



Dicle Üniversitesi
Mühendislik Fakültesi

mühendislikdergisi
journal of engineering

Dicle Üniversitesi Mühendislik Fakültesi
mühendislikdergisi
Cilt: 15, Sayı: 4, Aralık 2024 ISSN: 1309-8640

Dicle Üniversitesi Adına yayın Sahibi / Privilige Owner

Mehmet Sıraç ÖZERDEM

Baş Editör / Editor-in-Chief

Mehmet Sıraç ÖZERDEM

Alan Editörleri / Field Editors

Abdurrahman Saydut
Muhammet Ali Arserim
Abdulnasır Yıldız
Hüseyin Fırat
Mustafa Cansız
Mehmet Emin Öncü
Hüseyin Acar
Atilla Gence Devecioğlu
Fevzi Önen
İdris Bedirhanoğlu
Hasan Polat
Erkan Bahçe
Zeynel Fuat Toprak
Erhan Çetin
Halime Abakay Temel
Nurtekin Özen

Tasarım-Dizgi / Designing-Editing

Mesut ŞEKER

Yazışma Adresi

Mühendislik Dergisi, Koordinatörlük ve Yayın Bürosu,
Dicle Üniversitesi, Mühendislik Fakültesi, 21280 Diyarbakır
Telefon : +90-412 241 10 00 (Dahili: 3637)
Elektronik posta : muhendislikdergisi@dicle.edu.tr
web : <http://dergipark.gov.tr/dumf>, <https://duje.dicle.edu.tr/journal/>

Dergide yayınlanan yazılar izinsiz başka bir yerde yayınlanamaz veya bildiri olarak sunulamaz.

ISSN Basılı Materyal: 1309-8640

Online ISSN: 2146-4391

Hakem Listesi / Reviewers List

Dergimize yayınlanmak üzere gönderilmiş olan makaleleri titiz bir şekilde değerlendiren kıymetli hakem hocalarımıza, değerli katkılarından dolayı teşekkür eder, katkılarının devamını dileriz.

We greatly appreciate the contributions made by the scientists, who worked as reviewers for Dicle University Journal of Engineering (DUJE) and we expect their contributions to the following journal issues.

Tevfik Ağa ayak (Konya Teknik  niversitesi)

Kiraz E meli (Konya Teknik  niversitesi)

Taner Tuncer (Fırat  niversitesi)

Emine Cengiz (Yalova  niversitesi)

Mahmut Ađralı (İzmir YTE)

Salih Taha Alperen  z elik (Bing l  niversitesi)

Orhan Atilla (Fırat  niversitesi)

Durmu  Karabacak (Muđla Sıtkı Ko man  niversitesi)

Sebahat Altundađ (İn n   niversitesi)

Murat Batan (Batman  niversitesi)

 merul Faruk Dursun (İn n   niversitesi)

Ali Mortazavi (İzmir Demokrasi  niversitesi)

 ađın Kandemir  ava  (Dokuz Eyl l  niversitesi)

S leyman Mete (Gaziantep  niversitesi)

Yıldıray Yiđit (Bitlis Eren  niversitesi)

Ali H sn  Bademliođlu (Bursa Teknik  niversitesi)

Nurettin Yamankaradeniz (Uludađ  niversitesi)

Veysel Aslan (Harran  niversitesi)

Nurtekin  zen (Fırat  niversitesi)

Gonca  zer (Bing l  niversitesi)

Kadir Turgut (İstanbul Kent  niversitesi)

Bihter Da  (Fırat  niversitesi)

Medine İspir Arslan (ITU)

Anıl  zdemir (Gazi  niversitesi)

G kmen  zt rkmen (Gaziantep  niversitesi)

G khan Kahraman (Munzur  niversitesi)

Ekrem Ta g n (Adıyaman  niversitesi)

Menderes Kam (D zce  niversitesi)

Mahmut Uyar (Siirt  niversitesi)

Erkut Sayın (Fırat  niversitesi)

Deniz G lba ı (Sivas Cumhuriyet  niversitesi)

Mustafa Kumral (McGill  niversitesi)

Tuna Aydın (Kırıkkale Üniversitesi)
Zahide Bayer Öztürk (Nevşehir Üniversitesi)
Aslı Çakır Arianpour (Kastamonu Üniversitesi)
Volkan Arıkan (Osmaniye Korkut Ata Üniversitesi)
Umut Ercan (Batman Üniversitesi)
Murat Çağlayan (Mardin Artuklu Üniversitesi)
Aslıhan Ece Paköz (Mardin Artuklu Üniversitesi)
Ali Em (DU)
Tamer Bağatur (DU)
Halil Görgün (DU)
Özgür Akkoyun (DU)
Halime Abakay Temel (DU)
Fatma Deniz Öztürk (DU)
Hüseyin Fırat (DU)
Recep Çelik (DU)
Tamer Bağatur (DU)
Hüseyin Fırat (DU)
Fevzi Önen (DU)

İçindekiler / *Table of Contents*

Elektrik Elektronik Mühendisliği / Electrical and Electronics Engineering

- Detection of RPL-based Routing Attacks Using Machine Learning Algorithms
(Research Article)
Burak Aydın, Hakan Aydın, Sedat Görmüş, Emin Mollhasanoğlu **783**
- Polyp Segmentation with Deep Learning: Utilizing DeeplabV3+ Architecture and Various CNN Backbones (Research Article)
Yaren Akgöl, Buket Toptaş **797**
- Makine Öğrenmesi Teknikleri ile İşten Ayrılacak Personelin Tahminlenmesi ve Tekniklerin Performanslarının Karşılaştırılması (Araştırma Makalesi)
Prediction of Staff Turnover by Machine Learning Techniques and Comparison of the Performances of Techniques (Research Article)
Batuhan Bilenler, Sait Gül, Tamer Uçar **807**
- Temperature Prediction of Lithium-ion Battery by CPSO-UKF (Research Article)
Göksu Taş **817**
- Beton çatlakların derin öğrenme tabanlı Long-Term Prediction of Coronary Artery Disease via Ensemble Machine Learning Algorithms (Research Article)
Şehmus Aslan **827**
- A Novel DNA Classification Experiment: Spatial Transcriptomics Analysis for Human Monkeypox DNA-Motifs with Kolmogorov–Arnold Networks (Research Article)
Selçuk Yazar **839**

Makina Mühendisliği / Mechanical Engineering

- Farklı Gölgeleme Özelliğine Sahip Binaların Enerji İhtiyacına Bağlı Isı Yayıma Sisteminin Ekserji İncelemesi (Araştırma Makalesi)
Exergy Analysis of Heat Dissipation System Based on Energy Requirement of Buildings with Different Shading Properties (Research Article)
Okan Kon **853**
- Türkiye'nin Farklı Derece Gün Bölgelerinde Isı Pompası Kullanıldığında Optimum Yalıtım Kalınlığının Belirlenmesi ve Ekonomik Analizi (Araştırma Makalesi)
Determination of Optimum Insulation Thickness and Economic Analysis for Heat Pump Application in Different Degree Day Regions of Turkey (Research Article)
Atilla G. Devocioğlu, Uğur Yaman, Vedat Oruç **863**
- Experimental Research of the Influence of Fiber Laser Machining Parameters on HAZ Width in AISI 4140 Steels (Research Article)
Mehmet Şükrü Adin **873**
- Numerical Analysis of Dual Slot Pulsating Nanofluid Impinging Jets
(Research Article)
Ali Taşkıran, Celal Kıstak, Sinan Kapan, Nevin Çelik, İhsan Dağtekin **881**

Investigation of The Effect of Radius of Curvature on Buckling Load in Thin-Walled Beams
(Research Article)
Cenk Yanen **891**

Maden Mühendisliği / Mining Engineering

Ultrasonik Emülsifikasyonun Kömürün Yağ Aglomerasyonuna Etkisi (Araştırma Makalesi)
Effect of Ultrasonic Emulsification on Oil Agglomeration of Coal (Research Article)
Ercan Şahinoğlu **899**

Demir Tenör Değerlerinin Kestiriminde Makine Öğrenme Yöntemlerinin Karşılaştırılması
(Araştırma Makalesi)
*Comparison of Machine Learning Methods in Estimation of Iron Grade Values
(Research Article)*
Fırat Atalay **907**

Magnezyum oksit içeren hammaddelerin porselen izolatör bünyesi teknik özellikleri
üzerine olan etkisi (Araştırma Makalesi)
*Effect of magnesium oxide containing raw materials on the technical properties of
porcelain insulator body (Research Article)*
Ceyda Ayça Avcı, Şefik Baran Tarhan **917**

İnşaat Mühendisliği / Civil Engineering

Standart Kuraklık İndeksleri İle Kuraklık Analizi: Konya Kapalı Havzası Örneği
(Araştırma Makalesi)
*Drought Analysis with Standard Drought Indices: The Case of Konya Closed Basin
(Research Article)*
Arman Uçar, Ebru Eriş, Fevzi Önen **925**

The Impact of Isolation Parameters on Structural Responses due to Strong Earthquake
Motion Processed by DWT (Research Article)
Elif Çağda Kandemir **933**

CBS Tabanlı AHP Çok Kriterli Karar Verme Yöntemi (ÇKKVY) Kullanılarak Van Gölü
Güzelsu Alt Havzası Taşkın Risk Haritalarının Çıkarılması ve Değerlendirilmesi
(Araştırma Makalesi)
*Evaluation and Mapping of Flood Risk In Van Lake Güzelsu Sub-Basin Using GIS Based
AHP Multiple Criteria Decision Making (MCDM) Method (Research Article)*
Erdi Tanış, Recep Çelik **941**

Geleneksel Yapılarda Kullanılan Kerpiç Malzemenin SEM-EDX Analizlerinin
Değerlendirilmesi: Diyarbakır Karaçalı (Tilalo) Mahallesi'ndeki Güvercin Evleri
(Boranhane) Örneği (Araştırma Makalesi)
*Evaluation of SEM-EDX Analysis of Adobe Material Used in Traditional Buildings: The
Example of Pigeon Houses (Boranhane) in Diyarbakır Karaçalı (Tilalo) Neighborhood
(Research Article)*
Berfin Aydınalp, Nursen Işık **951**

Mechanical and microstructural properties of stone units in the masonry building stock of Urla peninsula (Research Article) Uğur Demir	963
Hareketli tabana sahip T-bağlantılı kanal sisteminde akım ve taban özelliklerinin nümerik incelenmesi (Araştırma Makalesi) <i>Numerical investigation of flow and bed features at a T-linked channel system with mobile-bed (Research Article)</i> Fırat Gümgüm	971
Comparative Analysis of HEC-RAS, SWMM, and THDH Approaches in Highway Culvert Design (Research Article) Kağan Cebe, Ömer Bilhan, Renan Sınanmış Balcı	977
Birleşik deprem etkilerinin ve ek dışmerkezliğin betonarme binaların davranışına etkisi (Araştırma Makalesi) <i>Effect of combined earthquake effects and additional eccentricity on the behaviour of reinforced concrete buildings (Research Article)</i> Gürkan Tam, Burak Yön	993
Geleneksel Urfa Evlerinin Yapım Teknikleri: Temeller ve Duvarlar (Araştırma Makalesi) <i>Construction Techniques of Traditional Urfa Houses: Foundations and Walls (Research Article)</i> Şeyda İnce Gayberi, Neslihan Dalkılıç	1003

Dicle Üniversitesi Mühendislik Fakültesi (DÜMF) Mühendislik Dergisi yayınlarında varılan sonuçlar veya fikirlerin sorumluluğunu taşımamaktadır. Üniversite'nin, bu yayında ileri sürülen bilgi, alet, ürün veya işlevin doğruluğu, bütünlüğü, uygunluğu ve kullanılabilirliği konusunda bir yüklenimi ve iddiası bulunmamaktadır. Bu nedenle herhangi bir şekilde sorumlu tutulamaz.

Bu yayının herhangi bir kısmı, mühendislik dergisinin yazılı izni olmadıkça kaynak gösterilmeden yayınlanamaz, bilgi saklama sistemine alınamaz veya elektronik, mekanik, fotokopi, kayıt veya başka sistemlerle çoğaltılamaz.



Detection of RPL-based Routing Attacks Using Machine Learning Algorithms

Burak AYDIN^{1*}, Hakan AYDIN², Sedat GÖRMÜŞ³, Emin MOLLAHASANOĞLU⁴

¹ Karadeniz Technical University, Computer Engineering Department, burakaydin@ktu.edu.tr, Orcid No: 0000-0002-5377-4590

² Karadeniz Technical University, Computer Engineering Department, hakanaydin@ktu.edu.tr, Orcid No: 0000-0002-4057-3693

³ Karadeniz Technical University, Computer Engineering Department, sedatgormus@ktu.edu.tr, Orcid No: 0000-0003-2172-2144

⁴ Karadeniz Technical University, Electrical and Electronics Engineering Department, emin.mollahasanoglu@ktu.edu.tr, Orcid No: 0000-0001-7029-1956

ARTICLE INFO

Article history:

Received 27 May 2024

Received in revised form 14 November 2024

Accepted 25 November 2024

Available online 23 December 2024

Keywords:

Internet of things, RPL, Machine learning, IDS, Routing attacks

Doi: 10.24012/dumf.1490367

* Corresponding author

ABSTRACT

This study analyzes various machine learning techniques for detecting attacks against Routing Protocol for Low-Power and Lossy Networks (RPL), a routing protocol commonly used in Internet of Things (IoT) applications. RPL is often employed in IPv6-based IoT applications that require low power consumption and limited bandwidth. The research reviews recent literature examining attacks on RPL-based networks and utilizes the ROUT-4-2023 dataset for detecting routing attacks. This dataset, created using the Cooja simulator, encompasses four types of routing attacks: Blackhole Attack, Flooding Attack, DODAG Version Number Attack, and Decreased Rank Attack. The attack types are detected using machine learning techniques. In the combined dataset, the Decision Tree and Bagging algorithm exhibited the highest performance with a 99.99% accuracy. To create a more accurate representation of the real world, we incorporate a 10% level of noise into the dataset. On the noisy dataset, Random Forest algorithm performed the best with about 84.80% accuracy. The high accuracy show that the employed methods can be effectively used as an Intrusion Detection System (IDS) to protect IoT networks. As a result, this study demonstrates that machine learning techniques offer a promising approach for detecting routing attacks in the RPL protocol.

Introduction

The concept of the Internet of Things (IoT) refers to the idea of various devices interacting and communicating with each other over the internet to share data. This concept has become highly significant today [1]. As shown in Figure 1, this approach is used in a diverse array of applications, from industrial systems to smart homes, from healthcare services to the agricultural sector [2]. However, this rapid growth and widespread use also introduce significant security challenges for IoT devices and networks. The increasing number of connected devices expands the attack surface, making it crucial to address vulnerabilities and protect sensitive information from potential threats.

Security vulnerabilities in IoT networks can arise from various sources, including weak authentication mechanisms, insufficient encryption, and lack of regular software updates. These security weaknesses can be exploited, potentially leading to unauthorized access, data breaches, and other harmful intrusions. Therefore, implementing robust security measures is essential to safeguarding IoT environments.




Figure 1. Internet of things domains of use

Given the diverse applications and the critical nature of IoT deployments, ensuring secure and efficient communication is paramount. Among the routing protocols commonly used in IoT networks, the Routing Protocol for Low-Power and Lossy Networks (RPL) stands out [3]. RPL aims to optimize communication in wireless sensor networks while ensuring low power consumption for IoT devices. Nevertheless, security vulnerabilities and attacks in RPL-based networks present a major concern. Intrusion Detection Systems (IDS) become an important tool for detecting and preventing attacks in RPL-based IoT networks. Machine learning-based IDS can provide more effective protection through methods such as network traffic analysis and identifying behavioral patterns [4]. Such systems can protect against known attacks by using predefined attack signatures and can also detect new and unknown attacks.

Applying machine learning in IoT not only enhances the performance of IoT systems but also allows for more efficient management of unpredictable processes. Moreover, it increases the effectiveness of these systems by reducing human intervention and eliminating the challenges of reprogramming [5].

The motivation of this study is to investigate the effects of using (performance of) machine learning algorithms to detect routing attacks in RPL-based IoT networks. In this scope, the ROUT-4-2023 [6] dataset representing IoT network scenarios with diverse attack types has been utilized for the first time to analyze the performance of various algorithms, including AdaBoost, KNN, Random Forest, Decision Tree, Bagging, Logistic Regression, Gaussian NB, Gradient Boosting, Extra Trees, XGBoost, ANN, and CNN. This study aims to analyze the ROUT-4-2023 dataset using machine learning and ANN models to assess their effectiveness in detecting attacks within the dataset. The ROUT-4-2023 dataset, a comprehensive representation of real-world IoT network scenarios with various attack types, serves as the basis for comparing the capabilities of different algorithms in identifying routing attacks. Through this evaluation, we aim to determine the impact of machine learning and neural network models on detecting and analyzing these attacks effectively.

The remainder of this study is organized as follows: Section RPL introduces the RPL routing protocol, detailing its operational mechanisms, core functionalities, and significance in IoT networks. This section also highlights the features that make RPL suitable for low-power and lossy networks. Section Literature reviews related work, analyzing previous studies on RPL-based IoT networks, including methodologies, findings, and limitations. Section Related work focuses on approaches for detecting routing attacks in RPL networks. It discusses various machine learning algorithms used for IoT security, their strengths, and weaknesses. Section Test results present the machine learning test results using the ROUT-4-2023 dataset, detailing the experimental setup, data pre-processing, and performance evaluation criteria. Section Discussion analyzes the results in relation to the dataset characteristics and algorithm performance, comparing machine learning and deep learning models in the context of IoT security

needs and computational efficiency. Finally, Section Conclusion summarizes the key contributions and findings, discusses their significance in IoT security, and suggests potential directions for future research.

RPL

Routing Protocol for Low-Power and Lossy Networks is a routing protocol specifically designed for wireless sensor networks. This protocol is of great importance, especially for applications such as Internet of Things and Smart Grid. The goal of the routing protocol is to ensure energy efficiency, low latency, and reliable communication in wireless sensor networks [7]. One of the main goals of the RPL protocol is to route data packets between nodes with low energy consumption. Thus, the battery life of the nodes in the network is extended and energy resources are used more efficiently [8].

RPL creates and manages the network topology at the node level to enable wireless sensor networks to efficiently transmit data. The protocol can create and manage various topology structures, for example, using DODAGs (Destination Oriented Directed Acyclic Graphs), which are hierarchical structures at the node level to ensure efficient data transmission. The routing protocol aims to transmit data packets with low latency and high reliability while minimizing the energy consumption of nodes in the network.

The main features of RPL include the use of node routing tables, the creation of network topology through inter-node routing messages, the mutual exchange of information between nodes, and the ability to determine the functions of nodes (e.g. root, parent, and leaf nodes).

Figure 2 shows the structure for creating DODAGs with RPL:

- DIS (DODAG Information Solicitation) is a type of message that nodes use to request DODAG information. When a node wants to learn or update its DODAG structure, it can request DIO messages from neighboring nodes by broadcasting the DIS message. DIS messages allow nodes in the network to dynamically discover and update the DODAG structure.
- DIO (DODAG Information Object) is one of the message types used in the RPL protocol. DIO messages are used for nodes in the network to create and update the DODAG structure. DIO messages broadcast by the root node at regular intervals enable other nodes to learn and update the DODAG structure. DIO messages contain neighboring nodes and routing metrics (e.g., link quality, latency) of nodes in the network. This information helps nodes determine the best routing path.
- DAO (Destination Advertisement Object) is another type of message used in the RPL protocol. DAO messages allow nodes to notify neighboring nodes of their presence and services, if any. With




Figure 2. Structure of building DODAG with RPL

DAO messages, a node introduces itself to its parent nodes and indicates that it wants to join the network. The parent nodes receive the DAO messages, update the network structure, and include the node in the DODAG structure. DAO messages can also contain the node's child nodes. This message enables the creation of downward (root to node) routing paths.

- DAO-ACK (DAO Acknowledgment) message type is utilized to confirm the receipt of DAO messages. Once a node transmits a DAO message to its parent node, it awaits a DAO-ACK message to confirm the successful transmission and its inclusion in the DODAG structure.
- Parent List is used to maintain node parents where a default parent is used as the default router. A node can forward data packets to its default parent node, which creates a cascading connection to the Root node of the RPL topology. The Parent List

helps nodes make routing decisions and determine the best path.

The common use of RPL in various application areas, such as IoT and WSN has also increased the security threats in these networks. As RPL continues to be widely adopted, the prevalence of security vulnerabilities has grown, necessitating a more robust approach to safeguarding these networks. Various attacks on RPL-based networks can compromise both the efficiency and the security of the entire network infrastructure. These attacks are particularly concerning as they have the potential to disrupt critical applications and services reliant on IoT and WSN technologies. Additionally, these attacks can culminate in node denial of service, where nodes are rendered inoperative, thereby severely degrading network performance and reliability. The taxonomy of attacks against RPL networks is depicted in Figure 3. This figure categorizes the various attack types, illustrating the broad spectrum of threats that can target RPL-based networks.

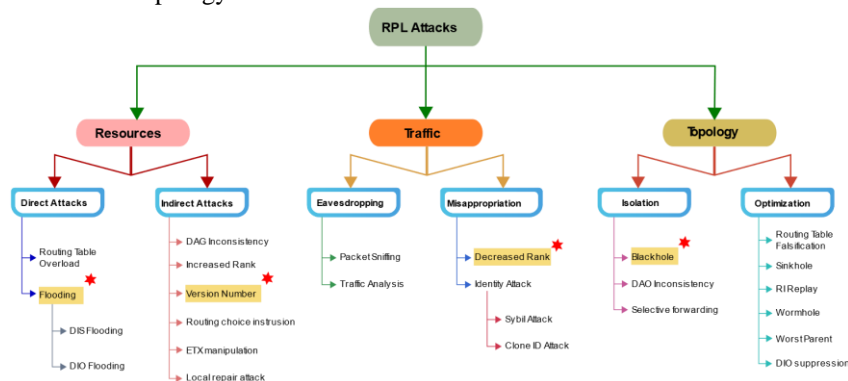


Figure 3. Taxonomy of attacks against RPL networks

The specific attack types examined in this study are clearly marked and highlighted within the figure, providing a visual representation of the focus areas of our research. By identifying and categorizing these threats, we can better understand the potential vulnerabilities and develop more effective countermeasures to protect RPL-based IoT and WSN networks.

Literature

In recent years, with the rapid deployment of IoT devices, attacks on RPL-based networks have increased. Many research and studies have been conducted to detect and prevent these attacks. These studies have been conducted to identify the security vulnerabilities of RPL-based networks, analyze attack patterns, and develop effective defense mechanisms [10]. The results of these studies provide an important resource for understanding the vulnerabilities of RPL-based networks and taking advanced security measures. Table 1 provides summaries of these studies and provides guidance to researchers and network administrators on attack detection and prevention.

In 2019, Verma et al. introduce ELNIDS (Ensemble Learning-based Network Intrusion Detection System) to detect various routing attacks against IPV6 routing protocols [11]. The ELNIDS system is specifically created to identify and identify seven different forms of routing attacks, including Sinkhole (SH), BlackHole (BH), Sybil, Clone ID (CID), Selective Forwarding (SF), Hello Flooding (HF), and Local Repair. This detection is done using the

NIDDS17 dataset, as mentioned in the paper [22]. The ELNIDS methodology is founded on the utilization of ensemble learning, which involves the amalgamation of diverse machine learning classifiers. The researchers utilize four distinct machine learning classifiers: Boosted Trees, Subspace Discriminant, RUSBoosted Tree, and Bagged Trees [23], [24]. The authors assess the individual performance of each classifier applying distinct evaluation and validation measures. Subsequently, they use an ensemble model, namely a voting scheme, to enhance the classification outcomes. Nevertheless, the process of constructing intricate ensemble models may entail significant computational expenses, rendering the system unfeasible.

In 2019, Aydogan et al. propose a new technique for identifying HF and VN attacks in RPL-based IIoT networks. They utilized genetic programming and suggested that this approach is the most appropriate framework for IIoT environments [12]. Their proposed technique uses Genetic Programming in conjunction with a centralized IDS to detect and identify threats. The implemented framework is installed at the main node to oversee the packets of the neighboring nodes. The root consistently analyzes the network data and collects 50 characteristics, which are subsequently utilized to construct genetic programming trees. The top-performing individual from the previous generation is assessed for both HF and DODAG VN attacks, resulting in the development of two detection algorithms. The values are acquired by gathering data at successive intervals of 500 ms and 5000 ms. The

Table 1. Comparative analysis of detection methods for various RPL-based routing attacks

Suggested	Types of Attacks	Methods Used
Verma et al. [11]	Sinkhole, BlackHole, Sybil, Clone ID, Selective Forwarding, Hello Flooding, Local Repair	Boosted Trees, Subspace Discriminant, RUSBoosted Tree, Bagged Trees
Aydogan et al. [12]	Version Number, Hello Flooding, Sinkhole	Genetic programming for attacks
Deshmukh-Bhosale et al. [13]	Wormhole, Hello Flooding	Routing information and received signal strength indicator
Farzaneh et al. [14]	Local Repair Attack	Fuzzy Logic
Agiollo et al. [15]	Sinkhole, Wormhole, Hello Flooding, Version Number, Clone ID, Local Repair, DIS, Selective Forwarding	Signature and behavior-based detection rule
Garcia Ribera et al. [16]	Hello Flood Attack, DIS Attack, DAO Insider Attack, Blackhole Attack, Greyhole Attack	a Hybrid IDS
Alazab et al. [17]	Blackhole, Selective Forwarding, Sybil Attacks	a Decision Tree Classifier and a One-class Support Vector Machine Classifier (a Hybrid Intrusion Detection System)
Azzaoui et al. [18]	CIC-IDS2017 Dataset (DoS, DDoS, Brute Force, XSS, SQL Injection, Infiltration, Portscan, Botnet), WSN-DS Dataset (Blackhole, Grayhole, Flooding, Scheduling)	a Lightweight Artificial Neural Network
Bokka et al. [19]	Blackhole, Sybil, Selective Forwarding, Sinkhole, DIO Suppression, DIS Flooding	analysis
Kiran et al. [20]	DODAG Information Solicitation (DIS) Attack, Version Number Attack, Decreased Rank Attack, Worst Parent Selection (WPS) Attack	analysis
Osman et al. [21]	Version Number, Decreased Rank, DIS Flooding Attacks	Ensemble Learning-based Intrusion Detection System (ELG-IDS)
Our work	Blackhole Attack, Flooding Attack, DODAG Version Number Attack, Decreased Rank Attack	AdaBoost, KNN, Random Forest, Decision Tree, Bagging, Logistic Regression, Gaussian NB, Gradient Boosting, Extra Trees, XGBoost, ANN, CNN

researchers only examine the accuracy of genetic programming in detecting intrusions and reducing false positives. They do not explore how intrusion techniques affect performance metrics like energy consumption and memory usage. In addition, the evaluation of the system does not consider factors such as resource requirements, scalability, extensibility, and mobility support.

Deshmukh-Bhosale et al. present a real-time approach for identifying wormhole and HF attacks in RPL-based IoT networks [13]. Their IDS utilizes the collected signal strength to detect nodes that may be engaging in suspicious activities. Both centralized and distributed IDS are suggested. The findings indicate that the accuracy of correctly identifying positive cases is 90% when the network is small, consisting of 8, 16, or 24 nodes. However, the performance of the method declines noticeably as the network size grows. In addition, the authors solely assess the impact of IDS on a solitary metric and a solitary attack. Furthermore, they disregard the typical issues of mobility associated with networks and fail to acknowledge that the offered solution relies on static topological information.

Farzaneh et al. conduct a study utilizing Fuzzy logic to detect local repair attacks on IoT networks, specifically targeting the RPL routing protocol. The study demonstrates that the suggested strategy, implemented using the Contiki operating system on the Cooja simulator, effectively detects local repair attacks with a significantly high True Positive Rate (TPR). The authors of this study assert that the proposed approach is a highly efficient means of identifying security risks in IoT networks that utilize the RPL protocol [14].

Agiollo et al. introduce the DETONAR model in RPL, which integrates the strengths of anomaly and signature-based IDS models to effectively identify malicious activities in network traffic [15]. This approach utilizes a mechanism known as the 'Detector', which employs signature and behavior-based detection algorithms to identify 14 distinct routing assaults. Additionally, the intrusion detection systems are assessed using the 'Routing Attacks Dataset' (RADAR). Nevertheless, their strategy fails to account for the ever-changing nature of the IoT network. Furthermore, the dataset might have been examined with regards to the privacy and security of Quality of Service (QoS).

Garcia Ribera et al. develop an IDS for IoT networks utilizing the RPL routing protocol. Their objective is to precisely and effectively identify many sorts of assaults, including different routing and denial-of-service (DoS) attacks. The attacks mentioned involve targeted attacks against RPL, such as the version number attack, blackhole attack, and grayhole attack. The effectiveness of the proposed IDS is assessed by a comprehensive analysis of the specified assaults and their consequences. This evaluation also encompasses the ability to forecast the performance of the IDS in terms of its accuracy and effectiveness when confronted with the predetermined attacks. The results obtained demonstrate a high level of accuracy in detection. Moreover, the detected attacks have

been determined to have a negligible impact on CPU utilization and power consumption. More precisely, the rise in CPU use is below 2% in every instance, while the average increase in power consumption is limited to 0.5% [16].

In 2023, a study is undertaken by Ammar Alazab et al. that specifically examined the security difficulties associated with routing attacks that target RPL in IoT systems based on 6LoWPAN. The assaults encompass Flooding assaults, Data-DoS/DDoS Attacks, Wormhole Attacks, RPL Rank Attacks, Blackhole Attacks, Version Attacks, and Sinkhole Attacks. To combat these dangers, they suggest implementing a pioneering Hybrid Intrusion Detection System (HIDS) that merges a decision tree classifier with a class Support Vector Machine classifier. The objective of this hybrid technique is to attain a high rate of detecting intrusions while keeping the incidence of false alarms low. This is accomplished by utilizing the advantages of both Signature Intrusion Detection Systems (SIDS) and Anomaly-based Intrusion Detection Systems (AIDS). Experiments conducted on a dataset of network traffic from real IoT devices, including different types of routing attacks, have demonstrated that their suggested Host-based Intrusion Detection System (HIDS) works better than conventional System-based Intrusion Detection Systems (SIDS) and Anomaly-based Intrusion Detection Systems (AIDS). The HIDS exhibits greater detection abilities and a reduced rate of false positives compared to the traditional techniques [17].

In 2024, Azzaoui et al. propose a streamlined cross-layer IDS approach for the IoT called RPL-IDS. This approach utilizes the RPL routing protocol and employs certain routing parents as artificial neural network (ANN) based mitigation agents. The researchers integrate RPL-IDS into the Contiki operating system and conducted a comprehensive evaluation using the Cooja simulator. The empirical findings demonstrate that RPL-IDS is efficient and can be implemented on devices with restricted resources. The work involves the construction of an IDS scheme that use a machine learning technique and may be implemented on devices with limited resources. Additionally, the results demonstrate that RPL-IDS exhibits superior detection rates in comparison to several IDS schemes documented in the literature. Furthermore, the energy overhead associated with RPL-IDS is nearly insignificant [18].

In 2024, Bokka et al. introduce a study on the effects of RPL routing attacks, which cause disruptions to the regular routing operations and structure of IoT networks. The study assessed the network's performance under normal conditions and five different routing attack scenarios, utilizing a range of performance measures. The metrics encompass Link data rate, Number of packets generated (control and data), Sensor data rate, Packet Delivery Rate (PDR), and Packet delivery delay. The text emphasizes the susceptibility of IoT devices connected via the RPL protocol to routing attacks and underscores the significance of protecting them to thwart both internal and external attacks. The study, which utilizes simulation, demonstrates the crucial importance of robust security measures in




Figure 4. Cooja attack models and feature extraction diagram

safeguarding IoT networks and devices against routing attacks [19].

Kiran et al. examine the effects of several RPL attacks, including DIS attack, version number attack, decreased rank attack, and worst parent selection (WPS) attacks. The Contiki Cooja network simulator is utilized for the purpose of simulation. In addition, a thorough examination of various attacks based on RPL is conducted, revealing that the WPS attack has a substantial influence on network performance in comparison to other assaults [20].

In 2024, Osman et al. present an Ensemble Learning-based Intrusion Detection System (ELG-IDS) using stacking and over-parameter optimization to detect three RPL internal attacks (version number, decreased rank, and DIS flooding attacks). ELG-IDS uses improved feature extraction and genetic algorithm-based feature selection. Their research improves the security of IoT networks by using ELG-IDS and provides better defense against emerging security threats [21].

Upon examining the presented studies, it is emphasized that RPL-based IoT networks face serious security threats, and this underscores the importance of implementing effective protection measures against these threats. Especially considering the limited resources and the impact of attacks on network performance, strong security controls need to be implemented. These studies show the necessity of machine learning methods, new approaches, and technologies to improve the security of IoT networks.

Related Work

Description of the ROUT-4-2023 dataset

The study uses the ROUT-4-2023 dataset, which is made up of ".csv" files with four different routing attacks against the RPL protocol: the Blackhole Attack (blackhole.csv), the Flooding Attack (flooding.csv), the DODAG Version Number Attack (dodag.csv), and the Decreased Rank Attack (rank.csv). It can see these attacks in Table 2. The attack type is given in the Category header. Malicious or

normal status is kept as Label. Additionally, as shown in Table 3, the dataset contains 16 features.

Table 2. Number of RPL-based routing attacks

Category	Malicious	Normal	Total
Blackhole Attack	134282	269852	404134
Flooding Attack	135576	263206	398782
DODAG Version Number Attack	170242	297818	468060
Decreased Rank Attack	139891	229108	368999
Total	579991	1059984	1639975

Table 3. Features and descriptions in the ROUT-4-2023 dataset

Name/Abbreviation	Description
TIME	Simulation time
SOURCE	Source Node IP
DESTINATION	Destination Node IP
LENGTH	Packet Length
INFO	Packet Information
TR	Transmission Rate (per 1000 ms)
RR	Reception Rate (per 1000 ms)
TAT	Transmission Average Time
RAT	Reception Average Time
TPC	Transmitted Packet Count (per second)
RPC	Received Packet Count (per second)
TTT	Total Transmission Time
TRT	Total Reception Time
DAO	DAO Packet Count
DIS	DIS Packet Count
DIO	DIO Packet Count

Figure 4 illustrates the sequence of steps involved in simulating attacks on IoT networks and extracting features for analysis using machine learning. The Cooja simulator is utilized to expose a network to different attacks, and the resulting network traffic is recorded in pcap files. The files undergo analysis using Wireshark and are subsequently converted to CSV format for feature preprocessing, which encompasses data cleaning and normalization. The processed data is subsequently utilized to train multiple machine learning models for the purpose of identifying and

categorizing IoT attacks, culminating in the development of an IoT attack detection model.

Types of attacks

Blackhole attack

It is a type of attack that targets data transmission on the network. In this attack, attackers receive messages, but instead of forwarding them to the destination, they destroy them or redirect them to their own devices. Thus, other devices on the network realize that their messages did not reach the destination and experience communication problems [25]. When the Blackhole Attack is carried out by an attacker in a strategic position in the network, it can isolate many nodes from the network and significantly impact network performance [26]. An example Blackhole Attack scenario is shown in Figure 5.




Figure 5. RPL blackhole attack

Flooding attack

It is a type of attack that involves transmitting large amounts of spoofed data to the network to consume communication resources on the network or render target devices non-functional. In this attack, attackers typically send large amounts of traffic to the network at a fast rate, consuming network resources or exceeding the capacity of the target device. Therefore, it becomes difficult for legitimate data packets to be processed and reach their destination. Flooding Attack can be used to damage the network by disrupting or disabling network services [27]. The HELLO Flood attack is a type of Flood attack using the RPL protocol on a network. In this attack, the attacker Floods the network using DIS messages, which are request messages. In RPL networks, the attacker can perform the HELLO Flood attack either by broadcasting DIS messages to neighboring nodes that should reset the trickle timer, or by sending a unicast DIS message to a node that should respond to a DIO message [26]. Figure 6 shows an example of Flooding Attack scenario.




Figure 6. RPL flooding attack

DODAG version number attack

This attack specifically focuses on exploiting version numbers within the Directed Acyclic Graph utilized in the RPL protocol. The DODAG Version Number is a crucial component of every DIO transmission. This value remains constant as it moves down the DODAG graph and is often only increased by the root node when the DODAG requires reconstruction. A node with an outdated version number signifies that it has not been transferred to the new DODAG graph and is not suitable for usage as a parent node. A malicious actor can modify this field by unlawfully increasing the version number of DIO messages as it transmits them to neighboring nodes. This form of attack has the potential to result in the needless reconstruction of the entire DODAG graph. During this attack, the perpetrators can control the routing processes in the network by substituting the version numbers in DODAG with counterfeit or altered values [26], [28]. Figure 7 shows an example DODAG Version Number Attack scenario.

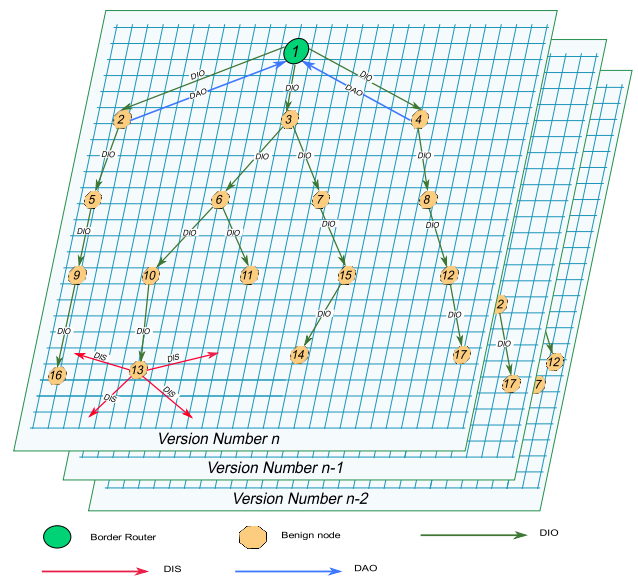


Figure 7. RPL DODAG version number attack

Decreased rank attack

This attack is carried out by manipulating the ranks in the routing tables of resource-constrained devices in the RPL network. As a result of these manipulations, devices with low Rank become favored over other devices in the network. By targeting devices with this low Rank, attackers can direct the data traffic in the network as they wish. The lower the rank in the DODAG graph, the closer the node is to the root and the more traffic that node has to manage. As a result, many legitimate nodes connect to the DODAG network through the attacker. In the RPL protocol, an attacker can change the ranking value through the tampering of DIO messages [26]. This attack results in the inability to perform correct routing operations and can prevent or delay data packets from reaching their destination [29]. Figure 8 shows an example of a decreased rank attack scenario.




Figure 8. RPL decreased rank attack

Algorithms

This study utilizes a range of machine learning and deep learning algorithms to detect RPL-based routing attacks in IoT networks. The selected algorithms, spanning from simple to complex models, are chosen for their proven effectiveness in classification tasks. By evaluating models such as AdaBoost, K-Nearest Neighbors (KNN), Decision Tree, Random Forest, Bagging, Logistic Regression, Gaussian Naive Bayes (GaussianNB), Gradient Boosting, Extra Trees, and XGBoost, as well as artificial neural networks (ANN) and convolutional neural networks (CNN), we aim to cover a diverse set of approaches for comparison [30-33].

Tree-based models, such as Random Forest, Decision Tree, and Extra Trees, are particularly suitable for classification tasks due to their ability to handle complex feature interactions and provide high accuracy. Ensemble methods like Bagging, AdaBoost, and Gradient Boosting are included to examine their robustness and performance under different boosting strategies. Additionally, neural network models (ANN and CNN) are incorporated to assess their potential in learning complex patterns in the dataset.

Logistic Regression and GaussianNB offer simpler, interpretable baseline models to compare against more complex algorithms.

The parameters used in these algorithms are carefully selected to optimize performance, and are listed below:

- AdaBoost was configured with a decision tree as its base classifier, and the number of weak classifiers was set to 100 to create a strong ensemble model. This number of estimators provides a balance between detection accuracy and computational efficiency, ensuring robust performance without excessive complexity.
- K-Nearest Neighbors (KNN), the number of neighbors was set to 1. By focusing on the single nearest neighbor, the model aims to increase precision in distinguishing between well-separated classes within the dataset, which helps improve classification outcomes in a simple yet effective way.
- Random Forest was also set to build 100 decision trees. With this configuration, the model gains both robustness and accuracy, as multiple trees reduce the variance in predictions, providing a stable output that generalizes well to new data. Using 100 trees strikes a balance by ensuring sufficient learning capacity without unnecessary computational demands.
- Decision Tree was used without specific hyperparameter tuning, as this model inherently splits data based on optimal feature values. This simplicity allows Decision Trees to perform well on their own, especially on datasets with clear, interpretable decision boundaries.
- Bagging, the number of estimators was also set to 100. This ensures stability and reduces the variance in predictions by averaging across multiple classifiers, each trained on different subsets of the data. This approach reinforces model robustness and improves accuracy, especially useful for data with potential noise.
- Logistic Regression, the maximum number of iterations was set to 100 to ensure that the model had ample opportunity to converge. This parameter controls the training duration, balancing adequate model tuning with computational efficiency.
- Gaussian Naive Bayes (GaussianNB) was used without specific parameter adjustments, as it relies on probability distributions and assumes feature independence, making it a straightforward yet effective choice for classification tasks in this study.
- Gradient Boosting was configured to include 100 boosting stages, which provides enough stages to gradually correct errors from previous models

while avoiding overfitting. This balanced approach enhances accuracy and helps the model perform better on complex data structures.

- Extra Trees, the number of trees was also set to 100, like Random Forest. This additional randomness in splitting nodes enhances generalization and further stabilizes the model's output by reducing prediction variance.
- XGBoost, the number of trees was set to 100, the learning rate to 0.1, and the maximum depth to 3. These settings ensure that each tree contributes gradually, allowing the model to learn incrementally and prevent overfitting. The depth limit of 3 helps maintain a simpler model that is computationally efficient and performs well on structured data.
- ANN uses the sgd (stochastic gradient descent) optimizer with an initial learning rate of 0.05. This configuration consists of two hidden layers with 64 and 32 nodes, respectively, and employs the ReLU activation function, which helps capture more complex patterns in the data. The adaptive learning rate allows efficient training by adjusting the learning rate as needed throughout the 500 training iterations. With a batch size of 32, this setup ensures a controlled and gradual learning process, making it well-suited for datasets where the complexity of decision boundaries benefits from a deeper network.
- For comparison purposes, this Convolutional Neural Network (CNN) model was tested to evaluate its effectiveness in binary classification of RPL-based routing attacks, leveraging both convolutional and fully connected layers to capture key patterns in the data. The architecture begins with a 1D convolutional layer with 32 filters and a kernel size of 2, using ReLU activation to extract local features from the input time series data. A subsequent max pooling layer with a pool size of 2 reduces dimensionality, focusing on the most relevant features while minimizing computation and overfitting. The output is flattened and passed through a dense layer of 50 neurons with ReLU activation, enabling the model to learn complex relationships. Finally, a single neuron with a sigmoid activation outputs a probability score for binary classification, and the model is compiled with the adam optimizer and binary_crossentropy loss function, ensuring effective training and accuracy in distinguishing attack instances from normal activity.

Test results

The tests are performed on the Visual Studio Code platform, Python version 3.12, AMD Ryzen 5 5500 3.60 GHz

processor, and 32 GB RAM. Different files containing 4 different attack types in the ROUT-4-2023 dataset are merged. This merged file is analyzed.

In the process of feature selection, all 13 features, excluding "time, source, destination", are utilized for feature extraction. Because these parameters will not be meaningful for the nodes that may join the network. The dataset is randomly divided into training and test data using 5-fold cross-validation (k=5). The results are presented by averaging 5 different cross-validation iterations for each model.

Performance metrics

Explanation of the expressions used in the measurement parameters:

- True Positive (TP): This statistic corresponds to the number of instances in which the IDS accurately identified and detected attacks.
- True Negative (TN): Refers to the count of instances where the IDS accurately identified that no attacks were present.
- False Positive (FP): This metric quantifies the number of instances where an IDS erroneously identified an attack when no attack really occurred. This encompasses instances where IDS erroneously detected and reported an attack despite the absence of an actual attack.
- False Negative (FN): Refers to the instances where IDS incorrectly indicated that no attack had a place, despite the presence of an actual attack.
- Accuracy: Refers to the proportion of correctly classified instances. This metric represents the proportion of events to total events that IDS correctly detected. It is often the most fundamental metric used to evaluate the performance of a model. The calculation of Accuracy is given in Equation 1.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (1)$$

- Recall: The ratio of true positives (predicted positives) to all positives. Also known as sensitivity. The calculation of Recall is given in Equation 2. Recall is an important metric that evaluates the ability of a model to accurately detect the positive class. A high recall value means that the model correctly detected most of the positive samples, while a low recall value means that the model missed some of the positive samples or classified them as false negatives.

$$Recall = \frac{TP}{TP + FN} \times 100 \quad (2)$$

Table 4. Performance Evaluation of Data

Algorithm	Accuracy (%)	Recall (%)	Precision (%)	F1 Score (%)	Training Time (s)	Prediction Time (s)	AUC	Log Loss
AdaBoost	81.5297	72.2550	74.6953	73.4403	84.5643	1.8047	0.7943	6.6574
KNN	99.8008	99.7338	99.7030	99.7184	3.5782	24.6636	0.9979	0.0718
Random Forest	99.9783	99.9678	99.9709	99.9693	113.0783	1.8342	0.9998	0.0078
Decision Tree	99.9920	99.9872	99.9899	99.9886	4.0960	0.0252	0.9999	0.0029
Bagging	99.9945	99.9907	99.9937	99.9922	294.4614	2.2958	0.9999	0.0020
Logistic Regression	72.4614	50.9102	63.8869	56.6651	1.0133	0.0078	0.6758	9.9258
Gaussian NB	71.7257	53.6537	61.4907	57.3055	0.2468	0.0546	0.6763	10.1910
Gradient Boosting	90.6458	90.6384	84.1389	87.2671	170.6360	0.2920	0.9064	3.3715
Extra Trees	99.9617	99.9405	99.9512	99.9458	58.3624	2.9720	0.9995	0.0138
XGBoost	89.9186	90.0350	82.9247	86.3333	1.5107	0.0531	0.8994	3.6336
ANN	95.6652	93.5362	94.1708	93.8456	3396.4120	0.1137	0.9518	1.5623
CNN	87.9658	80.0843	85.1612	82.4647	313.6185	7.0707	0.8618	4.3375

- Precision: The ratio of predicted positives to true positives (true positives and false positives). That is, the percentage of data points that the model predicts as positive is correct. The calculation of Precision is given in Equation 3.

$$Precision = \frac{TP}{TP + FP} \times 100 \quad (3)$$

- F1 Score: A measure that balances precision and recall. It is more useful for low precision and low-recall models. The calculation of F1 Score is given in Equation 4.

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \times 100 \quad (4)$$

- Training Time: Represents the training time of the model in seconds. This is the time it takes to train the model on a given training dataset.
- Prediction Time: Represents the model's prediction time in seconds. That is, the time it takes the trained model to predict new data points.
- AUC: Represents the area under the Receiver Operating Characteristic (ROC) curve. This area is used to evaluate the classification performance of the model. The closer to 1, the better the performance of the model.
- Log Loss: Represents the logarithmic loss value. It measures how far the model's predictions are from the true labels. A lower log loss indicates better model performance. The calculation of Log Loss is given in Equation 5.

