracaktır. Çalışanın rahat bir biçimde çalışması bu manada çok önem kazanmaktadır. Burada çalışanın rahatını kötü yönde etkileyen sebeplerin başında fiziksel riskler gelmektedir.

Genel olarak ocak ve fabrikalarda karşılaşılan fiziksel risk etmenlerinden başlıcaları titreşim ve gürültü olarak görülmektedir. İş sağlığı ve güvenliğinin temel sorunlarından birisi olan fiziksel risk etmenleri, doğaltaş madenciliğinde de karşımıza çıkmaktadır. Bu etkenlerden özellikle titreşim ve gürültü önemli riskler barındırmaktadır (karpal tünel sendromu, geçici/kalıcı işitme kayıpları vb.). Bu doğrultuda bakıldığında doğaltaş madenciliğinde kullanılan birçok makine ve donanımın sektör çalışanlarının sağlıklarını etkileyebileceği bir gerçektir. Kesme işlemi esnasında oluşan gürültü ise çalışanların işitme sağlığı ile doğrudan ilişkilidir. Ayrıca titreşim makinelerde arıza ve yorulmalara da sebep olmaktadır.

Bir cisim bir denge konumu etrafında belirli bir periyotta salınım hareketi yaptığında titreşim oluşur [2]. Genel olarak bakıldığında, ortamın katı olduğu durumlarda ortaya çıkan ve dokunulduğunda hissedilen, frekansı düşük ve genliği yüksek mekanik salınımlardır. Başka bir şekilde söylenmek istenirse; potansiyel enerjinin kinetik enerjiye, kinetik enerjinin potansiyel enerjiye dönüşmesi olayına titreşim (vibrasyon) adı verilmektedir. Titreşim salınımına sahip bir harekettir. Titreşim hareketinin birbiri ile bağlantılı dört parametresi bulunmaktadır. Bunlar frekans, ivme, hız ve yer değiştirme [3].

Gürültü tanımlaması yapılırken öncelikle gürültüye sebep olan sesi tanımlamak gerekir ki; bir maddenin

titreşimi ile oluşan ve bu titreşimin uygun ortamlarda (hava, sıvı veya gaz) yayılması ile meydana gelen enerji dalgasına ses adı verilmektedir [4]. Frekans ve şiddet, sesin niteliğini belirlemektedir. Frekans, sesi meydana getiren saniyedeki titreşim sayısı olarak ifade edilmektedir ve birimi Hertzdir (Hz). Sesin şiddeti olarak ifade edilen Desibel ise ses dalgasının içerdiği enerjinin birim alandaki enerjiye oranıdır. Birimi ise Desibeldir ve (dBA) şeklinde gösterilir. Bulunulan ortamda ses dalgalarının şiddeti ve yoğunluğu gürültü düzeyini belirler. Ortam ve kişisel maruziyet ölçümlerinde gürültünün şiddeti (dBA) dikkate alınmaktadır [5]. Endüstrideki gürültü, çalışanlar üzerinde özellikle fizyolojik ve psikolojik etkiler bırakır. Gürültü, işleme düzeyini ve sağlığına olumsuz yönde etki eden, kalıcı ya da geçici işleme sorunlarına sebep olan ve iş verimini düşüren seslerdir [6,7]. Ülkemizde gürültünün tespiti için yayınlanmış olan yönetmelik; 2013 yılında yayınlanmış olan Çalışanların Gürültü ile İlgili Risklerden Korunmalarına Dair Yönetmeliktir [8].

Doğaltaş sektöründe, üretim yapılan ocaklarda elmas tel kesme makineleri oluşturdukları gürültü düzeyleri bakımından incelenmesi gereken bir konu olarak karşımıza çıkmaktadır. Elmas tel kesme makinesinde kesme işlemi, özel bir sıralama ile dizilmiş elmas boncuklu tel yardımı yapılmaktadır. Makine yere sabitlenmiş ray üzerinde hareket eder ve telin soğutması su ile sağlanmaktadır.

Elmas tel kesme makinesi ile blokların ocak aynasından kesilmesi ve blok ebatlama işlemi esnasında oluşan gürültü, çalışanların meslek hastalığına yakalanması riskini doğurmaktadır. Oluşan bu riske karşılık ortamda çalışanlarda önlemler alınmalıdır, kişisel koruyucu donanımlar kullanılmalıdır. Ayrıca blok kesme işlemi sırasında kesilen doğaltaşın fırlaması, tel kayması-kopması vb. tehlikeler, kullanılan makinelerde, makine ile insan arasında konulan paravan vasıtası ile engellenmeye çalışılmaktadır [9].


Literatüre bakıldığında, doğaltaş ocaklarında ve doğaltaş işleme fabrikalarında fiziksel risklerin

bulunduğu görülmektedir. Hem el-kol hem de vücut titreşimi bakımından risklerin olması ayrıca önlemlerin artırılması gerektiğini bize göstermektedir. Ayrıca, gürültü problemi de birçok madencilik kolunda olduğu gibi doğaltaş madenciliğinde de sorunlara (işleme sorunları) sebep olacak düzeylere ulaşabilmektedir.

Çalışma kapsamında; elmas tel kesme işlemi sırasında oluşan el-kol titreşim ve gürültü maruziyet ölçümleri yapılmıştır. Ocaklarda, gürültü ve titreşim maruziyetini incelemek için sondaj makinesi, ekskavatör, kamyon ve yükleyicilerden de ölçümler alınmıştır. Bir doğaltaş işleme fabrikasından da gürültü ölçümleri alınmıştır.

2. MATERYAL VE YÖNTEM

Çalışma, Afyon İli sınırları içerisinde bulunan 3 doğaltaş ocağında yapılmıştır. Ocaklar İscehisar ve Emirdağ ilçe sınırları içerisinde bulunmaktadır (Şekil 1). Ocaklarda üretim elmas tel kesme ile yapılmaktadır.



Şekil 1. Ölçüm alınan ocak yerlerini gösteren harita [10]

Çalışanlardan alınan gürültü ölçümleri “Svantek SV 104IS Gürültü Seviyesi Ölçüm Cihazı” ile yapılmıştır. Cihaz, ölçüm yapılan alanların kararlı

bir gürültüye sahip olması nedeni ile ‘Slow’ (yavaş) modunda ve A ağırlıkta kullanılmıştır. Kararlı gürültüye sahip alanlarda yapılan ölçümlerde ‘Slow’ ya da ‘Fast’ konumu arasında istatistiksel bir değişiklik gözlenmemiş olup, farklılıklar kararsız gürültü ölçümlerinde ortaya çıkmaktadır. Yapılan ölçümlerde TS 2607 ISO 1999 standardı kullanılmıştır [11]. Makineleri kullanan operatörlerin, 8 saatlik bir iş günü için maruz kaldıkları gürültü seviyeleri ($L_{EX,8h}$) Eşitlik 1’de verilen formül kullanılarak hesaplanmıştır. Yorumlamalar $L_{EX,8h}$ değerlerine göre yapılmıştır.

$$L_{EX,8h} = L_{Aeq} + 10 \log [T_e/T_0] \quad (1)$$

$L_{EX,8h}$: Gürültü maruziyet düzeyi (dBA).

L_{Aeq} : Eşdeğer gürültü seviyesi (dBA).

T_e : Çalışma gününde etkin olarak maruz kalınan periyot (saat).

T_0 : Referans maruz kalma periyodu (= 8 saat).

Titreşim ölçümü; ivmeölçerlerden alınan verilerin işlenmesi ve kaydedilmesi için “Cesva VC431 Titreşim Ölçüm Cihazı” kullanılmıştır. Cihaz ISO 8041:2005, ISO 2631-1, ISO 2631-2, ISO 2631-5 ve ISO 5349 standartlarında öngörülen gereklilikleri karşılamaktadır. El-kol titreşimi için wh (ISO 5349) filtrelerini kanallar bazında ayarlamak mümkündür. 50 m/s² peak titreşim ivme değerleri kaydedilebilmektedir. Yapılan ölçümlerde TS EN 1032+A1, TS EN ISO 5349-1 ve TS ISO 2631-1/A1 standardı kullanılmıştır [12-14].

3. ARAŞTIRMA BULGULARI

3.1. Ocaklardan Alınan Ölçümleri

Özellikle doğaltaş ocaklarında çalışanların muhatap oldukları el-kol titreşimi maruziyeti oluşturan elmas tel kesme makineleridir. Elmas tel kesme makinesi kullanan çalışanların maruz kaldıkları titreşim ve gürültü değerleri, Emirdağ ve İncehisar bölgesinden seçilen 3 doğaltaş ocağında ölçülmüştür (O_1 , O_2 , O_3). Ölçüm sonuçları Çizelge 1’de verilmiştir. O_1 ve O_2 ocaklarında 2 adet, O_3 ocağında ise 1 addet elmas tel kesme makinesi vardır.

Çizelge 1. Elmas tel kesme makinesi kullanan çalışanların gürültü ve el-kol titreşim maruziyet değerleri


Yer	Titreşim (m/s ²)	L _{min} (dBA)	L _{max} (dBA)	L _{Aeq} (dBA)	L _{EX,8h} (dBA)
O_1	1,89	75,60	90,10	81,90	81,00
	1,82	77,06	91,53	82,00	81,10
O_2	3,25	80,65	91,88	83,80	82,90
	3,51	82,28	87,32	84,30	83,40
O_3	3,66	82,59	87,71	84,80	83,90

Ayrıca 3 farklı doğaltaş ocağında yükleyici, sondaj makinesi, ekskavatör ve kamyon kullanan çalışanların maruz kaldıkları gürültü değerleri de tespit edilmiştir (Çizelge 2). Yükleyici, ekskavatör ve kamyon kullanan operatörler için gürültü maruziyet ölçümleri, araçların kapalı kabinleri içerisinde yapılmıştır.

Çizelge 2. Makineleri kullanan operatörlerin gürültü ölçüm değerleri (dBA / $L_{EX,8h}$)

Gürültü Değeri (dBA)	L _{min}	L _{max}	L _{Aeq}	L _{EX,8h}
Makine	Yükleyici			
O_1	81,9	87,2	84,7	84,1
O_2	87,0	91,1	88,9	88,3
O_3	85,7	97,3	88,4	87,8
Makine	Sondaj Makinesi			
O_1	86,6	93,1	88,2	87,6
O_2	82,2	95,9	88,8	88,2
O_3	82,8	97,5	89,9	89,3
Makine	Ekskavatör			
O_1	85,4	93,1	87,4	86,8
O_2	86,4	92,9	88,0	87,4
O_3	82,1	95,9	88,7	88,1
Makine	Kamyon			
O_1	85,3	91,6	86,9	86,3
O_2	75,8	90,3	80,7	80,1
O_3	80,9	81,6	82,4	81,8

Gürültü ölçümü yapılan her üç ocak içinde, makine operatörlerinin maruziyetleri için ölçülen değerlerin ($L_{EX,8h}$), Gürültü Yönetmeliğinde belirtilen en düşük maruziyet etkin değerinden yüksek olduğu Şekil 2’de görülmektedir.




Şekil 2. Makineleri kullanan operatörlerin gürültü maruziyet düzeyleri (dBA)

Tüm vücut titreşim maruziyeti ile ilgili 3 ocakta yapılan çalışma sonuçları Çizelge 3'de görülmektedir.

Şekil 3'de verilen grafikte, farklı ocaklarda makine operatörlerinin maruz kaldıkları tüm vücut titreşimi görülmektedir. Makine operatörlerinin tamamının eylem değeri üzerinde titreşime maruz kaldıkları açıkça görülebilmektedir.

Çizelge 3. Ocaklarda makineleri kullanan operatörlerin/çalışanların tüm vücut titreşim maruziyet değerleri (m/s²)


Yer	Ölçüm Yapılan Makine / Ölçüm Değerleri (m/s ²)			
	Yükleyici	Sondaj Makinesi	Ekskavatör	Kamyon
O ₁	0,83	3,32	3,15	1,45
O ₂	1,30	3,48	1,15	0,99
O ₃	1,14	4,80	0,81	1,83



Şekil 2. Makineleri kullanan operatörlerin gürültü maruziyet düzeyleri (dBA)

3.2. Fabrika Gürültü Ölçümleri

Fabrikalar yani kapalı alanlarda akustik ve gürültü problemleri çalışanlar için büyük duyma sorunlarına (geçici/kalıcı duyma kayıplarına) yol açabilmektedir. Bunların tespiti içinde standartlara uygun yapılan ölçümler alınarak tespitler yapılmalıdır. Bu amaçla doğaltaş ebatlama yapan bir fabrikadan, her makinenin 1 m önünden gürültü ölçümleri alınmış ve Çizelge 4’de verilmiştir. Fabrikada 5 S/T, 2 ebatlama ünitesinden ölçümler alınmıştır. Özellikle gürültünün yoğun olduğu bu bölgelerde ölçümler alınarak çalışanların gürültü maruziyetleri tespit edilmiştir. Ölçüm alınan S/T’lerde farklı jeolojik ve mekanik özelliklerde doğaltaşlar kesildiği görülmüştür. Fakat doğaltaşların bu özellikleri ile ilgili kıyaslama/istatistiksel bir çalışma yapılmadığı için bu özelliklere değinilmemiştir. Şekil 4’de fabrikada gürültü ölçümlerinin alındığı makinelerin yerlerini gösteren ölçeksiz bir plan bulunmaktadır. S/T’ler arasında bir bölme bulunmamaktadır. Aynı şekilde ebatlama makineleri arasında da bir bölme bulunmamaktadır.



Şekil 4. Ölçüm yapılan makinelerin fabrika içindeki konumu

Çizelge 4’de fabrikada bulunan makinelerden alınan gürültü ölçüm değerleri görülmektedir.

Burada özellikle S/T’lerin oluşturduğu gürültünün (dBA), ebatlama makinelerinin oluşturduğu gürültüden (dBA) daha yüksek olduğu görülmektedir.

Çizelge 4. Fabrika içinde makineleri kullanan çalışanların gürültü ölçüm değerleri (dBA)

Ölçüm Yeri	Gürültü Değeri (dBA)			
	L_{min}	L_{max}	L_{Aeq}	$L_{EX,8h}$
Ebatlama 1	84,2	91,3	85,8	85,2
Ebatlama 2	84,7	90,9	86,1	85,5
S/T 1	85,9	91,2	87,5	87,9
S/T 2	86,8	100,6	90,9	90,3
S/T 3	81,6	95,4	88,2	87,6
S/T 4	89,2	102,5	92,4	91,8
S/T 5	87,8	100,3	91,2	90,6

4. SONUÇLAR

Ocaklarda kullanılan sondaj makinelerinde, el-kol titreşim maruziyeti, sekiz saatlik çalışma süresi için günlük maruziyet eylem değeri olan $2,5 \text{ m/s}^2$ ’den büyük değerler 0_2 ve 0_3 ocaklarında ölçülmüştür. Maruziyet sınır değeri olan 5 m/s^2 değerinin ise 3 ocakta da aşılmadığı görülmüştür (Çizelge 1).

3 ocakta bulunan yükleyici, sondaj makinesi, kamyon ve ekskavatör operatörlerinin tüm vücut titreşim maruziyetleri ölçülmüş; elde edilen sonuçlar Çizelge 3’de verilmiştir. Tüm değerlerin yönetmelikte verilen maruziyet eylem değerinin üzerinde olduğu Şekil 3’de açıkça görülmektedir. Yönetmelikte tüm vücut için maruziyet eylem değeri $0,5$, sınır değeri ise $1,15 \text{ m/s}^2$ ’dir. Eylem değerinden kasıt, önlem alınması gereken değer iken sınır değer ise çalışmayı kısıtlayacak değerdir.

Gürültü ölçümlerinde; elmas tel kesme makinesinde yapılan ölçümlerde elde edilen değerler her ne kadar maruziyet sınır değeri olan 87 dBA’dan düşük olsa da en düşük maruziyet etkin değeri olan 80 dBA geçtiği için yine de önlemler alınmalıdır. Kulaklık, tıkaç vb. koruyucu donanımlar çalışanların kullanımı temin edilmeli ve çalışanlara bu KKD’lerin kullanımları ile ilgili bilgilendirici eğitim mutlaka verilmelidir.

Ocakta alınan gürültü ölçümlerinde titreşim ölçümlerinde olduğu gibi yine sondaj makinesi en yüksek gürültü seviyesiyle birinci sırada bulunmaktadır. Makine üzerinde incelemeler yapılarak kaynağında gürültü ve titreşim maruziyetlerini azaltıcı faaliyetler yapılmalıdır. Bunun yanı sıra çalışanlara uygun ve etkin kişisel koruyucu donanımlar dağıtılmalıdır.

Fabrika içerisinde yapılan gürültü ölçümlerinde ebatlama makinelerinin ikisinde de en yüksek maruziyet etkin değeri olan 85 dBA'yı geçtikleri görülmektedir.

S/T makinelerinin ise maruziyet sınır değeri olan 87 dBA'nın aşıldığı Çizelge 4'de görülmektedir. S/T 4'ün oluşturduğu gürültü 92,4 dBA ile en yüksek düzeyde bulunmuştur.

Alınabilecek önlemleri ele alırsak;

- Tabii öncelik ortamda korunma önlemleri olmalıdır. Ocak şartlarında da olsa fabrikada da olsa gürültüyü ve titreşimi azaltacak önlemler üzerinde özellikle İş Güvenliği Uzmanı ve ocak sorumlusu (daimî nezaretçi) Maden Mühendisinin birlikte çalışmalar yapmaları çok daha iyi sonuçlar verecektir.

- Gürültü Yönetmeliğinde belirtildiği üzere, "Bu işlerle ilgili risklerin en aza indirilmesi için uygun tedbirler alınır" maddesi uyarınca önlemler alınmalıdır. Makinenin kesim esnasında oluşturduğu bu gürültüden çalışanları koruyabilmek için, çalışanların kişisel koruyucu donanımlarını (KKD) muhakkak kullanmaları sağlanmalıdır.

- Gürültünün ve titreşimin oluşturduğu risklerle mücadelede tabii ki sadece KKD'lerin kullanımı yeterli olmayabilir. İşte bu sebeple; titreşim ve gürültünün etkisini azaltıcı/önleyici ekipmanlar kullanımının yanı sıra çalışanlara muhakkak bu iki fiziksel risk konularında eğitimler verilmelidir. Kişisel koruyucu donanımların kullanımı konusunda hem özendirici çalışmalar yapılmalı hem de kullanılmaması konusunda caydırıcı önlemler mutlaka alınmalıdır. Ödül sisteminin uygulamaya konulması çalışanlar arasında KKD kullanımını teşvik edecektir.

- Makine bakımları makinelerde oluşan titreşim ve gürültünün azaltılması bakımından önem taşımaktadır.

- Fabrika içinde gürültü azaltıcı panel kullanılması faydalı olacaktır.

- Fabrika içinde gürültüsü yüksek olan makinelerin ayrı bir bölümde yer alması gürültü maruziyetini azaltıcı bir etken olacaktır.

- Ayrıca; Titreşim esnasında bakıldığında sadece çalışanlar için değil makineler için de büyük problem oluşturabilecek bir sorundur. Makinelerde titreşim olması genelde arzu edilmez. Makinelerde titreşim oluşumu sırasında, makine parçalarına titreşim sonucu uygulanan kuvvet sonucunda; gürültü, yüksek gerilmeler, aşınma, malzeme yorulması gibi istenmeyen davranışlara meydana gelir. Bu da makinelerde daha fazla arıza meydana gelmesine sebep olur.

Sonuç olarak bakıldığında doğaltaş sektörü hem titreşim hem de gürültü bakımından kişisel maruziyetin yüksek olduğu bir madencilik kolu olarak karşımıza çıkmaktadır.

5. TEŞEKKÜR

Bu makaleyi, 17.MUH.07 numaralı proje ile maddi olarak destekleyen Afyon Kocatepe Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi'ne (BAP) desteklerinden dolayı teşekkür ederiz.

6. KAYNAKLAR

1. Türkiye Cumhuriyeti Ekonomi Bakanlığı, 2021. Doğaltaş Sektör Raporu, Ankara.
2. Zeyrek, S., 2009. Titreşim, İş Sağlığı ve Güvenliği, Uzmanlık Tezi, Çalışma ve Sosyal Güvenlik Bakanlığı İş Sağlığı ve Güvenliği Genel Müdürlüğü, Ankara, 122.
3. Şahin, M.N., Işık, G., 2007. Titreşim, İş Sağlığı ve İş Güvenliği Açısından Etkileri Risklerin Kontrolü ve Uygulamalar, İş Sağlığı ve Güvenliği Sempozyumu, Ankara, 241.

4. Bell, A., 1966. Noise: An Occupational Hazard And Public Nuisance, World Health Organization, Geneva, 61-62.
5. Akbulut, T., 1996. İşçi Sağlığı Prensip ve Uygulamaları, 5. Baskı, Sistem Yayıncılık, 1246, İstanbul.
6. Erkan, N., 1995. Ergonomi. Verimlilik, Sağlık ve Güvenlik İçin İnsan Faktörü Mühendisliği. MPM Yayınları, 373. Genişletilmiş İkinci Basım, Mert Matbaası, Ankara.
7. Çandır, M., 1996. Gürültü, Mühendis ve Makine, TMMOB Makine Mühendisleri Odası Aylık Yayın Organı, Çalışma Güvenliği Özel Sayı, 37(435), 29-32.
8. Çalışanların Gürültü ile İlgili Risklerden Korunmalarına Dair Yönetmelik, 2013. 28721 Sayılı Resmî Gazete.
9. Arıtan, A. E., Tümer, M., 2017. Elmas Telli Sayalama Makinesi Kullanılan Bir Doğaltaş Fabrikasında Ortam Şartlarının Değerlendirilmesi, Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 32(4), 185-192.
10. Afyonkarahisar Haritası, <http://cografyaharita.com/haritalarim/41-afyonkarahisar-ili-haritasi.png>, Erişim tarihi: 21.05.2024.
11. TS 2607 ISO 1999, 2005. Akustik-İş Yerinde Maruz Kalınan Gürültünün Tayini ve Bu Gürültünün Sebep Olduğu İşitme Kaybının Tahmini, Ankara.
12. TS EN 1032+A1, 2011. Mekanik titreşim-Titreşim Emisyon Değerinin Belirlenmesi Amacıyla Hareketli Makinaların Deneye Tabi Tutulması, Türk Standartları Enstitüsü, Ankara.
13. TS EN ISO 5349, 2005. Mekanik titreşim-Kişilerin maruz kaldığı elle iletilen titreşimin ölçülmesi ve değerlendirilmesi-Bölüm 1: Genel kurallar, Türk Standartları Enstitüsü, Ankara.
14. TS ISO 2631-1/A1, 2013. Mekanik titreşim ve şok-tüm vücut titreşime maruz kalma değerlendirilmesi-Bölüm 1: Genel kurallar, Türk Standartları Enstitüsü, Ankara.

Comparison of Random Forest and Support Vector Regression Models in Predicting Hydrogen Production Process from Biomass

Gülbahar BİLGİÇ TÜZEMEN*¹ ORCID 0000-0002-9503-5884
Ali Emre GÖK² ORCID 0009-0009-8292-2132

¹Nevşehir Hacı Bektaş Veli University, Faculty of Engineering-Architecture, Department of Metallurgy and Material Engineering, Nevşehir, Türkiye

²Nevşehir Hacı Bektaş Veli University, Faculty of Engineering-Architecture, Department of Computer Engineering, Nevşehir, Türkiye

Geliş tarihi: 04.01.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: BİLGİÇ, G., GÖK, A.E., (2024). Comparison of Random Forest and Support Vector Regression Models in Predicting Hydrogen Production Process from Biomass. Cukurova University, Journal of the Faculty of Engineering, 39(2), 475-488.

Abstract

The need for energy in the world is increasing day by day and various energy production methods are used to meet this need. Production of hydrogen from biomass is one of these methods. Hydrogen production from biomass is a promising process to produce hydrogen and energy which has advantages such as the ability to use sustainable energy sources like biomass and solid waste, being carbon neutral, and increasing energy independence thanks to the variation of resources and the availability of local resources. The catalysts used in this process which can be conducted in three separate ways, affect hydrogen and energy production positively or negatively. One of the most important steps in effectively acquiring the ideal amount of product is predicting the outcomes of this procedure. This article compares a support vector regression (SVR) and random forest (RF) model to predict how various inputs used to produce hydrogen from biomass will affect hydrogen output. Additionally, the effect of catalyst addition on hydrogen yield in biomass processes was examined. In this context, 57 experimental studies from the literature were selected as a data set. From this data, 90% was selected for training and 10% for testing. The outputs were evaluated according to parameters such as R^2 , RMSE and MSE. The results show that RF and SVR models can significantly predict catalyst activity and hydrogen production.

Keywords: Hydrogen, Biomass, Random forest, Support vector regression

Biyokütleden Hidrojen Üretiminde Rastgele Orman ve Destek Vektör Regresyon Modellerinin Kıyaslaması

Öz

Dünyadaki enerji ihtiyacı günden güne artış göstermekte ve bu ihtiyacın karşılanması için, çeşitli enerji üretim yöntemleri kullanılmaktadır. Bu yöntemlerden biri biyokütleden hidrojen üretimidir. Biyokütle ve atık benzeri yenilenebilir enerji kaynaklarından yararlanma kabiliyeti, karbon nötr olması, kaynak çeşitliliği

*Sorumlu yazar (Corresponding Author): Gülbahar BİLGİÇ TÜZEMEN, glbhrblg@gmail.com

ve yerel kaynakların kullanılabilirliği sayesinde enerji bağımsızlığını artırması gibi avantajları bulunan biyokütleden hidrojen üretimi, gelecek vaat eden bir hidrojen ve enerji üretim sürecidir. Üç farklı yöntem kullanılarak gerçekleştirilebilen bu süreçte kullanılan katalizörler, hidrojen üretimine olumlu ve olumsuz etki etmektedir. Bu sürecin sonuçlarını tahmin etmek, optimum miktarda ürünü verimli bir şekilde elde etmede kritik bir adımdır. Bu makalede, biyokütleden hidrojen üretmek için kullanılan çeşitli girdilerin hidrojen çıktısını nasıl etkileyeceğini tahmin etmek için bir destek vektör regresyonunu (SVR) ve rastgele orman (RF) modelini karşılaştırılmıştır. Ayrıca biyokütle süreçlerinde katalizör ilavesinin hidrojen verimi üzerinde etkisini incelenmiştir. Bu bağlamda literatürden 57 deneysel çalışma veri seti olarak seçilmiştir. Bu verilerden eğitim için %90 ve test için %10 seçilmiştir. Sonuçlar R2, RMSE ve MSE gibi parametrelere göre değerlendirilmiştir. Sonuç olarak RF ve SVR modellerinin katalizör aktivitesini ve hidrojen üretimini önemli ölçüde tahmin edebildiğini göstermektedir.

Anahtar Kelimeler: Hidrojen, Biyokütle, Rastgele orman, Destek vektör regresyonu

1. INTRODUCTION

Nowadays, the majority of H₂ is produced commercially using inefficient and unsustainable methods like coal gasification and methane vapor reforming. Using tried-and-true thermochemical processes like pyrolysis, liquefaction, and gasification, carbonaceous materials may be converted into H₂-rich syngas and other hydrocarbons [1].

The effective thermochemical conversion process called gasification may combine solid biomass into flammable gases, such as carbon monoxide, carbon dioxide, hydrogen, methane, light hydrocarbons, and coal. Solid biomass may then be converted into electrical energy using this procedure. The catalytic gasification of municipal solid waste (MSW) is one of the best methods for producing syngas, or hydrogen-rich gas, from renewable sources [2]. This gas is utilized as feedstock for fuel cell applications and hydrogen combustion engines to release stored energy, or it can be used to create hydrogen to synthesize methanol and ammonia [3]. Moreover, because of the easy conditions and lower temperatures, it also lessens the creation of thermal NO_x [2].

Among thermochemical processes, gasification is seen as the most promising because of its high conversion efficiency and ability to manage various kinds of waste. Nonetheless, the tar produced during gasification is one of the primary issues. Tar content tends to clog pipelines, auxiliary equipment, and heat exchanger tubes, which raises

maintenance costs and reduces process efficiency overall. Significant efforts have been made to remove tar from fuel gas. Thermal processes such as catalytic cracking and high-temperature cracking have been the primary methods used so far. Because catalytic cracking can operate at comparatively lower temperatures and has high tar removal effectiveness, it is believed to be the most effective technology for minimizing tar production in the gas mixture. Due to their unique features in a variety of sectors, nanomaterials have garnered a lot of interest recently as catalysts in comparison to their bulk counterparts.

Many researchers have reported on various catalysts for gasification and pyrolysis processes, each with a different promoter and support [4,5]. Dolomite, nickel, dolomite, and olivine have been extensively used as catalysts in biomass gasification due to their affordability, availability, and ability to significantly reduce tar content in the gasifier effluent [2,6,7].

When paired with transition metal promoters, a catalyst may be used in a variety of ways to catalyze the conversion of MSW. For example, the impact of incorporating transition metal-containing Ni-CaO-based catalysts into Ni-CaO-based catalysts (such as Fe, Cu, Co, and Zn) for gasification and pyrolysis processes has been studied [5,8]. This can improve the process's energy density and efficiency while also raising the total production of syngas and hydrogen [9]. Also, the catalytic characteristics of nanoscale NiO (nano-NiO) particles have garnered significant interest. More precisely, nano-NiO

particles may be applied to the surface of different carriers (such as alumina and Al_2O_3) to produce the supported catalyst at a lower cost [10].

Recently, as in many different fields, there has been a great interest in machine learning (ML) to optimize the operating conditions of the gasification system. Regression analysis, artificial neural networks (ANN) [11,12], tree-based approaches like classification and random forest (RF) [13] based on regression trees (RT) and extreme trees, and support vector machines (SVM) [14] are frequently supported when modeling hydrogen generation processes from biomass [15].

Random forest, first introduced by Breiman [16], is a machine-learning technique that has become popular for prediction, analyzing variable importance, outlier identification, classification, and variable selection. The RF model uses a group of decision trees and an average of their estimations to solve classification or regression problems effectively. The branches of a tree are visited according to a set of constraints and relationships from root to leaf, and each tree selects the most popular one from its branches. These forecasts of related trees are averaged to acquire estimation. Input handling without entries, a smaller number of parameters high accuracy and noise resistance are some of the advantages of RF [16].

Decision trees in RF improve the efficiency of optimization models thanks to their high diversity and low bias. Furthermore, RF has a lower overfitting risk, and it has a hyperparameter for determining the number of estimators (trees) in it. In Figure 1, the schema of the RF algorithm is given. As seen in Figure 1, input data is presented to all the decision trees in the RF. From top to bottom, the nodes of a decision tree are called root, node, and leaf. The root node does not have parent nodes, while leaves do not have any children [17].

A support vector regressor (SVR) is an SVM-based model that is specialized for regression problems. SVR is distinguished by its kernels, number of support vectors, margin control, and sparse solutions. The regression of the SVR is like the regression of neural networks. The main difference

is that in the SVR, input layer weights are a subset of training samples. Even though SVR is less known than SVM, it has been a more effective tool in value estimation. In the training phase, it equally deals with high and low estimations that are wrongly done. In the SVR, the complexity of computations does not change according to input space; this is one of the benefits of the SVR. Besides, the SVR predicts highly accurately and is successful in generalization [18,19]. The schema of the SVR is given in Figure 2.

Mathematical models of the catalytic gasifier system can help cut down on the cost and duration of labor-intensive trials. However, gasification and pyrolysis are complex processes that mostly occur because of overlapping interactions, including solid-gas and gas-gas [19]. In the literature, many researchers have reported on various RF, SVR, and hybrid models for gasification and pyrolysis (the production of hydrogen-rich gas with and without catalysts) processes.

Mutlu, A.Y. and Yucel [20] employed RF and SVM-based classifiers to forecast the composition of syngas emitted during the gasification process because of their capacity to discern subtle patterns in noisy and complicated datasets. Both binary and multi-class classifiers, such as least squares SVM and RF, are trained using calorific values with discrete levels, yielding classification accuracy of over 89% and 96%, respectively. Two types of classifiers have been developed to anticipate the calorific value and composition of the producer gas generated in a downdraft gasifier during the gasification of woody biomass. The proposed methods were created and evaluated using 10-fold cross-validation on 5237 data samples. Binary and multi-class classifiers yielded prediction accuracy rates of more than 96% and 89%, respectively.

Elmaz, F. et. al. [21] assessed regression techniques (SVR, DTR, PR, and MLP) to predict the CH_4 , H, CO, and heating value (HHV) outputs of the downdraft biomass gasification process using an experimentally acquired data set. For HHV determination coefficient (R^2) > 85 outputs and outputs, respectively, MLP and DTR were obtained, and they beat the other methods. Quadratic PR had

the worst performance of all the recommended regression fared better than the other modeling approaches. With $R^2 > 0.9$ for the majority of outcomes, multilayer perceptron and decision tree




Figure 1. The random forest algorithm




Figure 2. The support vector regression

Leng et. al. [41] developed RF models with high accuracy and outstanding generalization capacity to compare both pyrolysis conditions and comprehensive raw material parameters. In this work, gradient boosting, RF-based regression

prediction models for three-phase product distribution and bio-oil HHV were built by collecting experimental data of rapid pyrolysis of lignocellulosic biomass in bubbly fluidized bed from earlier literature. As input attributes,

comprehensive raw material properties and pyrolysis circumstances were considered and compared. With its high accuracy and outstanding generalization ability, the RF has been demonstrated to be the most appropriate algorithm for predicting three-phase product yields and bio-oil HHV among other algorithms.

Xing J et. al. [23] used an RF model to forecast the primary chemical components of biomass based on the final analysis. Two datasets were constructed for the RF model's training and application using previously published information. The application findings demonstrate that the current RF model can predict chemical components for a variety of biomasses with high accuracy; the predicted values for lignin, hemicellulose, and cellulose are 0.962, 0.904, and 0.862, respectively.

Considering this information, the RF and SVR models were chosen to optimize the conditions for hydrogen production processes from biomass and to predict the effect of the catalyst. To collect information for data set preparation, literature studies on hydrogen production by gasification or pyrolysis were evaluated. In this context, 57 published data samples have been collected from experimental studies conducted in the literature. Data from 57 datasets were applied to build and evaluate ML models. As an information preparation process, the inputs are approximate analysis of biomass waste feedstocks, their volatile matter (VM), fixed carbon (FC), hydrogen (H), sulfur (S), carbon (C), nitrogen (N), and oxygen (O), temperature and the name of the catalyst were determined as. Only hydrogen production was considered as output. These examples were divided into training and application types, at rates of 90% and 10%, respectively, as in previous machine learning studies. To our knowledge, this is the first study in the literature on the effect of catalyst use.

In the second stage of this study, the dataset, preprocessing methods, and model evaluation metrics were explained. Afterwards, at the third stage, results obtained from this study were given with related graphics. Finally, in the fourth chapter,

a summary of this study and plans for further research were given.

2. MATERIALS AND METHODOLOGY

2.1. Sample Experimental Dataset Collection

Literature studies on hydrogen obtained from pyrolysis and gasification experiments were evaluated for data set preparation. In the created dataset, MSW samples include kitchen garbage, paper, textiles, plastic, dried sewage sludge, cassava shells, pine sawdust, corn stalks, sawdust, etc. Different biomasses were used. According to earlier machine learning research, such samples are split into training and test types with proportions of 90% and 10%, respectively. In this case, the RF model's inputs are the carbon percent, hydrogen-carbon ratio, and oxygen-carbon ratio; the output is the hydrogen yield. Figure 3 is the visualization of the use of machine learning algorithms for hydrogen output prediction by input and output. Table 1 describes the independent variables of the data set, and Table 2 shows examples of datasets. The data were collected from the sources specified in the literature [2,8,24-35]. Data in which catalysts were not used in production processes where hydrogen was released was also included in the study.




Figure 3. ML algorithms for hydrogen prediction approaches

Table 1. The description of independent variables of input and output

Input		Symbol	Unit
	Carbon	C	wt%
	Hydrogen	H	wt%
	Oxygen	O	wt%
	Nitrogen	N	wt%
	Sulphur	S	wt%
	Volatile matter	VM	wt%
	Fixed carbon	FC	wt%
	Ash		wt%
	Catalyst	Ni-Fe-WMP CaO NiO/MD Ni-Zn-WMP etc.	-
Output	Temperature	°C	Celsius
	Hydrogen Yield	HY	(vol.%)

Table 2. Sample of data set

C	H	O	N	S	VM	FC	Ash	Catalyst	Tem.	HY
52.2	5.5	40	2.3	0	82.7	12	5.3	Nickel based	850	46.5
51.81	5.76	30.22	0.26	0.36	82.28	11.79	5.93	CaMg (CO ₃) ₂	700	27.01
42.11	5.33	37.08	1.42	0.11	73.62	12.43	10.5	CaO	650	61.23
50.48	5.92	42.14	0.27	0.02	75.6	22.9	1.5	without catalyst	848	15.5
50.26	6.72	42.66	0.16	0.2	77.71	16.94	0.34	CaO	650	46.6
42.11	5.33	37.08	1.42	0.11	73.62	12.43	10.5	CaO	650	58.69
46.36	5.75	43.62	2.26	0.32	82.18	16.13	1.69	Nickel based	900	52.3
52.2	5.5	40	2.3	0	82.7	12	26.14	Nickel based	850	46.3
50.26	6.72	42.66	0.16	0.2	77.71	16.94	0.34	CaO	700	56.1
50.26	6.72	42.66	0.16	0.2	77.71	16.94	0.34	CaO	800	53.8
52.2	5.5	40	2.3	0	82.7	12	26.14	Nickel based	850	47.8
42.11	5.33	37.08	1.42	0.11	73.62	12.43	10.5	CaO	650	60.28
51.81	5.76	30.22	0.26	0.36	82.28	11.79	5.93	CaO	900	48.63
42.54	5.86	31.35	1.07	0.2	64.19	16.87	9.26	CaO	700	29.8
49.74	7.82	41.6	0.82	0.05	86.4	10.61	4.77	without catalyst	1000	51.36
40.31	5.29	21.21	5.73	1.32	61.56	7.01	26.14	without catalyst	793	45.35
51.81	5.76	30.22	0.26	0.36	82.28	11.79	5.93	CaO	750	34.7
47.1	5.9	46.9	0.1	0	74.6	18.1	1.1	Nickel based	800	49
50.26	6.72	42.66	0.16	0.2	77.71	16.94	0.34	CaO	750	60.8

Both RF and SVR models have hyperparameters that affect model performance positively and negatively. The RF has hyperparameters such as the number of estimators (number of trees), criterion, max depth, min samples split, min samples leaf, max features, bootstrap, and random state. Cost (C),

kernel, epsilon, gamma, degree and shrinking are hyperparameters used in the SVR model. In this study, the number of estimators, min samples split, and min samples leaf hyperparameters in the RF model and in the SVR model, C, kernel, and epsilon hyperparameters were used as presented in Table 3.

Table 3. Tuning parameters and values of applied methods

Method	Tuning parameter	Value
RF	Number of estimators	10
	Min samples split	2
	Min samples leaf	1
SVR	Cost (C)	2.811
	Kernel	linear
	Epsilon	0.67

2.2. Feature Extraction and Preprocessing

Once data collection was completed, some data pre-processing techniques were applied to the dataset to improve the models' performance. Since ML and deep learning models struggle to work with categorical data, they must be presented numerically. Therefore, the one-hot encoding method was applied to the dataset. This method transforms every categorical data into a column, and the presence and absence are respectively indicated with 1 and 0 values. Thanks to one-hot encoding, models understand the dataset better and perform better [12]. Another pre-processing technique that was applied to the dataset was normalization. Normalization is the scaling of data to a certain general range or distribution. That allows comparison between different data sets and improves performance. Besides, it reduces the complexity of the calculation process and calculation time. In this study, the dataset was normalized to a (-1, 1) interval by using the corresponding Python library [36]. The dataset was split into training and test sets once pre-processing was finished. The remaining 90% of the data was

utilized in the test set for model evaluation, with the training set being used for model training.

2.3 Evaluation

Following model development, the model accuracy and performance were assessed. The models' performance was assessed using the determination coefficient (R^2), variance, mean square error (MSE), root mean square error (RMSE), and mean absolute error (MAE) [2].

In our example, the RF and SVR models include storage data obtained from the biomass gasification and pyrolysis methods. As part of the information preparation process, the inputs were determined as the name of biomass waste feedstocks, VM, FC, C, H, N, S, O, temperature, and catalyst. The output/targeted variable was selected as H_2 . For the training data, a total of 52 runs (or 90% of the data) and 5 runs (10% of the data) were chosen by [37]. R^2 , RSME, MAE and MSE, represented by the equations in Table 4 respectively, were used for the model's accuracy values.

Table 4. Evaluation indicators of models' prediction performance

Method	Mathematical expression
Mean absolute error	$\frac{1}{n} \sum_{i=1}^n f_i - y_i $
Mean square error	$\frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2$
Root mean square error	$\sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2}$
Determination coefficient	$1 - \frac{\sum_{i=1}^n (y_i - f_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$

3. RESULT AND DISCUSSION

3.1. Performance Evaluation of Test Results

Table 5 shows the results of the two models' ML analyses (RF and SVR). The models used in this study were evaluated separately for both train and test sets based on MAE, MSE, RMSE, and R^2 . The

values of each metric are given in Table 5 and Figure 4. The data that are divided into test and training data at different rates have a coefficient of determination that ranges from 0.57 to 0.98, according to the results. R^2 was found to be 0.98 in the RF model and 0.94 in the SVR model. For the test data in the RF model, the minimal values of the criterion MAE, MSE, and RMSE were determined

to be 1.00, 1.31, and 1.15, respectively. For the test data in the SVR model as well, the minimum values of the criterion MAE, MSE, and RMSE were determined to be 1.34, 3.67, and 1.92, respectively. For the training data in the RF model, it was discovered that the minimal values of the criterion MAE, MSE, and RMSE were 2.64, 12.00, and 3.47, respectively. These results indicate that the RF model is more performant than the SVR model.

1.92) showed that the model was good at forecasting unknown data. However, the SVR model's deficient performance on the training dataset, with an $R^2 = 0.57$ and an $RMSE = 8.80$, showed its low predictive ability with known data. In Figures 5 and 6, prediction performances of the RF and SVR models in the test dataset are given. While real values are shown with the red line, estimations of the models are shown with circles.

Figure 4 shows the hydrogen yield prediction performances of the RF (a) and SVR (b) models on the training set. The expected values are shown with the red line and predictions are shown with stars. The RF model's training RMSE and R^2 values were obtained as 3.47 and 0.93, respectively, while these values were obtained as 1.15 and 0.98 in the test dataset. These values proved its dependability in forecasting unknown data. The performance of the SVR model in the test set ($R^2 = 0.94$ and $RMSE =$

The relative error distribution of the models is given in Figure 7. Analysis of relative error distribution is used for analyzing the reliability and performance of the models. It helps to understand how accurate or inaccurate the predictions are and to improve the models accordingly. In Figure 7, The blue and orange dots show the test and train error distribution of the RF model, while the green and red dots show the test and train error distribution of the SVR model, respectively.

Table 5. Analysis of train and test set outcomes of models

Method	Dataset	MAE	MSE	RMSE
RF	Train	2.64	12.00	3.47
	Test	1.00	1.31	1.15
SVR	Train	6.35	77.42	8.80
	Test	1.34	3.67	1.92

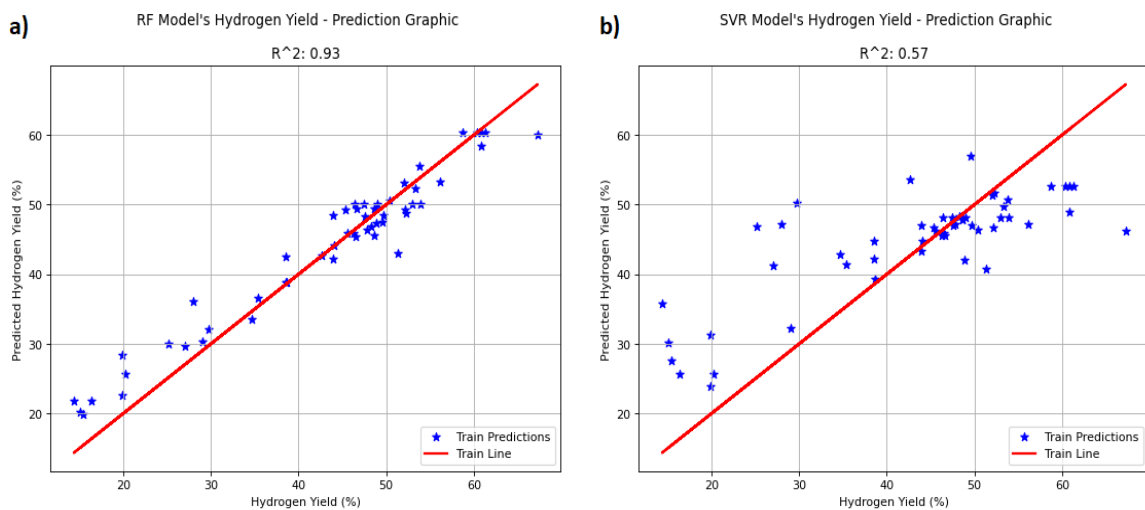


Figure 4. Hydrogen yield prediction performances of random forest (a) and support vector regressor (b) models on the training dataset




Figure 5. Prediction performance and R^2 score of random forest model




Figure 6. Prediction performance and R^2 score of support vector regression model




Figure 7. Relative error distribution of the models

3.2. Sensitivity Analysis

When assessing the degree of relationship between two variables, the Pearson correlation coefficient is commonly employed. A Pearson correlation coefficient (r) matrix is displayed in Figure 8, with each row denoting a variable from the dataset and each column representing the same variables [38]. The correlation coefficient between two variables is shown in each cell. The hydrogen generation is shown to be significantly influenced by the feedstock and experimental operating conditions, as indicated by the Pearson correlation coefficient matrix. The high positive correlations between feedstock attributes show that the choice of feedstock has a major effect on hydrogen generation. The positive relationship between carbon, hydrogen, volatile mixtures, and fixed carbon mixtures shows that the composition of the feedstock has a direct effect on the hydrogen yield. In contrast, the mixture of nitrogen, sulfur, and temperature has a negative relationship with pyrolytic product yields [15]. Since each feature contributes separately to the model, the absence of significant correlations between multiple input features helps preserve all these features. The negative correlation in both trait values indicated that these products reduced yield. Other attributes, on the other hand, showed fewer effects on hydrogen yield, with absolute correlation values less than 0.15. For instance, there was a 0.49 correlation coefficient between the carbon and oxygen levels of biomass characteristics. This result was in line with earlier experimental research [39].

The significance of specifying input variables in the hydrogen output of the RF model for the biomass process is illustrated in Figure 9. It is evident that the catalyst is a key factor in the predicted generated gas (26 % together), while it is also important for temperature (14%), H (16 %), N (7 %), FC (6 %), VM (6 %), ash (6 %) and less important for C (7 %), O (0.0256 %) and S (5%). Therefore, this study has proven that the catalyst has a powerful, positive effect on HP.

4. CONCLUSIONS AND FURTHER RESEARCH

Because biomass has a high conversion efficiency, gasification has drawn interest from academic and industry researchers. Nonetheless, the primary obstacle to the advancement of biomass gasification is tar production. Researchers have employed different catalysts to break down tar and create H₂-rich gas. Machine learning can help the process, though, as there is still a dearth of material in this field in the literature. Based on earlier research, the best catalyst to employ for this purpose was identified. This work uses SVR and RF algorithms to anticipate hydrogen generation. The machine learning evaluation accurately predicted the sort of catalyst that would be utilized to produce hydrogen from waste biomass. In addition, an assessment of each variable's relative relevance was made. For the RF and SVR methods, the R² values were 0.98 and 0.94, respectively. From the modeling results, it was seen that nickel-based and calcium-oxide catalysts would be more suitable. Furthermore, the training phase yields accuracies of 1.15 to 1.92 of RMSE, and 1.00 to 1.34 of MAE. It was evident from the modeling findings that catalysts based on calcium oxide and nickel would be more appropriate.

According to our knowledge, this is the first study in the literature on the effect of catalyst use. Additionally acquiring experimental data is a costly and prolonged process. Therefore, the dataset used in this study is limited. This limitation has a negative impact on the training and generalization abilities of the models. In further research, better results may be obtained by collecting a dataset that has more samples and a balanced distribution. In addition, the models have some limitations. The SVR model has limitations such as the determination of the kernel function, hyperparameter adjustment and data scaling. The SVR model's performance is dependent on its kernel function and hyperparameters. Determining the right type of kernel function and finding the best hyperparameters are crucial while using that model. The SVR model is also affected by the data scaling.

Improper scaling data may affect the performance negatively. The RF model has limitations such as the high cost of computation and the long processing time.




Figure 8. Correlation between parameters




Figure 9. Feature importance (%) of input variables on hydrogen output of RF model for Biomass process

5. REFERENCES

1. Jamro, I.A., Raheem, A., Khoso, S., Baloch, H.A., Kumar, A., Chen, G., Bhagat, W.A., Wenga, T., Ma, W., 2023. Investigation of Enhanced H₂ Production from Municipal Solid Waste Gasification Via Artificial Neural Network with Data on Tar Compounds. *Journal of Environmental Management*, 328, 117014.
2. He, M., Hu, Z., Xiao, B., Li, J., Guo, X., Luo, S., Yang, F., Feng, Y., Yang, G., Liu, S., 2009. Hydrogen-rich Gas from Catalytic Steam Gasification of Municipal Solid Waste (MSW): Influence of Catalyst and Temperature on Yield and Product Composition. *International Journal of Hydrogen Energy*, 34(1), 195-203.
3. Wu, M.-H., Lin, C.-L., Zeng, W.-Y., 2014. Effect of Waste Incineration and Gasification Processes on Heavy Metal Distribution. *Fuel Processing Technology*, 125, 67-72.
4. Gao, N., Liu, S., Han, Y., Xing, C., Li, A., 2015. Steam Reforming of Biomass Tar for Hydrogen Production over NiO/Ceramic Foam Catalyst. *International Journal of Hydrogen Energy*, 40(25), 7983-7990.
5. Irfan, M., Li, A., Zhang, L., Javid, M., Wang, M., Khushk, S., 2019. Enhanced H₂ Production from Municipal Solid Waste Gasification Using Ni-Cao-TiO₂ Bifunctional Catalyst Prepared by DC Arc Plasma Melting. *Industrial & Engineering Chemistry Research*, 58(29), 13408-13419.
6. Zhou, C., Yrjas, P., Engvall, K., 2021. Reaction Mechanisms for H₂O-Enhanced Dolomite Calcination at High Pressure. *Fuel Processing Technology*, 217, 106830.
7. Soomro, A., Chen, S., Ma, S., Xiang, W., 2018. Catalytic Activities of Nickel, Dolomite, and Olivine for Tar Removal and H₂-Enriched Gas Production in Biomass Gasification Process. *Energy & Environment*, 29(6), 839-867.
8. Irfan, M., Li, A., Zhang, L., Ji, G., Gao, Y., Khushk, S., 2021. Hydrogen-rich Syngas from Wet Municipal Solid Waste Gasification Using Ni/waste Marble Powder Catalyst Promoted by Transition Metals. *Waste Management*, 132, 96-104.
9. Li, B., Magoua Mbeugang, C. F., Huang, Y., Liu, D., Wang, Q., Zhang, S., 2022. A Review of Cao Based Catalysts for Tar Removal During Biomass Gasification. *Energy*, 244, 123172.
10. Shen, Y., Yoshikawa, K., 2013. Recent Progresses in Catalytic Tar Elimination During Biomass Gasification or Pyrolysis - A Review. *Renewable and Sustainable Energy Reviews*, 21, 371-392.
11. Bilgiç, G., Bendeş, E., Öztürk, B., Atasever, S., 2023. Recent Advances in Artificial Neural Network Research for Modeling Hydrogen Production Processes. *International Journal of Hydrogen Energy*, 48(50), 18947-18977.
12. Bilgiç, G., Öztürk, B., Atasever, S., Şahin, M., Kaplan, H., 2023. Prediction of Hydrogen Production by Magnetic Field Effect Water Electrolysis Using Artificial Neural Network Predictive Models. *International Journal of Hydrogen Energy*, 48(53), 20164-20175.
13. Qi, J., Zhang, K., Hu, M., Xu, P., Huhe, T., Ling, X., Yuan, H., Wang, Y., Chen, Y., 2023. Study on Waste Tire Pyrolysis Product Characteristics Based on Machine Learning. *Journal of Environmental Chemical Engineering*, 11(6), 111314.
14. Lei, C., Deng, J., Cao, K., Xiao, Y., Ma, L., Wang, W., Ma, T., Shu, C., 2019. A Comparison of Random Forest and Support Vector Machine Approaches to Predict Coal Spontaneous Combustion in Gob. *Fuel*, 239, 297-311.
15. Potnuri, R., Rao, C.S., Surya, D.V., Kumar, A., Basak, T., 2023. Utilizing Support Vector Regression Modeling to Predict Pyro Product Yields from Microwave-Assisted Catalytic Co-pyrolysis of Biomass and Waste Plastics. *Energy Conversion and Management*, 292, 117387.
16. Breiman, L., 2001. Random Forests. *Machine Learning*, 45(1), 5-32.
17. Yu, P.-S., Yang, T.-C., Chen, S.-Y., Kuo, C.-M., Tseng, H.-W., 2017. Comparison of Random Forests and Support Vector Machine for Real-Time Radar-Derived Rainfall Forecasting. *Journal of Hydrology*, 552, 92-104.

18. Smola, A.J., Schölkopf, B., 2004. A Tutorial on Support Vector Regression. *Statistics and Computing*, 14(3), 199-222.
19. Awad, M., Khanna, R., 2015. *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers*. Springer Natures, 268.
20. Mutlu, A. Y., Yucel, O., 2018. An Artificial Intelligence Based Approach to Predicting Syngas Composition for Downdraft Biomass Gasification. *Energy*, 165, 895-901.
21. Elmaz, F., Yücel, Ö., Mutlu, A.Y., 2020. Predictive Modeling of Biomass Gasification with Machine Learning-based Regression Methods. *Energy*, 191, 116541.
22. Leng, E., He, B., Chen, J., Liao, G., Ma, Y., Zhang, F., Liu, S., E, J., 2021. Prediction of Three-phase Product Distribution and Bio-oil Heating Value of Biomass Fast Pyrolysis Based on Machine Learning. *Energy*, 236, 121401.
23. Xing, J., Luo, K., Wang, H., Fan, J., 2019. Estimating Biomass Major Chemical Constituents from Ultimate Analysis Using a Random Forest Model. *Bioresource Technology*, 288, 121541.
24. Irfan, M., Li, A., Zhang, L., Ji, G., Gao, Y., Khushk, S., 2021. Hydrogen-rich Syngas from Wet Municipal Solid Waste Gasification Using Ni/waste Marble Powder Catalyst Promoted by Transition Metals. *Waste Management*, 132, 96-104.
25. Choi, Y.-K., Cho, M.-H., Kim, J.-S., 2015a. Steam/oxygen Gasification of Dried Sewage Sludge in a Two-stage Gasifier: Effects of the Steam to Fuel Ratio and Ash of the Activated Carbon on the Production of Hydrogen and Tar Removal. *Energy*, 91, 160-167.
26. Kargbo, H.O., Zhang, J., Phan, A.N., 2023. Robust Modelling Development for Optimisation of Hydrogen Production from Biomass Gasification Process Using Bootstrap Aggregated Neural Network. *International Journal of Hydrogen Energy*, 48(29), 10812-10828.
27. Luo, S., Xiao, B., Hu, Z., Liu, S., Guo, X., He, M., 2009. Hydrogen-rich Gas from Catalytic Steam Gasification of Biomass in a Fixed Bed Reactor: Influence of Temperature and Steam on Gasification Performance. *International Journal of Hydrogen Energy*, 34(5), 2191-2194.
28. Nahil, M.A., Wang, X., Wu, C., Yang, H., Chen, H., Williams, P.T., 2013. Novel Bi-functional Ni-Mg-Al-Cao Catalyst for Catalytic Gasification of Biomass for Hydrogen Production with in Situ CO₂ Adsorption. *RSC Advances*, 3(16), 5583.
29. Luo, S., Xiao, B., Hu, Z., Liu, S., Guo, X., He, M., 2009. Hydrogen-rich Gas from Catalytic Steam Gasification of Biomass in a Fixed Bed Reactor: Influence of Temperature and Steam on Gasification Performance. *International Journal of Hydrogen Energy*, 34(5), 2191-2194.
30. Barontini, F., Frigo, S., Gabbriellini, R., Sica, P., 2021. Co-gasification of Woody Biomass with Organic and Waste Matrices in a Down-draft Gasifier: An Experimental and Modeling Approach. *Energy Conversion and Management*, 245, 114566.
31. Li, B., Yang, H., Wei, L., Shao, J., Wang, X., Chen, H., 2017. Hydrogen Production from Agricultural Biomass Wastes Gasification in a Fluidized Bed with Calcium Oxide Enhancing. *International Journal of Hydrogen Energy*, 42(8), 4832-4839.
32. Gao, N., Liu, S., Han, Y., Xing, C., Li, A., 2015. Steam Reforming of Biomass Tar for Hydrogen Production over NIO/ceramic Foam Catalyst. *International Journal of Hydrogen Energy*, 40(25), 7983-7990.
33. Yusup, S., Khan, Z., Ahmad, M.M., Rashidi, N.A., 2014. Optimization of Hydrogen Production in In-situ Catalytic Adsorption (ICA) Steam Gasification Based on Response Surface Methodology. *Biomass and Bioenergy*, 60, 98-107.
34. Wei, L., Xu, S., Liu, J., Liu, C., Liu, S., 2008. Hydrogen Production in Steam Gasification of Biomass with CaO as a CO₂ Absorbent. *Energy & Fuels*, 22(3), 1997-2004.
35. Faki, E., Üzden, Ş.T., Seçer, A., Hasanoğlu, A., 2022. Hydrogen Production from Low Temperature Supercritical Water CO-Gasification of Low Rank Lignites with Biomass. *International Journal of Hydrogen Energy*, 47(12), 7682-7692.

36. Ozbas, E.E., Aksu, D., Ongen, A., Aydin, M.A., Ozcan, H.K., 2019. Hydrogen Production Via Biomass Gasification, and Modeling by Supervised Machine Learning Algorithms. *International Journal of Hydrogen Energy*, 44(32), 17260-17268.
37. Balsora, H.K., Kartik, S., Joshi, J.B., Sharma, A., Chakinala, A.G., 2023. Artificial Neural Network-based Models for the Prediction of Biomass Pyrolysis Products from Preliminary Analysis. *Industrial & Engineering Chemistry Research*, 62(36), 14311-14319.
38. Chen, Y., Wang, Z., Lin, S., Qin, Y., Huang, X., 2023. A Review on Biomass Thermal-oxidative Decomposition Data and Machine Learning Prediction of Thermal Analysis. *Cleaner Materials*, 9, 100206.
39. Onsree, T., Tippayawong, N., 2021. Machine Learning Application to Predict Yields of Solid Products from Biomass Torrefaction. *Renewable Energy*, 167, 425-432.

A Comparative Study on Data Balancing Methods for Alzheimer's Disease Classification

Esma ÖTER¹ ORCID 0009-0007-9823-2836

Yahya DOĞAN^{*1} ORCID 0000-0003-1529-6118

¹Siirt University, Faculty of Engineering, Department of Computer Engineering, Siirt, Türkiye

Geliş tarihi: 07.01.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ÖTER, E., DOĞAN, Y., (2024). A Comparative Study on Data Balancing Methods for Alzheimer's Disease Classification. Cukurova University, Journal of the Faculty of Engineering, 39(2), 489-501.

Abstract

Alzheimer's disease is a prevalent neurological disorder affecting millions of people worldwide, often associated with the aging process, leading to the death of nerve cells in the brain and loss of connections. Recently, promising results have been demonstrated in diagnosing Alzheimer's disease using deep learning models, and various approaches for early diagnosis have been proposed. However, the imbalance in health datasets, particularly those containing rare cases, can lead to performance losses and misleading results during model training. This study focuses on these imbalance issues, evaluating the effectiveness of different balancing methods using the Alzheimer's MRI dataset. In this context, the performance of SMOTE, ADASYN, and Weight Balancing methods is compared using a custom model. Experimental results indicate that, compared to the original imbalanced dataset, Weight balancing outperforms in terms of accuracy, precision, recall, and F1 score. While SMOTE and ADASYN show improvement in various metrics, they are considered inferior to the Weight Balancing method. This study contributes to selecting data-balancing methods to enhance the accuracy of deep learning models in Alzheimer's disease classification and emphasizes the importance of addressing class imbalances in health datasets.

Keywords: Deep learning, Convolutional neural networks, SMOTE, ADASYN, Weight balancing

Alzheimer Hastalığı Sınıflandırması için Veri Dengeleme Yöntemlerinin Karşılaştırmalı Bir Çalışması

Öz

Alzheimer hastalığı, dünya genelinde milyonlarca insanı etkileyen yaygın bir nörolojik bozukluktur ve genellikle yaşlanma süreciyle ilişkilidir; beyinde sinir hücrelerinin ölümüne ve bağlantı kaybına neden olur. Son zamanlarda, derin öğrenme modelleri kullanılarak Alzheimer hastalığının teşhisi konusunda umut verici sonuçlar elde edilmiş ve erken teşhis için çeşitli yaklaşımlar önerilmiştir. Ancak, özellikle nadir durumları içeren sağlık veri setlerindeki dengesizlik, model eğitimi sırasında performans kayıplarına ve yanıltıcı sonuçlara yol açabilir. Bu çalışma, bu dengesizlik sorunlarına odaklanarak, Alzheimer MRI veri seti için farklı dengeleme yöntemlerinin etkinliğini değerlendirmektedir. Bu bağlamda, özel bir model kullanılarak SMOTE, ADASYN ve Ağırlık Dengesi yöntemlerinin performansı karşılaştırılmaktadır.

*Sorumlu yazar (Corresponding Author): Yahya DOĞAN, yahyadogan@siirt.edu.tr

Deneyisel sonuçlar, orijinal dengesiz veri setine kıyasla Ağırlık Dengesi yönteminin doğruluk, hassasiyet, geri çağrı ve F1 skoru açısından daha üstün olduğunu göstermektedir. SMOTE ve ADASYN, çeşitli metriklerde iyileşme göstermesine rağmen, Ağırlık Dengesi yöntemine kıyasla daha düşük performansa sahip oldukları gözlemlenmiştir. Bu çalışma, Alzheimer hastalığı sınıflandırmasında derin öğrenme modellerinin doğruluğunu artırmak için veri dengeleme yöntemlerinin seçimine katkıda bulunur ve sağlık veri setlerinde sınıf dengesizliğinin ele alınmasının önemini vurgular.

Anahtar Kelimeler: Derin öğrenme, Evrimsel sinir ağları, SMOTE, ADASYN, Ağırlık dengeleme

1. INTRODUCTION

Alzheimer's disease, a prevalent neurological disorder that impacts approximately 50 million individuals globally, presents a significant challenge in the field of healthcare [1]. As this neurodegenerative disease progresses, it poses a serious threat to an individual's general health, potentially leading to death in the event of complete brain failure. Because of the broad loss of nerve cells across the brain, Alzheimer's has a far-reaching impact, extending to basic skills such as writing, speaking, and reading. Notably, people in the cognitive stages of Alzheimer's disease may have difficulty identifying their family members.

The insidious nature of Alzheimer's disease, distinguished by its gradual onset of symptoms, makes accurate and early diagnosis difficult [2]. The importance of early-stage identification, on the other hand, cannot be stressed, as it allows for rapid intervention and therapy, ultimately contributing to a better prognosis for people suffering from this complicated neurodegenerative disorder [3]. In this context, developing efficient diagnostic methods is critical to improving our ability to combat Alzheimer's disease and lessen its devastating effects on people and society as a whole.

Deep learning algorithms have seen substantial success in a variety of fields [4-7]. Consequently, the importance of deep learning-based approaches in the diagnosis of Alzheimer's disease has been rapidly increasing [8-11]. Various methods have been presented in this field to assist clinicians in making educated medical decisions as diagnostic aids for Alzheimer's disease. Lu et. al. [12] introduced an innovative multimodal deep neural network employing a multistage technique for the detection of dementia. Their method demonstrated

notable success, achieving an accuracy of 82.4% in predicting mild cognitive impairment (MCI) and identifying individuals who later developed Alzheimer's disease within three years. The model exhibited a notable sensitivity of 94.23% in Alzheimer's disease detection and achieved an accuracy of 86.3% for the non-demented class. Ahmed et. al. [13] proposed an ensemble CNN model for Alzheimer's disease (AD) diagnosis that used a feature extractor and the Softmax classifier. The model, designed to avoid overfitting, performed well, obtaining an accuracy of 90.05% by utilizing MRI images centered on the left and right hippocampal sections. Liu et. al. [14] utilized siamese neural networks to assess whole-brain volumetric asymmetry. They used the MRI cloud approach to produce low-dimensional descriptors for designated atlas brain structures. They employed a unique non-linear kernel method to normalize features, eliminating batch effects across different datasets and populations. Using the ADNI dataset, the networks achieved a balanced accuracy of 92.72% in the classification of MCI and Alzheimer's disease. Sarraf et. al. [15] suggested a deep learning pipeline for feature categorization that focused on processes that don't change with scale or shift and included a CNN model trained on a large dataset. The model performed well, with accuracy rates of 94.32% for functional MRI and 97.88% for MRI images.

The analysis of datasets in the field of healthcare typically begins with the challenges encountered in the process of collecting samples related to specific health conditions or diseases. One of these challenges arises from the rarity of certain health conditions or the limited number of samples belonging to specific classes, leading to an imbalance in the datasets. The collection of samples associated with rarely occurring diseases or specific

health conditions can adversely affect the effectiveness of analysis and classification models. This imbalance can lead to performance losses and misleading outcomes during model training. This study focuses on addressing the imbalance issues in healthcare datasets and investigates the performance of methods developed to overcome this challenge.

In the case of Alzheimer's disease diagnosis with deep learning algorithms, imbalanced datasets are a common issue. This occurs when one class has significantly more examples than the other. For instance, in Alzheimer's disease, the number of non-diseased individuals typically far exceeds that of diseased individuals. This imbalance negatively impacts the performance of classification models. In imbalanced datasets, the model tends to overfit the majority class and fails to learn accurately from the minority class. Consequently, it correctly classifies majority class examples but performs poorly on minority class examples. This leads to significant performance issues, especially when the minority class is critically important. In Alzheimer's disease, misclassification of the minority class can have serious consequences, such as missed opportunities for early intervention and treatment. Although overall accuracy might appear high, these metrics can be misleading for the minority class. In this context, the performance of dataset balancing methods is analyzed using the Alzheimer's MRI dataset.

2. MATERIALS AND METHODS

This section covers the dataset, model, strategies for dealing with data imbalances, training details, and metrics.

In this study, the Alzheimer's MRI Dataset [16] from the Kaggle website was used, which included four separate classes: non-demented, very mild, mild, and moderate. It is important to highlight that the dataset is unbalanced. The class distributions are as follows: Non-demented (3200 samples), very mild (2240 samples), moderate (64 samples), and mild (896 samples). Figure 1 shows a histogram indicating the distribution of each class. This dataset comprises a total of 6400 MRI images representing various levels of dementia.




Figure 1. Class distribution of the Alzheimer's MRI dataset

The dataset was partitioned into three independent subsets during the training process-training, testing, and validation sets-to properly evaluate the model's performance. Specifically, 85% of the dataset has been set aside for training, with the remaining 15% set aside for testing. Furthermore, 15% of the training dataset has been put aside to serve as the validation set to assess the model's generalization abilities. Figure 2 shows several random samples from the dataset




Figure 2. Random samples from the Alzheimer's MRI dataset

A. Model

To assess the performance of proposed interventions for the data imbalance problem, a custom model was created. The primary objective of this model is to classify a given input image and generate probability distributions for four different

classes as outputs. The model incorporates convolutional layers for feature extraction and complexity reduction, activation functions to introduce non-linearity, pooling layers to decrease the size of feature maps, batch normalization layers

to normalize inputs for each layer within the network, and dense layers for classification purposes. In Figure 3, details of each layer used in the model, such as the number of kernels, kernel size, input, and output dimensions, are provided.




Figure 3. A custom model created for comparing various approaches to address the issue of data imbalance

B. Methods for Addressing Data Imbalance

In this section, we discuss dataset balancing methods for imbalanced classification problems, where there is a skewed distribution of classes in the dataset and one class (usually the minority class) has significantly fewer examples than the others.

1. SMOTE (Synthetic Minority Over-Sampling Technique) [17]: This method draws inspiration from a technique used in handwritten character recognition, aiming to produce synthetic examples for the minority class. Rather than resorting to replacement over-sampling, a more specific approach is introduced by producing synthetic examples in the feature space as opposed to the data space.

The minority class is the focus of this method, and synthetic examples are constructed by extending along line segments linking any or all of its k nearest neighbours. The number of neighbours chosen at random from the k nearest neighbours is determined

by the degree of oversampling. The current implementation makes use of information from the five closest neighbours. For example, if a 200% over-sampling is desired, two neighbours are chosen at random from the five closest neighbours, and a synthetic example is constructed in each direction.

Creating synthetic examples entails calculating the difference between the current example's feature vector and its nearest neighbor. This difference is then multiplied by a number between 0 and 1, and the result is added to the feature vector. As a result, a point is generated randomly within the line segment connecting two specific features. This novel method efficiently broadens the deciding zone of the minority class, encouraging broader representation.

SMOTE offers several advantages and disadvantages for addressing class imbalances in datasets. Advantages include improved minority class representation by generating synthetic

examples, enhanced model performance in terms of accuracy, recall, and F1 score by providing a balanced training dataset and reducing overfitting by creating varied samples instead of duplicating minority class samples. Additionally, SMOTE helps establish better decision boundaries by broadening the minority class's decision zone and applies to various classification algorithms, making it a versatile tool.

Disadvantages include the potential introduction of synthetic noise into the dataset, which can negatively impact model performance if the generated samples are not representative of the true data distribution. The method also increases computational complexity as synthetic samples are generated and the k-nearest neighbors are determined, particularly for large datasets. There is a risk of overgeneralization, where the classifier may become too lenient in distinguishing between classes, reducing specificity. Furthermore, SMOTE's effectiveness is sensitive to parameter settings, such as the number of nearest neighbors (k) and the degree of over-sampling; poorly chosen parameters can adversely affect performance. In high-dimensional feature spaces, the nearest neighbor search and synthetic sample generation can become less effective, potentially leading to suboptimal results.

2. ADASYN (Adaptive Synthetic Sampling) [18]:

In this method, an adaptive approach, inspired by recently successful synthetic methods such as SMOTE [17], SMOTEBoost [19], and DataBoostIM [20], is proposed to make learning from imbalanced datasets. The dual goal is to decrease bias while also enabling adaptive learning. The fundamental concept underlying the ADASYN algorithm involves employing a density distribution as a criterion to autonomously determine the number of synthetic samples required for each minority data instance. The degree of class imbalance is initially estimated using Equation 1 as follows:

$$d = m_s/m_l \tag{1}$$

Where $d \in (0,1]$ defines m_s and m_l as the quantities of minority and majority class instances,

respectively. If d is less than a predefined threshold for the maximum tolerable degree of class imbalance, Equation 2 determines the required amount of synthetic data samples for the minority class. This ratio $d \in (0, 1]$ indicates the extent of imbalance in the dataset. A lower value of d signifies a higher degree of imbalance.

$$G = (m_l - m_s) \times \beta \tag{2}$$

The total number of synthetic samples G needed for the minority class is determined by the difference between the majority class instances m_l and the minority class instances m_s , multiplied by the balance level parameter β . This ensures that the dataset moves towards a balanced state as defined by β . The parameter $\beta \in [0, 1]$ indicates the targeted balance level following synthetic data generation. A value of $\beta = 1$ signifies the creation of a completely balanced dataset after the augmentation process. For each instance, x_i in the minority class, the K nearest neighbors are identified based on Euclidean distance in an n-dimensional space, and the r_i ratio is calculated as follows:

$$r_i = \frac{\Delta_i}{K}, \quad i = 1, 2, 3, \dots, m_s \tag{3}$$

Where Δ_i represents the count of instances in the K nearest neighbors of x_i that are from the majority class, resulting in $r_i \in [0, 1]$. This ratio helps in identifying how challenging it is for the model to classify the minority instance correctly. r_i is then normalized as follows:

$$\hat{r}_i = r_i / \sum_{i=1}^{m_s} r_i \tag{4}$$

Where \hat{r}_i represents a density distribution. This ensures that the synthetic samples are generated in proportion to the difficulty of the minority instances. The computation of the quantity of synthetic data samples to generate for each minority instance x_i is determined as follows:

$$g_i = \hat{r}_i \times G \tag{5}$$

Where G denotes the overall quantity of synthetic data instances needed for the minority class, as specified in Equation (2). This adaptive approach

ensures that more synthetic samples are generated for the harder-to-learn minority instances. For each minority class data instance x_i , a loop from 1 to g_i is created, and synthetic data samples are generated using the following equation.

$$s_i = x_i + (x_{z_i} - x_i) \lambda \quad (6)$$

A randomly selected minority data instance, x_{z_i} , is chosen from the K nearest neighbors of data x_i . Here, $(x_{z_i} - x_i)$ is the vector of distinction in an n -dimensional space, and λ is a random number: $\lambda \in [0,1]$. Physically, it is a metric that evaluates how weights are distributed among various instances within the minority class, considering their respective difficulty levels in learning. The dataset obtained after applying ADASYN not only achieves a balanced representation of the data distribution based on the specified balance level (determined by the β coefficient) but also directs the learning algorithm to focus on these particularly challenging instances. This is a significant distinction, particularly when compared to the SMOTE, where an equal number of synthetic samples are produced for each minority data instance.

ADASYN offers several advantages and disadvantages for addressing class imbalance in datasets. Advantages involve adaptive sample creation, which creates more synthetic examples for harder-to-learn instances, allowing the model to focus on challenging cases. This adaptive approach can improve overall classifier performance, particularly in terms of recall for the minority class. ADASYN provides dynamic balancing by adjusting the number of synthetic samples based on the density distribution of the minority class, resulting in a more balanced and representative dataset. Additionally, by generating synthetic samples based on the local data distribution, ADASYN helps reduce the risk of overfitting compared to methods that simply duplicate minority class samples. Disadvantages include increased computational complexity due to the need to calculate nearest neighbors and density distributions, especially for large datasets. The method can potentially introduce noise if the synthetic examples do not accurately represent the

underlying data distribution. The performance of ADASYN is sensitive to parameters such as the number of nearest neighbors (K) and the balance level (β), and improper parameter settings can lead to suboptimal results. In high-dimensional spaces, the nearest neighbor search and the generation of synthetic samples can become less effective, leading to poor model performance. Furthermore, the adaptive nature of ADASYN can make it more complex to implement and tune compared to simpler over-sampling methods.

3. Weight balancing [21]: While most deep learning algorithms tend to struggle with biased class data, the effectiveness of these models can be significantly enhanced by adapting existing training algorithms to accommodate the skewed distribution of classes. This adaptation involves assigning distinct weights to both majority and minority classes, thereby influencing the classification dynamics during the training phase. The primary objective is to penalize misclassifications made by the minority class by augmenting its class weight, while simultaneously diminishing the weight of the majority class.

One commonly employed method in this context is weight balancing, frequently utilized in classification models. This method entails the assignment of varying weights to different classes, aiming to increase the model's sensitivity to the minority class. Many classification algorithms offer the flexibility to assign class weights during training, with higher weights allocated to the minority class. This strategic weighting makes misclassifications of minority class instances more impactful in terms of the overall loss function, motivating the model to prioritize and improve predictions for the minority class. Weighting is applied to different classes in a dataset, taking into account the distribution of example counts across the classes, as illustrated below.

$$w_i = \frac{Ns}{Nc \times Ns_i} \quad (7)$$

Where w_i represents the weight assigned to each class, Ns denotes the total sample count, Nc refers to the total count of unique classes within the target

variable, Ns_i represents the total number of rows associated with the respective class i . By dividing the total number of samples by the product of the number of classes and the samples corresponding to each class, the formula dynamically calculates weights that reflect the relative proportions of each class in the dataset. This ensures a more nuanced and balanced consideration of different classes during the model training process, contributing to improved performance, especially in scenarios with imbalanced class distributions.

Weight balancing offers several advantages and disadvantages in addressing class imbalance in datasets. One significant advantage is its ability to enhance model sensitivity by increasing the weights of the minority class, thus improving recall and precision for these instances. Moreover, it is a versatile technique that can be easily applied to various machine learning and deep learning frameworks, making it flexible and adaptable. Additionally, weight balancing contributes to overall performance enhancement by reducing bias towards the majority class, thereby improving metrics such as F1-score and AUC. It can also be seamlessly integrated into different classification algorithms, further enhancing its utility. From an implementation standpoint, weight balancing is relatively simple, often requiring only minor adjustments to the loss function or training process.

However, weight balancing is not without its drawbacks. One potential issue is the risk of overcompensation, where setting weights too high for the minority class can lead to overfitting and poor generalization of new data. Furthermore, altering weights during training might result in computational costs, especially for massive datasets with many classes. The effectiveness of weight balancing is heavily dependent on accurately estimating class distribution, and incorrect weight assignments can result in suboptimal performance. Tuning weight values to find the optimal balance requires careful validation, which can be time-consuming and computationally expensive. Lastly, weight balancing may have a limited impact on severely imbalanced datasets, necessitating the use of additional techniques such as synthetic data generation for better results.

C. Training Details

The model was trained for 20 epochs from scratch, with a categorical loss function used throughout the training phase. Because of its known success with large datasets and complex models, the Adam algorithm [22] was used as the optimizer. During training, validation accuracy was continually assessed to evaluate model performance and minimize overfitting. In the convolutional and dense layers, ReLU activation functions were utilized, whereas the softmax activation function was utilized in the final fully connected layer. For each data imbalance approach, the model was trained from scratch.

D. Metrics

The confusion matrix is a commonly used set of metrics for determining how effectively classification models perform. The confusion matrix encompasses four distinct concepts: True Positive (TP), False Positive (FP), True Negative (TN), and False Negative (FN). A confusion matrix is typically represented in the following tabular format:

Table 1. The confusion matrix breaks down predictions into four categories: TP when the actual class is positive and the model correctly predicts it as positive; FP when the actual class is negative, but the model incorrectly predicts it as positive; TN when the actual class is negative, and the model correctly predicts it as negative; FN when the actual class is positive, but the model incorrectly predicts it as negative

	Positive	Negative
Predicted positive	TN	FP
Predicted negative	FN	TP

To evaluate method performance through the confusion matrix, four metrics were used: accuracy, precision, recall, and F1 score. Accuracy assesses the proportion of correctly predicted instances by a model, serving as a comprehensive measure to evaluate the overall effectiveness of a classification model.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (8)$$

The precision metric assesses the accuracy of a model's positive predictions by determining the proportion of correctly identified positive instances. This metric specifically focuses on minimizing the occurrence of false positive predictions in a classification model.

$$Precision = \frac{TP}{TP+FP} \tag{9}$$

The recall metric assesses a model's ability to accurately identify positive instances, providing the percentage of real positive values that were correctly predicted. The goal of this metric is to reduce the number of incorrect negative predictions in a classification model.

$$Recall = \frac{TP}{TP+FN} \tag{10}$$

The F1 score is a metric that represents the harmonic mean of precision and recall metrics, offering a balanced measure that considers both false positive and false negative predictions generated by a classification model.

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \tag{11}$$

3. EXPERIMENT AND RESULTS

This section presents a quantitative comparison of the SMOTE, ADASYN, and Weight balancing methods for the Alzheimer MRI dataset with unbalanced sample counts among classes. In this context, we first trained a custom model from scratch using the existing dataset and then analyzed its performance. The classification report of the model is presented in Table 2.

Table 2. Model performance without dataset balancing

	Precision	Recall	F1-score
0	0.98	0.97	0.98
1	0.94	0.96	0.95
2	0.99	0.95	0.97
3	1.0	0.83	0.91
Accuracy			0.97
Macro Avg	0.98	0.93	0.95
Weighted Avg	0.97	0.97	0.97

In the absence of applying a dataset balancing method, an accuracy value of 97% was obtained. Upon analyzing the overall classification performance through macro avg, encompassing precision, recall, and f1-score metrics, scores of 98%, 93%, and 95% were respectively achieved. Macro avg provides a comprehensive overview, particularly beneficial in evaluating performance metrics collectively in multi-class classification problems. It takes into account the imbalance among classes by treating each class's contribution equally. It computes and subsequently averages performance metrics for each class, considering their contributions. This approach ensures a fair evaluation of overall performance, irrespective of significant variations in performance across classes. When evaluated for specific classes, Class 3, with a limited number of instances, shows significantly low recall and F1-score metrics. Figure 4 depicts the validation loss and accuracy graphs for the relevant model.




Figure 4. Validation loss and accuracy graphs of the model trained without applying data balancing.

Figure 5 (a) presents the confusion matrix for the unbalanced dataset. Notably, 13 instances from the non-demented class are misclassified as very mild, while the remaining 499 instances are correctly classified. Similarly, in the very-mild class, 12 instances are misclassified as non-demented, 1 as mild, and the remaining 296 instances are correctly classified. For the mild class, 6 instances are misclassified as very-mild, while the remaining 127 instances are correctly classified. Lastly, in the moderate class, 1 instance is misclassified as very mild, and the remaining 5 instances are correctly classified.

In the second stage, the model performance was examined by applying the data balancing process using the SMOTE method. In this approach, the sample count for each class was designed to be the same as the class with the highest number of instances. Accordingly, the imbalance was addressed, ensuring that the sample count for each class was adjusted to 3200.

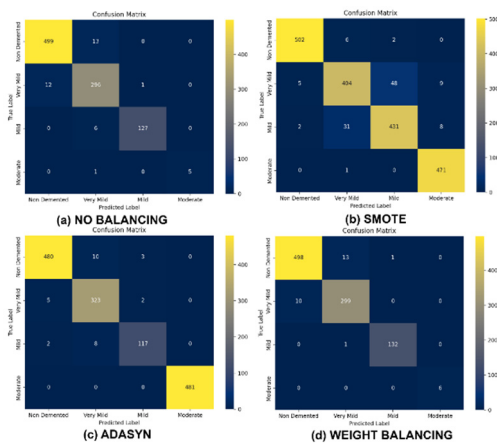


Figure 5. Comparison of confusion matrix results: (a) Unbalanced, (b) SMOTE balanced, (c) ADASYN balanced, and (d) Weight balanced.

Table 3 presents the performance report for the relevant method. When the SMOTE method is used for balancing, a decrease in model performance is observed. The accuracy value has decreased from 97% to 94% compared to the original dataset. Similarly, precision and f1-score decrease, while the recall value increases by 1%.

Table 3. Model performance when the SMOTE data balancing method is applied.

	Precision	Recall	F1-score
0	0.99	0.98	0.99
1	0.91	0.87	0.89
2	0.90	0.91	0.90
3	0.97	1.0	0.98
Accuracy			0.94
Macro Avg	0.94	0.94	0.94
Weighted Avg	0.94	0.94	0.94

Figure 6 shows the validation and loss graphs for the model trained using the relevant approach. In addition, Figure 5(b) shows the confusion matrix for the model trained using the SMOTE approach. In the non-demented class (510 examples), 6 are very mild, 1 is mild, and the rest are correctly classified. For the very mild class (466 examples), 5 are non-demented, 48 are mild, 9 are moderate, and the remaining are correctly classified. In the mild class (472 examples), 2 are non-demented, 31 are very mild, 8 are moderate, and the rest are correctly classified. In the moderate class (472 examples), 1 is misclassified as very mild, and the rest are correctly classified.




Figure 6. Validation loss and accuracy graphs of the model trained to apply the SMOTE data balancing method.

In the third stage, the model's performance was assessed using the ADASYN method, and Table 4 displays the corresponding performance report. Results indicate superior performance with ADASYN compared to the original and SMOTE methods for the Alzheimer's MRI Dataset. For the class with the fewest examples, i.e., 3, the original model had a recall and f1 scores of 83% and 91%, respectively. These scores were 100% and 98% in the SMOTE method, respectively, while the ADASYN method achieved 100% performance in both metrics. Overall averages show 97% accuracy in the original dataset, %94 with SMOTE, and 98% with ADASYN.

Table 4. Model performance when the ADASYN data balancing method is applied.

	Precision	Recall	F1-score
0	0.99	0.97	0.98
1	0.95	0.98	0.96
2	0.96	0.92	0.94
3	1.0	1.0	1.0
Accuracy			0.98
Macro Avg	0.97	0.97	0.97
Weighted Avg	0.98	0.98	0.98

Figure 5(c) presents the confusion matrix derived from the training process employing the ADASYN method. Within the non-demented class, which included 493 examples, 10 instances were classified as very mild, 3 as mild, and the remaining were accurately classified. In the very mild class, which consisted of 330 examples, 5 were designated as non-demented, 3 as mild, and the remainder were correctly classified. The mild class, which consisted of 127 examples, saw two cases classified as non-demented, eight as very mild, and the remainder correctly classified. Ultimately, within the moderate class, comprising 481 examples, all instances were accurately classified. Figure 7 illustrates the validation and accuracy graphs of the model trained using the ADASYN data balancing method.




Figure 7. Validation loss and accuracy graphs of the model trained to apply the ADASYN data balancing method.

Finally, the model's performance was assessed using the Weight-balancing method. In this approach, the dataset is not augmented; instead, weights are assigned based on the distribution of examples in the dataset. The goal is to increase the weight of the minority class to enhance the model's attention to it. In this context, considering the number of examples in the dataset, weight values of 0.5, 0.71, 1.79, and 25.0 were assigned to the non-demented, very mild, mild, and moderate classes, respectively. Table 5 summarizes the results from training the model with this method.

Table 5. Model performance when the Weight balancing method is applied.

	Precision	Recall	F1-score
0	0.98	0.97	0.98
1	0.96	0.97	0.96
2	0.99	0.99	0.99
3	1.0	1.0	1.0
Accuracy			0.97
Macro Avg	0.98	0.98	0.98
Weighted Avg	0.97	0.97	0.97

Upon examining Table 5, it is observed that the highest scores are obtained, particularly for the minority class, i.e., moderate. Looking at the macro average scores, the model achieved the highest performance scores, reaching 98% for precision, recall, and f1-score. When compared to the model trained with the original dataset, there is a 5% increase in the recall metric and a 3% increase in the f1-score metric. In Figure 5(d), the confusion matrix obtained when the model is trained using the weight balancing method is provided. The results show that, out of 512 examples in the non-demented class, 13 were classified as very mild, 1 as mild, and the rest were correctly classified. In the very mild class, with 309 examples, 10 were misclassified as non-demented, while the others were correctly classified. In the mild class with 133 examples, only 1 example was incorrectly classified as very mild. Finally, in the moderate class with six examples, all were correctly classified. Figure 8 displays the validation loss and accuracy graphs obtained when the model is trained using the weight balancing method.

Ultimately, the test dataset was separated before applying data balancing methods, and the performance of the methods was evaluated in this manner. Table 7 reveals that similar to previous experimental results, the weight-balancing method outperforms the others. The SMOTE approach produces worse results than the model trained on the original dataset. Similarly, the ADASYN method also yields better results than the original model.

Table 6. Performance comparison of data balancing methods on test dataset

	Accuracy	Precision	Recall	F1 score
SMOTE	94.17	94.05	94.03	94.02
ORJINAL	96.56	93.01	97.63	95.12
ADASYN	97.90	96.84	97.30	97.05
Weight balancing	97.40	98.32	98.20	98.26




Figure 8. Validation loss and accuracy graphs of the model trained to apply the Weight balancing method.

4. CONCLUSION

This study aimed to address the challenges posed by imbalanced datasets in Alzheimer's disease classification, focusing on the effectiveness of three data balancing methods: SMOTE, ADASYN, and Weight Balancing. The experiments were conducted using the Alzheimer's MRI dataset, and a custom deep-learning model was used for

evaluation. The results indicate that, compared to the original imbalanced dataset, the Weight Balancing method consistently outperforms in terms of accuracy, precision, recall, and F1 score. The method assigns weights based on class distribution, enabling the model to pay more attention to the minority class, which is particularly beneficial in the context of imbalanced health datasets. While SMOTE and ADASYN methods improve various metrics, they are considered inferior to the Weight Balancing method. The ADASYN method, in particular, demonstrated superior performance, achieving the highest scores for precision, recall, and F1 score, especially for the minority class, i.e., moderate. The study emphasizes the critical role of addressing class imbalances in health datasets for accurate and reliable model training. It contributes valuable insights into selecting data balancing methods to enhance the accuracy of deep learning models in Alzheimer's disease classification. The Weight Balancing method, with its ability to adapt class weights during training, stands out as a robust approach for improving model performance in scenarios with imbalanced class distributions. In future work, further exploration of different data balancing methods and validation on diverse datasets could provide additional perspectives on optimizing deep learning models for Alzheimer's disease classification.