(y_i) : True label (0 or 1)

(\hat{y}_i) : Estimated probability (between 0 and 1)

$$Log\ Loss = -\frac{1}{n} \sum_{i=1}^n (y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)) \quad (5)$$

Performance evaluation

Table 4 shows the performance of different machine learning algorithms. Performance metrics include Accuracy, Recall, Precision, F1 Score, training time, prediction time, AUC, and Log Loss.

The AdaBoost model provided an Accuracy of 81.53%. Recall and Precision are 72.25% and 74.70% respectively. The F1 score is 73.44%. The training time is 84.56 seconds, while the prediction time is 1.80 seconds. The AUC is 0.7943 and Log Loss is calculated as 6.6574.

KNN model has the highest accuracy rate with 99.80% accuracy rate. Recall is 99.73%, Precision is 99.70% and F1 score is 99.72%. Training time is 3.58 seconds and prediction time is 24.66 seconds. AUC is 0.9979 and Log Loss is 0.0718.

The Random Forest and Decision Tree algorithms have very high accuracy rates (99.98% and 99.99%). Other performance metrics are also very high. Training times increase depending on the number of decision trees.

The Bagging algorithm demonstrates the highest performance among the evaluated machine learning algorithms, achieving an exceptional accuracy of 99.99%. It also exhibits outstanding results in recall (99.99%), precision (99.99%), and F1 score (99.99%). These high values underscore the model's robustness and reliability in detecting and classifying RPL-based routing attacks. However, the Bagging algorithm's training time is significantly longer than the other algorithms, taking 294.46 seconds. This extended training duration is a trade-off for its superior accuracy and robustness. The algorithm's ability to aggregate multiple decision trees enhances its performance but also increases computational complexity and resource requirements. Despite this, the Bagging algorithm remains highly effective choice for scenarios where accuracy and robustness are paramount, and the available computational resources can accommodate the increased training time.

Logistic Regression yields a lower accuracy rate at 72.46%, with Recall at 50.91% and Precision at 53.69%. The model's F1 score stands at 56.67%, and training and prediction times are 1.01 seconds and 0.0078 seconds respectively, making it a fast but less reliable option for this context. AUC is 0.7373, and Log Loss is high at 9.9258.

Table 5. Performance Evaluation of Noisy Data

Algorithm	Accuracy (%)	Recall (%)	Precision (%)	F1 Score (%)	Training Time (s)	Prediction Time (s)	AUC	Log Loss	Accuracy Deviation (%)
AdaBoost	74.4405	68.5732	72.9462	69.5364	371.7664	2.3089	0.7931	0.6121	-7.0892
KNN	80.0297	78.1973	78.1546	78.1755	4.5428	223.8360	0.7820	7.1980	-19.7711
Random Forest	84.7978	81.5923	84.5195	82.6986	732.0494	6.2169	0.9182	0.3408	-15.1805
Decision Tree	77.9885	76.0722	75.9234	75.9958	47.5945	0.0777	0.7607	7.9337	-22.0035
Bagging	84.5792	81.5007	84.1192	82.5133	2972.2421	6.9626	0.9151	0.3539	-15.4153
Logistic Regression	72.4199	67.5026	69.8124	68.1653	2.3690	0.0082	0.7373	0.5609	-0.0415
Gaussian NB	71.8279	67.7259	69.011	68.1852	1.2164	0.0479	0.6784	0.8238	+0.1022
Gradient Boosting	78.5013	74.5297	77.0944	75.4244	767.7227	0.3091	0.8552	0.4467	-12.1445
Extra Trees	84.6286	81.3143	84.4100	82.4655	132.4850	9.1348	0.9171	0.3463	-15.3331
XGBoost	78.4861	74.4181	77.1341	75.3477	2.0502	0.0569	0.8531	0.4485	-11.4325
ANN	83.7789	80.4484	83.3294	81.5252	1850.0085	0.11329	0.9128	0.3406	-11.8863
CNN	81.7325	77.4846	81.6391	78.7808	321.4079	7.3378	0.8902	0.3814	-6.2333

Gaussian NB shows an accuracy rate of 71.73%, with Recall at 53.63% and Precision at 61.49%, resulting in an F1 score of 57.30%. The model's training and prediction times are notably short at 0.246 and 0.0546 seconds respectively. AUC is relatively low at 0.6763, and Log Loss is high at 10.1910, indicating limited applicability for this application.

Gradient Boosting achieved an accuracy of 90.65%, Recall at 89.63%, and Precision at 84.14%, giving an F1 score of 87.27%. Training time is considerable at 170.63 seconds, while prediction time is 2.92 seconds. AUC stands at 0.9064, and Log Loss is 3.3715, showing reliable but computationally intense performance.

Extra Trees achieved an accuracy of 99.96%, with Recall at 99.94%, Precision at 99.95%, and F1 score at 99.94%. Training time is 58.36 seconds, and prediction time is 2.97 seconds. AUC is high at 0.9995, and Log Loss is low at 0.0138, making it a strong choice.

XGBoost achieved an accuracy of 99.91%, Recall at 99.03%, and Precision at 99.03%, resulting in an F1 score of 99.03%. The training time is 112.07 seconds, and the prediction time is 2.53 seconds. AUC is 0.9994, and Log Loss is 0.0249, indicating high reliability and confidence in predictions.

The ANN model achieved an accuracy of 95.66%, indicating high classification performance. It has a recall of 93.53%, precision of 94.17%, and an F1 score of 93.84%, which demonstrate its effectiveness in correctly identifying both positive and negative cases. The model's AUC is 0.9518, reinforcing its strong performance in distinguishing between classes. However, the training time for ANN is notably high at 3396.41 seconds, which highlights the model's computational demands. The prediction time is relatively low at 0.1137 seconds, making it efficient during the testing phase. This setup suggests that while ANN requires substantial resources for training, it provides a robust performance and quick predictions, making it suitable for applications where high accuracy is prioritized over training speed.

CNN achieved an accuracy of 87.97%, Recall of 80.08%, and Precision of 85.16%, with an F1 score of 82.46%. While the training time is lengthy at 313.62 seconds, AUC is 0.8618, and Log Loss is 4.3375, making it suitable for

tasks involving complex feature extraction at the expense of computational efficiency.

As a result, when model performances are analyzed, it is seen that the Bagging model shows the highest performance. However, ANN has the longest training time among the models. The Decision Tree model stands out with its high accuracy rate and very low training and testing times. It is important to take this into consideration when making a choice in the application context. Given the critical importance of attack detection in IoT networks, where timely and accurate identification of threats is crucial for maintaining network security and performance, selecting the appropriate model is essential. The effectiveness of these models directly impacts the ability to safeguard IoT environments against malicious activities.

Performance evaluation of noisy data

In this study, we also test the performance of machine learning algorithms on noise-added data. In the real world, data is not always clean and error-free. Noise is inevitable in data collection processes. Testing how algorithms deal with noisy data increases the reliability of models in real-world applications.

For noise, a certain level of random normally distributed noise is added to the feature values of the dataset. The noise level is determined by multiplying the standard deviation of the data by 10%. This process is used to simulate real-world data collection errors. The noise addition process involves the following steps:

The noise level is determined. This level determines the magnitude of the added noise. The noise level (σ_{noise}) is a ratio of the standard deviation of the available data. Random noise is generated for each feature. This noise is generated by random numbers drawn from a normal distribution (Gaussian distribution), as shown in Equation 6:

$$noise_i \sim \mathcal{N}(0, \sigma_{noise} \cdot \sigma_i) \quad (6)$$

- ($noise_i$): Random noise for column i

- (σ_i): Standard deviation of column i

- (σ_{noise}): Noise level ($\sigma_{noise} = 0.1$)

The generated random noise (D_{noisy}) is added to a copy of the original data set (D_{noisy_i}), as shown in Equation 7:

$$D_{noisy}[:, i] = D[:, i] + noise_i \quad (7)$$

- $D[:, i]$: i column of the original data set

- $D_{noisy}[:, i]$: i column of the noise-added data set

There are no negative values in the dataset, so Equation 8 is used to take the absolute value of all values in column i in the matrix D_{noisy} , making negative values positive.

$$D_{noisy}[:, i] = |D_{noisy}[:, i]| \quad (8)$$

Analysis of noisy data is given in Table 5. The Accuracy Deviation (%) column represents the difference in accuracy between the noisy and original data, expressed as a percentage. According to Table 5, the Random Forest algorithm achieves the highest accuracy on noisy data, with an accuracy of 84.79%, recall of 81.59%, precision of 84.51%, and F1 score of 82.69%. Additionally, it has an AUC of 0.9182 and a Log Loss of 0.3408, which demonstrates the Random Forest algorithm's robustness in handling noisy data effectively.

In contrast, the Decision Tree algorithm experiences a significant decrease in accuracy on noisy data, achieving an accuracy of 77.98%, recall of 76.07%, precision of 75.92%, and F1 score of 75.99%. The AUC for Decision Tree drops to 0.7607, and Log Loss increases to 7.9337, indicating that the Decision Tree algorithm is notably more sensitive to noise. This is likely due to the Decision Tree's reliance on a single tree structure, making it more susceptible to noise or outliers, which can cause larger fluctuations in accuracy.

Both Random Forest and Bagging mitigate this issue by employing multiple decision trees, which collectively reduce the influence of individual tree errors and enhance model generalization. This ensemble approach diminishes the sensitivity to noise, making them more resilient. However, in this study, Random Forest not only outperforms Bagging in terms of accuracy but also achieves faster results due to its methodology of using a random subset of features for each tree. This approach decreases training time and further minimizes the correlation between trees, giving Random Forest an edge over Bagging.

Bagging, on the other hand, trains each decision tree on the full set of features, requiring more computational power and time. This model often involves a larger number of trees to achieve a strong generalization, which extends the training duration. While Bagging provides a highly robust and resilient model, it is more resource-intensive compared to Random Forest. The results in Table 5 demonstrate that Random Forest not only achieves a faster training time but also exhibits higher accuracy and robustness within the context of noisy data, outperforming Bagging.

Other algorithms, such as KNN and Gradient Boosting, also show reasonable resilience to noise, with accuracy rates of 80.30% and 85.50%, respectively. However, Logistic Regression and Gaussian NB exhibit lower performance, with Logistic Regression achieving 72.42% accuracy and

Gaussian NB achieving 71.82%, highlighting their limitations in handling noisy data effectively.

Finally, the neural network models ANN and CNN present varying performance levels under noisy conditions. While ANN and CNN demonstrate relatively high accuracy levels of 83.78% and 81.73%, respectively, the training times are considerably longer, particularly for ANN. This suggests that while neural networks can adapt to noisy data, they may require extensive computational resources, which could be a consideration in resource-constrained environments.

In summary, Random Forest stands out as the most effective model for handling noisy data, combining high accuracy, reasonable training time, and resilience against noise, making it a suitable choice in noisy environments.

Discussion

In this study, various machine learning algorithms were evaluated for detecting RPL-based routing attacks using the ROUT-4-2023 dataset. Results show that tree-based models, especially Random Forest, Decision Tree, and Bagging achieved higher accuracy and outperformed deep learning models like ANN and CNN. This can be attributed to the structure of the dataset, which allows tree-based algorithms to effectively separate attack types, resulting in superior performance without the computational complexity of deep learning models.

Due to the novelty of the ROUT-4-2023 dataset, comparisons with prior studies were not possible, as this dataset has not been previously used in the literature. This limitation highlights the need for further studies utilizing ROUT-4-2023 to establish a broader comparative framework.

Overall, the distinct features of the ROUT-4-2023 dataset enabled tree-based methods to provide efficient and accurate classifications. While ANN and CNN showed potential, their longer training times and computational demands did not yield notable benefits over simpler, interpretable tree models in this case. Future studies could explore deep learning approaches further on larger or more complex datasets to reassess their effectiveness in this context.

Conclusion

This study evaluated the effectiveness of various machine learning algorithms for detecting RPL-based routing attacks in IoT networks. Using the ROUT-4-2023 dataset, we demonstrated that tree-based models, particularly Decision Tree, Bagging, and Random Forest, achieved high accuracy, with Decision Tree and Bagging reaching an impressive accuracy of 99.99% on the combined dataset. To represent real-world conditions, a 10% noise level was added to the dataset, where Random Forest performed the best with an accuracy of approximately 84.80%. These high accuracy rates underline the suitability of machine learning-based IDS for classifying attack types in RPL-based networks, enhancing security and resilience in low-power and lossy network environments. On the other hand, due to

the easily separable nature of the dataset, more complex models like ANN and CNN did not achieve similarly high performance, underscoring that simpler models can be highly effective for this specific dataset. Our results highlight the advantages of machine learning in fortifying RPL protocol security, establishing a solid foundation for further research. Future studies may explore more advanced models, such as deep learning, to assess their potential in improving detection capabilities. Additionally, real-world testing across diverse IoT settings would be essential to validate the practical applicability and robustness of these models in live environments.

References

- [1] S. Görmüş, H. Aydın, and G. Ulutaş, "Security for the internet of things: a survey of existing mechanisms, protocols and open research issues," *Journal of the Faculty of Engineering and Architecture of Gazi University*, vol. 33, no. 4, pp. 1247–1272, 2018.
- [2] Q. Jing, A. V. Vasilakos, J. Wan, J. Lu, and D. Qiu, "Security of the internet of things: perspectives and challenges," *Wireless networks*, vol. 20, pp. 2481–2501, 2014.
- [3] R. Alexander, A. Brandt, J. Vasseur, J. Hui, K. Pister, P. Thubert, P. Levis, R. Struik, R. Kelsey, and T. Winter, "RPL: IPv6 Routing Protocol for Low-Power and Lossy Networks," RFC 6550, Mar. 2012. [Online]. Available: <https://www.rfc-editor.org/info/rfc6550>
- [4] A. Verma and V. Ranga, "Machine learning based intrusion detection systems for iot applications," *Wireless Personal Communications*, vol. 111, no. 4, pp. 2287–2310, 2020.
- [5] T. Bekar, S. Görmüş, B. Aydın, and H. Aydın, "Q-learning algorithm inspired objective function optimization for ietf 6tisch networks," in *2023 International Conference on Smart Applications, Communications and Networking (SmartNets)*, 2023, pp. 1–6.
- [6] M. EMEÇ and M. H. ÖZCANHAN, "Rout-4-2023: Rpl based routing attack dataset for iot," 2023. [Online]. Available: <https://dx.doi.org/10.21227/3mbe-5j70>
- [7] H. Aydın, S. Goermues, and Y. Jin, "A distributed user authentication mechanism for ietf 6tisch protocol," in *2018 IEEE 87th Vehicular Technology Conference (VTC Spring)*, 2018, pp. 1–7.
- [8] S. Külçü and S. Görmüş, "Improving synchronization time in 6tisch networks with smart antennas," in *2022 30th Signal Processing and Communications Applications Conference (SIU)*. IEEE, 2022, pp. 1–4.
- [9] A. Mayzaud, R. Badonnel, and I. Chrisment, "A taxonomy of attacks in rpl-based internet of things," *Int. J. Netw. Secur.*, vol. 18, pp. 459–473, 2016.
- [10] B. Aydın, S. Görmüş, H. Aydın, and S. Kulcu, "A new routing objective function for ietf 6tisch protocol," in *2022 30th Signal Processing and Communications Applications Conference (SIU)*. IEEE, 2022, pp. 1–4.
- [11] A. Verma and V. Ranga, "Elnids: Ensemble learning based network intrusion detection system for rpl based internet of things," in *2019 4th International conference on Internet of Things: Smart innovation and usages (IoT-SIU)*. IEEE, 2019, pp. 1–6.
- [12] E. Aydogan, S. Yilmaz, S. Sen, I. Butun, S. Forsström, and M. Gidlund, "A central intrusion detection system for rpl-based industrial internet of things," in *2019 15th IEEE International Workshop on Factory Communication Systems (WFCS)*. IEEE, 2019, pp. 1–5.
- [13] S. Deshmukh-Bhosale and S. S. Sonavane, "A real-time intrusion detection system for wormhole attack in the rpl based internet of things," *Procedia Manufacturing*, vol. 32, pp. 840–847, 2019.
- [14] B. Farzaneh, M. Koosha, E. Boochanpour, and E. Alizadeh, "A new method for intrusion detection on rpl routing protocol using fuzzy logic," in *2020 6th International Conference on Web Research (ICWR)*, 2020, pp. 245–250.
- [15] A. Agiollo, M. Conti, P. Kaliyar, T.-N. Lin, and L. Pajola, "Detonar: Detection of routing attacks in rpl-based iot," *IEEE transactions on network and service management*, vol. 18, no. 2, pp. 1178–1190, 2021.
- [16] E. Garcia Ribera, B. Martinez Alvarez, C. Samuel, P. P. Ioulianou, and V. G. Vassilakis, "An intrusion detection system for rpl-based iot networks," *Electronics*, vol. 11, no. 23, 2022.
- [17] A. Alazab, A. Khraisat, S. Singh, S. Bevinakoppa, and O. A. Mahdi, "Routing attacks detection in 6lowpan-based internet of things," *Electronics*, vol. 12, no. 6, 2023.
- [18] H. Azzaoui, A. Z. E. Boukhamla, P. Perazzo, M. Alazab, and V. Ravi, "A lightweight cooperative intrusion detection system for rpl-based iot," *Wireless Personal Communications*, pp. 1–24, 2024.
- [19] R. Bokka and T. Sadasivam, "Simulation-based analysis of rpl routing attacks and their impact on iot network performance," *Journal of Electronic Testing*, pp. 1–15, 2024.
- [20] U. Kiran, P. Maurya, and H. Sharma, "Investigating routing protocol attacks on low power and lossy iot networks," *SN Computer Science*, vol. 5, no. 4, p. 393, 2024.
- [21] M. Osman, J. He, K. Zhu, and F. M. M. Mokbal, "An ensemble learning framework for the detection of rpl attacks in iot networks based on the genetic feature selection approach," *Ad Hoc Networks*, vol. 152, p. 103331, 2024.

- [22] A. Verma and V. Ranga, "Rpl-nidds17-a data set for intrusion detection in rpl based 6lowpan networks," *Internet of Things*, vol. 5, no. 1, pp. 1-20, 2018.
- [23] G. De'Ath, "Boosted trees for ecological modeling and prediction," *Ecology*, vol. 88, no. 1, pp. 243-251, 2007.
- [24] C. Seiffert, T. M. Khoshgoftaar, J. Van Hulse, and A. Napolitano, "Rusboost: A hybrid approach to alleviating class imbalance," *IEEE transactions on systems, man, and cybernetics-part A: systems and humans*, vol. 40, no. 1, pp. 185-197, 2009.
- [25] D. Airehrour, J. Gutierrez, and S. K. Ray, "Securing rpl routing protocol from blackhole attacks using a trust-based mechanism," in 2016 26th International Telecommunication Networks and Applications Conference (ITNAC), 2016, pp. 115-120.
- [26] A. Mayzaud, R. Badonnel, and I. Chrisment, "A taxonomy of attacks in rpl-based internet of things," *International Journal of Network Security*, vol. 18, no. 3, pp. 459-473, 2016.
- [27] T. NGUYEN, T. NGO, T. NGUYEN, D. TRAN, H. A. TRAN, and T. BUI, "The flooding attack in low power and lossy networks: A case study," in 2018 International Conference on Smart Communications in Network Technologies (SaCoNeT), 2018, pp. 183-187.
- [28] A. Mayzaud, R. Badonnel, and I. Chrisment, "Detecting version number attacks in rpl-based networks using a distributed monitoring architecture," in 2016 12th International Conference on Network and Service Management (CNSM), 2016, pp. 127-135.
- [29] A. D. Seth, S. Biswas, and A. K. Dhar, "Detection and verification of decreased rank attack using round-trip times in rpl-based 6lowpan networks," in 2020 IEEE International Conference on Advanced Networks and Telecommunications Systems (ANTS), 2020, pp. 1-6.
- [30] O. H. Abdulganiyu, T. Ait Tchakoucht, and Y. K. Saheed, "A systematic literature review for network intrusion detection system (ids)," *International Journal of Information Security*, vol. 22, no. 5, pp. 1125-1162, 2023.
- [31] M. Douiba, S. Benkirane, A. Guezzaz, and M. Azrou, "An improved anomaly detection model for iot security using decision tree and gradient boosting," *The Journal of Supercomputing*, vol. 79, no. 3, pp. 3392-3411, 2023.
- [32] J. B. Awotunde, F. E. Ayo, R. Panigrahi, A. Garg, A. K. Bhoi, and P. Barsocchi, "A multi-level random forest model-based intrusion detection using fuzzy inference system for internet of things networks," *International Journal of Computational Intelligence Systems*, vol. 16, no. 1, p. 31, 2023.
- [33] J. B. Awotunde, S. O. Folorunso, A. L. Imoize, J. O. Odunuga, C.-C. Lee, C.-T. Li, and D.-T. Do, "An ensemble tree-based model for intrusion detection in industrial internet of things networks," *Applied Sciences*, vol. 13, no. 4, p. 2479, 2023.



Polyp Segmentation with Deep Learning: Utilizing DeeplabV3+ Architecture and Various CNN Backbones

Yaren AKGÖL^{1*}, Buket TOPTAŞ¹

¹ Bandırma Onyedi Eylül University, Software Eng. Dept, yarenakgol@ogr.bandirma.edu.tr, Orcid No: 0009-0004-5987-0171

¹ Bandırma Onyedi Eylül University, Software Eng. Dept, btoptas@bandirma.edu.tr, Orcid No: 0000-0003-2556-8199

ARTICLE INFO

Article history:

Received 16 July 2024
Received in revised form 8 Oct 2024
Accepted 17 Oct. 2024
Available online 23 December 2024

Keywords:

polyp segmentation, deeplabv3+,
colorectal cancer, colon cancer

Doi: 10.24012/dumf.1517112

ABSTRACT

Polyps are abnormal tissue growths that often serve as early indicators for various types of cancer. Early detection is crucial in the treatment of diseases like colorectal cancer, which has a high mortality rate. There is a significant need for automated diagnostic systems to detect these cancers efficiently. This article introduces a deep learning-based diagnostic system using the Deeplabv3+ architecture, which is enhanced by integrating four different backbone networks: Model 1 (DeeplabV3+), Model 2 (ResNet50), Model 3 (SqueezeNet), and Model 4 (VGG16). The enhanced architectures have been tested on the publicly available Kvasir-SEG and CVC-ClinicDB datasets for the task of polyp segmentation. Experimental results indicate that the best segmentation performance on the Kvasir-SEG dataset was achieved with Model 1, showing a mean Dice coefficient (mDice) of 0.858, a mean Intersection over Union (mIoU) of 0.850, an accuracy (Acc) of 0.948, a recall of 0.824, and a precision (Pr) of 0.896. For the CVC-ClinicDB dataset, the highest metrics were observed with Model 2 for mDice (0.914) and mIoU (0.912), and Model 1 for specificity (Sp) at 0.996 and precision at 0.959, whereas Model 4 exhibited the highest accuracy of 0.974. These results demonstrate the effectiveness of our models in automating the detection of polyps, potentially aiding in the early diagnosis of colorectal cancer.

Introduction

Medical image segmentation represents a highly sensitive and challenging field with significant impacts on human health. Challenges such as overlapping cells, differentiation of retinal blood vessels into arteries and veins, skin lesions obscured by hair, and polyps of various shapes and sizes exemplify the difficulties faced in this domain. However, recent years have witnessed rapid progress and significantly improved success rates in various areas of medical image segmentation, including retina [1], cell [2], mammogram [3], skin [4], and polyp segmentation [5], driven by advancements in deep learning methods. These developments constitute a significant leap forward in the field of medical image analysis, enhancing not only diagnostic accuracy but also streamlining workflows within medical practices. The integration of deep learning into medical imaging paves the way for more precise, efficient, and potentially life-saving diagnostic procedures.

Polyps, which are abnormal tissue growths developing on surfaces such as the colon, rectum, and stomach, represent one of the primary areas where deep learning architectures have been extensively applied in medical fields. Although polyps may appear benign, they increase the risk of cancer. According to cancer statistics published in 2022, colon and

rectum cancer ranks third worldwide in cancer-related deaths [6].

The early detection of polyps can facilitate timely treatment options and potentially reduce mortality rates associated with polyp-related complications. To achieve early detection, automated segmentation systems are essential. However, the segmentation of polyps is challenged by their irregular shapes, size variations, and differences in location and color. To address these challenges, a significant number of studies have been conducted in the literature. These studies and advanced methodologies are discussed in greater detail under the 'Related Work' section.

Related work

Traditional methods of polyp segmentation rely on manual feature extraction processes [7],[8]. With the advent of deep neural network architectures that minimize manual intervention by extracting semantic information from high-dimensional images, researchers have increasingly focused on leveraging these architectures.

Gangrade et al.[9] proposed a modified DeepLabV3+ architecture for polyp segmentation from colonoscopy images. This architecture is comprised of encoder and decoder layers. The encoder utilizes a pre-trained dilated

convolutional residual network to optimally achieve feature map resolution. The encoder-decoder structures include the Atrous Spatial Pyramid Pooling (ASPP) module and the ResNet101 backbone used in the proposed model. ASPP generates a multi-scale feature map by employing atrous convolution and global average pooling. Zhang et al. [5] have proposed the Dual-Branch Multi-Information Aggregation Network (DBMIANet) method to segment the same type of polyps reliably and effectively. DBMIA-Net employs three auxiliary modules to enhance its feature extraction and segmentation capabilities. These are the Adaptive Channel-Wise Graph Convolution (ACGC), Global Information Aggregation (GIA), and Edge Information Aggregation (EIA) modules. These modules are utilized by a transformer encoder and a Convolutional Neural Networks (CNN) encoder. The GIA module is used in aggregating global information, whereas the EIA module is employed for edge information aggregation. The ACGC module has been developed to improve the capability of learning channel feature associations representation. Li et al. [10] have proposed a model to address the challenge of detecting small polyps. The proposed model utilizes a two-stage transfer learning approach. In the first stage, the network is trained to identify specific areas of polyp lesions and to save initial weights. The second stage employs transfer learning to segment the relevant area in more detail. A Pyramid Vision Transformer (PVT) has been used as the feature backbone.

Li et al. [11] proposed a cross-level information fusion and guidance-oriented approach to polyp segmentation networks. The method employs a transformer encoder to build a robust feature representation. Modules such as the Edge Feature Processing Module (EFPM) and Crosslevel Information Processing Module (CIPM) are utilized to enhance the feature information coming from the encoders. EFPM focuses on the boundary information of polyps and is used to gather and process multi-scale features transmitted by various encoder layers. An Information Guidance Module (IGM) has been suggested to combine the processed features of EFPM and CIPM, maximizing the segmentation effect. Jia et al. [12] have proposed a semi-supervised framework named PolypMixNet, aimed at achieving colorectal polyp segmentation. The framework utilizes a mean teacher architecture and novel augmentation techniques within its model architecture. PolypMixNet includes a Polyp-Aware Mix-Up Algorithm (PolypMix) and a dual-level consistency regularization. PolypMix enhances the diversity of training data and addresses class imbalance in colonoscopy datasets. He et al. [13] introduced the Boundary-Guided Filter Network (BGF-Net), known for achieving enhanced medical image segmentation. In the proposed model, DeepLabV3+ has been selected as the backbone for BGF-Net. BGF-Net is composed of four main components: ResNet-101, Channel Boundary Guided (CBG), Spatial Boundary Guided (SBG), and Boundary Guided Filter (BGF). During the encoding process, CBG is connected to ResNet-101 to extract channel weights about boundary features. SBG is designed to capture spatial weights and to guide and optimize low-level features. BGF directs and preserves appropriate segment boundaries

through refined boundary resolution. Liu et al. [14] have proposed a novel Feature Combination Network (FCA-Net) for accurately detecting polyp sizes and locations. The proposed model comprises three modules: the Edge Perception Module (EPM), the Boundary-Guided Feature Aggregation Module (BFAM), and the Iterative Context Aggregation Module (ICAM). EPM is capable of simultaneously extracting initial boundary guidance maps from both low and high-level features. BFAM enhances hierarchical features, better preserves boundary details, and recalibrates positioned objects by integrating boundary information into the segmentation network. ICAM employs a contextaware approach to better leverage dependencies between features at different scales. Wang et al. [15] introduced CPSNet, a novel model for concealed polyp segmentation. CPSNet consists of three main modules: the Deep Multi-Scale Feature Fusion Module (DMF), the Camouflaged Object Detection Module (CDM), and the Multi-Scale Feature Enhancement Module (MFEM). These modules work collaboratively to enhance the segmentation process, increasing both resilience and accuracy. The model employs the DMF module for the progressive fusion of features, gathering structural and semantic information of polyps from deep features. CDM is used in shallow features to effectively identify camouflaged and concealed polyps. Furthermore, MFEM has been developed to seamlessly combine shallow and deep features, considering both local and global perspectives.

Liu et al. [16] detail the components of the proposed CAFE-Net architecture, which includes the PVT as its backbone, the Feature Completion and Exploration Module (FSEM), the Cross-Attention Decoder Module (CADM), and the Multi-Scale Feature Aggregation (MFA). During the decoder phase, CADM has been utilized to successfully amalgamate high and low-level features. Shao et al. [17] highlight that the variability in shapes and sizes of polyps poses challenges in early diagnosis. To address this issue, the Adaptive Feature Aggregation Network (AFANet) has been proposed. The proposed model is composed of the Multi-modal Balancing Attention Module (MMBA) and the Global Context Module (GCM). The MMBA module facilitates the extraction of enhanced local features by utilizing contextual information in the foreground, background, and edge regions of images, paying special attention to these areas. The GCM module, on the other hand, captures the global contextual features from the top of the encoder to examine the pathological image's global contextual characteristics in greater detail, and then transfers these features to the decoder layer. Muhammad et al. [18] have proposed a novel polyp segmentation method known as MMFIL-Net. The proposed model incorporates the Hierarchical Multi-Source Feature Interaction Module (HMFIM) and Multi-Source Feature Interaction Blocks (MFIB). MFIB aims to achieve generalized performance by manipulating multi-level and multi-source features to minimize the differences between low and high-level feature maps. Additionally, the Multiple Receptive Field Feature Interaction Block (MRFFIB) addresses segmentation issues of polyps of various sizes. To tackle the challenge of detecting and segmenting early-stage polyps

with ambiguous boundary information, the Dual Source Attention Fusion Block (DSAFB) was developed. The model utilizes EfficientNet-B0 as its encoder block. Yue et al. [19] have introduced the Boundary Uncertainty Aware Network (BUNet) to enhance polyp detection. Emphasizing the awareness of the shapes and sizes of polyps, a PVT encoder has been used to learn multi-scale feature representations. For low-level features, the Boundary Exploration Module (BEM) was preferred. Utilizing boundary information from BEM, the Boundary Uncertainty Aware Module (BUM) was proposed for detecting error-prone areas in high-level features. The pyramid image transformer PVT-V2 was employed to extract multi-scale and robust features. BUM consists of two parallel convolutional branches, which are supervised by the ground truths of the polyp and background. By taking the difference between feature maps generated from these branches, boundary uncertainty regions are identified, incorporating boundary cues from the BEM module.

Ahmed and Hasan [20] proposed a Twin Segmentation Network (Twin-SegNet) to enhance segmentation performance by merging polyp and background reconstructions. The model is structured into three main components: polyp and background segmentation models, the Partial Channel Recalibration (PCR) section, and the merging section. To ensure accurate segmentation of polyp regions and the background, mean squared error has been utilized. The Wavelet Convolutional Block (WCB) is recommended for edge information, while the Partial Channel Recalibration (PCR) block is proposed to allow for mutual feature exchange. In the initial part, the final convolution layer and sigmoid activation are extracted. The concluding part contains a final convolution layer followed by a sigmoid to generate the foreground and background segmentation maps. Fan et al. [21] have proposed Super-Resolution-Assisted Small Targets Polyp Segmentation Network (SRSegNet), emphasizing unified learning and multi-task learning. The proposed model consists of two main components. Firstly, a method for joint learning of high and low resolutions is utilized. It comprises two sub-segmentation branches that process the network's high and low-resolution inputs simultaneously. Each branch extracts features at different resolution levels and collectively they extract the network's entire feature set. Secondly, a multi-task learning approach is employed. This approach includes two sub-branches within the network, each conducting two different tasks simultaneously: low-resolution segmentation and super-resolution. Liu et al. [22] proposed the Multi-level Feature Fusion Network (MLFF-Net) to enhance segmentation performance by integrating multi-level feature fusion and attention mechanisms. The network is comprised of three modules: the Multi-scale Attention Module (MAM), the High-level Feature Enhancement Module (HFEM), and the Global Attention Module (GAM). MAM collects polyp details and information at various scales from the shallow outputs of the encoder. In HFEM, deeper features from the encoders are interlinked, enhancing the overall feature set. Meanwhile, the attention mechanism within HFEM reorganizes the importance of the combined features, dampening irrelevant components while

accentuating information critical to the task. GAM merges information from both encoder and decoder features and is used to model dependencies between different regions of an image, ensuring the model accounts for information from more distant. Pan et al. [23] proposed A Global Guided Local Feature Stepwise Aggregation Network for polyp segmentation (GLSNet) to improve performance in polyp segmentation. The model incorporates three modules: the Spatial Feature Enhancement (SFE) module, the Globally Guided Local Feature Enhancement (GLFE) module, and the Feature Stepwise Aggregation (FSA) module. The SFE module enhances the spatial features of polyps, allowing for the acquisition of more detailed information about them. The GLFE module utilizes high-level features to capture noise in low-level features and uncovers polyp information hidden within superficial features. Lastly, the FSA module combines positional and semantic information of polyps across different scales to achieve the final segmentation results.

Lin et al. [24] introduced CSwinDoubleU-Net, a novel dual U-shaped image segmentation network that combines an interlaced convolutional structure with Shifted Windows (Swin) Transformer to address segmentation challenges such as differentiation between polyp regions and backgrounds and motion blur. The model is a CNN-based structure featuring a U-shaped encoder and decoder. The first U-shaped encoder network ensures the precise location of encoded features at each step by considering positional information, achieved through multiple convolutional layers. Subsequently, the second U-shaped encoder network garners additional global feature information using Swin Transformer layers with the shifted window technique. Finally, a Convolution Feature And Self-Attention Feature Fusion Module (CSFFM) has been developed to merge local convolutional features from the first U-shaped structure with global self-attention features from the second U-shaped structure. Liu and Song [25] proposed Attention Combined Pyramid Vision Transformer (Att-PVT), a novel approach that combines CNN and PVT to accurately detect the position and size of polyps. The proposed model consists of three main components: Multidimensional Information Extraction (MIE), Cascaded Context Integration (CCI), and Multilevel Feature Fusion (MFF). Att-PVT utilizes feature maps through the MIE module. CCI aims to learn semantic and spatial information by adaptively combining the top three layers of polyp features. The MFF module integrates boundary information from a higher-level global map with lower-level layers. This module is crucial for the accurate segmentation of colorectal polyps. Nguyen and Nguyen [26] proposed PolyPooling, a model designed for the precise segmentation of polyps. The encoder utilizes PoolFormer, employing a hierarchical structure to encode multilevel features. For decoding, the model leverages the Hamburger module and the Convolutional Block Attention Module (CBAM). The SegFormer decoder processes blocks in parallel with associated MLP modules before combining them. Within the proposed model, the Channel-wise Feature Pyramid (CFP) and refinement module are used in conjunction with the Pooling Reverse Attention module (Pooling-RA). CFP

enables parallel learning while capturing finer details. The Pooling-RA module is suggested to mitigate computational complexity. Huang et al. [27] proposed a U-Net neural network model to enhance segmentation accuracy rates. The traditional U-Net serves as the foundational architecture for Reparameterized Convolutional Network (RCNU-Net). For segmentation, a specific loss calculation method known as CDLoss is employed within the proposed model. To prevent gradient loss, a multi-branched structural model is utilized. The CBAM acts as a crucial bridge by expanding the receptive field of filters in both channel and spatial dimensions. This facilitates a secondary feature extraction that leverages attention benefits for superior contextual information aiding segmentation. This study employs a joint loss calculation method that combines both Cross-Entropy Loss (CELoss) and Dice Loss in the overall architecture.

Despite new methods emerging in the literature for polyp segmentation, researchers have yet to fully overcome the challenges encountered in polyp segmentation. This field remains highly current and exciting. In this article, unlike other literature studies, the performance of the DeeplabV3+ architecture's backbone networks, which have provided quite successful results in segmentation processes, is examined. Four different CNN architectures were applied to the backbone network of the DeepLabV3+ architecture: Model 1 (DeepLabV3+), Model 2 (ResNet50), Model 3 (SqueezeNet), and Model 4 (VGG16); and the results were tested on two significant datasets.

The organization of the rest of the paper is as follows: In the Materials and methods section, we present the Used datasets, DeepLabV3+ architecture, Evaluation metrics and Implementation details. Results section contains the results section, which presents the experimental studies and results. The last section includes Discussion and conclusion.

Material and method

Used datasets

In this article, experiments were conducted on the two most preferred datasets in polyp segmentation studies to compare and evaluate the models used with the latest state-of-the-art (SOTA) methods. These datasets are the publicly available Kvasir-SEG dataset [28] and the CVC-ClinicDB dataset [29].

The Kvasir-SEG dataset, created by expert clinicians in 2020, comprises a total of 1000 colonoscopy images. The resolution of these images varies between 1920x1072 and 332x487. Ground truth (GT) images are available for all 1000 images. The CVC-ClinicDB dataset, introduced in 2015, consists of a total of 612 colorectal images obtained from 31 colorectal sequences. Ground truth images are also available for each image in this dataset.

DeepLabV3+ architecture

The DeepLabV3+ architecture consists of encoder and decoder modules [30]. The encoder is used to reduce feature maps and extract a set of semantic features, while the decoder is used to restore spatial information and generate more explicit segmentation features. The DeepLabV3+

architecture is an enhancement of the DeepLabV3 architecture. This network architecture adds a decoding module based on DeepLabV3 and the output combination of the encoder module becomes the input to the decoder module. The architecture broadly employs a backbone network and an ASPP mechanism. The ASPP mechanism consists of one 1×1 atrous convolution and three 3×3 atrous convolutions with atrous rates of 6, 12, and 18, respectively, along with a global pooling layer. The four convolution operations and one pooling layer are processed in parallel. The backbone network is utilized to extract semantic information of features [31]. The original DeepLabV3+ architecture employs the Xception model Chen et al. [30] as its backbone network. Features from the Backbone Network and ASPP mechanism are subjected to 4 times subsampling. Fig. 1 shows the DeepLabV3+ architecture. In this article, an end-to-end framework using the DeepLabV3+ architecture for the automatic segmentation of polyps has been developed. DenseNet [32], ResNet50 [33], SqueezeNet [34], and VGG16 [35] models were used as the Backbone Network, and the segmentation success of the architecture was tested across different backbone networks.

The DenseNet architecture derives its name from "Densely Connected Convolutional Networks." It is distinguished by its dense connections, allowing each layer to receive inputs from all preceding layers. This structure promotes the reuse of features, increases the model's parameter efficiency, and facilitates more effective gradient propagation through deep networks. As a result, high performance is achieved with fewer parameters, even in deeper networks.

The ResNet50 architecture is a popular CNN architecture that utilizes the residual learning approach for deep learning. Thanks to residual blocks, it enables efficient transmission of gradients to deeper layers, thus overcoming the vanishing gradient problem encountered with very deep networks and facilitating easier model training. The SqueezeNet architecture offers exceptional parameter efficiency among CNN architectures. It uses 'fire' modules in its structure and directly classifies the feature maps of each class using global average pooling instead of fully connected at the last layer, thus significantly reducing the model size.

The VGG16 architecture is a CNN architecture that demonstrates that depth can improve model performance. In its structure, 3×3 convolutional filters and maximum pooling layers are sequentially ordered and complemented by three dense layers. Each convolution block improves in-depth feature extraction by increasing the number of filters, and the ReLU activation function is used.

Pre-trained CNN networks serve as the "backbone" of the model by extracting low-level features from the input image. Using DenseNet architecture as the backbone network for pre-trained DeepLabV3+ architecture is referred to as Model 1, utilizing ResNet 50 architecture is named Model 2, employing SqueezeNet architecture is named Model 3, and utilizing VGG16 architecture is named Model 4.

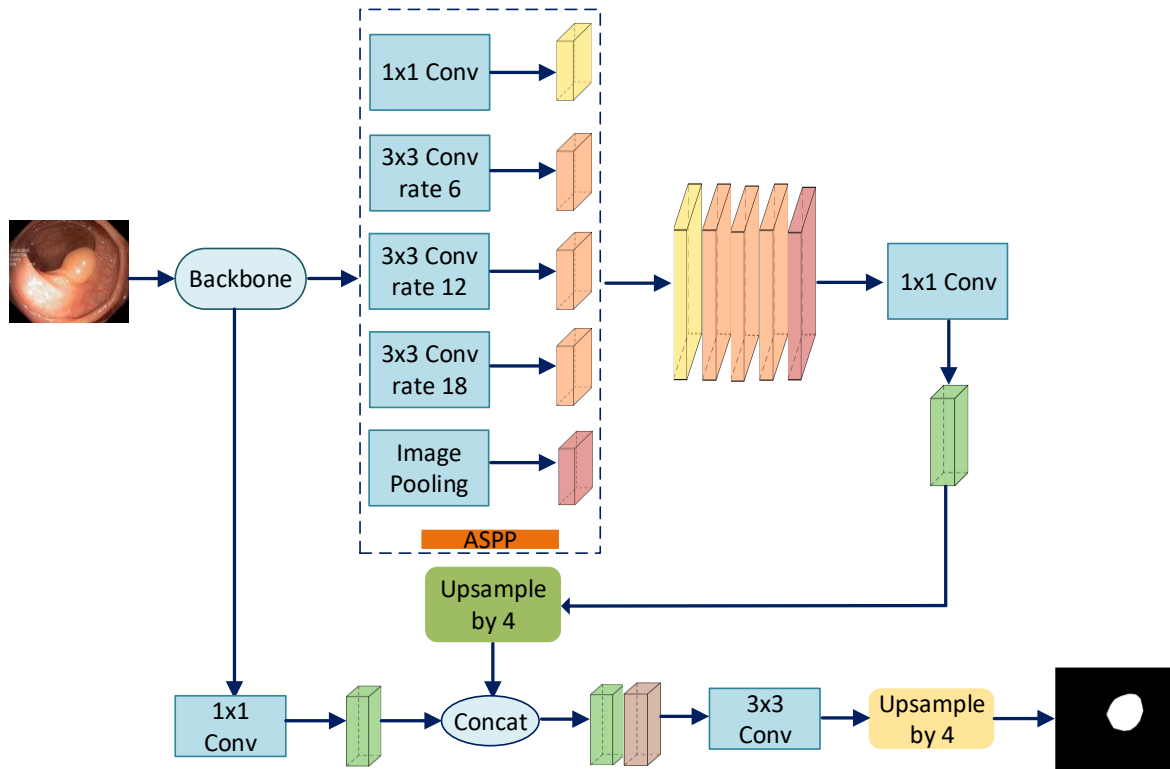


Figure 1. DeepLabV3+ architecture

Evaluation metrics

There are many different evaluation metrics commonly used in the field of medical image segmentation. This article has opted for the most frequently used evaluation metrics, and Equations (1)- (7) provide the mathematical expressions for these metrics. In the mathematical expressions, the terms FN, FP, TP, and TN are used to denote the number of false negatives, false positives, true positives, and true negatives, respectively.

$$mDice = \frac{1}{1+k} \sum_{i=0}^k \frac{2TP}{2TP + FP + FN} \quad (1)$$

$$mIoU = \frac{1}{1+k} \sum_{i=0}^k \frac{TP}{TP + FP + FN} \quad (2)$$

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$Sp = \frac{TN}{TN + FP} \quad (5)$$

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

$$MAE = \frac{1}{w \times H} \sum_{i=1}^w \sum_{j=1}^H |S(i,j) - G(i,j)| \quad (7)$$

Implementation details

All CNN architectures integrated into the backbone network of the DeepLabV3+ architecture have been trained using the TensorFlow framework on an NVIDIA RTX A4000 GPU. The same set of hyperparameters has been chosen for each model. These parameters are presented in Table 1.

Table 1. Optimal hyper-parameter values.

Hyper-Parameter	Value
Learning rate	0,0001
Batch size	8
Optimizer	Adam
Activation function	ReLU

Results

The datasets used in polyp segmentation with the DeepLabV3+ architecture have been divided into training,

validation, and testing sets. Each dataset was shuffled before being fed into the network and randomly split into 80% for training and 20% for testing. 20% of the data in the training dataset was used for validation. Accordingly, of the Kvasir-SEG dataset, 640 were used for training, 200 for testing, and 160 for validation. For the CVC-ClinicDB dataset, 392 were used for training, 122 for testing, and 98 for validation.

The experimental results obtained from the integration of the DeepLabV3+ architecture with different CNN architectures have been presented in terms of mDice and mIoU evaluation metrics for the Kvasir-SEG and CVC-ClinicDB datasets, respectively, in Fig. 2 and Fig. 3.




Figure 2. Results from the Kvasir-seg dataset.

According to Fig. 2, the evaluation metrics for the Kvasir-SEG dataset results are displayed, indicating that the best performance in polyp segmentation was achieved with Model 1, while the lowest performance was observed with Model 3.




Figure 3. Results from the CVC-ClinicDB dataset.

According to Fig. 3, the evaluation metrics for the results on the CVC-ClinicDB dataset are displayed, indicating that the best performance in polyp segmentation was achieved with Model 2, while the lowest performance was observed with Model 3.

The quantitative findings of the models and their comparison with SOTA methods are presented in Table 2. The performance success of SOTA methods is derived from the article by [9]. Gangrade et al. [9], conducted experiments with a 256x256 image size and training for 25 epochs. Additionally, the learning rate was set at 0.0002, and the Adam optimizer was chosen as the optimization method.

The dataset was divided into 80% training, 10% validation, and 10% testing. For the comparison to be fair, it's necessary to keep the hyper-parameters consistent; however, this article has conducted a comparison with hyper-parameter analysis. Gangrade et al. [9] trained for 25 epochs, but this was not considered sufficient for updating the weights. There might have been a case of overfitting. Choosing a learning rate of 0.0002 can increase the likelihood of the network getting stuck in local minima and extend the time it takes to reach the global minimum. The purpose of this table is to display the performance of methods on datasets. Thus, it demonstrates the level at which models obtained through the integration of different CNN architectures with DeepLabV3+ architecture stand in the literature.

In this article, data augmentation was not performed on the two datasets used, and the data were not subjected to preprocessing. Due to the images in the dataset being of various resolutions, the images were provided to the network architectures at a resolution of 256x256.

Fig. 4 and Fig. 5 display some example qualitative results of experiments conducted on the Kvasir-SEG and CVC-ClinicDB datasets, respectively. In these visuals, the first column represents images from the original dataset. The second column represents the ground truth (GT) images. The last four columns show the segmentation results for Model 1, Model 2, Model 3, and Model 4, respectively.

Looking at the test images provided in Fig. 4, it can be observed that Models 3 and Model 4 have low segmentation success in the third image. This situation indicates that these architectures struggle with images of non-polypoid lesions.

When looking at the test images provided in Fig. 5, it is observed that Model 3 is the most challenged. Upon examining the visual results, it can be concluded that the SqueezeNet architecture performs weaker as a backbone for DeepLabV3+ compared to other architectures.




Figure 4. Kvasir-seg dataset segmentation results.




Figure 5. CVC-ClinicDB dataset segmentation results.

Discussion and conclusion

Polyps, although generally benign structures, can be considered precancerous lesions in some cases. The early diagnosis and treatment of these structures are of great

importance, especially in preventing serious health issues like colorectal cancer.