5. REFERENCES

1. Nawaz, H., Maqsood, M., Afzal, S., Aadil, F., Mehmood, I., Rho, S., 2021. A Deep Feature-Based Real-Time System for Alzheimer Disease Stage Detection. *Multimedia Tools and Applications*, 80, 35789-35807.
2. Aditya Shastry, K., Sanjay, H.A., 2023. Artificial Intelligence Techniques for the Effective Diagnosis of Alzheimer's Disease: A Review. *Multimedia Tools and Applications*, 83(13), 40057-40092.
3. Yao, Z., Mao, W., Yuan, Y., Shi, Z., Zhu, G., Zhang, W., Wang, Z., Zhang, G., 2023. Fuzzy-VGG: A Fast Deep Learning Method for Predicting the Staging of Alzheimer's Disease Based on Brain MRI. *Information Sciences*, 642, 119129.
4. Özdemir, C., 2023. Designing Effective Models for COVID-19 Diagnosis through Transfer Learning and Interlayer Visualization. *Balkan Journal of Electrical and Computer Engineering*, 11(4), 340-345.
5. Sivari, E., Civelek, Z., Sahin, S., 2024. Determination and Classification of Fetal Sex on Ultrasound Images with Deep Learning. *Expert Systems with Applications*, 240, 122508.
6. Kılıç, Ş., Doğan, Y., 2023. Deep Learning Based Gender Identification Using ear Images. *Traitement du Signal*, 40(4), 1629-1639.
7. Ozdemir, C., 2023. Classification of Brain Tumors from MR Images Using a New CNN Architecture. *Traitement du Signal*, 40(2), 611-618.
8. Assmi, A., Elhabyb, K., Benba, A., Jilbab, A., 2024. Alzheimer's Disease Classification: A Comprehensive Study. *Multimedia Tools and Applications*, 1-24.
9. Mujahid, M., Rehman, A., Alam, T., Alamri, F. S., Fati, S. M., Saba, T., 2023. An Efficient Ensemble Approach for Alzheimer's Disease Detection Using an Adaptive Synthetic Technique and Deep Learning. *Diagnostics*, 13(15), 2489.
10. Borkar, P., Wankhede, V.A., Mane, D.T., Limkar, S., Ramesh, J.V.N., Ajani, S.N., 2023. Deep Learning and Image Processing-Based Early Detection of Alzheimer Disease in Cognitively Normal Individuals. *Soft Computing*, 1-23.
11. Thangavel, P., Natarajan, Y., Preethaa, K.S., 2023. EAD-DNN: Early Alzheimer's Disease Prediction Using Deep Neural Networks. *Biomedical Signal Processing and Control*, 86, 105215.
12. Lu, D., Popuri, K., Ding, G.W., Balachandar, R., Beg, M.F., 2018. Multimodal and Multiscale Deep Neural Networks for the Early Diagnosis of Alzheimer's Disease Using Structural MR and FDG-PET Images. *Scientific Reports*, 8(1), 5697.
13. Ahmed, S., Choi, K.Y., Lee, J.J., Kim, B.C., Kwon, G.R., Lee, K.H., Jung, H.Y., 2019. Ensembles of Patch-Based Classifiers for Diagnosis of Alzheimer Diseases. *IEEE Access*, 7, 73373-73383.

14. Liu, C.F., Padhy, S., Ramachandran, S., Wang, V.X., Efimov, A., Bernal, A., Shi, L., Vaillant, M., Ratnanather, J.T., Faria, A.V., 2019. Using Deep Siamese Neural Networks for Detection of Brain Asymmetries Associated with Alzheimer's Disease and Mild Cognitive Impairment. *Magnetic Resonance Imaging*, 64, 190-199.
15. Sarraf, S., DeSouza, D.D., Anderson, J., Tofighi, G., 2016. DeepAD: Alzheimer's Disease Classification via Deep Convolutional Neural Networks Using MRI and fMRI. *BioRxiv*, 070441.
16. Alzheimer MRI Preprocessed Dataset, <https://www.kaggle.com/datasets/sachinkumar413/alzheimer-mri-dataset>, Access date: 08.01.2024.
17. Chawla, N.V., Bowyer, K.W., Hall, L.O., Kegelmeyer, W.P., 2002. SMOTE: Synthetic Minority Over-Sampling Technique. *Journal of Artificial Intelligence Research*, 16, 321-357.
18. He, H., Bai, Y., Garcia, E.A., Li, S., 2008. ADASYN: Adaptive Synthetic Sampling Approach for Imbalanced Learning. In 2008 IEEE International Joint Conference on Neural Networks, Hong Kong, China.
19. Chawla, N.V., Lazarevic, A., Hall, L.O., Bowyer, K.W., 2003. SMOTEBoost: Improving Prediction of the Minority Class in Boosting. In *Knowledge Discovery in Databases: PKDD 2003: 7th European Conference on Principles and Practice of Knowledge Discovery in Databases*, Cavtat-Dubrovnik, Croatia.
20. Guo, H., Viktor, H.L., 2004. Learning from Imbalanced Data Sets with Boosting and Data Generation: The DataBoost-IM Approach. *ACM SigKDD Explorations Newsletter*, 6(1), 30-39.
21. Du, M., Tatbul, N., Rivers, B., Gupta, A.K., Hu, L., Wang, W., Marcus, R., Zhou, S., Lee, I., Gottschlich, J., 2020. A Skew-Sensitive Evaluation Framework for Imbalanced Data Classification. *arXiv preprint arXiv:2010.05995*.
22. Kingma, D.P., Ba, J., 2014. Adam: A Method for Stochastic Pptimization. *arXiv preprint arXiv:1412.6980*.

Yanmış Orman Alanlarının Uzaktan Algılama Teknikleri ile Araştırılması: Kozan Orman Yangını Örneği

Sevim Yasemin ÇİÇEKLİ*¹ ORCID 0000-0002-8140-1265

¹Çukurova Üniversitesi, Mühendislik Fakültesi, Jeoloji Mühendisliği Bölümü, Adana

Geliş tarihi: 12.02.2024 Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ÇİÇEKLİ, S.Y., (2024). Yanmış Orman Alanlarının Uzaktan Algılama Teknikleri ile Araştırılması: Kozan Orman Yangını Örneği. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 503-514.

Öz

Orman yangınları son yıllarda sık meydana gelen bir afet olup, yangınlar sebebiyle ormanlarda yaşayan canlıların yaşam alanları yok olmaktadır. Bitki örtüsünün örtünün yok olmasıyla erozyon, sel-taşkın ve hava kirliliği gibi doğal afetlerin sayısında ve hızında artma görülür. Gelişen uydu teknolojileri ile orman alanlarının gözlemlenmesinde uzaktan algılama tekniklerinin kullanımını mümkün olmuştur. Bu çalışmada 23 Ağustos 2020'de Adana'nın Kozan ilçesinde meydana gelen orman yangını sonrası değişen bitki örtüsü Sentinel-2B MSI uydu görüntüleri kullanılarak gözlemlenmiştir. 29 Temmuz 2020 ve 28 Ağustos 2020 tarihinde algılanmış Sentinel-2B MSI uydu görüntülerine Normalize Yanma Oranı (NBR) bant oranlama tekniği uygulanmış, Fark Normalize Yanma Oranı (dNBR) fark yöntemi kullanılarak yanan alanlar belirlenerek, doğruluk analizi yapılmıştır. Çalışma sonunda yanan ve zarar gören alan dNBR yöntemi ile 28,26 km² olarak hesaplanmış olup, yöntemin %96 oranında yüksek bir doğruluk sağladığı tespit edilmiştir. Sentinel-2B MSI görüntülerine Normalize Fark Bitki Örtüsü İndeksi (NDVI) uygulanarak yangın sonrası bölgede yapılan ağaçlandırma çalışması 25 km² lik bir alanın bitki örtüsüne kavuştuğu tespit edilmiştir.

Anahtar Kelimeler: Normalize yanma oranı, Fark normalize yanma oranı, Sentinel-2B, Orman yangını, Normalize fark bitki örtüsü indeksi

Investigation of Burned Forest Areas Using Remote Sensing Techniques: The Case of Kozan Forest Fire

Abstract

Forest fires are a frequent disaster in recent years, and the habitats of creatures living in forests are destroyed due to fires. With the loss of vegetation cover, there is an increase in the number and speed of natural disasters such as erosion, floods and air pollution. With developing satellite technologies, it has become possible to use remote sensing techniques in observing forest areas. In this study, changing vegetation after the forest fire that occurred in Kozan district of Adana on August 23, 2020 were observed using Sentinel-2B MSI satellite images. Normalized Burn Ratio (NBR) band ratio technique was applied to Sentinel-2B MSI satellite images detected on July 29, 2020 and August 28, 2020, burned areas were detected using the

*Sorumlu yazar (Corresponding Author): Sevim Yasemin ÇİÇEKLİ, s.y.cicekli@gmail.com

Differenced Normalized Burn Ratio (dNBR) method, the accuracy analysis was performed. At the end of the study, the burned and damaged area was calculated as 28,26 km² using the dNBR method determined that the method provided a high accuracy of 96%. By *Normalized Difference Vegetation Index* (NDVI) method to the Sentinel-2B MSI images, the afforestation work carried out in the post-fire region revealed an increase in vegetation cover of an area of 25 km².

Keywords: Normalized burn ratio, Differenced normalized burn ratio, Sentinel-2B, Forest fire, Normalized difference vegetation index

1. GİRİŞ

Orman yangınları, bitki örtüsünü tahrip olmasına, bu alandaki canlıların yaşam alanlarının zarar görmesine ve ekonomik kayıplara sebep olmaktadır. Orman yangınlarının gözlemlenmesi, oluşan tahribatın tespit edilmesi ve yanan alanlarda zaman içerisinde meydana gelen değişimlerin analiz edilmesi ekolojik ve ekonomik açıdan önemlidir. Uydu teknolojilerine meydana gelen yenilikler ve gelişmeler ile orman alanlarının gözlemlenmesinde ve orman yangınlarının analizinde uzaktan algılama tekniklerinin kullanımını mümkün olmuştur.

Literatürde orman yangınlarının hasarlarını tespit etmek amacı ile uzaktan algılama teknikleri kullanılarak yapılmış birçok çalışma vardır. Özdemir ve Demir, İzmir Karabağlar bölgesinde 2019 yılında çıkan orman yangını uydu görüntülerini kullanarak Normalize Fark Bitki Örtüsü İndeksi (NDVI), Normalize Yanma Oranı (NBR), Yanmış Alan İndeksi (BAI), Yalın Toprak İndeksi (BSI) teknikleri kullanarak analize etmiş ve %99 oranında doğrulukla Fark Normalize Bitki Örtüsü İndeksi (dNDVI) ve Fark Normalize Yanma Oranı (NBR) (dNBR) kullanarak yanan alanı hesaplamıştır [1]. Yılmaz ve arkadaşları, Çanakkale Gelibolu'da meydana gelen orman yangını Landsat-8 ve Sentinel-2 uydu görüntülerine BAI, Normalize Fark Nem İndeksi (NDMI), NBR ve NDVI teknikleri uygulamıştır. Her iki uydu tekniği için de en iyi sonucun Fark Normalize Fark Bitki Örtüsü İndeksi (dNDVI) yönteminin verdiği tespit edilmiştir [2]. Bright ve arkadaşları (2019) Landsat uydu görüntülerini kullanarak Kuzey Amerika'da yangın sonrası iyileşmeyi NBR yöntemi ile

gözlemlemiş ve yedi yıllık süreci incelemiştir [3]. Tsotgerel ve arkadaşları, Moğolistan'da meydana gelen orman yangınından sonra 2015-2018 Landsat-8 uydu görüntülerine NBR, NDVI uygulamış ve değişimi gözlemlemiştir [4]. Bıçakçı ve Yıldız, dNBR ve dNDVI yöntemi ile Belen orman yangınında hasar almış alanı tespit etmiştir [5]. Çavdaroğlu, Muğla'da meydana gelen orman yangınına dNBR ve NDVI yöntemlerini kullanarak analiz etmiştir [6]. Yılmaz ve arkadaşları, Belen orman yangınında hasar gören alanı dNBR ve NDVI yöntemleri kullanarak analiz etmiştir [7]. Bant oranlama teknikleri yüksek doğruluk sağlayarak, daha hızlı ve ekonomik olarak sonuç vermektedir.

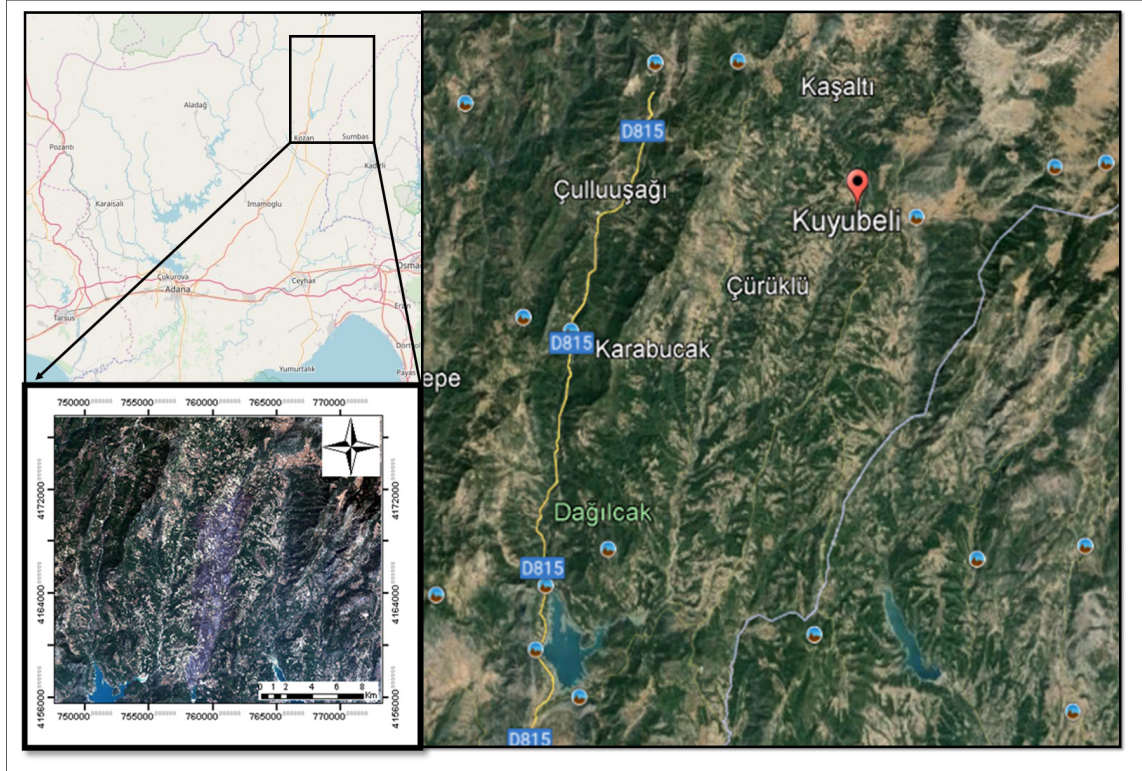
Adana'nın Kozan ilçesinde 23 Ağustos 2020'de bir orman yangını meydana gelmiş, çok geniş bir alana yayılmış, yerleşim yerleri boşaltılmış ve yangının kontrol altına alınması yaklaşık üç gün sürmüştür [8]. 2021 yılında bölgede yeniden bir ağaçlandırma çalışması başlamıştır [9]. Bu çalışmanın amacı, Adana'nın Kozan ilçesinde 23 Ağustos 2020'de meydana gelen ve çok büyük bir alana zarar veren orman yangını sonrası Sentinel-2B MSI uydu görüntüleri ile zarar gören alanın tespit edilmesi ve bölgede yangın sonrası ağaçlandırma çalışmaları yapıldığından iyileşme miktarının belirlenmesidir. 29 Temmuz 2020 ve 28 Ağustos 2020 tarihlerinde algılanmış Sentinel-2B uydu görüntülerine NBR ve dNBR indeksleri uygulanmış, yanan bölge ve yanma miktarları belirlenerek doğruluk analizi yapılmıştır. 29 Temmuz 2020, 28 Ağustos 2020 ve 24 Temmuz 2023 Sentinel-2B MSI görüntülerine NDVI uygulanarak yangın sonrası bölgede yapılan ağaçlandırma çalışması bitki örtüsünün artışı tespit edilmiştir.

2. MATERYAL VE METOT

2.1. Çalışma Alanı

Çalışma alanı, Adana'nın Kozan ilçesinde yer almaktadır. 23 Ağustos 2020'de Kozan ilçe merkezinin kuzey doğusunda yer alan Kuyubeli Köyü'nde başlayıp, güneye doğru yayılan ve üç gün

süren orman yangının sebep olduğu hasar araştırılmıştır. Yangından Kuyubeli, Çamlarca, Karahamzalı, Boztahta, Çürüklü, Eskimantaş köyleri de etkilenmiştir. Bu nedenle Kuyubeli, Çamlarca, Karahamzalı, Boztahta, Çürüklü, Eskimantaş köyleri çalışma alanında bulunmaktadır (Şekil 1)



Şekil 1. Çalışma alanı [10,11]

2.2. Veri Seti

Bu çalışmada 29 Temmuz 2020, 28 Ağustos 2020 ve 24 Temmuz 2023 tarihinde algılanmış Sentinel-2B uydu görüntüleri kullanılmıştır. Uydu görüntüleri Avrupa Uzay Ajansı (ESA) web sayfasından temin edilmiştir [10]. 29 Temmuz 2020 tarihinde algılanmış Sentinel 2B görüntü 828 megabayt, 28 Ağustos 2020 tarihinde algılanmış

Sentinel 2B görüntü 821 megabayt ve 24 Temmuz 2023 tarihinde algılanmış Sentinel 2B görüntü 827 megabayt boyutundadır. Sentinel-2B, 7 Mart 2017'de fırlatılan bir Avrupa optik görüntüleme uydusudur. Avrupa Uzay Ajansı'nın Copernicus Programı kapsamında fırlatılan ikinci Sentinel-2 uydusudur. Sentinel-2B uydu görüntüleri Çizelge 1'de Sentinel-2B uydusunun bantlarına ait özellikleri yer almaktadır [10]. (Şekil 1)

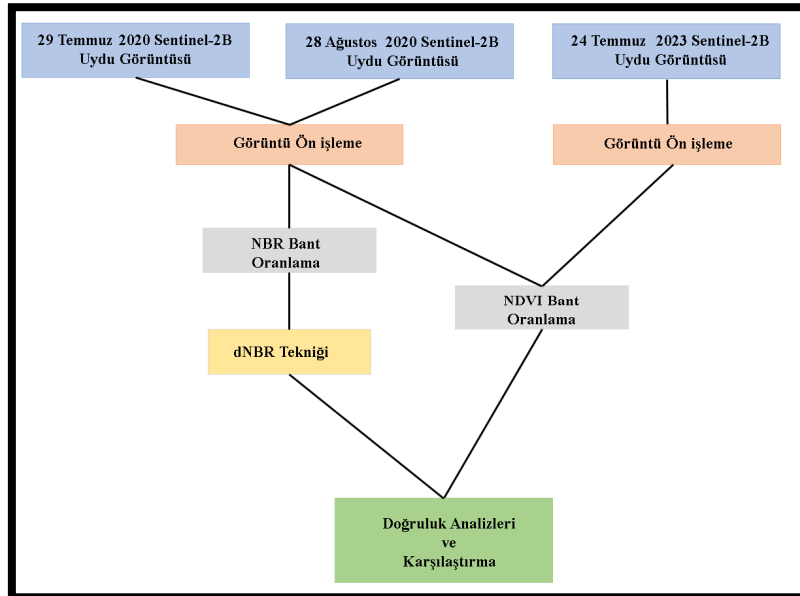
Çizelge 1. Sentinel-2B bantları ve özellikleri [10]

Sentinel-2B Uydu bantları	Özellikler	
	Dalga boyu (mikrometre)	Çözünürlük (m.)
Bant-1 Kıyı Aerosol	0,442	60
Bant-2 Mavi	0,492	10
Bant-3 Yeşil	0,559	10
Bant-4 Kırmızı	0,665	10
Bant-5 Bitki örtüsü kırmızı kenar	0,703	20
Bant-6 Bitki örtüsü kırmızı kenar	0,739	20
Bant-7 Bitki örtüsü kırmızı kenar	0,779	20
Bant-8 NIR (Yakın kızılötesi, Near-infrared)	0,833	10
Band-8A Bitki örtüsü kırmızı kenar	0,864	20
Band-9 Su buharı	0,943	60
Band-10 SWIR cirrus (Kısa dalga kızıl ötesi, Short wavelength infrared)	1,376	60
Band-11 SWIR (Kısa dalga kızıl ötesi, Short wavelength infrared)	1,610	20
Band-12 SWIR (Kısa dalga kızıl ötesi, Short wavelength infrared)	2,185	20

2.3. Metot

Sentinel-2B görüntüleri, ESA web sayfasından temin edilmiştir [10]. Kullanılan görüntüler, L1C serisi olduğundan ve atmosferik düzeltmeleri yapılmış halde sunulmuştur bu nedenle ön işleme aşamasında yalnızca görüntülerin kesilmiş ve NBR

uygulanırken kullanılan NIR bantı 10 m., SWIR bantı 20 m. çözünürlüklü olmasından dolayı, NBR için kullanılan bantlar 20 m.'ye yeniden örneklenmiştir (Şekil 2). Görüntülerin kesilmesi ve yeniden örnekleme işlemi ESA'ya ait SNAP yazılımında yapılmıştır. (Şekil 1)



Şekil 2. İş akış diyagramı

2.3.1. Normalize Yanma Oranı (NBR) ve Fark Normalize Yanma Oranı (dNBR)

Araştırma bölgesinde yer alan yanmış bölgeleri ve yanma şiddetini belirlemek için literatürde yaygın olarak dNBR indeksi kullanılmaktadır [12]. NBR, hesaplamada NIR ve SWIR₂ bantları kullanılır. Formülü Eşitlik 1’de yer almaktadır.

$$NBR = \frac{NIR - SWIR_2}{NIR + SWIR_2} \quad (1)$$

Sentinel 2B uydu görüntülerinde bant 8, NIR ve bant 12 SWIR₂ yi temsil eder (Çizelge 1). NBR hesaplanırken bant 8 ve bant 12 kullanılmıştır.

NBR değer aralığı -1 ila 1’dir. NBR değerinin -1 değerine yakın olması yanmış bitki örtüsü anlamına gelmektedir. dNBR ise meydana gelen yangını öncesi ve sonrası hesaplanan değerlerin farkı alınarak elde edilmektedir [12]. dNBR formülü Eşitlik 2’de yer almaktadır.

$$dNBR = NBR_{önce} - NBR_{sonra} \quad (2)$$

2.3.2. Normalize Fark Bitki Örtüsü İndeksi (NDVI)


Bitki örtüsünü belirlemek için NDVI yöntemi sıklıkla kullanılır [13]. NIR ve kırmızı bantları kullanılarak Eşitlik 3’de yer alan ifade ile hesaplanmaktadır.

$$NDVI = \frac{NIR - KIRMIZI}{NIR + KIRMIZI} \quad (3)$$

Sentinel 2B uydu görüntülerinde bant 8, NIR ve bant 4 kırmızı bantı temsil eder (Çizelge 1). NDVI hesaplanırken bant 8 ve bant 4 kullanılmıştır.

2.3.3. Hata Matrisi

Çalışmada hataların tespit edilmesi için hata matrisleri kullanılmıştır. Hata matrisinde düşey sütun kullanılan kontrol noktalarını (referans veri), yatay sütun ise değerlendirmesi yapılacak veriyi temsil eder [14]. Hata matrisinin şematik gösterimi Şekil 3’te sunulmuştur.



Şekil 3. Hata matrisi şematik gösterimi

Matris üzerinde doğruluk sınıflandırılmış piksellerin toplam sayısının (köşegen toplamı) referans piksellerin toplam sayısına bölünmesiyle elde edilir [15].

Kappa değeri doğruluk analizi yapan bir yöntem olup, hata matrisinin köşegen elemanları, satır ve sütun değerleri toplamı ve toplam hücre sayısını kullanır [16]. Kappa formülü Eşitlik 4’te sunulmuştur.

$$Kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (4)$$

Kappa denkleminde “r” sınıf sayısını, “x_{ii}” Hata matrisinin köşegen elemanları, “x_{i+}” Satır toplamı, “x_{+i}” Sütun toplamı, “N” Hata matrisindeki toplam hücre sayısını temsil eder [16].


3. BULGULAR VE TARTIŞMA

3.1. Bulgular


Görüntülere NBR, dNBR ve NDVI yöntemleri uygulanmış, hata matrisleri oluşturularak doğruluk analizleri gerçekleştirilmiştir.

3.1.1. NBR ve dNBR Yöntemleri ile Elde Edilen Bulgular

29 Temmuz 2020 ve 28 Ağustos 2020 tarihli görüntülere NBR bant oranlaması uygulanmıştır (Şekil 4). NBR yönteminden sonra, elde edilen NBR görüntüleri kullanılarak dNBR fark yöntemi uygulanmıştır (Şekil 5).




(a)



(b)

Şekil 4. (a) 29 Temmuz 2020 NBR görüntüsü, (b) 28 Ağustos 2020 NBR görüntüsü



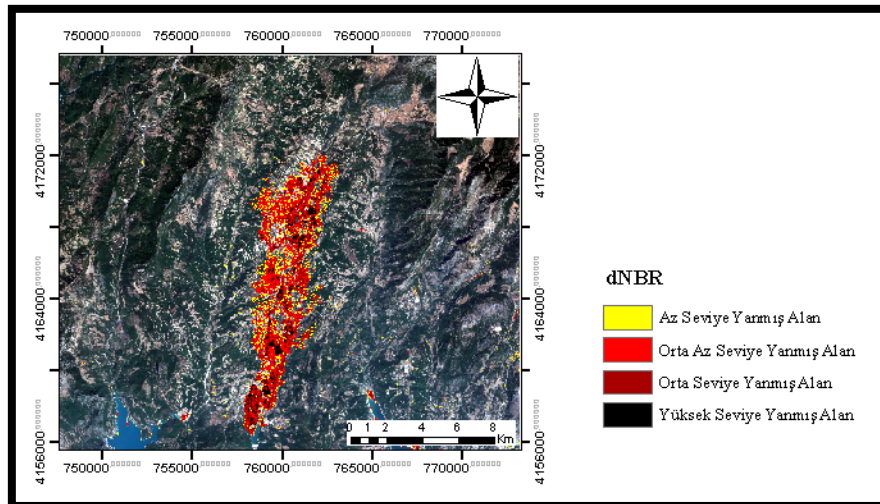
Şekil 5. dNBR görüntüsü

Yanma derecelerine göre sınıflama işleminde kullanılacak eşikleri belirlemek için, Avrupa Orman Yangınları Bilgi Sistemi (EFFIS) web sayfasından Sentinel-2 uyduları için alınan yanma derecelerine göre dNBR aralıkları Çizelge 2’de verilmiştir.

EFFIS’den temin edilen bilgiler ve histogram üzerinden geometrik aralıklar kullanılarak belirlenen yanma sınıfları oluşturulmuştur (Şekil 6).

Çizelge 2. Yanma derecelerine göre dNBR aralıkları [17]

Sınıf	dNBR aralığı
Yanmamış	< 0,1
Az	0,1 – 0,270
Orta-az seviye yanmış	0,270 – 0,440
Orta yüksek seviye yanmış	0,440 – 0,660
Çok Yüksek seviye yanmış	>=0,660



Şekil 2. dNBR görüntüsü

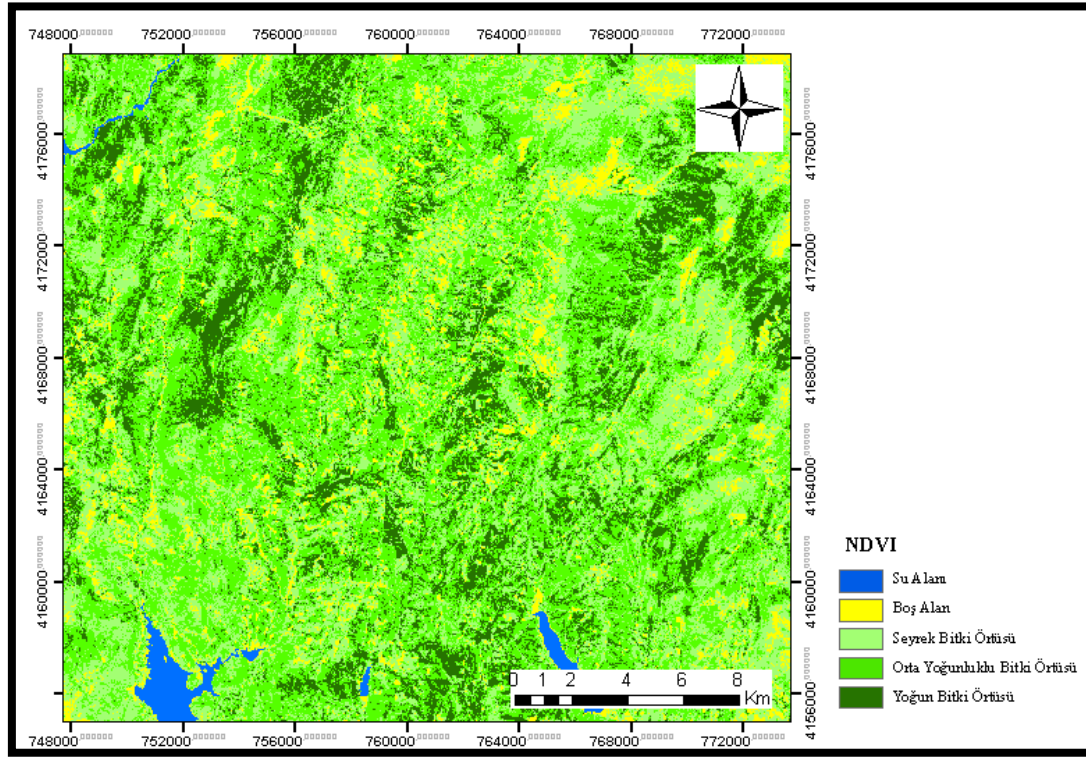
29 Temmuz 2020 ve 28 Ağustos 2020 NBR görüntüleri karşılaştırıldığında yanmış orman alanındaki NBR değerinin değiştiği ve 1 değerine yaklaştığı görülmektedir (Şekil 4). dNBR görüntülerinde yanan alanlar 0,1-1 aralığındadır. dNBR görüntüsünde orman yangınında zarar görmüş alanın, dNBR değerinin diğer alanlardan farklı olduğu ve 1 değerine yakın olduğu görülmektedir (Şekil 5, Şekil 6).

3.1.2. NDVI Yöntemi ile Elde Edilen Bulgular

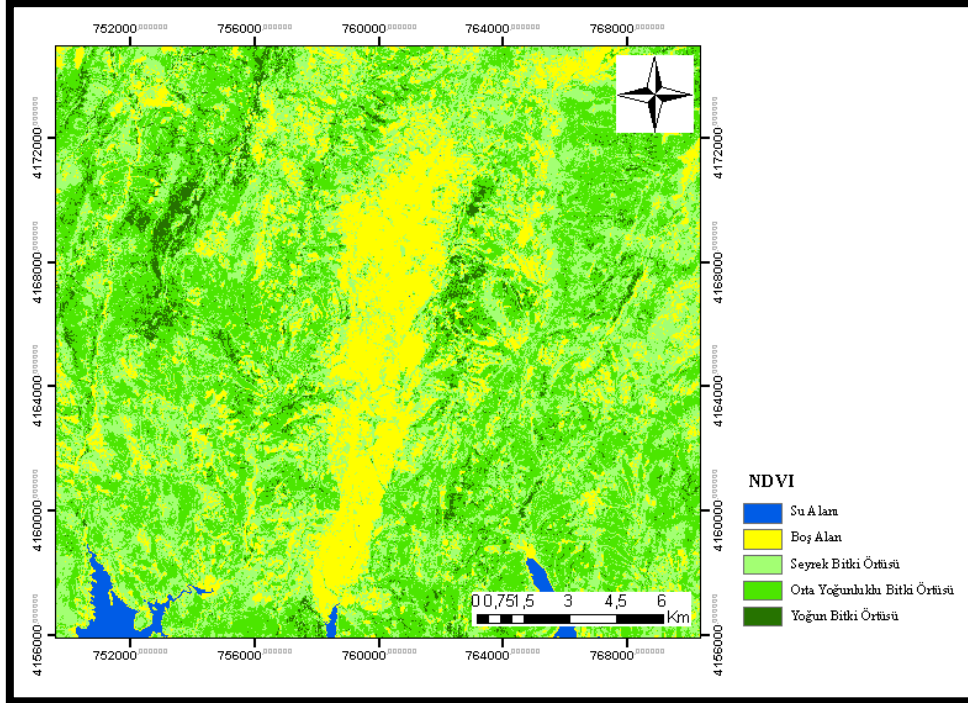
29 Temmuz 2020, 28 Ağustos 2020 ve 24 Temmuz 2023 tarihli Sentinel görüntülerine NDVI uygulanmıştır. NDVI haritaları oluşturulurken kullanılan aralıklar Çizelge 3’de yer almaktadır. Literatürdeki çalışmalarda kullanılan değerler ve histogram üzerinden geometrik aralıklar kullanılarak sınıflar oluşturulmuştur (Şekil 7).

Çizelge 3. NDVI sınıfları aralıkları

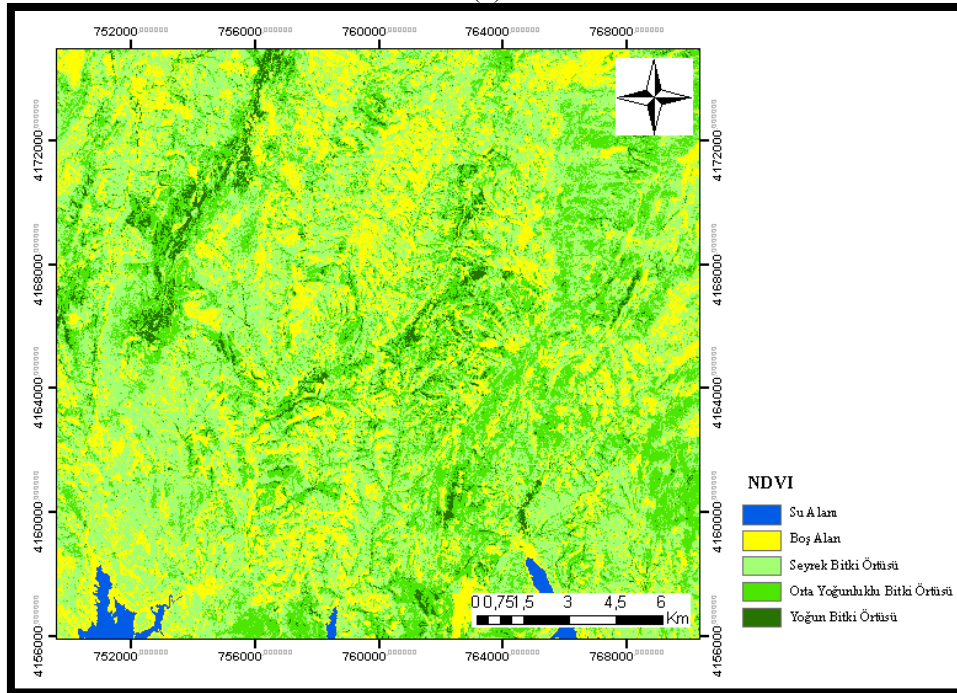
Sınıf	NDVI aralığı	
Su alanı	<-0,046	[18], [19]
Boş alan	-0,046- 0,25	[19]
Seyrek bitki örtüsü	0,25- 0,35	[20], [19]
Orta yoğunluklu bitki örtüsü	0,35- 0,5	[20], [19]
Yoğun bitki örtüsü	0,5- 1	[20], [19]



(a)



(b)



(c)

Şekil 7. 29 Temmuz 2020 (a), 28 Ağustos 2020 (b) ve 24 Temmuz 2023 (c) NDVI haritaları

Bitki örtüsünün orman yangını sebebi ile aldığı hasardan dolayı, 28 Ağustos 2020 tarihli görüntüye ait NDVI haritasında, 29 Temmuz 2020 tarihli görüntüye ait NDVI haritasından farklı olarak yanmış alanının boş alan sınıfı olarak görülmektedir. Yapılan ağaçlandırma çalışması sonrasında 24 Temmuz 2023 tarihli görüntüye ait NDVI haritasında ise yanmış alanın bitki örtüsünde artış olduğu görülmektedir (Şekil 7).

3.1.3. Hesaplanan Yanma Sınıfları ve Doğruluk Analizi

Orman yangınında zarar gören alanlar hesaplanmıştır. Toplam 28,26 km² alan yanmış olup 2,35 km² (235 hektar) alan tamamen yanmıştır. Oluşturulan yanma sınıflarının piksel sayıları ve alanları Çizelge 4'de sunulmuştur.

Çizelge 4. Hesaplanan yanma sınıfları

Yanma sınıfı	Piksel	Alan (km ²)
Yüksek seviye yanmış alan	5879	2,35
Orta seviye yanmış alan	22977	9,19
Orta az seviye yanmış alan	29459	11,7
Az yanmış alan	12578	5,02

Çalışma alanı üzerinde rastgele seçilmiş ve NDVI sınıfı bilinen 100 adet kontrol noktası ile doğruluk analizi yapılmıştır. Hata matrisi oluşturulmuş ve NDVI yönteminin doğruluğu Çizelge 5'deki gibi hesaplanmıştır.

Çizelge 5. NDVI doğrulukları ve kappa değeri

Görüntü tarihi	Genel doğruluk	Kappa değeri
29 Temmuz 2020	%93	0,900
28 Ağustos 2020	%91	0,874
24 Temmuz 2023	%88	0,832

dNBR yönteminin doğruluğunu tespit etmek için çalışma alanı üzerinde dNBR sınıfı bilinen 100 adet kontrol noktası rastgele seçilerek, hata matrisi oluşturulmuş ve dNBR yönteminin doğruluğu %96 olarak, kappa değeri 0,81 olarak hesaplanmıştır.

3.2. Tartışma

Çalışmada elde edilen sonuçlar, literatürdeki çalışmalarda elde edilen sonuçlarla uyumludur. Özdemir ve Demir, yanan alanları Sentinel MSI verileriyle hesaplanan dNBR yöntemleri ile %99 doğrulukla [1], Yılmaz ve arkadaşları yanmış alanları Sentinel-2 görüntüleri için dNBR %89 doğrulukla [2] tespit etmiştir. Öncü ve Çorumluoğlu, Tınazlı İzmir bölgesinde orman yangını için yaptıkları çalışmada, yanmış alanları NBR yöntemi ile % 99,2, NDVI yöntemi ile %99,5 doğrulukla tespit etmiştir [21]. Yüksel, Mersin Gülnar'da yanmış orman alanını dNBR yöntemi ile %88,89 doğrulukla tespit etmiştir [22].

2020 yangını sonrasında oluşan hasar sonrası 2021 yılında başlayan ağaç dikme çalışmaları ile 25 km² alan bitki örtüsüne kavuşmuştur.

28 Ağustos 2020 ve 29 Temmuz 2020 NDVI haritaları incelendiğinde boş alan sınıfının değişiminin aynı görüntülere ait NBR haritaları ve dNBR haritasının yanmış alanları temsil eden sınıfları ile uyum sağladığı gözlemlenmektedir. 24 Temmuz 2023 NDVI ve 28 Ağustos 2020 NDVI haritaları karşılaştırıldığında ağaçlandırma çalışması sonrasında boş alan sınıfı azalmış olduğu ve dNBR haritasında yanmış alanları temsil eden bölgenin bitki örtüsündeki artış görülmektedir.

Çalışmada elde edilen sonuçlar, uzaktan algılama tekniklerinin orman yangınlarının araştırılması ve zarar gören bitki örtüsünün takip edilmesi konusunda büyük bir öneme sahip olduğunu göstermekte olup, literatürdeki çalışmaların sonuçları ile uyum sağlamaktadır. Öncü ve Çorumluoğlu, uzaktan algılama tekniklerinin orman yangınlarının analiz edilmesi ve orman yangın bölgesindeki farklı noktalarda çıkan yangının neden olduğu toplam hasarın ve hasar yoğunluk seviyelerinin kısa sürede belirlenmesinde önemli bir araç olduğunu tespit etmiştir [21]. Yüksel, uydu görüntülerinin yanan alan tespit edilmesinde ve yanma şiddetlerinin hesaplanmasında kullanılabileceğini belirtmiştir [22].

4. SONUÇ

Orman yangınları, ekolojik ve çevresel açıdan büyük bir öneme sahip orman alanları için büyük bir tehdit oluşturmaktadır. Teknoloji, orman yangınları sonrası zarar gören alanları yüksek doğrulukla tespit edilmesi için uzaktan algılama tekniklerinin kullanımını yaygınlaştırmıştır ve bant oranlama teknikleri sıklıkla kullanılan bir yöntem olmuştur. Bu çalışmada 23 Ağustos 2020 tarihinde Adana ili Kozan ilçesinde meydana gelen orman yangını sonucunda yanan alanı tespit etmek, yangın haritalarını üretmek ve ağaçlandırma çalışması sonrası iyileşme miktarını hesaplamak için NBR, dNBR ve NDVI yöntemleri kullanılmıştır.

Meydana gelen yangından etkilenen orman alanı dNBR yöntemi ile 28,26 km² bulunmuştur. Hata matrisi oluşturulmuş ve %96 doğruluk tespit edilmiştir. Ayrıca 25 km² lik iyileşme NDVI yöntemi ile tespit edilmiştir. Elde edilen sonuçlar literatürdeki çalışmalardan elde edilen sonuçlarla uyum sağlamıştır.

Uydu teknolojilerinin kullanımı, orman yangınlarını hızlı bir şekilde tespit edilmesi, analiz etme ve yorumlamanın daha kolay olmasını sağlayacaktır. Sonuç olarak, uzaktan algılama teknikleri orman yangınlarının gözlemlenmesi ve analizinde büyük bir öneme sahiptir. Yanmış alanların tespit edilmesi, yanan orman alanlarının yeniden ağaçlandırılması çalışmaları için uzaktan algılama görüntüleri kolaylıkla kullanılabilir.

Daha ileri araştırmalarda yangını etkileyen sıcaklık ve rüzgar gibi ek parametrelerin de dahil edilebilir. Yanmış alanlarda ekolojik zararı tahmin etmek için çalışmaya yeni parametreler dahil edilebilir.