This article presents polyp segmentation on colonoscopy images using the DeepLabV3+ architecture with various backbone networks. In the method, pre-trained CNN

networks are used as the backbone for the DeepLabV3+ architecture. This approach allows the network to adapt more quickly to datasets by leveraging what it has learned from previous tasks, achieving higher performance with less input.

The performance of the conducted study has been compared with other SOTA methods in the literature. Upon examining Table 2, it is observed that SOTA methods yield different results for each dataset. According to the Table 2, the best result on the Kvasir-SEG dataset was obtained with the DeepLabV3+ architecture's Inception backbone.

However, the best result on the CVC-ClinicDB dataset was achieved with Model 2, which uses the ResNet50 architecture as its backbone network. Experimental studies have been evaluated using metrics such as mDice, mIoU, Acc, Recall, SP, and MAE. According to these metric results, the worst backbone network for both datasets was the SqueezeNet architecture. In the study, experiments were conducted on raw data without any data augmentation or preprocessing. While this approach may reduce the models' generalization ability, it has sped up the analysis of the models' performance on raw data. For the future, it is recommended to modify the DeepLabV3+ architecture with the Resnet50 backbone network to increase the models' robustness and generalizability.

Ethics committee approval and conflict of interest statement

There is no need to obtain permission from the ethics committee for the article prepared.

There is no conflict of interest with any person / institution in the article prepared.

Authors' Contributions

AKGÖL: Conceptualization, Methodology, Writing – original draft. TOPTAŞ: Supervision, Validation, Writing – editing.

References

- [1] B. Toptaş and D. Hanbay, "Separation of arteries and veins in retinal fundus images with a new CNN architecture," *Comput. Methods Biomech. Biomed. Eng. Imaging Vis.*, vol. 11, no. 4, pp. 1512–1522, 2023, doi: 10.1080/21681163.2022.2151066.
- [2] M. Toptaş and D. Hanbay, "Mikroskopik Kan Hücre Görüntülerinin Güncel Derin Öğrenme Mimarıları ile Bölütlemesi," *Mühendislik Bilim. ve Araştırmaları Derg.*, vol. 5, no. 1, pp. 135–141, 2023, doi: 10.46387/bjesr.1261689.
- [3] C. Özdemir, "Meme Ultrason Görüntülerinde Kanser Hücre Segmentasyonu için Yeni Bir FCN Modeli," *Afyon Kocatepe Univ. J. Sci. Eng.*, vol. 23, no. 5, pp. 1160–1170, 2023, doi: 10.35414/akufemubid.1259253.
- [4] N. Şahin, N. Alpaslan, and D. Hanbay, "Robust optimization of SegNet hyperparameters for skin lesion segmentation," *Multimed. Tools Appl.*, vol. 81, no. 25, pp. 36031–36051, 2022, doi: 10.1007/s11042-021-11032-6.
- [5] W. Zhang, F. Lu, H. Su, and Y. Hu, "Dual-branch multi-information aggregation network with transformer and convolution for polyp segmentation," *Comput. Biol. Med.*, vol. 168, 2024, doi: 10.1016/j.combiomed.2023.107760.
- [6] A. Siegel, R. L. Miller, K. D. Fuchs, H. E., & Jemal, "Cancer statistics, 2021," *Ca Cancer J Clin*, pp. 7–33, 2021.
- [7] O. H. Maghsoudi, "Superpixel based segmentation and classification of polyps in wireless capsule endoscopy," in *2017 IEEE Signal Processing in Medicine and Biology Symposium, SPMB 2017 - Proceedings*, 2017, pp. 1–4. doi: 10.1109/SPMB.2017.8257027.
- [8] S. Hwang and M. E. Celebi, "Polyp detection in Wireless Capsule Endoscopy videos based on image segmentation and geometric feature," in *2010 IEEE International Conference on Acoustics, Speech and Signal Processing*, IEEE, 2010, pp. 678–681. doi: 10.1109/ICASSP.2010.5495103.
- [9] S. Gangrade, P. C. Sharma, A. K. Sharma, and Y. P. Singh, "Modified DeeplabV3+ with multi-level context attention mechanism for colonoscopy polyp segmentation," *Comput. Biol. Med.*, vol. 170, 2024, doi: 10.1016/j.combiomed.2024.108096.
- [10] S. Li *et al.*, "Boundary guided network with two-stage transfer learning for gastrointestinal polyps segmentation," *Expert Syst. Appl.*, vol. 240, 2024, doi: 10.1016/j.eswa.2023.122503.
- [11] W. Li, Z. Huang, F. Li, Y. Zhao, and H. Zhang, "CFG-Net: Cross-level information fusion and guidance network for Polyp Segmentation," *Comput. Biol. Med.*, vol. 169, 2024, doi: 10.1016/j.combiomed.2024.107931.
- [12] X. Jia *et al.*, "PolypMixNet: Enhancing semi-supervised polyp segmentation with polyp-aware augmentation," *Comput. Biol. Med.*, vol. 170, 2024, doi: 10.1016/j.combiomed.2024.108006.
- [13] Y. He, Y. Yi, C. Zheng, and J. Kong, "BGF-Net: Boundary guided filter network for medical image segmentation," *Comput. Biol. Med.*, vol. 171, 2024, doi: 10.1016/j.combiomed.2024.108184.
- [14] D. Liu, H. Deng, Z. Huang, and J. Fu, "FCA-Net: Fully context-aware feature aggregation network for medical segmentation," *Biomed. Signal Process. Control*, vol. 91, 2024, doi: 10.1016/j.bspc.2024.106004.
- [15] H. Wang *et al.*, "Unveiling camouflaged and partially occluded colorectal polyps: Introducing CPSNet for accurate colon polyp segmentation," *Comput. Biol. Med.*, vol. 171, 2024, doi: 10.1016/j.combiomed.2024.108186.
- [16] G. Liu *et al.*, "CAFE-Net: Cross-Attention and Feature Exploration Network for polyp segmentation," *Expert Syst. Appl.*, vol. 238, 2024, doi: 10.1016/j.eswa.2023.121754.
- [17] D. Shao, H. Yang, C. Liu, and L. Ma, "AFANet: Adaptive Feature Aggregation for Polyp Segmentation," *Med. Eng. Phys.*, p. 104118, 2024, doi: 10.1016/j.medengphy.2024.104118.

- [18] Z. U. D. Muhammad, U. Muhammad, Z. Huang, and N. Gu, "MMFIL-Net: Multi-level and multi-source feature interactive lightweight network for polyp segmentation," *Displays*, vol. 81, 2024, doi: 10.1016/j.displa.2023.102600.
- [19] G. Yue *et al.*, "Boundary uncertainty aware network for automated polyp segmentation," *Neural Networks*, vol. 170, pp. 390–404, 2024, doi: 10.1016/j.neunet.2023.11.050.
- [20] S. Ahmed and M. K. Hasan, "Twin-SegNet: Dynamically coupled complementary segmentation networks for generalized medical image segmentation," *Comput. Vis. Image Underst.*, vol. 240, 2024, doi: 10.1016/j.cviu.2023.103910.
- [21] P. Fan, Y. Diao, F. Li, W. Zhao, and Z. Chen, "SRSegNet: Super-resolution-assisted small targets polyp segmentation network with combined high and low resolution," *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 36, no. 3, 2024, doi: 10.1016/j.jksuci.2024.101981.
- [22] J. Liu, Q. Chen, Y. Zhang, Z. Wang, X. Deng, and J. Wang, "Multi-level feature fusion network combining attention mechanisms for polyp segmentation," *Inf. Fusion*, vol. 104, 2024, doi: 10.1016/j.inffus.2023.102195.
- [23] X. Pan, C. Ma, Y. Mu, and M. Bi, "GLSNet: A Global Guided Local Feature Stepwise Aggregation Network for polyp segmentation," *Biomed. Signal Process. Control*, vol. 87, 2024, doi: 10.1016/j.bspc.2023.105528.
- [24] Y. Lin, X. Han, K. Chen, W. Zhang, and Q. Liu, "CSwinDoubleU-Net: A double U-shaped network combined with convolution and Swin Transformer for colorectal polyp segmentation," *Biomed. Signal Process. Control*, vol. 89, 2024, doi: 10.1016/j.bspc.2023.105749.
- [25] X. Liu and S. Song, "Attention combined pyramid vision transformer for polyp segmentation," *Biomed. Signal Process. Control*, vol. 89, 2024, doi: 10.1016/j.bspc.2023.105792.
- [26] D. C. Nguyen and H. L. Nguyen, "PolyPooling: An accurate polyp segmentation from colonoscopy images," *Biomed. Signal Process. Control*, vol. 92, 2024, doi: 10.1016/j.bspc.2024.105979.
- [27] B. Huang, T. Huang, J. Xu, J. Min, C. Hu, and Z. Zhang, "RCNU-Net: Reparameterized convolutional network with convolutional block attention module for improved polyp image segmentation," *Biomed. Signal Process. Control*, vol. 93, 2024, doi: 10.1016/j.bspc.2024.106138.
- [28] D. Jha *et al.*, "Kvasir-SEG: A Segmented Polyp Dataset," 2020, pp. 451–462. doi: 10.1007/978-3-030-37734-2_37.
- [29] J. Bernal, F. J. Sánchez, G. Fernández-Esparrach, D. Gil, C. Rodríguez, and F. Vilarinho, "WM-DOVA maps for accurate polyp highlighting in colonoscopy: Validation vs. saliency maps from physicians," *Comput. Med. Imaging Graph.*, vol. 43, pp. 99–111, Jul. 2015, doi: 10.1016/j.compmedimag.2015.02.007.
- [30] L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, "Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation," Feb. 2018, doi: <https://doi.org/10.48550/arXiv.1802.02611>.
- [31] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, and R. M. Summers, "ChestX-ray8: Hospital-scale chest X-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases," *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, vol. 2017-Janua. pp. 3462–3471, 2017. doi: 10.1109/CVPR.2017.369.
- [32] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, "Densely Connected Convolutional Networks," Aug. 2016, [Online]. Available: <http://arxiv.org/abs/1608.06993>
- [33] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem. pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [34] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size," Feb. 2016, [Online]. Available: <http://arxiv.org/abs/1602.07360>
- [35] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, 2015.
- [36] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," 2015, pp. 234–241. doi: 10.1007/978-3-319-24574-4_28.
- [37] Z. Zhou, M. M. R. Siddiquee, N. Tajbakhsh, and J. Liang, "UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation," *IEEE Trans. Med. Imaging*, vol. 39, no. 6, pp. 1856–1867, Jun. 2020, doi: 10.1109/TMI.2019.2959609.
- [38] D. Jha *et al.*, "Real-Time Polyp Detection, Localization and Segmentation in Colonoscopy Using Deep Learning," *IEEE Access*, vol. 9, pp. 40496–40510, 2021, doi: 10.1109/ACCESS.2021.3063716.



Makine Öğrenmesi Teknikleri ile İşten Ayrılacak Personelin Tahminlenmesi ve Tekniklerin Performanslarının Karşılaştırılması

Prediction of Staff Turnover by Machine Learning Techniques and Comparison of the Performances of Techniques

Batuhan Bilenler^{1*}, Sait Gül², Tamer Uçar³

¹ Bahçeşehir Üniversitesi, İşletme Mühendisliği Bölümü, batuhan.bilenler@bahcesehir.edu.tr

ORCID: <https://orcid.org/0000-0002-7925-4876>

² Bahçeşehir Üniversitesi, İşletme Mühendisliği Bölümü, sait.gul@bau.edu.tr

ORCID: <https://orcid.org/0000-0002-6011-0848>

³ Bahçeşehir Üniversitesi, Yazılım Mühendisliği Bölümü, tamer.ucar@bau.edu.tr

ORCID: <https://orcid.org/0000-0002-9397-6656>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 17 Temmuz 2024
Revizyon 10 Ekim 2024
Kabul 22 Ekim 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

Personel kayıp tahmini, makine öğrenmesi, insan kaynakları analitiği, veri analizi.

ÖZ

Şirketlerin sürdürülebilir başarısı için yetenekli insan kaynağını şirkette tutundurmak oldukça önemlidir. Bu çalışmada, araştırma yapmak amacıyla açık kaynak olarak Kaggle platformunda HR_comma_sep.csv ismiyle yer alan 14.999 personelin verileri kullanılarak işten ayrılacak olan personelin tahminlenmesi amaçlanmıştır. Gradyan Artırma, Rastgele Orman ve Ekstrem Gradyan Artırma regresyon teknikleri ile tahminleme yapılmıştır. Değerlendirme metrikleri olan ortalama mutlak hata (mean absolute error), hata karelerinin ortalaması (mean squared error), R² skoru ve düzeltilmiş R² (Adjusted R²) değerleri karşılaştırılmış olup 3 modelin de anlamlı ölçüde tahminleme yapabilir olduğu sonucuna ulaşılmıştır. Ortalama hata skorları birbirine oldukça yakın olduğu için R² değeri 1'e en yakın olan Rastgele Orman tekniği üzerinden özellik önemi çıkarılmıştır. İncelenen özellikler arasında, işten ayrılmayı etkileyen en önemli öznenliğin personel tatmini olduğu görülmüştür. Makine öğrenmesi tekniklerinin insan kaynakları alanında kullanımının, şirket içerisindeki yetenekli personeli şirkete tutundurma stratejilerini belirleme anlamında insan kaynakları yöneticilerine oldukça faydalı çıktılar üretebileceği düşünülmektedir.

ARTICLE INFO

Article history:

Received 17 July 2024
Received in revised form 10 October 2024
Accepted 22 October 2024
Available online 23 December 2024

Keywords:

Staff turnover rate, machine learning, human resources analytics, data analysis.

ABSTRACT

Retaining talented human resources within a company is crucial for sustainable success. This study aims to predict staff turnover using a company's personnel data shared as open source for research purposes. Predictions were made using Gradient Boosting Tree, Random Forest Trees, and XGBoosting Regression techniques. The evaluation metrics used were mean absolute error, mean squared error, R² score and adjusted R² values. It was concluded that all three models could make significant predictions. Since the mean error scores of the three techniques were quite close to each other, feature importance was derived from the Random Forest technique, which had an R² value closest to 1. Among the features examined, employee satisfaction was found as the most important factor affecting staff turnover. It is believed that the usage of machine learning techniques in human resources management could produce highly beneficial insights for human resources managers in terms of determining strategies for retaining talented employees.

Doi: 10.24012/dumf.1517176

* Sorumlu Yazar

Giriş

Bir şirketin hedeflerine ulaşması için insan kaynağı yönetimine önem vermesi gerekmektedir. Yöneticilerin, hızla değişen piyasa koşullarına göre dinamik şekilde karar alabilmeleri ama aynı zamanda şirketi hedeflerine taşıyacak personelin mutluluğunu göz ardı etmemeleri gereklidir. Özellikle anahtar rolde bulunan personeli şirkete tutundurma amacıyla şirketlerin üst yönetimleri çeşitli yöntemler uygulayarak personellerin tatminini artırıcı hamleler yapmaktadırlar.

Gün geçtikçe farklılaşan sosyal, ekonomik ve teknolojik koşullar, her alanda olduğu gibi insan kaynakları alanında da yeni ihtiyaçlar doğurmakta ve bu ihtiyaçlar yeni kavramların, teorilerin ve uygulamaların ortaya çıkmasına neden olmaktadır [1]. İşletmeler için önemli değerlerden birisi de kayıpların önceden doğru şekilde tahmin edilebilmesidir [2]. Müşterileri elinde tutma, sadece en iyi ve faydalı müşterileri rakiplerden korumak değil, aynı zamanda onlar arasındaki ilişki ve bağlantıları sürdürmek ve böylece hizmet kullanımını ve buna bağlı geliri korumaktır [3].

İnsan Kaynağı (İK) analitiği, insan kaynakları süreçlerinin her biri hakkında daha iyi içgörü sağlamak, ilgili verileri toplamak ve daha sonra bu süreçlerin nasıl iyileştirileceğine dair objektif kararlar almak amacıyla kullanılan süreç, hesaplama veya modellerdir. İnsan kaynakları analitiği alanında literatür taraması gerçekleştirildiğinde analitik çalışmaların, personel seçim problemi ve mevcut personelin ayrılıp ayrılmaması üzerine yoğunlaştığı görülmektedir. Personelin işten ayrılma (*staff turnover*) tahmini probleminin ele alınış yöntemi olarak farklı farklı yaklaşımlara başvurulduğu görülmektedir. Shankar ve diğ. [4] veri madenciliği teknikleri kullanarak personelin işten ayrılma problemini istatistiksel bakış açısı ile tahminlemeye çalışmıştır. Alao ve diğ. [5], karar ağacı yöntemini kullanarak geçmiş verileri analiz ederek personelin ayrılma tahmininin yapılabileceğini göstermiştir. Abdulsalam ve diğ. [6], rastgele orman (random forest) ve convolution neural network algoritmaları kullanarak performans analizi gerçekleştirmiş ve trend olan iki yöntemi derinlemesine inceleyerek performans karşılaştırması yapmıştır. Gao ve diğ. [7] ise 2009 yılında rastgele orman yönteminin diğer makine öğrenmesi yöntemlerinden daha başarılı sonuçlar elde ettiğini gösteren bir karşılaştırmalı analiz gerçekleştirmişlerdir.

Tablo 1'de insan kaynağı analitiği alanında çözülen problemler ve bu problemleri çözme yöntemleri sınıflandırılmıştır. Görüldüğü gibi yazında çoğunlukla, personelin işten ayrılması ve personelin işe alımı konularında yoğunlaşmış olup, yöntemsel açıdan makine öğrenmesi tekniklerinin tercih edildiği görülmektedir.

Tablo 1. Makine Öğrenmesi ile İK Analitiğinde Yapılan Sınıflandırma ve Regresyon Çalışmaları

Çalışma-Yılı	Çalışmanın Türü	Değerlendirme Metrikleri	Çalışma Yapılan Veri seti
[8]- 2018	Sınıflandırma	Doğruluk oranı, Keskinlik, Duyarlılık, F1 değeri	Çalışmada kullanılan veri seti IBM HR Analytics Employee Attrition and Performance veri seti olarak belirtilmiştir.
[9]- 2019	Sınıflandırma	Doğruluk oranı, ROC Eğrisi altındaki alan, F1 değeri	Çin'de görev yapan bir Telekom şirketinin personel veri seti kullanılmıştır.
[10]- 2019	Sınıflandırma	Doğruluk oranı, F1 değeri, ROC Eğrisi altındaki alan	Çalışmada kullanılan veri seti IBM HR Analytics Employee Attrition and Performance veri seti olarak belirtilmiştir.
[11]- 2021	Sınıflandırma	Doğruluk oranı, ROC Eğrisi altındaki alan, F1 değeri	IBM HR Analytics Employee Attrition and Performance veri setini kullanmışlardır.
[12]- 2018	Regresyon	Kök Ortalama Kare Hatası, Ortalama Mutlak Hata	Çalışmada kullanılan veri seti Kaggle üzerinde mevcut olan IBM HR Analytics Employee Attrition and Performance'dır
[13]- 2023	Sınıflandırma	Doğruluk oranı, F1 değeri, ROC Eğrisi altındaki alan	Çalışmada belirtilen veri seti Kaggle'daki IBM HR Analytics Employee Attrition and Performance veri setidir.
[14]- 2018	Sınıflandırma	Doğruluk oranı, Keskinlik, Duyarlılık	IBM HR Analytics Employee Attrition and Performance veri seti kullanılmıştır.
[15]- 2022	Sınıflandırma	Doğruluk oranı, Keskinlik, Duyarlılık, F1 değeri	Bir telekomünikasyon şirketine ait gerçek veriler kullanılmıştır, ancak şirket adı belirtilmemiştir.
[16]- 2013	Sınıflandırma	Doğruluk oranı, F1 değeri	Nijerya Yüksek Enstitüsünün 1978-2006 arasında çalışan personel listesi
[17]- 2020	Sınıflandırma	Doğruluk oranı, ROC Eğrisi altındaki alan	Kaggle platformundaki IBM HR Analytics Employee Attrition and Performance veri seti kullanılmıştır.
[18]- 2018	Sınıflandırma	Doğruluk oranı, Keskinlik, Duyarlılık, F1 değeri	IBM HR Analytics Employee Attrition and Performance veri seti kullanılmıştır.
[19]- 2021	Sınıflandırma	Doğruluk oranı, F1 değeri, ROC Eğrisi altındaki alan	IBM HR Analytics Employee Attrition veri seti kullanılmıştır.
[20]- 2020	Sınıflandırma	Doğruluk oranı, Keskinlik, F1 değeri	IBM HR Analytics Employee Attrition and Performance veri seti kullanılmıştır.
[21]- 2023	Sınıflandırma	Doğruluk oranı, F1 değeri, Eğrinin altında kalan alan	IBM HR Analytics Employee Attrition and Performance veri seti kullanılmıştır.
[22]- 2022	Regresyon	Kök Ortalama Kare Hatası, Ortalama Mutlak Hata	IBM HR Analytics Employee Attrition and Performance veri seti kullanılmıştır.
[23]- 2021	Sınıflandırma	Doğruluk oranı, F1 değeri, ROC Eğrisi altındaki alan	IBM HR Analytics Employee Attrition and Performance veri seti kullanılmıştır.

Çoğu çalışma IBM HR Analytics Employee Attrition and Performance veri setini kullanmıştır. Bu veri seti, Kaggle'da halka açık olarak bulunan ve yaygın olarak kullanılan bir veri

setidir. Özel veri kaynakları kullanılan çalışmalarda ise şirket ismi genellikle belirtilmemiştir.

Regresyon tabanlı yaklaşım ile personelin işten ayrılma tahmini ile ilgili yapılan bir çalışmada, ortalama hata karelerinin kökü, destek vektör regresyon yöntemi ile 0,671; karar ağacı regresyon yönteminde 0,624; rastgele orman yöntemiyle 0,614 bulunmuştur [22]. Bu üç teknik arasında en başarılı sonucu rastgele orman tekniği vermiştir. Yapılan başka bir çalışmada ise, rastgele orman tekniğinin doğruluk oranı 0,985; Adaboosting tekniğinin ki ise 0,984 bulunmuştur. F1 değerleri ise 0,982 olarak aynı bulunmuştur. Bu da sınıflandırma tabanlı işten ayrılma tahmininin her iki yöntemin de başarılı şekilde yapabileceğini göstermiştir [13].

Personelin işten ayrılma tahmini üzerine yöntemleri karşılaştıran bir çalışmada ise, en iyi sınıflandırma modelinin %97,5 doğruluk oranı ile rastgele orman olduğunu önermektedir. İkinci en iyi yöntem, %96,6 doğruluk oranı ile naïve bayes'tir ve en düşük doğruluk oranına sahip sınıflandırma modeli ise %88,7 ile karar ağacı olarak çıkmıştır [14]. Çalışma bu makine öğrenmesi teknikleri içerisinde, çalışan devrini tahmin etmek için en güvenilir ve doğru sınıflandırma modelinin rastgele orman algoritması olduğunu tespit etmiştir.

Başka bir çalışmada ise personelin ayrılma tahmini kNN ve rastgele orman tekniği ile ayrı ayrı yapılmış ve performanslar karşılaştırılmıştır. Rastgele orman %80 oranında doğruluk oranı verirken kNN %84 performans göstermiştir. ROC altında kalan alanlar karşılaştırıldığında ise rastgele orman tekniğinin daha çok alan kapladığını göstermiştir.

Literatürde yapılan çalışmalara bakıldığında zaman sınıflandırma problemi için doğruluk değeri, F1 skoru, duyarlılık değerlerine ağırlıklı olarak bakıldığını görmekteyiz. Regresyon probleminde ise, Ortalama Mutlak Hata, hata karelerinin ortalamasının karekökü, gerektiğinde R-kare değerine bakıldığı görülmektedir. Yapılan bu çalışma regresyon problemi olduğu için ortalama hata, mutlak hata, hata karelerinin ortalamasının karekökü ve R-kare değerlerine bakılmaktadır.

Personelin işten ayrılma tahmini üzerine yapılan ampirik çalışmalar, insan kaynakları yönetiminde büyük önem taşımaktadır. Bu çalışmalarda genellikle makine öğrenimi algoritmaları kullanılarak, çalışanların işten ayrılma eğilimlerini belirlemeye yönelik modeller geliştirilir. IBM HR Analytics gibi popüler veri setleri üzerinde çalışan araştırmacılar, çalışanların yaş, kıdem, maaş, departman, iş memnuniyeti ve eğitim gibi çeşitli özelliklerini analiz ederek ayrılma olasılığını tahmin etmeye çalışmışlardır.

Personelin İşten Ayrılma Tahmin Problemi

Literatürdeki çoğu çalışma, çalışan devrini iki farklı kategori ve ikisinin de altında ikiye farklı tür olmak üzere dört açıdan incelemektedir [24-25].

- *İşten Çıkarma Devri:* Bu tür devir, organizasyon tarafından başlatılır ve bireysel bir çalışanı hedefler. Sebepler ise, çalışanın disiplin ve/veya performans sorunlarıyla ilgili olabilir.

- *Küçülme Devri:* Bu tür devir, organizasyon tarafından başlatılır ve organizasyonel yeniden yapılanmanın bir parçası olarak meydana gelir (kaybedilen fon, iş gereksinimlerinin değişmesi, yeniden yapılanma gibi).
- *Kaçınılabılır Devir:* Bu tür devir, çalışan tarafından başlatılır ve organizasyon tarafından muhtemelen önlenebilir.
- *Kaçınılamaz Devir:* Bu tür devir, çalışan tarafından başlatılır ve emeklilik, ölüm gibi kaçınılmaz durumlarda meydana gelir.

Personelin İşten Ayrılmasını Etkileyen Parametreler ve Yapılmış Benzer Çalışmalar

Bir isteğe bağlı devir çalışmasının meta-analiz yaklaşımı ile gösterdiği gibi, bir çalışanın yaş, cinsiyet gibi demografik özellikleri ile maaş, kıdem, iş tatmini gibi birçok çalışma ortamı özelliklerinin devir tahmininde birlikte rol oynadığı görülmektedir [26]. Yaş, ekonomik faaliyet, kıdem, mevcut pozisyondaki çalışma süresi ve eğitim gibi değişkenlerin devir üzerindeki en güçlü göstergeler olduğunu belirten başka çalışmalar da vardır [27]. İş tatmininin çalışan devrinde anahtar rol oynadığını gösteren pek çok çalışma söz konusudur [27]-[33]. Çalışmada göz önüne alınan öznitelikler Tablo 2'de özellikleriyle birlikte verilmektedir.

İş bağlılığı kavramını kullanarak çalışanların işten ayrılma niyetlerini tahmin etmeye yönelik çoklu yöntemler kullanılır. Hangi özniteliklerin işten ayrılma kararını etkilediğini görebilmek amacıyla yapılan bir çalışmada yaş, cinsiyet, eğitim seviyesi gibi demografik faktörlerin iş bağlılığı ve işten ayrılma niyeti üzerindeki etkileri incelenmiştir. Çalışma sonucunda, çalışanların organizasyona ve topluluğa olan bağlılıklarının işten ayrılma niyetlerini önemli ölçüde azalttığı gözlemlenmiştir [34]. Başka bir çalışmada ise, çalışanların iş tatmini ve işten ayrılma niyeti arasındaki ilişkiye psikolojik güçlendirme faktörünün etkisi incelenmiştir. Psikolojik güçlendirme, iş tatmininin işten ayrılma niyeti üzerindeki etkisini moderatör olarak değerlendirmiştir. İş tatminini artırıcı önerilerde bulunulmuştur [35].

Sağlık sektöründe gerçekleştirilen bir başka çalışmada, sağlık çalışanlarında iş-aile çatışmasının işten ayrılma niyeti üzerindeki etkileri araştırılmıştır. İş-aile çatışmasının iş tatmini ve genel iş memnuniyeti üzerindeki olumsuz etkilerini değerlendirip, bu çatışmanın işten ayrılma niyeti ile olan ilişkisi irdelenmiştir. İş-aile memnuniyeti azaldıkça işten ayrılmanın arttığı sonucuna ulaşılmıştır [36].

Makine öğrenimi tekniklerinin işten ayrılma tahmini için nasıl kullanılabileceğine dair bir çalışmada ise, veri madenciliği ve makine öğrenimi algoritmalarını kullanarak çalışanların işten ayrılma niyetlerini tahmin etmeye yönelik çeşitli modeller sunulmuştur. Rastgele orman ve Gradyan artırma tekniklerinin diğer tekniklerden daha başarılı sonuç verdiği çalışmanın sonucunda ortaya konulmuştur [37].

Çalışan direncinin, işten ayrılma niyetini nasıl etkileyebileceği ve finans sektöründeki örneklerle bu etkinin nasıl değiştiğini araştıran başka bir çalışmada, anket üzerinden alınan verilerle yapısal eşitlik modeli kurulmuş ve yüksek çalışan dayanıklılığının, işten ayrılma niyetini

azaltıcı bir etkisi olduğu bulunmuştur. Dayanıklı çalışanlar, zorluklar karşısında daha dirençli oldukları için işlerinden ayrılma niyetleri daha düşük olmaktadır [38].

İş ortamında bireylerin mutlu olmasının, iş bağlılığı, iş tatmini ve duygusal organizasyonel bağlılığı etkilediği fikriyle yola çıkılmış olan başka bir çalışmada tüm organizasyonel seviyelerde, mutluluğun bireyler ve organizasyonlar için önemli sonuçları olduğu ve işe bağlılık ile iş tatmini arasında anlamlı bir ilişki olduğu ortaya çıkarılmıştır [39]. Başka bir çalışmada ise, 245 itfaiyeci ve onların süpervizörleri ile çalışan bağlılığını etkileyen özniteliklerin tespit edilmesi hedeflenmiştir. Bağlılığın, algılanan örgütsel destek ve temel öz değerlendirmeler görev performansı ve örgütsel vatandaşlık davranışı arasındaki ilişkilere aracılık ettiğine dair sonuçlar ortaya çıkmıştır [40].

Tükenmişlik, motivasyon ve performans kavramlarının iş ortamındaki kaynak miktarındaki artış sağlandığı takdirde nasıl etkileneceği sorusuna yanıt bulmak için yapılan bir çalışmada, çalışma ortamında iş kaynaklarındaki artışın, çalışanların bağlılık ve performansı üzerinde olumlu bir etkisi olduğu bulunmuştur. Yüksek iş tatmini, çalışanların işlerine karşı daha olumlu bir tutum sergilemesine ve bağlılıklarının artmasına neden olabilir sonucuna ulaşılmıştır. Bu durum, hem bireysel hem de örgütsel düzeyde verimliliği artırabilir öngörüsü desteklenmiş ve stresle başa çıkma duygusunun kuvvetlendirildiği, uzun çalışma sürelerinin azalacağına dair inancın artırıldığına ve böylece de işten ayrılma duygusunun azaldığı sonucuna ulaşılmıştır [41]. Esnek çalışma programlarının iş-yaşam dengesi, çalışan memnuniyeti ve genel iş performansı üzerindeki etkilerini incelemek üzere yapılan başka bir çalışmada, esnek çalışma düzenlerinin çalışanların iş stresini azaltma, iş tatminini artırma ve işe olan bağlılıklarını güçlendirme potansiyeline sahip olduğunu gösterilmiştir [42].

Bu çalışma kapsamında, Gradyan artırma, rastgele orman ve ekstrem Gradyan artırma regresyon teknikleri ile personelin işten ayrılma kararı alıp almayacağını ayrı ayrı tahminlenmesi ve kullanılan üç tekniğin performanslarının karşılaştırılması yapılmaktadır. Ayrıca personeli ayrılma kararına götüren en önemli özniteliklerin belirlenmesi de çalışmanın amaçlarından biridir.

Materyal ve Metot

Bu çalışmada personelin işten ayrılma tahmini için kullanılacak modeller oluşturulmadan önce veri analiz edilmiş olup birtakım veri ön işleme süreçleri işletilmiştir. Veri analizi ve modelleri Knime Analytic Tool aracı kullanılarak gerçekleştirilmiştir. Knime, veri analizi ve makine öğrenmesi yöntemlerinin kullanımına olanak sağlayan kullanıcı dostu bir analitik araçtır. İş parçacıklarını yapmakla görevli düğümleri hazır olarak sunması önemli bir özelliğidir. Düğümleri uç uca ekleme mantığı ile çalışmaktadır.

Bu yöntemlerin tercih edilmesindeki temel motivasyon ağaç yöntemlerinin ileri versiyonu olarak kabul edilen torbalama (bagging) ve artırmalı ağaç (boosting) yöntemlerini birlikte kullanan ve performanslarını karşılaştıran bir karar destek sistemi oluşturmaktır. Zaman içerisinde yeni personel

verileri eklendikçe veri setinin varyansı değişecektir. Bu nedenle, düşük ve yüksek varyans durumlarının her ikisinde de başarılı çalışabilecek ağaç modelleri tercih edilmiştir. Herhangi bir t anında veri setinin güncel durumuna bağlı olarak yöntem değişiklik gösterebilecektir. Bu sayede karar destek sisteminde yöntem bazlı bir esneklik yaratması hedeflenmiştir.

Kullanılan Veri Seti

Bu çalışmada, araştırma yapmak amacıyla açık kaynak olarak Kaggle platformunda bulunan HR_comma_sep.csv isimli veri seti kullanılmıştır [49]. Veri seti 14.999 personel verisinden oluşmaktadır. Tablo 2’de veri setini oluşturan özniteliklerin yapısı hakkında bilgi verilmektedir.

Tablo 2. Veri setini oluşturan özniteliklerin yapısı

Sütun Adı	Veri Tipi	Alt Sınır	Üst Sınır
Emp_Id	Metin	-	-
Satisfaction_level	Ondalıklı sayı	0,09	1
Last_evaluation	Ondalıklı sayı	0,36	1
Number_project	Tamsayı	2	7
average_monthly_hours	Tamsayı	96	310
time_spend_company	Tamsayı	2	10
Work_accident	Tamsayı	0	1
left	Tamsayı	0	1
promotion_last_5years	Tamsayı	0	1
Department	Metin	-	-
salary	Metin	-	-

Paylaşılan veri setinde bu verilerin nasıl elde edildiği veya hesaplama metodu hakkında bilgi mevcut değildir. Veri setinin datacard bölümünde bir not veya bilgi görülememiştir. Çalışma, verilerin bu hali kullanılarak yapılacaktır. Sütun isimleri ve veri yapısı tutulan veri hakkında kolaylık sağlamaktadır. Verilerin temel istatistiksel bilgileri Tablo 3’te gösterilmiştir.

- Emp_Id: Personelin numarası.
- Satisfaction_level: Personelin tatmin seviyesi.
- Last_evaluation: Son değerlendirme puanı.
- Number_project: Yer aldığı toplam proje sayısı.
- average_monthly_hours: Ortalama aylık kaç saat çalıştığı.
- time_spend_company: Şirkette kaç yıldır bulunduğu.
- Work_accident: İş kazası geçirip geçirmediği.
- Left: İşten ayrıldı mı? (Bağımlı değişken)
- promotion_last_5years: Şirkette son 5 yılda terfi aldı mı?
- Department: Çalıştığı bölüm.
- Salary: Maaş seviyesi (Düşük/Orta/Yüksek)

Tablo 3. Verilerin temel istatistikleri

	En küçük	En büyük	Ortalama	Standard Sapma	Varyans	Kayıp Veri
satisfaction_level	0,09	1	0,612	0,248	0,061	0
last_evaluation	0,36	1	0,716	0,171	0,029	0
number_project	2	7	3,803	1,232	1,5192	0
average_monthly_hours	96	310	201,05	49,943	2494,313	0

time_spend_company	2	10	3,498	1,46	2,131	0
Work_accident	0	1	0,144	0,351	0,123	0
left	0	1	0,238	0,425	0,181	0
promotion_last_5years	0	1	0,021	0,144	0,02	0

Veri Ön İşleme

Veri setinde personelin departman ve maaş bilgileri kategorik değişken şeklindedir. Maaş bilgisi düşük, orta ve yüksek olarak firma tarafından etiketli olarak paylaşılmıştır. Bu bilgileri kullanabilmek için “One-to-Many” düğümü yardımıyla veri manipülasyona (0-1) uğratılmıştır. Dönüşüm gerçekleştikten sonra modele eski halinin girdi olarak verilmemesi için veri setinden kaldırılmıştır.

Satırlar üzerinde yapılan kontrolle boş verinin bulunmadığı görülmüştür. Herhangi bir anomali değerinin olmadığı, hayatın olağan akışına ters gelecek bir bilginin bulunmadığı ve modellemeye uygun hale bir veri setinin elde bulunduğu anlaşılmıştır.

Veri manipülasyonu sonrası verisetindeki Satisfaction_level, Last_evaluation, Number_project, average_monthly_hours, time_spend_company, Work_accident, left, promotion_last_5years, Department, salary öznitelikleri modellere girdi olarak verilmiştir.

Makine Öğrenmesi

Yapay zekâ alanının çatısı altında yer alan makine öğrenmesi kavramı, insan beyninin hesaplayamayacağı kadar karmaşık model ve süreçler oluşturarak analitik çıktılar üretmeyi sağlayan bir teknikler topluluğudur. Karar alma sürecinde geçmiş verileri kullanarak tahmin sonuçları üretilir. Bu çalışma kapsamında regresyon algoritmalarından olan Gradient Boosting Tree, Random Forest Trees, XGBoosting Regresyon teknikleri kullanılmış olup ağaç teknikleri üzerinde performans karşılaştırması da gerçekleştirilmiştir.

Rastgele Orman Yöntemi: Bu algoritma, rastgele bir şekilde öznitelikleri düğümlere atar. Başarılı sonuç verdiği görülen bir modelde özniteliklerin hangisinin kullanıldığı ve kaçınıcı seviyeden modelde başarılı sonuç verdiği o parametrenin önem düzeyini de gösterir. Rastgele orman yöntemi, veri madenciliği ve makine öğrenimi uygulamalarında kullanılan bir topluluk (ensemble) yöntemidir ve birçok karar ağacını bir araya getirerek regresyon analizi yapar. İlk adım, veri toplamak ve kullanmak istenilen bağımlı (hedef) değişkeni ve bağımsız (girdi) değişkenleri tanımlamaktır. Örneğin, ev fiyatları tahmin edilecekse, odaların sayısı, banyo sayısı, evin yaşı vb. bağımsız değişkenler kullanılabilir.

Herhangi bir karar ağacının amacı en iyi özelliği belirleyip, aşağı doğru dallanarak mimari yapıyı oluşturmaktır. Rastgele orman algoritmasında ise özelliğin iyi olup olmadığına bakmadan, oldukça yüksek sayıda ağaç oluşturup her birinden farklı boyutlarda kazanımlar sağlanmaktadır. Bu özelliği sayesinde aşırı öğrenme (overfitting) oldukça azalacaktır. Bu kazanım, rastgele orman yönteminin en büyük kazanımlarından biri olarak gösterilebilmektedir. Rastgele orman modeli bir problemi çözmek için hem veri setinden

hem de öznitelik setinden rastgele 10'larca ya da 100'lerce farklı alt-setler seçer ve bunları eğitir [43].

Gradyan Artırma Yöntemi (Gradient Boosting): Boosting yöntemleri genel olarak zayıf olan öğrencileri güçlü hale getirmek için kullanılan bir tekniktir. Gradyan artırma yöntemi bir önceki ağacın hatalarını en aza indirmek amacıyla bir sonraki ağacı oluşturur. Başlangıç olması için bir adet ağaç oluşturulur. İlk ağacın tahmin ettiği hatanın negatif gradyanını tahmin etmek için bu algoritma kullanılır [44]. Yeni ağaç bir önceki ağacın hatalarını tahmin eder. Bu süreç yinelenmeli olarak ilerler ve sonuçlar giderek daha da iyileşmeye başlar. Bu tekniğin ana amacı hataları en düşük seviyeye çekerek ağaç modelini kurmaktır. Veri sayısının fazla olduğu modellerde avantajlıdır. Kirli veri üzerinde başarılı sonuç verdiği de bilinmektedir. Hem regresyon hem de sınıflandırma problemlerinde kullanılabilir.

Genellikle karar ağaçları gibi basit modeller kullanılır. Gradyan artırmanın temel mantığı, hata fonksiyonunun gradyanına (eğim) dayalı olarak tahmin hatalarını minimize etmeye yönelik adımlar atmaktır. Gradyan artırma, bir hata fonksiyonu tanımlar ve her adımda bu fonksiyonun gradyanına göre modelin performansını iyileştirir. Özellikle, veri seti üzerinde ardışık olarak oluşturulan her bir karar ağacı, önceki modelin hatalarını azaltacak şekilde eğitilir. Bu sayede, model her adımda daha iyi tahminler yapar.

Gradyan artırmanın önemli avantajlarından biri, doğruluğu yüksek tahminler yapabilmesidir. Küçük öğrenme oranları kullanarak, modelin yavaş yavaş öğrenmesini ve daha genel bir tahmin yapmasını sağlayabilir. Ayrıca, erken durdurma (early stopping) gibi tekniklerle modelin gereksiz yere çok fazla öğrenmesi engellenebilir. Bu özellikler, yöntemin tercih edilmesinde etkili olabilmektedir.

Gradyan artırma, karmaşık veri yapıları ve büyük veri setlerinde oldukça etkili bir yöntemdir. Özellikle, XGBoost ve LightGBM gibi modern versiyonları, büyük veri setlerinde hız ve doğruluk açısından önemli iyileştirmeler sağlar. Bu algoritmalar, yüksek performanslı tahminler yapabilme yeteneğine sahiptir. Gradyan artırmanın bu esnek ve güçlü yapısı, finans, sağlık, pazarlama ve daha birçok alanda yaygın olarak kullanılabilir.

Ekstrem Gradyan Artırma Yöntemi (XGBoosting): Ekstrem gradyan artırma algoritması, gradyan artırma algoritmasının optimize edilmiş ileri bir versiyonu sayılabilir. Önceki versiyonlara göre sağladığı avantajları Ekstrem gradyan artırma kullanımının yaygınlaşmasındaki en önemli nedendir [45]. Ağaç oluşturulurken fazla dallanma ve derinliğe ulaştığı takdirde ağaç budanmaya başlar. Aşırı öğrenmeyi engellediği için oldukça fazla kullanılan bir tekniktir.

Çalışmada, bağımlı değişken olan “left” değeri ikili (binary) olarak tutulmaktadır. Personeller için oluşturulan ayrılma tahmin skorlarının hangi eşik değere göre değerlendirileceğine dair insan kaynakları yönetiminin tercih kullanabileceği düşünülerek problem regresyon bakış açısıyla irdelenmektedir.

Ekstrem gradyan artırma, zayıf öğrencileri ardışık olarak birleştirerek hataları minimize ederken, Rastgele orman çok

sayıda karar ağacını bir araya getirip aşırı öğrenmeyi azaltır ve öznelik önemini belirlemede etkilidir. Ekstrem gradyan artırma ise, optimize edilmiş yapısı ile hızlı ve verimli modeller üretir. Bu yöntemler yüksek boyutlu veri setlerinde etkili sonuçlar vermektedir. Literatürdeki çalışmalarda da ağaç tabanlı yöntemlerin kullanıldığı ve başarılı sonuçlar elde edildiği gözlemlenmiştir

Regresyon Modelinin Değerlendirme Ölçütleri

R² Skoru: verilerin yerleştirilmiş regresyon hattına olan mesafesinin istatistiksel ölçüsüdür. Regresyon noktasına isabet edemeyen her noktaya artık adı verilmektedir. Bu artıkların her birinin karelerinin toplamına Artıkların Karelerinin Toplamı (AKT) ve her bir noktanın ortalamaya uzaklığının karesini de Ortalamaya Uzaklığın Kareler Toplamı (OUKT) şeklinde adlandırırsak R² değeri, bu iki istatistik kullanılarak Denklem 1'deki gibi hesaplanır.

$$R^2 \text{ Skoru} = 1 - (\text{AKT}/\text{OUKT})$$

R² değeri 1'e ne kadar yakın ise regresyon modelinin o kadar doğru olduğu anlaşılır. Bu metrikte dikkat edilmesi gereken husus R² değeri eğer 1 çıkarsa modelin ezberlemiş olabileceğidir. 1 değerinden uzaklaşmasıyla modelin tahminleme gücünde azalma olduğu anlaşılmaktadır.

Ortalama Mutlak Hata (Mean Absolute Error): Mutlak hata, tahmin edilen değerler ile gerçek değerler arasındaki farktır. Tam olarak ifade etmek gerekirse, veri kümesinin tüm örneğinde, o örnek için gerçek değer ile öngörülen değer arasındaki her bir farkın mutlak değerinin ortalamasına ortalama mutlak hata (mean absolute error) denir. Düşük bir değer olması modelin az hata yaptığını, yani iyi tahminlemede bulunduğunu gösterir.

Düzeltilmiş R-Kare (Adjusted R Square-R²): Modeldeki değişkenlerin sayısı için ayarlanmış olan R² değiştirilmiş bir versiyondur. Düzeltilmiş R² değeri, herhangi bir yeni değişken modele eklendiğinde artar. Bağımsız değişken eklendikçe model karmaşılaşır, model karmaşılaşınca aşırı ezberleme gibi problemler ortaya çıkabilir.

Ortalama Kare Hatası (Mean Squared Error): En sık kullanılan regresyon kaybı fonksiyonudur. Ortalama Kare Hatası, tüm veri kümesinde örnek başına ortalama hata kareleri kaybıdır. Bu metriğin 0'a yakın çıkması modelin daha doğru tahmin ürettiğini gösterir.

Uygulama Sonuçları

3 farklı makine öğrenmesi algoritması eldeki veri setine uygulanmış ve sonuçları karşılaştırılmıştır. İnsan kaynakları analitiği problemindeki özneliklerin önem seviyelerinin belirlenmesinden önce, modellerin performans göstergeleri Tablo 4'te paylaşılmaktadır.

Tablo 4. Yöntemlerin performans sonuçları

	Rastgele Orman Yöntemi (Ağaç sayısı=100, tree deep=10)	Gradyan Artırma Yöntemi (Ağaç sayısı=10, tree deep=10)	Ekstrem Gradyan Artırma Yöntemi (tree deep=10)
R² Skoru	0,921	0,854	0,870
Ortalama Mutlak Hata	0,014	0,026	0,022
Hata Kareleri Ortalamasının Karekökü	0,044	0,031	0,023
Düzeltilmiş R²	0,906	0,853	0,869

Her 3 modelin de oldukça başarılı tahminleme yapabildiği görülmektedir. Ortalama hata skorları birbirine oldukça yakın çıktığı için yöntem seçiminde R² değeri 1'e en yakın çıkan rastgele orman modeli üzerinden öznelik önemi belirlenmiştir.

R² skorlarını incelediğimizde:

R² Skoru, bir modelin açıklayıcı gücünü gösterir. 1'e ne kadar yakınsa, modelin hedef değişkenin varyansını o kadar iyi açıkladığını belirtir.

Rastgele Orman (R² skoru = 0,921) ile en yüksek değeri sağlıyor. Bu, modelin hedef değişkenin %92.1' ini açıkladığı anlamına gelir. Gradyan Artırma (R² skoru = 0,854) değeri ile daha düşük ve hedef değişkenin yaklaşık %85.4' ünü açıklamaktadır. Ekstrem Gradyan Artırma (R² skoru = 0,870) ile Gradyan Artırma yönteminden biraz daha iyi sonuç verdiği görülmektedir. Sonuç olarak, R² açısından Rastgele Orman Yöntemi en iyi performansı göstermiştir.

Ortalama mutlak hata skorlarını incelediğimizde:

Ortalama mutlak hata, modelin tahmin ettiği değerler ile gerçek değerler arasındaki ortalama farkı ölçer. Daha düşük bir ortalama mutlak hata daha başarılıdır.

Rastgele Orman (ortalama mutlak hata = 0,014), en düşük hata oranına sahip olduğu görülmüştür. Gradyan Artırma (ortalama mutlak hata = 0,026) ile en yüksek hata oranına sahiptir. Ekstrem Gradyan Artırma (ortalama mutlak hata = 0,022), Gradyan Artırma yönteminden daha iyi ancak Rastgele Orman kadar iyi değildir. Sonuç olarak, hata analizi açısından da Rastgele Orman yöntemi en iyi performansı sergilemiştir.

Düzeltilmiş R² değerlerini incelediğimizde:

Düzeltilmiş R² değerlerine göre de sonuçlar yorumlanabilir. Rastgele orman (Düzeltilmiş R²=0,906) yüksek bir değer ile verileri oldukça iyi açıklamaktadır. Gradyan Artırma (Düzeltilmiş R²=0,853) daha düşük bir düzeltilmiş R² skoru ile en az iyi performans gösteren modeldir. Ekstrem Gradyan Artırma (Düzeltilmiş R²=0,869), Gradyan artırmadan daha iyi performans sergilemekte ancak rastgele ormandan daha düşük performans göstermektedir.

Hata Kareleri Ortalamasının Karekökü değerlerini incelediğimizde:

Hata kareleri ortalamasının karekökü, hataların karekökünü olarak ortalamayı hesaplar ve büyük hatalara daha fazla ağırlık verir. Rastgele Orman (Hata kareleri ortalamasının karekökü = 0,044) değeri ile en yüksek değere sahip yöntem olduğu görülmüştür. Bu, büyük hatalar konusunda diğer iki modele göre daha zayıf olduğunu gösterir. Gradyan Artırma (Hata kareleri ortalamasının karekökü = 0,031), ise biraz daha iyi bir sonuç verdiği görülmüştür. Ekstrem Gradyan Artırma (Hata kareleri ortalamasının karekökü = 0,023) ise, 3 yöntem arasında en düşük değeri sunarak büyük hataları en iyi şekilde minimize edebildiğini göstermiştir. Ekstrem Gradyan Artırma yönteminde hata büyüklüklerinin küçük ve tutarlı olması ortalama mutlak hata ile ortalama kare hata değerlerinin birbirine yakın olmasını açıklamaktadır. Sonuç olarak, Hata kareleri ortalamasının karekökü değerleri baz alındığında büyük hatalar açısından Ekstrem Gradyan Artırma Yöntemi en iyi performansı sergiliyor.

Tüm metrikleri genel olarak değerlendirecek olursak:

Rastgele Orman Yöntemi, R^2 Skoru, ortalama mutlak hata ve düzeltilmiş R^2 açısından en yüksek performansı göstermektedir. Ancak hata kareleri ortalamasının karekökü değeri, diğer modellerden biraz daha yüksektir. Bu da modelin büyük hatalara daha duyarlı olduğunu göstermektedir.

Ekstrem Gradyan Artırma Yöntemi, en düşük hata kareleri ortalamasının karekökü değerine sahip olup, büyük hataları minimize etme konusunda başarılı olarak değerlendirilebilir. Ancak genel performansı (R^2 ve düzeltilmiş R^2) açısından Rastgele Orman'ın gerisinde kalmıştır.

Gradyan Artırma Yöntemi, genel olarak en düşük performansa sahip model olarak gözükmekte olup özellikle hem R^2 hem de ortalama mutlak hata açısından daha zayıf kalmıştır.

Bu analiz sonucunda, **Rastgele Orman Yöntemi**, veri setinin yapısına en uygun model olarak öne çıkmıştır.

Ağaç algoritmalarında, önce kök düğüm, sonrasında ise ilk hangi nitelikten bölüneceği ve kurallarının tespit edilmesi gerekmektedir. En iyi ayırım noktalarının tespit edilmesi için ise gini indeks yöntemi kullanılabilir. Gini indeks değeri, bir sınıfın içindeki izafi olarak sıklığı ifade eder. Her bir özellik için ayrı ayrı hesaplanan Gini indeks değerleri arasından en küçük olanı seçilir. Bölünme işlemi bu değere göre yapılmaktadır. Bu işlemler kalan veriler için de tekrar edilir ve diğer bölünmeler için hesaplanır. Sonuç olarak, bir özneliğin gini indeks değeri ne kadar düşük ise önemi ve dolayısıyla ağırlığı o kadar yüksek olacaktır. Gini hesaplaması aşağıdaki şekilde formüle edilmiştir. Sklearn kütüphanesinin içerisinde yer alan Feature Importance fonksiyonu, özellik önemlerini model üzerinde otomatik olarak hesaplayabilmektedir.

$$\text{Gini} = 1 - \left(\sum_{i=0}^m p(i)^2 \right)$$

Burada $p(i)$, sınıf i 'nin toplam nüfus içerisindeki oranını temsil eder. m ise, toplam sınıf sayısıdır.

S	Öznitelikler	S	Gini-based feature importance
	promotion_last_5years		0.000147
	product_mng		0.000403
	RandD		0.000587
	hr		0.000634
	management		0.000877
	marketing		0.001181
	high		0.001249
	accounting		0.001326
	Work_accident		0.001541
	IT		0.002037
	sales		0.002061
	medium		0.002492
	support		0.002744
	low		0.003191
	technical		0.003720
	average_monthly_hours		0.102119
	number_project		0.105349
	last_evaluation		0.124229
	time_spend_company		0.143736
	satisfaction_level		0.500376

Şekil 1. Özniteliklerin özellik önemlerinin gösterimi

Tüm özneliklerin işten ayrılmaya olan etkileri Şekil 1'de gösterilmiştir. Öznelik önemleri en düşükten en yükseğe doğru sıralanmış olup en önemli özneliğin açık ara farkla personel tatmini olduğu açığa çıkmıştır. Bu da yazındaki çalışmaları destekler niteliktedir. Önem skorları incelendiğinde 5 öznelik ile işten ayrılma kararının büyük ölçüde açıklanabileceği sonucuna ulaşmak mümkündür: çalışan tatmini (%50,03), şirkette bulunulan yıl (%14,37), değerlendirme puanı (%12,42), proje sayısı (%10,54) ve ortalama aylık çalışma süresi (%10,21). Bu 5 özneliğin toplam ağırlığı %97,57'dir.

Sonuç ve Değerlendirme

İnsan kaynağı analitiği çalışmaları son yıllarda giderek trend olan çalışma alanlarından biridir. Personellerin işten ayrılma tahminini önceden yapabilmek şirket için önemli bir değer olabilecektir. İşten ayrılma kararını öznel veriler yerine, nesnel veriler üzerinden ortaya koyabilen makine öğrenmesi modelleri bu çalışmada kullanılmıştır. Şirketin geçmiş dönem verileri, kurum kültürünü yansıtmada anlamında objektif bir perspektif sunabilmektedir. Veriden anlam çıkarma tekniğine ve devamlı öğrenme mantığına dayanan farklı makine öğrenmesi yaklaşımları ile tahminleme problemi ele alınmıştır. Ortalama hata skoru birbirine yakın çıkan tekniklerin yanında R^2 skoruna da bakılmasında fayda vardır.

Çalışan tatmini, çalışanların işten ayrılmalarında en önemli etken olarak öne çıkmıştır. Bu öznelik toplam ağırlığın yarısından fazlasını (%50,03) oluşturmaktadır. Çalışanlar, iş yerinde memnun olmadıklarında işten ayrılma eğilimi göstermektedirler. Tatmin düzeyi düşük olan çalışanlar, başka bir iş arayışına girebilir veya mevcut pozisyonlarında uzun süre kalma konusunda motivasyonlarını kaybedebilirler. Bu durum iş yükü, çalışma ortamı, maaş memnuniyeti, kariyer olanakları gibi faktörlerden etkilenebilir. Analiz, çalışan memnuniyetinin yüksek olduğu durumlarda işten ayrılma olasılığının önemli ölçüde azaldığını vurgulamaktadır.

Çalışanların şirkette ne kadar süre buldukları, işten ayrılma riskini etkileyen ikinci en önemli faktör olarak belirlenmiştir (%14,37). Genel olarak, çalışanlar şirkette ne kadar uzun süre kalırsa, kurumsal bağlılıkları o kadar artar, ancak bir noktadan sonra kariyer gelişimi, monotonluk ya da yeni

fırsatlar arama isteği işten ayrılma olasılığını artırabilir. Yeni çalışanların ayrılma riski yüksek olabilirken, uzun süreli çalışanlar için bu risk değişkenlik gösterebilir. Bu nedenle, şirkette geçirilen yılın işten ayrılma olasılığı üzerindeki etkisi çift yönlü değerlendirilebilir.

Çalışanların performans değerlendirmeleri de önemli bir etken olarak görülmektedir (%12,42). Değerlendirme puanları, çalışanların kariyer ilerlemelerini, ödüllendirme sistemlerini ve terfi fırsatlarını etkileyebilmektedir. Düşük performans puanlarına sahip çalışanlar, işten çıkarılma riskiyle karşı karşıya kalabilir ya da düşük motivasyon nedeniyle gönüllü olarak ayrılmayı tercih edebilirler. Buna karşılık, yüksek performans gösteren çalışanlar, kendilerine yeterli ödül ya da kariyer fırsatları sunulmazsa ayrılma eğilimi gösterebilirler.

Çalışanların üzerinde çalıştıkları proje sayısı, işten ayrılma kararında %10,54 oranında etkilidir. Fazla sayıda proje üstlenen çalışanlar, iş yükünün artması nedeniyle stres veya tükenmişlik hissedebilirler, bu da işten ayrılma olasılığını artırabilir. Öte yandan, projelerde yeterince görev almayan çalışanlar ise işlerinde gelişim fırsatı bulamayıp motivasyonlarını kaybedebilirler. Bu yüzden, proje sayısının işten ayrılma üzerindeki etkisi, hem iş yükünün dengesizliği hem de kariyer gelişimi eksikliğine bağlı olarak değişebilir.

Ortalama aylık çalışma süresi de işten ayrılma riskini etkileyen önemli bir faktör olarak ortaya çıkmaktadır (%10,21). Çalışanlar, fazla mesai yapmaya zorlandıklarında ya da uzun çalışma saatleriyle karşı karşıya kaldıklarında, iş-yaşam dengesini kurmakta zorlanabilirler ve bu durum, işten ayrılma eğilimini artırabilir.

Çalışan tatmini, şirkette kalınan süre, değerlendirme puanı, proje sayısı ve çalışma süresinden oluşan 5 özneliğin toplam ağırlığının %97,57 olması, işten ayrılma kararının büyük ölçüde bu faktörlere dayandığını açıkça göstermektedir. Çalışan tatmini en baskın faktör olup, çalışanların işlerinde ne kadar memnun olduklarının, işte kalma eğilimleri üzerinde çok büyük bir etkiye sahip olduğunu ortaya koymaktadır. Diğer dört öznelik ise daha spesifik durumlara işaret eder: şirkette kalınan süre, çalışanların bağlılığını ve kariyer gelişimini; değerlendirme puanı, performansla ilgili motivasyonu; proje sayısı ve çalışma süresi ise iş yükü ve iş-yaşam dengesi ile ilgili zorlukları temsil etmektedir. Bu özneliklerin bir arada değerlendirilmesi, çalışan bağlılığını artırmaya ve işten ayrılma oranlarını azaltmaya yönelik stratejilerin geliştirilmesinde kritik rol oynayabilir.

Bu çalışmada yapıldığı gibi rastgele orman yöntemi kullanıldıktan sonra özellik önemi veya özellik azaltma amaçlarıyla yapılmış çalışmalar incelenmiş olup, Gini indeksi yardımıyla başarılı şekilde sonuçlar elde edilebilmiştir. [46], yapmış olduğu çalışmada rastgele orman yöntemini kullanarak özellik önemi ve özellik eleme işlemi için gini değerini kullanmıştır. [47] ise, rastgele ormanın gini önemi, spektral verilere dayalı özelliklerin önemini ölçmede üstün bir yöntem sağlarken, optimal bir özellik alt kümesinde, düzenlenmiş sınıflayıcıların rastgele orman sınıflayıcısından daha tercih edilir olabileceği belirtilmiştir. Bununla birlikte, düzenlenmiş sınıflayıcılar yalnızca doğrusal bağımlılıkları modelleme sınırlamasına sahiptir. Gini önemine dayanan bir

özellik seçimi, optimal özellik alt kümesini belirlemek ve sınıflandırma görevindeki gürültüyü ortadan kaldırarak hem boyut azaltma hem de gürültü eliminasyonu sağlamak için düzenlenmiş doğrusal sınıflandırmadan önce uygulanabileceğini çalışmalarında göstermiştir. Başka bir çalışmada ise, rastgele orman yöntemi kullanılırken özellik öneminin gini değeri üzerinden başarılı şekilde değerlendirilebileceği sonucuna ulaşılmıştır [48].

Bu çalışma karşılaştırma tabanlı karar destek sisteminin bir altyapısı niteliği taşımaktadır. İlerleyen zamanlarda yeni verilerle besleyerek veri setindeki değişimlere bağlı olarak algoritma seçiminde değişiklik gösterebilecektir. Bu nedenle, yeni veriler geldikçe farklı teknikleri karşılaştıran bir karar destek sistemine dönüşebilecektir.

Yazında oldukça büyük yer kaplayan personelin işten ayrılma kararını tahminleme problemi için başkaca makine öğrenmesi teknikleri de denenebilir. Ayrıca başka personel veri setlerinde bu algoritmalarla modellerin nasıl performans göstereceği irdelenebilir. Şirketlerin önerilerini daha iyi görebilmeleri için ellerindeki personelleri daha stratejik bir açıdan değerlendirmeleri ve insan kaynakları politikalarını da bu kapsamda güncellemeleri iyi olabilir.

Kaynaklar

- [1] S. Reşitoğlu, "Yetkinlik Bazlı Performans Değerlendirme ve Çalışan Memnuniyeti- Bir Uygulama," Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, İzmir, 2011.
- [2] C. Yalçın, "Müşteri Kayıp Analizi (Customer Churn Analysis)," YBS Ansiklopedi, vol. 7, 2019.
- [3] V. Gülpınar, "Yapay Sinir Ağları ve Sosyal Ağ Analizi Yardımı ile Türk Telekomünikasyon Piyasasında Müşteri Kaybı Analizi," Marmara Üniversitesi İktisadi İdari Bilimler Dergisi, vol. 34, no. 1, pp. 331-350, 2013.
- [4] R. S. Shankar, J. Rajanikanth, V. V. Sivaramaraju, and K. V. S. S. R. Murthy, "Prediction of Employee Attrition Using Data Mining," in IEEE International Conference on System, Computation, Automation and Networking (ICSCAN), Pondicherry, India, 2018, doi: 10.1109/ICSCAN.2018.8541242.
- [5] D. Alao and A. B. Adeyemo, "Analyzing Employee Attrition Using Decision Tree Algorithms," Computing, Information Systems, Development Informatics and Allied Research Journal, vol. 4, no. 1, pp. 17-28, 2013.
- [6] S. O. Abdulsalam, J. F. Ajao, B. F. Balogun, and M. O. Arowolo, "A Churn Prediction System for Telecommunication Company Using Random Forest and Convolution Neural Network Algorithms," 2022.
- [7] X. Gao, J. Wen, and C. Zhang, "An Improved Random Forest Algorithm for Predicting Employee Turnover," Mathematical Problems in Engineering, vol. 2019, no. 1, 2019.

- [8] S. S. Alduayj and K. Rajpoot, "Predicting Employee Attrition using Machine Learning," in 2018 International Conference on Innovations in Information Technology (IIT), pp. 93-98.
- [9] X. Gao, J. Wen, and C. Zhang, "An Improved Random Forest Algorithm for Predicting Employee Turnover," *Mathematical Problems in Engineering*, vol. 2019, no. 1, 2019.
- [10] S. F. Sari and K. M. Lhaksmana, "Employee Attrition Prediction Using Feature Selection with Information Gain and Random Forest Classification," *Journal of Computer System and Informatics (JoSYC)*, 2022.
- [11] R. Joseph, S. Udupa, S. Jangale, K. Kotkar, and P. Pawar, "Employee Attrition Using Machine Learning And Depression Analysis," in 2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS), pp. 1000-1005.
- [12] M. M. Alam, K. Mohiuddin, M. K. Islam, M. Hassan, M. A. Hoque, and S. M. Allayear, "A Machine Learning Approach to Analyze and Reduce Features to a Significant Number for Employee's Turn Over Prediction Model," *Advances in Intelligent Systems and Computing*, 2018.
- [13] Y. Chen, X. Lin, and K. Zhan, "Employee Attrition Classification Model Based on Stacking Algorithm," *Psychology Research*, vol. 13, no. 6, pp. 279-285, 2023.
- [14] A. Alamsyah and N. Salma, "A Comparative Study of Employee Churn Prediction Model," in 2018 4th International Conference on Science and Technology (ICST), pp. 1-4.
- [15] S. O. Abdulsalam, J. F. Ajao, B. F. Balogun, and M. O. Arowolo, "A Churn Prediction System for Telecommunication Company Using Random Forest and Convolution Neural Network Algorithms," *EAI Endorsed Transactions on Mobile Communications and Applications*, vol. 7, no. 21, e4, 2022. doi: 10.4108/eetmca.v6i21.2181.
- [16] D. O. Alao and A. B. Adeyemo, "Analyzing Employee Attrition Using Decision Tree Algorithms," 2013.
- [17] M. Subhashini and R. Gopinath, "Employee Attrition Prediction in Industry Using Machine Learning Techniques," *International Journal of Advanced Research in Engineering and Technology (IJARET)*, vol. 11, no. 12, 2020.
- [18] S. S. Reddy, J. Rajanikanth, V. V. Sivaramaraju, and K. V. S. S. R. Murthy, "Prediction of Employee Attrition Using Data Mining," in 2018 IEEE International Conference on System, Computation, Automation and Networking (ICSCA), pp. 1-8.
- [19] A. Qutub, A. Al-Mehmadi, M. Al-Hssan, R. Aljohani, and H. S. Alghamdi, "Prediction of Employee Attrition Using Machine Learning and Ensemble Methods," *International Journal of Machine Learning*, vol. 11, no. 2, 2021.
- [20] S. Dutta and S. K. Bandyopadhyay, "Employee Attrition Prediction Using Neural Network Cross Validation Method," *International Journal of Commerce and Management*, vol. 6, no. 3, pp. 80-85, 2020.
- [21] S. Agarwal, C. Bhardwaj, G. Gatkamani, R. Gururaj, N. Darapaneni, and A. R. Paduri, "AI Based Employee Attrition Prediction Tool," *Lecture Notes in Computer Science*, pp. 580-588, 2023. doi: 10.1007/978-3-031-36402-0_54.
- [22] M. Atef, D. Elzanfaly, and S. Ouf, "Early Prediction of Employee Turnover Using Machine Learning Algorithms," *International Journal of Electrical and Computer Engineering Systems*, vol. 13, no. 2, pp. 135-144, 2022.
- [23] T. S. Poornappriya and R. Gopinath, "Employee Attrition In Human Resource Using Machine Learning Techniques," *Webology*, vol. 18, no. 6.
- [24] M. A. Abelson, "Examination of Avoidable and Unavoidable Turnover," *Journal of Applied Psychology*, vol. 72, no. 3, pp. 382-386, 1987.
- [25] H. G. Heneman, T. Judge, and J. D. Kammeyer-Mueller, *Staffing Organizations*, 7th ed. Mendota House, 2012.
- [26] J. L. Cotton and J. M. Tuttle, "Employee Turnover: A Meta-Analysis and Review with Implications for Research," *Academy of Management Review*, vol. 11, no. 1, 1986.
- [27] J. R. Terborg and T. W. Lee, "A Predictive Study of Organizational Turnover Rates," *Academy of Management Journal*, vol. 27, no. 4, pp. 793-810, 1984.
- [28] S. M. Carraher, "Turnover Prediction Using Attitudes Towards Benefits, Pay, and Pay Satisfaction Among Employees and Entrepreneurs in Estonia, Latvia, and Lithuania," *Baltic Journal of Management*, vol. 6, no. 1, pp. 25-52, 2011.
- [29] A. Erosa, L. Fuster, and D. Restuccia, "Fertility Decisions and Gender Differences in Labor Turnover, Employment, and Wages," *Review of Economic Dynamics*, vol. 5, no. 4, pp. 856-891, 2002.
- [30] E. M. Ineson, E. Benke, and J. László, "Employee Loyalty in Hungarian Hotels," *International Journal of Hospitality Management*, vol. 32, pp. 31-39, 2013.
- [31] A. I. Kraut, "Predicting Turnover of Employees from Measured Job Attitudes," *Organizational Behavior and Human Performance*, vol. 13, no. 2, pp. 233-243, 1975.
- [32] D. C. Maynard, T. A. Joseph, and A. M. Maynard, "Underemployment, Job Attitudes, and Turnover Intentions,"

Journal of Organizational Behavior, vol. 27, no. 4, pp. 509-536, 2006.

[33] S. Sellgren, G. Ekvall, and G. Tomson, "Nursing Staff Turnover: Does Leadership Matter?", *Leadership in Health Services*, vol. 20, no. 3

[34] D. G. Allen and R. W. Griffeth, "Job embeddedness and turnover intention: A multi-method study," *Journal of Applied Psychology*, vol. 102, no. 4, pp. 620-633, 2017. doi: 10.1037/apl0000181.

[35] J. Liu, Z. Wang, and C. Lu, "Employee turnover intention and job satisfaction: The moderating role of psychological empowerment," *Frontiers in Psychology*, vol. 8, p. 1018, 2017. doi: 10.3389/fpsyg.2017.01018.

[36] Y. Chang and C. Chen, "The relationship between work-family conflict and turnover intention: A study of healthcare professionals," *Journal of Nursing Management*, vol. 26, no. 5, pp. 587-596, 2018.

[37] X. Zhai and S. Xu, "Turnover prediction using machine learning techniques: An empirical study," *Journal of Business Research*, vol. 120, pp. 19-28, 2020.

[38] P. Chen and L. Zhang, "The role of employee resilience in mitigating turnover intention: Evidence from the financial sector," *International Journal of Human Resource Management*, vol. 30, no. 8, pp. 1239-1260, 2019.

[39] F. C. D. Fisher, "Happiness at work," *International Journal of Management Reviews*, vol. 12, no. 4, pp. 384-412, 2010.

[40] B. L. Rich, J. A. LePine, and E. R. Crawford, "Job engagement: Antecedents and effects on job performance," *Academy of Management Journal*, vol. 53, no. 3, pp. 617-635, 2010.

[41] M. Tims, A. B. Bakker, and D. Derks, "The impact of job crafting on job demands, job resources, and well-being," *Journal of Occupational Health Psychology*, vol. 18, no. 2, pp. 230-240, 2013.

[42] E. E. Kossek and J. S. Michel, "Flexible work schedules," in *APA Handbook of Industrial and Organizational Psychology*, vol. 1, S. Zedeck, Ed. Washington, DC, USA: American Psychological Association, 2011, pp. 535-572.

[43] H. K. Şimşek, "Makine Öğrenmesi Dersleri 5b: Random Forest (Regresyon)," *Medium*, Dec. 12, 2022. [Online]. Available: <https://medium.com/data-science-tr/makine-ogrenmesi-dersleri-5a-random-forest-regresyon-2a91715a8b66>. [Erişim Tarihi: 05.04.2024].

[44] E. Güler, "Gradient Boosting Nedir?" *Medium*, Mar. 14, 2024. [Online]. Available: <https://efecanxrd.medium.com/gradient-boosting-nedir-2ba518700777>. [Erişim Tarihi: 05.04.2024].

[45] A. C. Kelle ve H. Yüce, "MQTT Trafikinde DoS Saldırılarının Makine Öğrenmesi ile Sınıflandırılması ve Modelin SHAP ile Yorumlanması," *J. Mater. Mechat. A*, vol. 3, no. 1, pp. 50-62, 2022, doi: 10.55546/jmm.995091.

[46] Saarela, M., Jauhiainen, S. Comparison of feature importance measures as explanations for classification models. *SN Appl. Sci.* 3, 272 (2021). <https://doi.org/10.1007/s42452-021-04148-9>

[47] Menze, B.H., Kelm, B.M., Masuch, R. et al. A comparison of random forest and its Gini importance with standard chemometric methods for the feature selection and classification of spectral data. *BMC Bioinformatics* 10, 213 (2009).

[48] Kristin K. Nicodemus, Letter to the Editor: On the stability and ranking of predictors from random forest variable importance measures, *Briefings in Bioinformatics*, Volume 12, Issue 4, 2011, Pages 369-373, <https://doi.org/10.1093/bib/bbr016>

[49] Kaggle. HR_comma_sep.csv. <https://www.kaggle.com/datasets/liujiqi/hr-comma-sepcsv>. Erişim Tarihi: 04.03.2024



Temperature Prediction of Lithium-ion Battery by CPSO-UKF

Göksu TAŞ^{1*}

¹ Manisa Celal Bayar University, Mechatronics Engineering Department, goksu.tas@cbu.edu.tr, Orcid No: 0000-0003-2343-9182

ARTICLE INFO

Article history:

Received 5 August 2024
Received in revised form 16 September 2024
Accepted 30 September 2024
Available online 23 December 2024

Keywords:

Electric Vehicle, Lithium-ion, Temperature Prediction, Unscented Kalman Filter, Chaos Particle Swarm Algorithm

Doi: 10.24012/dumf.1528158

* Corresponding author

ABSTRACT

In this study, the temperature estimation of lithium-ion batteries is proposed by the Chaos Particle Swarm Algorithm-Unscented Kalman Filter (UKF). 18650-type lithium-ion batteries are widely used in electric vehicles due to their compact design and long life. The accurate estimation of the temperature parameter of these batteries is critical for reasons such as balancing the performance and predicting chemical degradation. Therefore, in this study, the temperature parameter estimation of an 18650-type lithium-ion battery is made by UKF-based methods. Due to the intensive and mathematical processing load of the UKF method, the parameter values are determined by Chaos Particle Swarm Optimization (PSO) methods, and their estimation performances are compared. The parameter values such as alpha, kappa, and R matrix of the UKF method are determined by Particle Swarm Optimization (PSO), Chaos Particle Swarm Optimization (CPSO), Comprehensive Learning Particle Swarm Optimization (CLPSO), and hyperparameter values determined by trial and error. The hyperparameter values obtained from these four different methods were applied to the UKF method separately, and their estimation performances were compared. The CPSO-UKF method became the most successful method by reaching an accuracy of 99.99228% in estimation according to the R^2 metric. The success of the proposed method is also given with other regression metrics.

Introduction

Due to its many benefits, including high energy density, power density, extended service life, lack of memory effect, and others, lithium-ion batteries have been widely used in new energy vehicles and portable electronics since the 1990s [1]. Recent years have seen a fast development of lithium (Li)-based metal batteries, such as Li-ion batteries, Li-S batteries, and Li-air batteries, due to the expanding uses of portable devices, electric cars, and smart grids. Power Li batteries must have high energy density in order to extend the operating mileage of applications like electric automobiles [2]. Despite its many benefits, consumers firmly believe that better lithium-ion batteries will eventually be produced since the current generation of these batteries is unable to fully meet business demands. In the realm of new energy vehicles, an optimal battery should possess not only exceptional cycle performance, high-rate capabilities, and a broad operating temperature range, but also exceptional safety performance [3]. To create batteries that are more affordable, denser, lighter, more powerful, and have a larger storage capacity, battery producers are always experimenting with novel chemistries. Presently, LIB technology has the best energy density among all innovative storage methods. For this reason, due to the

many beneficial features of lithium-ion batteries, their use is critical for areas such as energy and production. It's remarkable how characteristics like quick charging and a temperature operating window between $-50\text{ }^{\circ}\text{C}$ and $125\text{ }^{\circ}\text{C}$ can be fine-tuned thanks to the huge range of cell designs and chemicals. Other advantages of Li-ion batteries are their low self-discharge rate, lengthy lifespan, and high cycling performance, they can often withstand hundreds of charging and discharging cycles [4]. The usual temperature range of 20 to $60\text{ }^{\circ}\text{C}$ is sufficient for lithium-ion batteries (LIBs) to store energy and function efficiently; however, below zero, performance drastically decreases [5]. Even at $-40\text{ }^{\circ}\text{C}$, the most frost-resistant batteries continue to function, although their capacity drops to around 12%. Moreover, cycling at low temperatures speeds up LIB aging, which makes long-term battery use in cold climates restricted [6].

In addition to EVs, LIBs are widely used in a variety of portable consumer electronics products and energy storage facilities. However, cold temperatures significantly impair LIBs' functioning. The discharge capacity of LIBs rapidly decreases below $0\text{ }^{\circ}\text{C}$, and they are unable to fulfill the low-temperature standards necessary for electronic gadgets and electric vehicles to operate normally. A study found that at temperatures below $-10\text{ }^{\circ}\text{C}$, LIBs lose the most energy

and capacity [7]. The parameters of lithium-ion batteries are very important for the safe use of batteries under different temperature conditions. Since the temperature parameters of lithium-ion batteries cannot be determined reliably and healthily, critical problems such as incorrect prediction of battery life and energy management arise. Estimation methods for lithium-ion battery parameters are similar. For this reason, many studies have been conducted in the literature on this issue. For real-world Battery Management System (BMS) [8], [9] applications, it was presented a particle filter-based co-estimation approach for state of charge (SOC) [10] and state of health (SOH) [11] based on the mathematically complicated P2D model, which has a time-delayed response [12]. A chaotic firefly-particle filtering technique was developed, which mimics the way in which fireflies naturally interact with one another by using light to achieve particle optimization. In order to perform high-precision SOC and SOH co-estimations, it discovers a new optimal solution by chaotically mapping a set of particles to distinct solution spaces [13]. For the purpose of co-estimating the SOC and SOH of lithium-ion batteries, a study was given that suggested a backpropagation neural network-dual extended Kalman filter (DEKF) technique based on the limited memory recursive least squares (LMRLS) algorithm. By accounting for the coupling impact between SOC and SOH, the backpropagation neural network is utilized to perform synergistic estimation, which enhances the tracking accuracy of the DEKF technique [14]. An adaptive extended H-infinity filtering approach using a particle swarm optimization network was reported in a study. This method creatively makes use of the monitoring of the battery's aging characteristics in terms of capacity and power fading for SOC and SOH estimates [15].

Since lithium-based batteries have an important place today, their importance is increasing in the future due to more consistent use of energy. As a result of the literature research, together with the importance of the above-mentioned issue and the problems that arise, it has been concluded that the temperature estimation of lithium-ion batteries is very important. In addition, it has been concluded that this problem has not been solved while determining the hyperparameter values of the UKF method with trial-and-error methods while determining the parameters of lithium-based batteries. For this reason, in this study, a solution has been provided to this problem by determining the hyperparameter values with the PSO, CPSO, and CLPSO methods in the UKF method while estimating the parameters of 18650-type lithium-ion batteries. In this study, the temperature parameter estimation performances of the PSO-UKF, CPSO-UKF, and CLPSO-UKF methods of the 18650-type lithium-ion battery have been compared and presented. The hyperparameter values of the UKF method have been determined successfully with all optimization methods, and it has yielded more successful results than the traditional UKF. The obtained results have been presented with many graphics and regression estimation metrics that can be applied in real life.

Material and Method

In this study, the dataset was edited using the MATLAB program. The obtained edited dataset was used to estimate temperature using the Python programming language on a computer running the Ubuntu operating system. The necessary codes for optimization and filtering were edited, and the results were recorded.

Experimental Data

The battery data used in this study was taken from another study published in 2023 [16]. In the experimental study conducted in the related study, a total of 25 LIBs were used for the test. 5 cells were tested for each SOH condition. An RPT was performed on each LIB when aged to 100%, 95%, 90%, 85%, and 80% SOH values through electrical cycling. To measure the retained energy capacity, the LIBs were stored in a thermal chamber at 25 °C. They were left for one hour to equilibrate. Then, each LIB was charged to 4.2 V using the C/3 constant current profile, at which point the LIB was held at this voltage and charged in constant voltage (CV) mode until the value of the charge current decreased to C/20. SOH is defined as the ratio of the cell's measured energy capacity at a particular cycle number to its measured energy capacity at the time of its first measurement. The energy capacity of the cell as measured at a specific number of cycles is expressed by its current capacity. In the relevant dataset, 90% SOH means that the battery capacity maintains 90% of its original capacity after certain cycles. For this reason, although there is no fixed cycle number for each SOH level, when the dataset is examined, it is seen that the SOH value is 90.80% in 120 cycles and 95.06% in 60 cycle numbers for a battery cell. The relevant SOH formula is given in Equation 1 [16].

$$SOH = \frac{\text{Current Capacity}}{\text{Reference Capacity}} \times 100 \quad (1)$$

The characteristics of the battery used in this study are given in Table 1 [17].

Table 1. Lithium-ion battery specifications

Parameter	Details
Nominal Voltage	3.63 V
	Constant current 0.3C (1,455mA)
Standard Charge	Constant voltage 4.2V
	End current (Cut off) 50mA
Weight	68.0 ± 1.0 g
Energy	Nominal 18.20Wh

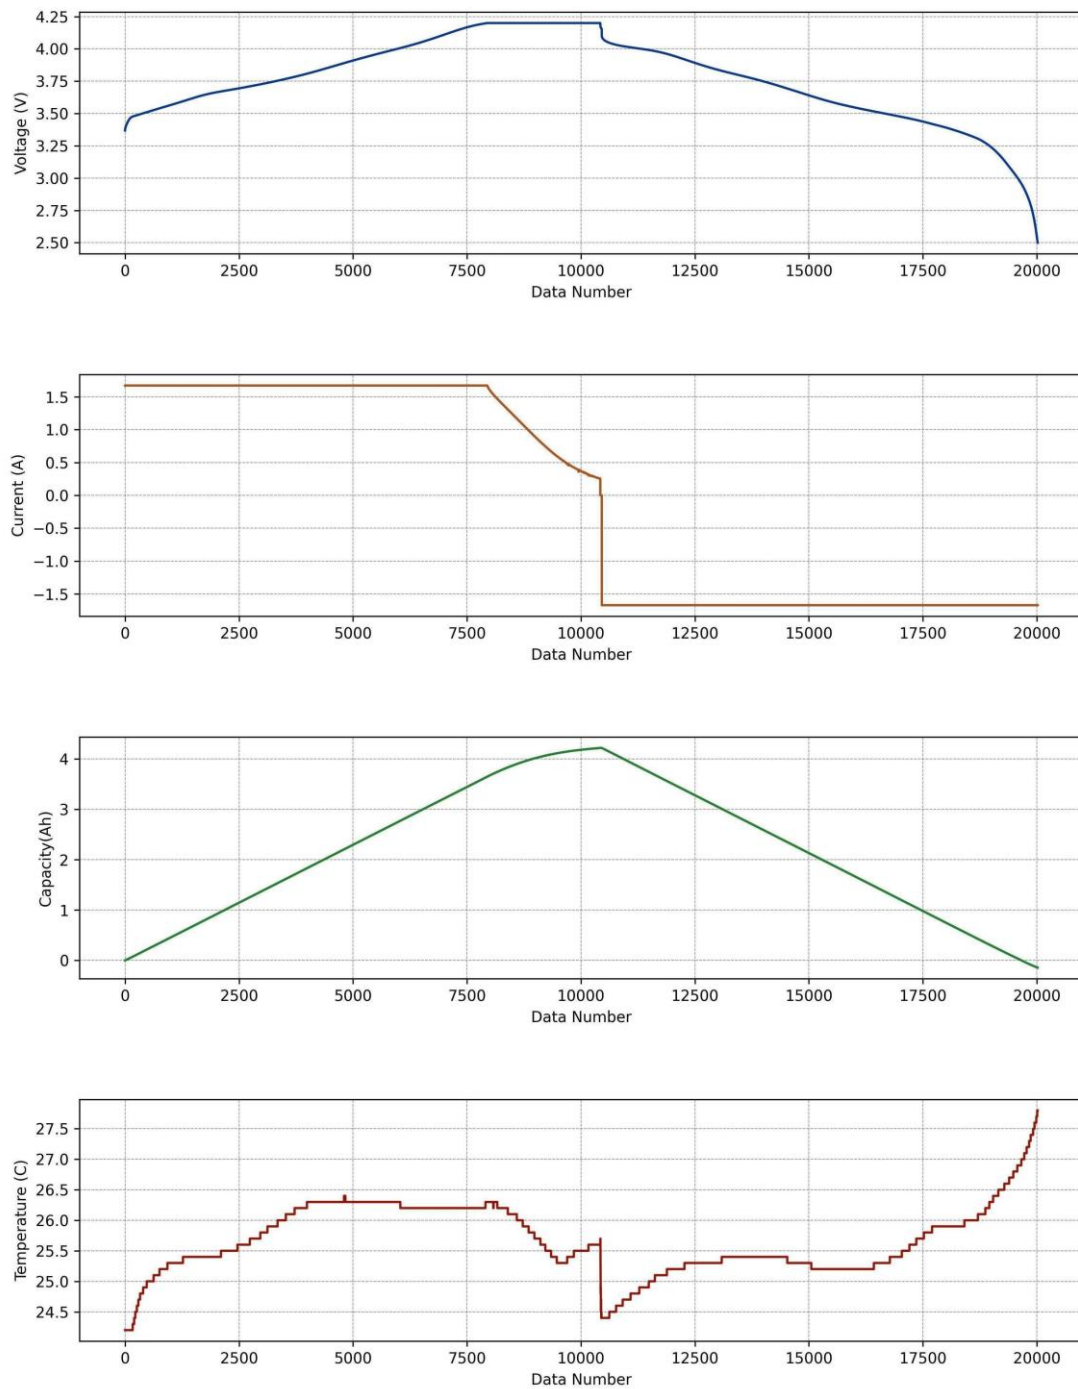


Figure 1. Dataset properties

The column data of the dataset used in this study is visualized in Figure 1. It is observed that the voltage value and capacity of the battery increase while charging with constant current, and the temperature value also increases. The dataset is rearranged to consist of four columns. The temperature column is the row estimated by the UKF method.

Chaos Particle Swarm Optimization

Both the quality of the solution and the PSO algorithm's rate of convergence depend on how the particle swarm is initialized. Since there is no previous information available, random initialization is often used to establish the position and velocity of the particles during the particle swarm initialization step. While particle swarms with random distributions are somewhat successful, certain particles may slow down the algorithm's convergence




Figure 3. Unscented transformation

because they are too distant from the best answer. In the chaotic attraction domain, chaotic motion takes place in a variety of states while maintaining the necessary unpredictability of particle group initiation. A comparatively frequent occurrence in nonlinear systems is chaos. The law claims that it can traverse all states within a certain range and is ergodic and intrinsically random. Equation 2 presents the mapping relationship for a typical chaotic system, which is the logistic mapping [18].

$$z_{i+1} = \mu z_i(1 - z_i), z_i \in (0,1] \quad (2)$$

In this case, the control variable is μ . The logistic map becomes fully chaotic at $\mu = 4$, and the resultant chaotic variable z_i exhibits superior ergodicity.

The logistic chaotic map's bifurcation diagram is seen in Figure 2.




Figure 2. CPSO search [18]

During the search, the particle swarm can be distributed via the chaotic map to a random value in the interval $[0, 1]$. Nevertheless, as Figure 1 illustrates, the particles are more widely distributed in the region of 0 and 1 via the conventional chaotic mapping procedure in Equation 1. Because of this, the chaotic distribution is not uniform, which makes it impossible for the particles to be distributed evenly in the $[0, 1]$ interval during the chaotic search process [18].

Unscented Kalman Filter

When used on a linear model, the Kalman filter is one specific kind of recursive Bayesian filter. For use with non-linear models, the extended Kalman filter (EKF) and unscented Kalman filter (UKF) are improvements over the Kalman filter. Although the UKF performs better in non-linear systems and small observed data regimes than the EKF, it should be emphasized that it is more computationally costly. Developed originally by Julier and Uhlman, the UKF is a flexible filter suitable for complicated non-linear systems. It makes use of the notion of unscented transformation to approximate the statistics of non-linear systems that are reasonably complicated. In the unscented transformation, a set of sample points is selected deterministically in order to mimic the statistical features of a random variable. It refers to these as sigma points. To perform the non-linear transformation, each sigma point is propagated across the non-linear systems. The statistical characteristics of the modified random variable are represented by these transformed sets of points [19]. Sigma points are used in the unscented transformation, as shown in Figure 3.

C represents the updated sigma points, b represents the production of symmetric sigma points around the mean, and a represents the a priori data.

KF theory is currently widely applied in various high-tech industries, including tracking, guiding, military applications, agriculture, and defense. A discrete linear time-varying system is given by Equation 3 and Equation 4.

$$x(k + 1) = A(k)x(k) + B(k)u(k) + e(k) \quad (3)$$

$$y(k) = C(k)x(k) + \varepsilon(k) \quad (4)$$

The time step in this case is k , and the system status, control, and output variables are, respectively, $x \in R^n$, $b \in R^r$, and $y \in R^m$. Process noise (e) and measurement noise (ε) are uncorrelated and normally distributed zero-mean white noise sequences; Q and R are the variances of e and ε , respectively. A , B , and C are matrices with appropriate dimensions.

The UKF method based on unscented transformation (UT) was proposed by Julier [20]. UKF adheres to the KF structure; however, it expands and maps the Sigma point set in a nonlinear manner by projecting the state at the next moment. It has three benefits: first, it eliminates the need for the laborious computation of the complex nonlinear function's Jacobian matrix; second, it ensures the nonlinear system's universal adaptability; and third, the noise of the Gaussian distribution is reduced as a result of the Gaussian distribution's expanding Sigma point set. It specifies the UKF-based filtering procedure for the nonlinear time-varying system shown in Equation 5 and Equation 6.

$$x(k + 1) = f(k, x(k), u(k)) + e(k) \quad (5)$$

$$y(k) = h(k, x(k)) + \varepsilon(k) \quad (6)$$

First, UT is used to determine the $2n+1$ Sigma sampling points and the weights that correlate to them. In this case, symmetric distribution sampling with UT is used. The situation is given in Equation 7.

$$X^{(i)}(k + 1|k) = f[k, X^{(i)}(k|k), u(k)] \quad (7)$$

Then, the estimation results and covariance matrix of the system state variables are obtained as in Equation 8 and Equation 9.

$$\hat{X}(k + 1|k) = \sum_{i=0}^{2n} w^{(i)} X^{(i)}(k + 1|k) \quad (8)$$

$$P(k + 1|k) = \sum_{i=0}^{2n} w^{(i)} [\hat{X}(k + 1|k) - X^{(i)}(k + 1|k)] [\hat{X}(k + 1|k) - X^{(i)}(k + 1|k)]^T + Q \quad (9)$$

To get $2n + 1$ predicted observations Y , UT is used once more to construct a fresh set of Sigma points and accompanying weights based on the anticipated values. These values are then inserted into the nonlinear measurement function. This situation is given in Equation 10.

$$Y^{(i)}(k + 1|k) = h[k, X^{(i)}(k + 1|k)] \quad (10)$$

The update step is given in Equation 11, Equation 12 and Equation 13.

$$K(k + 1) = P_{x_k y_k} P_{y_k y_k}^{-1} \quad (11)$$

$$\hat{x}(k + 1|k + 1) = \hat{X}(k + 1|k) + K(k + 1)[y(k + 1) - \hat{Y}(k + 1|k)] \quad (12)$$

$$P(k + 1|k + 1) = P(k + 1|k) - K(k + 1)P_{x_k y_k} K^T(k + 1) \quad (13)$$

P is the variance, $k+1$ is time, and $f(*)$ and $h(*)$ are the nonlinear function parameters [21]. The prediction metrics used in this study are given in Equation 22, Equation 23, Equation 24. Y is the true value, \bar{y} is the mean of the true value and y_t^i is the predicted value [22].

$$MSE = \frac{1}{T} \sum_{t=1}^T (y - y_t^i)^2 \quad (14)$$

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (y - y_t^i)^2} \quad (15)$$

$$MAE = \frac{1}{T} \sum_{t=1}^T |y - y_t^i| \quad (16)$$

$$R^2 = \frac{\sum (y_t^i - \bar{y})^2}{\sum (\bar{y} - y)^2} \quad (17)$$

Results

It is critical that the temperature estimation of the lithium-ion battery is done by unscented Kalman filter-based methods. In this study, the hyperparameter values of the Unscented Kalman Filter Method are determined quickly by PSO and improved PSO methods, and then the battery temperature estimation is made. Table 2 shows the results found by PSO optimization and its derivatives for the sought parameter values of the UKF method in this study. The population number was determined as 50 for all optimization methods.

In Figure 4, the exploration and exploitation processes in the C-PSO method are presented graphically and the process of searching for a suitable solution in the optimization method is visualized. It is seen that the optimization method successfully achieved the stage of reaching a suitable solution by establishing a balanced search for the two concepts.




Figure 4. Hyperparameter search process of the CPSO-UKF method.

Table 3 shows the estimation success of the methods obtained by applying the hyperparameter values found by the optimization methods for the UKF method. When the lowest error was evaluated according to the MAE metric, the CPSO-UKF method made the least error with a value of 0.0000368. The UKF method was the method that made the most errors in prediction compared to the other methods. The PSO-UKF method made less error in

Table 2. Found hyperparameter by optimization method

Method	Alpha		Kappa		R	
	Search Area	Found	Search Area	Found	Search Area	Found
PSO	0.0001-0.1	0.0780940	0- 20	6.2504753	0.1-100	0.1006981
C-PSO	0.0001-0.1	0.0515949	0- 20	2.2726251	0.1-100	0.0000771
CL-PSO	0.0001-0.1	0.0656085	0- 20	19.0	0.1-100	0.2455204

Table 3. Estimation results of UKF methods

Method	MSE	RMSE	MAE	R ²
UKF	0.0172722	0.1314238	0.0012692	0.9463256
PSO-UKF	0.0000251	0.0050155	0.0000370	0.9999218
CPSO-UKF	0.0000248	0.0049817	0.0000368	0.9999228
CLPSO-UKF	0.0001376	0.0117342	0.0000871	0.9995721




Figure 5. CPSO-UKF estimation result

prediction than the CLPSO-UKF method, with a value of 0.005013% according to the MAE metric. In Figure 5, a detailed comparison of the real value and the estimated values of the CPSO-UKF method is made. The CPSO-UKF method made a very small error in prediction from the real value with a value of 0.002482% according to the MSE metric. The temperature of the lithium-ion battery was successfully estimated using the Unscented Kalman Filter method.

All methods achieved more successful results than the normal UKF method. The CPSO -UKF method was the most successful method in temperature estimation with a value of 99.99228% according to the R^2 metric. The PSO-UKF method achieved more successful results than the standard UKF method. The CLPSO-UKF method achieved 0.03497% less success according to the R^2 metric than the PSO-UKF method.

Figure 5 provides the actual temperature value, and the temperature estimate by the using CPSO-UKF method. It is seen that the difference between the estimated value and the actual value is very small.

Conclusion

As the use of lithium-based batteries increases day by day, the improvement of energy consumption and performance of these batteries has become critical. In this study, temperature estimation of an 18650-type lithium-ion

battery was made with UKF-based methods. Since the hyperparameter determination process is long and tiring, alpha, kappa, and R matrix values, which are among the most important hyperparameter values of the UKF method, were determined with PSO, CPSO, and CLPSO methods. In the hyperparameter search process, the population number was set as 50 for all optimization methods. By applying the obtained hyperparameter values to the UKF method, the lithium battery temperature estimation performances of the UKF, PSO-UKF, CPSO-UKF, and CLPSO-UKF methods were compared. All methods based on PSO optimization achieved more successful results compared to the standard UKF method. According to all experiments, the CPSO-UKF method was suggested as the most successful method with the least estimation error with a value of 0.49817% according to the RMSE metric. The process of finding the appropriate solution and the temperature estimation process of the proposed method were presented with different visuals and estimation metrics, and their success was presented. The author is considering using metaheuristic optimization methods in the lithium battery-based parameter estimation process with the particle filter method in future studies.