5. KAYNAKLAR

- Özdemir, F.B., Demir, N., 2022. 2019 İzmir Karabağlar İlçesi Orman Yangın Alanının Uydu Görüntüleri ile Analizi. Turkish Journal of Remote Sensing and GIS, 3(1), 20-33.
- Yılmaz, B., Demirel, M., Balçık, F., 2022. Yanmış Alanların Sentinel-2 MSI ve Landsat-8 OLI ile Tespiti ve Analizi: Çanakkale/Gelibolu Orman Yangını. Doğal Afetler ve Çevre Dergisi, 8(1), 76-86.
- Bright, B.C., Hudak, A.T., Kennedy, R.E., Braaten, J.D., Henareh K.A., 2019. Examining Post-Fire Vegetation Recovery with Landsat Time Series Analysis in Three Western North American Forest Types. Fire Ecology, 15(1), 1-14.
- Tsoygerel, O., Cho, K., 2021. A Study on Evaluating Recovery from Forest Fire in Mongolia Using NDVI and NBR Derived from Landsat Oli Data. The 42nd Asian Conference on Remote Sensing (ACRS2021), 1-8.
- Bıçakçı, C., Yıldız, S.S., 2024. Google Earth Engine ve Coğrafi Bilgi Sistemleri Kullanarak Orman Yangını Şiddetinin Belirlenmesinde Farklı İndekslerin Karşılaştırılması: 2023 Hatay-Belen Yangını Örneği. Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 7(2), 708-719.
- Cavdaroglu G.C., 2021. Google Earth Engine Based Approach for Finding Fire Locations and Burned Areas in Muğla, Turkey. American Journal of Remote Sensing, 9(2), 72-77.
- Yılmaz, O.S., Oruç, M.S., Ateş, A.M., Gülgen, F., 2021. Orman Yangını Şiddetinin Google Earth Engine ve Coğrafi Bilgi Sistemleri Kullanarak Analizi: Hatay-Belen Örneği. Journal of the Institute of Science and Technology, 11(2), 1519-1532.
- T.C. Tarım ve Orman Bakanlığı Adana İl Tarım ve Orman Müdürlüğü, 2020. Kozan İlçesinde Orman Yangını Kontrol Altına Alındı Soğutma Çalışmaları Devam Ediyor, <https://adana.tarimorman.gov.tr/Haber/707/Kozan-Ilcesinde-Orman-Yangini-Kontrol-Altina-Alindi-Sogutma-Calismalari-Devam-Ediyor.>, Erişim tarihi: 10 Ocak 2024.
- Adana Valiliği, 2021. Kozan Yangınında Yok Olan Orman Alanları Yeniden Ağaçlandırılıyor, <http://adana.gov.tr/ms-3453>. Erişim tarihi: 10 Ocak 2024.
- ESA, 2023. European Space Agency Data Hub.<https://scihub.copernicus.eu/dhus/#/home>. Erişim tarihi: 10 Ocak 2024.

11. Google LLC, 2024. Google Earth Engine (Computer software) <https://earthengine.google.com>. Erişim tarihi :6 Mayıs 2024.
12. Key, C.H., Benson, N.C., 2006. Landscape Assessment: Ground Measure of Severity, The Composite Burn Index, And Remote Sensing of Severity, The Normalized Burn Ratio, in: Lutes, D.C., Keane, R.E., Caratti, J.F., Key, C.H., Benson, N.C., Sutherland, S., Gangi, L.J. (Gtr.), FIREMON: Fire Effects Monitoring and Inventory System, 1-55, Washington DC.
13. Pettorelli, N., Ryan, S., Mueller, T., Bunnefeld, N., Jędrzejewska, B., Lima, M., Kausrud, K., 2011. The Normalized Difference Vegetation Index (NDVI): Unforeseen Successes in Animal Ecology. *Climate Research*, 46(1), 15-27.
14. Yener, H., Koç, A., Çoban, H.O., 2006. Uzaktan Algılama Verilerinde Sınıflandırma Doğruluğunun Belirlenmesi Yöntemleri. *İstanbul Üniversitesi Orman Fakültesi Dergisi*, Seri B, 56/2.
15. Davarcı, M.A., 2011. 2006-2010 Yılları Arasında Seyhan ve Yüreğir İlçelerinde Uzaktan Algılama ile Ekili Ürün Değişimi Tespiti. Yüksek Lisans Tezi, Ç.Ü. Fen Bilimleri Enstitüsü, Adana, 114.
16. Çetinkaya, B., Toz, G., 2007. Coğrafi Veri Seçim İşlemi Sonuçlarının Değerlendirilmesinde Hata Matrisinin Kullanımı. *İtü Dergisi/D*, 6(5-6), 59-68.
17. European Forest Fire Information System (EFFIS), <https://effis.jrc.ec.europa.eu/about-effis/technical-background/fire-severity>. Erişim tarihi: 10 Ocak 2024.
18. Bisrat, E., Berhanu, B., 2018. Identification of Surface Water Storing Sites Using Topographic Wetness Index (TWI) and Normalized Difference Vegetation Index (NDVI). *Journal of Natural Resources and Development*, 8, 91-100.
19. Mehta, A., Shukla, S., Rakholia, S., 2021. Vegetation Change Analysis Using Normalized Difference Vegetation Index and Land Surface Temperature in Greater Gir Landscape. *J Sci Res*, 65(3), 1-6.
20. Hashim, H., Abd Latif, Z., Adnan, N.A., 2019. Urban Vegetation Classification with NDVI Threshold Value Method with Very High Resolution (VHR) Pleiades Imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 237-240.
21. Öncü, G., Çorumluoğlu, Ö., 2023. Assessment of Forest Fire Damage Severity By Remote Sensing Techniques. *International Journal of Environment and Geoinformatics*, 10(2), 151-158.
22. Yüksel, K., 2022. Yanan Orman Alanı Tespitinde Farklı Uzaktan Algılama İndislerinin Değerlendirilmesi: 2022 Yılı Mersin (Gülner) Orman Yangını Örneği. *ArtGRID- Journal of Architecture Engineering and Fine Arts*, 4(2), 160-171.

Pamuklu İpliklerin Köpük Aplikasyon Metodu Kullanılarak İndigo Boyarmadde ile Boyanması

Sıddık YAVUZ*¹ ORCID 0000-0001-6885-7391
Onur BALCI¹ ORCID 0000-0003-1585-8336

¹Kahramanmaraş Sütçü İmam Üniversitesi, Mühendislik Mimarlık Fakültesi, Tekstil Mühendisliği Bölümü, Kahramanmaraş

Geliş tarihi: 03.06.2024 Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: YAVUZ, S., BALCI, O., (2024). Pamuklu İpliklerin Köpük Aplikasyon Metodu Kullanılarak İndigo Boyarmadde ile Boyanması. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 515-526.

Öz

İndigo boyarmaddesi, insanlığın kullandığı en eski boyarmaddelerden bir tanesidir. 20. Yüzyıl'ın başından itibaren, denim (kot) kumaşı ve bu kumaştan yapılan pantolonlar (jeans) Dünya çapında yaygınlaşmıştır. İndigo boyarmaddesi tekstilde kullanılan diğer boyarmaddeler ile kıyaslandığında kimyası ve boyama mekanizması bakımından birçok noktada farklılıklar göstermektedir. Bu çalışma kapsamında köpük aplikasyon yöntemi ile %100 pamuklu ipliklere indigo boyarmadde ile boyama yapmak ve klasik metotlara alternatif bir yaklaşım geliştirmek hedeflenmiştir. Köpük aplikasyonu yapabilmek için bir aparat tasarlanmış ve imalatı gerçekleştirilmiştir. Geliştirilen yeni aparat kullanılarak, çözgü ipliklerine köpük aplikasyon tekniği ile indigo boyamalar yapılarak denim kumaş dokunmuştur. Elde edilen numunelerin renk, haslık, dayanım ve elastikiyet gibi performans özellikleri araştırılmıştır. Böylece çalışma sonunda köpük aplikasyon yönteminin indigo boyama için uygulanabilirliği kanıtlanmıştır. Köpük aplikasyon yöntemi ile indigo boyamanın konvansiyonel yöntemlere göre avantajları, yatırım maliyeti ve yerleşim alanının daha az olması, boyama sonu çıkan atıkların çevreye olan etkisinin az oluşu ve daha az iplik telefinin çıkması olarak sıralanabilmektedir.

Anahtar Kelimeler: İndigo, Denim, Boyama, Köpük, Renk, Haslık

Dyeing of Cotton Yarns with Indigo Dyestuff Using the Foam Application Method

Abstract

The indigo dyestuff is one of the oldest dyestuffs used by humanity. Since the beginning of the 20th century, denim fabric and trousers made from this fabric have become widespread around the world. Indigo dyestuff, when compared to other dyestuffs used in textiles, differs in many respects in terms of its chemistry and dyeing mechanism. Within the scope of this study, it was aimed to dye 100% cotton yarns with indigo dyestuff using the foam application method and to develop an alternative approach to classical methods. An apparatus for foam application has been designed and manufactured. Using the newly developed apparatus, indigo dyeing was done on the warp threads using the foam application technique. The denim fabric is woven with dyed threads. Performance properties of the obtained samples such as color, fastness,

*Sorumlu yazar (Corresponding Author): Sıddık YAVUZ, sddkyavuz@gmail.com

strength and elasticity were investigated. Thus, at the end of the study, the applicability of the foam application method for indigo dyeing was proven. The advantages of indigo dyeing with the foam application method compared to the conventional method can be listed as lower investment cost and residential area, less environmental impact of the waste produced after dyeing, and less yarn waste.

Keywords: Indigo, Denim, Dyeing, Foam, Colour, Fastness

1. GİRİŞ

İndigo boyarmaddesi, bulunduğu coğrafyaya göre değişik türleri ve adları olan, ancak yaygın olarak "indigofera" olarak adlandırılan bir bitkinin özünden elde edilmiştir. Bu boyamanın geçmişi çok eskilere dayanmaktadır. Değişik kaynaklarda yapılan arkeolojik kazılarda M.Ö.4000 yıllarında kullanıldığı varsayılmaktadır. İndigo bitkisinden elde edilen öz, canlı mavi renk tonları elde etmek için kullanılmıştır. İndigo, denim (kot) kumaşın çözgü ipliklerini boyamak amacı ile kullanılmakta olan bir boyarmaddedir. İndigo boyarmaddenin sentetik olarak üretiminin denim kumaş üretiminin yaygınlaşması üzerinde oldukça etkisi vardır. Tarihte indigo boyama, çile haline getirilen ipliklerin kazanlarda hazırlanan boyarmaddenin içine daldırılıp çıkartılmasıyla yapılmıştır. 20. yy.'ın başından itibaren makinalar devreye girmiş ve boyama işlemi makinalarda yapılmaya başlamıştır.

Güncel literatür incelendiğinde, denim kumaşlar üzerine gerçekleştirilen çalışmaların çoğunun hazır giyim aşamasındaki efektlendirme veya kumaş oluşumu esnasında uygulanan bitim işlemleri ile ilgili olduğunu görmek mümkündür [1-7]. Literatürde denim kumaştakinin aksine, indigo boyarmadde ve alternatif boyama yöntemleri üzerine deneysel çalışmalara rastlanmadığı tespit edilmiştir. Bu çalışma tespit edilen bu eksiğin giderilmesi için önemli verileri içermektedir [8-13]. Köpük aplikasyon ile ilgili yapılan çalışmalar incelendiğinde ise tekstilde apre uygulamaları üzerine gerçekleştirilen çalışmalara ulaşılabilmektedir. Bu bağlamda köpük aplikasyon tekniği ile indigo boyarmaddenin kullanıldığı, boyama tekniği açısından bu detaydaki ilk çalışmadır [14-18].

İndigo boyama, kullanılan boyarmaddenin ve boyama işlemi için kullanılan makine yapılarından

dolayı atık su oranı en fazla olan boyama yöntemidir. Boyama prosesleri ve makineleri incelendiğinde halat boyama ve slasher çözgü boyama yöntemlerinde 3-4 tekne ön terbiye, 10-12 tekne boyama ve 3-4 tekne de son yıkama olmak üzere toplamda 20 civarında tekne bulunmaktadır. Boyama işleminin başlaması için en küçük makinalarda bile yaklaşık 30 ton civarı indigo boyarmadde içeren renkli su kullanılması gerekmektedir. Boyama işlem sırasında her ön ve ard yıkama teknesi için ayrıca aşırı bir su tüketimine ihtiyaç duyulmaktadır. Tüketilen su, içerdiği boyarmadde ve yardımcı kimyasallar bakımında da oldukça kirletici bir yapıya sahiptir. Bu sebeple sürdürülebilir indigo boyama yöntemleri geliştirilerek kimyasal ve su tüketimlerinin azaltılması hedeflen çalışmalar büyük bir önem arz etmektedir.

İndigo boyama, halat boyama, açık en çözgü (slasher) boyama ve looptex olmak üzere 3 farklı yöntem ile yapılmaktadır. Ticari olarak halat boyama ve açık en çözgü boyama çok yaygındır. Looptex denilen yöntem ise verimlilik ve kalite etkilerinden dolayı çok yaygın kullanılmamaktadır [2].


Bu çalışmada asıl amaç, var olan bu boyama yöntemlerinden bir tanesini (slasher tip, açık en çözgü boyama) modifiye ederek, çevreci bir boyama elde etmektir. Özellikle son yıllarda tekstilde kullanımı gittikçe artan ve daha ekonomik olan köpüklü aplikasyon yöntemi ile hem yatırım maliyetleri hem de üretim maliyetleri ve verimliliği daha uygun olan yeni bir metot geliştirileceği öngörülmüştür. Bu öngörüden yola çıkarak köpük aplikasyon ile indigo boyama yapabilmek için geliştirilen yeni aparat, yatay konumlandırılmış olan baskı silindirlerinin üzerine yerleştirilmiştir. Köpük ve azot gazı besleme sistemleri bu aparata eklenerek, sistem çalışır duruma getirilmiştir. Köpük aplikasyon sistemi ile indigo boyama yönteminin çözgü ipliklerine uygulanabilirliği, bu çalışmada kanıtlanmıştır. Söz konusu yeni yöntemin sağlayacağı avantajlar belirlenmiştir.

2. MATERYAL VE METOD

2.1. Materyal

Bu çalışmada belirtilen amaçlar doğrultusunda köpük aplikasyonunu gerçekleştirmek için açık en (slasher) boyama makinesi üzerinde yeni bir makine/aparat geliştirilmiştir.

Geliştirilen makinede köpük aplikasyonu sırasında ortamda bulunan oksijen ile köpük formunda olan indigo boyarmaddenin reaksiyona girerek yükseltgenmesini engellemek için aparata azot gazı bağlantıları yapılmıştır. Açık en (slasher) indigo boya makinasına ait bir adet boyama teknesi üzerinde çözgü geçiş yönü ve silindir dönüş yönü, diğer tekne bağlantıları değiştirilmiştir. Geliştirilen aparat Şekil 1'de görüldüğü gibi ön işlemi önceki teknelerde yapılan çözgü ipliği, aparatın üst kısmında bulunan ve serbest dönen silindirler arasından geçirilerek tekne üstünden bulunan tahrikli ve yatay konumlandırılmış olan silindirler üzerinden köpük aplikasyonu yapılarak baskı işleminden sonra oksidasyon bölgesine sevk edilerek köpük aplikasyonu ile boyama işlemi gerçekleştirilmiştir.



Şekil 1. Köpük aparatının tekne üstü yerleşimin görünüşü

Çalışma kapsamında boyamada kullanılan çözgü ipliği Ne 14/1 ring şantuk ve hammaddesi %100 pamuktur. Çalışma kapsamında boyama, terbiye ve yıkama işlemleri sırasında kullanılan kimyasallar Çizelge 1'de gösterilmiştir.

Çizelge 1. Çalışmada kullanılan kimyasallar

Proses	İsim	Görevi / Özellik
İNDİGO BOYAMA REÇETESİ	Sıvı indigo	İndirgenmiş indigo
	Kostik	48 Be ⁰
	Islatıcı	Sıvı
	Hidrosülfid	İndirgeyici – Toz
	Sitrik Asit	Toz
	İyon tutucu	Sıvı
	Islatıcı	Sıvı
TERBİYE REÇETESİ	Kostik	48 Be ⁰
	Islatıcı	Sıvı
	Yumuşatıcı	Noniyonik- Sıvı
	Yumuşatıcı	Polietilen- Sıvı
	Sitrik Asit	Toz

2.2. Metot

Çalışma kapsamında 100% indigo boyarmadde ile açık en boyama (slasher) makinasında konvansiyonel sistem ile boyanan bir reçete referans olarak alınmıştır. Referans alınan bu "reçete 1" olarak numaralandırılmıştır (Çizelge 2). Referans numune dışında 10 farklı proses oluşturulmuş ve bu prosesler doğrultusunda 10 farklı boyama yapılmıştır. Toplamda 11 proses uygulaması yapılmıştır. Çizelge 2'de de detayları verilen ve bu çalışmada değişkenlik gösteren parametreler aşağıdaki gibidir;

- Aplikasyon yöntemi (konvansiyonel emdirme, köpük)
- Makina çalışma hızı (5-10 ve 20 mt/dk)
- Boyama ortamı (azot – atmosfer)
- Baskı silindirleri basıncı (2,5 bar, 3 bar ve 4,5 bar)
- Boyarmadde konsantrasyonu (300 g/L – 400 g/L)
- Köpük yoğunluğu (200 g/L, 250 g/L ve 300 g/L)

Çizelge 2'den de görüleceği gibi referans proses 1'de indirgenmiş sıvı boyarmadde kullanılırken, diğer denemelerde indirgenmiş sıvı boyarmadde köpük jeneratöründe köpük formuna çevrilmiştir.

Emdirme metodunda boyarmadde su ile taşınırken, köpük tekniğinde bu su ve hava ile sağlanmaktadır. Sıvı indigo referans denemede klasik slasher boyama makinesinde, emdirme metoduna göre uygulanmıştır.

Makine hızı, baskı silindiri basıncı ve köpük yoğunluğu pamuklu ipliğinin boyarmadde alım

oranını değiştireceğinden, çalışmada da değişken olarak seçilmiştir. Boyarmadde konsatrasyonu referans denemede 400 g/L seçilirken, köpük uygulamalarında bu 300 g/L olarak belirlenmiştir. Ayrıca bazı denemeler, indigo boyarmaddenin hava ortamındaki stabilitesini artırmak ve köpük uygulama şartlarını belirleyebilmek için azot gazı kullanılarak yapılmıştır.

Bu, indigo boyarmaddenin life penetre olamadan yükseltgenmesini azaltabilme ve boyarmaddeyi hava şartlarından koruma amacıyla alınmış bir önlemdir. Azot gazı ile havadaki oksijen miktarı seyreltilmiş ve havanın oksitleme kapasitesi düşürülmüştür.

Çizelge 2. Boyama için uygulanan prosesler

Proses no	Aplikasyon yöntemi	Aplikasyon ortamı	Hız (m/dk)	Baskı (bar)	İndigo kons. (g/L)	Köpük yoğunluğu (g/L)
1 (Ref.)	Emdirme	Atmosferik	20	3,0	400	-
2	Köpük	Atmosferik	5	2,5	300	200
3	Köpük	Azot	5	2,5	300	200
4	Köpük	Azot	5	3,0	300	300
5	Köpük	Atmosferik	5	3,0	300	300
6	Köpük	Atmosferik	5	3,0	300	250
7	Köpük	Atmosferik	10	3,0	300	250
8	Köpük	Azot	5	4,5	300	250
9	Köpük	Azot	10	3,0	300	250
10	Köpük	Azot	5	3,0	300	250
11	Köpük	Atmosferik	5	4,5	300	250

Konvansiyonel boyama için boyarmadde ve kimyasallar, tekne içi boya konsantrasyonu ve pH'ı sabitlendikten sonra tekneye otomatik dozaj sistemleri ile belirlenen oranda beslenmektedir. Bu çalışmada referans alınan reçete için %4 lük oranında sıvı indigo beslemesi yapılmıştır. Tekne içi pH değeri 12 için kostik ilavesi yapılmıştır. Bu çalışmada köpük aplikasyon sistemi ile yapılan indigo boyaması için uygulanan reçete (Proses 2-11 için) ise Çizelge 3'de görüldüğü gibidir. Merserizasyon olarak nitelendirilen ve boyamadan önceki teknelerde uygulanan ön işlem için uygulanan reçete Çizelge 4'de görüldüğü gibi hazırlanmıştır. Bu işlem özellikle çözgü ipliklerinde ring efektinin oluşabilme durumu için gerekli bir uygulamadır [12].

Çizelge 3. Boyama reçetesi

Kimyasal ve boyarmadde	g/L
Sıvı indigo (indirgenmiş)	300
Hidrosülfid (toz)	15
Islatıcı (yüzey aktif)	20
Kostik (48 Be°)	15
Köpük Ajanı	30

Çizelge 4. Ön işlem uygulanan reçete

Kimyasal ve boyarmadde	g/L
Kostik (sodyumhidroksit)	35
Islatıcı	15

Çizelge 5. Dokuma bilgileri

Çözgü iplik no	Ne 14/1 RŞ
Çözgü tel sayısı (adet)	5484
Tarak numarası (tel/diş)	70/4
Tarak eni (cm)	196
Atkı iplik (Ne)	20/1-44 dtex
Atkı sıklığı (tel/cm)	20
Örgü	3/1 Z

Bu çalışmada üretilen ham pamuklu kumaşlar için sırasıyla yakma, kısmi merserize, fikse, kimyasal apre ve sanfor prosesleri uygulanmıştır.

Test yapılmadan önce boyanmış ve dokunmuş kumaşlara ev tipi yıkama işlemi yapılmıştır. Ev tipi yıkama işlemi, evde kullanılmakta olan yıkama makinalarında 3 defa, 60 dakika süreyle, 60°C sıcaklıktaki işlem olarak tanımlanmaktadır. Renk ölçümleri ise sadece ev tipi yıkama öncesi elde edilen numuneler üzerine yapılmıştır. Renk ölçümleri spektrofotometre kullanılarak

gerçekleştirilmiştir. Testler, Çizelge 6'da gösterilen standartlara göre yapılmıştır.

Çizelge 6. Uygulan testler ve standartları

Yapılan test adı	Test standardı
Gramaj	ASTM D 3776
Elastikiyet	ASTM D 3107-07
Potluk	ASTM D 3107-07
Kopma muk.	ASTM D 5035 – 95
Yırtılma muk.	ASTM D 1424 – 83
Sertlik (stiffness)	ASTM D 4032 – 94
Sürtünmeye karşı renk haslığı	AATCC 8 – 94

3. BULGULAR


3.1. Renk Ölçümü Testi Sonuçları

11 proses ile elde edilen numunelerin renk ölçümleri Şekil 2'de gösterilmiştir. Yeni geliştirilen prosesler için kritik karar noktaları göz önüne alındığında, odaklanılması gereken en önemli konunun kumaşların renk ile ilgili parametrelerinin olduğunu söylemek mümkündür. Mamul kumaşların L^* değerleri Şekil 2'de gösterilmiştir. Şekil 2 incelendiğinde köpük boyama yöntemi ile elde edilmiş numunelerin renk değerlerinin tamamının referansa göre açık olduğu, daha yüksek ölçülen L^* değerlerinden anlaşılmaktadır. Bilindiği gibi CIELab renk sistemine göre L^* değeri 0 (siyah)-100 (beyaz) aralığında değişen bir büyüklüktür ve değer büyüdükçe beyaza daha yakın bir ton almaktadır.

Köpük aplikasyon sistemi ile yapılan tüm çalışmalar içinde, konvansiyonel slasher boyama renk koyuluğuna en yakın boyamaların P4, P5 ve P6 proseslerinde elde edildiği görülmüştür. Çizelge 2'de görüldüğü gibi P6-P7 ve P9-P10 proseslerinde

sadece hız değişkeni farklılık göstermiştir. Şekil 2'de görüldüğü gibi proses hızı arttıkça L^* değeri artmış, yani renk açık tonda çıkmıştır. Bu veriler ışığında hızın etkisinin atmosferik çalışma şartlarında daha belirgin olarak ortaya çıktığı tespit edilmiştir. Bu da atmosferik şartlarda indigo boyarmaddenin daha kolay okside olması ve hızdan daha fazla etkilenmesi ile açıklanabilmektedir. Hızın artması atmosferik şartlarda teknedeki boyama çözeltisinin daha fazla havalanmasına, karışmasına ve Hidrosülfid oranının da bozulmasına neden olmaktadır. Hidrosülfid oranının değişmesi boyama çözeltisinin bozulmasını ve renk değişimine neden olmaktadır. Azot varlığı bunu azaltmaktadır.

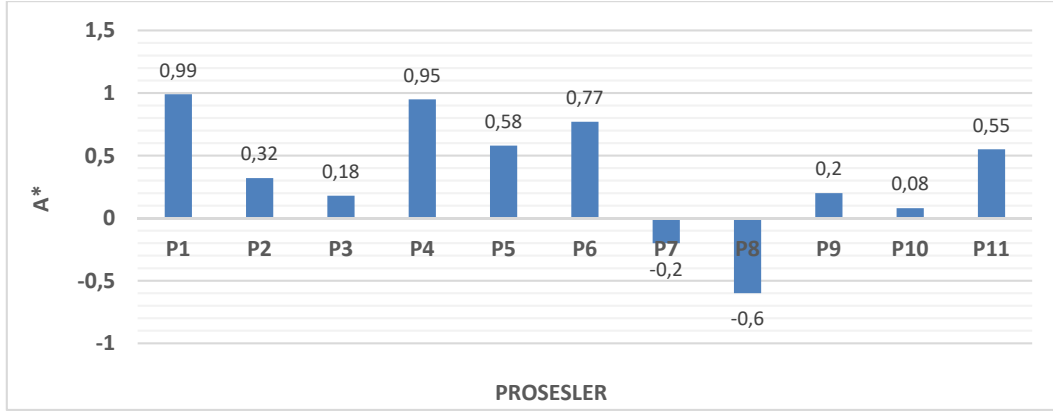
Boyamanın yapıldığı ortam (atmosferik ortam ve azot ortamı) açısından renk sonuçları Şekil 2'de verilen L^* değerleri üzerinden incelendiğinde, P5-P4 proseslerinin L^* değerleri karşılaştırıldığında, azot ortamı ile yapılan sonucu üretilen numune kumaşın rengi daha koyu ölçülmüştür. P7-P9 ve P2-P3 proseslerinde tersi bir durum olduğu görülmektedir. Bunun sebebi ilgili proseslerde çalışma hızının 10 metre/dk olması gösterilebilmektedir. Baskı silindirlerine uygulanan basınç parametresine göre renk değerleri incelendiğinde, uygulanan baskı değeri arttıkça, kısmi de olsa renk koyuluğunun azalmakta olduğu görülmektedir. Uygulanan köpük yoğunluğu parametresine göre renk verileri incelendiğinde, köpük yoğunluğu fazla olan P5 prosesinin renginin, köpük yoğunluğu az olan P6 prosesinin rengine göre daha açık olduğu görülmektedir. Köpük yoğunluğunun fazla olması, boyarmadde çözeltisinin penetrasyonunu düşürmüştür. Şekil 2 incelendiğinde P6, P11'e göre daha koyu olarak ölçülmüştür.



Şekil 2. Numunelerin L^* değerleri

Renk ölçümü çıktılarında olan a* değeri, rengin kırmızı veya yeşil değerlerini göstermektedir. Bu çalışmada elde edilen numune kumaşların a* değerleri Şekil 3'te gösterilmiştir. Sonuçlar incelendiğinde, rengin köpük boyama sonrası,

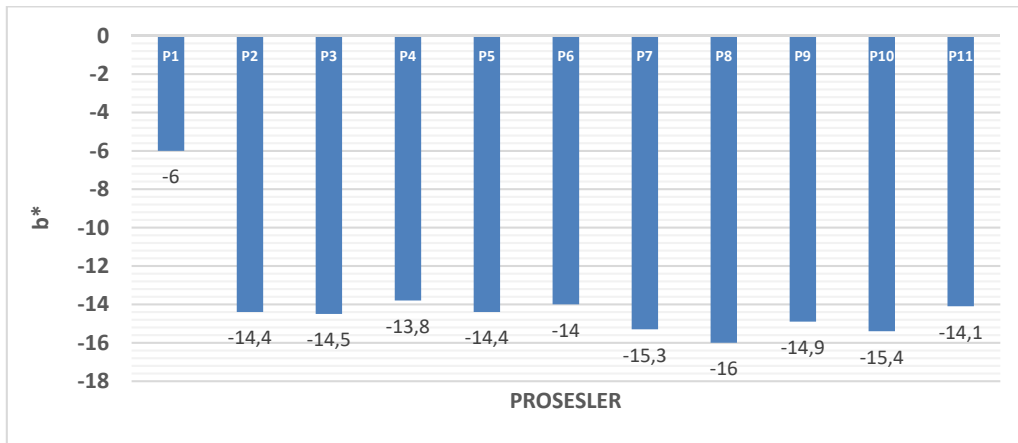
klasik boyamaya göre kırmızılığını kaybettiği ve yeşil tona kaydığı söylenebilmektedir. Bu renk değişiminin derecesi, yapılan işleme göre değişiklik göstermiştir.



Şekil 3. Numunelerin a* değeri

Bu çalışmada elde edilen mamul kumaşların b* değerleri de ölçülmüştür ve proses bazında çıkan sonuçlar Şekil 4'te gösterilmiştir. CIELab renk uzayında ölçülen bu değer, kumaş renginin sarı veya mavi değerlerini göstermektedir. P2-P11 denemelerinden elde edilen numunelerin b* değerlerine bakıldığında, P1'e göre rengin daha mavi ölçüldüğü görülmektedir. P7-P6 ve P9-P10 proseslerinde sadece hız değişkenleri farklılık göstermektedir. Test sonuçları incelendiğinde mavilik değerlerinde hıza bağlı önemli bir

değişiklik tespit edilmemiştir. Deney planı içerisinde incelenen bir diğer konu köpük aplikasyonunun yapıldığı ortam ile ilgilidir. P7-P9, P2-P3 ve P5-P4 prosesleri ile üretilen numune kumaşların Şekil 4'te verilen b* değerleri incelendiğinde, azot ortamı ile çalışmanın mavilik değerini ya değiştirmedeği veya düşük miktarda mavi tona kayacak şekilde değiştirdiği tespit edilmiştir. Şekil 4 incelendiğinde köpük yoğunluğu, konsantrasyon, basınç değişiminin b* değeri üzerinde önemli bir etkisi olmadığı belirlenmiştir.



Şekil 4. Numunelerin b* değerleri

3.2. Sürtünmeye Karşı Renk Haslığı Testi Sonuçları

Bu çalışmada elde edilen kumaşların mamul ve ev yıkama sonrası formlarına kuru sürtme haslıkları ve yaş sürtme haslık testi uygulanmıştır, sonuçlar Çizelge 7'de gösterilmiştir. Proses 2-11'in renk haslığı performanslarının konvansiyonel uygulamaya (Proses 1) kıyasla daha yüksek olduğunu söylemek mümkündür. Bu durum ağırlıklı olarak yaş haslık değerleri için daha net olarak ortaya çıkmıştır. Bu boya penetrasyonun artışı ve boyarmaddenin elyafa daha iyi nüfuz etmesiyle açıklanabilmektedir.


Çizelge 7. Kumaşların renk haslık değerleri

Proses no	Mamul numune		Yıkanmış numune	
	Kuru	Yaş	Kuru	Yaş
P1	4	1/2	4	2
P2	4	1/2	4/5	2/3
P3	4	1/2	4/5	2/3
P4	4	2	4/5	2/3
P5	4	2	4/5	2/3
P6	3/4	2	4/5	2/3
P7	3/4	2	4/5	2/3
P8	3/4	2	4/5	3
P9	3/4	2	4/5	2/3
P10	3/4	2/3	4/5	2/3
P11	3/4	2/3	4/5	3/4

3.3. Gramaj Testi Sonuçları

Bu çalışma sonucu elde edilen kumaşların gramaj testi, mamul ve yıkanmış örnekler olarak ayrı ayrı yapılmıştır. Sonuçlar Şekil 5'de gösterilmiştir.

Şekil 5 incelendiğinde, konvansiyonel prosese kıyasla, köpükle boyanan numunelerin gramaj değerlerinin değişen miktarlarda daha düşük olduğu tespit edilmiştir. Bunun temel nedeninin köpük uygulamasında daha az boyarmaddenin kumaşa aktarılmış olması ve köpük uygulamasının klasik slasher sisteminde olduğu gibi 10 alkali banyoya sahip olmaması gösterilebilmektedir. Şekil 5 incelendiğinde, ön işlem, köpük yoğunluğu, boyama konsantrasyonu, yıkama tekne sayısı, silindir baskı değeri ve boyama ortamının gramaj üzerinde önemli derecede etkisi olmadığı tespit edilmiştir. Boyama konsantrasyonu ve boyama ortamının gramajda %1-3 arasında değişime neden olduğu, ancak bunun bilinen \pm %3 değişim tolerans limitleri içerisinde kaldığı için önemsiz olduğu sonucuna varılmıştır. Boyama konsantrasyonunun artışının ve atmosfer ortamında boyamanın gramajda düşük miktarda artışa neden olduğu tespit edilmiştir. Köpük yoğunluğu değişkeninde ise yoğunluğu fazla olan uygulamadan elde edilen numunenin gramajı, düşük olana göre %3,2 daha yüksek çıkmıştır. Bu da tolerans limitlerine oldukça yakındır.



Şekil 5. Mamul ve yıkanmış numunelerin gramaj (gr/m²) değerleri


3.4 Elastikiyet Test Sonuçları

Uygulanan tüm prosesler sonucu elde edilen kumaş numunelerinin hem mamul olarak hem de ev tipi

yıkama sonrasında elastikiyet değerleri ölçülmüştür. Bu ölçüm sonucunda çıkan değerler Şekil 6'da verilmiştir. Şekil 6 incelendiğinde numunelerin mamul ve yıkama sonrası elastikiyet

değerleri %48 ile %42 arasında değişmiştir. Orijinal kumaşın elastikiyeti %48 iken, köpük aplikasyon yöntemleri ile boyama yapılan kumaşların elastikiyet değerleri %48 ile %42 arasında ölçülmüştür. Mamul elastikiyet değerleri ise %24

ile %21,2 arasında gerçekleşmiştir. Dolayısıyla köpük uygulamaları-referans ve köpük uygulamalarının kendi içerisinde önemli farkların olmadığı yorumu yapılabilmektedir.




Şekil 6. Kumaşların mamul ve yıkama sonrası elastikiyetleri


3.5. Kopma ve Yırtılma Mukavemeti Test Sonuçları

Numune kumaşların mamul formunda çözgü ve atkı kopma mukavemeti değerleri Şekil 7 de,

gösterildiği gibi proses bazlı anlamlı bir değişim görülmemiştir. Mamul formunda yırtılma mukavemeti değerleri ise Şekil 8'de gösterilmiştir. Gerek çözgü gerekse de atkı yırtılma mukavemeti değerlerinde önemli bir değişim tespit edilmemiştir.



Şekil 7. Mamul numunelerin çözgü ve atkı kopma mukavemetleri (kgf)

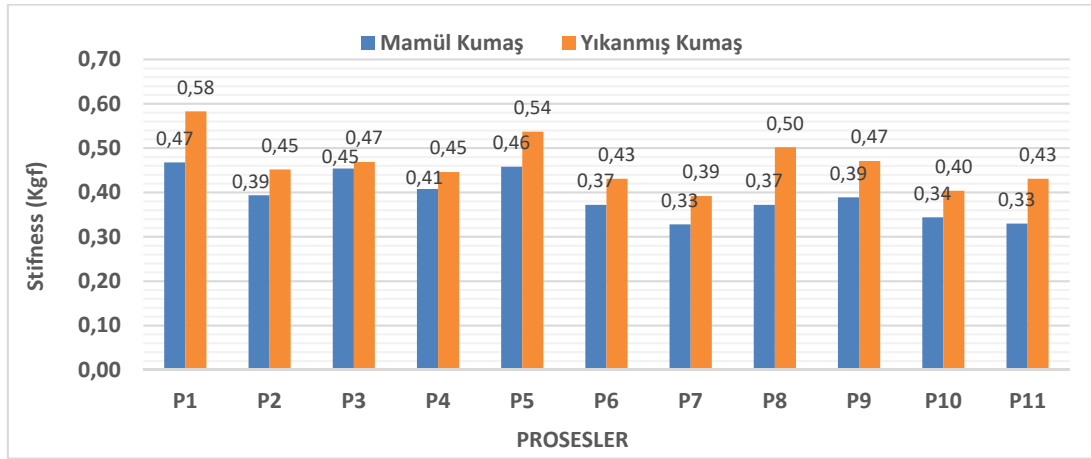


Şekil 8. Mamul numunelerin çözgü ve atkı yırtılma mukavemetleri (gf)

3.6. Sertlik (Stifness) Test Sonuçları

Hem mamul hem de evsel yıkama sonrası numunelere sertlik (stifness) testi yapılmış ve sonuçları Şekil 9'da gösterilmiştir. Test sonuçları incelendiğinde, konvansiyonel boyama yöntemine göre köpük aplikasyonu ile üretilen kumaşların sertlik değerlerinin azaldığı tespit edilmiştir. Bilindiği gibi konvansiyonel slasher boyamada çözgü iplik grubu 10 tekneye dalma hareketi yapmakta ve her seferinde üzerine sıkma ve çekme nedeniyle gerilim yüklenmektedir. Ancak köpük aplikasyonda dalma yapılan tekne tektir. Bu gerilimin kumaşın yumuşaklık değeri üzerinde olumsuzluğa neden olabileceği düşünülmektedir. Yıkama prosesinin yapılması sertlik değerini

artırmıştır. Köpük aplikasyon teknesi üzerindeki baskı silindirlerinin basınç değerlerine bağlı olarak yapılan değerlendirme incelendiğinde, tüm proseslerde düşük baskı uygulanan numunelerin sertlik değerlerinin daha az ölçüldüğü görülmektedir. Özellikle 2,5 bar baskı uygulanan P2-P3 proseslerinin sertlik değerlerinin, diğer proseslere göre yüksek olması, bu ilişkiyi daha açık bir şekilde göstermektedir. Aplikasyon esnasında kullanılan köpüğün yoğunluğuna bağlı olarak yapılan değerlendirmede ise köpük yoğunluğu fazla olan P4 ve P5 proseslerinin sertlik değerlerinin daha yüksek olduğu görülmektedir. Yani köpük yoğunluğu arttıkça çözgü ipliğine nüfuz eden indigo boyarmaddesi artmakta ve bu da kumaşın daha sert tutumda olmasına sebep olmaktadır.



Şekil 9. Numune kumaşların Stifness (sertlik) değerleri

3.7. Tüketim Analizi

Çalışma kapsamında geliştirilen yeni aparat ile uygulanan köpüklü sistem ile indigo aplikasyon reçetesinin, enerji, işçilik, boyarmadde – kimyasal, randıman ve atık üretimi değerleri, konvansiyonel

yöntem ile yapılan indigo boyama reçetesinin verileri ile kıyaslanmıştır. Bu çalışma sonucu elde edilen veriler Çizelge 8'de verilmiştir. Hesaplamalar birim kumaş (metre) üzerinden yapılmıştır.

Çizelge 8. Tüketim analiz verileri

Parametre	Konvansiyonel yöntem	Köpük aplikasyon yöntemi
Enerji	3,2 kW/metre	2,4 kW/metre
İşçilik	1028 metre/kişi	1028 metre/kişi
Boya - Kimyasal	20 gram/metre	16 gram/metre
Randıman / Verimlilik	15 metre/dakika	20 metre/dakika
Katı atık (iplik)	13,8 gram/metre	8,08 gram/metre
Sıvı atık (kimyasal –boyarmadde)	0,06 litre/metre	0,009 lt/metre

- Enerji Tüketimi

Çalışma kapsamında geliştirilen yeni aparat vasıtası ile yapılan köpük aplikasyon sistemi ile indigo boyama yönteminin, konvansiyonel (slasher) indigo boyama sistemlerine göre enerji tüketimleri kıyaslanmıştır. Konvansiyonel yöntemde toplamda 16 boya ve yıkama teknesi kullanılıyorken, köpüklü sistemde 7 adet boya ve yıkama teknesi kullanılmıştır. Bu değişime bağlı olarak, ortalama tüketimi 4 kWh olan motorlardan 9 adet motor kullanım dışı kalmıştır. Bu da saatlik 36 kWh enerji tasarrufu sağlamaktadır. Boya tonunu daha da koyulaştırmak için 2 tekne daha eklenme olasılığını eklediğinde ise saatlik 28 kWh elektrik tasarrufu elde edilmiş olacaktır. Yani konvansiyonel yöntem ile 3,2 kW /mt , köpük yöntemi ile 2,4 kW/mt enerji tüketimi tüketimi olacaktır.

- İşçilik

Köpük aplikasyon sistem ile yapılan indigo boyama yöntemi için gerekli olan işçi sayısı, konvansiyonel yöntem ile kıyaslandığında sayısal bir değişim olmayacağı düşünülmektedir. Ancak işçi başına düşen iş yoğunluğunun daha az olacağı söylenebilmektedir. Çünkü bu sistemde makine temizliği, ek kimyasal takipleri ve hazırlanmaları ve tekne içi parametrelerinin kontrolü gibi noktalar, daha az veya hiç olmayacaktır. Her iki yöntem için bir vardiya için (yaklaşık 8 saat) birim eleman başına düşen üretim 1028 metre/kişi olarak gerçekleşmiştir.

- Boya ve kimyasal tüketimi

Köpük aplikasyon sistem ile yapılan çalışmalardan P2 ve P3 prosesleri için tüketim maliyetleri hesaplanmıştır. Köpük aplikasyonu için hazırlanan çözeltiden 1 litre ile yaklaşık 25 metre çözgü ipliği boyanmıştır. 1 litre çözeltide 300 gram, %40 lık boyarmadde bulunmaktadır. Konvansiyonel yöntem ile yapılan boyamada ise 300 gram, %40'lık boyarmadde çözeltisi ile yaklaşık 15 metre çözgü boyanabilmektedir. Bu veriler incelendiğinde birim bazında yaklaşık %65 oranında daha az boyarmadde kullanıldığı gözlemlenmiştir. Ancak, köpük aplikasyonu yapılan boyamada renk derinliğinin daha açık olması, köpük uygulama

sayısının artırılmasını zorunlu kılmaktadır. Bu çerçevede 2 adet daha köpük aplikasyon aparatı eklenip ve boyarmadde tüketimleri hesaplanması gerekmektedir. Ayrıca uzun metraj çalışmaları yapılması zorunludur. Köpüklü aplikasyon ile ihtiyaç duyulan boyarmadde tüketimi konvansiyonel boyamaya göre yaklaşık %20 daha az olacağı öngörülmektedir.

- Randıman (Verimlilik)

Yapılan çalışma kapsamında elde edilen veriler incelendiğinde, köpük aplikasyon sistemi ile yapılan boyamalarda renk verilerinin en iyi olduğu hız 5 metre/dakikadır. Konvansiyonel yöntemde ise kullanılan hız 20 metre/dakika olarak verilmiştir. Yeni sistem geliştirilmeden kullanılması durumunda, üretim randımanı daha düşük olacaktır. Ancak eklenecek yeni aparatlar (özellikle köpük aplikasyon noktasının artırılması) ile üretim randımanının konvansiyonel yöntemle yaklaştırılacağı öngörülmektedir.

- Atık üretimi

Çalışma kapsamında uygulaması yapılan köpüklü sistem ile indigo boyama yönteminde üretim sırasında çıkan katı ve sıvı atıkların, konvansiyonel sisteme göre daha az olduğu görülmüştür. Özellikle boyama öncesi ve sonrasında oluşan “renkli üstübu” denilen atık iplik miktarının, boyaması 20.000 metre olan bir çözgü ipliği grubu için yaklaşık %40 daha az olacağı öngörülmektedir. Boyama sonrasında drenaja verilen boyarmadde ve kimyasal miktarı açısından incelendiğinde, 20.000 metre olan bir çözgü ipliği için yaklaşık %85 civarında bir iyileşme olacağı öngörülmektedir. Çünkü konvansiyonel yöntemde her tekne içinde bulunan 1200 litre civarındaki boyarmadde çözeltisi belli aralıklarla drenaja atılmak zorunda iken, köpüklü yöntemde bu şekilde bir atık oluşmamaktadır. Sadece köpük yapımı ve beslemesi sırasında önemsenemeyecek bir miktar kayıp oluşmaktadır.

4. SONUÇLAR

Bu çalışma kapsamında köpük aplikasyon sistemi kullanılarak, açık en çözgü boyama (slasher)

makine üzerinde yapılan modifikasyon ile pamuk ipliğinin indigo boyarmadde ile boyanması hedeflenmiştir. Belirlenen hedef doğrultusunda bir aparat geliştirilmiştir. Yapılan yeni aparat kullanılarak indigo boyama işlemi 10 farklı deneme ile sınanmıştır. Köpük aplikasyon ile indigo boyanan çözümlü ipliklerinden aynı özelliklerde kumaş üretilmiş ve aynı şartlarda terbiye edilerek mamul kumaşlar elde edilmiştir. Konvansiyonel yöntem ve köpük aplikasyonu ile boyanan 11 kumaşın gramaj, elastikiyet (%), kopma mukavemeti, yırtılma mukavemeti, kuru ve yaş sürtünmeye karşı renk haslığı, sertlik (stifness) ve renk ölçüm (CIELab değerleri) testleri ile performansları belirlenmeye çalışılmıştır. İndirgenmiş formda bulunan sıvı indigonun, eklenen köpük yapıcı kimyasal ile köpük jeneratörü kullanarak köpük oluşturulabileceği görülmüştür. Ayrıca oluşan bu köpüğün yoğunluğunun, jeneratör ve eklenen köpük ajanı ile rahatlıkla değiştirilebileceği de tespit edilmiştir. Atmosferdeki hava yerine, jeneratöre bağlanan azot gazının etkisiyle, köpük oluşumu sırasında indigo boyanın yükseltgenmesi engellenmiştir. Bu çalışmada boyanan 11 farklı çözümlü dokuma işletmesinde aynı makinada ve aynı parametrelerde dokunmuştur. Tüm proseslerde dokuma randımanını negatif yönde etkileyecek herhangi bir sorun ile karşılaşılmamıştır. Ayrıca dokunmuş ve mamul yapılmış kumaşların fiziksel kalite özelliklerinin de genel hatlarıyla olumsuz etkilenmediği söylenebilmektedir.

Bu çalışma sonunda konvansiyonel boyamaya göre boya ve enerji tüketiminin daha az, işçiliğinin daha düşük olacağı belirlenmiştir. Ayrıca her boyama sonunda çevreye verilen zararın köpüklü sistem ile daha az olacağı gözlemlenmiştir. Dolayısıyla bu proses için, daha sürdürülebilir bir boyama prosesi tanımlanması yapmanın yanlış olmayacağı söylenebilmektedir.

Köpük aplikasyon ile indigo boyama yapılan 10 farklı proses incelendiği zaman, hem test sonuçları açısından hem de boyama esnasında yapılan gözlemler bakımında olumlu sonuçlar olduğu gibi, geliştirmeye açık negatif verilerin de olduğu tespit edilmiştir. Özellikle renk derinliğinin (özellikle L* ve b*) geliştirilmesi gereken en önemli performans

olduğu belirlenmiştir. Köpük aplikasyonda, emdirme metoduna göre düşük miktarda boyarmadde ipliğe aktarılmaktadır. Bunun ilk nedeni daha düşük pick-up değerinde aplikasyon yapılması, diğeri ise 10 tekne yerine tek tekne kullanılmasından kaynaklı, iplik dalma sayısı ve süresinin düşmesidir. Bu halka efektinin oluşması ve renk derinliği açısından problem teşkil ettiği ispatlanmıştır. Bunu çözebilmek için boyarmadde konsantrasyonunun artması ve köpük aplikasyonu tekne sayısının artırılması önerileri sunulabilmektedir. Fiziksel performans açısından sonuçlar irdelendiğinde köpük-konvansiyonel uygulamalar veya köpük aplikasyonun kendi arasında önemli bir fark tespit edilmediği belirlenmiştir. Bu açıdan konu incelendiğinde, köpük aplikasyonun slasher boyama makinesi üzerinde yapılacak modifikasyonlarla iyi bir alternatif olacağı düşünülmektedir.

5. REFERANSLAR

1. Toksöz, M., Mezarıcıöz, S., 2013. Denim Kumaşlara Uygulanan Özel Yıkama Uygulamaları. Çukurova Üniversitesi, Mühendislik Mimarlık Fakültesi Dergisi, 28(2), 141-147.
2. Yavuz, S., 2016. %100 Pamuklu İpliklerin Denim Sektörü için Köpük Aplikasyon Yöntemi ile Renklendirilmesi. Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Tekstil Mühendisliği Anabilim Dalı. Kahramanmaraş.
3. Kadem, F.D., Bakırcı, G.G., 2016. Denim Kumaşların Dikiş Performansları Üzerine Deneysel Bir Çalışma. Çukurova Üniversitesi, Mühendislik Mimarlık Fakültesi Dergisi, 31(1), 143-148.
4. Oğulata, R.T., Nergis, A., 2016. Rins Yıkamanın Denim Kumaş Performansı Üzerindeki Etkilerinin Araştırılması. Çukurova Üniversitesi, Mühendislik Mimarlık Fakültesi Dergisi, 31(2), 421-435.
5. Kadem, F.D., Tölek, Ş., 2016. Kaplamalı Denim Kumaşlarda Performans Özellikleri Üzerine Deneysel Bir Çalışma. Çukurova Üniversitesi, Mühendislik Mimarlık Fakültesi Dergisi, 31(2), 307-315.

6. Oğulata, R.T., Nergis, A., 2017. Farklı Yıkamaların Denim Kumaş Performansının Üzerindeki Etkilerinin Araştırılması. Çukurova Üniversitesi, Mühendislik Mimarlık Fakültesi Dergisi, 32(4), 87-98.
7. Sarker, M.E., Mezarıcıöz, S., 2023. The Effects of Several Washings on Some Comfort Features of Denim Fabrics Made Cotton and Coolmax Weft Yarns with and without Elastan. Çukurova Üniversitesi, Mühendislik Mimarlık Fakültesi Dergisi, 38(4), 1151-1159.
8. Luo, Y., Pei, L., Wang, J., 2020. Sustainable Indigo Dye and Improvement Rubbing Fastness of Dyed Cotton Fiber Using Different Fixing Agents for Optaining Eco Friendly Cowboy Products. Journal of Cleaner Production, 251(2020), 119728
9. Yi, C., Tan, X., Bie, B., Ma, H., 2020. Practical and Environment-Friendly Indirect Electrochemical Reduction of Indigo Dyeing. Scientific Reports, 10, 4927.
10. Li, X., Wang, K., Wang, M., Zhang, W., Yuo J., 2020. Sustainable Electrochemical Dyeing of Indigo with Fe(II) Based Complexes. Journal of Cleaner Production. 276(2020), 123251.
11. Mezarıcıöz, S., Sırlıbaş, S., 2021. Denim Kumaşlara Çevre Dostu Ön Terbiyesiz Boyama Metodunun Uygulanması. Çukurova Üniversitesi, Mühendislik Mimarlık Fakültesi Dergisi, 36(4), 1127-1135.
12. Rai, S., Saremi, R., Sharma, S., Minko, S, 2021. Environment – Friendly Nanocellulose – Indigo Dyeing of Textiles. Royal Society of Chemistry, July-2021.
13. Wu, M., Chen, Y., Peng, P., Zuo D., Wing Q., Liu, L., Liao, S., 2022. Optimization of Dark Dyeing Poly (Lactic Asid) with Indigo Dyes Applied to Denim Fabric. The Journal of Textile Institute. 114(3), 455-461.
14. Mohsin, M., Sardar, S., 2020. Development of Sustainable and Cost Efficient Textile Foam Finishing and Its Comparison with Conventional Padding. Cellulose, 27,4091-4107.
15. Abate, M.T., Tadesse, M.G., 2021. Airflow, Foam and Supercritical Carbon Dioxide Dyeing Technologies. Ethiopian Institute of Textile and Fashoin Technology. Bahir Dar University, Bahir Dar, Ethiopia.
16. Cohen, N.S., 2021. Analysis of Reactive Dyes on Pretreated Fabric for Foam Dyeing. A Thesis Submitted to the Graduate Faculty of North Carolina State University in Partial Fulfilment of The Requirement for the Degree of Master Science.
17. Zhu, D., Wan, Z., Liao, S., Wang, Q., Liu, L., Yi, C., 2022. Foaming Indigo: An Efficient Technology for Yarn Dyeing. Dyes and Pigments 197(2022), 109862.
18. Mohsin, M., Sardar, S., Shehzad, A., Anam, W, Ijaz, S., Afraz, N., Jamil, A., 2023. Performance Enhancement of Water and Energy Efficient Foam Dyeing and Finishing Through Different Foaming Agents. Journal of Natural Fibers. 20(1), 216.

Bir Firmanın Belirsizlik Altında Sürdürülebilirlik Performansının Değerlendirilmesi: Bulanık AHP Yaklaşımı

Kübra TÜMAY ATEŞ*¹ ORCID 0000-0002-3337-7969

¹Çukurova Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Adana

Geliş tarihi: 23.05.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: TÜMAY ATEŞ, K., (2024). Bir Firmanın Belirsizlik Altında Sürdürülebilirlik Performansının Değerlendirilmesi: Bulanık AHP Yaklaşımı. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 527-533.

Öz

Sürdürülebilirlik performansını belirlemek için kullanılan geleneksel yöntemler, genellikle kesin verilere dayanır ve belirsizlikleri dikkate almaz. Ancak, gerçek dünyada, sürdürülebilirlik performansını etkileyen faktörler genellikle belirsizdir. Bu nedenle, sürdürülebilirlik performansını objektif bir şekilde değerlendirmek için belirsizlikleri ele alabilen bir yöntem gereklidir. Sürdürülebilirlik, çevresel, ekonomik ve sosyal boyutlarıyla karmaşık bir kavram olup, bu boyutların etkileşimi, işletmelerin uzun vadeli başarısı üzerinde önemli bir etkiye sahiptir. Bu çalışma, bu boyutlar arasındaki ilişkileri ve önem sıralarını belirlemek için bulanık mantık prensiplerini entegre eden bir Fuzzy Analitik Hiyerarşi Prosesi (AHP) yaklaşımını önermektedir. Fabrikaların sürdürülebilirlik performansını belirlemek için Fuzzy AHP yöntemi kullanılarak altı temel kriterin sürdürülebilirliğe olan etkisi değerlendirilmiştir. Bu altı temel kriter alanında uzman kişiler ve fabrika yönetimi ile birlikte; enerji verimliliği, atık yönetimi, su kullanımı, işçi sağlığı ve güvenliği, toplumsal katılım ve sorumluluk, ve tedarik zinciri yönetimi olarak firmaların sürdürülebilirlik performansını belirlemek için seçilmiştir. Çalışma sonucunda bir fabrika için "Enerji Verimliliği" kriterininin 0,27 puan ile diğer kriterlerden çok daha öncelikli olduğu saptanmıştır.

Anahtar Kelimeler: Bulanık AHP, Sürdürülebilirlik, Enerji firmaları, Enerji verimliliği

Assessment of a Company's Sustainability Performance Under Uncertainty: Fuzzy AHP Approach

Abstract

Traditional methods used to determine sustainability performance generally rely on precise data and do not take uncertainties into account. However, in the real world, factors affecting sustainability performance are often uncertain. Therefore, a method capable of addressing uncertainties is necessary to objectively assess sustainability performance. Sustainability is a complex concept with environmental, economic, and social dimensions, and the interaction of these dimensions has a significant impact on the long-term success of businesses. This study proposes a Fuzzy Analytic Hierarchy Process (Fuzzy AHP) approach that integrates fuzzy logic principles to determine the relationships and priorities among these dimensions. Six key criteria

*Sorumlu yazar (Corresponding Author): Kübra TÜMAY ATEŞ, tumaykubra@gmail.com

influencing sustainability were evaluated using the Fuzzy Analytic Hierarchy Process method to determine the sustainability performance of factories. These six key criteria, selected in collaboration with experts and factory management, include energy efficiency, waste management, water usage, worker health and safety, social engagement and responsibility, and supply chain management. The study concluded that for a factory, the criterion of "Energy Efficiency" is prioritized with a score of 0.27 compared to other criteria.

Keywords: Fuzzy AHP, Sustainability, Energy companies, Energy efficiency

1. GİRİŞ

Günümüzde, işletmelerin sürdürülebilirlik alanında gösterdikleri performans, hem çevresel hem de sosyal etkiler açısından giderek daha fazla önem kazanmaktadır. Endüstriyel faaliyetlerin artan çevresel etkileri ve sosyal sorumluluk beklentileri, işletmeleri sürdürülebilirlik ilkelerine uyum sağlamaya ve bu ilkeleri iş stratejilerine entegre etmeye yönlendirmektedir. Bu bağlamda, sürdürülebilirlik kavramı, işletmelerin faaliyetlerini çevresel, ekonomik ve sosyal açıdan dengelemesini ve uzun vadeli başarılarını sağlamasını gerektirmektedir.

Sanayi endüstrisi gibi büyük ölçekli üretim tesisleri, çeşitli sürdürülebilirlik kriterlerinin etkilerine maruz kalan ve bu kriterleri yönetmek için karmaşık stratejiler geliştirmesi gereken önde gelen sektörlerden biridir. Bu kriterler arasında enerji verimliliği, atık yönetimi, su kullanımı, işçi sağlığı ve güvenliği, toplumsal katılım ve sorumluluk, ve tedarik zinciri yönetimi gibi önemli faktörler bulunmaktadır. Her biri, işletmenin sürdürülebilirlik performansını belirlemede kritik bir rol oynar ve etkileşimleri karmaşık bir denge gerektirir. Bu çalışmanın amacı, fabrikaların sürdürülebilirlik performansını belirlemek ve geliştirmek için kullanılacak etkili stratejileri araştırmaktır. Enerji verimliliği, atık yönetimi, su kullanımı, işçi sağlığı ve güvenliği, toplumsal katılım ve sorumluluk, ve tedarik zinciri yönetimi gibi ana kriterler, bir fabrikanın sürdürülebilirlik performansını analiz etmek için seçilmiştir.

Gerek belirsizlik altında yapılan analizler gerekse bir enerji firmasından alınan gerçek verilerin kullanıldığı bu çalışma, farklı bir bakış açısı ile ele alınmıştır. Bu kapsamda, fabrikaların sürdürülebilirlik kriterlerine olan etkisini

belirlemek amacıyla Fuzzy AHP (Fuzzy Analytic Hierarchy Process) yöntemi kullanılmıştır. Günümüzde çok yaygın olarak kullanılan bu tekniğin çok sayıda değişik sektöre uygulandığı görülmektedir.

Saaty, Analitik Hiyerarşi Süreci'nin (AHP) aksiyomatik temelleri incelenmiştir. AHP'nin matematiksel yapısı ve temel prensipleri detaylı bir şekilde ele alınmıştır [1]. Özgen ve Saçlı çalışmalarında Türkiye'de yenilenebilir enerji kaynağı seçimi için Fuzzy AHP ve PROMETHEE (Preference Ranking Organization Method for Enrichment Evaluation) yöntemleri kullanılmıştır. Çalışma, yenilenebilir enerji projelerinin seçiminde karar verme sürecinde kullanılacak etkili yöntemleri sunmaktadır [2].

Kahraman ve Sener, rüzgar türbini seçimi için yeni bir yöntem olan Fuzzy AHP ve Pitagorcu bulanık kümeleri kullanarak, rüzgar enerjisi projelerinin planlanması ve geliştirilmesinde karar verme sürecinde kullanılacak yenilikçi bir yöntem önermiştir [3]. Kwak ve Lee, organizasyonel sürdürülebilirliğin değerlendirilmesi için yeni bir yaklaşım olan Fuzzy AHP ve aralık değerli intuitionist bulanık TOPSIS (Technique for Order Preference by Similarity to Ideal Solution) yöntemleri kullanarak organizasyonların sürdürülebilirlik performansını değerlendirmek için etkili bir metodoloji sunmuştur [4]. Deng ve Wu, otomotiv endüstrisinde yeşil tedarik zinciri yönetimi için Fuzzy AHP tabanlı bir karar verme modelini inceleyerek, yeşil tedarik zinciri yönetimi stratejilerinin belirlenmesinde ve yeşil uygulamaların entegrasyonunda etkili bir araç sunmuştur [5]. Chen ve Li, sürdürülebilir tedarikçi seçimi için Fuzzy AHP, ELECTRE (Elimination and Choice Translating Reality) ve TODIM (Tomada de Decisão Interativa Multicritério)

yöntemlerini birleştiren yeni bir hibrit çok kriterli karar verme modeli sunmuştur. Tedarikçi seçimi sürecinde belirsizlikleri ele almak için etkili bir yaklaşım öne sürmüştür [6]. Kahraman ve Cebi, çok kriterli tedarikçi seçimi probleminde Fuzzy AHP yöntemi uygulanmıştır. Fuzzy AHP'nin, tedarikçi seçimindeki belirsizlikleri ele almak ve karar vericilere esneklik sağlamak için etkili bir araç olduğu gösterilmiştir [7]. Yazdani-Chamzini ve Keramati, İran'da yenilenebilir enerji projelerine yatırım yapılmasını önceliklendirmek için Fuzzy AHP tabanlı bir yaklaşımı inceleyip, yenilenebilir enerji yatırımlarının planlanması ve önceliklendirilmesinde etkili bir araç sunmuştur [8]. Chen, yeşil tedarikçi seçimi için Fuzzy çok kriterli karar verme yöntemlerini inceleyerek yeşil tedarikçi seçiminde kullanılan farklı Fuzzy yöntemlerini karşılaştırır ve gelecekteki araştırma alanlarına odaklanmıştır [9]. Wang ve Kuo, havacılık endüstrisinde karbon dengeleme projelerini değerlendirmek ve seçmek için Fuzzy AHP tabanlı bir yaklaşımı inceleyip, havacılık endüstrisinde karbon ayak izinin azaltılmasına yönelik stratejilerin geliştirilmesine rehberlik etmiştir [10]. Lee ve Lin, akıllı şehirlerin sürdürülebilir kalkınmasını değerlendirmek için entegre bir Fuzzy AHP ve DEMATEL (Decision-Making Trial and Evaluation Laboratory) yaklaşımını incelemiştir. Akıllı şehirlerin sürdürülebilirlik performansını analiz etmek ve iyileştirmek için etkili bir çalışma sunmuştur [11]. Liu ve Liu, bulanık analitik hiyerarşi süreci (Fuzzy AHP) kullanarak çevresel, sosyal ve kurumsal faktörlerin yatırım kararlarında nasıl değerlendirilebileceğini incelemiştir [12]. Özdemir ve Akdoğan, bulanık çok kriterli karar verme yöntemini kullanarak yeşil inovasyon yönetimini değerlendirmiştir. Çalışmada, yeşil ürün tasarımı, yeşil tedarikçi seçimi ve pazarlama stratejileri gibi yeşil inovasyon süreçlerinin sürdürülebilirlik boyutları ile nasıl entegre edildiği incelenmiştir [13]. Atay ve Kahraman, bulanık mantık modellerini kullanarak iklim değişikliği risklerini değerlendirmiştir. Bu çalışma, belirsizliklerin ve karmaşıklıkların bulanık mantık ile nasıl yönetildiğini ve işletmelerin iklim değişikliği ile ilgili stratejilerini nasıl şekillendirebileceğini göstermiştir [14].

Bu çalışmalar, Fuzzy AHP'nin yenilenebilir enerji, rüzgar enerjisi ve organizasyonel sürdürülebilirlik gibi farklı alanlarda nasıl kullanılabileceğine dair güncel bir bakış açısı sunmaktadır.

2. MATERYAL VE METOT

Fuzzy AHP (Fuzzy Analytic Hierarchy Process) yöntemi, belirsizlik ve bulanıklık içeren karar verme süreçlerinde kullanılan bir metodolojidir. Bu metodoloji, bulanık mantık prensiplerini, karar verme sürecindeki belirsizlikleri ele almak için geliştirilmiş olan Analitik Hiyerarşi Süreci (AHP) metodolojisiyle birleştirir. Lotfi Zadeh, bulanık mantık alanında temel çalışmalarıyla bilinirken, Thomas L. Saaty, AHP metodolojisini geliştirerek karar verme problemlerine uygulanabilir hale getirmiştir [15-17].

Fuzzy AHP, AHP'nin temel prensiplerini kullanır ve bu prensipleri bulanık küme teorisine dayandırır [17]. Oluşturulan teoride S_i , i . değerinin bulanık sayılardaki karşılığı olarak tanımlanmıştır. Bulanık karşılaştırma değerleri ise M_{gi}^j olarak ifade edilmiştir. Bu gösterim, i . kriterin j . kritere göre üçgensel bulanık sayı karşılığını ifade etmektedir. Chang'ın teorisi adım adım denklemlerle açıklanmıştır [18]:

1. Adım: i . ölçüte göre bulanık sentetik mertebe değerleri hesaplanır.

$$S_i = \sum_{j=1}^m M_{gi}^j * [\sum_{j=1}^n \sum_{j=1}^m M_{gi}^j]^{-1} \quad (1)$$

$$[\sum_{j=1}^n \sum_{j=1}^m M_{gi}^j]^{-1} = [\frac{1}{\sum_{i=1}^n u_i}, \frac{1}{\sum_{i=1}^n m_i}, \frac{1}{\sum_{i=1}^n l_i}]$$

2. Adım: M_1 ve M_2 nin birbirlerine göre üçgensel bulanık sayıların olabilirlik dereceleri hesaplanır.

$$M_2 = (l_2, m_2, u_2) \geq M_1 = (l_1, m_1, u_1)$$

$$V(M_2 \geq M_1) = \begin{cases} 1, & m_2 \geq m_1 \\ 0, & l_1 \geq u_2 \\ 0, & \frac{l_1 - u_2}{(m_2 - u_2) - (m_1 - l_1)} \text{ diğerleri} \end{cases} \quad (2)$$

3. Adım: Her satır için ikili karşılaştırmalar yapılır ve minimum değerleri alınır.

$$i = \{1,2,\dots, n\} \text{ için } d'(A_i) = \min V(S_i \geq S_n) \quad (3)$$

4.Adım: $n \neq i$ olmak üzere ağırlık vektörü hesaplanır.

$$W' = ((d'(A_1), d'(A_2), \dots, \dots, d'(A_n))^T \quad (4)$$

$$i = \{1,2,\dots, n\}$$

5. Adım: Hesaplanan ağırlık vektörleri normalize edilir ve buradaki W sayısı bulanık bir sayı değildir.

$$W = ((d(A_1), d(A_2), \dots, \dots, d(A_n))^T \quad (5)$$

$$i = \{1,2,\dots, n\}$$

2.1. Alternatif Küme Tanımı ve Karar Vericinin Dilsel Değerlendirmesinin Elde Edilmesi

Bulanık AHP yönteminin başlangıcı itibariyle kriterlerin belirlenmesinin ardından, uzmanların

Çizelge 1'de verilen dilsel değerler ölçeğine göre kriterlere ilişkin görüşlerini belirtmişlerdir.

Çizelge 1. Saaty'nin 1-9 dil ölçeği [19]

Dilsel terimler	Üçgensel bulanık sayılar	Önem derecesi
Eşit	$\tilde{1}$	(1,1,1)
Zayıf	$\tilde{3}$	(2/3,1,3/2)
Oldukça güçlü	$\tilde{5}$	(3/2,2,5/2)
Çok güçlü	$\tilde{7}$	(5/2,3,7/2)
Kesin	$\tilde{9}$	(7/2,4,9/2)

Bu değerlendirmeye göre fabrikanın sürdürülebilirlik kriterleri; Enerji Verimliliği, Atık Yönetimi, Su Kullanımı, İşçi Sağlığı ve Güvenliği, Toplumsal Katılım ve Sorumluluk, Tedarik Zinciri Yönetimi olarak belirlenmiştir. Bu kriterler belirlendikten sonra Adım 2' uygulanarak ikili karşılaştırma matrisi oluşturulmuştur (Çizelge 2).

Çizelge 2. Uzman görüşleri ve fabrika yönetimi ile belirlenen bulanık karşılaştırma matrisi

	Enerji verimliliği	Atık yönetimi	Su kullanımı	İşçi sağlığı ve güvenliği	Toplumsal katılım ve sorumluluğu	Tedarik zinciri yönetimi
Enerji verimliliği	1	5	3	3	4	2
Atık yönetimi	1/5	1	1/3	1/2	2	1
Su kullanımı	1/3	3	1	2	3	2
İşçi sağlığı ve güvenliği	1/3	2	1/2	1	2	1
Toplumsal katılım ve sorumluluk	1/4	1/2	1/3	1/2	1	1/2
Tedarik zinciri yönetimi	1/2	1	1/2	1	2	1

Bulanık sayılar ile elde edilen karşılaştırma matrisine 3. ve 4. Adım uygulanarak Çizelge 3'deki normalleştirilmiş matris elde edilmiştir.

Çizelge 3. Karşılaştırma matrisinin normalleştirilmesi

	Enerji verimliliği	Atık yönetimi	Su kullanımı	İşçi sağlığı ve güvenliği	Toplumsal katılım ve sorumluluğu	Tedarik zinciri yönetimi
Enerji verimliliği	0,50	0,29	0,33	0,27	0,30	0,28
Atık yönetimi	0,10	0,17	0,11	0,09	0,15	0,14
Su kullanımı	0,20	0,30	0,20	0,18	0,23	0,28
İşçi sağlığı ve güvenliği	0,20	0,23	0,11	0,09	0,15	0,14
Toplumsal katılım ve sorumluluk	0,12	0,11	0,09	0,07	0,07	0,59
Tedarik zinciri yönetimi	0,16	0,29	0,22	0,18	0,15	0,14

Daha sonra her bir kriterin ağırlığı Denklem 5 uygulanarak hesaplanmıştır. W_G hesaplanırken satırların minimum değerleri kullanılmıştır. Daha sonra W_G değerleri 0 ile 1 arasında normalleştirilerek Çizelge 4 elde edilmiştir.

$$W_G = (0,28, 0,09, 0,18, 0,27, 0,30, 0,59)$$

$$\text{Normalize } W_G = (0,27, 0,20, 0,17, 0,10, 0,08, 0,19)$$

Normalleştirilmiş matrisin elde edilmesinin ardından kriterlerin öncelik değerleri hesaplanmıştır.

Çizelge 4. Kriterlerin öncelik değerlerinin hesaplanması

Enerji Verimliliği	0,27
Atık Yönetimi	0,20
Su Kullanımı	0,17
İşçi Sağlığı ve Güvenliği	0,10
Toplumsal Katılım ve Sorumluluk	0,08
Tedarik Zinciri Yönetimi	0,19

Çizelge 4'deki ağırlıklar, her bir kriterin önem derecesini yansıtmaktadır. Bu ağırlıklar kullanılarak, fabrikanın sürdürülebilirlik kriterleri önceliklendirilmiştir. Buna göre;

- Enerji Verimliliği: 0.27
- Atık Yönetimi: 0.20
- Su Kullanımı: 0.17
- İşçi Sağlığı ve Güvenliği: 0.10
- Toplumsal Katılım ve Sorumluluk: 0.08
- Tedarik Zinciri Yönetimi: 0.19

olarak belirlenmiştir.

Bu ağırlıklar dikkate alınarak, fabrikanın sürdürülebilirlik performansını en çok etkileyen kriterin 0,27 puan ile "Enerji Verimliliği" olduğu görülmektedir. Ardından, sırasıyla 0,20 puan ile "Atık Yönetimi", 0,19 puan ile "Tedarik Zinciri Yönetimi", 0,17 puan ile "Su Kullanımı", 0,10 puan ile "İşçi Sağlığı ve Güvenliği" ve 0,08 puan ile de "Toplumsal Katılım ve Sorumluluk" kriterleri gelmektedir.

Bu önceliklendirme, fabrikanın sürdürülebilirlik çabalarında hangi alanlara öncelik verilmesi

gerektiği konusunda bir yol gösterici olarak kullanılabilir.

3. ARAŞTIRMA BULGULARI

Bu çalışmada, fabrikalarının sürdürülebilirlik performansını belirlemek için altı temel kriterin etkisi Fuzzy AHP yöntemi kullanılarak değerlendirilmiştir. Aynı zamanda belirlenen altı temel kriterin sürdürülebilirliğe olan etkisi değerlendirilmiş ve önceliklendirilmiştir. Çalışmada, sürdürülebilirliği etkileyen faktörlerin belirlenmesi için uzman görüşlerinden ve fabrika yönetiminden yararlanılmıştır. Ardından, Fuzzy AHP yöntemi kullanılarak faktörlerin önem sıraları belirlenmiş ve ağırlıkları hesaplanmıştır.

Enerji verimliliği, belirlenen altı kriter arasında en yüksek önceliğe sahip olarak belirlenmiştir. Bu sonuç, enerji verimliliğinin fabrikalardaki sürdürülebilirlik performansı üzerindeki önemini vurgulamaktadır. Fabrikaların enerji tüketimini azaltmak ve enerji verimliliğini artırmak için çeşitli stratejiler geliştirmesi kritik öneme sahiptir.

Atık yönetimi ve tedarik zinciri yönetimi, diğer önemli sürdürülebilirlik kriterleri olarak belirlenmiştir. Atık yönetimi, atıkların azaltılması, yeniden kullanımı ve geri dönüşümü gibi stratejileri içermektedir. Tedarik zinciri yönetimi ise, tedarikçi ilişkilerinin yönetimi, tedarik zinciri şeffaflığı ve sürdürülebilirlik kriterlerinin tedarikçilere yayılması gibi alanları kapsamaktadır.

Su kullanımı, işçi sağlığı ve güvenliği ve toplumsal katılım ve sorumluluk da önemli sürdürülebilirlik kriterleri olarak belirlenmiştir. Bu kriterler, su kaynaklarının korunması, işçi sağlığının ve güvenliğinin iyileştirilmesi ve toplumla etkileşimin artırılması gibi alanlarda fabrikaların çabalarını odaklaması gerektiğini göstermektedir.

Bu çalışmanın bulguları, benzer üretim tesisleri için sürdürülebilirlik stratejilerinin geliştirilmesine ve uygulanmasına değerli bir katkı sağlamaktadır. Enerji verimliliği, atık yönetimi ve tedarik zinciri yönetimi gibi öncelikli alanlara odaklanarak, fabrikalar çevresel etkilerini azaltabilir, kaynak

verimliliğini artırabilir ve sosyal sorumluluklarını yerine getirebilirler. Ayrıca, Fuzzy AHP yöntemi gibi analitik araçların, karmaşık sürdürülebilirlik problemlerinin çözümünde etkili bir şekilde kullanılabileceğini göstermektedir.

4. SONUÇ

Günümüzde, işletmelerin sürdürülebilirlik performansını değerlendirmesi ve iyileştirmesi giderek daha önemli hale gelmektedir. Sürdürülebilirlik, çevresel, ekonomik ve sosyal boyutlarıyla karmaşık bir kavram olup, bu boyutların etkileşimi, işletmelerin uzun vadeli başarısı üzerinde önemli bir etkiye sahiptir. Sürdürülebilirlik kavramının işletme ve endüstriyel süreçlerdeki önemini vurgulamak ve sürdürülebilirliğe etki eden faktörlerin belirlenmesi ve önceliklendirilmesi amacıyla Fuzzy AHP yöntemi kullanılmıştır. Fuzzy AHP yöntemi, işletmeler için sürdürülebilirlik performansını değerlendirmede kullanılan önemli bir analitik araçtır. Bu yöntem, geleneksel AHP'nin aksine belirsizlikleri daha iyi ele alabilir ve faktörler arasındaki ilişkileri daha gerçekçi bir şekilde modelleyebilir. Özellikle sürdürülebilirlik performansını etkileyen faktörlerin önceliklendirilmesi ve yönetilmesi konusunda Fuzzy AHP, karar vericilere değerli bir analitik çerçeve sunar.

Bu makalede, Fuzzy AHP yönteminin temel prensipleri tanıtarak bir fabrika üzerinde sürdürülebilirlik performansı, değerlendirme örneği üzerinde uygulanmıştır. Sonuç olarak sürdürülebilirlik performansını en çok etkileyen kriterin 0,27 puan ile "Enerji Verimliliği" olduğu görülmüştür.

Bu kapsamda bir fabrikanın enerji verimliliğini artırabilmesi için birkaç strateji ve uygulama sunulabilir;

Enerji Verimliliği Değerlendirmesi: Öncelikle, firmanın mevcut enerji kullanımını ve verimliliğini değerlendirmek için bir enerji denetimi yapılabilir. Bu denetim, enerji kullanımıyla ilgili mevcut verilerin analizini içerebilir ve hangi alanlarda iyileştirmeler yapılabileceğini belirleyebilir.

Enerji Tasarruflu Ekipmanlar: Enerji verimliliğini artırmak için enerji tasarruflu ekipmanlar kullanılabilir. Enerji Yönetim Sistemleri (EMS): EMS'ler, enerji kullanımını izlemek, kontrol etmek ve optimize etmek için kullanılır. Bu sistemler, enerji tüketimini zamanlamak, cihazları otomatik olarak kapatmak veya enerji kullanımını optimize etmek için akıllı algoritmalar kullanılabilir.

Çalışan Eğitimi ve Farkındalık: Çalışanları enerji tasarrufu konusunda eğitmek ve farkındalıklarını artırmak önemlidir. Yenilenebilir Enerji Kaynakları: Firma, kendi enerji ihtiyacının bir kısmını yenilenebilir enerji kaynaklarından karşılayabilir. Güneş enerjisi panelleri veya rüzgar türbinleri gibi yenilenebilir enerji sistemleri kurarak, enerji maliyetlerini azaltabilir ve çevresel etkilerini azaltabilir.

Enerji Verimliliği Politikaları ve Teşvikler: Fabrika, enerji verimliliğini teşvik etmek için politikalar ve teşvikler geliştirebilir.

Tüm çalışma sonucunda, Fuzzy AHP'nin sürdürülebilirlik performansının belirlenmesinde ve karar verme süreçlerinde etkili bir araç olduğu görülmüştür. Özetlenen adımlar ve yapılan örnek çalışma ile Fuzzy AHP'nin başarılı bir şekilde uygulandığı ve karar verme sürecinde etkin bir rol oynadığı söylenebilir.

5. KAYNAKLAR

1. Saaty, T.L., 1986. Axiomatic Foundation of the Analytic Hierarchy Process. *Management Science*, 32(7), 841-855.
2. Özgen, G., Saçlı, M., 2021. Fuzzy AHP and PROMETHEE Methods in Renewable Energy Source Selection: A Case Study in Turkey. *Renewable and Sustainable Energy Reviews*, 151, 111400.
3. Kahraman, C., Sener, B., 2022. A Novel Method for Wind Turbine Selection: Fuzzy AHP and Pythagorean Fuzzy Sets. *Renewable Energy*, 184, 1031-1043.
4. Kwak, J.H., Lee, H.K., 2023. A Novel Approach for Assessing Organizational Sustainability: Fuzzy AHP and Interval-Valued Intuitionistic

- Fuzzy TOPSIS. Expert Systems With Applications, 181, 115094.
5. Deng, Y., Wu, J., 2023. Fuzzy AHP-Based Decision-Making Model for Green Supply Chain Management: A Case Study of the Automotive Industry. *Journal of Cleaner Production*, 324, 129128.
 6. Chen, Y., Li, Y., 2022. A Novel Hybrid MCDM Model Combining Fuzzy AHP, ELECTRE, and TODIM Methods for Sustainable Supplier Selection. *Journal of Environmental Management*, 304, 114118.
 7. Kahraman, C., Cebi, F., 2009. Multi-Criteria Supplier Selection Using Fuzzy AHP. *Logistics Information Management*, 22(6), 475-484.
 8. Yazdani-Chamzini, A., Keramati, A., 2023. A Novel Fuzzy AHP-Based Approach for Prioritizing Investment in Renewable Energy Projects: A Case Study in Iran. *Renewable Energy*, 205, 377-387.
 9. Chen, C.T., 2022. Fuzzy Multiple Criteria Decision-Making Methods for Green Supplier Selection: A Literature Review and Future Research Agenda. *Journal of Cleaner Production*, 320, 128887.
 10. Wang, X., Kuo, Y.H., 2023. Fuzzy AHP-Based Approach for Assessing and Selecting Carbon Offset Projects in Aviation Industry: A Case Study in China. *Transportation Research Part D: Transport and Environment*, 102, 103215.
 11. Lee, L.W., Lin, C.Y., 2022. An Integrated Fuzzy AHP and DEMATEL Approach for Evaluating the Sustainable Development of Smart Cities: A Case Study of Taiwan. *Sustainable Cities and Society*, 84, 102638.
 12. Liu, C., Liu, S., 2020. Evaluating Sustainable Investment Decisions Using Fuzzy Analytic Hierarchy Process (Fuzzy AHP): Environmental, Social, and Corporate Governance Factors. *Journal of Sustainable Finance & Investment*, 10(1), 78-95.
 13. Özdemir, D., Akdoğan, A.A., 2021. Assessing Green Innovation Management Using Fuzzy Multi-Criteria Decision Making (Fuzzy MCDM): Integration of Sustainability Dimensions in Green Product Design, Green Supplier Selection, and Marketing Strategies. *Journal of Environmental Management*, 278, 111520.
 14. Atay, M., Kahraman, C., 2020. Evaluating Climate Change Risks Using Fuzzy Logic Models: Managing Uncertainties and Complexities in Shaping Business Strategies. *Business Strategy and the Environment*, 29(5), 2258-2272.
 15. Saaty, T.L., Zadeh, L.A., 2000. *Fuzzy Sets and Fuzzy Logic: The Foundations of Application - From a Mathematical Point of View*. Springer, 215.
 16. Chen, S.J., Hwang, C.L., 1992. *Fuzzy Multiple Attribute Decision Making Methods*. In *Fuzzy Multiple Attribute Decision Making: Methods and Applications* Berlin, Heidelberg: Springer Berlin Heidelberg, Nguyen, 289-486.
 17. Nguyen, H.T., Wu, B., 1999. *Fuzzy Sets and Fuzzy Decision-Making*. CRC Press, 259.
 18. Chang, D.-Y., 1996. Applications of the Extent Analysis Method on Fuzzy AHP. *European Journal of Operational Research*, 95(3), 649-655.
 19. Buckley, J.J., 1985. Fuzzy Hierarchical Analysis. *Fuzzy Set Syst*, 17(3), 233-247.

An ERP Based Industry 4.0 Maturity Model Proposal

Kerem ELİBAL*¹ ORCID 0000-0003-0328-9332

Eren ÖZCEYLAN² ORCID 0000-0002-5213-6335

Cihan ÇETİNKAYA³ ORCID 0000-0002-5899-8438

¹BCS Metal Co., Gaziantep, Türkiye

²Gaziantep University, Department of Industrial Engineering, Gaziantep, Türkiye

³Adana Science and Technology University, Department of Management Information Systems, Adana, Türkiye

Geliş tarihi: 09.06.2024

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: ELİBAL, K., ÖZCEYLAN, E., ÇETİNKAYA, C., (2024). An ERP Based Industry 4.0 Maturity Model Proposal. Cukurova University, Journal of the Faculty of Engineering, 39(2), 535-544.

Abstract

This study proposes an Enterprise Resource Planning (ERP) based Industry 4.0 maturity. The model aims to make the vast array of Industry 4.0 technologies comprehensible and actionable for Small and Medium Sized Enterprises (SMEs) by mapping them to specific ERP functions, thus enabling a more agile and tailored approach to digitalization. A comprehensive literature review revealed limited research on this integrated approach and highlighted the need for a model that supports quick assessments and adaptable implementation strategies. A sample application has been conducted in a manufacturing company and it has been seen that the model leverages ERP's modularity to address company-specific needs and includes rapid evaluation features that provides to the dynamic requirements of SMEs, enhancing their competitive edge in the digital landscape. Additionally, the findings serve as a valuable guide for ERP designers/vendors, providing insights into the integration of Industry 4.0 technologies that can enhance ERP system capabilities.

Keywords: Maturity model, Industry 4.0, Enterprise resource planning, ERP

ERP Tabanlı Endüstri 4.0 Olgunluk Modeli Önerisi

Öz

Bu çalışma Kurumsal Kaynak Planlaması (ERP) tabanlı bir Endüstri 4.0 olgunluk modeli önermektedir. Önerilen model, çok çeşitli Endüstri 4.0 teknolojilerini belirli ERP işlevleriyle eşleştirerek, bu teknolojileri Küçük ve Orta Ölçekli İşletmeler (KOBİ'ler) için anlaşılır ve uygulanabilir hale getirmeyi, böylece dijitalleşmeye daha çevik ve özel bir yaklaşım sağlamayı amaçlamaktadır. Yapılan kapsamlı literatür taraması ERP-Endüstri 4.0 entegrasyonu hakkında kısıtlı çalışmalar olduğunu göstermiş, hızlı ve çabuk adapte edilebilir bir değerlendirme modelinin gerekliliğini ortaya koymuştur. Geliştirilen model ile bir üretim şirketinde örnek bir uygulama yapılmış ve modelin, ERP'nin modülerliğinden yararlanarak şirkete özel ihtiyaçları karşıladığı ve KOBİ'lerin dinamik gereksinimlerini karşılayarak dijital ortamda rekabet güçlerini artıran hızlı değerlendirme özelliklerini içerdiği görülmüştür. Ek olarak bulgular, ERP

*Sorumlu yazar (Corresponding Author): Kerem ELİBAL, keremelibal@gmail.com

tasarımcıları/tedarikçileri için değerli bir rehber görevi görmekte ve ERP sistem yeteneklerini geliştirebilecek Endüstri 4.0 teknolojilerinin entegrasyonuna ilişkin bilgiler sağlamaktadır.

Anahtar Kelimeler: Olgunluk modeli, Endüstri 4.0, Kurumsal kaynak planlaması, ERP

1. INTRODUCTION

Assessing the current situation in the context of Industry 4.0 and taking action plans according to this assessment is a crucial concept for an effective digital transformation which can be made by maturity modelling concept. Not only the lack of consensus about Industry 4.0 concepts and definition [1-4], also the variety of proposed dimensions of Industry 4.0 maturity models [5] are causing confusion for the practitioners. Manufacturing organizations, especially Small and Medium Sized Companies (SMEDs) are facing difficulties in the selection and implementation of Industry 4.0 solutions [6]. Limitations in time, financial resources, and the availability of qualified practitioners are some of the constraints for SMEDs which they challenge during the digital transformation process [5].

A recent literature review which is conducted by Elibal and Özceylan [5] showed that in 57 academic publications 341 different dimensions have been proposed to assess the readiness of digitalization. This variety arises some questions such as; i) to which dimension should be focused, ii) what are the value-focused dimensions, iii) what kind of practices of Industry 4.0 leverage the digitalization of an organization in an agile way. Current maturity models may be insufficient for making fast evaluations and plans to answer these questions while agility is the most important factor for organizations; especially for SMEs because of their limited resources. To overcome this problem, an ERP based Industry 4.0 maturity model will be proposed in this study.

ERP applications are going to be assumed as the core functions of an organization and Industry 4.0 concepts are going to be described via mapping these ERP functions. Thus, it is expected that; (i) Industry 4.0 concepts will be come down to an understandable level for the assessment participants, (ii) an agile assessment and planning will be possible which is more applicable especially

for SMEs, (iii) modularity of ERP will provide the modularity of the model, (iv) company/case specific assessments may be possible.

A literature review which has been conducted at Scopus and IEEE Xplore databases with the search query mentioned in Table 1 (at 13-05-2024) showed that there are very limited studies about the reviewed concept and this result leveraged the motivation of this paper. Among 11 publications found, only the study of Basl and Novakova [7] proposed an ERP 4.0 maturity model.

Table 1. Search query for ERP based maturity model publications

(TITLE-ABS-KEY (erp) AND TITLE-ABS-KEY (maturity) AND (TITLE-ABS-KEY ("industry 4.0") OR TITLE-ABS-KEY ("manufacturing 4.0")) OR TITLE-ABS-KEY ("smart manufacturing") OR TITLE-ABS-KEY ("smart factory") OR TITLE-ABS-KEY ("factory 4.0") OR TITLE-ABS-KEY ("industrie 4.0") OR TITLE-ABS-KEY ("fourth industrial"))

Basl and Novakova [7] proposed four dimensions as mentioned below;

- The overall model of providing ERP services aiming at cloud
- Integrated technology trends 4.0 aiming at IoT, digital twin, blockchain, etc.
- Improved core functionality of ERP like planning and decision support
- Increasing levels of automation and robotization of business processes supported by ERP

While the study of Basl and Novakova [7] provides valuable insights into ERP-based Industry 4.0, it offers a foundational understanding of how modern ERP systems can integrate advanced Industry 4.0 technologies. Their work outlines essential trends and offers a preliminary framework for evaluating ERP 4.0 maturity. This approach is instrumental in

understanding the evolution of ERP systems in the context of Industry 4.0, highlighting the increasing importance of cloud computing, IoT, AI, and automation in modern enterprise systems. However, it remains a general framework. The model lacks specificity in its practical implications and does not provide detailed guidance on how to integrate specific technologies with various ERP functions. This limitation poses challenges for businesses, especially SMEs, in implementing effective digital transformation strategies.