Ethics committee approval

There is no need to obtain permission from the ethics committee for the article prepared.

Conflict of Interest

There is no conflict of interest with any person / institution in the article prepared.

References

- [1] M. Li, J. Lu, Z. Chen, and K. Amine, "30 Years of Lithium-Ion Batteries," *Advanced Materials*, vol. 30, no. 33, p. 1800561, 2018, doi: 10.1002/adma.201800561.
- [2] B. Li et al., "A Review of Solid Electrolyte Interphase (SEI) and Dendrite Formation in Lithium Batteries," *Electrochem. Energy Rev.*, vol. 6, no. 1, p. 7, Mar. 2023, doi: 10.1007/s41918-022-00147-5.
- [3] X. Chen et al., "Practical Application of All-Solid-State Lithium Batteries Based on High-Voltage Cathodes: Challenges and Progress," *Advanced Energy Materials*, vol. 13, no. 35, p. 2301230, 2023, doi: 10.1002/aenm.202301230.
- [4] S. M. Abu et al., "State of the art of lithium-ion battery material potentials: An analytical evaluations, issues and future research directions," *Journal of Cleaner Production*, vol. 394, p. 136246, Mar. 2023, doi: 10.1016/j.jclepro.2023.136246.
- [5] A. Senyshyn, M. J. Mühlbauer, O. Dolotko, and H. Ehrenberg, "Low-temperature performance of Lithium-ion batteries: The behavior of lithiated graphite," *Journal of Power Sources*, vol. 282, pp. 235–240, May 2015, doi: 10.1016/j.jpowsour.2015.02.008.
- [6] A. Belgibayeva et al., "Lithium-ion batteries for low-temperature applications: Limiting factors and solutions," *Journal of Power Sources*, vol. 557, p. 232550, Feb. 2023, doi: 10.1016/j.jpowsour.2022.232550.
- [7] X. Su et al., "Liquid electrolytes for low-temperature lithium batteries: main limitations, current advances, and future perspectives," *Energy Storage Materials*, vol. 56, pp. 642–663, Feb. 2023, doi: 10.1016/j.ensm.2023.01.044.
- [8] M. Waseem, M. Ahmad, A. Parveen, and M. Suhaib, "Battery technologies and functionality of battery management system for EVs: Current status, key challenges, and future prospectives," *Journal of Power Sources*, vol. 580, p. 233349, Oct. 2023, doi: 10.1016/j.jpowsour.2023.233349.
- [9] R. R. Kumar, C. Bharatiraja, K. Udhayakumar, S. Devakirubakaran, K. S. Sekar, and L. Mihet-Popa, "Advances in Batteries, Battery Modeling, Battery Management System, Battery Thermal Management, SOC, SOH, and Charge/Discharge Characteristics in EV Applications," *IEEE Access*, vol. 11, pp. 105761–105809, 2023, doi: 10.1109/ACCESS.2023.3318121.
- [10] G. Taş, C. Bal, and A. Uysal, "Performance comparison of lithium polymer battery SOC estimation using GWO-BiLSTM and cutting-edge deep learning methods," *Electr Eng*, vol. 105, no. 5, pp. 3383–3397, Oct. 2023, doi: 10.1007/s00202-023-01934-z.
- [11] M. Zhang et al., "Electrochemical Impedance Spectroscopy: A New Chapter in the Fast and Accurate Estimation of the State of Health for Lithium-Ion Batteries," *Energies*, vol. 16, no. 4, Art. no. 4, Jan. 2023, doi: 10.3390/en16041599.
- [12] B. Liu, X. Tang, and F. Gao, "Joint estimation of battery state-of-charge and state-of-health based on a simplified pseudo-two-dimensional model," *Electrochimica Acta*, vol. 344, p. 136098, Jun. 2020, doi: 10.1016/j.electacta.2020.136098.
- [13] J. Qiao, S. Wang, C. Yu, X. Yang, and C. Fernandez, "A chaotic firefly - Particle filtering method of dynamic migration modeling for the state-of-charge and state-of-health co-estimation of a lithium-ion battery performance," *Energy*, vol. 263, p. 126164, Jan. 2023, doi: 10.1016/j.energy.2022.126164.
- [14] C. Wang, S. Wang, J. Zhou, J. Qiao, X. Yang, and Y. Xie, "A novel back propagation neural network-dual extended Kalman filter method for state-of-charge and state-of-health co-estimation of lithium-ion batteries based on limited memory least square algorithm," *Journal of Energy Storage*, vol. 59, p. 106563, Mar. 2023, doi: 10.1016/j.est.2022.106563.
- [15] W. Li, M. Rentemeister, J. Badeda, D. Jöst, D. Schulte, and D. U. Sauer, "Digital twin for battery systems: Cloud battery management system with online state-of-charge and state-of-health estimation," *Journal of Energy Storage*, vol. 30, p. 101557, Aug. 2020, doi: 10.1016/j.est.2020.101557.
- [16] M. Rashid, M. Faraji-Niri, J. Sansom, M. Sheikh, D. Widanage, and J. Marco, "Dataset for rapid state of health estimation of lithium batteries using EIS and machine learning: Training and validation," *Data in Brief*, vol. 48, p. 109157, Jun. 2023, doi: 10.1016/j.dib.2023.109157.

- [17] DNKPOWER, “3.63V-4850mAh-18.20Wh-LG-M50-21700 Battery,” Lithium ion Battery Manufacturer and Supplier in China-DNK Power. Accessed: Aug. 03, 2024. [Online]. Available: <https://www.dnkpower.com/lg-m5021700-m50t21700/>
- [18] Z. Ma, X. Yuan, S. Han, D. Sun, and Y. Ma, “Improved Chaotic Particle Swarm Optimization Algorithm with More Symmetric Distribution for Numerical Function Optimization,” *Symmetry*, vol. 11, no. 7, Art. no. 7, Jul. 2019, doi: 10.3390/sym11070876.
- [19] N. M. M. Kalimullah, K. Shukla, A. Shelke, and A. Habib, “Stiffness tensor estimation of anisotropic crystal using point contact method and unscented Kalman filter,” *Ultrasonics*, vol. 131, p. 106939, May 2023, doi: 10.1016/j.ultras.2023.106939.
- [20] J. Shen et al., “Alternative combined co-estimation of state of charge and capacity for lithium-ion batteries in wide temperature scope,” *Energy*, vol. 244, p. 123236, Apr. 2022, doi: 10.1016/j.energy.2022.123236.
- [21] Z. Long, M. Bai, M. Ren, J. Liu, and D. Yu, “Fault detection and isolation of aeroengine combustion chamber based on unscented Kalman filter method fusing artificial neural network,” *Energy*, vol. 272, p. 127068, Jun. 2023, doi: 10.1016/j.energy.2023.127068.
- [22] G. Taş, A. Uysal, and C. Bal, “A New Lithium Polymer Battery Dataset with Different Discharge Levels: SOC Estimation of Lithium Polymer Batteries with Different Convolutional Neural Network Models,” *Arab J Sci Eng*, vol. 48, no. 5, pp. 6873–6888, May 2023, doi: 10.1007/s13369-022-07586-8.



Long-Term Prediction of Coronary Artery Disease via Ensemble Machine Learning Algorithms

Şehmus ASLAN^{1*}

¹ Mardin Artuklu University, Business Administration Department, Mardin, sehmusaslan@artuklu.edu.tr, ORCID: 0000-0003-1886-3421

ARTICLE INFO

Article history:

Received 12 August 2024
Received in revised form 12 October 2024
Accepted 24 October 2024
Available online 23 December 2024

Keywords:

machine learning, coronary artery disease prediction, class imbalance, SMOTE, stackingC classifier.

Doi: 10.24012/dumf.1531523

* Corresponding author

ABSTRACT

Coronary artery disease (CAD) is the leading cause of death worldwide, necessitating early detection methods that are non-invasive, cost-effective, and reliable. In this study, the effectiveness of various machine learning (ML) models in predicting CAD was evaluated, with a focus on addressing class imbalance using the Synthetic Minority Oversampling Technique (SMOTE). The Framingham CAD dataset was utilized, and SMOTE was applied with different k-values to balance the data, examining the impact on prediction performance. Eight significant features—age, diaBP, glucose, heart rate, sysBP, totChol, cigsPerDay, and BMI—were determined during preprocessing and used for further analysis. Among the models tested, the StackingC classifier demonstrated superior performance, achieving an accuracy of 95.81%, sensitivity of 95.9%, specificity of 95.7%, and an AUROC of 99.2% for k=1. These findings highlight the potential of the StackingC model as a robust tool for CAD prediction, offering a promising non-invasive method for early diagnosis.

Introduction

According to the WHO report [1], ischemic heart disease, also known as coronary heart disease, was the primary cause of death worldwide in 2019. It accounted for 16% of all deaths and experienced the most significant rise in fatalities since 2000; resulting in 8.9 million deaths in 2019 (see Fig. 1). Early detection of coronary artery disease (CAD) is essential to prevent an increased risk. Coronary angiography is the definitive diagnostic tool for CAD but is invasive and can result in complications like artery dissection, arrhythmia, and even death. Additionally, image-based detection methods are expensive and impractical for screening large populations, particularly in developing countries. Due to these limitations and the potentially dangerous nature of angiography, researchers have been seeking noninvasive, cost-effective, fast, and reliable methods for early CAD detection. Machine learning (ML) algorithms are among the techniques being explored for this purpose [2].

ML methodologies have shown significant potential in accurately diagnosing heart disease, improving the

efficiency of medical professionals, and generating economic benefits. As datasets expand and ML algorithms advance, the impact of ML applications on automated heart disease prediction is expected to increase substantially. On the other hand, class imbalance issues are common in medical diagnostics, where majority class samples outnumber minority class samples. Traditional classification algorithms often misclassify minority observations as noise, leading to lower accuracy for the minority class. Addressing this imbalance is essential for improving the overall diagnostic performance of ML algorithms. In order to tackle this problem, the synthetic minority oversampling technique (SMOTE) algorithm is used in this study and efforts are made to improve the performance of SMOTE. This study has two primary contributions to the existing literature:

- The first is to determine the impact of the k hyper parameter in the K-Nearest Neighbors (KNN) classifier used for SMOTE on prediction performance.
- The second is to evaluate the effectiveness of various machine learning models in predicting CAD, aiming to identify the optimal ML model for coronary artery disease prediction.




Figure 1. Leading causes of death globally

The remainder of the paper is structured as follows: Section 2 presents the literature review. Section 3 describes the dataset and outlines the proposed methodology. Section 4 discusses the experimental results and provides an analysis. Finally, Section 5 covers the conclusion and potential future work.

Literature Review

Up to now, a substantial number of studies have been conducted to predict CAD, extensively applying machine learning. Notably, Alizadehsani et al. [2] and Kutiami et al. [3] have provided comprehensive reviews on CAD prediction. Kurt et al. [4] compared various classification techniques for CAD prediction in 1245 subjects, finding the multi-layer perceptron (MLP) to be the best predictor with an area under the receiver operating characteristic curve (AUROC) of 0.783, outperforming logistic regression (LR), classification and regression trees (CART), radial basis function (RBF), and self-organizing feature maps (SOFM). Babaoğlu et al. [5] explored principal component analysis (PCA) with support vector machines (SVM) for assessing exercise stress tests. The results showed that reducing features with PCA improved SVM model accuracy and reduced errors. Alizadehsani et al. [6] introduced the Z-Alizadeh Sani dataset and achieved a 94.08% accuracy in diagnosing CAD using effective features and data mining methods.

Furthermore, Akila and Chandramathi [7] proposed a hybrid method involving decision trees (C4.5) and MLP, achieving classification accuracies of 98.66% for C4.5 and 96.66% for MLP. Lo et al. [8] combined four heart disease datasets, using seven machine learning methods to predict CAD, and developed a new classifier with optimal performance using the TOPSIS algorithm. Miao et al. [9] developed an ensemble machine learning model using adaptive boosting, achieving accuracies between 77.78% and 96.72% across multiple datasets. Alizadehsani et al. [10] also aimed for high accuracy in diagnosing major coronary arteries stenosis, achieving rates of 86.14% for

the LAD artery, 83.17% for the LCX artery, and 83.50% for the RCA, which are the highest reported in the literature.

Forsen et al. [11] systematically evaluated machine learning methods like L1 regression and random forest (RF) classifiers for CAD prediction using metabolomic data. Beunza et al. [12] compared machine learning algorithms on the Framingham Heart Study data, finding artificial neural networks (ANN) achieved the highest AUROC in R-Studio (0.71) and SVMs performed best in RapidMiner (0.75). Abdar et al. [13] tested ten traditional algorithms, ultimately selecting three types of SVMs optimized using genetic algorithms and particle swarm optimization, achieving a 93.08% accuracy and 91.51% F1-score with the optimized N2Genetic-nuSVM model on the Z-Alizadeh Sani dataset. Likewise, Dahal and Gautam [14] implemented five supervised classification methods for CAD prediction and determined the best model through performance comparison.

Dipto et al. [15] developed a prototype system using various machine learning algorithms to identify the most suitable model for a clinical dataset, finding the ANN to achieve the highest accuracy. Additionally, Dutta et al. [16] introduced a two-layer convolutional neural network (CNN) for classifying imbalanced clinical data, achieving high accuracy and specificity. Joloudari et al. [17] enhanced CAD diagnosis accuracy through an integrated machine learning approach, utilizing random trees (RT), C5.0 decision trees, SVM, and chi-squared automatic interaction detection (CHAID) decision trees. Muhammad et al. [18] developed machine learning models for CAD prediction using data from hospitals in Nigeria, with the random forest model achieving the highest accuracy and AUROC. Wang et al. [19] introduced a cloud-random forest (C-RF) model for assessing CAD risk. Using the Framingham dataset from Kaggle, the model achieved 85% accuracy and demonstrated superior performance in classification accuracy, error rates, and AUROC value compared to CART, SVM, CNN, and RF models. Wang et al. [20] enrolled 3,112 CAD patients and 3,182 controls

Table 1. Summary of literature review on CAD prediction using ML techniques

Authors	Method Used	Dataset	Class Imbalance Handling
Kurt et al. [4]	Logistic Regression, CART, Neural Networks	Trakya University dataset (1245 samples)	No specific focus on class imbalance
Alizadehsani et al. [6]	SVM with Feature Selection and Information Gain	Z-Alizadeh Sani (303 samples)	No specific focus on class imbalance
Alizadehsani et al. [10]	SVM with Kernel Fusion, Information Gain, Feature Selection	Z-Alizadeh Sani (303 samples)	No specific focus on class imbalance
Lo et al. [8]	Ensemble Learning, Co-Expressed Observations, TOPSIS	UCI Machine Learning Repository (822 samples)	No specific focus on class imbalance
Miao et al. [9]	Adaptive Boosting Algorithm, Ensemble Learning	UCI Machine Learning Repository (920 samples)	No specific focus on class imbalance
Forssen et al. [11]	L1 regression, Random Forest	4C Metabolomics dataset (3409 samples)	No specific focus on class imbalance
Beunza et al. [12]	SVM, Neural Networks, Decision Trees, Random Forest	Framingham Heart Study (4240 samples)	Applied oversampling to balance dataset
Dahal and Gautam [14]	SVM, LR, Bagging CART, RF, KNN	Z-Alizadeh Sani (303 samples)	Applied SMOTE to balance dataset
Dipto et al. [15]	Logistic Regression, SVM, ANN	Z-Alizadeh Sani dataset (303 samples)	Applied SMOTE to balance dataset
Dutta et al. [16]	CNN with LASSO	NHANES dataset (37,079 samples)	Addressed class imbalance with CNN structure
Masih et al. [21]	Multilayer Perceptron-based DNN	Framingham Heart Study (4583 samples)	Applied SMOTE to balance dataset
Wang et al. [20]	Cloud-Random Forest	Framingham Heart Study (4238 samples)	Applied SMOTE to balance dataset
Trigka et al. [22]	Stacking Ensemble with SMOTE	Framingham Heart Study (4238 samples)	Applied SMOTE to balance dataset
Mishra et al. [23]	SVM, Logistic Regression, Random Forest, Decision Tree	Various hospitals in Odisha (3254 samples)	No specific focus on class imbalance
Saeedbaksh et al. [23]	SVM, ANN, Random Forest	Isfahan Cohort Study dataset (11495 samples)	No specific focus on class imbalance
This Study (2024)	StackingC	Framingham CAD dataset (4238 samples)	SMOTE with varying k-values

from three centers in China, developing a RF model. This model achieved an AUROC of 0.948 in the development cohort and 0.944 and 0.940 in two validation cohorts. An easy-to-use tool combining 15 indexes was also created for clinical application, enhancing CAD management and prevention. Trigka and Dritsas [22] evaluated various machine learning models with and without SMOTE, finding the stacking ensemble model combined with SMOTE and 10-fold cross-validation to outperform others. Huang and Huang [24] used the NHANES dataset to identify CAD risk factors with machine learning, achieving an AUROC of 0.89 with the XGBoost model. Özbilgin et al. [25] proposed a non-invasive CAD diagnosis method using iris images and SVM, achieving a 93% accuracy rate. Saeedbaksh et al. [23] used SVM, ANN, and RF to predict CAD with high accuracy, identifying key predictors and extracting eleven high-confidence rules. Li et al. [26] proposed a deep learning hybrid model for CAD prediction, significantly improving accuracy and addressing overfitting issues. Table 1 presents a summary of literature review on CAD prediction using ML techniques

After analyzing the related literature, it is evident that various studies have explored the use of machine learning models for coronary artery disease (CAD) prediction, employing methods such as support vector machines (SVM), random forests, and convolutional neural networks (CNN), demonstrating moderate to high accuracy and AUROC scores. However, a significant gap exists in addressing the issue of class imbalance, a common problem in medical datasets where CAD-positive cases are underrepresented. This imbalance often leads to reduced model performance, particularly in predicting minority class instances, which are critical in healthcare applications. Additionally, while previous research has shown the potential of ensemble models, like stacking classifiers, to enhance performance by leveraging the strengths of multiple models, there has been limited focus on optimizing these models for CAD prediction. Another unexplored area in the literature is the effect of different SMOTE (Synthetic Minority Oversampling Technique) k-values on model performance, which can have a substantial impact on how

well machine learning models manage imbalanced datasets.

This study addresses these gaps by applying SMOTE to balance the dataset and experimenting with various k -values to optimize model performance. Moreover, it evaluates a stacking ensemble model (StackingC), which combines multiple classifiers and demonstrates superior performance over traditional machine learning models. The findings reveal that StackingC consistently outperforms other models, achieving high accuracy, sensitivity, specificity, and AUROC, making it a robust and reliable tool for CAD prediction, especially in the context of imbalanced datasets. This research not only advances the application of ensemble models for CAD prediction but also provides valuable insights into how tuning the k -parameter of SMOTE can enhance model performance, effectively addressing key gaps identified in the literature.

Material and Method

This section outlines the approach used in the study, detailing the materials, datasets, and methodologies employed to predict coronary artery disease (CAD) risk using machine learning techniques.

Dataset description

This research paper utilizes the Framingham CAD dataset, available on Kaggle [27], to conduct an empirical examination of CAD risk assessment methods. The dataset originates from a continuous cardiovascular study involving residents of Framingham, Massachusetts. The objective is to predict whether a patient will experience coronary heart disease within the following ten years.

The Framingham CAD dataset encompasses 15 risk indicators associated with CAD, with a collective sample size of 4238 participants, of whom 644 (15.2%) were diagnosed with CAD. Detailed statistical information regarding the features concerning the target class labels is provided in Table 2 and 3. The Framingham CAD dataset was chosen for several reasons. First, it includes well-established risk factors for CAD, such as age, systolic and diastolic blood pressure, cholesterol levels, glucose, and smoking habits, all of which are critical in predicting the disease. These features have been widely used in cardiovascular research and are known to provide reliable insight into coronary artery disease. The dataset's breadth and depth allow for a comprehensive analysis of the disease risk, making it a suitable foundation for machine learning-based predictive modeling.

Second, the dataset's public availability on platforms like Kaggle ensures transparency and reproducibility, which are essential in scientific research. Its accessibility allows researchers to validate findings and develop comparable models, increasing the robustness of machine learning approaches in CAD prediction.

Additionally, despite its initial class imbalance (with 15.2% of participants diagnosed with CAD), the dataset offers a sufficient sample size to apply techniques like Synthetic Minority Oversampling Technique (SMOTE) [28]. SMOTE was used to balance the dataset, creating equal representation of CAD and non-CAD cases, which enhances the accuracy and reliability of the predictive models.

Overall, the Framingham CAD dataset provides an ideal combination of relevance, data quality, and availability. Its use of established risk factors and its large sample size, together with the applied class-balancing techniques, make it a robust choice for developing accurate and reliable machine learning models for early CAD detection.

Data Preprocessing

The number of participants who have been diagnosed with CAD is 644 (15.2%), indicating an imbalanced dataset. In accordance with the principle of balancing the quantity of CAD and non-CAD samples, SMOTE method [28] was employed to transform the Framingham dataset into a balanced dataset. SMOTE relies on the K-Nearest Neighbors (KNN) [29] classifier generating synthetic data for the minority class in order to achieve a uniform distribution across both classes. One of the objectives of this study is to observe the effects of the k hyper parameter of the KNN classifier used for SMOTE on the prediction performance. Hence, SMOTE was applied with 3 different k values which are 1, 3, and 5, resulting in the creation of three distinct datasets. Following the implementation of SMOTE, the datasets achieved balance, consisting of 7188 participants with an equal distribution of 3594 instances each for both CAD and non-CAD classes. Furthermore, in order to prevent a reduction in the observation count, any missing values within the continuous variables were filled by averaging the remaining non-missing values within that specific variable. Lastly, all attributes with numeric values were normalized within the range of [0, 1].

Feature selection

In this study, Random Forest (RF) [30] was utilized alongside 10-fold cross-validation to eliminate irrelevant features, which can degrade model performance. The combination of robustness, scalability, interpretability, and automatic feature selection makes RF a popular choice for selecting the best features in machine learning tasks. The main steps of feature selection using RF in this study are described as follows:

Step 1: RF was trained using the entire dataset with 10-fold cross-validation.

Step 2: Then, for each attribute in the dataset, we temporarily removed this attribute and trained the classifier again using the remaining attributes.

Step 3: After training the RF without each attribute, we evaluated the performance of the RF using accuracy metric through cross-validation.

Step 4: The importance of each attribute was determined based on how much the performance of the RF degrades when that attribute is removed. If removing an attribute causes a significant drop in performance, it suggests that the attribute is important for classification.

Step 5: Finally, the attributes were ranked based on their importance scores. Attributes with higher scores were considered more important for classification, while attributes with lower scores might be deemed less important or even irrelevant.

After obtaining the rank of significance for the features (see Fig. 2), a decision was made regarding which features to use for the model. Starting from the feature

with the lowest score, each feature was individually removed from the model, and RF classifier was run. The accuracy metric reached its maximum level with 8 features as it is shown Table 4. The 8 features that maximize the accuracy of the RF model are as follows: age, diaBP, glucose, heartRate sysBP, totChol, cigsPerDay, BMI. Hence, only these features were utilized for the remainder of the study

Machine learning models

In particular, the focus was on evaluating Bayesian Network (BN) [31] and the K-Star algorithm [32]. Ensemble ML algorithms were also explored, including Random Forest (RF) [30], Stacking [33], and StackingC [34]. After numerous preliminary experiments, the optimal hyper parameters for the algorithms were determined and are detailed in Table 5:

Table 2. Numerical features of Framingham dataset

Attribute	Description	Min	Max	Mean ± stdDev
Age	Age of the patient in years	32	70	49.5 ± 8.56
Cigs/day	Number of cigarettes smoked per day	0	70	9 ± 11.92
totChol	Total cholesterol level	113	464	236.8 ± 43.69
SysBP	Systolic blood pressure	83.5	295	132.3 ± 22.1
DiaBP	Diastolic blood pressure	48	142.5	82.9 ± 11.97
BMI	Body Mass Index	15.54	56.8	25.8 ± 4.07
Heart rate	Heart rate (beats per minute)	44	143	75.7 ± 11.99
Glucose	Glucose level	40	394	81.8 ± 23.89

Table 3. Nominal features of Framingham dataset

Attribute	Description	Categories	n
Gender	Gender of the patient	Male	1819
		Female	2419
Education	Level of education	Some high school	1825
		High school graduate	1253
		Some college or vocational school	687
		College graduate	473
Current smoker	Indicator of whether the participant is smoking	Yes	2094
		No	2144
BPMeds	Indicator of whether the participant is on blood pressure medication	Yes	124
		No	4114
prevStroke	Indicator of whether the participant has a history of stroke	Yes	25
		No	4213
prevHyp	Indicator of whether the participant has a history of hypertension	Yes	1316
		No	2922
Diabetes	Indicator of diabetes presence	Yes	109
		No	4129




Figure 2. Selection of important influencing factors of CAD using RF

Table 4. Performance evaluation related to the number of features

Feature Number	6	7	8	9	10	11	12	13	14	15
Accuracy (%)	90.16	90.33	90.35	90.16	89.89	89.83	89.84	89.79	89.72	89.72

Table 5. Optimal hyper parameters for ML models for the Framingham dataset

Random Forest (RF)	numIterations	300
	numFeatures	5
K-Star (K*)	globalBlend	30
Bayesian Network (BN)	estimator	SimpleEstimator
	searchAlgorithm	K2
Stacking	classifiers	RF, K*, BN
	metaClassifier	K*
StackingC	classifiers	RF, K*, BN
	metaClassifier	K*

Experimental Results

This section presents the experimental results of the study, detailing the evaluation metrics and test outcomes of the machine learning models used for coronary artery disease (CAD) prediction.

Evaluation Metrics

To assess the performance of machine learning models, a confusion matrix was utilized. This matrix showcases the disparities between actual and predicted classes. Each row of the confusion matrix corresponds to instances in the predicted class, while each column represents instances in the real class, and vice versa. Typically, the confusion matrix comprises four distinct terms: True Positive (TP), False Positive (FP), True Negative (TN), and False Negative (FN). True Positive (TP) denotes the number of predicted values correctly identifying the presence of disease, while True Negative (TN) represents the count of

predicted values correctly identifying the absence of disease. False Positive (FP) indicates the count of predicted values incorrectly classified as positive (when they were actually negative), and False Negative (FN) refers to the count of predicted values incorrectly classified as negative (when they were actually positive). Using these terms, performance metrics such as accuracy, sensitivity, specificity, and Area Under the Receiver Operating Characteristic Curve (AUROC) were calculated. A description of each performance metric is provided below.

$$\text{Accuracy} = \frac{TN+TP}{TN+TP+FN+FP} \tag{1}$$

$$\text{Sensitivity} = \frac{TP}{TP+FN} \tag{2}$$

$$\text{Specificity} = \frac{TN}{TN+FP} \tag{3}$$

In this study the performance of the ML models' was assessed using accuracy, specificity, sensitivity, and AUROC values.

Experimental setup

The algorithms were implemented in WEKA 3.9.6 and run on a PC with a 2.3 GHz AMD Ryzen 5 processor and 8 GB of RAM with Windows 11. A 10-fold cross-validation was applied to measure the efficiency of the machine learning models on the balanced dataset of 7188 instances after SMOTE, for each of the three values of k: 1, 3, and 5.

Test results

In this paper, five machine learning techniques were compared: Bayesian Network (BN) [31], K-Star [32], Random Forest (RF) [30], Stacking [33], and StackingC [34]. The comparison was performed on Framingham dataset balanced by SMOTE [28] using three different values of the k hyper parameter: 1, 3, and 5.

Table 6. Performance evaluation of ML models for k=1

	Accuracy (%)	Sensitivity (%)	Specificity (%)	AUROC (%)
BN	90.35	83.4	97.2	93.5
K-Star	84.24	98.3	70.2	97.9
RF	90.43	90.8	90.1	96.5
Stacking	95.92	95.4	96.5	99.1
StackingC	95.81	95.9	95.7	99.2

Table 7. Performance evaluation of ML models for k=3

	Accuracy (%)	Sensitivity (%)	Specificity (%)	AUROC (%)
BN	90.58	82.8	98.4	93.6
K-Star	81.15	94.3	68.0	93.9
RF	87.54	89.1	86	94.7
Stacking	95.08	93.9	96.3	98.6
StackingC	95.23	94.3	96.1	98.7

Table 8. Performance evaluation of ML models for k=5

	Accuracy (%)	Sensitivity (%)	Specificity (%)	AUROC (%)
BN	88.97	82.2	95.7	93.1
K-Star	78.85	91.5	66.2	90.9
RF	86.14	87.7	84.6	93.7
Stacking	94.23	92.7	95.8	98.1
StackingC	93.93	93.2	94.6	98.2

According to Table 6, 7, 8 the k hyper parameter in SMOTE influences the performance of the ML models. Generally, lower values of k yield higher performance metrics, while higher values of k show a decrease in these metrics. Considering the overall performance across different values of the k hyper parameter in SMOTE, the Stacking and StackingC classifiers stand out as the best options for Framingham dataset due to their consistently high accuracy, sensitivity, specificity, and AUROC. However, StackingC has shown slightly better performance compared to Stacking. StackingC demonstrates high accuracy across all values of k (95.81% for k=1, 95.23% for k=3, and 95.23% for k=5). Furthermore, both sensitivity (95.9%) and specificity (95.7%) are high for k=1, suggesting that the model is equally good at identifying CAD cases and non-CAD cases. This balance is crucial for medical diagnosis to avoid both false alarms and missed diagnoses.




Figure 3. ROC curves comparing machine learning models at k=1 (SMOTE)




Figure 4. ROC curves comparing machine learning models at k=3 (SMOTE)




Figure 5. ROC curves comparing machine learning models at k=5 (SMOTE)

To provide a deeper understanding of the classification performance of the ML models, ROC curves are displayed in Figures 3, 4 and 5. The ROC curve is crucial for evaluating classifier performance because it provides a comprehensive view of the trade-off between the true positive rate (sensitivity) and the false positive rate (1-specificity) across different threshold settings. The AUROC values are consistently high for StackingC, indicating strong overall performance and reliability in distinguishing between positive and negative cases of CAD (99.2 for k=1, 98.7 for k=3, and 98.2 for k=5). StackingC gave the best performance for k=1 in SMOTE with 10-fold cross-validation, and the confusion matrix of this model is given in Table 9.

terms of balancing accuracy, sensitivity, specificity, and AUROC. This balance is crucial for medical diagnostics, where both false positives and false negatives can have significant consequences. The StackingC model's exceptional performance across multiple evaluation metrics suggests it is a robust tool for CAD prediction, and its applicability could extend to clinical settings for early diagnosis.

Table 9. Confusion matrix for stackingC using k=1 in SMOTE for Framingham dataset

	Predicted CAD	Predicted non-CAD	Total
Actual CAD	3446	148	3594
Actual non-CAD	153	3441	3594
Total	3599	3589	

Additionally, a comparative analysis between the current study and previous studies was performed using accuracy, specificity, sensitivity, and AUROC evaluation criteria, with the results presented in Table 10. Beunza et al. [12] utilized support vector machines (SVM) on the same Framingham dataset, achieving an accuracy of 69% and an AUROC of 75%, which is substantially lower than the results achieved by the StackingC model in this study. Similarly, Wang et al. [20] employed a cloud-random forest (C-RF) model on the Framingham dataset and achieved an accuracy of 85% and an AUROC of 85%, again demonstrating the superior performance of the StackingC model used in this paper.

In comparison, Trigka and Dritsas [22] applied a stacking ensemble model with SMOTE to predict CAD and achieved an accuracy of 90.9% and an AUROC of 96.1%. While this shows strong performance, the StackingC model in the current study outperformed it with an accuracy of 95.81% and AUROC of 99.2%, underscoring the effectiveness of the ensemble learning method used in this study.

Moreover, Masih et al. [21] applied a convolutional neural network (CNN) model, achieving an accuracy of 96.5% on the Framingham dataset. Although the CNN model achieved slightly higher accuracy, the StackingC model's AUROC of 99.2%, alongside its balanced sensitivity and specificity, makes it a more reliable and robust model for distinguishing between CAD and non-CAD cases.

These comparisons emphasize that while machine learning models such as SVM, random forests, stacking models, and CNNs have been widely used for CAD prediction, the StackingC model in this study demonstrates superior overall performance, particularly in

In summary, although there have been numerous studies using machine learning techniques for CAD prediction, this study's StackingC model offers improved performance when compared to many previous approaches, making it a valuable contribution to the field.

Table 10. Comparison of the ML models from previous studies for Framingham dataset

Authors	Dataset	Method	Accuracy(%)	Sensitivity(%)	Specificity(%)	AUROC(%)
Beunza [12]	Framingham	SVM	69	42	84	75
Wang [20]	Framingham	C-RF	85	84	86	85
Trigka [22]	Framingham	Stacking	90.9	87.6	NaN	96.1
Masih [21]	Framingham	CNN	96.5	91.9	98.28	NaN
This study	Framingham	StackingC	95.81	95.9	95.7	99.2

Conclusion

In this study, it is aimed to enhance the prediction of coronary artery disease (CAD) using various machine learning models, focusing on the Synthetic Minority Oversampling Technique (SMOTE) and its impact on model performance. The results demonstrated that the application of SMOTE, particularly with lower k-values, significantly improved the performance metrics of the machine learning models. Among the models tested, the StackingC classifier consistently outperformed others, achieving high accuracy, sensitivity, specificity, and AUROC values across different k-values. This suggests that StackingC is highly effective in distinguishing between CAD and non-CAD cases, making it a reliable tool for medical diagnostics.

To optimize the predictive accuracy of the ML models, it was identified the eight most significant features using the Random Forest (RF) model. The features that maximize the accuracy of the RF model are age, diaBP, glucose, heart rate, sysBP, totChol, cigsPerDay, and BMI. Hence, only these features were utilized for the remainder of the study. This feature selection process was critical in enhancing the model's performance, ensuring that the most relevant and impactful variables were included in the prediction models.

This study's findings highlight the importance of addressing class imbalance in medical datasets to enhance the accuracy and reliability of predictive models. The use of SMOTE in balancing the dataset proved crucial, particularly for models like StackingC, which showed superior performance in all evaluation metrics. The StackingC model achieved an accuracy of 95.81%, sensitivity of 95.9%, specificity of 95.7%, and an AUROC of 99.2% for k=1, underscoring its robustness and potential for clinical application. The StackingC model holds significant promise for real-world applications, particularly in healthcare settings where early and accurate detection of CAD is critical. This model could be integrated into clinical decision support systems to assist healthcare professionals in identifying high-risk patients. With its high sensitivity and specificity, the model can reliably distinguish between CAD-positive and CAD-negative cases, reducing the

chances of both false positives and false negatives. This would be particularly valuable in resource-constrained environments where access to invasive diagnostic methods, such as coronary angiography, is limited. By offering a non-invasive, cost-effective, and rapid diagnostic tool, the StackingC model could improve early detection and intervention, potentially reducing mortality rates from CAD.

Despite its strong performance, the study has some limitations that should be acknowledged. First, the dataset used is the Framingham CAD dataset, which, while comprehensive, may not fully represent the diverse global population. The model's performance might vary when applied to other populations with different risk factors and demographic characteristics. Additionally, the study primarily focused on balancing the dataset using SMOTE, but there could be other methods for handling class imbalance that might yield different results. The impact of hyper-parameter tuning and alternative resampling techniques, such as ADASYN or NearMiss, was not explored in this study.

Future research could address these limitations by validating the StackingC model on larger, more diverse datasets, potentially from different geographic regions and healthcare settings. Expanding the feature set to include other relevant risk factors, such as genetic data or lifestyle factors, could improve the model's generalizability. Additionally, exploring other machine learning techniques, such as deep learning models, or hybrid approaches that combine ensemble learning with neural networks, could further enhance performance.

Another promising direction for future research is the development of interpretable models that allow healthcare professionals to understand the underlying reasons for a model's predictions. Explainability in AI models is crucial, especially in high-stakes fields like healthcare. Research could focus on incorporating explainability techniques like SHAP (Shapley Additive Explanations) or LIME (Local Interpretable Model-agnostic Explanations) to make the predictions more transparent to clinicians.

Ethics Committee Approval

There is no need to obtain permission from the ethics committee for the article prepared. There is no conflict of interest with any person / institution in the article prepared.

References

- [1] World Health Organization, "The top 10 causes of death," Jun. 09, 2024. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>
- [2] R. Alizadehsani *et al.*, "Machine learning-based coronary artery disease diagnosis: A comprehensive review," *Comput. Biol. Med.*, vol. 111, p. 103346, Aug. 2019, doi: 10.1016/j.combiomed.2019.103346.
- [3] S. Kutiami, R. Millham, A. F. Adekoya, M. Tettey, B. A. Weyori, and P. Appiahene, "Application of Machine Learning Algorithms in Coronary Heart Disease: A Systematic Literature Review and Meta-Analysis," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 6, 2022, doi: 10.14569/IJACSA.2022.0130620.
- [4] I. Kurt, M. Ture, and A. T. Kurum, "Comparing performances of logistic regression, classification and regression tree, and neural networks for predicting coronary artery disease," *Expert Syst. Appl.*, vol. 34, no. 1, pp. 366–374, Jan. 2008, doi: 10.1016/j.eswa.2006.09.004.
- [5] I. Babaoğlu, O. Fındık, and M. Bayrak, "Effects of principle component analysis on assessment of coronary artery diseases using support vector machine," *Expert Syst. Appl.*, vol. 37, no. 3, pp. 2182–2185, Mar. 2010, doi: 10.1016/j.eswa.2009.07.055.
- [6] R. Alizadehsani *et al.*, "A data mining approach for diagnosis of coronary artery disease," *Comput. Methods Programs Biomed.*, vol. 111, no. 1, pp. 52–61, Jul. 2013, doi: 10.1016/j.cmpb.2013.03.004.
- [7] S. Akila and S. Chandramathi, "A Hybrid Method for Coronary Heart Disease Risk Prediction using Decision Tree and Multi Layer Perceptron," *Indian J. Sci. Technol.*, vol. 8, no. 34, Dec. 2015, doi: 10.17485/ijst/2015/v8i34/85947.
- [8] Y.-T. Lo, H. Fujita, and T.-W. Pai, "PREDICTION OF CORONARY ARTERY DISEASE BASED ON ENSEMBLE LEARNING APPROACHES AND CO-EXPRESSED OBSERVATIONS," *J. Mech. Med. Biol.*, vol. 16, no. 01, p. 1640010, Feb. 2016, doi: 10.1142/S0219519416400108.
- [9] K. H. Miao, J. H., and G. J., "Diagnosing Coronary Heart Disease using Ensemble Machine Learning," *Int. J. Adv. Comput. Sci. Appl.*, vol. 7, no. 10, 2016, doi: 10.14569/IJACSA.2016.071004.
- [10] R. Alizadehsani *et al.*, "Coronary artery disease detection using computational intelligence methods," *Knowl.-Based Syst.*, vol. 109, pp. 187–197, Oct. 2016, doi: 10.1016/j.knosys.2016.07.004.
- [11] H. Forssen, R. Patel, N. Fitzpatrick, A. Timmis, H. Hemingway, and S. Denaxas, "Evaluation of Machine Learning Methods to Predict Coronary Artery Disease Using Metabolomic Data".
- [12] J.-J. Beunza *et al.*, "Comparison of machine learning algorithms for clinical event prediction (risk of coronary heart disease)," *J. Biomed. Inform.*, vol. 97, p. 103257, Sep. 2019, doi: 10.1016/j.jbi.2019.103257.
- [13] M. Abdar, W. Książek, U. R. Acharya, R.-S. Tan, V. Makarenkov, and P. Pławiak, "A new machine learning technique for an accurate diagnosis of coronary artery disease," *Comput. Methods Programs Biomed.*, vol. 179, p. 104992, Oct. 2019, doi: 10.1016/j.cmpb.2019.104992.
- [14] K. R. Dahal and Y. Gautam, "Argumentative Comparative Analysis of Machine Learning on Coronary Artery Disease," *Open J. Stat.*, vol. 10, no. 04, pp. 694–705, 2020, doi: 10.4236/ojs.2020.104043.
- [15] I. C. Dipto, T. Islam, H. M. M. Rahman, and M. A. Rahman, "Comparison of Different Machine Learning Algorithms for the Prediction of Coronary Artery Disease," *J. Data Anal. Inf. Process.*, vol. 08, no. 02, pp. 41–68, 2020, doi: 10.4236/jdaip.2020.82003.
- [16] A. Dutta, T. Batabyal, M. Basu, and S. T. Acton, "An efficient convolutional neural network for coronary heart disease prediction," *Expert Syst. Appl.*, vol. 159, p. 113408, Nov. 2020, doi: 10.1016/j.eswa.2020.113408.
- [17] J. H. Joloudari *et al.*, "Coronary Artery Disease Diagnosis; Ranking the Significant Features Using a Random Trees Model," *Int. J. Environ. Res. Public. Health*, vol. 17, no. 3, p. 731, Jan. 2020, doi: 10.3390/ijerph17030731.
- [18] L. J. Muhammad, I. Al-Shourbaji, A. A. Haruna, I. A. Mohammed, A. Ahmad, and M. B. Jibrin, "Machine Learning Predictive Models for Coronary Artery Disease," *SN Comput. Sci.*, vol. 2, no. 5, p. 350, Sep. 2021, doi: 10.1007/s42979-021-00731-4.
- [19] C. Wang *et al.*, "Development and Validation of a Predictive Model for Coronary Artery Disease Using Machine Learning," *Front. Cardiovasc. Med.*, vol. 8, p. 614204, Feb. 2021, doi: 10.3389/fcvm.2021.614204.
- [20] J. Wang, C. Rao, M. Goh, and X. Xiao, "Risk assessment of coronary heart disease based on cloud-random forest," *Artif. Intell. Rev.*, vol. 56, no. 1, pp. 203–232, Jan. 2023, doi: 10.1007/s10462-022-10170-z.
- [21] N. Masih, H. Naz, and S. Ahuja, "Multilayer perceptron based deep neural network for early detection of coronary heart disease," *Health Technol.*, vol. 11, no. 1, pp. 127–138, Jan. 2021, doi: 10.1007/s12553-020-00509-3.
- [22] M. Trigka and E. Dritsas, "Long-Term Coronary Artery Disease Risk Prediction with Machine Learning Models," *Sensors*, vol. 23, no. 3, p. 1193, Jan. 2023, doi: 10.3390/s23031193.
- [23] S. Saeedbakhsh, M. Sattari, M. Mohammadi, J. Najafian, and F. Mohammadi, "Diagnosis of

- coronary artery disease based on machine learning algorithms support vector machine, artificial neural network, and random forest,” *Adv. Biomed. Res.*, vol. 12, no. 1, p. 51, 2023, doi: 10.4103/abr.abr_383_21.
- [24] A. A. Huang and S. Y. Huang, “Use of machine learning to identify risk factors for coronary artery disease,” *PLOS ONE*, vol. 18, no. 4, p. e0284103, Apr. 2023, doi: 10.1371/journal.pone.0284103.
- [25] F. Özbilgin, Ç. Kurnaz, and E. Aydın, “Prediction of Coronary Artery Disease Using Machine Learning Techniques with Iris Analysis,” *Diagnostics*, vol. 13, no. 6, p. 1081, Mar. 2023, doi: 10.3390/diagnostics13061081.
- [26] F. Li, Y. Chen, and H. Xu, “Coronary heart disease prediction based on hybrid deep learning,” *Rev. Sci. Instrum.*, vol. 95, no. 1, p. 015115, Jan. 2024, doi: 10.1063/5.0172368.
- [27] “The Framingham CAD dataset.” Accessed: Jun. 10, 2024. [Online]. Available: <https://www.kaggle.com/datasets/navink25/framingham>
- [28] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “SMOTE: Synthetic Minority Over-sampling Technique,” *J. Artif. Intell. Res.*, vol. 16, pp. 321–357, Jun. 2002, doi: 10.1613/jair.953.
- [29] D. W. Aha, D. Kibler, and M. K. Albert, “Instance-based learning algorithms,” *Mach. Learn.*, vol. 6, no. 1, pp. 37–66, Jan. 1991, doi: 10.1007/BF00153759.
- [30] L. Breiman, “Random Forests,” *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.
- [31] M. Friedman, “The Use of Ranks to Avoid the Assumption of Normality Implicit in the Analysis of Variance,” *J. Am. Stat. Assoc.*, vol. 32, no. 200, pp. 675–701, Dec. 1937, doi: 10.1080/01621459.1937.10503522.
- [32] J. G. Cleary and L. E. Trigg, “K*: An Instance-based Learner Using an Entropic Distance Measure,” in *Machine Learning Proceedings 1995*, Elsevier, 1995, pp. 108–114. doi: 10.1016/B978-1-55860-377-6.50022-0.
- [33] D. H. Wolpert, “Stacked generalization,” *Neural Netw.*, vol. 5, no. 2, pp. 241–259, Jan. 1992, doi: 10.1016/S0893-6080(05)80023-1.
- [34] A. Seewald, *How to Make Stacking Better and Faster While Also Taking Care of an Unknown Weakness*. 2002, p. 561.



A Novel DNA Classification Experiment: Spatial Transcriptomics Analysis for Human Monkeypox DNA-Motifs with Kolmogorov–Arnold Networks

Selçuk YAZAR^{1*}

¹ Kırklareli University, Software Engineering Department, selcukyazar@klu.edu.tr, Orcid No: 0000-0001-6567-4995

ARTICLE INFO

Article history:

Received 22 August 2024
Received in revised form 25 September 2024
Accepted 8 October 2024
Available online 23 December 2024

Keywords:

*Spatial Transcriptomics,
Kolmogorov-Arnold Networks,
Deep Learning, Gene Expression
Patterns, Regional Classification*

Doi: 10.24012/dumf.1537079

* Corresponding author

ABSTRACT

Spatial Transcriptomics (ST) has emerged as a powerful tool for understanding gene expression patterns across different regions of a tissue or organism. It is crucial for disease research and developing new therapies. It allows for the measurement of gene expression across specific, localized areas of a tissue slide, though it does so with limited throughput. Yet, the data produced by ST technologies are characteristically noisy, high-dimensional, sparse, and multi-modal, encompassing elements like histological images and count matrices. Existing methods for analyzing ST data, which often rely on traditional statistical or machine learning techniques, have proven inadequate in many cases due to challenges like scale, multi-modality, and the inherent limitations of spatially-resolved data, including spatial resolution, sensitivity, and gene coverage. To address these specific challenges, researchers have turned to deep learning-based models. In this study, we present a novel approach to transcriptomics analysis using Kolmogorov-Arnold Networks (KANs), a state-of-the-art deep learning model to predict regional origin of monkeypox transcriptomic sample. By leveraging the ability of KANs to learn and represent complex, non-linear functions, we aim to uncover intricate spatial patterns of gene expression and gain insights into the underlying biological processes. Study's analysis focuses on two distinct regions, America and Asia, and employs a KAN-based classifier. The results demonstrate the promising performance of KANs in this context, with a precision of 0.45 and a recall of 0.93 for the America region, indicating a strong ability to correctly identify samples from this region. Findings indicate that predicting the regional transcriptome of monkeypox from DNA motifs could facilitate image-based screening for phylogenetic analyses.