This paper aims to build a comprehensive ERP-based Industry 4.0 maturity model designed to facilitate digital transformation in SMEs by integrating core ERP functions with advanced Industry 4.0 technologies. The model aims to make the vast array of Industry 4.0 technologies comprehensible and actionable for SMEs, enabling a more agile and tailored approach to digitalization. Some practical expected benefits from the proposed model can be summarized as below;

- The model's modularity allows for rapid evaluation and adaptable implementation strategies tailored to the specific needs of SMEs. This flexibility is crucial for SMEs, which often face constraints in time, financial resources, and availability of qualified practitioners. While organizations use ERP systems according to their needs, improving current modules of ERP in the context of Industry 4.0 provide a value-focused enhancement. Modularity of the model will enable SMEs to adopt and integrate Industry 4.0 technologies incrementally, reducing the complexity and cost associated with large-scale implementations. By breaking down the the model into manageable modules, SMEs can prioritize their most critical needs and implement solutions that provide the most immediate benefits. For example, a SME might start by integrating IoT capabilities into its inventory management module to gain real-time visibility into stock levels and reduce waste. Once this module is successfully implemented and provides benefits, the company can then focus on other modules, such as AI-driven

predictive maintenance or advanced data analytics for decision support. A Human Resources (HR) module may not be used in the organization so the digitalization in this area may be supposed to be not crucial. This step-by-step approach allows SMEs to spread out costs over time and reduce the risk of disruption to their operations. Moreover, modularity of the proposed model ensures that the ERP system can be easily customized to fit the unique processes and workflows of each SME. This customization is particularly valuable because it allows the ERP system to grow and evolve alongside the business, adapting to new challenges and opportunities without requiring a complete overhaul. As a result, SMEs can achieve a more scalable and sustainable digital transformation.

- The proposed model provide valuable insights for ERP designers and vendors, guiding the development of new ERP solutions that are better aligned with the evolving needs of modern businesses. This can lead to the creation of ERP systems that fully leverage Industry 4.0 technologies, offering enhanced functionality and competitive advantages.

In order to propose an ERP based Industry 4.0 maturity model that mainly aims to provide expected benefits mentioned above, in section 2 the literature review about ERP and Industry 4.0 will be investigated. In section 3, a draft of proposed model will be presented. A sample application will be presented in section 4, and finally conclusions and future research suggestions will be done.

2. LITERATURE REVIEW

As the aim of this paper is to propose an ERP based Industry 4.0 maturity model, to understand the relationship between these concepts, a literature review has been conducted at Scopus Database (13-05-2024) with the search query mentioned in Table 2. Among 307 publications found, 34 of them are investigated in order to identify which Industry 4.0 technologies are used in ERP systems. Highlighted technologies are summarized in Table 3.

Table 2. Search query for ERP-Industry 4.0 related publications

(TITLE-ABS-KEY (erp) AND TITLE-ABS-KEY ("industry 4.0") OR TITLE-ABS-KEY ("manufacturing 4.0") OR TITLE-ABS-KEY ("smart manufacturing") OR TITLE-ABS-KEY ("smart factory") OR TITLE-ABS-KEY ("factory 4.0") OR TITLE-ABS-KEY ("industrie 4.0") OR TITLE-ABS-KEY ("fourth industrial") OR TITLE-ABS-KEY ("4th industrial")) AND (LIMIT-TO (LANGUAGE , "English"))
--

Table 3. Highlighted Industry 4.0 technologies in ERP

Publications	Industry 4.0 technologies in ERP
[8]	Information integration
[9]	Connection of machines, real time monitoring, planning decisions
[10]	Tablet computers and mobile phones, big data analytics, virtual application, integration with social networks
[11]	Cloud computing, IoT
[12]	Autonomous robot integration
[13]	RFID
[14]	Mobile devices, cloud computing, big data, IoT, digital production and additive manufacturing, AI, ML, virtual assistance
[15]	CPS, IoT, actuators, sensors, big data
[16]	RFID
[17]	Mobility, integration, smart devices, big data, data analytics, cloud
[18]	Cognitive technologies, big data, IoT, cloud computing, VR and AR, corporate portal, wireless mobil solutions, electronic data interchange (EDI)
[19]	Cloud ERP
[20]	Big data, cloud computing, AI, IoT
[21]	IoT
[22]	IoT, sensors, CPS, big data, cloud computing
[23]	Cloud ERP
[24]	RFID
[25]	Blockchain
[26]	Sensor, real time process monitoring
[27]	Big data, system integration, cloud, and automatic identification and data capture.

[28]	IoT
[29]	Real time data
[30]	IoT
[31]	Cloud Database
[32]	Augmented reality
[33]	IoT, RFID, real time analyses, social media analyses
[34]	Cloud Database
[35]	IoT, real time data, ML, AI
[36]	Cloud computing, IoT
[37]	IoT, big data, mobil devices, cloud computing
[38]	Big data, cloud technologies
[39]	Automated warehouse
[40]	Machine interconnection
[41]	Digital twin

Table 3 provides an overview of various publications related to the application of Industry 4.0 technologies within Enterprise Resource Planning (ERP) systems, spanning from 2012 to 2024. The listed technologies include Cloud Computing, IoT (Internet of Things), Big Data, AI (Artificial Intelligence), and RFID (Radio Frequency Identification), among others. These technologies are integrated into ERP systems to enhance capabilities such as real-time data processing, mobile computing, and sensor-based monitoring, aiming to improve automation, connectivity, and decision-making processes in business environments. Each publication focuses on different aspects of these integrations, highlighting advancements in ERP functionality through the adoption of Industry 4.0 technologies. Via the gained insights from Table 3, a draft model will be proposed in section 3.

3. ERP BASED INDUSTRY 4.0 MATURITY MODEL

In this section ERP based Industry 4.0 model will be presented. The proposed model includes 13 sub-dimensions under six main dimensions which are also the common modules of an ERP system; planning and manufacturing, customer relationship management, warehouse management, procurement, human resources, finance and accounting [42-44], as in illustrated in Figure 1.



Figure 1. Dimensions of the proposed model

For each dimension Level 1 and Level 5 statements had been defined. As in shown in Table 4, participants will be asked to select a level between 1 and 5 according to the statements. It is possible that some of the ERP modules may not be used in the organization or the mentioned concept may not be relevant, so the “not relevant” options may be selected in this situation.

Table 4. Level definitions of the proposed model

ERP Module	Dimension	Level-1	Level-5
Planning and Manufacturing	M2M communication	No M2M communication	Highly integrated M2M communication
	Data collection and monitoring	Manual input into ERP	Real time data collection and monitoring via IoT, sensors, data capture, etc.
	Scheduling	Manuel scheduling via data in ERP	AI based scheduling with real time data
Customer relationship management	Customer communication	Manual analytics via ERP	Highly integrated customer portal, social media listening, etc.
	Demand analysis	Manual analysis via data in ERP	AI based demand prediction
Warehouse management	Communicable raw materials, semi-parts	No communication	Highly integrated communication via IoT, RFID, etc.
	Warehouse stock monitoring	Manual monitoring in ERP	Real time monitoring via sensors, data capture, etc.
Procurement	Supplier communication	Manual data in ERP	Highly integrated supplier portal, social media listening, etc.
	Supplier analytics	Manual analytics via ERP	AI based supplier analytics via real time data, social media listening, etc.
Human Resources	Performance analytics	Manual analytics via ERP	AI based performance analytics via real time data, data capture, etc.
	Employee education	Manual analytics via ERP	AI based education predictions, electronic and online education environmnet with AR, VR
Finance and Accounting	Customer-supplier accounting	Manual analytics via ERP	AI based tracing and risk analyses
	Cost-budget tracing	Manual analytics via ERP	AI based cost and budget analyses with real time data, predictive insights

Table 4 outlines a comprehensive overview of different ERP modules, highlighting the transition from basic (Level-1) to advanced (Level-5) levels of integration and functionality. Each dimension within these modules is described with its Level-1 and Level-5 states, providing a clear picture of how operations can evolve with technological advancements.

In the Planning and Manufacturing dimension, M2M communication at Level-1 involves no interaction between machines, while at Level-5, machines are highly integrated, sharing data in real-time to optimize production. Data collection and monitoring evolve from manual input into ERP systems to real-time data gathering using IoT, sensors, and data capture technologies. Scheduling progresses from manual, ERP-based methods to AI-driven, real-time scheduling, enhancing efficiency and responsiveness.

The Customer Relationship Management (CRM) dimension shows a shift from manual customer communication and data analysis within ERP systems at Level-1 to highly integrated customer portals and social media listening tools at Level-5. This integration allows for better customer engagement and more accurate demand analysis through AI-based predictions.

In Warehouse Management, communicable raw materials and semi-parts move from no communication at Level-1 to real-time tracking and integration via IoT and RFID technologies at Level-5. Warehouse stock monitoring advances from manual checks to real-time monitoring using sensors and automated data capture, ensuring more accurate and efficient inventory management.

The Procurement dimension highlights improvements in supplier communication and analytics. At Level-1, supplier interactions and analytics are manually handled within ERP systems, whereas at Level-5, these processes are enhanced through highly integrated supplier portals and AI-based analytics, utilizing real-time data and social media listening for better decision-making.

Human Resources demonstrates a transition from manual performance analytics and employee education tracking to AI-based systems that provide real-time data and predictive insights. At Level-5, performance analytics leverage real-time data capture, while employee education benefits from AI-driven predictions and advanced training environments utilizing AR and VR technologies. Finally, the Finance and Accounting dimension shows how customer-supplier accounting and cost-budget tracing evolve from manual analytics in ERP systems to AI-based tracing, risk analyses, and real-time budget assessments. This shift enables more accurate financial management and predictive insights, ultimately improving overall financial health and decision-making processes.

4. APPLICATION

The proposed draft model has been applied to an automotive sub-contractor, BCS Metal Co., which is located in Gaziantep/Türkiye. The company mainly produces bus, midi-bus, truck and trailer chassis and has an ERP system with the modules of production and planning, customer and supplier management, warehouse management, human resources and finance-accounting. The model has been presented to the executive of the company and the level assignments from 1-5 has been done for each sub-dimension as in shown in Table 5.

Table 5. Level assignments of the company

ERP Module	Dimension	Level	Not Relevant
Planning and Manufacturing	M2M	1	
	Data collection	3	
	Scheduling	2	
Customer relationship	Customer	3	
	Demand analysis	1	
Warehouse management	Communicable		-
	Warehouse stock	2	
Procurement	Supplier	1	
	Supplier analytics	1	
Human Resources	Performance	2	
	Employee	1	
Finance and Accounting	Customer-	2	
	Cost-budget	3	

The company declared that “communicable raw materials, semi-parts” dimension is not relevant with their needs and business, so the radar chart of the model has been constructed with 12 dimensions as shown in Figure 2.




Figure 1. Maturity radar chart

The results obtained by applying the model to BCS Metal Co. can be used as a basic guide to create the company's digital transformation roadmap. The maturity levels determined for each ERP module clearly reveal the company's current status and development needs. These results can determine which areas the company needs to make improvements, enabling more effective use of resources. Targets should be set, especially for dimensions at low levels, and improvements in these areas should be prioritized. In addition, the flexibility and modular structure provided by the model allows the company to manage the digital transformation process step by step and in accordance with the specific needs of the company. In this way, the steps to be taken towards digitalization become clear and strategic plans can be created to increase the competitiveness of the company.

5. CONCLUSION

In this paper, an ERP based Industry 4.0 model has been proposed and a sample application has been conducted. Motivation of the study is developing a maturity model that provides a structured framework for assessing and advancing digital transformation in SMEs by integrating core ERP functions with Industry 4.0 technologies. This approach not only makes Industry 4.0 concepts

more accessible and actionable for SMEs but also supports agile and tailored digitalization strategies that address specific organizational needs and constraints. Organizations may use the model according to the modules of applied own ERP system. Not only for organizations, the model also may be used as a guide for ERP designer and/or vendor to adapt the system according to the Industry 4.0 technologies.

Sample application showed us an organization can assess the own situation of the digitalization according to the ERP modules used. The model appears to have the potential to clearly determine the steps companies will take towards digitalization according to their needs.

Rapid technological developments and the increasing needs of organizations increase the diversity of both ERP modules and Industry 4.0 technologies day by day. This study should be considered as an initial study, and the development of the dimensions (according to ERP modules) and maturity statements (according to Industry 4.0 technologies) of this model with different research methods (such as Delphi Technique) should be considered as a future study. A sectoral separation has also been identified as an important future study.

In addition, the implementation of the developed model in manufacturing companies and evaluation of its effectiveness should be considered as an important future study.

6. REFERENCES

1. Cordeiro, R.F., Reis, L.P., Fernandes, J.M., 2024. A Study on the Barriers that Impact the Adoption of Industry 4.0 in the Context of Brazilian Companies. *The TQM Journal*, 36(1), 361-384.
2. Figliè, R., Amadio, R., Tyrovolas, M., Stylios, C., Paško, Ł., Stadnicka, D., Mazzei, D., 2024. Towards a Taxonomy of Industrial Challenges and Enabling Technologies in Industry 4.0. *IEEE Access*, 12, 19355-19374.
3. Folgado, F.J., Calderón, D., González, I., Calderón, A.J., 2024. Review of Industry 4.0

- from the Perspective of Automation and Supervision Systems: Definitions, Architectures and Recent Trends. *Electronics*, 13(4), 782.
4. Vargas, G.B., Gomes, J.D.O., Vargas Vallejos, R., 2024. A Framework for the Prioritization of Industry 4.0 and Lean Manufacturing Technologies Based on Network Theory. *Journal of Manufacturing Technology Management*, 35(1), 95-118.
 5. Elibal, K., Özceylan, E., 2024. An Industry 4.0 Maturity Model Proposal Based on Total Quality Management Principles: An Application to an Automotive Parts Manufacturer. *IEEE Transactions on Engineering Management*, 71, 10815-10832.
 6. Müller, J.M., Islam, N., Kazantsev, N., Romanello, R., Olivera, G., Das, D., Hamzeh, R., 2024. Barriers and Enablers for Industry 4.0 in SMEs: A Combined Integration Framework. *IEEE Transactions on Engineering Management*.
 7. Basl, J., Novakova, M., 2019. Analysis of Selected ERP 4.0 Features and Proposal of an ERP 4.0 Maturity Model. *Research and Practical Issues of Enterprise Information Systems: 13th IFIP WG 8.9 International Conference, CONFENIS 2019, Prague, Czech Republic*, 13, 3-11.
 8. Rashid, M.A., Riaz, Z., Turan, E., Haskilic, V., Sunje, A., Khan, N., 2012. Smart Factory: E-Business Perspective of Enhanced ERP in Aircraft Manufacturing Industry. *Proceedings of PICMET'12: Technology Management for Emerging Technologies*, 3262-3275.
 9. Haddara, M., Elragal, A., 2015. The Readiness of ERP Systems for the Factory of the Future. *Procedia Computer Science*, 64, 721-728.
 10. Stojkić, Ž., Veža, I., Bošnjak, I., 2016. A Concept of Information System Implementation (CRM and ERP) within Industry 4.0. *Proceedings of the 26th DAAAM International Symposium*, 912-919.
 11. Trusculescu, A., Draghici, A., Albulescu, C.T., 2015. Key Metrics and Key Drivers in the Valuation of Public Enterprise Resource Planning Companies. *Procedia Computer Science*, 64, 917-923.
 12. Christmann, D., Schmidt, A., Giehl, C., Reichardt, M., Ohmer, M., Berg, M., Herfet, T., 2016. Vertical Integration and Adaptive Services in Networked Production Environments. *Innovations in Enterprise Information Systems Management and Engineering: 4th International Conference*.
 13. Majeed, A.A., Rupasinghe, T.D., 2017. Internet of Things (IoT) Embedded Future Supply Chains for Industry 4.0: An Assessment from an ERP-based Fashion Apparel and Footwear Industry. *International Journal of Supply Chain Management*, 6(1), 25-40.
 14. Basl, J., 2018. Penetration of Industry 4.0 Principles into ERP Vendors' Products and Services—A Central European Study. *Research and Practical Issues of Enterprise Information Systems: 11th IFIP WG 8.9 Working Conference, Shanghai, China*.
 15. Sishi, M., Telukdarie, A., 2020. Implementation of Industry 4.0 Technologies in the Mining Industry-A Case Study. *International Journal of Mining and Mineral Engineering*, 11(1), 1-22.
 16. Mladineo, M., Veza, I., Gjeldum, N., Crnjac, M., Aljinovic, A., Basic, A., 2019. Integration and Testing of the RFID-enabled Smart Factory Concept within the Learning Factory. *Procedia Manufacturing*, 31, 384-389.
 17. Telukdarie, A., Sishi, M.N., 2018. Enterprise Definition for Industry 4.0. *IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, 849-853.
 18. Bytniewski, A., Matouk, K., Rot, A., Hernes, M., Kozina, A., 2020. Towards Industry 4.0: Functional and Technological Basis for ERP 4.0 Systems. *Towards Industry 4.0. Current Challenges in Information Systems*, 3-19.
 19. Gupta, S., Meissonier, R., Drave, V.A., Roubaud, D., 2020. Examining the Impact of Cloud ERP on Sustainable Performance: A Dynamic Capability View. *International Journal of Information Management*, 51, 102028.
 20. Majstorovic, V., Stojadinovic, S., Lalic, B., Marjanovic, U., 2020. ERP in Industry 4.0 Context. *IFIP International Conference on Advances in Production Management Systems*, 287-294.
 21. Nugroho, A., Rizaludin, D., Soebandhi, S., Junaedi, L., Winardi, S., Al-Azam, M.N., 2020. Automatic Sign of Commencement of Work from Enterprise Resource Planning.

- International Conference on Smart Technology and Applications (ICoSTA), 1-6.
22. Tsai, W.H., Lan, S.H., Lee, H.L., 2020. Applying ERP and MES to Implement the IFRS 8 Operating Segments: A Steel Group's Activity-Based Standard Costing Production Decision Model. *Sustainability*, 12(10), 4303.
 23. Wang, S., Guo, M., Hu, Y.X., Chiu, Y.K., Jing, C., 2022. Smart Manufacturing Business Management System for Network Industry Spin-off Enterprises. *Enterprise Information Systems*, 16(2), 285-306.
 24. Zeba, G., Čičak, M., 2020. Application of RFID Technology for Better Efficiency of Resource Planning. *New Technologies, Development and Application III* 6, 382-387.
 25. Dasaklis, T.K., Voutsinas, T.G., Mihiotis, A., 2021. Integrating Blockchain with Enterprise Resource Planning systems: Benefits and Challenges. *Proceedings of the 25th Pan-Hellenic Conference on Informatics*, 265-270.
 26. Ferrari, A.M., Volpi, L., Settembre-Blundo, D., García-Muiña, F.E., 2021. Dynamic Life Cycle Assessment (LCA) Integrating Life Cycle Inventory (LCI) and Enterprise Resource Planning (ERP) in an Industry 4.0 Environment. *Journal of Cleaner Production*, 286, 125314.
 27. Polivka, M., Dvořáková, L., 2021. The Current State of the Use of Selected Industry 4.0 Technologies in Manufacturing Companies. *Proceedings of the 32nd DAAAM International Symposium*, 0652-0659.
 28. Mantravadi, S., Möller, C., Chen, L.I., Schnyder, R., 2022. Design Choices for Next-Generation IIoT-connected MES/MOM: An Empirical Study on Smart Factories. *Robotics and Computer-Integrated Manufacturing*, 73, 102225.
 29. Parra, B., Pando Cerra, P., Álvarez Peñín, P.I., 2022. Combining ERP, Lean Philosophy and ICT: An Industry 4.0 Approach in an SME in the Manufacturing Sector in Spain. *Engineering Management Journal*, 34(4), 655-670.
 30. Paththinige, P., Thilakarathne, K., Rathnasekara, T., Wickramaarachchi, R., Withanaarachchi, A., 2022. Examine the Impact of IoT for Supply Chain-Based Operations in ERP Systems: Systematic Literature Review. *International Research Conference on Smart Computing and Systems Engineering (SCSE)* 5, 344-350.
 31. Prakash, V., Savaglio, C., Garg, L., Bawa, S., Spezzano, G., 2022. Cloud and Edge-Based ERP Systems for Industrial Internet of Things and Smart Factory. *Procedia Computer Science*, 200, 537-545.
 32. Bakale, T., Picek, R., 2023. Application of Augmented Reality in Creating Added Value for an ERP System. *4th International Conference on Communications, Information, Electronic and Energy Systems (CIEES)*, 1-5.
 33. Giuliano, F., Rombo, S.E., Bonomo, M., Iiritano, S., Granata, L., Ruffolo, M., Tinnirello, I., 2023. Amarelli's Industry 4.0 Transformation with IoT and Digital Advertisement: Optimizing Operations and Engaging Customers. *EDBT/ICDT Workshops*.
 34. Kopishynska, O., Utkin, Y., Makhmudov, K., Kalashnik, O., Moroz, S., Somych, M., 2023. Digital Transformation of Resource Management of Territorial Communities Based on the Cloud ERP System in the Concept of Industry 4.0. *Journal of Systemics. Cybernetics and Informatics*, 21(2), 21-29.
 35. Kopishynska, O., Utkin, Y., Sliusar, I., Muravlov, V., Makhmudov, K., Chip, L., 2023. Application of Modern Enterprise Resource Planning Systems for Agri-Food Supply Chains as a Strategy for Reaching the Level of Industry 4.0 for Non-Manufacturing Organizations. *Engineering Proceedings*, 40(1), 15.
 36. Majstorovic, V., Simeunovic, V., Mitrovic, R., Stosic, D., Dimitrijevic, S., Miskovic, Z., 2023. Development of Cloud ERP Model and Its Application in Smart Mining. *International Conference on Intelligent Systems in Production Engineering and Maintenance*, 28-42.
 37. Morawiec, P., Sołtysik-Piorunkiewicz, A., 2023. ERP System Development for Business Agility in Industry 4.0 - A Literature Review Based on the TOE Framework. *Sustainability*, 15(5), 4646.
 38. Polivka, M., Dvořáková, L., 2023. The Importance of Industry 4.0 Technologies when Selecting an ERP System—An Empirical Study. *Business Administration and Management*, 26(3), 51-69.

39. Tong, Q., Ming, X., Zhang, X., 2023. Construction of Sustainable Digital Factory for Automated Warehouse Based on Integration of ERP and WMS. *Sustainability*, 15(2), 1022.
40. Borda, F., Cosma, A.M., Filice, L., 2024. Enabling Industry 4.0 Transformation in Calabria Region: Framework, Machine Interconnection and ERP Synergy. *Procedia Computer Science*, 232, 1151-1163.
41. Durão, L.F.C., Zancul, E., Schützer, K., 2024. Digital Twin Data Architecture for Product-Service Systems. *Procedia CIRP*, 121, 79-84.
42. Garg, P., Khurana, R., 2017. Applying Structural Equation Model to Study the Critical Risks in ERP Implementation in Indian Retail. *Benchmarking: An International Journal*, 24(1), 143-162.
43. Raja, S. L. N., Joseph, N., Totawar, A., 2020. Analysing ERP Implementations from Organizational Change Perspective: An Exploratory Study. *International Working Conference on Transfer and Diffusion of IT*, 674-678.
44. Rajapakse, D.P.P.K., Thushara, S.C., 2023. Critical Failure Factors in ERP Implementation: A Systematic Literature Review. *Journal of Business and Technology*, 7(1).

A Numerical Modelling of V-Bending

Ergin KOSA*¹ ORCID 0000-0002-4607-4115

¹Beykent University, Faculty of Engineering and Architecture, Mechanical Engineering
Department, Istanbul, Türkiye

Geliş tarihi: 25.09.2023

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: KOSA, E., (2024). A Numerical Modelling of V-Bending. Cukurova University, Journal of the Faculty of Engineering, 39(2), 545-554.

Abstract

In the study, a sheet metal is bent to analyze the punch force, Von Misses stresses and plastic strains on the metal for friction and non-friction cases. The 2-D v-bending forming is modelled in program. Model includes a die, a punch and a blank. Solid mechanics physics interface has been used in program. The analyze has been run with friction and non-friction cases for different strain-hardening exponents and sheet metal thicknesses. The sheet lengths and widths are 60 mm. Thickness of sheet metal is varied between 1.0 to 3.0 mm. The strain hardening exponent has been altered from 0.1 to 0.5. It is computed that the punch force has been increased as thickness of sheet metal and strain hardening exponent decreases. The achieved maximum punch force is at values of 1.12×10^5 N, 3.75×10^5 N and 4.05×10^5 N for thickness of 1.0-mm, 2.0-mm and 3.0-mm respectively when strain hardening exponent is 0.3. Also, as the strain hardening exponent increases from 0.1 to 0.5, the maximum punch force lowers from 2.03×10^5 N to 8.08×10^4 N for 1 mm thickness at friction case. Moreover, the maximum punch force reached up to 9.13×10^4 N for 1 mm thick sheet metal at non-friction case when the strain hardening exponent is 0.1. It is concluded that the maximum Von Misses stress has been calculated at the tip of sheet metal.

Keywords: Numerical, Sheet metal, Punch, Thickness, V-bending, Strain hardening exponent

V- Bükmenin Sayısal Modellenmesi

Öz

Çalışmada, sürtünmeli ve sürtünmesiz durumlar için zımba kuvvetini, Von Misses gerilmelerini ve metal üzerindeki plastik gerinimleri analiz etmek için bir metal levha bükülmüştür. 2 boyutlu v-bükme şekillendirme programda modellenmiştir. Model bir kalıp, bir zımba ve bir sac levhadan oluşmaktadır. Programda katı mekanik fiziği arayüzü kullanılmıştır. Analiz; farklı pekleşme üsteli ve sac kalınlıkları için sürtünmeli ve sürtünmesiz ortam koşullarında yürütülmüştür. Sac uzunlukları ve genişlikleri 60 mm'dir. Sac kalınlıkları 1,0 ila 3,0 mm arasında değişmektedir. Pekleşme üsteli 0,1'den 0,5'e kadar değiştirilmiştir. Sac kalınlığı ve pekleşme üsteli azaldıkça zımba kuvvetinin arttığı hesaplanmıştır. Elde edilen maksimum zımba kuvveti, pekleşme üsteli 0.3 olduğunda 1,0 mm, 2,0 mm ve 3,0 mm kalınlık için sırasıyla 1.12×10^5 N, 3.75×10^5 N and 4.05×10^5 N değerlerindedir. Ayrıca sürtünmeli durumda 1 mm kalınlık için pekleşme üsteli 0,1'den 0,5'e arttıkça maksimum zımba kuvveti 1.49×10^5 N to 8.08×10^4 N'ye düşer. Dahası, pekleşme üsteli 0.1 iken maksimum zımba kuvveti sürtünmesiz durumda 1 mm kalınlığındaki sac için 9.13×10^4 N değerine ulaşmıştır. Maksimum Von Misses gerilmesinin sacın ucunda hesaplandığı sonucuna varılmıştır.

Anahtar Kelimeler: Sayısal, Sac metal, Zımba, Kalınlık, V-bükme, Pekleşme üsteli

*Sorumlu yazar (Corresponding Author): Ergin KOSA, erginkosa@beykent.edu.tr

1. INTRODUCTION

Bending is performed in terms of different forming processes such as v-bending [1,2], air bending [3], flanging [4], u-bending [5], rotary draw bending [6], three-point bending [7], hemming [8,9] and seaming [10]. V-bending process is dominantly used in manufacturing of automobile industry [11]. Some of the researches are focused on spring-back problem [12,13], bend radius [14], bend angle [15,16] and strain hardening [17].

Researchers studied on bending experimentally and numerically [12,18,19]. Cao et. al. [20] changed temperature and speed of bending during forming of stainless steel. It was found that as temperature increased from 600°C to 850°C, springback angle was reduced continuously. Bending speed has an influence on springback angle so that spring back angle is decreasingly increased as the bending speed increased from 0 mms^{-1} to 5 mms^{-1} . Dhillip et. al. [21] realized finite element analysis of 3-D model of sheet metals in ANSYS program. The maximum principal stress and elastic strain was computed for annealed 1020 carbon steel, aluminum and stainless steel. Thipprakmas and Sontamino [15] used bent hole parts to observe effect of hole and hole position on the springback character of material experimentally. It was observed that bent hole parts show higher springback character when comparing to bent non-holed parts. Özdemir [22] investigated the bending behavior of continuous glass fiber-reinforced composite sheets. Dwell time, pressure, bending angle and die radii were the studied parameters in Özdemir's work.

As a result of the work, it was found that the most suitable option to reduce springback problem is at 90° bending angle and 120 s dwell time under 3 MPa pressure for a die radius of 6 mm. Li et. al. [23] bent titanium tubes to focus on effect of forming temperature and bending angle on springback numerically and experimentally.

It was concluded that increase in forming temperature lowers the springback and unlike springback increases with bending angle. Pritima et al. [24] analyzed the bending of AISI 1040 sheet metal. Effect of width of sheet, velocity, holding time are some of the parameters studied in the work.

It was evident that decrease in holding time, increase in width and rise in punch speed increase the springback. Krinninger et. al. [25] used stainless steel and microalloyed steel to investigate the influence of bending angle, punch velocity and bending radius on springback angle. It was concluded that as the punch velocity increases from 10 mm/s to 300 mm/s, it lowers the springback angle and as the bending angle or bending radius increases, the springback angle increases. Nakajima et. al. [26] focused on the bending of square tubes and used mandrel to get an accurate square cross section of aluminum tubes as workpiece after press bend and utilized restraint plate to decrease the deviation of thickness of square tubes. Gupta and Payal [27] bent the electrogalvanized steel to search the effect of die width and galvanized thickness. The findings showed that spring back increases with the increase of coating thickness and spring back for rolling of direction 90° orientation is more than rolling direction 0° orientation. Hotaka et. al. [28] used repeated bending to develop formability of twin roll cast Mg-Al-Zn-Sn alloy. Two methods such as repeated bending by differential speed rolling and repeated bending by using three rolls were applied. After bending processes, the solution heat treatment of the pre-strained material was performed. Thus, the microstructure of specimens was changed. Then, the specimens were bent by V-bending. It was concluded that repeated bending by using three rolls was effective to develop formability of specimens and achieved springback angles of specimens were lower after V-bending. Örnekeçi and Ekşi [29] investigated springback properties of 6061 aluminum in V-bending for different die angles and widths. It was found that springback decreased as the die width increased and as die angle increased, springback also increased. Also, the ANOVA results showed that die width was more important than die angle in terms of springback.

Sofia et. al. used [30] USS CR980XG3TM steel to analyze and clarify the dependence of springback on the tool's geometry and the V-bending tools with different bending angles of 60° and 90° and punch radii of 5° and 10° were selected. It was concluded that as the punch radius increased or die angle decreased, the mean springback increased.

In the work, the model of a sheet metal has been analyzed numerically in a multiphysics program. The punch force and displacement have been examined for different strain hardening exponents and thicknesses of sheet metal at friction and non-friction conditions. The work provides to determine the effect of parameters on punch force in fields of metal bending.

2. METHODS

2.1. V-Bending Model

V-bending is preferred to be analyzed in the work. Because v-bending is commonly utilized in low manufacturing processes. V-die angles varying from obtuse to acute are able to be manufactured. The v-dies are cheap and basic compared to other bending operation equipment [31].

Model of the bending is shown in figure 1. V-Bending forming consists of a punch, a die and a sheet metal as illustrated in figure 1. Because of the symmetric process, just one half of the geometry is used. The length and the width of the sheet metal is 60 mm and die angle is 90°. The model was run at friction and non-friction mediums.

The parameters such as strain hardening exponent and sheet metal thickness affecting the punch force have been studied on the work for different cases. For friction case, Coulomb friction coefficient was defined between punch with sheet metal and die with sheet metal as 0.2. The sheet material is selected as an aluminum alloy due to the fact that it has an advantage of lightweight because of comparatively low density and demonstrates relatively high ductility [32]. The material parameters of the blank material and the parameters that are changed for the representative blank material is given in table 1.

The material of punch and die are structural steel. The material properties have also an influence in forming is given in table 2. Strain hardening is one of the most vital effects on material to become it stronger. Hardening functions are given as;

Hollomon hardening function [33]:

$$\sigma = K\epsilon^n \quad (1)$$

Ludwing equation [34]:

$$\sigma = \sigma_y + K\epsilon^n \quad (2)$$

n is strain-hardening exponent, it gets the value of 0 for perfectly plastic solids and the value of 1.0 for perfectly elastic materials. The elasto-plastic material model is built for the work of v-bending process. K is Hollomon hardening parameter in units of $N.mm^{-2}$. ϵ is strain in units of mm/mm .

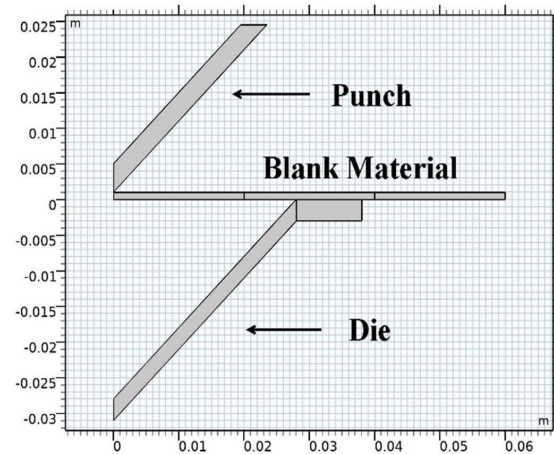


Figure 1. V-bending model

Punch and die are defined as rigid bodies. Thus, duration of simulation can be reduced when the bending metal is modelled as deformable with homogeneous solid element. The punch is adjusted as full contact with top surface of the blank. The displacement of the punch is determined as equal to the depth of die. The displacement behavior of punch is given in figure 2. Figure 2 describes how the punch movement has been changed according to time. Maximum punch displacement is 28 mm. In the mesh, the maximum element size was 0.00402, the minimum element size was 0.00003, the maximum element growth rate was 1.3, the curvature factor was 0.3 and the resolution of narrow regions was 1.




Figure 2. Displacement of punch

2.2. Numerical Modelling of Bend Forming

Method of finite element analysis is an active and an adequate choice to assist the design and analyze the bend forming.

The 2-D model contains several nonlinearities such as boundary nonlinearity (contact), material nonlinearity (elastoplastic material) and geometric nonlinearity. It is assumed that plain strain is occurred because out of plain thickness is wide. Due to the fact that the thickness of the plate is small when comparing the tool, moderate strains are occurred in spite of large displacements and rotations. The augmented Lagrangian contact technique is adopted. Solid mechanics physics interface was defined and user-controlled mesh was applied. MUMPS solver was used for the stationary solver.

Table 1. Material properties of representative blank material

Term	Representative blank material
Hollomon hardening parameter, K	550.4 MPa
Strain hardening exponent, n	0.1-0.3-0.5
Initial yield stress, σ_0	150 MPa
Young's modulus, E	70.5 GPa
Density, ρ	2700 kgm ⁻³
Thickness	1.0mm-2.0mm-3.0mm
Width	60 mm
Length	60 mm
Poisson ratio, ν	0.342

Table 2. Material properties of structural steel die and punch

Term	Steel die and punch material
Young's modulus, E	200 GPa
Density, ρ	7850 kgm ⁻³
Poisson ratio, ν	0.30

3. RESULTS AND DISCUSSIONS

3.1. Effect of Sheet Thickness in Friction Case

The effect of thickness on punch force was investigated due to being one of the parameters determining the machine capacity. So, the thickness of plate was changed. The 1.0-mm, 2.0-mm and 3.0-mm thick plates were bent under friction case. The friction coefficient was defined as 0.2. Figure 3 emphasizes variation of the punch force according to punch action in the case strain hardening exponent of 0.3 for different sheet metal thickness at friction case. The punch force is reached up to 1.12×10^5 N, 2.38×10^5 N and 4.05×10^5 N for thickness of 1.0-mm, 2.0-mm and 3.0-mm respectively as illustrated in figure 3. The amount of maximum stress and the region of maximum stress on the sheet metal in friction case for the thickness of 2.0 mm are shown in figure 4. Von Mises stress distribution on blank material, punch and die are depicted in figure 4. Equivalent plastic strain on the sheet metal for the case of strain hardening exponent of 0.5 for 1 mm thick sheet metal in friction case is illustrated in figure 5.




Figure 3. Punch force according to displacement for different thickness of sheet metal at friction case for strain hardening exponent of 0.3




Figure 4. Stress distribution on surface of sheet metal in v-bending at friction case for thickness=2.0 mm and strain hardening exponent of 0.3




Figure 5. Equivalent plastic strain on sheet metal in v-bending for the case of strain hardening exponent=0.5 and thickness=1.0 mm in friction medium

As the thickness of blank metal is increased, the punch force raises. The punch force increases exponentially as the displacement increases. Figure 3 shows that it needs much more force and energy to form it as the cross-section area increases.

3.2. Effect of Strain Hardening Exponent in Friction Case

The effect of thickness on strain hardening exponent was investigated. Small plastic strains

were defined for plasticity model. So, the strain hardening exponent was taken as 0.1, 0.3 and 0.5 at friction case. The sheet plates having different strain hardening exponents were bent under friction case. As the strain-hardening exponent increases, the punch force to bend the sheet material by an angle of 90° decreases. Figure 6 emphasizes variation of the punch force according to punch action for different strain hardening exponent and 1.0 mm thick sheet metal at friction case. As shown in figure 6, as the strain hardening exponent increases from 0.1 to 0.5, the punch force to deform the blank material decreases from 2.03×10^5 N to 8.08×10^4 N at a displacement rate depicted in figure 2.




Figure 6. Punch force according to displacement for different strain hardening exponent of 1mm thick sheet metal material at friction case

The amount of maximum stress and the region of maximum stress on the sheet metal in friction case for the strain hardening exponent of 0.5- and 1.0- mm thick sheet plate are shown in figure 7. Von Mises stress distribution on blank material, punch and die for strain hardening exponent of 0.5 are depicted in figure 7. The equivalent plastic strain on sheet metal in the case of strain hardening exponent of 0.3 for 3.0 mm thick sheet metal at friction condition is illustrated in figure 8.




Figure 7. Stress distribution on surface of 1 mm thick sheet metal in v-bending for $n=0.5$




Figure 8. Equivalent plastic strain on sheet metal in v-bending for the case of strain hardening exponent $=0.3$ and thickness=3.0 mm in friction medium

3.3. Effect of Sheet Thickness in Non-Friction Case

The effect of thickness on punch force was investigated. So, the thickness of sheet metal was varied. The 1.0-, 2.0- and 3.0-mm thick plates were bent under non-friction condition. The punch forces keep increasing to deform the sheet metal within the die. As the blank is sufficiently deformed after a

certain point, it needs a lower punch force to suppress the sheet metal into the die. Figure 9 emphasizes variation of the punch force according to punch action for different sheet metal thickness in the case of strain hardening exponent of 0.3 at non-friction case. As the punch reaches the forming shape, the sheet metal gets in contact with the bottom of the die, thus the force increases remarkably to end the bending as illustrated in figure 9. At non-friction case, the punch force raises from 5.67×10^3 N to 14.21×10^3 N, as the thickness of material increases from 1.0 mm to 3.0 mm as seen in figure 9.




Figure 9. Punch force according to displacement for different thickness of sheet metal at non friction case for strain hardening exponent of 0.3

The amount of maximum stress and the region of maximum stress on the sheet metal for the strain hardening exponent of 0.3 are shown in figure 10.

The amount of maximum stress and the region of maximum stress on the sheet metal in non-friction case for the thickness of 2.0 are shown in figure 10. As depicted in figure 10, the highest Von Misses stress was computed at tip of the V-bended sheet metal. The equivalent plastic strains on sheet metal in the case of strain hardening exponent of 0.5 for 1.0 mm thick sheet metal at non-friction condition were illustrated in figure 11.




Figure 10. Stress distribution on surface of sheet metal in v-bending at non-friction case for thickness is 2.0 mm and strain hardening exponent of 0.3




Figure 11. Equivalent plastic strain on sheet metal in v-bending for the case of strain hardening exponent =0.5 and thickness=1.0 mm in non-friction medium

3.4. Effect of Strain Hardening Exponent in Non-Friction Case

The effect of thickness on strain hardening exponent was investigated. Isotropic hardening

model was chosen. Small plastic strains were specified for plasticity model. So, the strain hardening exponent was taken as 0.1, 0.3 and 0.5 at non-friction medium. The sheet plates having different strain hardening exponents were bent under non-friction condition. Figure 12 emphasizes variation of the punch force according to punch action for different strain hardening exponent and 1.0 mm thick sheet metal at non-friction case. As the strain hardening exponent increases from 0.1 to 0.5, the punch force to deform the blank material decreases from 9.13×10^4 N to 191 N at non-friction case as shown in figure 12. The amount of maximum stress and the region of maximum stress on the sheet metal in non-friction case for the strain hardening exponent of 0.5 and 1.0 mm thick sheet metal are shown in figure 13. As illustrated in figure 13, the highest Von Mises stress was calculated at tip of the V-bended sheet metal. In non-friction case, equivalent plastic strain on 3 mm thick sheet metal in the case of strain hardening exponent of 0.3 are depicted in figure 14.




Figure 12. Punch force according to displacement for different strain hardening exponent of 1mm thick sheet metal material at non-friction case




Figure 13. Stress distribution on surface of 1.0 mm thick sheet metal in v-bending for strain hardening exponent of 0.5




Figure 14. Equivalent plastic strain on sheet metal in v-bending for the case of strain hardening exponent =0.3 and thickness=3.0 mm in non-friction medium

4. CONCLUSION

The change in punch force was investigated in the work of v-bending analysis. The punch force increased exponentially as the deflection increases in v-bending analyzes for the blank metal thickness value of 1.0, 2.0 and 3.0 mm. The results show that as thickness of the blank metal increases, there must

be higher force to bend it by an angle of 90°. If the non-friction case and friction case are compared in terms of punch force capacity, at friction case it requires higher punch force to form the sheet metal due to Coulomb friction between the punch-sheet metal and sheet metal-die. Practically, the surfaces are able to be lubricated to lower the friction.

Although the strain hardening exponent indicates the how much the metal can be strengthened, for the small plastic strains, lower the value of n, greater is the punch force.

Also, the blank material starts to be bent, it will need more punch force. Results demonstrate that as the sheet metal deforms, it becomes stronger and harder. The strain hardening exponent was lowered from 0.5 to 0.1, the punch force reached the highest value of 2.03×10^5 N for the 1 mm thick sheet metal at friction case and 9.13×10^4 N for the 1 mm thick sheet metal at non-friction case.

The findings provide a comprehensible approach at the bending region and can help to understand the effect of parameters on forming to improve the design of the forming actions for different sheet metal bending applications.

5. NOMENCLATURE

σ	stress [N.m ⁻²]
σ_y	yield strength [N.m ⁻²]
K	hardening parameter
ϵ	strain [mm.mm ⁻¹]
n	strain hardening exponent

6. REFERENCES

1. Miksza, M., Bohdal Ł., Koška K., 2021. Numerical Analysis of the V-die Bending Process of the Zinc Coated DC01 Steel. Journal of Mechanical and Energy Engineering, 5(2), 87-94.
2. Purwadi, W., Bandanadjaja, B., Idamayanti, D., 2020. Shifting of the Neutral Line at a V-Bending Process of AISI 1015 Steel Plate. In Journal of Physics: Conference Series, 1450(1), 012126.

3. Ben Salem, C., Meslameni, W., 2022. A Numerical Investigation on the Springback in Air V-bending of Aluminum 1050A. *International Journal of Research in Industrial Engineering*, 11(2), 119-133.
4. Golovashchenko, S.F., 2008. Quality of Trimming and Its Effect on Stretch Flanging of Automotive Panels. *Journal of Materials Engineering and Performance*, 17, 316-325.
5. Qian, Z., Zhao, Y., Wang, C., Liu, S., Xiong, Z., Meehan, P.A., Daniel, W.J.T., Ding, S., 2021. Numerical and Experimental Investigation of the Bending Zone in Free U-bending. *Journal of Manufacturing Science and Engineering*, 143(9), 1-32.
6. Li, Y., Liu, Y., Liu, M., Liu, H., 2022. Sensitivity Analysis for Springback of QSTE700 High-strength Steel Rectangular Welded Tube to Material Parameters in Rotary Draw Bending. *The International Journal of Advanced Manufacturing Technology*, 122(3-4), 1747-1762.
7. Hilditch, T., Atwell, D., Easton, M., Barnett, M., 2009. Performance of Wrought Aluminium and Magnesium Alloy Tubes in Three-point Bending. *Materials & Design*, 30(7), 2316-2322.
8. Le Maoût, N., Manach, P.Y., Thuillier, S., 2012. Influence of Prestrain on the Numerical Simulation of the Roller Hemming Process. *Journal of Materials Processing Technology*, 212(2), 450-457.
9. Lin, G., Iyer, K., Hu, S.J., Cai, W., Marin, S.P., 2005. A Computational Design-of-Experiments Study of Hemming Processes for Automotive Aluminium Alloys. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 219(10), 711-722.
10. Kim, Y., Kang, D.W., Ku, T.W., Kim, J., Kang, B.S., 2007. Multi Stage Seaming Process for Large Tubular Mechanical Bonded Structure. In *Key Engineering Materials*, 340, 1437-1442.
11. Weiss, M., Marnette, J., Wolfram, P., Larrañaga, J., Hodgson, P.D., 2012. Comparison of Bending of Automotive Steels in Roll Forming and in a V-die. In *Key Engineering Materials*, 504, 797-802.
12. Şen, N., Taşdemir, V., 2021. Experimental and Numerical Investigation of the Springback Behaviour of CP800 Sheet After the V-bending Process. *Ironmaking & Steelmaking*, 48(7), 811-818.
13. Adnan, A.F., Abdullah, A.B., Samad, Z., 2017. Study of Springback Pattern of Non-uniform Thickness Section Based on V-bending Experiment. *Journal of Mechanical Engineering and Sciences*, 11(3), 2845-2855.
14. Sharma, P.K., Gautam, V., Agrawal, A.K., 2022. Investigations on Effect of Bending Radius on Springback Behaviour of Three-ply Clad Sheet. *Materials Today: Proceedings*, 62, 1651-1657.
15. Thipprakmas, S., Sontamino, A., 2022. Spring-Back Characteristics on Bent Holed Parts in V-Die Bending Process. *Advances in Materials Science and Engineering*.
16. Karalar, M., Bayramoğlu, M., 2022. Combined Impacts of Thickness and Bending Angle on Springback of 1000DP Steel Sheets. *Ironmaking & Steelmaking*, 49(7), 693-698.
17. Liu, Z., Ma, L., Meng, Z., Liu, P., Du, Y., 2021. Effect of Yield Criterion and Variable Elastic Modulus on Springback Prediction of Ti-6Al-4V Sheet V-shaped Bending. *The International Journal of Advanced Manufacturing Technology*, 116, 1925-1936.
18. Kim, Y., Gu, G.H., Kim, R.E., Seo, M.H., Kim, H.S., 2022. Deformation Behavior of Lightweight Clad Sheet: Experiment and Modeling. *Materials Science and Engineering: A*, 852, 143666.
19. Slota, J., Jurčišin, M., 2012. Experimental and Numerical Prediction of Springback in V-Bending of Anisotropic Sheet Metals for Automotive Industry. *Zeszyty Naukowe Politechniki Rzeszowskiej. Mechanika*, 84 [284](3), 55-68.
20. Cao, A., Li, W., Wang, J., Fu, J., 2022. Influence of Stamping Parameters on Stamping Characteristics of SAF2205 Bidirectional Stainless Steel. *SN Applied Sciences*, 4(2), 35.
21. Dhilip, A., Archana, A., Brindha, M., Kanmani, M., Rajeshwari, B.P., RubaDharshini, S., 2021. Bending Stress Analysis in Sheet Metal Forming Process. *Nveo-Natural Volatiles & Essential Oils Journal*, 3064-3075.

22. Ozdemir, A.O., 2023. Investigation of the Spring-back Phenomenon in Two-dimensional Bending of Continuous Glass Fiber-Reinforced Polyamide Composite Sheets. *Journal of Composite Materials*, 00219983221148093.
23. Li, G., He, Z., Ma, J., Yang, H., Li, H., 2021. Springback Analysis for Warm Bending of Titanium Tube Based on Coupled Thermal-Mechanical Simulation. *Materials*, 14(17), 5044.
24. Pritima, D. Veerappan, G. Patel, V.D., Parthasarathy, N.R., 2022. Analysis of Spring Back Behaviour During Bending of AISI 1045 Sheet Metal. *Materials Today: Proceedings*, 59, 1575-1580.
25. Krininger, M., Opritescu, D., Golle, R., Volk, W., 2016. Experimental Investigation of the Influence of Punch Velocity on the Springback Behavior and the Flat Length in free Bending. *Procedia Cirp*, 41, 1066-1071.
26. Nakajima, K., Utsumi, N., Yoshida, M., 2013. Suppressing Method of the Cross Section Deformation for Extruded Square Tubes in Press Bending. *International Journal of Precision Engineering and Manufacturing*, 14, 965-970.
27. Gupta, T.R., Payal, H.S., 2016. Investigative Study on Bending and Spring Back of Electro Galvanized Steel. In 5th International Symposium on Fusion of Science & Technology, 18-22.
28. Tozuka, H., Watari, H., Toshio, H.A.G.A. 2024. Improving Room Temperature Formability of Twin-roll Cast Mg-Al-Zn-Sn Alloy by Repeated Bending. *Materials Research Proceedings*, 41, 2499-2505.
29. Örnekcı, A.O., Ekşi, S., 2024. Experimental Study on Springback Properties of 6061 Aluminum in V-Bending. *Sakarya University Journal of Science*, 28(3), 646-653.
30. Sofia, E.P.C., Gabriela, V.I.N.C.Z.E., André, D.P.P., Carmen, B.M., 2024. Bending of Third Generation Steel: Experimental and Numerical Approach, 41, 1196-1205.
31. Groover M.P. 2007. *Fundamental of Modern Manufacturing*, 3rd Edition, John Wiley & Sons, Inc.
32. William, D., Calister, Jr., 2001. *Fundamentals of Material Science and Engineering: An Introduction*. 5th Edition, John Wiley & Sons, Inc.
33. Hollomon, H., 1945. *Transactions of Metallurgical Society of AIME*, 162, 268.
34. Ludwigson, D.C., 1971. *Metallurgical Transactions*. 2, 2825.

MR Görüntülerinden Alzheimer Hastalığının Sınıflandırılması için Inception ve Sıkma-Uyarma Ağı Tabanlı Derin Öğrenme Modeli

Hüseyin FIRAT*¹ ORCID 0000-0002-1257-8518

Hüseyin ÜZEN² ORCID 0000-0002-0998-2130

¹Dicle Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Diyarbakır

²Bingöl Üniversitesi, Mühendislik - Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü,
Bingöl

Geliş tarihi: 08.11.2023

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: FIRAT, H., ÜZEN, H., (2024). MR Görüntülerinden Alzheimer Hastalığının Sınıflandırılması için Inception ve Sıkma-Uyarma Ağı Tabanlı Derin Öğrenme Modeli. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 555-567.

Öz

Alzheimer hastalığı (AH) ilerleyici bir beyin hastalığıdır ve yaşlı yetişkinlerde demansın önde gelen nedenidir. Hastalığın ilk aşamalarında tedavi daha etkili olduğu için erken teşhis hayati önem taşımaktadır. Derin öğrenme tekniklerinin, AH tespiti de dahil olmak üzere tıbbi görüntüleme için etkili olduğu kanıtlanmıştır. Bu çalışmada, manyetik rezonans görüntüleme görüntülerinden AH sınıflandırması için bir Inception modülü ile bir sıkma ve uyarma bloğunu birleştiren yeni bir yöntem tanıtılmaktadır. Inception modülü, farklı ölçeklerde çoklu paralel evrişimler kullanarak evrişimsel sinir ağı doğruluğunu arttırmaktadır. Sıkma ve uyarma bloğu, minimum ek parametre ile performansı arttırmaktadır. Dört sınıflı Kaggle veri seti üzerindeki deneysel sonuçlar ile %98,28'lik bir doğruluk değeri elde edilmiştir. Literatürdeki son çalışmalarla yapılan karşılaştırmalar, önerilen yöntemin AH'yi yüksek doğrulukla sınıflandırmadaki başarısını açıkça göstermektedir. Bu yaklaşım, tıbbi görüntülerden AH'yi doğru bir şekilde sınıflandırarak daha erken teşhis ve müdahaleye olanak sağlama konusunda umut vaat etmektedir.

Anahtar Kelimeler: Inception modülü, Sıkma-uyarma bloğu, Alzheimer hastalığı, Sınıflandırma

Inception and Squeeze-Excitation Network Based Deep Learning Model for Classification of Alzheimer's Disease from MRI Images

Abstract

Alzheimer's disease (AD) is a progressive brain disorder, the leading cause of dementia in older adults. Early identification is vital, as treatment is more effective in the disease's initial stages. Deep learning techniques have proven to be effective in medical imaging, including AD detection. This study introduces a novel method for AD classification from MRI images, combining an Inception module and a squeeze-and-excitation block. The Inception module increases convolutional neural network accuracy by using multiple parallel convolutions at different scales. The squeeze-and-excitation block enhances performance

*Sorumlu yazar (Corresponding Author): Hüseyin FIRAT, huseyin.firat@dicle.edu.tr

with minimal added parameters. The experimental results on the four-class Kaggle dataset yielded an accuracy of 98.28%. Comparisons with recent studies in the literature clearly demonstrate the success of the proposed method in classifying AD with high accuracy. This approach holds promise for accurately classifying AD from medical images, enabling earlier diagnosis and intervention.

Keywords: Inception module, Squeeze-and-excitation block, Alzheimer's disease, Classification

1. GİRİŞ

Alzheimer hastalığı (AH), geri dönüşü olmayan ve kronik nörodejeneratif bir hastalıktır ve yaşlılar arasında demansın önde gelen nedenidir [1]. Terapötik ilerlemenin başlaması ve etkili hasta tedavisi için AH prognozunun erken ve kesin analizi gereklidir. Dünya Sağlık Örgütü, AH'nin beşinci en önemli ölüm nedeni olarak kanseri geride bıraktığını ve 2050 yılına kadar AH hastalarının sayısının 152 milyona ulaşmasının beklendiğini bildirmiştir. Bu da 21. yüzyılda önemli bir sağlık sorunu teşkil edecektir [2]. AH, beyin hücrelerini kademeli olarak tahrip eden, hafıza kaybına ve bilişsel sorunlara neden olan ve nihayetinde gerçek yaşamın günlük aktivitelerini gerçekleştirme yeteneğinin kaybını hızlandıran uzun süreli nörolojik bir beyin hastalığıdır [3]. AH hastalığına yakalan insanlar yavaş yavaş hatırlama veya düşünme gibi bilişsel işlevlerini kaybedecek ve sonunda günlük aktiviteleri gerçekleştirme yeteneklerini kaybedeceklerdir. AH gelişimi bağlamında, hafif bilişsel bozukluk (HBB) normal bilişten AH'ye uzanan süreç boyunca zihinsel becerilerde hafif bir düşüşü temsil ederken, HBB olan bireylerin %33'ünden fazlası beş yıl veya daha uzun bir süre içinde AH'ye ilerleyecektir [2]. Bunun yanı sıra, AH'nin klinik öncesi bir aşaması olan HBB, normal yaşlanma ile AH arasında geçici bir durumdur.

Ne yazık ki AH'nin nedeni ve mekanizması hala tam olarak anlaşılammıştır ve iyileştirici bir tedavisi yoktur. Ancak hastalığın ilerlemesi ilaç tedavisi, egzersiz ve hafıza eğitimi yoluyla yavaşlatılabilmektedir. Bu konuda AH'nin erken tespiti ve HBB'nin doğru tanısı hastalığın ilerlemesini geciktirmek ve hastanın yaşam kalitesini arttırmak açısından büyük önem taşımaktadır. Bununla birlikte, doktorlar nöro görüntüleme ve bilgisayar destekli tanı yaklaşımlarını kullanarak AH'yi erken evrelerinde

önemli ölçüde daha az doğrulukla sınıflandırabilmektedirler. Bilgisayarlı Tomografi (BT) taraması, Pozitron Emisyon Tomografisi (PET) taraması ve özellikle Manyetik Rezonans Görüntüleme (MRG) taraması dahil olmak üzere nöro-görüntüleme, tıbbi tanıda hayati bir rol oynamaktadır [4]. İnsan vücudu hakkında bilgi sağlayan etkili bir non-invaziv yöntemdir. Tıbbi teşhis sürecinin ilerlemesi, günümüzde bilgisayar destekli teşhis alanında muazzam araştırma alanı oluşturmuştur [5].

Bilgisayar destekli teşhis sistemi, geleneksel ve derin öğrenme tabanlı olarak ayırt edebileceğimiz görüntü analiz tekniklerine dayanmaktadır. Bunlar: ön işleme, segmentasyon, özellik çıkarma ve sınıflandırma şeklindedir. Görüntü ön işleme, olası bozulmaları veya gereksiz verileri ortadan kaldırmak veya daha sonraki işlemler için önemli özellikleri vurgulamak ve geliştirmek için görüntüyü analiz etmeden önce hazırlamaktadır. Daha sonra, segmentasyon adımı önemli bölgeleri bir sonraki adımda çıkarılan renk, yoğunluk veya doku gibi ortak özelliklere sahip piksel gruplarına ayırmaktadır. Segmentasyonun amacı, görüntü temsili basitleştirmek ve daha anlamlı ve analiz edilmesi daha kolay bir hale getirmektir. Son adım, denetimli veya denetimsiz makine öğrenimi yaklaşımlarını kullanarak nesnelere bir etiket atamaktan oluşan sınıflandırmadır. Ancak son yıllarda, evrimsel sinir ağının (ESA) önerilmesinden bu yana derin öğrenme algoritmaları ortaya çıkmıştır. ESA'lar özellik tanımlayıcılarına veya belirli özellik çıkarma tekniklerine ihtiyaç duymadan özellikleri bağımsız olarak çıkarabilirler [6].

Derin öğrenme algoritmaları geleneksel makine öğrenme yöntemlerinden farklıdır. Görüntü ön işlemine çok az ihtiyaç duyarlar veya hiç ihtiyaç duymazlar. Önceden özellik seçimi gerektirmeden ham görüntülerden otomatik olarak optimum bir

veri temsili çıkarabilirler, bu da daha objektif bir süreçle sonuçlanmaktadır. Bu nedenle, derin öğrenme algoritmaları ince ve yaygın anatomik anormallikleri tespit etmek için daha uygundur. Son yıllarda tıbbi görüntü analizinde yaygın olarak kullanılmakta ve sınıflandırma, segmentasyon gibi çalışma alanlarında oldukça başarılı sonuçlar üretmektedir.

Literatürde son yıllarda AH'ın sınıflandırılması için çeşitli derin öğrenme tabanlı çalışmalar yapılmıştır. Bunlardan bazıları şu şekildedir: [3] nolu çalışmada, MRG görüntüleri kullanarak AH'ı tanımlamak için güvenilir ve verimli bir yöntem geliştirmek için derin ESA kullanmayı amaçlamaktadır. Bu doğrultuda, Alzheimer Hastalığı Tespit Ağı (Detection of Alzheimer's Disease Network - DADNet), parametreleri ve hesaplama maliyetlerini azaltırken Alzheimer hastalığının evrelerini doğru bir şekilde sınıflandırmak için sıfırdan geliştirilmiştir. Kaggle veri seti kullanılarak %90 doğruluk değeri elde etmişlerdir. [7] nolu çalışmada, MRG görüntüleri kullanılarak AH sınıflandırılması için hafif bir derin ESA geliştirdiler. Kaggle veri seti üzerinde gerçekleştirilen deneysel çalışmalar sonucunda %95,93 doğruluk değeri elde ettiler. [8] nolu çalışmada, AH sınıflandırılması için geliştirilen ESA tabanlı yöntem ile kaggle veri seti kullanarak %94,63 doğruluk elde ettiler. [9] nolu çalışmada, AH sınıflandırılması için önceden eğitilmiş ResNet kullanılarak kaggle veri seti ile %94,10 doğruluk elde ettiler. [10] nolu çalışmada, destek vektör makineleri (DVM) ile birlikte iki farklı ESA tabanlı yöntem kullanarak AH sınıflandırılması için deneysel çalışmalar yaptılar. İlk yöntemde AlexNet ile birlikte DVM kullanarak kaggle veri seti üzerinde %94,84 doğruluk değeri elde ederken, ikinci yöntemde ResNet ile birlikte DVM kullanarak aynı veri seti üzerinde %94,14 doğruluk değeri elde ettiler. [11] nolu çalışmada, Kaggle platformundan elde ettikleri MRG görüntülerinden AH sınıflandırılması için ESA tabanlı bir yöntem önerdiler. Önerilen bu yöntemi DEMentia NETwork (DEMNET) olarak adlandırdılar. Önerilen bu yöntem ile gerçekleştirilen kapsamlı deneysel çalışmalar sonucunda %95,23 doğruluk değeri elde ettiler.

Bu çalışmada, AH'ın MRG görüntülerinden çok sınıflı olarak sınıflandırılması için ESA tabanlı yeni bir yöntem önerilmiştir. Önerilen yöntem Inception modülü ve sıkma-uyarma bloğunun birleşiminden oluşmaktadır. Inception modülünün kullanımı ile farklı ölçeklerde çoklu paralel evrişimler gerçekleştirerek ESA'ların verimliliğini ve sınıflandırma performansını arttırmak amaçlanmıştır. Inception modülü ayrıca daha büyük filtreler uygulamadan önce giriş tensöründeki kanal sayısını azaltmak için kullanılan 1x1 evrişim katmanı içermektedir. Bu, sınıflandırma doğruluğunu korurken ağır hesaplama maliyetini azaltmaya yardımcı olmaktadır. Aynı zamanda bellekten verimli bir şekilde tasarruf edilmesi sağlanmaktadır. Sıkma-uyarma bloğunun ESA'nın temsil kalitesini arttırmak için tasarlandığı göz önüne alındığında, hem özellik çıkarma hem de sınıflandırma performansını arttırmak için bu araştırma kapsamında önerilen yöntem dahil edilmiştir. Sıkma-uyarma bloğunun önerilen yöntemle entegrasyonu, genel parametre sayısında yalnızca minimum artışla sınıflandırma performansını artırma yeteneklerinden kaynaklanmaktadır. Önerilen yöntemin sınıflandırma performansının analizi için Kaggle platformunda yer alan MRG görüntüleri kullanılarak deneysel çalışmalar yapılmıştır [12]. Deneysel çalışmalar sonucunda %98,28 doğruluk değeri elde edilmiştir.

Bu çalışmanın geri kalanında öncelikle veri seti, önerilen yöntem ve önerilen yöntemin arka planında kullanılan Inception modülü ile sıkma-uyarma bloğunun yer aldığı materyal ve metod bölümü Bölüm 2'de yer almaktadır. Ardından deneysel çalışmalar ve sınıflandırma sonuçlarının verildiği Bölüm 3 gelmektedir. Son olarak, çalışmanın genel bir özetinin yer aldığı sonuç bölümü Bölüm 4'te bulunmaktadır.


2. MATERYAL VE METOT

2.1. Veri Seti

Bu çalışmada kullanılan veri seti, Manyetik Rezonans Görüntüleme (MRG) tarama görüntüleri ve ilgili sınıf etiketleri bilgilerine sahip halka açık

bir platform olan Kaggle'dan alınmıştır [12]. Bu veri seti 4 sınıf (hafif bunamış-mild demented, orta derece bunamış-moderate demented, bunak olmayan-non demented, çok hafif bunamış-very mild demented) ve toplam 6400 MRG görüntüsü içermektedir. Bu 4 sınıfta yer alan görüntüler ise şu

şekildedir: 896 hafif bunamış, 64 orta derece bunamış, 3200 bunak olmayan ve 2240 çok hafif bunamış. MRG görüntü örnekleri, dört farklı sınıfa ait 150 x 150 piksellik üç kanallı (RGB) görüntülerdir. Bu 4 sınıfa ait örnek MRG görüntüleri Şekil 1'de verilmiştir.



Şekil 1. Örnek MRG görüntüleri

2.2. Inception Modülü

Inception modülü, ESA'larda sınıflandırma ve nesne tanıma için kullanılan bir yapı taşıdır. Bu modül, 2014 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasını kazanan GoogLeNet mimarisinde tanıtılmıştır. Bu modül, paralel olarak farklı boyutlarda (1x1, 3x3 ve 5x5) filtreler kullanarak birden fazla ölçek ve çözünürlükteki görüntülerden verimli bir şekilde özellik çıkarmak için tasarlanmıştır. Bu, ağı görüntüdeki hem ince taneli hem de kaba taneli ayrıntıları yakalamasını sağlamaktadır. Inception modülü ayrıca girdinin boyutluluğunu azaltmaya ve hesaplama performansını arttırmaya yardımcı olan 1x1 evrimsel katman içerir. Ayrıca modül, özellik haritalarını küçültmek için havuzlama işlemlerini kullanır, bu da aşırı öğrenmenin etkisini azaltmaya yardımcı olabilir. Inception modülü, derin ağlar oluşturmak için bir araya getirilebilmekte ve çeşitli görüntü tanıma görevlerinde son teknoloji


performans elde edebilmektedir [13,14]. Inception modülünün yapısı Şekil 2'de verilmiştir.

2.3. Sıkma-Uyarma (SU) Bloğu

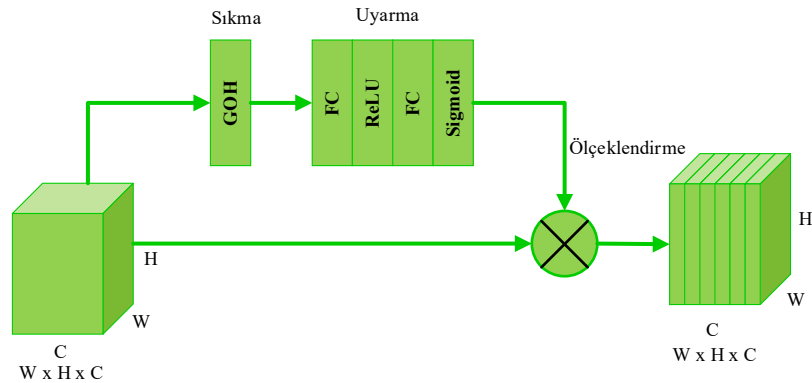
SU bloğu, ESA'lar için hesaplama yükünü önemli ölçüde arttırmadan kanal ilişkilerini geliştiren bir çerçeve sunmaktadır. Bu blok, aldığı giriş özelliklerini yeniden kalibre ederek önemli özellik bilgilerini etkili bir şekilde geliştirir. SU bloğunun kullanılması, kanallar arasındaki karşılıklı bağımlılıkların geliştirilmesine katkıda bulunur ve böylece görüntü sınıflandırma görevleri için özellik bilgilerinin uygunluğunu artırır. Şekil 3'te SU bloğunun yapısal taslağını gösterilmektedir. Başlangıçta, SU bloğu mevcut kanal sayısı ile birlikte bir özellik haritası alır. Daha sonra, Global Ortalama Havuzlama (GOH) kullanılarak her kanal tek bir sayısal değere dönüştürülür ("sıkma" olarak adlandırılır). Bu süreçte, her kanalla ilişkili özellik haritaları, GOH gibi bir kanal tanımlayıcı tekniği

kullanılarak 1×1 özellik haritalarına yoğunlaştırılır. Bu aşama, genel kanal bilgilerini kapsayan bir skaler değer üretir. "Sıkma" işleminin birincil amacı küresel bir alıcı alan oluşturarak küresel bilginin alt ağ katmanları tarafından bile kullanılmasını kolaylaştırmaktır. "Sıkma" işleminin ardından "uyarma" süreci devreye girerek, belirlenen parametrelere dayalı olarak her bir özellik kanalı için ağırlıklar oluşturur. Bu parametreler, özellik kanalları arasında var olan korelasyonları yakalamak için açıkça eğitilir. Mimari, yöntemin karmaşıklığını yönetmek, genelleştirmeyi kolaylaştırmak ve kanal korelasyonlarını modellemek için bir darboğaz yapısı sunmak üzere iki tam bağlantılı katman (Fully connected-FC) içerir. İlk FC katmanı, özellik boyutlarını azaltmaya yarar ve bu boyutlar daha sonra bir sonraki FC katmanında orijinal boyutlarına geri genişletilir. Bu iki FC katmanı arasında ReLU aktivasyon

fonksiyonu kullanılarak ağa doğrusal olmayan bir yapı kazandırılır ve böylece ağın karmaşık kanal korelasyonlarına daha iyi adapte olması sağlanır. Doğrudan bir FC katmanının aksine, iki FC katmanının kullanılması modelin doğrusal olmayan özelliklerini geliştirerek karmaşık kanal ilişkilerine daha iyi uyum sağlarken aynı zamanda hesaplama yükünü ve parametre sayısını azaltır. FC-ReLU-FC dizisinden sonra, 0 ile 1 arasında değişen normalleştirilmiş ağırlıkları hesaplamak için sigmoid fonksiyonu çağrılır. Daha sonra, normalleştirilmiş ağırlıkları her kanalın özelliklerine göre ayarlamak için bir ölçeklendirme prosedürü uygulanır. Daha da önemlisi, SU bloğundaki bu işlemler minimum ek hesaplama yüküne neden olur. Bu blok, sınıflandırma performansını artırma kabiliyeti nedeniyle çeşitli yöntemlere kolay bir şekilde entegre edilebilir [15-17].



Şekil 2. Inception modülü



Şekil 3. SU blok yapısı

2.4. Önerilen Yöntem

Önerilen yöntem Şekil 4'te gösterildiği gibi Inception modüllerinin ve sıkma-uyarma bloğunun birleşiminden oluşmaktadır. Önerilen yöntemde girdi MRG görüntüleri öncelikle 150x150x3 boyutuna yeniden boyutlandırılmıştır. Girdi MRG görüntülerine öncelikle 3x3 çekirdek boyutunda 64 filtrelili 2 boyutlu (2B) evrişim işlemi uygulanmaktadır. Ardından sırasıyla 3x3 çekirdek boyutunda maksimum havuzlama, 3x3 ve 1x1 çekirdek boyutunda ve 128 filtrelili 2B evrişim işlemi uygulanmaktadır. Bu işlemlerden sonra elde edilen özellik haritası ilk Inception modülünün girişine verilmektedir. Inception modülü Şekil 2'de gösterildiği gibi uygulanmaktadır. İlk Inception modülünün çıktısına sırasıyla 3x3 çekirdek boyutunda 64 filtrelili 2B evrişim, 3x3 çekirdek boyutunda maksimum havuzlama, 3x3 ve 1x1 çekirdek boyutunda ve 128 filtrelili 2B evrişim işlemleri uygulanmaktadır. Bu işlemlerin sonunda elde edilen özellik haritasına ikinci Inception modülü uygulanmaktadır. İkinci Inception modülünün çıktısına sırasıyla 3x3 çekirdek boyutu ve 128 filtreye sahip 2B evrişim, 3x3 çekirdek boyutuna sahip maksimum havuzlama ve 1x1 çekirdek boyutu ve 128 filtreye sahip 2B evrişim işlemleri uygulanmaktadır. Ayrıca, ReLU aktivasyon fonksiyonu tüm evrişim katmanlarına uygulanmaktadır. Tüm bu işlemlerin sonunda elde edilen özellik haritası SU bloğunun girişine verilmektedir. SU bloğu Şekil 3'te gösterildiği gibi sıkma, uyarma ve ölçeklendirme aşamalarından oluşmaktadır. SU bloğunda bu işlemler gerçekleştirildikten sonra GOH ve ardından toplu normalizasyon (Batch normalization) işlemleri gerçekleştirilmektedir. GOH, standart evrişimsel sinir ağlarında tam bağlantılı katmanları değiştirmek için tasarlanmış bir havuzlama işlemidir. GOH ile son katmandaki sınıflandırma görevinin karşılık gelen her sınıfı için bir özellik haritası oluşturulmaktadır. Özellik haritalarının üstüne tam bağlantılı katmanları eklemek yerine, her bir özellik haritasının ortalaması alınmakta ve elde edilen vektör doğrudan softmax katmanına aktarılmaktadır. Ayrıca önerilen yöntemde GOH'un kullanmanın avantajı, GOH'ta optimize edilecek bir parametre olmaması ve dolayısıyla bu katmanda aşırı öğrenmenin önlenmesidir. GOH'un çıktısı,

özellikleri sınıflandırmak için bir softmax fonksiyonuna verilmektedir. Bununla birlikte, softmax'tan önce, eğitim sürecini kolaylaştırmak ve hızlandırmak için toplu normalleştirme uygulanmaktadır. Son olarak, Softmax her sınıfa olasılık değerleri atamaktadır.

Önerilen yöntemin özgün katkısı, Inception modülü ile sıkma-uyarma bloğunu birleştirerek daha az parametre ile yüksek performans elde etmesidir. Evrişimsel sinir ağı tabanlı derin öğrenme modelleri kullanan diğer çalışmalardan farklı olarak, bu yöntem, Inception modülü sayesinde, farklı evrişimsel çekirdek boyutları kullanılarak girdi görüntülerinden çeşitli ölçeklerde özellikler çıkarılmaktadır. Bu, modelin farklı detayları ve özellikleri yakalayabilmesini sağlamaktadır. Aynı zamanda, yöntemin zengin ve çok yönlü özellikler öğrenmesi açısından önemlidir. Bu modül ayrıca 1x1 evrişimler kullanarak çapraz kanal modelleri öğrenmekte ve çoklu evrişim katmanlarıyla modülün çok yönlü özellik çıkarma kapasitesinden faydalanmaktadır. Bu, ağıın genel özellik çıkarma yeteneklerine katkıda bulunarak yüksek doğruluk sağlamaktadır. Sıkma-uyarma bloğu, kanal dikkatini artırarak önemli özelliklerin daha iyi öğrenilmesinde etkilidir. Bu blok, ek işlem maliyeti neredeyse olmadan performans artışı sağlamak ve herhangi bir modele kolayca eklenebilmektedir. Bu iki yöntemin kombinasyonu, daha az parametre ile çalışarak hesaplama maliyetlerini düşürmekte ve daha verimli bir yöntem sunmaktadır.

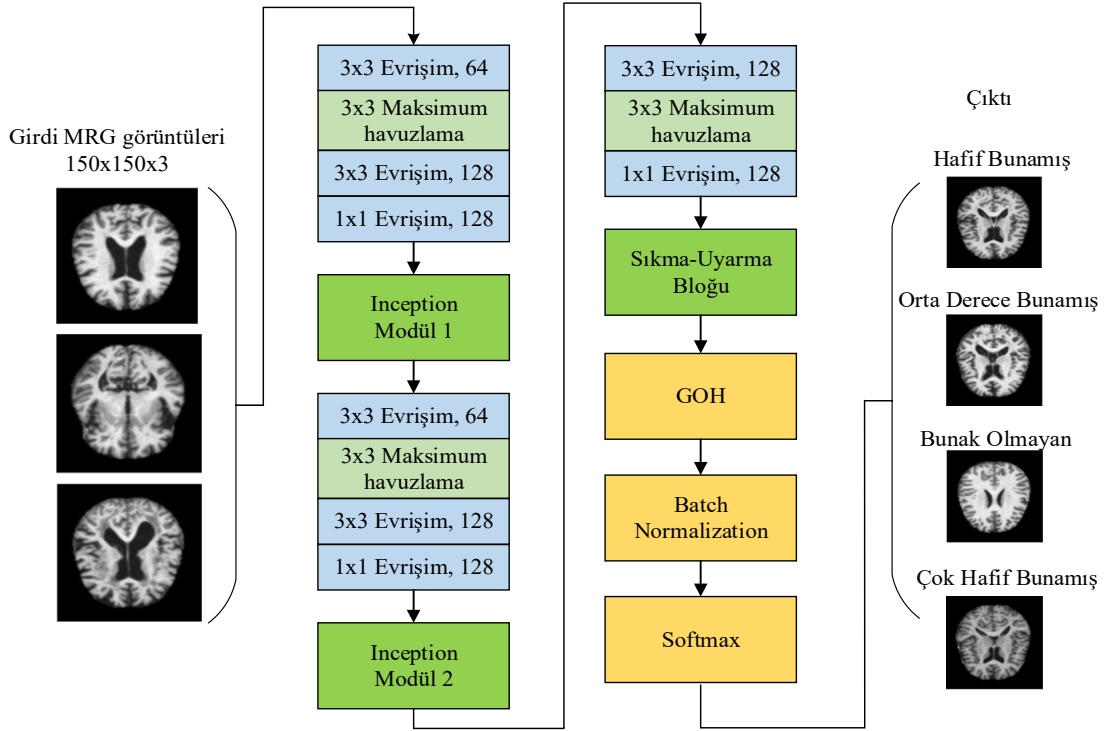
3. DENEYSEL ÇALIŞMALAR

3.1. Parametre Detayları

Çalışma kapsamında deneysel çalışmalar kaggle platformunda python programlama dili ve keras ile tensorflow kütüphaneleri kullanılarak gerçekleştirilmiştir. Kaggle platformunda donanım hızlandırıcı olarak TPU kullanılmıştır. Deneysel çalışmalarda tüm görüntüler 150x150x3 boyutundadır. Veri setinde yer alan 6400 görüntü, eğitim, doğrulama ve test veri seti için sırasıyla %80, %10 ve %10'a bölünmüştür. Yani, 5120 görüntü eğitim, 640 görüntü doğrulama ve 640 görüntü test için kullanılmıştır. Önerilen yöntemi

eğitmek için kullanılan hiperparametreler şu şekildedir. Batch size değeri olarak 128 alınmıştır.

Yöntem 100 epok'ta eğitilmiştir. Optimizer olarak Adam kullanılmıştır.



Şekil 4. Önerilen yöntem

3.2. Değerlendirme Ölçütleri

Önerilen yöntemin performansını kıyaslamak için farklı değerlendirme ölçütleri kullanılmıştır. Aşağıdaki dört ölçüt, bir sınıflandırıcının çeşitli ölçütlerini gözlemlerken yaygın olarak kullanılmaktadır.

- Doğruluk, doğru tahminlerin yöntem tarafından yapılan toplam tahmin sayısına oranını temsil etmektedir. Doğruluk Eşitlik 1'deki gibi hesaplanmaktadır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

- Çok sınıflı sınıflandırma bağlamında kesinlik, her sınıf için bir yöntem tarafından yapılan pozitif tahminlerin doğruluğunu değerlendiren

bir ölçüttür. Kesinlik, pozitif olarak tahmin edilen örneklerin kaçının gerçekten sınıfa ait olduğunu ölçmektedir. Eşitlik 2'deki gibi tanımlanmaktadır.

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

- Duyarlılık, yöntemin toplam gerçek pozitif örneklerden (gerçek pozitifler + yanlış negatifler) ilgili tüm örnekleri (gerçek pozitifler) doğru bir şekilde tanımlama yeteneğini değerlendirmek için sınıflandırmada kullanılan bir ölçüttür. Başka bir deyişle, yöntem tarafından doğru şekilde tanımlanan gerçek pozitif örneklerin yüzdesini ölçmektedir. Eşitlik 3'teki gibi tanımlanmaktadır.

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

- F1-skoru, çok sınıflı sınıflandırmada kesinlik ve duyarlılık arasında bir denge sağlamak için kullanılan bir ölçüttür. Hem kesinlik hem de duyarlılık tek bir değerde birleştirilerek bir yöntemin genel performansını değerlendirmek için kullanışlı bir ölçüt haline getirir. F1-skoru, kesinlik ve duyarlılığın harmonik ortalaması olarak hesaplanmakta ve yanlış pozitifler ile yanlış negatifler arasında bir denge bulmak istenildiğinde özellikle değerlidir. Eşitlik 4'teki gibi hesaplanmaktadır.

$$F1 - skoru = 2 * \frac{Kesinlik \times Duyarlilik}{Kesinlik + Duyarlilik} \quad (4)$$

Eşitlik 1, 2, 3 ve 4'teki TN, TP, FN ve FP karışıklık matrisinden elde edilmektedir. Gerçek Negatifler (TN), model tarafından negatif sınıf (ör. "0" veya "hayır") olarak doğru şekilde tahmin edilen örneklerin sayısını temsil eder. Bunlar, modelin gerçekte ait olmadıkları halde örnekleri pozitif sınıfa ait değilmiş gibi doğru bir şekilde tanımladığı durumlardır. Gerçek Pozitifler (TP), model tarafından pozitif sınıf (örneğin, "1" veya "evet") olarak doğru tahmin edilen örneklerin sayısını temsil eder. Bunlar, modelin örnekleri gerçekten pozitif sınıfa ait olduklarında pozitif sınıfa ait olarak doğru şekilde tanımladığı durumlardır. Yanlış Pozitifler (FP), aslında negatif sınıfa ait oldukları halde model tarafından yanlışlıkla pozitif sınıf olarak tahmin edilen örneklerin sayısını temsil eder. Bunlar, modelin negatif bir tahminde bulunması gerekirken pozitif bir tahminde bulunduğu durumlardır. Yanlış Negatifler (FN), aslında pozitif sınıfa ait oldukları halde model tarafından yanlışlıkla negatif sınıf olarak tahmin edilen örneklerin sayısını temsil eder. Bunlar, modelin pozitif bir tahminde bulunması gerekirken negatif bir tahminde bulunduğu durumlardır.

3.2. Deneysel Sonuçlar

Deneysel çalışmalar sonucunda önerilen yöntemin karışıklık matrisi Şekil 5'te verilmiştir. Şekil 5'e

göre, 91 hafif bunamış görüntüsünden, 88 görüntünün doğru şekilde sınıflandırıldığı görülmektedir. Bu sınıfta 1 görüntü bunak olmayan ve 2 görüntü de çok hafif bunamış olarak yanlış tahmin edilmiştir. Orta derece bunamış sınıfında yer alan 8 görüntünün tamamı doğru bir şekilde tahmin edilmiştir. 319 bunak olmayan görüntüden 318'inin doğru, 1 görüntünün çok hafif bunamış olarak yanlış tahmin edildiği ve son olarak 222 çok hafif bunamış görüntüden 215'inin doğru, 7 görüntünün bunak olmayan görüntü olarak yanlış tahmin edildiği görülmektedir. Bu karışıklık matrisinden yola çıkarak sınıf bazlı doğruluk değerleri şu şekildedir: hafif bunamış sınıf %99,53, orta derece bunamış sınıf %100, bunak olmayan sınıf %98,59 ve çok hafif bunamış sınıf %98,44'tür. 4 sınıfın genel doğruluk değeri %98,28 iken, makro ortalama değeri %99,14'tür.

Hafif Bunamış	88	0	1	2
Orta Derece Bunamış	0	8	0	0
Bunak Olmayan	0	0	318	1
Çok Hafif Bunamış	0	0	7	215
	Hafif Bunamış	Orta Derece Bunamış	Bunak Olmayan	Çok Hafif Bunamış

Şekil 5. Önerilen yöntemin karışıklık matrisi

Literatürden aynı veri setini kullanan çalışmalar ile gerçekleştirilen karşılaştırma sonuçları Çizelge 1'de verilmiştir. Inception modülü ve SU bloğunun birleşiminden oluşan önerilen yöntem ile %98,28 doğruluk, %99,04 kesinlik, %98,31 duyarlılık ve %98,67 F1-skoru elde edilmiştir. Önerilen yöntemle en yakın sonuçlar %95,93 doğruluk ve kesinlik, %95,88 duyarlılık ve %95,90 F1 skoru ile [7] nolu çalışmada geliştirilen hafif derin ESA yöntemi ile elde edilmiştir. Diğer yöntemlerden önerilen yöntemle en yakın sonuçlar %95,23 doğruluk, %96

kesinlik, %95 duyarlılık ve %95,27 F1 skoru ile [11] nolu çalışmada önerilen ESA yöntemi ile elde edilmiştir. Bu yöntemlerin yanı sıra, [3] nolu çalışmada önerilen ESA yöntemi ile %90 doğruluk, %91,34 kesinlik, %87,34 duyarlılık, %88,09 F1 skoru, [8] nolu çalışmada geliştirilen ESA yöntemi ile %94,68 doğruluk, %94,75 kesinlik, duyarlılık ve F1 skoru, [9] nolu çalışmada önerilen önceden eğitilmiş ResNet50 mimarisi ile %94,10 doğruluk, %96,50 kesinlik, %94,75 duyarlılık, %95,5 F1 skoru elde edilmiştir. [10] nolu çalışmada iki farklı

yöntem önerilmiştir. İlk yöntemde AlexNet ve Destek vektör makineleri (DVM) kullanılarak %94,84 doğruluk, %93,02 kesinlik, %94,32 duyarlılık ve %93,66 F1 skoru elde edilirken, ResNet50 ve DVM'nin kullanıldığı ikinci yöntemde, %94,14 doğruluk, %91,41 kesinlik, %91,92 duyarlılık ve %91,66 F1 skoru elde edilmiştir. Karşılaştırmada kullanılan tüm yöntemler göz önüne alındığında önerilen yöntemin açık bir şekilde daha başarılı sonuçlar ürettiği görülmektedir.

Çizelge 1. Çoklu sınıflandırma görevi için önerilen yöntemin literatürde yer alan farklı yöntemler ile karşılaştırılması

Çalışma	Yöntem	Performans
[3]	ESA – DADNet	Doğruluk = %90 Kesinlik = %91,34 Duyarlılık = %87,34 F1-skor = %88,09
[7]	Hafif Derin ESA	Doğruluk = %95,93 Kesinlik = %95,93 Duyarlılık = %95,88 F1-skor = %95,90
[8]	ESA	Doğruluk = %94,63 Kesinlik = %94,75 Duyarlılık = %94,75 F1-skor = %94,75
[9]	Önceden eğitilmiş ResNet50	Doğruluk = %94,10 Kesinlik = %96,50 Duyarlılık = %94,75 F1-skor = %95,5
[10]	AlexNet+DVM	Doğruluk = %94,84 Kesinlik = %93,02 Duyarlılık = %94,32 F1-skor = %93,66
[10]	ResNet50+DVM	Doğruluk = %94,14 Kesinlik = %91,41 Duyarlılık = %91,92 F1-skor = %91,66
[11]	ESA - DEMNET	Doğruluk = %95,23 Kesinlik = %96 Duyarlılık = %95 F1-skor = %95,27
Önerilen yöntem	Derin ESA (Inception + SU)	Doğruluk = %98,28 Kesinlik = %99,04 Duyarlılık = %98,31 F1-skor = %98,67


Önerilen yöntemin farklı derin öğrenme tabanlı yöntemler ile karşılaştırılması Çizelge 2’de verilmiştir. Çizelge 2’de yer alan tüm yöntemler sıfırdan eğitilmiş ve sonuçları elde edilmiştir. Önerilen yöntem ile %98,28 doğruluk, %99,04 kesinlik, %98,31 duyarlılık ve %98,67 F1 skoru elde edilmiştir. Önerilen yönteme en yakın sonuçlar, %97,81 doğruluk, %98,50 kesinlik, %98,35 duyarlılık, %98,42 F1 skoru ile ResNet152, %97,66 doğruluk, %98,45 kesinlik, %98,13 duyarlılık, %98,29 F1 skoru ile InceptionV3, %97,81 doğruluk, %98,41 kesinlik, %94,80 duyarlılık, %96,57 F1 skoru ile InceptionResNetV2 yöntemlerinde elde edilmiştir. Diğer yöntemlerin doğruluk, kesinlik, duyarlılık ve F1 skorları incelendiğinde, VGG16 ile %87,81, %84,97, %81,81, %83,36, VGG19 ile %74,69, %72,03, %65,52, %68,62, ResNet101 ile %96,41, %97,32, %96,90, %97,11, MobileNet ile %89,69, %92,92, %86,63, %89,66, EfficientNetB0 ile %96,88, %97,92, %96,59, %97,25, EfficientNetB1 ile %97,03, %98,15, %91,13, %94,51 değerleri bulunmuştur. Tüm sonuçlar incelendiğinde, önerilen yöntem, en yakın değeri elde eden ResNet152’den %0,47 doğruluk, %0,54 kesinlik ve %0,25 F1 skoru daha başarılı değerler üretmiştir. Bunu yanı sıra ResNet152 yaklaşık 58 milyon

parametre içerirken, önerilen yöntem yaklaşık 1 milyon parametre içermektedir. Buradan da önerilen yöntemimiz ile daha az parametre ile daha başarılı sonuçların elde edildiği açık bir şekilde görülmektedir. Ayrıca önerilen yöntemin eğitim (train)-doğrulama (validation) doğruluk (accuracy) ve kayıp grafikleri Şekil 6’da verilmiştir. Şekil 6 incelendiğinde, eğitim doğruluğunun yaklaşık 40 epok’ta %100’e ulaştığı, doğrulama doğruluğunun yaklaşık 60 epok’a kadar dalgalanma gösterdiği görülmektedir. Kayıp (Loss) grafiğinde ise yaklaşık 20 epok’a kadar eğitim kaybı azalmakta ve 20 epok’tan sonra 0’a yaklaşmaktadır. Doğrulama kaybı ise yaklaşık 55 epok’a kadar dalgalanma göstermekte ve 55 epok’tan sonra 0’a yaklaşmaktadır.