Introduction

Spatial transcriptomics (ST) represents a significant advancement over traditional gene expression analysis methods by incorporating the geographical location of DNA within tissue sections, thereby preserving the spatial context of gene activity. Traditional methods, such as single-cell RNA sequencing (scRNAseq), lack the ability to maintain this spatial information, which is crucial for understanding the complex interactions and heterogeneity within tissues [1]. ST technologies, by contrast, enable the profiling of gene expression at a single-cell resolution while retaining the cellular compositions within a tissue, offering insights into cellular interactions that were previously unattainable [2]. The data produced by conventional ST technologies exhibit inherent characteristics such as noise, high dimensionality, sparsity, and multimodality, necessitating the utilization of specialized computational tools like machine learning (ML) for precise and robust analysis [2]. The integration of machine learning (ML) techniques, has further differentiated ST from traditional methods. The development of tools like SPADE for identifying spatially variable genes and PERSIST for optimizing gene panels for ST studies exemplifies the tailored approaches being developed to leverage the unique

aspects of ST data [3, 4]. These tools, which are based on machine learning models, offer superior performance in detecting spatially relevant gene expression patterns and selecting informative gene targets, respectively, compared to methods used in traditional gene expression analysis [5], [6]. Additionally, the application of ST, combined with graph-based machine learning methods, has been demonstrated in research on glioblastoma multiforme, uncovering spatially restricted tumor niches and signaling networks relevant to patient survival. This highlights the potential of ST combined with ML to contribute to the development of new therapeutic strategies by providing a more nuanced understanding of disease pathology at the spatial level. ST, enhanced by machine learning techniques, offers a more comprehensive and nuanced understanding of gene expression by preserving and analyzing the spatial context of tissues, a capability that traditional methods lack. Yet, machine learning frameworks have shown to be sub-optimal for analyzing the complex, noisy, and high-dimensional data generated by ST due to challenges such as spatial resolution, sensitivity, and gene coverage [7]. Deep learning (DL)-based models, however, are being developed to address these ST-specific challenges, including alignment, spatial reconstruction, and spatial clustering, showcasing the potential for transformational applications

in analyzing spatially resolved transcriptomics data [8]. These approaches not only advance our fundamental understanding of biological processes but also open new avenues for disease research and therapeutic development.

The historical process of human monkeypox disease traces back to its first identification in the Democratic Republic of Congo (DRC) in 1970, following the discovery of the monkeypox virus in monkeys in 1958 [9]. Initially endemic to Central and Western Africa, the disease is caused by the monkeypox virus (MPXV), a zoonotic orthopoxvirus sharing clinical similarities with smallpox but distinguishable by symptoms such as lymphadenopathy [10]. Over the years, the disease has seen a gradual increase in incidence, with a notable shift in the median age of affected individuals from children to young adults and a variation in fatality rates between different clades of the virus. Human monkeypox, caused by Monkeypox virus, has historical significance post smallpox eradication. The recent 2022 outbreak, with global spread and human-to-human transmission, highlights its current threat level.

The classification of human monkeypox disease using deep learning techniques encompasses a variety of approaches aimed at enhancing early detection, diagnosis, and understanding of the disease's spread. These methods leverage Convolutional Neural Networks (CNNs), transfer learning, ensemble learning, and feature fusion techniques to analyze skin lesion images and predict monkeypox outbreaks. One primary method involves the development of diagnostic models using Generalization and Regularization-based Transfer Learning approaches (GRATLA) for binary and multiclass classification of monkeypox, demonstrating the potential of machine learning in distinguishing between infected and non-infected individuals with high accuracy [11]. Similarly, the construction of a Computer-Aided Diagnosis (CAD) tool, "Monkey-CAD," utilizes features extracted from multiple CNNs, employing Discrete Wavelet Transform (DWT) for feature fusion and entropy-based feature selection to enhance classification performance [12]. The application of machine learning and image processing methods, including data augmentation and transfer learning strategies across various deep learning models, has been pivotal in developing highly accurate models for monkeypox diagnosis, such as "PoxNet22," which achieved 100% precision, recall, and accuracy [13]. Additionally, emotion classification from social media posts using deep learning models like CNN, Long-Short Term Memory (LSTM) and Bi-Directional LSTM (BiLSTM) have provided insights into public sentiment and concerns regarding monkeypox, indirectly aiding in geographical classification by identifying areas of heightened concern [13]. Deep-learning methods supported with transfer learning tools and hyperparameter optimization have been employed to detect monkeypox through skin lesions, with models like MobileNetV3-s showing remarkable results [14]. The development of an image-based deep convolutional neural network, MPXV-CNN, for identifying characteristic skin lesions caused by monkeypox, has shown robust classification performance across various skin tones and

body regions [15]. Ensemble learning-based frameworks that combine probabilities from pre-trained base learners like Inception V3, Xception, and DenseNet169 have also been proposed to detect monkeypox virus presence from skin lesion images with high accuracy [16]. Mobile applications using deep learning for preliminary diagnosis of monkeypox through skin lesion images offer a quick and accessible tool for individuals, potentially aiding in the geographical classification by facilitating early detection [17]. Longitudinal studies assessing spatiotemporal risk factors of monkeypox infection and predicting global epidemiological trends using modified SEIR models and k-means clustering analysis have provided insights into changing risk factors and future outbreak predictions [18]. Finally, the comparison of different pre-trained deep learning models fine-tuned for monkeypox virus detection has led to the development of ensemble approaches that improve overall performance, aiding health practitioners in mass screening [19]. These methods collectively contribute to the geographical classification of monkeypox disease by enabling accurate and early detection, understanding public sentiment, and predicting future outbreaks, thereby assisting in containment efforts and public health planning.

The fact that deep learning is successful in various fields and is effective in the classification of monkeypox disease geographically, led us to analyze the DNA data of monkeypox disease with KANs, a new deep learning model, in this study. The utilization of color-coded representations in genetic sequence visualization offers a compelling approach to elucidate complex genomic information. By assigning specific colors to each nucleotide—blue for Adenine, yellow for Thymine, red for Cytosine, green for Guanine, and white for undefined nucleotides—researchers can create an intuitive visual map of DNA structures, facilitating the identification of patterns and motifs within the genetic code. This method is further enhanced by the implementation of advanced edge detection algorithms, which employ brightness and geometric thresholds, along with segmentation area parameters, to accentuate structural features that might otherwise remain obscure in traditional digital mapping techniques. Moreover, these color-coded images are designed to serve as input for transfer learning classification models, effectively bridging the gap between bioinformatics and machine learning. This innovative approach enables the application of sophisticated pattern recognition and classification techniques to genetic sequence data through their visual representations, potentially offering new insights into genomic structures and functions.

In the study, DNA sequences associated with monkeypox disease were initially obtained from both American and Asian regions. These sequences were subsequently color-coded, and DNA motifs were generated. Following motif creation, a filtering process was conducted, and the resultant images were subjected to classification using both KANs and various Artificial Neural Network (ANN) models, which were then compared. There are several deficiencies of traditional spatial transcriptomics (ST) methods such as

the use of tools like SPADE and PERSIST, and the application of graph-based ML methods, are associated with the paper's approach. SPADE and PERSIST tools exemplify tailored approaches developed to leverage the unique aspects of ST data. The paper's use of KANs can be seen as a continuation of this trend, aiming to provide superior performance in detecting spatially relevant gene expression patterns and selecting informative gene targets. Also in Graph-Based ML methods, The application of graph-based ML methods in previous research highlights the potential of combining ST with ML to uncover spatially restricted niches and signaling networks. This paper's approach with KANs aligns with this by offering a more nuanced understanding of disease pathology at the spatial level, potentially contributing to new therapeutic strategies.

Model performance was evaluated based on precision, recall, and F1-score metrics. The highlights of this study can be explained as follows:

- For the first time in this study, the DNA sequences that cause monkeypox disease were color-coded.
- To the best of our knowledge, for the first time in this study, KANs deep learning model was employed to classify monkeypox DNA motifs.
- This study shows that deep learning-based image-screen methods can be effective in regional transcriptome and phylogenetic analysis.

The remainder of the study is organized as follows: In the second section, information about the data set and methods used in the study is given. In the third section, application results are given, and the findings obtained with both KANs, and other models are compared. In the fourth section, discussion is made and the performance of the KANs model is examined. In the last section, the study was concluded, suggestions and future studies were mentioned.

Material and Methods

Datasets

The DNA sequences utilized in the research were sourced from GISAID [20] and the National Center for Biotechnology Center (NCBI Virus) [21]. These databases offer a comprehensive analysis of Human Monkey Pox DNA records globally since its isolation in December 2022. During the investigation, we acquired the Asian-tagged series from the NCBI Virus database and the remaining sequences from GISAID. Data archived and shared in these repositories are formatted as FASTA [22] files, containing essential details such as date, location, quality, and publication information of the researchers involved in isolating the virus's DNA sequence. The repositories also indicate the quality of DNA sequences, leading us to avoid utilizing incomplete or low-quality sequences in our classification model. Presently, GISAID has published over 5,000 complete or partial genomic sequences, while the NCBI Virus database contains more than 2,000 fully or partially labeled sequences. The cumulative count of complete gene sequences obtained from these databases amounts to 3,165. The distribution of these sequences is as

follows: Europe 900, America (North and South) 1,448, Asia 926, as depicted in Figure 1. The data integrity and completeness in these repositories are signified by the requirement of a base pair count exceeding 29,000 and an unresolved amino acid percentage of less than 5%. These criteria ensure that the DNA information collected accurately represents all amino acid values. Despite our preference for fully isolated gene sequences, occasional utilization of sequences containing "N" placeholders was necessary due to limited data availability. Due to the relative unevenness in the distribution of DNA sequences, the data set collected during the study was divided into two groups: American and Asian. In such a study, a simple binary classification problem was applied. This resulted in two almost equally distributed classes.

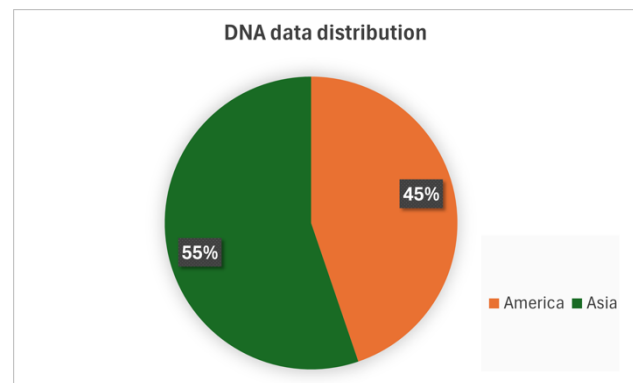


Figure 1. The complete genome sequences counts are distributed by continents for the training dataset.

DNA Motifs

When the DNA sequences of the Human Monkey Pox virus were transformed into visual representations, a strategic approach was employed by drawing an analogy and portraying them in the form of circular shapes. It is worth noting that a DNA sequence is comprised of four fundamental nucleobases, namely Adenine (A), Cytosine (C), Guanine (G), and Thymine (T). The representation of these nucleobases is further enhanced by the utilization of distinct color codes; Adenine-Yellow, Cytosine-Blue, Guanine-Green and Thymine-Red.

The algorithm employed for the creation of DNA motifs is a sophisticated computational procedure utilized for the precise determination of the multitude of points necessary to discretize a circular shape into pixels. Within the intricate flow of this algorithmic process, the initial step involves the identification of points within the eight divided segments, followed by the meticulous determination of points within the remaining octant. In the meticulous process of pinpointing each point (x, y) along the circumference of the circle, the subsequent pixel coordinates are calculated as either (x, y + 1) or (x-1, y + 1), ensuring a systematic approach to pixel placement.

The application of this algorithm was pivotal in the task of populating the circle generated through the utilization of

DNA data, meticulously translated into a character array. This method resulted in the creation of intricate motifs, whereby the RNA sequences were transformed and represented in images with a resolution of 200x200 pixels and 3 color channels, thereby enhancing the visual representation of the genetic information. The varying lengths of gene sequences under scrutiny necessitated a meticulous determination of the optimal dimensions within our circle drawing algorithm, ensuring a standardized and efficient computational process. The flowchart of the process of the stages here is given in Appendix-A in detail. The detailed process steps of the flow chart are as follows:

The algorithm for DNA motif creation and filtering represents a sophisticated approach to transforming genetic sequence data into visual representations suitable for advanced analytical techniques, including machine learning applications. This process encompasses multiple stages, from initial data preprocessing to the generation of filtered images, each step carefully designed to ensure the integrity and relevance of the resulting motifs.

The process commences with the initialization phase, wherein the algorithm establishes crucial file paths for FASTA input, genome storage, motif output, and filtered motif storage. Concurrently, a regex filter is prepared to facilitate efficient text processing. Subsequently, the algorithm engages in a meticulous FASTA file processing stage. Here, the contents of the FASTA file are read and parsed using regex splitting, effectively separating the file into discrete entries for individual analysis.

Following the initial parsing, the algorithm proceeds with a line-by-line examination of the genetic sequences. This stage implements a series of stringent filters to ensure only high-quality, relevant genetic data is processed further. The filtering criteria include checks for non-empty lines, exclusion of header lines (those starting with ">"), minimum length requirements (greater than 50 characters), and the absence of long stretches of undefined nucleotides ("NNNNNNNN"). Lines meeting these criteria contribute to the construction of a comprehensive genome string, which is periodically written to storage and checked against a minimum length threshold to ensure sufficient genetic material for meaningful analysis.

The core of the motif creation process lies in the image generation phase. Here, the algorithm initializes key parameters such as image radius and origin, creating a bitmap with dimensions of 200x200 pixels. The algorithm then employs a mathematical approach to determine the height of each column in the circular representation, calculated as the square root of the difference between the squared radius and the squared x-coordinate. This calculation ensures a proper circular shape in the resulting image.

In the pixel processing stage, the algorithm iterates through each calculated y-coordinate, mapping nucleotides from the genetic sequence to specific colors: Adenine to blue, Thymine to yellow, Cytosine to red, Guanine to green, and any undefined nucleotides to white. This color-coding scheme creates a visually distinct representation of the

genetic sequence, with each pixel in the image corresponding to a specific nucleotide in the original sequence.

Post-generation, the algorithm applies a sophisticated edge detection technique to enhance the visual patterns within the motif. This process involves the careful setting of brightness and geometric thresholds, as well as a segmentation area parameter. The edge detection algorithm examines each pixel in the context of its local neighborhood, defined by a circular mask. By comparing brightness values and calculating a segmentation area, the algorithm determines whether each pixel represents an edge or a continuous region, thereby highlighting the structural features of the genetic sequence in the visual representation.

The final stages of the algorithm involve the storage of both the original motif image and its edge-detected variant, saved as PNG files in their respective directories. These images serve as the end product of the visualization process, encapsulating complex genetic information in a format conducive to further computational analysis.

Ultimately, these generated images are primed for utilization in transfer learning classification models. This final step bridges the gap between bioinformatics and machine learning, allowing for the application of advanced pattern recognition and classification techniques to genetic sequence data through their visual representations.

In conclusion, this algorithm represents a multifaceted approach to genetic sequence visualization, combining elements of bioinformatics, image processing, and machine learning preparation. By transforming complex genetic data into standardized, visually interpretable formats, it paves the way for novel insights and analytical approaches in genomic research and related fields.

Throughout the process of motif creation, any gaps or unoccupied pixels were elegantly filled with white color to seamlessly complete the circular shape, albeit with a subtle linear flaw discernible on the right periphery. From the perspective of artificial neural networks, these images can be interpreted as multi-dimensional arrays with dimensions of 200x200x3, encapsulating the intricate details of the DNA motifs. The resultant DNA motif, a product of this intricate algorithmic process, is visually presented in Figure 2 showcasing the culmination of computational precision and biological data integration. Before obtaining the images in this particular context, it was necessary for us to utilize the FASTA files that were acquired from various datasets, a crucial step in the process aimed at transforming these files into motifs. This transformation involved the meticulous separation of the data contained within these files into distinct DNA sequences, a task that was accomplished through the implementation of a specialized application that we meticulously crafted using the Delphi programming language.




Figure 2. The motif of the sample isolated Human Monkey Pox DNA and generated and filtered nucleobase the motif.

Based on the results of this preliminary examination, clusters were created using the K-means clustering algorithm in combination with the Principal Component Analysis method. The aim here is to determine whether it is possible to separate the motif images in a phylogenetic analysis. The application showed that a total of 49 clusters belonging to 3165 DNA motifs were formed. Cluster 5 and cluster 21 were selected and analyzed as examples from the clusters obtained here. The first results obtained can be seen in Figure 3.




Figure 3. K-means sample cluster comparing with phylogenetic distributions.

The genomes shown in Figure 3 with accession numbers OP890527, OP752114, ON754986 belong to cluster 5 and the others to cluster 21. This random selection suggests that the DNA-motif application can be used to classify genomes to a certain extent.

Also when observing the motif files acquired through our research endeavors, it became evident that certain segments within them exhibit a repetitive nature. Upon closer examination, we assessed that these reiterated sections potentially signify specific patterns within the DNA configuration of the virus, whereby some segments remain unaltered while others undergo mutations. The accurate functioning of the classification model hinges on the ability to recognize and delineate these patterns, particularly crucial for pinpointing mutations that vary across different geographical regions. Furthermore, we deliberated that the identification of these patterns could prove advantageous in constructing the hierarchical structure of phylogenetic trees using newly obtained DNA sequences, as well as in drawing comparisons with previously analyzed genetic sequences.

A prominent technique employed in the realm of visual information processing, including tasks like image segmentation and pattern recognition, pertains to the utilization of the edge detection methodology. Over time, numerous algorithms have been devised for edge detection

purposes. Nevertheless, it is noteworthy that the inception of low-level applications marked the initial stages of image processing methodologies, which have progressively evolved to more sophisticated levels in contemporary times. In our quest to identify repetitive motifs within the motif files at hand, we opted for the utilization of the low-level edge detection algorithm. Applying the image filter converted RGB pictures to grayscale from motifs obtained. Picture dimensions are stored as 200x200x3.

Kolmogorov-Arnold Networks

Kolmogorov-Arnold Networks (KANs) emerge as highly promising alternatives to Multi-Layer Perceptrons (MLPs) within the realm of neural networks. It is important to note that KANs boast robust mathematical underpinnings akin to those of MLPs: the latter are established upon the foundational universal approximation theorem, whereas the former find their basis in the esteemed Kolmogorov-Arnold representation theorem [24]. In a fascinating duality, KANs and MLPs exhibit contrasting characteristics: KANs implement activation functions on edges, whereas MLPs employ activation functions on nodes. This seemingly subtle alteration actually renders KANs superior to MLPs in terms of both model accuracy and interpretability [25].

KANs, highlights the foundational role of MLPs in deep learning, acknowledged for their expressive power in approximating nonlinear functions, as guaranteed by the universal approximation theorem. However, MLPs for their significant drawbacks, including their consumption of a vast majority of non-embedding parameters in models like transformers and their relative lack of interpretability without the aid of post-analysis tools. In contrast, KANs are proposed with learnable activation functions on edges, replacing every weight parameter with a univariate function parametrized as a spline, which leads to improvements in accuracy and interpretability over MLPs. KANs, with their architecture, mathematical foundation, and potential for scientific discovery, promising a significant leap in accuracy and interpretability for data fitting and PDE solving while potentially overcoming the curse of dimensionality.

KANs leveraging the Kolmogorov-Arnold representation theorem to propose a neural network architecture with learnable activation functions on edges, replacing traditional weight parameters with univariate functions parametrized as splines. The methodology begins with the design of a neural network that explicitly parametrizes the Kolmogorov-Arnold representation, using B-spline curves with learnable coefficients for each 1D function, forming the basis of KANs. This approach allows for the creation of a prototype KAN, visualized as a two-layer neural network with activation functions placed on edges and simple summation performed on nodes. To enhance the model's capability, the paper discusses generalizing KANs to be wider and deeper, addressing the challenge of extending the Kolmogorov-Arnold representation to deeper networks by drawing an analogy between MLPs and KANs and defining a "KAN layer" as a matrix of 1D functions with trainable parameters. Furthermore, KANs with existing methods, highlighting the continuous learning and robustness of KANs over traditional symbolic regression techniques. It also delves into the scaling laws and intrinsic dimensionality, providing a theoretical framework for understanding the efficiency and effectiveness of KANs in terms of model parameters and test loss. The main differences between KAN networks and standard MLP networks are shown in Table 1.

Table 1. Kolmogorov-Arnold Networks (KANs) vs. Multi-Layer Perceptrons (MLPs).

Kolmogorov-Arnold Network (KAN)	Multi-Layer Perceptron (MLP)
$f(x) = \sum_{q=1}^{2n+1} \Phi_q \left(\sum_{p=1}^n \Phi_{q,p}(x_p) \right)$	$f(x) \approx \sum_{i=1}^{N(\epsilon)} a_i \sigma(w_i \cdot x + b_i)$
Sum operation on nodes and learnable activation functions on edges.	Learnable weights on edges and fixed activation functions on nodes.
$\text{KAN}(x) = (\Phi_3 \circ \Phi_2 \circ \Phi_1)(x)$	$\text{MLP}(x) = (w_3 \circ \sigma_2 \circ w_2 \circ \sigma_1 \circ w_1)(x)$

In Table 1, univariate functions $\Phi_{p,q}, \Phi_q$ defined as $\Phi_{p,q} : [0, 1] \rightarrow \mathbb{R}$ and $\Phi_q : \mathbb{R} \rightarrow \mathbb{R}$. Given an input vector x_0 , in a network of L KAN layers, $\text{KAN}(x)$ is the output of the network.

Experiments and Results

Before the classification with KAN networks, existing methods were tested in order to correctly classify the motif structure designed for this study. One of the problems that can be encountered in DNA classification studies is that the random evolution process in gene changes is not predictable. However, after the motifs are obtained, the first naive examination shows that some patterns follow each other. This view is that they can be analyzed by basic classification methods. For this purpose, the previously proven transfer learning method was applied. Transfer learning plays a pivotal role in the field of artificial intelligence (AI) by enabling the application of knowledge gained from one task to improve performance on a related but different task. This technique is particularly beneficial in scenarios where labeled data for the target task is scarce, allowing models to leverage larger datasets from related tasks to overcome overfitting and enhance performance on the target task. distinguishes itself from traditional machine learning techniques through its unique approach of leveraging pre-existing knowledge from one task to improve performance on a related, yet distinct, task [29-31]. Unlike conventional machine learning methods that start the learning process from scratch for each new task, transfer learning capitalizes on the insight gained from previously solved problems to enhance learning efficiency and accuracy for new problems. This is particularly advantageous in scenarios where labeled data for the new task is scarce or expensive to obtain, as it allows the model to bypass the intensive data requirement typically necessary for training machine learning models from the ground up. Moreover, transfer learning is versatile in its application, encompassing a range of computational intelligence-based techniques, including neural networks, evolutionary algorithms, swarm intelligence, and fuzzy logic, to improve performance further than what vanilla transfer learning can achieve on its own [29].

Transfer learning operates by leveraging the knowledge acquired from one or more source tasks to improve the learning efficiency and performance on a related target task. This process is particularly beneficial in scenarios where labeled data for the target task are scarce or expensive to obtain. At its core, transfer learning involves two main stages: pre-training and fine-tuning [30]. During the pre-training stage, a model is trained on a source task that has abundant labeled data. This model learns a set of features or representations that are potentially useful for the target task. For instance, in the domain of circuit performance prediction, neural networks optimally trained on data from one technology node can learn features that are transferable to another technology node, significantly reducing the amount of data required for accurate predictions in the target node [31].

In this study, the weight values extracted from the pre-existing networks were transferred initially to an AveragePooling layer. Subsequently, a 50% dropout was implemented to transfer the values from this layer to the neural network connections, thus mitigating overfitting during the learning process. The dropout mechanism facilitates the removal of certain network cells from the model, consequently averting overfitting of the neural network. During the final phase, the DNA sequences were directed to the 4-dimensional fully connected layer designated for classifying the four classes. The non-linear function selected for this layer was SoftMax. SoftMax function operates by taking a vector of K real numbers as input and normalizing it to a distribution of K probabilities proportionate to the exponents of the input numbers.

Additionally, within the model, the loss function employed was categorical cross-entropy. This function is commonly utilized for single label categorization, signifying that only one class is relevant for each data point. Optimization method was preferred and used as RMSProp (Root Mean Square Propagation) for training. Optimization functions are used to determine the learning rate of the artificial neural network. The Learning Rate value in the optimization function was set as 0.001. Also training lasted for 15 epochs.

The classification results of the pre-trained networks used in the study are shown in Table 2. The network structure chosen for the best classification reflects an optimal model.

Table 2. Test dataset results obtained in various artificial neural networks.

#	Model	Precision	Recall	f1-score	Test Accuracy
0	MobileNet	0.6855	0.6571	0.62056	0.6571
1	MobileNetV2	0.6468	0.6444	0.6247	0.6444
2	InceptionV3	0.6383	0.6222	0.5768	0.6222
3	ResNet50	0.7054	0.5809	0.4506	0.5809
4	ResNet101	0.3157	0.5619	0.4043	0.5619
5	DenseNet121	0.5265	0.5619	0.4043	0.5619
6	VGG16	0.3157	0.5619	0.4043	0.5619
7	InceptionResNetV2	0.3157	0.5619	0.4043	0.5619
8	VGG19	0.3157	0.5619	0.4043	0.5619
9	DenseNet169	0.6302	0.6190	0.5764	0.6190

Table 2 shows that the MobileNet network gives the best results. Here, the pruned weights of this network are thought to cause a more effective classification. The comparative analysis of various artificial neural networks reveals MobileNet as the optimal model, demonstrating superior performance across multiple evaluation metrics. MobileNet achieved the highest recall and test accuracy (both 0.6571), indicating its proficiency in correctly identifying positive instances and overall classification accuracy. Its precision (0.6855) was second only to ResNet50, showcasing its ability to minimize false positives. The F1-score (0.62056), a harmonic mean of precision and recall, further corroborates MobileNet's balanced performance. These metrics are derived from standard formulae:

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

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

$$\text{F1} = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall}),$$

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}),$$

where TP, FP, TN, and FN represent True Positives, False Positives, True Negatives, and False Negatives, respectively. MobileNet's consistent high performance across these metrics underscores its efficacy in scenarios requiring a balance between precision and recall, coupled with high overall accuracy. After this stage, DNA sequences that were separated from the dataset and not included in the training were tested with MobileNet. In this network, Test Loss is 0.5982, Test accuracy is 65.71% and Cohen Kappa Score is 0.25737. Other results of the network are as shown in Table 3.

Table 3. MobileNet results of Test dataset.

Region	Precision	Recall	f1-Score	Support
America	0.75	0.33	0.45	138
Asia	0.64	0.92	0.75	177

Accuracy and loss graphs for training set obtained is shown in Figure 4.




Figure 4. Training loss and accuracy plots of MobileNet model.

The confusion matrix of the test results is also shown in Figure 5. The confusion matrix reveals a notable level of accuracy in classifying our motif files. Despite the minor inaccuracies, it is essential to acknowledge the interrelation among the data elements, such as the mutation-induced connection observed in virus DNA. The contentious nature of this assertion deems it as a focal point for further discussion. Extensive investigation is necessary to support the claim that the error matrix also highlights these distinctions, particularly due to the absence of absolute geographical delineations in virus mutations.




Figure 5. Confusion matrix was obtained in the test of two classes (America:1, Asia 0) in MobileNet model.

Considering the success of the network model used in this study in the transfer learning process, the equivalent structure was applied to KAN networks. However, as expected, the results were not obtained as expected since the KAN network did not have a set of weights whose success was calculated in advance. Accuracy and loss plots for training process shown in Figure 6.



Figure 6. Training loss and accuracy plots of KAN model

In KAN networks, sum functions are used from the weights. In various experiments, an effective sum function could not be found. However, since it is still a new technology, the results obtained are still promising. According to the results obtained from the test data Accuracy is 0.45182, Precision is 0.43129, Recall is 0.45182, F1 Score is 0.32187 and Cohen Kappa Score is -0.02551. In Table 4, observed values from the results obtained on the test data set are shown.

Table 4. KAN results of Test dataset.

Region	Precision	Recall	f1-Score	Support
America	0.45	0.93	0.61	292
Asia	0.41	0.04	0.07	341

The confusion matrix of the test results in KAN is also shown in Figure 7.




Figure 7. Confusion matrix was obtained in the test of two classes in KAN (America:1, Asia 0).

Discussion and Conclusion

DNA classification is a critical component in the fields of bioinformatics and computational biology, contributing

significantly to genome annotation, disease diagnosis, and evolutionary studies. Through the process of genome annotation, DNA classification facilitates the identification of functional elements within genomes, such as genes, regulatory regions, and non-coding DNAs. This is essential for comprehending the organization and function of genomes, thereby providing foundational insights for further genetic research. In the realm of disease diagnosis and prognosis, accurate DNA classification aids in the detection of genetic variations associated with various diseases. This capability enables early diagnosis and prognosis, thereby allowing for the development of personalized treatment strategies that can improve patient outcomes. Spatial transcriptomics analysis is a powerful technique for understanding tissue heterogeneity and gene expression patterns within their spatial contexts. By preserving the spatial organization of cells within a tissue, spatial transcriptomics allows researchers to identify distinct cell types, their spatial arrangement, and their interactions. This is crucial for deciphering the complexity of tissue composition and function. Furthermore, spatial transcriptomics has the potential to uncover novel cell types and states along with their spatial relationships, thus providing a more detailed understanding of tissue architecture and dynamics. In the study of disease pathology, spatial transcriptomics is instrumental in examining gene expression changes within the context of disease progression. Despite the significant advancements, there are several challenges associated with employing deep learning techniques in DNA classification and spatial transcriptomics analysis. One major challenge is the limited availability of labeled data, which is essential for training deep learning models. The acquisition of labeled DNA sequences or spatial transcriptomics data is often expensive, time-consuming, and necessitates expert annotation. Another challenge is class imbalance within genomic and transcriptomic datasets, where some classes, such as rare genetic variants or cell types, are underrepresented. This imbalance can lead to biased models that do not perform well on minority classes. Additionally, the length and complexity of DNA sequences pose difficulties for deep

learning models, which must capture long-range dependencies and intricate patterns to be effective. As the field advances, deep learning is anticipated to play an increasingly vital role in unraveling the complexities of genomes and spatial gene expression patterns, ultimately contributing to significant progress in basic research, disease understanding, and personalized medicine.

According to the KAN results obtained in the study, for the America region, the model achieves a Precision of 0.45, indicating that 45% of the instances predicted as America are actually from America. The Recall is 0.93, which means that the model correctly identifies 93% of all instances that truly belong to America. The F1-Score of 0.61 suggests a moderate balance between Precision and Recall. The Support value of 292 represents the total number of instances from America in the dataset. On the other hand, the model's performance for the Asia region is significantly lower. The Precision is 0.41, meaning that 41% of the instances predicted as Asia are correctly classified. However, the Recall is only 0.04, indicating that the model identifies just 4% of all instances that actually belong to Asia. This extremely low Recall suggests that the model is struggling to recognize instances from Asia, leading to a high number of false negatives. The F1-Score of 0.07 further confirms the poor performance for this region. The Support value of 341 shows that there are more instances from Asia than America in the dataset.

The observed performance gap between the two regions implies a potential bias towards the America region within the model, as indicated by the notably higher Recall metric. Several factors could contribute to this bias:

First, an imbalanced dataset might be a contributing factor, wherein the training data comprises a disproportionately larger number of instances from the America region compared to Asia. This imbalance can lead the model to favor the majority class, potentially skewing its performance towards better recognition of instances from the overrepresented region. Second, discrepancies in feature representation could exacerbate the bias. It is plausible that the features utilized for classification exhibit greater discriminative power for instances originating from the America region, thus facilitating easier identification by the model. This could stem from inherent differences in the characteristics or distributions of features between the two regions. Lastly, the selected model architecture might inherently predispose towards capturing patterns specific to the America region more effectively. Certain architectural choices, such as network depth, layer configurations, or activation functions, could inadvertently favor learning representations that align better with the characteristics prevalent in the America region, consequently amplifying the observed bias in model performance.

Addressing these potential sources of bias necessitates careful consideration during the model development and evaluation process. Strategies for mitigating bias include ensuring balanced representation of instances from different regions in the training data, augmenting features to enhance their discriminative power across diverse regions and

exploring alternative model architectures that are more agnostic to regional disparities. By adopting such approaches, the model's robustness and generalizability across varied geographical contexts can be enhanced, thereby fostering more equitable performance outcomes.

Despite the impressive results achieved so far, there is still significant room for improvement and further development of KANs. One area of active research is the exploration of new network architectures that can better capture the intricate relationships within data. This includes the investigation of deeper and more complex network structures, as well as the incorporation of attention mechanisms and memory components. By designing more sophisticated architectures, researchers aim to unlock the full potential of KANs and push the boundaries of their performance. Another promising avenue for future development is the integration of KANs with other machine learning techniques. For instance, combining KANs with deep learning approaches, such as convolutional neural networks (CNNs) or recurrent neural networks (RNNs), could lead to powerful hybrid models that leverage the strengths of both paradigms. Additionally, the incorporation of transfer learning and multi-task learning strategies could enable KANs to efficiently learn from related tasks and domains, further enhancing their adaptability and generalization capabilities. Furthermore, the interpretability and explainability of KANs are crucial aspects that require further investigation. While these networks have shown remarkable performance, understanding the internal representations and decision-making processes of KANs remains a challenge. Developing techniques to visualize and interpret the learned features and decision boundaries of KANs will not only improve their trustworthiness but also facilitate their application in domains where transparency is essential, such as healthcare and finance.

In conclusion, Kolmogorov-Arnold Networks have emerged as a promising state-of-the-art technology in the field of machine learning. The current results obtained using KANs are highly encouraging, showcasing their ability to learn and represent complex functions efficiently. However, there is still significant potential for further development and improvement. By exploring new network architectures, integrating KANs with other machine learning techniques, and addressing interpretability and explainability challenges, researchers can unlock the full potential of these networks. As the field of machine learning continues to evolve, it is expected that KANs will play an increasingly important role in shaping the future of artificial intelligence and its applications across various domains.

Acknowledgement

The GISAID and NCBI(Virus) researchers did not participate in the analysis or writing of this paper.

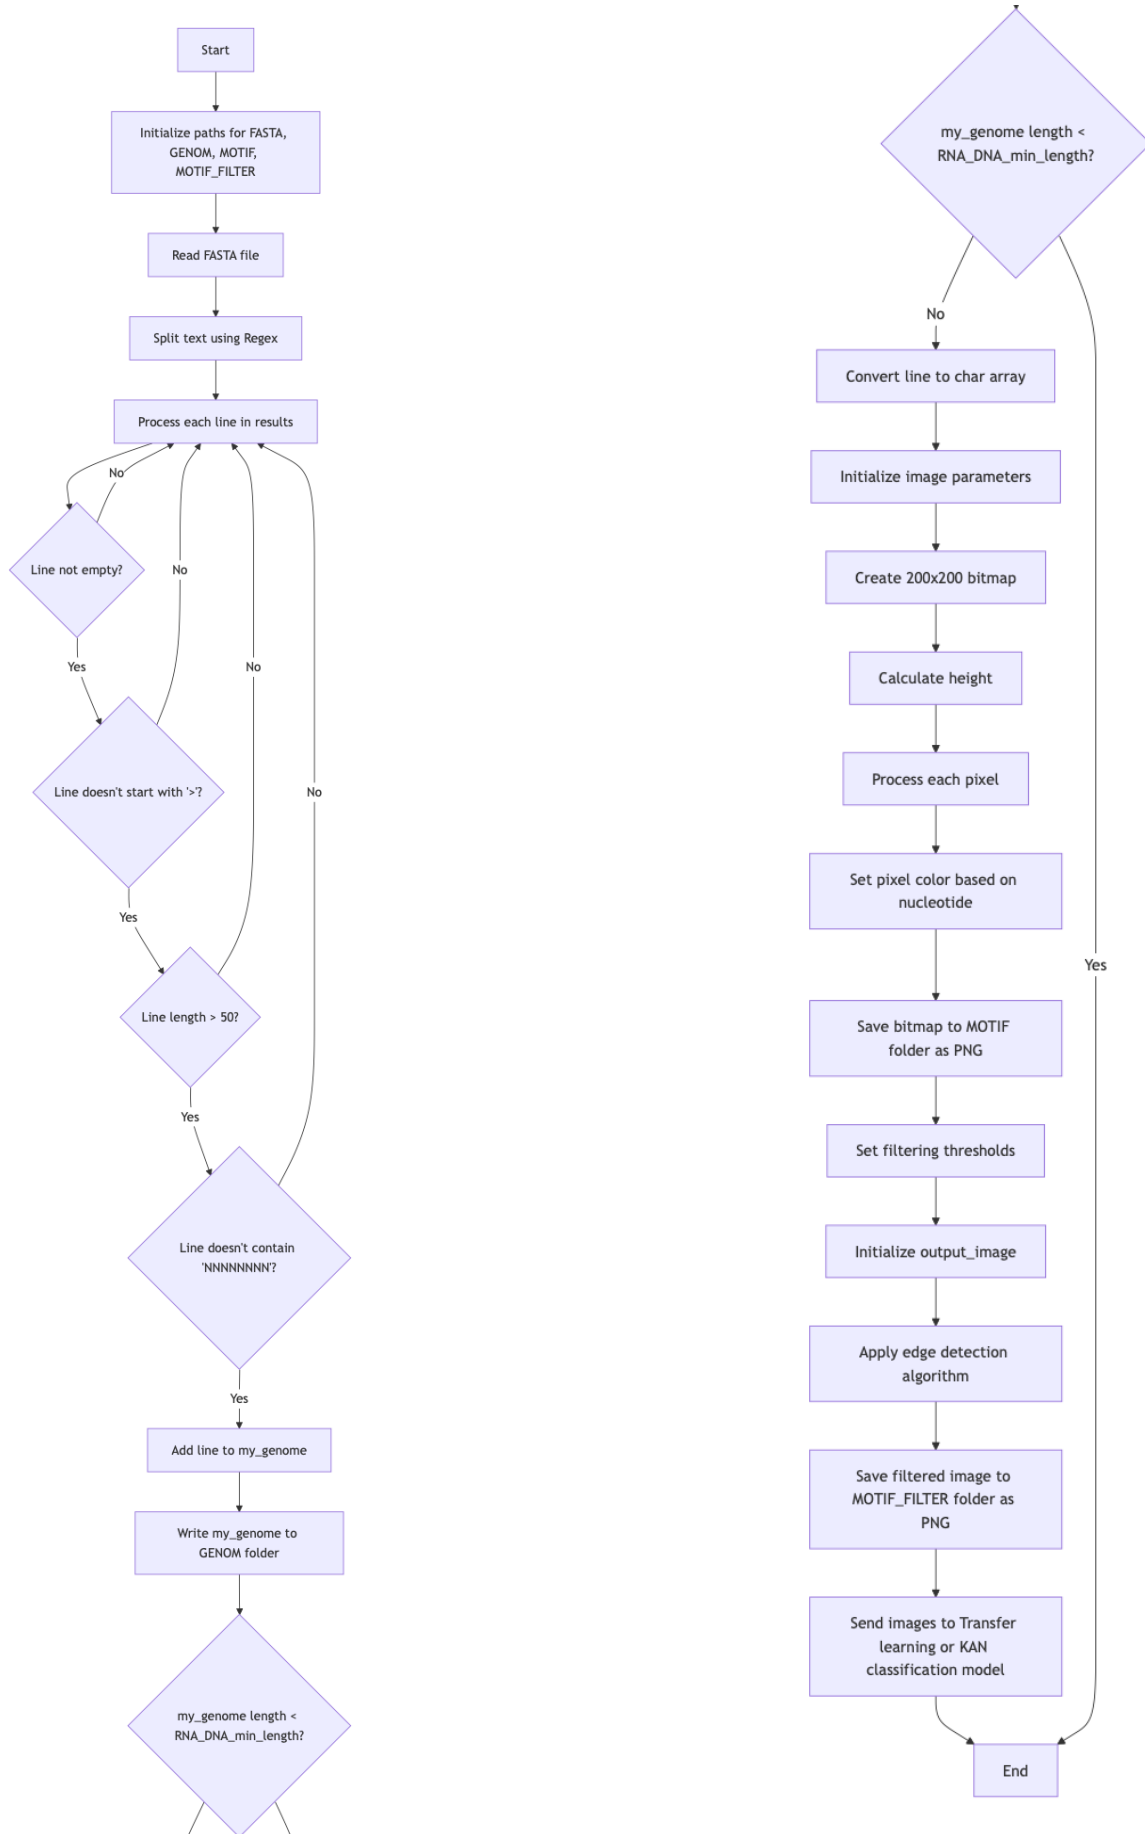
References

- [1] H. Park et al., "Spatial Transcriptomics: Technical Aspects of Recent Developments and Their Applications in

- Neuroscience and Cancer Research,” *Adv. Sci.*, vol. 10, no. 16, p. 2206939, Jun. 2023, doi: 10.1002/advs.202206939.
- [2] A. A. Heydari and S. S. Sindi, “Deep learning in spatial transcriptomics: Learning from the next next-generation sequencing,” *Biophys. Rev.*, vol. 4, no. 1, p. 011306, Mar. 2023, doi: 10.1063/5.0091135.
- [3] D. F. Miyagishima et al., “157 Identifying Spatial Transcriptomics Signaling Networks in Human Glioblastoma Using Graph-Based Machine Learning,” *Neurosurgery*, vol. 69, no. Supplement_1, pp. 42–42, Apr. 2023, doi: 10.1227/neu.0000000000002375_157.
- [4] I. Covert, R. Gala, T. Wang, K. Svoboda, U. Sümbül, and S.-I. Lee, “Predictive and robust gene selection for spatial transcriptomics,” *Nat. Commun.*, vol. 14, no. 1, p. 2091, Apr. 2023, doi: 10.1038/s41467-023-37392-1.
- [5] A. J. Lee, R. Cahill, and R. Abbasi-Asl, “Machine Learning for Uncovering Biological Insights in Spatial Transcriptomics Data,” 2023, doi: 10.48550/ARXIV.2303.16725.
- [6] Z. Qiu, S. Li, M. Luo, S. Zhu, Z. Wang, and Y. Jiang, “Detection of differentially expressed genes in spatial transcriptomics data by spatial analysis of spatial statistics,” *Front. Neurosci.*, vol. 16, p. 1086168, Nov. 2022, doi: 10.3389/fnins.2022.1086168.
- [7] F. Qin, X. Luo, B. Cai, F. Xiao, and G. Cai, “Spatial pattern and differential expression analysis with spatial transcriptomic data,” *Jul.* 09, 2023. doi: 10.1101/2023.07.06.547967.
- [8] A. Robles-Remacho*, R. M. Sanchez-Martin, and J. J. Diaz-Mochon*, “Spatial Transcriptomics: Emerging Technologies in Tissue Gene Expression Profiling,” Apr. 28, 2023. doi: 10.26434/chemrxiv-2023-n20f0.
- [9] M. Zahmatyar et al., “Human monkeypox: history, presentations, transmission, epidemiology, diagnosis, treatment, and prevention,” *Front. Med.*, vol. 10, p. 1157670, Jul. 2023, doi: 10.3389/fmed.2023.1157670.
- [10] Y. Li, S. Stanojevic, and L. X. Garmire, “Emerging artificial intelligence applications in Spatial Transcriptomics analysis,” *Comput. Struct. Biotechnol. J.*, vol. 20, pp. 2895–2908, 2022, doi: 10.1016/j.csbj.2022.05.056.
- [11] M. M. Ahsan et al., “Deep transfer learning approaches for Monkeypox disease diagnosis,” *Expert Syst. Appl.*, vol. 216, p. 119483, Apr. 2023, doi: 10.1016/j.eswa.2022.119483.
- [12] O. Attallah, “MonDial-CAD: Monkeypox diagnosis via selected hybrid CNNs unified with feature selection and ensemble learning,” *Digit. Health*, vol. 9, p. 205520762311800, Jan. 2023, doi: 10.1177/20552076231180054.
- [13] F. Yasmin et al., “PoxNet22: A Fine-Tuned Model for the Classification of Monkeypox Disease Using Transfer Learning,” *IEEE Access*, vol. 11, pp. 24053–24076, 2023, doi: 10.1109/ACCESS.2023.3253868.
- [14] R. Olusegun, T. Oladunni, H. Audu, Y. Houkpati, and S. Bengesi, “Text Mining and Emotion Classification on Monkeypox Twitter Dataset: A Deep Learning-Natural Language Processing (NLP) Approach,” *IEEE Access*, vol. 11, pp. 49882–49894, 2023, doi: 10.1109/ACCESS.2023.3277868.
- [15] M. Altun, H. Gürüler, O. Özkaraca, F. Khan, J. Khan, and Y. Lee, “Monkeypox Detection Using CNN with Transfer Learning,” *Sensors*, vol. 23, no. 4, p. 1783, Feb. 2023, doi: 10.3390/s23041783.
- [16] A. H. Thieme et al., “A deep-learning algorithm to classify skin lesions from mpox virus infection,” *Nat. Med.*, vol. 29, no. 3, pp. 738–747, Mar. 2023, doi: 10.1038/s41591-023-02225-7.
- [17] R. Pramanik, B. Banerjee, G. Efimenko, D. Kaplun, and R. Sarkar, “Monkeypox detection from skin lesion images using an amalgamation of CNN models aided with Beta function-based normalization scheme,” *PLOS ONE*, vol. 18, no. 4, p. e0281815, Apr. 2023, doi: 10.1371/journal.pone.0281815.
- [18] V. H. Sahin, I. Oztel, and G. Yolcu Oztel, “Human Monkeypox Classification from Skin Lesion Images with Deep Pre-trained Network using Mobile Application,” *J. Med. Syst.*, vol. 46, no. 11, p. 79, Oct. 2022, doi: 10.1007/s10916-022-01863-7.
- [19] J. Gao et al., “Monkeypox outbreaks in the context of the COVID-19 pandemic: Network and clustering analyses of global risks and modified SEIR prediction of epidemic trends,” *Front. Public Health*, vol. 11, p. 1052946, Jan. 2023, doi: 10.3389/fpubh.2023.1052946.
- [20] Y. Shu and J. McCauley, “GISAID: Global initiative on sharing all influenza data – from vision to reality,” *Eurosurveillance*, vol. 22, no. 13, Mar. 2017, doi: 10.2807/1560-7917.ES.2017.22.13.30494.
- [21] E. L. Hatcher et al., “Virus Variation Resource – improved response to emergent viral outbreaks,” *Nucleic Acids Res.*, vol. 45, no. D1, pp. D482–D490, Jan. 2017, doi: 10.1093/nar/gkw1065.
- [22] W. R. Pearson and D. J. Lipman, “Improved tools for biological sequence comparison,” *Proc. Natl. Acad. Sci.*, vol. 85, no. 8, pp. 2444–2448, Apr. 1988, doi: 10.1073/pnas.85.8.2444.
- [23] W. S. Klug, M. R. Cummings, C. A. Spencer, M. A. Palladino, and D. J. Killian, *Essentials of genetics*, Tenth edition. Hoboken, NJ: Pearson, 2020.
- [24] A. N. Kolmogorov, “On the representation of continuous functions of many variables by superposition of continuous functions of one variable and addition,” presented at the *Doklady Akademii Nauk*, Russian Academy of Sciences, 1957, pp. 953–956.
- [25] Z. Liu et al., “KAN: Kolmogorov-Arnold Networks,” *ArXiv Prepr. ArXiv240419756*, 2024.