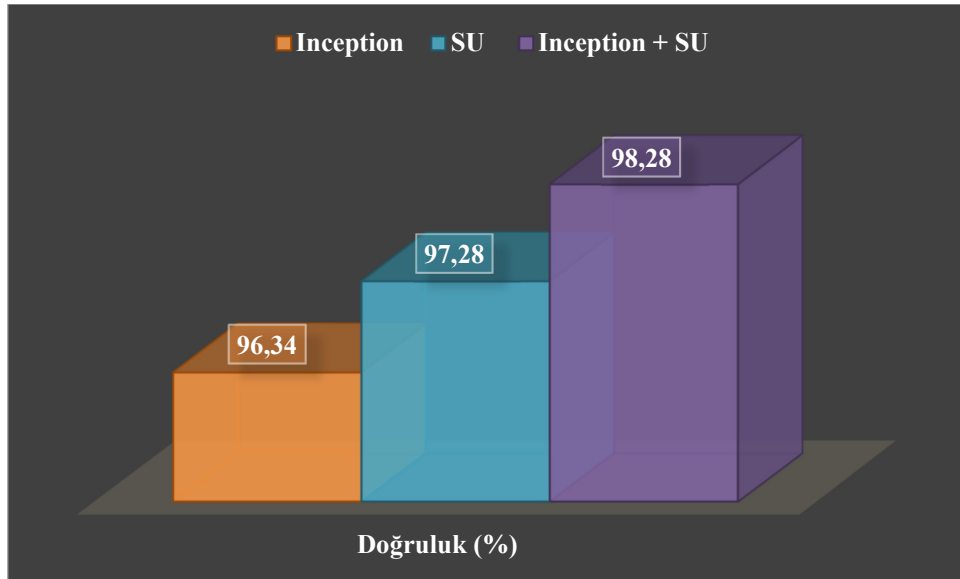
Önerilen yöntemde kullanılan Inception modülleri ve SU bloğunun bileşen analizi yapılmış ve Şekil 7’de verilmiştir. Sadece Inception modülleri kullanıldığında %96,34, sadece SU bloğu kullanıldığında %97,28 doğruluk değeri elde edilmektedir. Her iki bileşeni içeren önerilen yöntem (Inception + SU) ise %98,28 doğruluk değeri elde etmiştir. Inception ve SU bloğunun birlikte kullanımının sınıflandırma doğruluğunu arttırdığı görülmektedir.

Çizelge 2. Önerilen yöntemin farklı derin öğrenme tabanlı yöntemler ile karşılaştırılması

Model	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-skor (%)	Parametre sayısı
VGG16	87,81	84,97	81,81	83,36	14,718,788
VGG19	74,69	72,03	65,52	68,62	20,028,484
ResNet101	96,41	97,32	96,90	97,11	42,674,564
ResNet152	97,81	98,50	98,35	98,42	58,387,332
InceptionV3	97,66	98,45	98,13	98,29	21,819,172
MobileNet	89,69	92,92	86,63	89,66	3,237,060
InceptionResNetV2	97,81	98,41	94,80	96,57	54,349,028
EfficientNetB0	96,88	97,92	96,59	97,25	4,059,815
EfficientNetB1	97,03	98,15	91,13	94,51	6,585,483
Önerilen yöntem	98,28	99,04	98,31	98,67	943,397



Şekil 6. Önerilen yöntem için eğitim (train)-doğrulama (validation) grafikleri. Soldaki doğruluk ve sağdaki kayıp grafiği



Şekil 7. Önerilen yöntemin bileşen analizi

4. SONUÇLAR

Alzheimer Hastalığı (AH), yaşlı bireylerin yaşamlarını derinden etkileyen ciddi bir hastalıktır. AH'nin erken ve doğru teşhisi, hastalığın etkilerini

azaltmada kritik bir öneme sahiptir. Geleneksel yöntemlerle yapılan teşhislerin zorlukları göz önünde bulundurulduğunda, yapay zeka ve özellikle derin öğrenme yöntemleri AH'nin erken teşhisinde önemli bir rol oynamaktadır. Bu

çalışmada, MRG görüntüleri kullanılarak AH'yi tespit etmek ve sınıflandırmak için derin öğrenme tabanlı yeni bir yöntem geliştirilmiştir. Geliştirilen bu yöntem, Inception modülü ve sıkma-uyarma bloğunun birleşiminden oluşmaktadır. Inception modülü, (1) farklı evrimsel çekirdek boyutları kullanarak girdi görüntülerinden çeşitli ölçeklerde özellikler çıkarmaktadır. (2) 1x1 evrişim kullanarak ağın genel özellik çıkarma yeteneklerini arttırmakta ve çapraz kanal modelleri öğrenmektedir. Bu, sinir ağında yüksek doğruluk sağlamaktadır. (3) Çoklu evrimsel katmanlar kullanarak çok yönlü özellik çıkarmayı sağlamaktadır. Bu, ağın performansını arttırmakta ve yüksek doğruluk sağlamaktadır. Sıkma-uyarma bloğu ise neredeyse hiçbir ek işlem maliyeti gerektirmeden sınıflandırma görevlerinde performans artışı sağlamaktadır ve herhangi bir modele kolayca eklenebilmektedir. Önerilen yöntemin performansını değerlendirmek için, Kaggle platformunda halka açık dört sınıf içeren bir MRG veriseti üzerinde kapsamlı deneysel çalışmalar gerçekleştirilmiştir. Deneysel sonuçlarında, önerilen yöntem %98,28 doğruluk, %99,04 kesinlik, %98,31 duyarlılık ve %98,67 F1 skoru elde etmiştir. Önerilen yöntem, literatürde aynı verisetini kullanan son yıllardaki farklı çalışmalarla karşılaştırıldığında, performans açısından daha üstün sonuçlar vermiştir. Ayrıca literatürden farklı derin öğrenme tabanlı yöntemler ile yapılan kapsamlı değerlendirmeler sonucunda, önerilen yöntem daha düşük parametre sayısı ile daha başarılı sonuçlar elde etmiştir. Bu bulgular, önerilen yöntemin AH sınıflandırmasında yüksek doğruluk ve güvenilirlik sağladığını ortaya koymaktadır. Inception modülü ve sıkma-uyarma bloğunun birleşimi, modelin performansını arttırmış ve yöntemin etkili bir teşhis aracı olma potansiyelini göstermiştir. Bu, hem erken teşhis hem de tedavi sürecinde önemli katkılar sağlayabilmektedir. Bunun yanı sıra, önerilen yöntemin daha az parametre sayısı ile daha üstün sonuçlar elde etmesinin çeşitli olumlu etkileri bulunmaktadır. (1) Daha az parametre, yöntemin daha az hesaplama kaynağı gerektirmesi anlamına gelmektedir. Ayrıca, yöntemin depolama ve bellek kullanımını azaltarak kaynak tasarrufu sağlamaktadır. (2) Önerilen yöntemin daha hızlı eğitilmesini ve daha hızlı çıkarım yapmasını sağlar. Sonuç olarak, AH teşhisinde önerilen yöntem

erken teşhis için umut verici bir araç olarak kullanılabilir. Gelecek çalışmalarda, önerilen yöntemin farklı AH verisetleri üzerinde değerlendirilmesi ile ilgili çalışmalar yürütülmektedir. Ayrıca, doktorların Alzheimer hastalığını daha hızlı ve etkin bir şekilde teşhis etmesine yardımcı olacak gerçek zamanlı bir uygulamanın geliştirilmesi hedeflenmektedir.

5. KAYNAKLAR

1. Dadar, M., Pascoal, T.A., Manitsirikul, S., 2017. Validation of a Regression Technique for Segmentation of White Matter Hyperintensities in Alzheimer's Disease. *IEEE Transactions on Medical Imaging*, 36, 1758-1768.
2. Livingston, G., Sommerlad, A., Orgeta, V., 2017. Dementia Prevention, Intervention, and Care. *Lancet*, 390, 2673-2734.
3. Ahmed, G., Er, M.J., Muhammad, M., 2022. DAD-Net: Classification of Alzheimer's Disease Using Neural Network. *Molecules*, 27, 1-21
4. Tufail, Bin A., Ma, Y.K., Zhang, Q.N., 2020. Binary Classification of Alzheimer's Disease Using sMRI Imaging Modality and Deep Learning. *Journal of Digital Imaging*, 33, 1073-1090.
5. Tiwari, S., Venkata, A., Kaushik, A., 2019. Alzheimer's Disease Diagnostics and Therapeutics Market. *International Journal of Nanomedicine*, 14, 5541-5554
6. Loddo, A., Buttau, S., Di Ruberto, C., 2022. Deep Learning Based Pipelines for Alzheimer's Disease Diagnosis: A Comparative Study and a Novel Deep-ensemble Method. *Computers in Biology and Medicine*, 141, 105032.
7. El-Latif, A.A.A., Chelloug, S.A., Alabdulhafith, M., Hammad, M., 2023. Accurate Detection of Alzheimer's Disease Using Lightweight Deep Learning Model on MRI Data. *Diagnostics*, 13, 1-21.
8. Bangyal, W.H., Rehman, N.U., Nawaz, A., 2022. Constructing Domain Ontology for Alzheimer Disease Using Deep Learning Based Approach. *Electronics*, 11.
9. Balasundaram, A., Srinivasan, S., Prasad, A., 2023. Hippocampus Segmentation-Based Alzheimer's Disease Diagnosis and

- Classification of MRI Images. *Arabian Journal for Science and Engineering*, 48, 10249-10265.
10. Mohammed, B.A., Senan, E.M., Rassem, T.H., 2021. Multi-method Analysis of Medical Records and Mri Images for Early Diagnosis of Dementia and Alzheimer's Disease Based on Deep Learning and Hybrid Methods. *Electronics*, 10, 1-20.
 11. Murugan, S., Venkatesan, C., Sumithra, M.G., 2021. DEMNET: A Deep Learning Model for Early Diagnosis of Alzheimer Diseases and Dementia from MR Images. *IEEE Access*, 9, 90319-90329.
 12. Kumar, S., 2021. Alzheimer MRI Preprocessed Dataset. <https://www.kaggle.com/datasets/sachinkumar413/alzheimer-mri-dataset>. Access date: 12 October 2023.
 13. Firat, H., Emin, M., Mehmet, A., Hanbay, D., 2022 Hybrid 3D/2D Complete Inception Module and Convolutional Neural Network for Hyperspectral Remote Sensing Image Classification. *Neural Process Letters*, 1-44.
 14. Szegedy, C., Liu, W., Jia, Y., 2015. Going Deeper with Convolutions. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. IEEE Computer Society, 1-9.
 15. Hu, J., Shen, L., Sun, G., 2018. Squeeze-and-Excitation Networks. *Proc IEEE Comput Soc Conf Comput Vis Pattern Recognition*, 7132-7141.
 16. Firat, H., 2023. Classification of White Blood Cells Using the Squeeze-Excitation Residual Network. *Bilişim Teknolojileri Dergisi*, 16, 189-205.
 17. Asker, M.E., 2023. Hyperspectral Image Classification Method Based on Squeeze-and-Excitation Networks, Depthwise Separable Convolution and Multibranch Feature Fusion. *Earth Science Informatics*, 1427-1448.

Natural Dyeing of Cotton, Wool and Viscose Fabrics with Sodium Copper Chlorophyllin

Gamze GÜLŞEN BAKICI*¹ ORCID 0000-0002-4241-7096
Deniz Mutlu ALA¹ ORCID 0000-0002-5864-308X

¹Cukurova University, Adana Organized Industrial Zone Vocational School of Technical Sciences, Textile, Apparel, Footwear and Leather Department, Adana, Türkiye

Geliş tarihi: 23.04.2024 Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: GÜLŞEN BAKICI, G., ALA, D.M., (2024). Natural Dyeing of Cotton, Wool and Viscose Fabrics with Sodium Copper Chlorophyllin. Cukurova University, Journal of the Faculty of Engineering, 39(2), 569-576.

Abstract

This study investigates the optimal dyeing concentrations of cotton, wool, and viscose fabrics with sodium copper chlorophyllin (SCC). Using SSC above the optimal concentration increases the amount of SCC in the wastewater, which is a disadvantage. Pre-finished 100% cotton, wool and viscose 1 x 1 rib knitted fabrics were dyed with varying SCC concentrations. Optimal dyeing concentrations were determined using UV-Vis spectrophotometry, showing dye absorption decreasing as SCC concentration increases. Equilibrium was reached at approximately 7 ml/L for cotton and viscose, and 3 ml/L for wool. Color measurement values and K/S values of the dyed samples were obtained according to the CIELab color system. The K/S values of dyed cotton, viscose, and wool fabrics rose as the concentration of SCC increased, reaching a peak at 9 ml/L for viscose and 12 ml/L for cotton and wool. Rubbing and perspiration fastness were rated good to excellent.

Keywords: Sodium copper chlorophyllin, Natural dyeing, UV-visible spectrophotometer, Color fastness

Pamuk, Yün ve Viskon Kumaşların Sodyum Bakır Klorofil ile Doğal Boyanması

Öz

Bu çalışmanın amacı pamuk, yün ve viskon kumaşların sodyum bakır klorofil (SCC) ile optimum boyama konsantrasyonlarının araştırılmasıdır. Ön terbiyesi yapılmış %100 pamuk, yün ve viskon 1 x 1 ribana örme kumaşlar farklı SCC konsantrasyonlarıyla boyanmıştır. Optimal boyama konsantrasyonlarını belirlemek için UV-Vis spektrofotometre kullanılarak SCC konsantrasyonunun boya çekimine etkisi incelenmiştir. SSC'nin optimal konsantrasyondan fazla kullanılması bir dezavantaj olarak atık suyun SCC miktarını artırır. SCC konsantrasyonunun artmasıyla boya çekiminin azaldığı ve pamuk ve viskon için yaklaşık 7 ml/L, yün için ise 3 ml/L civarında dengeye ulaştığı görülmüştür. Numunelerin K/S değerleri ve renk ölçümleri CIELab renk sistemi kullanılarak ölçülmüştür. K/S değerleri yün kumaşlarda 12 ml/L'ye kadar, pamuk ve viskon kumaşlarda ise 9 ml/L'ye kadar artmıştır. Sürtünme ve terlemeye karşı renk haslığı değerlendirilmiş olup boyalı kumaşların haslık değerleri iyi ile mükemmel arasındadır.

Anahtar Kelimeler: Sodyum bakır klorofil, Doğal boyama, UV-vis spektrofotometre, Renk haslık

*Sorumlu yazar (Corresponding Author): Gamze GÜLŞEN BAKICI, serapakcan@tarsus.edu.tr

1. INTRODUCTION

Compared with synthetic dyes, natural dyes are known to be eco-friendly, biodegradable, less toxic and less allergenic, as they are derived from natural resources classified as plant, animal, mineral and microbial dyes [1-3]. However the use of natural dyes for textile dyeing has been dramatically cut down since the discovery of synthetic dyes in 19th century as synthetic dyes can produce a wide range of bright shades, with fairly good color fastness, dyeing reproducibility and low cost [4,5]. In recent years there is a reviving interest in the dyeing of the textile materials with natural dyes due to the increasing popularity of concept of eco-friendly textiles based on naturally sustainable goods [6-8]. There are some studies on the coloring of different types of fabrics using natural dyestuffs. Bahtiyari et. al. pigmented cotton fabrics using extracts from pomegranate peel, nutshell, orange tree leaves, alkanet roots, and dyer's chamomile via the pigment printing method [9]. In 2015, Davulcu developed polypropylene (PP) fibers dyed with natural dyes by adding hyperbranched polymer (HBP) using melt spinning. They used walnut shell, oak gall, dyer's chamomile, sage tea, and cehri as natural dye sources [10]. Tutak et. al. studied on usability pomegranate peel natural dye solution on wool fabrics [11].

In several studies textile materials are colored in variable tones of mainly yellow, red and blue colors by using the natural dyestuffs that obtained from different types of plants and insects. To obtain a green color, textile materials are usually dyed blue with indigo first and then, the mordanted material is dyed a second time with a yellow plant [12]. Natural green extracts consisting of chlorophyll molecules, which are abundant in all green plants, algae and cyanobacteria, are also used as fabric dyeing colorants [13,14]. Despite attempts to use chlorophyll as a natural green dye, it often yields a dull yellow or brownish color due to the loss of magnesium ions from the chlorophyll molecules during extraction and processing. As a derivative of natural chlorophyll, sodium copper chlorophyllin (SCC) is a natural edible pigment and a water-

soluble bright green colorant with good stability [15,16].

There are several studies which reported SCC application in dyeing textiles. Park and Park dyed cotton fabrics with natural chlorophyll derivatives (chlorophyllin, Chlin) with and without chitosan treatment to enhance textile coloration and antimicrobial activity [17]. Hou et. al., dyed silk into a bright green shade with SCC and were investigated kinetics and thermodynamics of SCC adsorption on silk in dye bath with and without sodium chloride at different temperatures [15]. Xiu-Liang et. al., were investigated the adsorption kinetics of SCC on silk fabrics and the dyeing mechanism in order to improve the dye up-taking process control and provide a theoretical guidance for dyeing process optimization of SCC on silk fabrics [18]. Zhang and Tao, studied the eco-friendly dyeing of silk fabric with SCC using different mordanting methods as well as a non-mordanting method [19]. Zhao et. al., employed ethylenediaminetetraacetic acid disodium salt and sodium citrate as additives to treat dyed cotton fabrics and studied on photofading of SCC and gardenia yellow [20]. Liu et. al., firstly used SCC as an environmentally friendly dyestuff to dye the wool fibers, then the dyed woolfibers was phosphorylated with phosphoric acid to obtain flame retardant woolfibers [16].

This study aims to explore the potential usability of sodium copper chlorophyll (SCC) as an alternative for the textile dye industry, which is actively seeking sustainable and renewable resources for textile production. The investigation focuses on its effectiveness in dyeing various types of fibers. Fabrics were pre-treated and then dyed with different concentrations of SCC without mordanting. The effect of SCC concentration on dye exhaustion was determined by spectrophotometric method in order to investigate the optimal dyeing concentrations. Color measurements and color fastness of dyed samples against rubbing and perspiration were also evaluated.

2. MATERIAL AND METHOD

2.1. Material

100% carded cotton ring spun yarn with Ne 20/1 yarn count, 100% carded viscose ring spun yarn with Ne 20/1 yarn count and 100% worsted wool yarn with Nm 5/1 yarn count were used. The yarns were knitted with flat knitting machines of 10 gauge thus 100% cotton, 100% wool and 100% viscose 1 x 1 rib fabrics were produced. Tito Co. Ltd. supplied the commercial sodium copper chlorophyll dye liquid.

2.2. Method

2.2.1. Pre-Finishing Process

The cotton fabric underwent bleaching in a laboratory-type machine at 95°C for 4 hours. The bleaching solution consisted of 6% H₂O₂, 4g/L (46°Be) NaOH, 0,5 g/L oil remover soap, 0,5 g/L anticreasing agent, 0,8 g/L ion trapping agent, 0,5 g/L wetting agent, and 0,8 g/L peroxide stabilizer. The liquor ratio was chosen to be 30:1. The fabric was rinsed and neutralized. After bleaching anti-peroxide process was applied. The pre-finishing treatment for wool and viscose fabrics was performed at 40°C for 60 minutes using a solution containing 5 g/L of oil remover soap in a laboratory dyeing machine, with a liquor-to-goods ratio of 30:1.

2.2.2. Dyeing Process

The dyeing of cotton, viscose and wool fabrics were carried out in exhaust dyeing method with a laboratory-type dyeing machine at 60°C for 60 minutes at a liquor-to-goods ratio of 10:1. Dyeing was done with different concentrations of SCC as given in Table 1. The fabric underwent two cold-water washes and was then dried under room temperature conditions.

Table 1. SCC concentrations

Sample code			SCC Conc. (ml/L)
Cotton	Viscose	Wool	
C1	V1	W1	1
C3	V3	W3	3
C5	V5	W5	5
C7	V7	W7	7
C9	V9	W9	9
C12	V12	W12	12

2.2.3. Dye Exhaustion

The method employed with a Shimadzu UV-1800 UV/VIS spectrophotometer (Eksoy Company, Turkey) relies on an absorbance-concentration curve generated using dye solutions of known concentrations. This curve is then used to determine the concentration of a dye solution with an unknown concentration. Maximum absorption wavelength (λ_{max}) was identified as 626.5 nm. Calibration curve is given in Figure 1. As seen in Figure 1, it is observed that the absorption values of the dye solutions increase linearly with the increase in dye concentrations.




Figure 1. Calibration curve

The exhausted and unexhausted amounts of SCC were determined by calculating the difference in dye concentration in the dyebath before and after dyeing. The percentile of exhausted dye was calculated with Equation (1) by the initial and ultimate concentrations of the dye bath;

$$\text{Dye Exhaustion (\%)} = \left[\frac{(C_b - C_a)}{C_b} \times 100 \right] \quad (1)$$

C_b represents the initial concentration of the dye bath, while C_a denotes the final concentration of the dye bath [21].

2.2.4. Color Measurements & Color Strength

K/S values and the CIELab color values of the dyed samples were measured by Datacolor 850 spectrophotometer (Eksoy Company, Turkey) using an illuminant D65 and 10° standard observer. Total colour difference ΔE [equation (1)] is calculated to determine the color difference between reference sample and other samples [14].

$$\Delta E = ((\Delta a^2) + (\Delta b^2) + (\Delta L^2))^{1/2} \tag{2}$$

$$K/S = (1-R)^2/2R \tag{3}$$

where, R=reflectance, K=absorption coefficient and S=scattering coefficient of dye [22].

2.2.5. Fastness Tests

Color fastness tests to rubbing and perspiration of dyed fabric samples were evaluated according to ISO 105-X12 and ISO 105-E04, respectively.

3. RESULTS AND DISCUSSION

3.1. Dye Exhaustion

To investigate the effects of SCC concentration on the dye exhaustion and K/S values of dyed samples, cotton, viscose and wool fabrics were dyed with different concentrations of SCC as indicated in the experimental section. The results obtained are represented in Table 2.

As seen in Table 2, with increase in the SCC concentration, the amount of exhausted SCC increases. It is expected that the exhausted amount of SCC should increase with increase in the amount of SCC particles available for sorption in the dyeing bath. But percentile value of the dye exhaustion decreases with increase in the SCC concentration, till it reaches the optimum concentration. This situation was considered as the saturation of the fibers in terms of dye uptake in a certain time with

the increasing amount of dye molecules in the dyeing bath and less space should left for the remaining dwangye molecules to diffuse into the inner area of fibers. Table 2 indicates that the percentile value of dye exhaustion decreased with an increase in the SCC concentration and reached equilibrium when the SCC concentration is about 7 ml/L for cotton, 7 ml/L for viscose and 3 ml/L for wool fabrics. More increase in the SCC concentration should result the increase in the amount of SCC that should remain in the effluent. That means the load of unexhausted dye remaining in the effluent can be reduced using a maximum amount of 7 ml/L concentration of SCC while dyeing cotton, 7 ml/L concentration of SCC while dyeing viscose and 3 ml/L concentration of SCC while dyeing wool.

Table 2. Effect of concentration of SCC on dye exhaustion and K/S of the dyed cotton, viscose and wool fabrics

Sample code	SCC Conc. (ml/L)	Dye Exhaustion		Unexhausted Dye (mL)	K/S
		(%)	(mL)		
Cotton	C1	1	50,00	0,5	0,35
	C3	3	30,00	0,9	0,67
	C5	5	24,00	1,2	0,84
	C7	7	14,29	1,0	6,0
	C9	9	16,67	1,5	7,5
	C12	12	15,83	1,9	10,1
Viscose	V1	1	40,00	0,4	0,45
	V3	3	26,66	0,8	0,79
	V5	5	20,00	1,0	0,91
	V7	7	15,71	1,1	5,9
	V9	9	17,77	1,6	7,4
	V12	12	15,00	1,8	10,2
Wool	W1	1	50,00	0,5	0,67
	W3	3	40,00	1,2	1,8
	W5	5	40,00	2,0	3,0
	W7	7	37,14	2,6	4,4
	W9	9	40,00	3,6	5,4
	W12	12	41,66	5,0	7,0

3.2. Color Measurement & Color Strength

To investigate the effects of SCC concentration on the color parameter and color difference, the

CIELab system was used. C7, V7 and W3 were taken as reference samples in the color measurement results of the cotton, viscose and wool fabrics as the percentile dye exhaustion reached equilibrium when the SCC concentration is about 7 ml/L for cotton, 7 ml/L for viscose and 3 ml/L for wool fabrics. As seen in Table 3, L* refers to the lightness-darkness values from 100 to 0, representing white to black. Both the a* value and b* value denote the red-green values that run from negative (green) to positive (red) and the yellow-blue values that run from negative (blue) to positive (yellow) respectively. Characteristic value c* represents the chroma or purity of the color. The dyed cotton and viscose fabrics showed L* values close to each other, while wool fabrics showed lower L* values causing darkness compared to cotton and wool fabrics. Moreover an increase in the SCC concentration of dyeing cotton, viscose and wool fabrics caused similar trends in terms of L*, a*, b*, C* and ho values. In Table 3, the L* value increased when the SCC concentration changed from 1 ml/L to 3 ml/L, but decreased with more increase in the SCC concentration. When calculating the color difference, ΔE , from the reference samples using the L*, a* and b* value, the color difference was higher while dyeing with lower concentrations of SCC than dyeing with higher concentrations of SCC

The K/S values of cotton, viscose and wool fabrics were in a range of 0.35 – 1.11, 0.45 – 0.90 and 0.67 – 1.37 respectively. This indicates that viscose fabric was dyed a deeper color than cotton and wool fabric was dyed a deeper color than viscose. It is clear from Table 3 that the value of K/S depends on the concentration of the SCC used as well as the origin of the fibre. The results revealed that K/S increases with the increased percentage of SCC concentration. This may possibly be due to the increasing amount of dye molecules in the dyeing bath that should be exhausted. The maximum K/S values were obtained at 9 ml/L concentration of SCC while dyeing viscose and 12 ml/L concentration of SCC while dyeing cotton and wool.

Table 3. Effect of concentration of SCC on dye exhaustion of the dyed cotton, viscose and wool fabrics

Sample code	L*	a*	b*	ΔE	K/S	
Cotton	C1	85,22	-5,41	8,49	4,67	0,35
	C3	80,11	-7,45	9,34	2,11	0,67
	C5	78,00	-8,27	9,32	1,06	0,84
	C7	76,52	-9,33	9,46		
	C9	76,75	-8,23	9,26	0,93	0,93
	C12	75,41	-9,76	9,19	0,64	1,11
Viscose	V1	83,69	-4,85	9,19	3,39	0,45
	V3	79,05	-6,59	9,57	1,19	0,79
	V5	77,53	-6,77	9,01	0,42	0,91
	V7	76,49	-6,88	8,92		
	V9	76,87	-7,03	8,51	0,45	0,96
	V12	77,41	-6,81	8,29	0,65	0,90
Wool	W1	76,39	-6,34	14,24	2,84	0,67
	W3	72,25	-8,90	13,65		
	W5	70,43	-9,75	13,33	1,07	1,16
	W7	69,55	-10,32	12,93	1,77	1,26
	W9	68,94	-10,22	12,78	1,92	1,31
	W12	68,29	-9,64	12,74	1,84	1,37

3.3. Color Fastness Test Results

Table 4, 5 and 6 outlines the color fastness results to rubbing (dry and wet) and perspiration (acidic and alkaline) of cotton, wool and viscose fabrics dyed with different concentrations of SCC without mordanting. As expected the grades of color fastness to rubbing for the dry test are higher than the grades for the wet test. Color fastness to rubbing for wet test of wool samples ranged 4/5, which were mostly higher than than the cotton and viscose fabrics (ranged grade from 3/4 to grade 4/5). All of the fabrics showed excellent grades of color fastness to rubbing for the dry test (grade 5). In terms of the gray scale assessment, the grades of staining of perspiration fastness on all the dyed cotton, viscose and wool fabrics revealed good fastness with a grade range between 4/5 and 5 both for acidic and alkaline medium, while the grades of color change ranged between 3/4 to 5. From the color fastness test results it can be concluded that SCC dye exhibits good fastness to rubbing and objective fastness to perspiration.

Table 4. Color fastness to perspiration (acidic)

Sample code	Acidic						Change
	Color staining*						
	1	2	3	4	5	6	
C1	5	4/5	5	5	5	5	4/5
C3	5	4/5	5	5	5	5	4/5
C5	5	4/5	5	5	5	5	4/5
C7	5	4/5	5	5	5	5	5
C9	5	4/5	5	5	5	5	5
C12	5	4/5	5	5	5	5	5
V1	5	5	5	5	5	5	5
V3	5	5	5	5	5	5	5
V5	5	5	5	5	5	5	4
V7	5	4/5	4/5	4/5	5	4/5	4
V9	5	4/5	4/5	4/5	4/5	4/5	3/4
V12	5	4/5	4/5	4/5	4/5	4/5	4
W1	5	5	5	5	5	5	4/5
W3	5	5	5	5	5	5	4/5
W5	5	5	5	5	5	5	4/5
W7	5	5	5	5	5	5	4/5
W9	5	5	5	5	5	5	5
W12	5	4/5	4/5	4/5	5	4/5	5

*Multifiber (1-Acetate, 2-Cotton, 3-Polyamide, 4-Polyester, 5-Acrylic, 6-Wool)

Table 5. Color fastness to perspiration (alkaline)

Sample code	Alkaline						Change
	Color staining*						
	1	2	3	4	5	6	
C1	5	5	5	5	5	5	4/5
C3	5	5	5	5	4/5	5	4/5
C5	5	5	5	5	4/5	5	4/5
C7	5	5	5	5	4/5	5	4/5
C9	5	5	4/5	4/5	4/5	4/5	4/5
C12	4/5	4/5	4/5	4/5	4/5	4	4/5
V1	5	5	5	5	5	5	4/5
V3	5	5	5	5	5	5	4/5
V5	5	4/5	4/5	4/5	5	5	3/4
V7	5	4/5	4/5	4/5	5	4/5	3/4
V9	5	4/5	4/5	4/5	5	4/5	3/4
V12	5	4/5	4/5	4/5	5	4/5	4
W1	5	5	5	5	5	5	4/5
W3	5	4/5	4/5	4/5	4/5	5	4/5
W5	5	4/5	4/5	4/5	4/5	5	4/5
W7	5	4/5	4/5	4/5	4/5	5	4/5
W9	5	5	4/5	4/5	4/5	5	5
W12	5	5	5	5	5	4/5	4/5

*Multifiber (1-Acetate, 2-Cotton, 3-Polyamide, 4-Polyester, 5-Acrylic, 6-Wool)

Table 6. Color fastness to rubbing

Sample code	Rubbing	
	Dry	Wet
C1	5	4/5
C3	5	4/5
C5	5	4
C7	5	4
C9	5	4
C12	5	3/4
V1	5	4/5
V3	5	4
V5	5	3/4
V7	5	3/4
V9	5	3/4
V12	5	3/4
W1	5	4/5
W3	5	4/5
W5	5	4/5
W7	5	4/5
W9	5	4/5
W12	5	4/5

4. CONCLUSION

The effects of SCC concentration on the dye exhaustion and color parameters in dyeing cotton, viscose and wool fabrics has been studied. Fabrics were pre-treated and then dyed with different concentrations of SCC without mordanting. The dye exhaustion values which were determined by spectrophotometric method indicates that the percentile dye exhaustion decreased with an increase in the SCC concentration and reached equilibrium when the SCC concentration is about 7 ml/L for cotton, 7 ml/L for viscose and 3ml/L for wool fabrics. More increase in the SCC concentration results with an increase in the amount of SCC that should remain in the effluent. The K/S values of dyed cotton, viscose and wool fabrics increased with increasing the concentration of SCC up to 9 ml/L while dyeing viscose and up to 12 ml/L while dyeing cotton and wool. The fastness ratings to rubbing and perspiration of cotton, viscose and wool fabrics dyed with different concentrations of SCC are good to excellent. Only in few cases color fastness to rubbing for wet test and color change after the color fastness to perspiration were observed fair to good level. Based on the color fastness results, it can be said that the fastness values of the SCC are suitable for the dyeing process.

5. ACKNOWLEDGEMENT

This work was supported by the Research Fund of Çukurova University (Project Number: FBA-2018-10278). The authors wish to thank to Eksoy Chemical Industry, Turkey.

6. REFERENCES

1. Ali, S., Nisar, N., Hussain, T., 2007. Dyeing Properties of Natural Dyes Extracted from Eucalyptus. *The Journal of the Textile Institute*, 98(6), 559-562.
2. Tayade, P.B., Adivarekar, R.V., 2013. Dyeing of Cotton Fabric with Cuminum cyminum L. as a Natural Dye and its Comparison with Synthetic Dye. *The Journal of the Textile Institute*, 104(10), 1080-1088.
3. Mansour, R., Ezzili, B., Farouk, M., 2017. The use of Response Surface Method to Optimize the Extraction of Natural Dye from Winery Waste in Textile Dyeing. *The Journal of the Textile Institute*, 108(4), 528-537.
4. Giacomini, F., Menegazzo, M.A.B., Santos, J.C.O., Arroyo, P.A., Barros, M.A.S.D., 2016. Ecofriendly Dyeing of Silk with Extract of Yerba Mate (*Ilex Paraguariensis*). *Textile Research Journal*, 87(7), 829-837.
5. Jiang, H., Hu, X., Meena, B.I., Khan, A., Hussain, M.T., Yao, J., Wang, J., 2019. Extraction of Natural Dyes from the Stem of *Caulis Spatholobi* and their Application on Wool. *Textile Research Journal*, 89(23-24), 5209-5217.
6. Kumbasar, E.P.A., Atav, R., Bahtiyari, M.İ., 2009. Effects of Alkali Proteases on Dyeing Properties of Various Proteinous Materials with Natural Dyes. *Textile Research Journal*, 79(6), 517-525.
7. Safapour, S., Sadeghi-Kiakhani, M., Doustmohammadi, S., 2019. Chitosan-cyanuric Chloride Hybrid as an Efficient Novel Bio-mordant for Improvement of Cochineal Natural Dye Absorption on Wool Yarns. *The Journal of the Textile Institute*, 110(1), 81-88.
8. Li, K., Ding, Q., Zhang, H., 2022. Eco-friendly Dyeing of Cotton Fabric Using Natural Dye from Orange Peel. *The Journal of the Textile Institute*, 113(3), 360-366.
9. Bahtiyari, M.İ., Benli, H., Yavaş, A., Akça, C., 2017. Use of Different Natural Dye Sources for Printing of Cotton Fabrics. *Textile and Apparel*, 27(3), 259-265.
10. Davulcu, A., 2015. Investigation the Dyeability of Hyperbranched Polymer Modified Polypropylene Fibers with Natural Dyes. *Textile and Apparel*, 25(1), 73-79.
11. Tutak, M., Acar, G., Akman, O., 2014. Natural Dyeing Properties of Wool Fabrics by Pomegranate (*Punica granatum*) Peel. *Textile and Apparel*, 24(1), 81-85.
12. Deveoğlu, O., Karadağ, R., 2011. Genel Bir Bakış: Doğal Boyarmaddeler. *Marmara Üniversitesi Fen Bilimleri Dergisi*, 23(1), 21-32.
13. Yoo, H.J., Ahn, C., Narantuya, L., 2013. Extractions of Chlorophyll from Spinach and Mate Powders and their Dyeability on Fabrics. *Journal of the Korean Society of Clothing and Textiles*, 37(3), 413-423.
14. Usop, R., Abidin, Z.H.Z., Mazni, N.A., Hadi, A.N., 2016. The Colour Stability of Natural Dye Coating Films Consisting of Chlorophyll after Exposed to UV-A. *Pigment & Resin Technology*, 45(3), 149-157.
15. Hou, X., Yang, R., Xu, H., Yang, Y., 2012. Adsorption Kinetic and Thermodynamic Studies of Silk Dyed with Sodium Copper Chlorophyllin. *Industrial & Engineering Chemistry Research*, 51(25), 8341-8347.
16. Liu, Y., Guo, Y., Ren, Y., Wang, Y., Guo, X., Liu, X., 2020. Phosphorylation of Sodium Copper Chlorophyll Enables Color-fasten and Durable Flame Retardant Wool Fibers. *Polymer Degradation and Stability*, 179, 109286.
17. Park, S.J., Park, Y.M., 2010. Eco-dyeing and Antimicrobial Properties of Chlorophyllin Copper Complex Extracted from *Sasa Veitchii*. *Fibers and Polymers*, 11(3), 357-362.
18. Xiu-liang, H., Rui-ling, Y., Xin-zi, C., Yi-qi, Y., 2012. Dyeing Kinetics of Sodium Copper Chlorophyll on Silk. *Natural Product Research & Development*, 24, 312-315.

19. Zhang, J., Tao, R., 2014. Eco-friendly Dyeing of Silk Fabric with Sodium Copper Chlorophyll. *Advanced Materials Research*, 941, 1313-1316.
20. Zhao, Z., Zhang, M., Hurren, C., Zhou, L., Wu, J., Sun, L., 2020. Study on Photofading of Two Natural Dyes Sodium Copper Chlorophyllin and Gardenia Yellow on Cotton. *Cellulose*, 27(14), 8405-8427.
21. Yolacan, G., 2009. Effects of Alkali Pre-treatment on Dye Exhaustion, Color Values, Color Fastness, Tensile and Surface Properties of Lyocell Yarns. *Fibers and Polymers*, 10, 625-635.
22. Usop, R., Abidin, Z.H.Z., Mazni, N.A., Hadi, A.N., Halim, N.A., Taha, R.M., Arof, A.K., 2016. The Colour Stability of Natural Dye Coating Films Consisting of Chlorophyll After Exposed to UV-A. *Pigment & Resin Technology*, 45(3), 149-157.
23. Periyasamy, A.P., 2022. Natural Dyeing of Cellulose Fibers Using Syzygium Cumini Fruit Extracts and a Bio-mordant: A Step Toward Sustainable Dyeing. *Sustainable Materials and Technologies*, 33, e00472.

Çukurova Üniversitesi Mühendislik Fakültesi Dergisi Yazım Kuralları

Çukurova Üniversitesi Mühendislik Fakültesi Dergisi mühendislik bilimlerindeki güncel bilimsel ve teknik gelişmeleri araştırmacılara ve mühendislere ulaştırmayı hedeflemektedir. Tüm mühendislik alanları ile ilgili teorik/deneysel ve uygulamaya yönelik çalışmalar Dergi'nin ilgi alanındadır. Çukurova Üniversitesi Mühendislik Fakültesi Dergisi daha önce başka hiçbir yerde yayımlanmamış, özgün ve güncel bilimsel araştırma ve uygulamaları içeren makale ve kısa bildirimleri ile Dergi'de daha önce yayımlanmış makalelerle ilgili tartışmaları kabul etmektedir. Çeviri ve derleme makaleler kabul edilmemektedir. Makaleler Türkçe veya İngilizce olabilir. Dergi'ye gönderilen yazılar yayınlansın veya yayınlansın iade edilmez. Makaleleri yayınlama yetkisi dergi yayın kuruluna aittir.

Makalenin tamamı bilgisayar ortamında hazırlanmalı baskıya hazır biçimde iki adet (birisinde yazar adları ve adresleri olmamak üzere) **Dergi web sayfasında verilen örnek şablona uygun hazırlanmış olarak elektronik ortamda veya e-posta ekinde gönderilmelidir.**

Makale, A4 (210x297 mm) boyutlu kağıda, Windows uyumlu Word ortamında, Times New Roman font kullanılarak, birer aralıkla yazılmalı, ana başlıklar 12 Punto (koyu), yazar adları 12 Punto (koyu), alt başlıklar ve metin 10 punto olmalıdır.

Çizimler ve çizelgelerle birlikte, makaleler 15 sayfadan, kısa bildirimler 4 sayfadan daha uzun olmamalıdır. **Makale Türkçe ise: Türkçe Başlık, İngilizce Başlık, Öz, Anahtar Kelimeler, Abstract** (İngilizce öz), **Keywords, Metin, Semboller** (gerekliyse), **Teşekkür** (gerekliyse) ve **Kaynaklar**,

Makale İngilizce ise: İngilizce Başlık, Türkçe Başlık, Abstract, Keywords, Öz (Türkçe öz), **Anahtar Kelimeler, Text, Notations** (gerekliyse), **Acknowledgments** (gerekliyse) ve **References** sırası içinde düzenlenmelidir.

Başlık kısa ve açık olmalı, içeriği yansıtılabilmelidir. **Öz** (ve **Abstract**) çalışmanın amacını, kapsamını, yöntemini ve ulaşılan sonuçları kısaca tanımlamalı ve 150 kelimeyi aşmamalıdır. En az üç, en fazla beş tane anahtar kelime verilmelidir. Başlık, Öz ve İngilizce başlıklı Abstract birinci sayfaya sığdırılmalı ve ana metin ikinci sayfadan başlatılmalıdır. **Metin** yalnız bir dil ve anlatımla yazılmalı, makale Türkçe ise Türkçe, makale İngilizce ise İngilizce yazım kurallarına uygun olmalıdır.

Bölüm ve alt bölüm başlıkları numaralanmalıdır. Denklemler numaralanmalı ve bu numaralar satır sonunda parantez içinde gösterilmelidir. Yazılarda yalnızca SI birimleri kullanılmalıdır. Semboller uluslararası kullanıma uygun seçilmeli; her bir sembol ilk kullanıldığı yerde tanımlanmalıdır. Teşekkür olabildiğince kısa olmalı, çalışmaya katkısı ve desteği bulunan kişi ve kuruluşlar belirtilmelidir. Çizelgeler, çizimler ve fotoğraflar metin içine yerleştirilmeli, her birine numara ve başlık verilmeli ve başlıklar çizim ve fotoğrafların altına, çizelgelerin üstüne yazılmalıdır.

Kaynaklar metinde köşeli parantez içinde numaralanmalı ve kaynaklar listesinde metin içinde veriliş sırasına uygun biçimde belirtilmelidir. Etik kuralları gereğince, alıntılar tırnak içinde verilmeli ve bir referans numarası ile kaynak belirtilmelidir. Kaynaklarda şu bilgiler verilmelidir:

Makale ise: Yazar(lar)ın soyadı, adının baş harfi., yıl. makalenin tam başlığı. derginin adı, cilt, sayı, başlama ve bitiş sayfaları.

Kitap ise: Yazar(lar)ın soyadı, adının baş harfi., yıl. kitabın tam adı. cilt numarası, varsa editörü, yayımlandığı yer, son sayfa no.

Bildiri ise: Yazar(lar)ın soyadı, adının baş harfi., yıl. bildirim tam başlığı. konferansın adı, yapıldığı yer.

Elektronik ortamdan alınmış ise: Bildiri sadece CD/DVD'de yayınlanmış ise: Yazar(lar)ın soyadı, adının baş harfi., diğer yazarlar, yıl, bildirim adı. konferansın adı (CD/DVD), yapıldığı yer, yıl. "Konferansın adından hemen sonra parantez içerisinde CD/DVD olduğu belirtilecektir."

Tez ise: Yazarın soyadı, adının baş harfi., yıl. tezin adı. derecesi, sunulduğu kurum, son sayfa no.

Rapor ise: Yazarın soyadı, adının baş harfi., diğer yazarlar, yıl. raporun adı. türü, numarası, kuruluşun adı, yayımlandığı yer.

Web Sitesi ise: Yazar(lar) belli ise; yazarın soyadı, adının baş harfi., diğer yazarlar, varsa yayımlandığı yıl. yazımın başlığı, web adresi (<http://www.xxxxx.xxx.xxx>), Erişim Tarihi: gün.ay.yıl.

Kurum/Kuruluşlara ait ise: Kurum adı, varsa yayımlandığı yıl. yazımın başlığı, web adresi (<http://www.xxxxx.xxx.xxx>), Erişim Tarihi: gün.ay.yıl.

Elektronik kitap/rapor ise: Yazar(lar)ın soyadı, adının baş harfi veya kitap/raporu yayımlayan kurum veya kuruluşun adı, varsa yayımlandığı yıl, konunun tam adı, Erişim Tarihi: gün.ay.yıl.