- [26] E. Waisberg et al., "Transfer learning as an AI-based solution to address limited datasets in space medicine," *Life Sci. Space Res.*, vol. 36, pp. 36–38, Feb. 2023, doi: 10.1016/j.lssr.2022.12.002.
- [27] L. Jin, C. Qu, Y. Zhang, C. Fan, Z. Zhu, and S. Liu, "Transfer Learning on Trial: A Case Study to Apply Existing Models to Heterogeneous Datasets," in *2023 International Conference on Pattern Recognition, Machine Vision and Intelligent Algorithms (PRMVIA)*, Beihai, China: IEEE, Mar. 2023, pp. 292–296. doi: 10.1109/PRMVIA58252.2023.00054.
- [28] K. Combs, H. Lu, and T. J. Bihl, "Transfer Learning and Analogical Inference: A Critical Comparison of Algorithms, Methods, and Applications," *Algorithms*, vol. 16, no. 3, p. 146, Mar. 2023, doi: 10.3390/a16030146.
- [29] J. Wang and Y. Chen, "From Machine Learning to Transfer Learning," in *Introduction to Transfer Learning, in Machine Learning: Foundations, Methodologies, and Applications.*, Singapore: Springer Nature Singapore, 2023, pp. 39–52. doi: 10.1007/978-981-19-7584-4_2.
- [30] A. H. Ali, M. G. Yaseen, M. Aljanabi, S. A. Abed, and C. Gpt, "Transfer Learning: A New Promising Techniques," *Mesopotamian J. Big Data*, pp. 29–30, Feb. 2023, doi: 10.58496/MJBD/2023/004.
- [31] Z. Wu and I. Savidis, "Transfer Learning for Reuse of Analog Circuit Sizing Models Across Technology Nodes," in *2022 IEEE International Symposium on Circuits and Systems (ISCAS)*, Austin, TX, USA: IEEE, May 2022, pp. 1033–1037. doi: 10.1109/ISCAS48785.2022.9937457.

APPENDIX-A: Flowchart of motif generation and classification process





Farklı Gölgeleme Özelliğine Sahip Binaların Enerji İhtiyacına Bağlı Isı Yayıma Sisteminin Ekserji İncelemesi

Exergy Analysis of Heat Dissipation System Based on Energy Requirement of Buildings with Different Shading Properties

Okan Kon^{1*}

¹ Balıkesir Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü, okan@balikesir.edu.tr

ORCID: <https://orcid.org/0000-0002-5166-0258>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 12 Ağustos 2024
Revizyon 10 Ekim 2024
Kabul 11 Ekim 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

Isıtma sistemi tesisatı, ısıtıcı, yakıt tüketimi, ekserji analizi, yakıt kimyasal ekserjisi

ÖZ

Çalışmada, ülkemizin farklı iklim bölgelerini temsilen seçilen Adana, Ordu, Nevşehir ve Bitlis şehirlerindeki farklı gölgeleme özelliğine sahip merkezi ısıtmalı binaların tesisatın dağıtıcı ve ısıtıcı özelliklerine bağlı ekserji yükleri tespit edilmiştir. Buna göre ilk olarak ayrı bina, ağaçlı bina ve bitişik bina olarak gölgeleme özellikleri tespit edilmiştir. Daha sonra gölgeleme ve iklim özelliklerine bağlı ısıtma enerji ihtiyacı hesaplanmıştır. Isıtma enerji ihtiyacına bağlı olarak doğal gaz, kömür ve fuel-oil yakıt için tüketim miktarları bulunmuştur. 90-70 ve 70-50 °C sıcaklık ile ısıtma yapan tesisatın ısı yayma (tesisat boruları ve kolon sistemi) ve ısıtıcı (radyatör) için gerekli parametrelerin değerleri hesaplanmıştır. Bu parametrelere bağlı ekserji yükleri tespit edilmiştir. Ekserji yüklerine bağlı farklı yakıtlar için tüketim miktarları tespit edilmiştir. Ekserji yüklerine bağlı yakıt tüketimleri hesaplarında doğal gaz, kömür ve fuel-oil için yakıtların kimyasal ekserjileri hesaplanmıştır. Sonuç olarak, en düşük 70-50 °C sıcaklıktaki tesisat dağıtım sistemi ve ayrı bina için 293.7 kg ile doğal gaz tüketimi, en yüksek ise 90-70 °C sıcaklıktaki tesisat dağıtım sistemi ve bitişik bina için 5321.3 kg ile kömür tüketimi hesaplanmıştır.

ARTICLE INFO

Article history:

Received 12 August 2024
Received in revised form 10 October 2024
Accepted 11 October 2024
Available online 23 December 2024

Keywords:

Heating system installation, heater, fuel consumption, exergy analysis, fuel chemical exergy

ABSTRACT

In the study, exergy loads depending on the distribution and heating properties of centrally heated buildings with different shading properties in Adana, Ordu, Nevşehir and Bitlis cities selected from different climate regions of our country were determined. First, the shading properties of detached buildings, buildings with trees and adjacent buildings were determined. Then, the heating energy requirement was calculated depending on the shading and climate characteristics. Fuel consumption for natural gas, coal and fuel-oil depended on the heating requirement. The necessary parameters for the heat distribution (installation pipes and column system) and heater (radiator) of the installation heating with 90-70 and 70-50 °C temperatures were calculated. Exergy loads depending on these parameters were determined. Fuel consumptions for different fuels were determined depending on the exergy loads. In addition, the chemical exergy of the fuels for natural gas, coal and fuel oil were found. As a result, the lowest natural gas consumption for the installation distribution system at 70-50 °C and the detached building type was calculated as 293.7 kg, and the highest consumption for coal was calculated as 5321.3 kg for the installation distribution system at 90-70 °C and the adjacent building.

Doi: 10.24012/dumf.1532106

* Sorumlu yazar

Giriş



Isı enerjisi, sıcaklığı yüksek olan yerden düşük olan yere doğru akış yapar, bu binaların dış duvarının özelliklerine bağlı olarak, entropi ve ekserji değerlerini belirlemek için kullanılmaktadır. Isı geçişinin meydana geldiği yönde sıcaklık değeri sabit kalmaz ve azalır. Buna göre entropi artacağından, duvardaki gerçekleşen ekserji geçişi azalacaktır. Ekserjetik olarak, duvarlarda sıcaklık değişimlerine bağlı entropi meydana gelir ve bunun sonucu olarak ekserji yıkımına sebep olur [1-3]. Binalarda enerji ilgili incelemeler, ilk olarak termodinamiğin birinci kanuna göre yapılmaktadır. Bu durum, binaların enerji kullanımında eksiklik yaratmaktadır. Buna göre ekserji analizi hem termodinamiğin birinci hem de ikinci kanununa göre yapılmalıdır. Binalarda enerjinin akışı belirlenmesi ekipmanların tasarlanması ve kullanımında oldukça önemlidir [4].

Çalışma ile ilgili literatür incelendiğinde; Kılıçlı A. yaptığı çalışmada, Ege Üniversitesindeki uluslararası Bilgisayar Enstitüsü binası için enerji incelemelerini yapmıştır. Binanın şuanadaki ve iyileştirilmiş halde hem enerji hem de ekserji analizleri yapılmıştır. Binanın enerji tasarruf potansiyeli tespit edilmiştir [1]. Yıldız ve Güngör yaptıkları çalışmada binalarda mekân ısıtma süreci için enerji ve ekserji analizleri yapılmıştır. Analizlerde ısıtma yükü dikkate alınmıştır. Analizler, İzmir'de 720 m³ hacimli ve taban alanı 240 m² olan bir ofis için yapılmıştır. Tüm sistemdeki enerji ve ekserji kayıpları ölçülmüştür [2]. Yıldırım, yaptığı çalışmada enerji analizi için yakıtın yanma enerjisine bağlı olarak, ekserji analizi için ise optimum yalıtımlı ve yalıtımsız duvar için, yüzey sıcaklıkları kullanılarak yapmıştır [3]. Hepbaşlı v.d. çalışmalarında, binaların ekserji analizinde kullanılan farklı yöntemler incelenmiştir. HVAC mühendislerinin ekserjiye dayalı bina analizleri konusunda bilgi kazanılması sağlanmıştır. Böylece enerjetik ve ekserjetik değerlendirmeleri göz önüne almaları gerektiği vurgulanmıştır [4]. Karakaşlı çalışmasında, Elazığ bir Hastane'nin yılda yaklaşık 6795.6 kWh ısıtma enerjisine ihtiyaç duyan göz polikliniğinin ve hastane binasının farklı bölümlerinde enerji ve ekserji analizi yapılmıştır. Sistem termodinamiğin birinci ve ikinci yasasına göre odaların enerji ve ekserji analizi araştırılmıştır [5]. Balta v.d. yaptıkları çalışmada, enerji santralinden, toprak kaynaklı ısı pompasına ve bina kabuğuna kadar ısıtma sisteminin ekserjetik analizi ve değerlendirilme yapılmıştır. Binalardaki enerji akışının iyileştirilmesi ve binalarda enerji kullanılmasının iyileşme olanakları araştırılmıştır [6]. Özel v.d. çalışmalarında, boru sisteminin optimum yalıtım kalınlığı, Türkiye'nin Bilecik şehri için çevresel etki analizi kullanılarak araştırılmışlardır. Boru sistemi için optimum yalıtım kalınlığı enerji, ekserji ve entransy yaklaşımı ile belirlenmiştir. Boru sisteminden enerji/ekserji/entransy kaybı, yakıt tüketimi ve CO₂ emisyonu hesaplanmıştır [7]. Shukuya çalışmasında, son 30 yılda yapılan ekserji araştırmalarının mevcut durumu hakkında genel bilgi vermiştir. Buna göre, termodinamiğin iki temel kanunu, sıcak ve soğuk ekserji kavramlarının kısa bir tanıtımını yapmıştır. Üç tipik uygulama gösterilmektedir; bunlar gölgeleme cihazları ile pencere sistemlerinin değerlendirmesi, yaz mevsimleri için insan vücudu ekserji analizi ve bir ısı pompası sisteminin ekserjetik değerlendirmesidir [8]. Omar çalışmasında, binaların ısı

enerji ihtiyacını karşılamak için yaygın kullanılan merkezi ısıtma sistemi ve bireysel ısıtma sistemleri incelenmiştir. Bunu için Kars ilindeki 10 dairesi 5 katlı bir binanın ısı kaybı ve enerji ihtiyacı TS 825 göre hesaplanmıştır. Her iki ısıtma sistem için ısıtıcı cihazların kapasiteleri tespit edilmiş, ısıtma sistemi elemanları belirlenmiş, yıllık yakıt tüketiminin miktarı ve maliyet hesapları yapılmıştır [9]. Yang v.d. yaptıkları çalışmada, büyük binalardaki hem mekân ısıtma hem de evsel sıcak su sistemlerinde bölgesel ısıtma sisteminin dönüş su borularında izlenemeyen arızaların özelliklerini ve potansiyel etkilerini araştırmışlardır. Tesisattaki arızalar ile binalarda eşit olmayan ısı dağılımı ve etkileri incelenmiştir [10]. Benakopoulos v.d. çalışmalarında, ısıtma tesisatının radyatör sistemlerinin düşük sıcaklıkta çalışmasını sağlanmasında, kullanımda olmayan radyatörleri belirlemek ve daha yüksek ısı taleplerine sahip kritik daireleri tespit etmek için yeni uygulama geliştirmişlerdir. Çalışmada, yetersiz ısınan komşu dairelere olan ısı kaybının artmasının, tesisatı yoğun şekilde etkilediğini ortaya çıkarmıştır [11]. Benakopoulos v.d. diğer bir çalışmasında, her dairedeki tüm radyatörlerinin kullanımını sağlamak için radyatör sisteminin besleme su sıcaklığını en aza indirme potansiyelini araştırmışlardır. Çalışmada, maksimum pompa çalışmasına göre gereken minimum besleme su sıcaklığını hesaplamak için örnek binanın radyatör sisteminin termal/hidrolik bir modeli oluşturulmuştur. Sonuç olarak, 44/30 °C'lik ortalama besleme gidiş ve dönüş sıcaklıklarıyla tüm radyatörlerin kullanıldığında en verimli ısıtma elde edildiği tespit edilmiştir [12]. Lammle v.d. yaptıkları çalışmada, ısı pompası sistemlerinin performansı ile mekân ısıtma su tesisatının sıcaklığı arasında ilişki araştırılmıştır. Sonuç olarak, hava ve yer kaynaklı ısı pompalarının uygulama verileri ve sistem simülasyonları, ortalama ısı pompası sıcaklığı arasında doğrusal bir korelasyon olduğu görülmüştür. İncelenen binada, tüm radyatörlerin yalnızca %7'sinin değiştirilmesi ile ısıtma sistemi su sıcaklıklarını 75/60 °C dan 55/45 °C'ye düşürmek için yeterli olduğu tespit edilmiştir [13]. Li ve Svendsen çalışmalarında Danimarka'da yürütülen bir pilot proje ile 30 müstakil konut için ısıtma sağlamak üzere 55/25 °C sıcaklıklı bölge ısıtma tesisatı analiz edilmiştir. Isıtma ihtiyacı banyoda yerden ısıtma ve diğer odalarda düşük sıcaklıklı radyatörler aracılığıyla karşılanmaktadır. Şebekenin termal ve hidrolik koşulları sabit durumda analizler yapılmıştır. Genel sistem enerjisi ve ekserji verimlilikleri hesaplanmış ve ısıtma sistemi bileşenleri için ekserji kayıpları belirlenmiştir [14]. Liu Z. yaptıkları çalışmada, seçilen bina için tesisat besleme suyu sıcaklığının ve akış hızının ortalama tepki hızı, güneş radyasyonu ve dış sıcaklığı ile değişimi incelenmiştir [15]. Wang v.d. çalışmalarında, farklı hidrolik bağlantılı tesisat dikkate alarak küçük bir ekipman monte edilerek mevcut radyatörün ısıtma gücünü iyileştirmek için optimum ve tekno-ekonomik bir yöntem geliştirilmiştir. Buna bağlı olarak Çin'deki bir yurt odası için bir hesaplamalı akışkanlar dinamiği (CFD) modeli önerilmiştir. Model, radyatörün en düşük besleme su sıcaklığını belirlemek için kullanılmıştır [16]. Ge v.d. çalışmalarında, ısıtma sisteminin giriş su sıcaklığıyla tanımlanan termal dirence dayalı olarak dinamik model geliştirmişleridir. Bu model, eş zamanlı ve kapsamlı bir şekilde, borulamanın ve binanın ısı transferi, ısı depolama ve gecikme özelliklerini yansıtmaktadır. Önerilen model ile tüm gün ısıtma sistemine kıyasla % 25.27'lik büyük bir enerji

tasarrufu potansiyeline sahip olduğu görülmüştür [17]. Liu v.d. yaptıkları çalışmada, sirkülasyon suyu pompalarının değişken frekans kontrolünün kullanımı ve ısıtma yükündeki değişikliklere bağlı çalışma şartları sağlamak için gerekli incelemeler yapılmıştır. Çalışmada, sık meydana gelen su sıcaklığı dalgalanmaları nedeni ile oluşan döngüsel gerilim, yorulma sınırına ulaştığında tesisat boru hattının düşük döngüsel yorulma arızasına yol açtığı görülmüştür. Sonuçta, tesisat boru hattının su çalışma sıcaklığı ne kadar düşükse, sıcaklık farkı dalgalanması o kadar küçük olduğu görülmüştür. Sirkülasyon suyu pompasının değişken akış hızını düzenlerken boru hattı yorulma hasarının katkısının büyük olduğu tespit edilmiştir [18]. Rosa ve Bianco çalışmalarında, sıcak su taşıyan tesisat boru sistemleri için yalıtım katmanlarının optimum kalınlığını belirlemek için farklı optimizasyon yaklaşımlarını araştırmışlardır. Çalışmada, boru boyutu, yalıtım malzemeleri, yakıt, çalışma sıcaklığı, iklim koşulları, yakıt piyasa fiyatı, yalıtım katmanı vb. parametreler dikkate alınarak hesaplamalar yapılmıştır [19].

Çalışmanın amacı, Türkiye'nin dört iklim bölgesini temsilen seçilen; Adana, Ordu, Nevşehir ve Bitlis şehirlerindeki; ayrı bina, ağaçlı bina ve bitişik bina olarak gölgelenme özelliğine sahip binaların merkezi ısıtmalı, ısıtma tesisatı dağıtıcı ve ısıtıcı özelliklerine bağlı enerji tüketimi ile ekserji yükleri ve bunlara bağlı yakıt tüketimlerini hesaplamaktır. Yakıt olarak, doğal gaz, kömür ve fuel-oil kullanıldığı kabul edilmiştir. Isıtma sistemi dağıtıcı ve ısıtıcı özelliği 90-70 ve 70-50 °C sistemli olarak alınmıştır. Isıtma sistemi dağıtıcı ve ısıtıcı özellikleri ve ekserji yüküne bağlı olarak yakıt tüketimi hesaplanmıştır. Bunun için yakıtların kimyasal ekserjileri tespit edilmiştir. Çalışma, ısıtma sisteminin tesisat özelliğine bağlı enerji ve ekserji incelemesiyle yakıt tüketiminin araştırmasıyla literatüre katkı sağlayacaktır. Çalışmada incelenen dağıtıcı ve ısıtıcıların Şekil 1'de görselleri verilmiştir. Binaların ısı yayma sistemi tesisat boru ve radyatörleri içeren tüm ekipmanlar şekilde gösterilmiştir.



Şekil 1. Isı yayma sistemi tesisat boru, radyatör ve kolektör görselleri [9, 10, 15, 16]

Materyal ve Metod

Yıllık Isıtma Enerji İhtiyacı Hesabı

Bina yıllık ısıtma enerjisi ihtiyacı hesaplanırken ısıtma yapılan aylar toplanır [20,21].

$$Q_h = \sum Q_{ay} \quad (1)$$

Isıtma yapılan aylar için ısıtma enerjisi ihtiyacı,

$$Q_{ay} = [H \cdot (T_i - T_d) - \eta_{ay} \cdot (\Phi_{i-ay} - \Phi_{s-ay})] \quad (2)$$

hesaplanır. Burada, T_i ve T_d sırası ile iç ve dış ortam sıcaklıkları, η_{ay} aylık ortalama kazanç kullanım faktörünü, Φ_{i-ay} iç kazanç, Φ_{s-ay} aylık ortalama güneş enerjisi kazançlarını göstermektedir. Toplam özgül ısı kaybı,

$$H = H_T + H_V \quad (3)$$

bulunur. Burada H_T , iletim ve taşınım yoluyla gerçekleşen ısı kaybı ve H_V , havalandırma yoluyla gerçekleşen ısı kaybının göstermektedir. Hem iletim hem de taşınım yoluyla ısı kaybı,

$$H_T = \sum A \cdot U \quad (4)$$

$$\sum A \cdot U = U_d \cdot A_d + U_p \cdot A_p + U_k \cdot A_k + 0.8 U_{ta} \cdot A_{ta} + 0.5 U_{dö} \cdot A_{dö} \quad (5)$$

tespit edilir. Burada, U_d , U_p , U_k , U_{ta} , $U_{dö}$ sırası ile dış duvarın, pencerenin, dış kapının, tavanın, zemine outtran tabanın ısı geçirgenlik katsayısını göstermektedir. A_d , A_p , A_k , A_{ta} , $A_{dö}$ sırası ile dış duvarın, pencerenin, dış kapının, tavanın ve döşemenin alanlarını ifade etmektedir. Havalandırma ile meydana gelen ısı kaybı,

$$H_V = 0.33 \cdot n_h \cdot V_h \quad (6)$$

hesaplanır. Burada, n_h hava değişim oranıdır ve değeri çalışmada 0.7 h^{-1} alınmıştır. Isıtılan tüm hacmi $V_{brüt}$ ve V_h havalandırılan hacmi ($V_h = 0.7 \cdot V_{brüt}$) göstermektedir. A_n bina kullanım alanı;

$$A_n = 0.32 \cdot V_{brüt} \quad (7)$$

bulunur. TS 825 e göre konutlarda iç kazançlar olarak birim kullanım alanı başına 5 W/m² alınmaktadır. İç kazançlar A_n bağlı olarak aşağıdaki denklem ile tespit edilir [20, 21].

$$\Phi_{i-ay} \leq 5 \cdot A_n \quad (8)$$

Aylık ortalama güneş enerjisi kazancı,

$$\Phi_{s-ay} = \sum r_{i-ay} \cdot g_{i-ay} \cdot I_{i-ay} \cdot A_i \quad (9)$$

Burada, “i” yönü göstermektedir. r_{i-ay}, saydam yüzeylerin aylık ortalama gölgeleme faktörünü, g_{i-ay}, güneş enerjisi geçirme faktörünü, I_{i-ay}, aylık ortalama güneş ışınımı ve A_i, pencere alanını göstermektedir. Hem iç kazançlar hem de güneş enerjisi kazançları yararlanma faktörü ile kullanılır. Bu faktör kazançlara ve kayıplara bağlıdır. Kazanç / kayıp oranı,

$$KKO_{ay} = (\Phi_{i-ay} + \Phi_{s-ay}) / H \cdot (T_i - T_{d-ay}) \quad (10)$$

hesaplanır. Aylık ortalama kazanç kullanım faktörü aşağıdaki formül ile bulunur [9,10].

$$\eta_{ay} = 1 - e^{-\left(\frac{1}{KKO_{ay}}\right)} \quad (11)$$

Bina Isı Enerjisi Yayma (Oda Isıtma) Sistemi için Ekserji Hesabı

Isı enerjisi yayılma sistemi, ısının alana yayıldığı bir alan ısıtıcısıdır. Tipik ısıtma yayılma sistemleri radyatörler, yerden ısıtma sistemleri ve fan coil üniteleridir. Isı enerjisi yayılma sistemi, dağıtım sisteminin bir alt sistemidir. Bu nedenle yayılma alt sistemi olarak adlandırılır. Oda ısıtma sisteminin enerji ve ekserji taleplerini karşılayacak şekilde tasarlanmıştır ve radyatörün ısı enerjisi dağıtım sistemine ek enerji talebi meydana gelmektedir [2,4,6]. Farklı yakıtlar ve farklı sıcaklık değerinde ısıtıcıyla (radyatör) ısıtma yapılan bina için verim değeri η_r (çalışmada 0.95 alınmıştır [2,4]). Isı enerjisi yayma (alan ısıtma sistemi) ısıtıcı (radyatör) ısı kaybı,

$$Q_r = Q_h \cdot \left(\frac{1}{\eta_r} - 1\right) \quad (12)$$

hesaplanır. Burada, Q_h bina ısıtma enerjisi ihtiyacıdır. Isıtıcı (radyatör) yüzey sıcaklığı (T_{ısıtıcı}), yayılma sisteminin giriş ve dönüş sıcaklıkları ile iç ortamın logaritmik ortalama sıcaklığı kullanılarak bulunmaktadır. Giriş su sıcaklığı T_{iç} ve dönüş su sıcaklığı T_{dönüş} ekserji analizi için çok önemlidir.

$$T_{ısıtıcı} = \left(\frac{T_{giriş} - T_{dönüş}}{\ln \left(\frac{T_{giriş} - T_{iç}}{T_{dönüş} - T_{iç}} \right)} \cdot \frac{1}{2} \right) + T_{iç} \quad (13)$$

Isıtıcı (radyatör) ekserji yükü.

$$E_{ks-ısıtıcı} = Q_h \cdot \left[1 - \frac{T_{çevre}}{T_{ısıtıcı}} \right] \quad (14)$$

tespit edilir. Isıtıcı (radyatör) için ısı enerjisi yayılma sisteminin ekserji yükü,

$$\Delta E_{ks-yayılma} = \frac{(Q_h + Q_r)}{(T_{giriş} - T_{dönüş})} \cdot \left\{ (T_{giriş} - T_{dönüş}) - T_0 \cdot \ln \left(\frac{T_{giriş}}{T_{dönüş}} \right) \right\} \quad (15)$$

$$E_{ks-Tüm yayılma} = E_{ks-ısıtıcı} + \Delta E_{ks-yayılma} \quad (16)$$

bulunur. Dağıtım sisteminin ısı kaybı (η_D, çalışmada dağıtım sistemi verimi 0.96 alınmıştır [2,4]),

$$Q_{Dkayıp} = (Q_h + Q_r) \cdot \left(\frac{1}{\eta_D} - 1 \right) \quad (17)$$

hesaplanır. Dağıtım sisteminin ekserji yükü;

$$\Delta E_{ks-dag} = \frac{Q_{Dkayıp}}{\Delta T_{dag}} \cdot \left\{ T_{dag} - T_0 \cdot \ln \left(\frac{T_{dag}}{T_{dag} - \Delta T_{dag}} \right) \right\} \quad (18)$$

$$E_{ks-Tüm dag} = E_{ks-ısıtıcı} + \Delta E_{ks-dag} \quad (19)$$

tespit edilir. Burada T_{dag} ısıtma sistemi dağıtıcı sıcaklığıdır.

Bina Isıtma Enerjisi Yayma (Oda Isıtma) Sistemi için Ekserji Yüküne Bağlı Yakıt Tüketimi

Kömür için kimyasal ekserji [22-25],

$$\gamma_{Y_K} \cong 1.0438 + 0.0158 \frac{H}{C} + 0.0813 \frac{O}{C} + 0.0471 \frac{N}{C} \quad (20)$$

Fuel-oil için kimyasal ekserji,

$$\gamma_{Y_S} \cong 1.0374 + 0.0159 \frac{H}{C} + 0.0567 \frac{O}{C} + 0.05985 \frac{S}{C} (1 - 0.1737 \frac{H}{C}) \quad (21)$$

Doğal gaz için kimyasal ekserji,

$$\gamma_{Y_G} \cong 1.0334 + 0.0183 \frac{H}{C} - 0.0694 \frac{1}{C} \quad (22)$$

hesaplanır. Ekserji kaybına bağlı yıllık yakıt tüketimi [7],

$$Y_{Ekskayıp} = \frac{E_{ks-Tüm yayılma} + E_{ks-Tüm Dag}}{\eta_{Y \cdot H_u}} \quad (23)$$

bulunur. Burada, H_u yakıtın alt ısıl değerini, η ısıtma sistemi verimini, γ_Y yakıtın kimyasal ekserji değerini göstermektedir.

Bina Enerji İhtiyacı Hesaplamalarında Kullanılan Parametreler

Hesaplamalarda kullanılan örnek binanın, Tablo 1 de tüm yapı kabuğu bileşenlerinin kalınlıkları ve ısı iletim katsayıları verilmiştir. Tablo 2’de yapı kabuğu için yalıtım kalınlıkları gösterilmiştir. Enerji ihtiyacı, yakıt tüketimi ve ekserji yükü hesaplarında kullanılan tüm değerler Tablo 3 de verilmiştir.

Tablo 1. Örnek binanın yapı kabuğu bileşenleri ve özellikleri [21]

Yapı Bileşeni	Eleman	Kalınlık (m)	Isı İletim Katsayısı (W/m.K)
Dış Duvar	Çimento harcı dış sıva	0.030	1.600
	Poliüretan sert köpük	x	0.031
	Düşey delikli tuğla	0.190	0.330
	Alçı harcı iç sıva	0.020	0.700
Kolon	Çimento harcı dış sıva	0.030	1.600
	Poliüretan sert köpük	x	0.031
	Donatılı Beton	0.250	2.500
	Alçı harcı iç sıva	0.020	0.700
Tavan	Cam Yünü	x	0.040
	Genleştirilmiş perlit	0.050	0.350
	Hafif agregalar kullanılarak yapılmış beton	0.250	0.460
	Alçı harcı, kireçli alçı harcı	0.020	0.700
Taban	Sentetik malzemeden kaplamalar	0.010	0.230
	Çimento harcı sıva	0.030	1.600
	Poliüretan sert köpük	x	0.040
	Genleştirilmiş perlit	0.070	0.350
	Hafif agregalar kullanılarak yapılmış beton	0.250	0.460
	Alçı harcı iç sıva	0.020	0.700
Pencere	Çift camlı		1.9 (W/m ² . K)
Dış Kapı			4 (W/m ² . K)

Tablo 2. Dört iklim bölgesini temsilen seçilen şehirlerin yapı kabuğunun farklı yalıtım malzemelerine bağlı yalıtım kalınlıkları

Bölge	Yapı Elemanı	Yalıtım Malzemesi	Yalıtım Kalınlığı
1.Bölge (Adana)	Dış Duvar	Poliüretan sert köpük	0.060
2.Bölge (Ordu)			0.080
3.Bölge (Nevşehir)			0.095
4.Bölge (Bitlis)			0.110
1.Bölge (Adana)	Kolon-Kiriş	Poliüretan sert köpük	0.075
2.Bölge (Ordu)			0.095
3.Bölge (Nevşehir)			0.110
4.Bölge (Bitlis)			0.120
1.Bölge (Adana)	Tavan	Cam Yünü	0.110
2.Bölge (Ordu)			0.150
3.Bölge (Nevşehir)			0.170
4.Bölge (Bitlis)			0.200
1.Bölge (Adana)	Taban/Döşeme	Poliüretan sert köpük	0.100
2.Bölge (Ordu)			0.140
3.Bölge (Nevşehir)			0.160
4.Bölge (Bitlis)			0.190

Tablo 3. Farklı yakıtların özellikleri [22-24] [26]

Parametre	Kömür	Doğal Gaz	Fuel-Oil
Kimyasal Formül	C _{7.074} H _{5.149} O _{0.521} S _{0.01} N _{0.086}	C _{1.269} H _{4.516} O _{0.024} N _{0.012}	C _{7.3125} H _{10.407} O _{0.04} S _{0.026} N _{0.02}
Alt Isıl Değer Verim	29.295 10 ⁶ J/kg	34.526 10 ⁶ J/m ³	40.594 10 ⁶ J/kg
Yoğunluk (kg/m ³)	1200	0.76	950
Kimyasal Ekserji (Çalışmada Hesaplanan)	1.06	1.04	1.07

Bulgular ve Tartışma


Çalışmada, birinci iklim bölgesini temsilen seçilen Adana şehri için ocak, şubat, mart, kasım ve aralık aylarında beş aylık ısıtma döneminde dış ortam sıcaklığı 10.3 °C, ikinci iklim bölgesini temsilen seçilen Ordu şehri için ocak, şubat, mart, nisan, ekim, kasım ve aralık aylarında yedi aylık ısıtma döneminde dış ortam sıcaklığı 7.7 °C, üçüncü iklim bölgesini temsilen seçilen Nevşehir şehri için ocak, şubat, mart, nisan, mayıs, ekim, kasım ve aralık aylarında sekiz aylık ısıtma döneminde dış ortam sıcaklığı 5.9 °C ve dördüncü iklim bölgesini temsilen seçilen Bitlis şehri için ocak, şubat, mart, nisan, mayıs, ekim, kasım ve aralık aylarında sekiz aylık ısıtma döneminde dış ortam sıcaklığı 2.7 °C kabul edilmiştir. Bu değerler Şekil 2 de verilmiştir. Birinci bölgeden dördüncü bölgeye ilerledikçe dış ortam sıcaklığı azalmaktadır. Dış ortam sıcaklık değerleri ekserji yükü hesaplarında en önemli parametrelerdendir. Ekserji yükü hesapları için çalışmada, ölü hal sıcaklığı Adana şehri için 10.3 °C, Ordu şehri için 7.7 °C, Nevşehir şehri için 5.9 °C ve Bitlis şehri için 2.7 °C kabul edilmiştir.

Çalışmada, farklı gölgelenme özelliğine (gölgelenme faktörü) göre ayrıık bina, ağaçlı bina ve bitişik bina olarak üç farklı sınıfta değerlendirilmiştir. Ayrıık bina özelliğine göre farklı iklim bölgesindeki şehirler için 13761-50874 kWh, ağaçlı bina özelliğine göre 15346-53754 kWh ve bitişik bina özelliğine göre 16064-55316 kWh arasında değişmektedir. Bu değerler Şekil 3 de gösterilmiştir. Ortalama gölgelenme faktörü değeri, ayrıık bina için 0.8, ağaçla kaplı bina 0.6 ve bitişik bina için 0.5 dir [TS 825]. Bu nedenle gölgelenme faktörü önemli parametredir. Diğer önemli bir parametreler ise güneş radyasyonu değeridir.

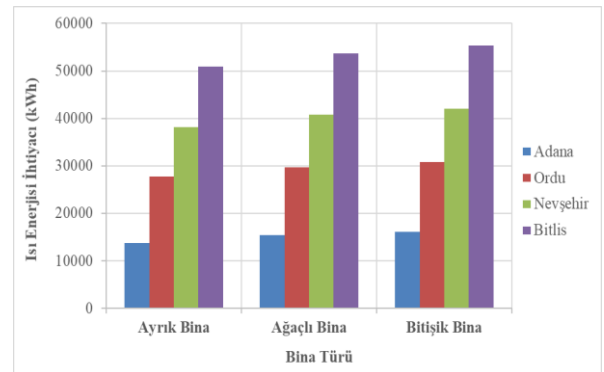
Çalışmada, ısıtma sistemi doğal gaz, kömür ve fuel-oil yakıt olarak kullanıldığı kabul edilmiştir. Isıtma sisteminde sıcak su sirkülasyon sıcaklığı 90-70 ve 70-50 °C olarak düşünülmüştür. Ekserji yükü değeri, tüm gölgelenme özelliklerine göre doğal gaz için, 90-70 ve 70-50 °C sıcaklık özelliğine göre; 3467.8-20135.0 kWh, kömür için 4417.3-25611.3 kWh, fuel-oil için 3825.6-22181.7 kWh arasında hesaplanmıştır. Bu ve diğer tüm ekserji yükü değerleri binaların gölgelenme özelliğine göre Şekil 4 te verilmiştir. 90-70 °C sıcaklıktaki ısıtma sistemi dağıtıcı ve ısıtıcı özelliği için daha yüksek enerji ihtiyacı ve ekserji yükü meydana gelmektedir. Çalışmada, T_{ısıtıcı} değeri 90-70 °C

ısıtma sistemi dağıtıcı özelliği için 49.222 °C ve 70-50 °C için 39.080 °C hesaplanmıştır.


Çalışmada, ayrıık bina, ağaçlı bina ve bitişik bina özelliğine bağlı olarak ısıtma dönemi için doğal gaz tüketimi 1212.1-4872.4 kg, fuel-oil tüketimi 1526.0- 6134.3 kg, kömür tüketimi 3036.4- 12205.8 kg arasında hesaplanmıştır. Bu ve diğer tüm yakıtların tüketim miktarları Tablo 4 te gösterilmiştir. Aynı özelliklerine göre ekserji yüküne bağlı olarak yakıt tüketimi, 90-70 ve 70-50 °C sıcaklık için doğal gaz tüketimi 293.7-1705.4 kg, kömür tüketimi 917.8-5321.3 kg ve fuel-oil tüketimi 396.5-2298.9 kg arasında hesaplanmıştır. Bu ve diğer yakıt miktarları Tablo 5 de verilmiştir. Ekserji yüküne bağlı yakıt tüketimi, binaların gölgelenme özelliği, yakıtların kimyasal ekserjisi (doğal gaz için 1.04, kömür için 1.6 ve fuel-oil için 1.07), yakıtların alt ısıl değeri ile ısıl verimleri ve dış ortam sıcaklıklarına bağlı olarak değişmektedir.




Şekil 2. Farklı iklim bölgelerindeki şehirlerin ısıtma yapılan dönem için aylık dış ortam sıcaklık değerleri




Şekil 3. Farklı iklim bölgelerindeki şehirler için bina ısıtma enerji ihtiyacı



(a)



(c)



(b)

Şekil 4. Farklı iklim bölgelerindeki şehirler için a) Ayrık Bina, b) Ağaçlı Bina, c) Bitişik Bina tipine göre ekserji yükü

Tablo 4. Farklı iklim bölgeleri bina türleri ve ısıtma sistemi için enerji ihtiyacına (enerji yüküne) göre farklı yakıtların tüketim miktarları (kg)

Şehir	Kömür			Fuel-oil			Doğal gaz		
	Ayrık Bina	Ağaçlı Bina	Bitişik Bina	Ayrık Bina	Ağaçlı Bina	Bitişik Bina	Ayrık Bina	Ağaçlı Bina	Bitişik Bina
Adana	3036.4	3386.2	3544.6	1526.0	1701.8	1781.4	1212.1	1351.7	1415.0
Ordu	6123.0	6545.7	6786.5	3077.3	3289.7	3410.7	2444.2	2613.0	2709.1
Nevşehir	8433.4	8989.9	9284.7	4238.5	4518.1	4666.3	3366.6	3588.7	3706.4
Bitlis	11225.6	11861.1	12205.8	5641.7	5961.1	6134.3	4481.2	4734.9	4872.4

Tablo 5. Farklı iklim bölgeleri, bina türleri ve ısıtma sistemi için ekserji yüküne bağlı farklı yakıtların tüketim miktarları (kg)

Şehir	Ayrık Bina					
	Doğal Gaz (90-70)	Doğal Gaz (70-50)	Kömür (90-70)	Kömür (70-50)	Fuel-oil (90-70)	Fuel-oil (70-50)
Adana	393.9	293.7	1203.7	917.8	524.8	396.5
Ordu	808.5	632.2	2513.8	1966.0	1090.0	851.3
Nevşehir	1145.9	906.4	3565.6	2811.1	1544.9	1220.0
Bitlis	1568.4	1249.6	4894.0	3900.4	2114.3	1687.2
Ağaçlı Bina						
Adana	439.3	327.5	1342.4	1023.5	585.3	442.2
Ordu	864.3	675.9	2687.3	2101.8	1165.2	910.1
Nevşehir	1221.5	966.2	3800.8	2996.6	1646.8	1300.5
Bitlis	1657.2	1320.3	5171.1	4121.2	2234.0	1782.8
Bitişik Bina						
Adana	459.9	342.9	1405.2	1071.4	612.7	462.8
Ordu	896.1	700.7	2786.2	2179.1	1208.1	943.5
Nevşehir	1261.6	997.9	3925.5	3094.9	1700.8	1343.2
Bitlis	1705.4	1358.7	5321.3	4241.0	2298.9	1834.6

Sonuç

Adanadan Bitlis'e doğru gidildikçe, yani birinci iklim bölgesinden dördüncü iklim bölgesine gidildikçe enerji tüketimi artmaktadır. Bina gölgelenme durumu dikkate alındığında, ayrı bina en az enerji tüketimi, ağaçlı binalı ortalama enerji tüketimi ve bitişik binalarda en fazla enerji tüketimi meydana gelmektedir. Buna bağlı olarak tüm yakıtlar için tüketim miktarı en düşük ayrı bina ve en yüksek bitişik binada tespit edilmiştir. Enerji ihtiyacına bağlı yakıt tüketimi, en yüksek 12205.8 kg ile bitişik bina özelliğinde kömürde ve en düşük ise 1212.1 kg ile ayrı bina özelliğinde doğal gazda meydana gelmiştir. Kömür tüketimi en fazla iken doğal gaz tüketimi en az seviyede olduğu görülmüştür. Ekserji yüküne bağlı, ısıtma tesisatı dağıtım ve ısıtıcı özelliği bağlı olarak 90-70 °C sıcaklıktaki dağıtım sistemi yüksek ve 70-50 °C sıcaklıktaki düşük enerji ihtiyacı, ekserji yükü ve yakıt tüketimleri meydana geldiği hesaplanmıştır. En düşük 70-50 °C sıcaklıktaki tesisat dağıtım sistemi ve ayrı bina için 293.7 kg ile doğal gaz tüketimi, en yüksek ise 90-70 °C sıcaklıktaki tesisat dağıtım sistemi ve bitişik bina için 5321.3 kg ile kömür tüketimi hesaplanmıştır.

Sonuç olarak, enerji ihtiyacı, ekserji yüküne ve yakıt tüketimine bağlı olarak 70-50 °C sıcaklıktaki ısıtma tesisatı dağıtım sistemi ve gölgelenme özelliği olarak ayrı bina için en düşük seviyede hesaplandığından en uygun bina özelliği olduğu tespit edilmiştir.

Kaynaklar

- [1] A. Kılıçlı, "Ege Üniversitesi bünyesindeki mevcut bir binanın enerji-ekserji analizi ve iyileştirme önerileri", Doktora Tezi, Ege Üniversitesi Fen Bilimleri Enstitüsü, Güneş Enerjisi Anabilim Dalı, İzmir, Türkiye, 2018.
- [2] A. Yıldız and A. Güngör, "Energy and exergy analyses of space heating in buildings", *Applied Energy*, vol. 86, pp. 1939–1948, 2009.
<https://doi.org/10.1016/j.apenergy.2008.12.010>
- [3] E. Yıldırım, "Bina dış duvar yalıtımının enerji ve ekserji analizi yöntemiyle optimize edilmesi", Yüksek Lisans Tezi, Ege Üniversitesi Fen Bilimleri Enstitüsü, Güneş Enerjisi Anabilim Dalı, İzmir, Türkiye, 2015.
- [4] A. Hepbaşlı, H. G. Özcan, H. Günerhan ve N. Yıldırım, "Binaların ekserji bazlı termodinamik analizleri ve değerlendirmeleri", *14. Ulusal Tesisat Mühendisliği Kongresi*, İzmir, Türkiye, 17-20 Nisan 2019.
- [5] E. Karakaşlı, "Değişik iklim bölgelerindeki binaların performansının ekserjetik açıdan değerlendirilmesi", Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Makine Eğitimi Anabilim Dalı, Elazığ, Türkiye, 2012.
- [6] M. T. Balta, Y. Kalıncı and A Hepbaşlı. "Evaluating a low exergy heating system from the power plant through the heat pump to the building envelope", *Energy and Buildings*,

40, pp1799–1804, 2008.

<https://doi.org/10.1016/j.enbuild.2008.03.008>

[7] G. Özel, E. Açıkcalp, T. H. Karakoç, A. Hepbaşlı, "Novel method for determining optimum insulation thickness of a piping system", *1th International Conference on Energy (ICOE 2014) Colombo*, Sri Lanka, 2014.

[8] M. Shukuya, "Exergetic approach to the understanding of built environment—state-of-the-art review", *Japan Architectural Review*, pp. 1–10, 2019.
<https://doi.org/10.1002/2475-8876.12082>

[9] M. A. Omar, "Comparison of central and individual heating systems used for heating housings", *Türk Doğa ve Fen Dergisi*, vol. 12, no 2, pp 8-16, 2023.
<https://doi.org/10.46810/tdfd.1235610>

[10] Q. Yang, R. Salenbien, K. M. Smith, M. Tunzi, "Identifying untraced faults associated with high return temperatures from heating systems in buildings connected to district heating networks", *Energy*, Vol 309, 133097, 2024. <https://doi.org/10.1016/j.energy.2024.133097>

[11] T. Benakopoulos, M. Tunzi, R. Salenbien, K. K. Hansen, S. Svendsen, "Implementation of a strategy for low-temperature operation of radiator systems using data from existing digital heat cost allocators", *Energy*, Vol 251, 123844, 2022.
<https://doi.org/10.1016/j.energy.2022.123844>

[12] T. Benakopoulos, M. Tunzi, R. Salenbien, S. Svendsen, "Strategy for low-temperature operation of radiator systems using data from existing digital heat cost allocators", *Energy*, Vol 231, 120928, 2021.
<https://doi.org/10.1016/j.energy.2021.120928>

[13] M. Lammle, C. Bongs, J. Wapler, D. Günther, S. Hess, M. Kropp, S. Herkel, "Performance of air and ground source heat pumps retrofitted to radiator heating systems and measures to reduce space heating temperatures in existing buildings", *Energy*, Vol 242, 122952, 2022.
<https://doi.org/10.1016/j.energy.2021.122952>

[14] H. Li, S. Svendsen, "Energy and exergy analysis of low temperature district heating network", *Energy*, Vol 45, no 1, pp237-246, 2012.
<https://doi.org/10.1016/j.energy.2012.03.056>

[15] Z. Liu, H. Zhang, Y. Wang, S. You, T. Dai, Y. Jiang, "Evaluation of the controllability of multi-family building with radiator heating systems: A frequency domain approach", *Energy*, Vol 294, 130895, 2024.
<https://doi.org/10.1016/j.energy.2024.130895>

[16] H. Wang, Y. Zhou, X. Li, X. Wu, H. Wang, A. Elnaz, K. Granlund, R. Lahdelma, E. Teppo, "Study on the performance of a forced convection low temperature radiator for district heating", *Energy* Vol 283, 129036, 2023. <https://doi.org/10.1016/j.energy.2023.129036>

[17] Z. Ge, W. Fang, S. Wang, J. Hao, Y. Yang, L. Tian, J. Sun, F. Dong, "Dynamic modeling and intelligent heating strategies of district heating system based on the standardized thermal resistance", *Applied Thermal Engineering*, vol 222, 119919, 2023.
<https://doi.org/10.1016/j.applthermaleng.2022.119919>

- [18] F. Liu, C. Song, W. Pan, G. Wang, H. Zhang, Y. Lei, "Thermal fatigue analysis of district heating pipeline under variable frequency regulation of circulating water pump", *Applied Thermal Engineering*, Vol 242, 122535. 2024. <https://doi.org/10.1016/j.applthermaleng.2024.122535>
- [19] M. D. Rosa, V. Bianco, "Optimal insulation layer for heated water pipes under technical, economic and carbon emission constraints", *Energy*, Vol 270, 126961, 2023. <https://doi.org/10.1016/j.energy.2023.126961>
- [20] O. Kon ve K. Sandal, "Binaların Dış Duvarlarının Yüzey Özelliklerine Bağlı Enerji Tüketim Analizleri ve Sıcaklık Sönüm Faktörü, Binaların Dış Duvarlarının Yüzey Özelliklerine Bağlı Enerji Tüketimi", *Journal of Innovations in Civil Engineering and Technology (JICIVILTECH)*, vol. 5, no:2, sayfa: 49-69, 2023. <https://doi.org/10.60093/jiciviltech.1381812>
- [21] *Binalarda Isı Yalıtım Kuralları*, TS 825, Standart 2008.
- [22] O. Kon ve B. Yüksel, "Kazanlarda yakıt ve yanma havasına bağlı yanma gazlarının özelliklerindeki değişim", *13. Uluslararası Yanma Sempozyumu*, Bursa/Türkiye, 9-11 Eylül 2015.
- [23] D. B. Özkan and C. Onan, "Optimum of insulation thickness for different glazing areas in buildings for various climatic regions in Turkey", *Applied Energy*, vol. 88, no. 4, pp.1311-1342,2011. <https://doi.org/10.1016/j.apenergy.2010.10.025>

[24] H. Aydın, "Ticari uçakların ekserjetik sürdürülebilirlik indikatörlerinin geliştirilmesi", Doktora Tezi, Anadolu Üniversitesi Fen Bilimleri Enstitüsü Sivil Havacılık Anabilim Dalı, Eskişehir, Türkiye, 2012.

[25] Y. A. Çengel, "Isı ve kütle transferi pratik bir yaklaşım", Palme Yayıncılık, Ankara, Türkiye, 2011.

[26] ISISAN Yayınları, "Doğal Gaz-LPG Tesisatı ve Bacalar", No: 345.

Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur.

Çıkar taşması beyanı

Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

Yazar Katkısı

Kon O., çalışma konsepti ve tasarım, literatür, hesaplamalar, analiz, yazım, yorum ve diğer katkılar tarafından yapılmıştır.



Türkiye'nin Farklı Derece Gün Bölgelerinde Isı Pompası Kullanıldığında Optimum Yalıtım Kalınlığının Belirlenmesi ve Ekonomik Analizi

Determination of Optimum Insulation Thickness and Economic Analysis for Heat Pump Application in Different Degree Day Regions of Turkey

Atilla G. Devcioğlu^{1*}, Uğur Yaman², Vedat Oruç³

¹Dicle Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü, Diyarbakır, Türkiye, atillad@dicle.edu.tr
ORCID: <https://orcid.org/0000-0001-9174-378X>

²Dicle Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü, Diyarbakır, Türkiye,
ugur.yaman@dicle.edu.tr ORCID: <https://orcid.org/0009-0009-6625-1025>

³Dicle Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü, Diyarbakır, Türkiye, voruc@dicle.edu.tr
ORCID: <https://orcid.org/0000-0001-9055-1508>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 10 Eylül 2024
Revizyon 25 Eylül 2024
Kabul 5 Ekim 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

*Isı pompası; Isıtma derece-gün;
optimum izolasyon kalınlığı*

ÖZ

Isı pompası ile ısıtma yapılması durumunda, Türkiye'nin farklı ısıtma derece gün değerlerine sahip illerindeki binaların dış duvarları için optimum yalıtım kalınlıkları belirlenmiştir. TS 825 göre birinci, ikinci ve üçüncü derece gün bölgesinde bulunan Aydın, Diyarbakır ve Nevşehir illeri için, yakıt olarak elektrik (ısı pompası) ve doğalgaz kullanılması, yalıtım malzemesi olarak ekstrüde polistiren (XPS) ve taş yünü kullanılması durumunda optimum yalıtım kalınlıkları belirlenmiştir. Sonuçlarda, ısı pompası ve taş yünü kullanılması durumunda sırasıyla Aydın, Diyarbakır ve Nevşehir için optimum yalıtım kalınlıkları 0.022, 0.036 ve 0.047 m tespit edilmiştir. Bu değerler doğal gaz kullanılması durumuna göre %22-%29 oranında azalma göstermiştir.

ARTICLE INFO

Article history:

Received 10 September 2024
Received in revised form 25 September 2024
Accepted 5 October 2024
Available online 23 December 2024

Keywords:

*Heat pump; Heating degree-days;
Optimal insulation thickness*

ABSTRACT

In case of heating with a heat pump, optimum insulation thicknesses were determined for external walls of buildings in provinces of Turkey with different heating degree day values. For Aydın, Diyarbakır and Nevşehir provinces located in the first, second and third degree day zones according to TS 825, optimum insulation thicknesses were determined when electricity (heat pump) and natural gas were used as fuels, and extruded polystyrene (XPS) and rock wool were used as insulation materials. In the results, optimum insulation thicknesses were determined as 0.022, 0.036 and 0.047 m for Aydın, Diyarbakır and Nevşehir, respectively for the case of using-heat pump and rock wool use. These values decreased by 22%-29% compared to the case of using natural gas.

Doi: 10.24012/dumf.1547522

* Sorumlu Yazar

Giriş

Dış duvarların yalıtımı, enerji tüketimini ve dolayısıyla karbon emisyonlarını azaltmada büyük bir potansiyele sahiptir. Dış duvarlar için optimum yalıtım kalınlığının belirlenmesi standardı olmadığı için yapı sektöründe yalıtım kalınlığı tespiti TS 825'e göre yapılmaktadır.

Avrupa Birliği (AB) binalarda enerji tüketiminin azaltılması için tüm yeni binaların 2030 yılına kadar sıfır emisyonlu olması, bina dış kabuğunun iyi yalıtımlı olması ve yalnızca yenilenebilir enerji kaynaklarından elektrik kullanması ve kullanımından kaynaklanan karbon emisyonlarının 2030'dan itibaren hesaplanması gerektiğini bildirmiştir [1]. AB Enerji Verimliliği Direktifi, üye ülkelerin, 2024'ten 2030'a kadar ortalama yıllık enerji tasarrufu oranını mevcut %0.8'den %1.49'a çıkarmak zorunda olduğunu söylemektedir [2].

Binalar küresel enerji tüketiminin %20'sini ve binaların inşası ve işletilmesi için küresel elektriğin %50'sini tükettiği görülmektedir [3].

Mühendislik hesaplamalarında yapılarda enerjinin etkin kullanılması elzemdir. Farklı duvar profilleri için yapılan çalışmada betonpan ve demir profille örülmüş duvarın tuğla duvardan %37.5 daha fazla enerji tasarrufu sağladığı sonucuna varılmıştır. Demir profilli binalar enerji tasarrufu açısından avantajlı fakat yoğunlaşma açısından dezavantajlıdır [4]. Yapılarda enerjinin etkin kullanılması için en önemli uygulama ısı yalıtımdır. Binaların dış kabuğuna ve çatısına ısı yalıtımı uygulanması enerjinin verimliliği açısından önemli olduğu gibi emisyonların azaltılması, ısı konfor ve enerji tüketimine bağlı işletme giderlerinin minimize edilmesi açısından çok önemlidir [5]. TS 825 Isı Yalıtım Standartları'nın tüm binalara uygulanmasıyla Türkiye'de birim alan başına enerji tüketiminin 100–150 kWh/ m²'ye indirilebileceği belirtilmiştir [6].

Daha önceki çalışmalarda, binalarda ısı yalıtımının enerji, ekonomik ve çevresel performansı ile ilgili incelemeler yapılmıştır.

İtalya'da düşük dereceli günlere sahip iklim bölgelerinde, kaplamanın soğutma ihtiyaçları üzerindeki olumsuz etkisi incelenmiştir. Tüm iklim bölgelerinde, soğutma ihtiyacı en sıcak aylarda azalırken, kaplama nedeniyle dağıtılmayan ek

termal yük ılıman aylarda artmaktadır. Sonuç olarak, binanın toplam enerji ihtiyaçlarına dayanarak farklı İtalyan iklim bölgeleri için optimum yalıtım kalınlıkları belirlenmiştir [7]. ASHRAE standardı kullanılarak soğutma derece gün (CDD) ve ısıtma derece gün (HDD)'ye dayalı belirlenen optimum yalıtım kalınlıkları, Birleşik Krallık Meteoroloji Ofisi ve saatlik yöntemler kullanılarak elde edilen kalınlıklara kıyasla ortalama %14 oranında düşük tahmin edilmiştir. Elde edilen sonuçlar, iklimin karasallaşmasıyla birlikte, Yaşan Döngüsü Maliyet Analiz (LCCA) yöntemi kullanılarak bina dış duvar optimum yalıtım kalınlığını belirlemek için derece günlerini hesaplamak için başka bir yöntemi doğru şekilde kullanmanın önemli hale geldiğini göstermiştir [8].

Arnavutluk'taki binalar üzerine yapılan çalışma toplam ısı transfer değerinin 0.30 W/m²K eşit veya daha az olması gerektiğini, bu da binaların 0.03 ila 0.11 m aralığında optimize edilmiş yalıtım kalınlığına ihtiyacı olduğunu göstermektedir. Yenilenmemiş binalarla, yıllık 23.50 – 84.50 €/m² net tasarruf, 39.10 kgCO₂/m²'ye kadar CO₂ azaltımı ve maksimum 0.30 ila 1.20 yıla kadar basit geri ödeme süresine ihtiyaç olacağı belirlenmiştir [9].

İngiliz konut stoğunun optimize edilmiş duvar yalıtım kalınlığını belirlemek için yapılan çalışmada, optimize edilmiş cam yünü yalıtım kalınlığının 0.010 m ile 0.275 m arasında olduğu belirtilmiştir. Duvar yalıtım kalınlığını arttırmanın olumsuz etkilere yol açacağı ortaya konulmuştur. Stok seviyesinde tüm yaşam enerji tüketiminin azaltılmasına ilişkin fazla tahmini %20.5 ile %26.7 arasında değişmektedir [10].

Elâzığ ili için yalıtım kalınlığının 10 yıllık zaman diliminde bugünkü net değer faktörüyle hesaplama yapılmış ve optimum yalıtım kalınlıklarıyla beraber enerji tasarrufları ve geri ödeme süreleri hesaplanmıştır [11]. Kürekçi ve arkadaşları [12], çalışmalarında derece gün değerleri kullanarak ekonomik analiz yöntemiyle Türkiye'de bulunan 81 ilde 2 farklı yakıt ve 5 farklı ısı yalıtım malzemesi için optimum yalıtım kalınlığı ve buna bağlı enerji tasarrufları ve ekonomik geri ödeme sürelerini hesaplamışlardır. Isı yalıtımı binalarda enerji performansının arttırılmasında kullanılan en etkin ve basit çözümlerden biridir. Isı yalıtımı ile enerji performansının arttırılmasının yanı sıra fosil yakıt

kaynaklı çevresel emisyonlarda ciddi oranda azaltılabilmektedir. Özellikle soğuk iklim bölgelerinde ısı yalıtımı ısıtma amaçlı enerji tüketiminde ve buna bağlı çevresel emisyonlarda ciddi tasarruf sağlamaktadır [13]. Bu çalışmada, Türkiye'nin 1., 2. ve 3. derece gün bölgesinde bulunan Aydın, Diyarbakır ve Nevşehir illerindeki binaları ısıtmak amacıyla doğalgaz yakıtı ve ısı pompası kullanılması dikkate alınarak ekstrüde polistiren köpük (XPS) ve taş yünü yalıtım malzemeleri için analizler gerçekleştirilmiştir. Bu çalışmanın özgün yanı üç farklı iklim bölgesinde bulunan illerde bina dış duvarları için optimum yalıtım kalınlığının belirlenmesi ve ekonomik analiz yapılarak geri ödeme sürelerinin hesaplanmasıdır.

1. Materyal ve Metot

Bu çalışmada üç farklı iklim bölgesinde bulunan Aydın, Diyarbakır ve Nevşehir illerine ait ısıtma derece gün (HDD) değerleri için yalıtım malzemesi olarak XPS ve taş yünü, yakıt olarak doğal gaz ve ısı pompası için elektrik seçilerek optimum yalıtım kalınlıkları hesaplanmıştır.

Denge sıcaklığı, iç ortamın ısıtılmasına gerek duyulmayan sıcaklıktır. HDD belirlenirken dış ortam sıcaklığı ile denge sıcaklığı dikkate alınır [13].

Eğer, $T_0 < T_b$ ise;


$$HDD = \sum_{j=0}^N (T_b - T_0) \quad (1)$$

Eğer, $T_b < T_0$ ise;

$$HDD=0 \quad (2)$$

Burada T_b denge sıcaklığıdır, T_0 bir meteoroloji istasyonunda kaydedilen günlük ortalama dış hava sıcaklığıdır, N bir ısıtma sezonunda $T_0 < T_b$ olması koşuluyla gün sayısıdır. Bu nedenle ısıtma derece-gün değerleri $T_0 < T_b$ olarak hesaplanır. Türkiye, TS 825'in belirlediği ısıtma derece-gün sayılarına göre dört iklim bölgesine ayrılmıştır. 1. Bölge ısınma için en az enerji ihtiyacı olan bölgeyi, 4. Bölge ise en soğuk dolayısıyla ısıtma için enerjiye en çok ihtiyaç duyulan bölgeyi temsil etmektedir. Soğutma uygulamaları için de benzer şekilde derece-gün değerleri hesaplanabilir [14,15]. Bu çalışmadaki seçilen iller için

ısıtma derece-gün değerleri Tablo 1'de [16] ve bu illerin fiziki konumları Şekil 1'de verilmiştir.



Şekil 1. TSE 825'e göre 3 bölgede bulunan şehirler

Tablo 1. HDD değerleri [16]

Şehirler	HDD
Aydın	1213
Diyarbakır	2142
Nevşehir	3033

2. Optimum Yalıtım Kalınlığı ve Ekonomik Geri Ödeme Süreleri

2.1. Optimum Yalıtım Kalınlığı

Isı daima sıcak olan bölgeden soğuk olan bölgeye geçer. Dış hava sıcaklığının iç hava sıcaklığından küçük olduğu zamanlarda bina dış kabuğundan ısı kayıpları gerçekleşir. Dış duvarın birim yüzey alanı başına kaybedilen ısı miktarı (Q) aşağıdaki gibi elde edilir [17]

$$Q = U \times (T_i - T_0) \quad (3)$$

Burada U duvarın toplam ısı transfer katsayısı (W/m^2K), T_i iç hava sıcaklığı ve T_0 dış hava sıcaklığıdır. Bir yalıtım katmanı içeren dış duvarın toplam ısı transfer katsayısı (U) denklem (4)'de verilmektedir [18]

$$U = \frac{1}{R_i + R_w + R_{ins} + R_o} \quad (4)$$


$$R_{ins} = \frac{x_{ins}}{k_{ins}} \quad (5)$$

burada R_i ve R_o sırasıyla iç ve dış ortamın taşınım ısı direncini göstermekte olup değerleri $0.13 \text{ m}^2K/W$ ve 0.04

m^2K/W 'dir. R_w yalıtımsız duvarın ısı direncini, x ve k sırasıyla yalıtım malzemesinin kalınlığını ve ısı iletkenlik katsayısını göstermektedir. Yalıtımsız duvarın toplam direnci ($R_{w,t}$) denklem (6) yardımıyla belirlenmiş olup, Şekil 2' de verilen kompozit duvarın, malzemelerinin fiziksel ve termal özellikleri Tablo 2 ve Tablo 3'de sunulmuştur [19,20].

Tablo 2. Yalıtım Malzemelerinin Özellikleri [19,20]

	XPS	Cam Yünü
k (W/mK)	0.031	0.04
C_y (\$/m ³)	180	80
d (kg/m ³)	28	24



Şekil 2. Kompozit duvar

Tablo 3. Kompozit Duvar Bileşenlerinin Değerleri [20]

Duvar bileşenleri	Kalınlık (m)	k (W/mK)	R (m ² K/W)
İç Sıva	0.02	0.087	0.230
Tuğla	0.13	0.45	0.289
Diş Sıva	0.03	1.4	0.021
R_o			0.040
R_i			0.130
$R_{w,t}$			0.503

$$R_{w,t} = R_i + R_w + R_o \quad (6)$$

HDD değerleri kullanarak birim yüzey alanı için yıllık ısı kaybı (q_{yil}) denklem (7) ile bulunabilir [21],

$$q_{yil} = 86400 \times HDD \times U \quad (7)$$

Diş duvarın birim alanından ısı kaybı ile ısıtma için gerekli olan yıllık enerji miktarı (E), denklem (8)'de belirtildiği gibi, yıllık ısı kaybının ısıtma sisteminin verimi (η) değerine bölünmesiyle elde edilir [15],

$$E = \frac{q_{yil}}{\eta} \quad (8)$$

Yıllık ısıtma enerjisi ihtiyacı miktarı (E_H) denklem (9) ile hesaplanabilir [22]:

$$E_H = \frac{86400 \times HDD \times U}{(R_{w,t} + R_{i,ns}) \times H_u \times \eta} \quad (9)$$

Burada H_u kullanılan yakıtın alt ısı değeri olup, Tablo 4'te bu çalışmada kullanılan yakıtların alt ısı değerleri belirtilmiştir [23]. Tablodaki C_F açıklaması da burada belirtilsin

Tablo 4. Çalışmada Kullanılan Yakıtların Alt Isıl Değerleri (H_u) [23]

Yakıt	H_u	η (%)	C_F
Doğalgaz	34485000 J/m ³	90	0.360 \$/m ³
Elektrik	3599000 J/kg	99	0.046 \$/kg

Yalıtımsız duvarın birim alanını ısıtmak için gerekli olan yıllık enerji ihtiyacı ile yalıtımlı duvarın birim alanını ısıtmak için gerekli enerji ihtiyacı farkı bize net yıllık enerji tasarrufunu (ET) verir. Enflasyon ve faiz oranının bağlı şimdiki değer faktörü (PWF) Denklem (12) ile hesaplanabilir. Denklem (13)'te ise faizin enflasyon oranına eşit olduğu durumda bugünkü net değer faktörü hesabı verilmiştir. Denklem (14) ile yalıtımın maliyeti, Denklem (15) ile ısıtma için optimum yalıtım kalınlığı hesaplanabilir [12].

Eğer, $i > g$ ise:

$$r = \frac{i-g}{1+g} \quad (10)$$

Eğer, $g > i$ ise:

$$r = \frac{g-i}{1+i} \quad (11)$$

$$PWF = \frac{(1+r)^N - 1}{r \times (1+r)^N} \quad (12)$$

Eğer, $i = g$ ise:

$$PWF = \frac{N}{1+i} \quad (13)$$

$$C_{ins} = C_y \times x \quad (14)$$

$$X_{OptH} = 293.94 \times \left(\frac{HDD \times C_f \times PWF \times k}{H_u \times C_{ins} \times \Omega} \right)^{\frac{1}{2}} - k \times R_{w,t} \quad (15)$$

2.2. Ekonomik Geri Ödeme Süresi

Geri ödeme süresi (PP), bir yatırımın ekonomik sürdürülebilirliğini ölçen bir yöntem değil, kaç yıllık gelirlerin giderleri karşılayacağını hesaplayan bir yöntemdir. Denklem (16)'da C_H yalıtımsız, $C_{t,H}$ ise yalıtımlı haldeki enerji maliyetlerini temsil eder [11]. Isıtılan binalar için yıllık toplam net tasarruf miktarı ($A_{yıl,H}$) denklem (17) ile, pph açıklaması yazılmalı PP_H ise denklem (18) ile hesaplanmaktadır [24].

$$C_{t,H} = C_H \times PWF \times C_{ins} \quad (16)$$

$$A_{yıl,H} = C_H - C_{t,H} \quad (17)$$

$$PP_H = \frac{C_{ins}}{A_{yıl,H}} \quad (18)$$


3. BULGULAR

3.1. Optimum Yalıtım Kalınlıkları


Çalışmada TSE 825'e göre farklı iklim bölgelerinde bulunan Aydın, Diyarbakır, Nevşehir illerinde yakıt olarak doğalgaz ve ısı pompası, yalıtım malzemesinin olarak da XPS ve taş yünü için optimum kalınlıkları belirlenmiştir. Şekil 3'te Aydın için farklı yakıt türleri ve yalıtım malzemeler için optimum yalıtım kalınlıkları verilmiştir. Grafiklerin ortak özelliği yalıtım kalınlığının artmasıyla, yalıtım maliyetinin artmış enerji maliyetinin ise azalmış olmasıdır. Toplam maliyet, birim alan için yakıt ve yalıtım malzemesi maliyetlerinin toplamını göstermektedir. Aydın ili için doğal gaz kullanılması durumunda optimum yalıtım kalınlıklarının sırasıyla XPS ve Taş yünü için 0.029 m ve 0.031 m, ısı pompası kullanılması durumunda ise 0.015 m ve 0.022 m olarak hesaplanmıştır.

Aydın ili için doğalgaz ve XPS kullanılması durumunda, optimum yalıtım kalınlığı için toplam maliyet 13.67 $\$/m^2$ ve ısıtma maliyeti 6.47 $\$/m^2$ olurken, yalıtımsız duvar için enerji maliyeti 23.08 $\$/m^2$ 'dir. Aynı şartlarda optimum kalınlıklı taş yünü kullanılması durumunda, enerji maliyeti


5.8 $\$/m^2$ bulunmuştur. Isı pompası kullanılması durumunda XPS için, toplam ısıtma maliyeti 6.78 $\$/m^2$ ve enerji maliyeti 3.18 $\$/m^2$ olurken, optimum kalınlıklı taş yünü kullanılması durumunda, enerji maliyeti 2.92 $\$/m^2$ olmuştur. Karşılaştırmada en uygun enerji maliyetinin ısı pompası, yalıtım malzemesi olarak taş yünü kullanılması durumu olduğu söylenebilir.




(a)




(b)



(c)



(d)




(b)


Şekil 3. Aydın için optimum yalıtım kalınlığının maliyetle değişimi (a) Doğal gaz-XPS (b) Doğal gaz-Taş yünü (c) Isı pompası- XPS (d) Isı pompası Taş yünü

Şekil 4'te Diyarbakır ili için doğal gaz kullanılması durumunda optimum yalıtım kalınlıklarının sırasıyla XPS ve Taş yünü için 0.043 m ve 0.05 m, ısı pompası kullanılması durumunda 0.017 m ve 0.036 m olarak hesaplanmıştır.


Diyarbakır ili için doğal gaz ve optimum kalınlıklı XPS kullanılması durumunda, toplam maliyet 18.33 $\$/m^2$ ve enerji maliyeti 11.43 $\$/m^2$ olurken, yalıtımsız durumda enerji maliyeti 40.76 $\$/m^2$ 'dir. Toplam maliyet ve enerji maliyeti arasındaki fark, optimize edilmiş yalıtım maliyeti olan 7.2 $\$/m^2$ olarak hesaplanmıştır. Aynı şartlarda optimum kalınlıklı taş yünü kullanılması durumunda, enerji maliyeti 7.4 $\$/m^2$ olmuştur. Isı pompası kullanılması durumunda optimum kalınlıklı XPS için, toplam maliyet 9.22 $\$/m^2$ ve enerji maliyeti 5.62 $\$/m^2$ olurken, optimum kalınlıklı taş yünü kullanılması durumunda, enerji maliyeti 4.29 $\$/m^2$ olmuştur. Karşılaştırmada en uygun enerji maliyetinin yakıt olarak doğal gaz, yalıtım malzemesi olarak Taş yünü kullanılması durumunda olduğu söylenebilir.



(c)



(d)




(a)


Şekil 4 Diyarbakır için optimum yalıtım kalınlığının maliyetle değişimi (a) Doğal gaz-XPS (b) Doğal gaz-Taş yünü (c) Isı pompası- XPS (d) Isı pompası Taş yünü

Şekil 5'te Nevşehir ili için doğal gaz kullanılması durumunda optimum yalıtım kalınlıklarının sırasıyla XPS ve Taş yünü için 0.055 m ve 0.06 m, ısı pompası kullanılması durumunda 0.025 m ve 0.047 m olarak hesaplanmıştır.


Nevşehir ili için doğal gaz ve optimum kalınlıklı XPS kullanılması durumunda, toplam maliyet 22.70 $\$/m^2$ ve enerji maliyeti 11.90 $\$/m^2$ olurken, yalıtılmamış duvarlı enerji maliyeti 57.71 $\$/m^2$ 'dir. Toplam maliyet ve enerji maliyeti arasındaki fark, optimize edilmiş yalıtım kalınlığındaki yalıtım maliyeti olan 10.8 $\$/m^2$ verir. Aynı şartlarda optimum kalınlıklı taş yünü kullanılması durumunda, enerji maliyeti 9.67 $\$/m^2$ olmuştur. Isı pompası kullanılması durumunda optimum kalınlıklı XPS için, toplam maliyet 11.56 $\$/m^2$ ve enerji maliyeti 7.96 $\$/m^2$ olurken, optimum kalınlıklı taş yünü kullanılması durumunda, enerji maliyeti 5.21 $\$/m^2$ olmuştur. Karşılaştırmada en uygun enerji maliyetinin ısı pompası, yalıtım malzemesi olarak taş yünü kullanılması durumunda olduğu söylenebilir.




(a)



(b)



(c)



(d)

Şekil 5. Nevşehir için optimum yalıtım kalınlığının maliyetle değişimi (a) Doğal gaz-XPS (b) Doğal gaz-Taş yünü (c) Isı pompası- XPS (d) Isı pompası Taş yünü

Tablo 5 ve Tablo 6'da TSE 825'e göre farklı iklim bölgelerinde bulunan Aydın, Diyarbakır, Nevşehir illerinde yakıt olarak doğalgaz ve ısı pompası ile ısıtma, yalıtım malzemesinin olarak da XPS ve taş yünü için optimum kalınlıkları, yıllık kazanç ($AY_{(H)}$) ve ekonomik geri ödeme süreleri (PP) hesaplanmıştır. Tablo 5'te yakıt olarak doğalgaz kullanımında birinci bölgede bulunan Aydın ilinden 3. Bölgede bulunan Nevşehir iline doğru gidildikçe, yıllık kazanç bazında sırasıyla %100 ve %47 oranında artış gözlenmektedir. Isıtma pompası ile ısıtma yapıldığında yıllık kazançlar sırasıyla %105 ve %54 oranında artış sağlamıştır. Yine Tablo 5'te doğalgaz ile ısıtma ile ısı pompasıyla ısıtma arasında ekonomik geri ödeme sürelerinde sırasıyla Aydın, Diyarbakır ve Nevşehir illerinde 2.6, 2 ve 1.65 yıl fark

bulunmaktadır.

Tablo 5. XPS kullanımı

Doğalgaz ve XPS kullanımında bölgeler bazında veriler

Şehirler	HDD	X _{opt.} (m)	A . Y _(H) (\$/m ²)	PP (Yıl)
Aydın	1213	0.029	1.6	3.3
Diyarbakır	2142	0.043	3.2	2.5
Nevşehir	3033	0.055	4.7	2.1

Isı pompası ve XPS kullanımında bölgeler bazında veriler

Şehirler	HDD	X _{opt.} (m)	A . Y _(H) (\$/m ²)	PP (Yıl)
Aydın	1213	0.015	0.39	5.9
Diyarbakır	2142	0.017	0.8	4.5
Nevşehir	3033	0.025	1.23	3.75

Tablo 6. Taş yünü kullanımı

Doğalgaz ve taş yünü kullanımında bölgeler bazında veriler

Şehirler	HDD	X _{opt.} (m)	A . Y _(H) (\$/m ²)	PP (Yıl)
Aydın	1213	0.031	1.55	3.8
Diyarbakır	2142	0.05	3	2.8
Nevşehir	3033	0.06	4.5	2.3

Isı pompası ve taş yünü kullanımında bölgeler bazında veriler

Şehirler	HDD	X _{opt.} (m)	A . Y _(H) (\$/m ²)	PP (Yıl)
Aydın	1213	0.022	0.48	4.5
Diyarbakır	2142	0.036	0.94	3.4
Nevşehir	3033	0.047	1.4	2.9

Tablo 6’da ısıtma için ısı pompası ve doğalgaz kullanımları kıyaslandığında birinci bölgede bulunan Aydın ilinden 3. Bölgede bulunan Nevşehir iline doğru gidildikçe, yıllık kazanç farkları sırasıyla 1.07, 2.06 ve 3.1 \$/m² hesaplanmıştır. Yine 6’da doğalgaz ve ısı pompasıyla ısıtma arasında ekonomik geri ödeme sürelerinde sırasıyla Aydın, Diyarbakır ve Nevşehir illerinde 0.7, 0.6 ve 0.6 yıl fark bulunmaktadır.

3. SONUÇLAR VE ÖNERİLER

Sonuç olarak, Şekil 3, Şekil 4, Şekil 5’te gösterilen yalıtım kalınlığı-maliyet grafiklerinde ve Tablo 5 ve Tablo 6’da belirlenen bulgularda TSE 825’e göre belirlenen bölgelerde birinci bölgede ısıtma için ısı pompası kullanmanın avantajlı olacağı, ikinci ve üçüncü bölgelerde ise ısıtma için doğalgaz kullanımının avantajlı olduğu gözlemlenmiştir. Ayrıca ısı pompalarının belirli sıcaklık derecelerinin altında verimsiz çalışması ve ilk yatırım maliyetlerinin yüksek olması sebebiyle sıcak bölgelerde kullanımının daha uygun olacağı önerilir.

Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur. Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

Kaynaklar

- [1] EPBD recast, Directive 2010/31/EU of the European Parliament and of Council of 19 May 2010 on the energy performance of buildings (recast), Official Journal of the European Union, 2021.
- [2] Energy Efficiency Directive (EU/2023/1791), https://energy.ec.europa.eu/topics/energy-efficiency/energy-efficiency-targets-directive-and-rules/energy-efficiency-directive_en
- [3] IPCC 2014. Climate change 2014: synthesis report. Contribution of Working Groups I, II and III to the fifth assessment report of the Intergovernmental Panel on Climate Change, Switzerland.
- [4] Kahraman, G. (2021). Comparison of heat transfer and condensation on the walls of buildings constructed with iron profiles versus other classic models. *Heat Transfer Research*, 52(14).
- [5] Öztuna, S. ve Dereli, E., (2009). Edirne ilinde optimum duvar yalıtım kalınlığının enerji tasarrufuna etkisi, *Trakya Univ J Sci*, 10, 2, 139-147.
- [6] Dilmac, S., & Kesen, N. (2003). A comparison of new Turkish thermal insulation standard (TS 825), ISO 9164, EN 832 and German regulation. *Energy and Buildings*, 35(2), 161-174.
- [7] Borelli, D., Cavalletti, A., Cavalletti, P., Peshku, J., & Tagliafico, L. A. (2024). A methodology to evaluate the optimal insulation thickness for heating and cooling needs in

different climatic zones for buildings made of reinforced concrete with cavity walls. *Heliyon*, 10(10).

[8] Verichev, K., Serrano-Jiménez, A., Carpio, M., Barrios-Padura, Á., & Díaz-López, C. (2023). Influence of degree days calculation methods on the optimum thermal insulation thickness in life-cycle cost analysis for building envelopes in Mediterranean and Semi-Arid climates. *Journal of Building Engineering*, 79, 107783.

[9] Malka, L., Kuriqi, A., & Haxhimusa, A. (2022). Optimum insulation thickness design of exterior walls and overhauling cost to enhance the energy efficiency of Albanian's buildings stock. *Journal of Cleaner Production*, 381, 135160.

[10] Li, X., & Tingley, D. D. (2023). A whole life, national approach to optimize the thickness of wall insulation. *Renewable and Sustainable Energy Reviews*, 174, 113137.

[11] Özel, M., (2011). "Effect of wall orientation on the optimum insulation thickness by using a dynamic method", *Applied Energy*, 88: 2429-2435.

[12] Kürekçi, A., Bardakçı, A., D., Çubuk, H. ve Emanet, Ö., (2012). "Türkiye'nin Tüm İlleri İçin

[13]. Akyüz, M. K., Altuntaş, Ö., & Söğüt, M. Z. (2017). Economic and environmental optimization of an airport terminal building's wall and roof insulation. *Sustainability*, 9(10), 1849.

[14] Ashrae, *Ashrae Handbook- Fundamentals (SI)*, Energy estimating and modeling methods chapter 31, 2001.

[15] Büyükalaca, O., Bulut, H., Yılmaz, T., Türkiye'nin bazı illeri için derece-gün değerleri, 12. Ulusal Isı Bilimi ve Tekniği Kongresi Bildiriler Kitabı, Cilt 1, sayfa 107-112, Sakarya, 2000.

[16] Pusat Ş, Ekmekçi İ, Dündar AÇ, Ermiş K, Şen Y. İstanbul İçin Tipik Meteorolojik Yıl ve Derece-Saat Hesabı. 2.Ulusal İklimlendirme Soğutma Eğitimi Sempozyumu ve Sergisi Oct. 23-25 2014, Balıkesir, Turkey.

[17] TSE (Turkish Standards Institution). TS 825: Thermal Insulation in Buildings; 1998.

[18] Ertürk, M. 2017. A new model for exergetic optimum insulation thickness. *International Journal of Exergy* 22 (4):309–30. doi:10.1504/IJEX.2017.083945.

[19] N. Daouas, Z. Hassen & H. B. Aissia, "Analytical period solution for the study of thermal performance and optimum insulation thickness of building walls in Tunisia", *Appl Thermal Eng*, vol. 30, pp. 319–326, 2010.

[20] Evin, D., and A. Ucar. 2019. Energy impact and eco-efficiency of the envelope insulation in residential buildings in Turkey. *Applied Thermal Engineering* 154:57384. doi:10.1016/j.applthermaleng. 2019.03.102.

[21] A. Uçar & F. Balo, "Determination of the energy savings and the optimum insulation thickness in the four different insulated exterior walls", *Renewable Energy*, vol. 35, pp. 88-94, 2010.

[22] Küçüktopcu E, Cemek B. A study on environmental impact of insulation thickness of poultry building walls. *Energy*. 2018; 150:583-590.

[23] Bolattürk, A., (2008). "Optimum Insulation Thickness for Building Walls with Respect to Cooling and Heating Degree-Hours in the Warmest Zone of Turkey", *Building and Environment*, 43: 1055-1064.

[24] N. Sisman, E. Kahya , N. Aras & H. Aras, "Determination of optimum insulation thicknesses of the external walls and roof (ceiling) for Turkey's different degree-day regions", *Energy Policy*, vol. 35, pp. 5151-5155, 2007.



Research Article

Experimental Research of the Influence of Fiber Laser Machining Parameters on HAZ Width in AISI 4140 Steels

Mehmet Şükrü Adin*

Batman University, Besiri OSB Vocational School, mehmetasukru.adin@batman.edu.tr, Orcid No: 0000-0002-2307-9669

ARTICLE INFO

Article history:

Received 08 October 2024
Received in revised form 12 November 2024
Accepted 25 November 2024
Available online 23 December 2024

Keywords:

Fiber laser machining, Laser cutting, Heat affected zone, HAZ width, AISI 4140, Taguchi DOE

Doi: 10.24012/dumf.1563430

* Corresponding author

ABSTRACT

In present day, laser beam machining technology attracts great attention due to its cost-effectiveness, high machining quality, mass manufacturing velocity and broad areas of applicability throughout different manufacturing industries. However, intensive researches are required since many materials with different properties (chemical and mechanical) are used in the manufacturing industries; and there is need for high quality machining through newly developed laser technologies. In this context, in this experimental research, unlike most studies in the literature, an investigation was carried out on heat affected zone (HAZ) occurring in AISI 4140 steel machined by laser beam in different cutting geometries (triangle, square and circle cutting). In the present study, when the average HAZ widths calculated according to the laser cutting geometries were examined, it was understood that the highest average HAZ width (579 μm) was obtained in the triangle cutting geometry and the lowest average HAZ width (369 μm) was obtained in the circle cutting geometry. What is more, when the average HAZ widths obtained according to laser cutting geometries were compared, it was observed that the average HAZ widths of the specimens cut in triangle geometry were 31.61% and 56.93% larger than the specimens cut in square and circle cutting geometries, respectively. Furthermore, it was found that as the laser power increased, the HAZ widths were negatively affected (i.e., HAZ widths increased), but as the cutting speed increased, the HAZ widths were positively affected (i.e., HAZ widths decreased). From the ANOVA analyses, it was found that the cutting geometry (with a rate of 51.32%) was the most pivotal parameter influencing the HAZ width. When the regression analysis results (based on quadratic regression models) were checked, it was understood that R^2 value had a very high rate (96.79%) as desired. Thus, from these results, it was understood that the model developed to predict the HAZ width values has a high success rate and reliability.

Introduction

Nowadays, there is a great demand for machining materials with different properties (in terms of chemical and physical properties) using laser technologies. The most important reasons for this demand are their low costs and high-quality machining capabilities [1, 2]. Moreover, they have another advantage that no cutting tools are needed in machining operations [2]. Considering the laser technologies used in modern manufacturing industries, it is seen that especially CO₂ and fiber laser technologies stand out. However, in recent years, interest in fiber laser has been increasing day by day due to its relatively newer and more advanced features [3, 4]. Additionally, the fact that it is more cost-effective than CO₂ laser is seen as another advantage [5, 6]. In laser cutting processes, one of the most important factors affecting laser cutting efficiency is the absorption capacity of the material being machined. This factor is highly affected by many parameters such as the type of material (chemical and physical), the wavelength of the laser beam and the angle of incidence of the laser beam. Compared to CO₂ lasers, fiber lasers, due to their shorter wavelengths, provide higher absorption when processing metal materials. As a natural consequence of this situation

(since it provides higher absorption), it provides higher quality machining [1, 5, 7, 8]. Although fiber laser is a newer technology than CO₂ laser, machining parameters need to be optimized separately for each material in order to achieve high quality machining of materials with different chemical and physical properties [4-6]. In the laser cutting process (to summarize briefly), local melting occurs in the workpiece (metal) under the influence of the laser beam focused on the workpiece and the molten metal is blown out from the operation area with the help of the assist gas used during the process. As a consequence of this continuous operation, the workpiece is separated (i.e., cutting occurs) from each other [4, 5]. In laser cutting processes, for a high-quality cutting, it is very important to take into account many parameters such as laser technology, cutting geometry, laser power, cutting speed, type of assist gas, gas pressure, chemical and physical properties of the workpiece, and thickness of the workpiece [5, 6]. Therefore, a lot of research needs to be carried out regarding these parameters. As a matter of fact, it is seen in the literature that investigations have been conducted regarding many of these parameters [3-5]. However, when

the investigations in the literature are checked, it is observed that laser cutting geometries are generally in the form of a straight line. In other words, it is understood that a limited number of investigations have been conducted on different cutting geometries and their effects. Moreover, as a consequence of literature review, it was understood that there are very few investigations on the heat affected zone (HAZ) that occurs in metal workpieces during laser cutting process [3-6].

In this experimental research, unlike most studies in the literature, an investigation was carried out on HAZ occurring in AISI 4140 steel machined by laser beam in different cutting geometries (triangle, square and circle). In order to conduct the investigation cost-effectively and also for a comprehensive evaluation, one of the most widely used optimization methods was employed.

Materials and methods

Workpiece material

In this current research, AISI 4140 steel was utilized as the workpiece. AISI 4140 steel is a type of steel that stands out with its many features such as superior strength, wear resistance and good toughness. These steels are among the most demanded materials in the manufacturing industries due to their high durability [9, 10]. That is why it was specially selected within the scope of this research. In Table 1, the chemical compositions of AISI 4140 steel used as the workpiece in this research is given.

Table 1. Chemical compositions

Chemical composition (wt.%)			
C	0.41	Cr	1.04
Si	0.24	Ni	0.03
P	0.012	Mo	0.172
Mn	0.82	Cu	0.01
S	0.023	Fe	Bal.

As displayed in Fig. 1, images and dimensions (100 mm x 50 mm x 10 mm) of AISI 4140 steel materials machined with laser beam in different cutting geometries are given.




Figure 1. Images and dimensions of AISI 4140 test specimens

Use of Taguchi method

In the present day, many optimization methods are used in different manufacturing industries for high quality machining of workpieces with different characteristics (chemically and physically). The Taguchi method, which provides cost-effective solutions with a minimum number of experiments, is the most well-known of these optimization methods. That is why, in this research, this optimization method was utilized to obtain the most cost-effective solutions [11-13]. Moreover, variance (ANOVA) and regression analyses were also performed to make the study more comprehensive. ANOVA analysis was performed based on literature investigations at a confidence level of 95% and a significance level of 5%, and the most accurate results were achieved [11, 13, 14]. In this research, the "Smaller is better" approach (due to adverse effects on the workpiece) was adopted because the HAZ (the heat affected zone) width in laser-cut materials was required to be as minimum as possible [2]. In this context, for each experimental result obtained, signal-to-noise ratios (S/N ratios) were calculated using the formula (equation (1)) given below [11, 12].

Smaller is better:

$$S/N = -10 \log \left(\frac{1}{n} \sum_{i=1}^n y_i^2 \right) \quad (1)$$

In this current research, Minitab statistical software (Fig. 2), which is widely used in investigations [15], was used to perform the analyses.

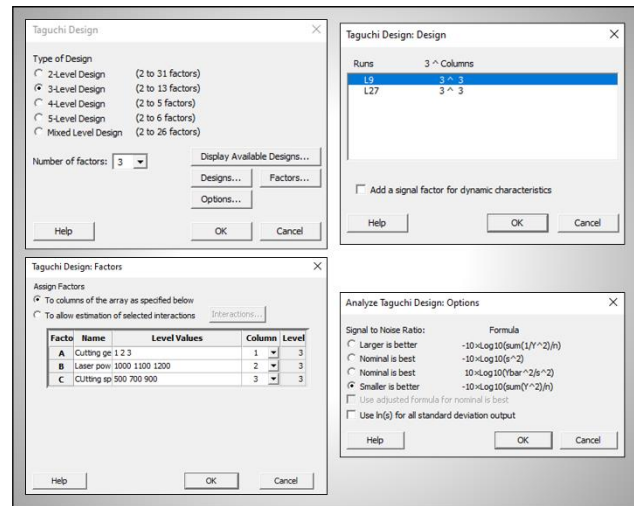


Figure 2. Step by step adjustments to perform analyses

Besides, as depicted in Fig. 2, the Taguchi L9 (3-level design) experimental design (DOE) was adopted (based on laser machining parameters and levels). In Table 2, the machining parameters and levels determined for laser cutting experiments within the scope of this research are given. The laser cutting parameters (gas pressure, laser power, cutting speed) used in this research were determined based on the investigations in the literature [2, 4, 16]. However, different values were determined (between the top and bottom values) in order to make this research original.

Table 2. Laser machining parameters and levels

Parameter	Unit	Level 1	Level 2	Level 3
Cutting geometry	-	1 (Triangle)	2 (Square)	3 (Circle)
Gas pressure	Bar	0.6	-	-
Laser power	W	1000	1100	1200
Cutting speed	mm/min	500	700	900

As displayed in Table 2, the levels of laser cutting parameters were increased according to the same increase rate (for each parameter separately), thus enabling more precise results to be obtained.

Laser beam machining experiments

In this current investigation, laser cutting experiments were conducted using a Senfeng brand CNC fiber laser machine with a maximum power of 2000 W. Since they have significant effects on the results of the experiments [4, 5], ambient temperature and relative humidity were measured three times using a Hubstein HTC-1 brand device and the averages of these values were calculated. The average relative humidity and ambient temperature throughout the laser cutting experiments were found to be 53% and 25°C, respectively. Fig. 3 depicts images of AISI 4140 steel materials machined in different laser cutting geometries (i.e., triangle, square and circle) taken during cutting experiments. Moreover, as seen in Fig.3, the laser cutting lengths were specifically ensured to be the same (96 mm) despite the different laser cutting geometries. Because, due to the nature of laser beam cutting processes, laser cutting lengths are very important [4]. As a matter of fact, this issue (laser cutting lengths) will be expressed in detail in the results and discussion section. The laser cutting geometries used in this research were specifically determined (for the purpose of an original research) because there is no similar study in the literature. In the laser cutting experiments performed with a fiber laser machine, a 2 mm diameter nozzle and O₂ gas (as assist gas) were used [4-6, 16]. In the laser cutting experiments performed according to Taguchi's L₉ DOE, the thickness (10 mm, i.e. thicker) of the workpieces was determined in the light of the studies in the literature in order to make the HAZ widths more apparent [4-6].

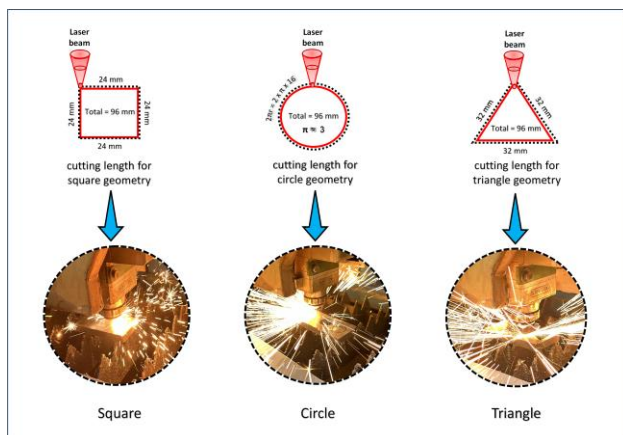


Figure 3. Laser cutting lengths (triangle, square and circle) and images taken during laser cutting experiments

HAZ width measurements

In this research, in order to investigate the effects of different cutting geometries and cutting parameters on the cut specimens, firstly the images of the edges of the cut specimens were captured with the help of a microscope (Leica DM 750P branded microscope) and then the HAZ widths were precisely measured on these images with the help of ImageJ software. As depicted in Fig. 4, the image taken of the cut edge of the steel material cut with a laser beam and a measurement process performed on this image are shown. In this research, since the negative effects of HAZ widths on the specimen are known [2, 4, 15-17], measurements were made at five different points of each cut (cut with different cutting geometries) specimen and then the arithmetic averages of these results were calculated.




Figure 4. Measuring on a captured image

Results and discussion

HAZ width

Nowadays, in the manufacturing industries where laser-cutting processes are carried out, the surface roughness, cutting width and HAZ widths of the cut workpieces are taken into consideration as important aspects. The most important reason for this is that the machining quality of these manufactured parts directly affects their performance in their permanent use place [2, 4, 15-17]. For these reasons, in this research, measurements (HAZ widths) were made at five different points of each cut (cut with different cutting geometries) specimen and then the arithmetic averages of these results were calculated. In Fig. 5, the results of HAZ widths obtained as a consequence of this experimental study are given separately for different cutting geometries.

As illustrated in Fig. 5, when the specimens cut in triangle geometry with the laser beam were checked, it was seen that the highest HAZ width was 715 μm . On the other side, the lowest HAZ width was measured as 411 μm in specimens cut in triangle geometry with laser beam. When the highest (715 μm) and lowest (411 μm) HAZ widths obtained from these specimens cut in triangle geometries were compared, it was observed that the highest HAZ width was 73.96% larger than the lowest HAZ width.

On the other hand, as depicted in Fig. 5, when the specimens cut in square geometry with the laser beam were checked, it was observed that the highest HAZ width was 531 μm . On the other side, the lowest HAZ width was measured as 389

µm in specimens cut in square geometry with laser beam. When the highest (531 µm) and lowest (389 µm) HAZ widths obtained from these specimens cut in square geometries were compared, it was revealed that the highest HAZ width was 36.53% larger than the lowest HAZ width.




Figure 5. HAZ widths obtained based on different cutting geometries

Besides, as displayed in Fig. 5, when the specimens cut in circle geometry with the laser beam were checked, it was observed that the highest HAZ width was 409 µm. On the other side, the lowest HAZ width was measured as 313 µm in specimens cut in circle geometry with laser beam. When the highest (409 µm) and lowest (313 µm) HAZ widths obtained from these specimens cut in circle geometries were compared, it was seen that the highest HAZ width was 30.69 % larger than the lowest HAZ width. As illustrated in Fig. 6, the average HAZ width values calculated according to different laser cutting geometries (triangle, square and circle) are given.




Figure 6. Average HAZ widths based on different laser cutting geometries

When the average HAZ widths calculated according to the laser cutting geometries given in Fig. 6 are examined, it is understood that the highest average HAZ width is obtained in the triangle cutting geometry and the lowest

average HAZ width is obtained in the circle cutting geometry. What is more, when the average HAZ widths obtained according to laser cutting geometries were compared, it was seen that the average HAZ widths of the specimens cut in triangle geometry were 31.61% and 56.93% larger than the specimens cut in square and circle cutting geometries, respectively.

In this current investigation, analyses (based on Taguchi experimental design) were performed in the Minitab program in order to perform a more comprehensive analysis of the HAZ widths occurring in steel specimens cut in different cutting geometries. As a consequence of the analyses, the S/N ratios calculated for each HAZ width are illustrated in Fig. 7.




Figure 7. S/N ratios based on HAZ widths

As depicted in Fig. 7, when the analyses made according to the HAZ widths of the specimens cut in different cutting geometries were checked, it was understood that the highest S/N ratio was obtained in the specimen with experiment number L8 (- 49.9109). This highest S/N ratio was achieved in a circle cutting geometry and a HAZ width of 313 µm, respectively. On the other hand, when the analyses made based on the HAZ widths of the specimens cut in different cutting geometries were checked, it was found that the lowest S/N ratio was obtained in the specimen with experiment number L3 (- 57.0861). This lowest S/N ratio was achieved in a triangle cutting geometry and a HAZ width of 715 µm, respectively. As a consequence of the analyses carried out with the Minitab program, a main effect plot was also obtained according to the S/N ratios calculated based on the HAZ widths and illustrated in Fig. 8.

When the graph of the average of S/N ratios obtained according to the HAZ widths given in Fig. 8 is checked, it is clearly observed that the best result (i.e., the highest average S/N ratio) among different cutting geometries was obtained with the circle cutting geometry. Moreover, it was found that HAZ widths were negatively affected (i.e., HAZ widths increase) as the laser power increased.




Figure 8. Main effects plot for HAZ widths

On the other hand, it was understood that HAZ widths were positively affected (i.e., HAZ widths decrease) as the cutting speed increased. In other words, it was found that the HAZ width had a directly proportional relationship with the laser power but an inversely proportional relationship with the cutting speed. As a matter of fact, when the results found in this research were compared with the results of investigations (regarding HAZ widths) in the literature, it was revealed that there were similar trends [2-4, 17, 18]. Additionally, in the light of the results obtained within the scope of this investigation, it can be stated that the most suitable machining parameters for the steel workpiece cut with fiber laser are circle cutting geometry, 1000 W laser power and 900 mm/min cutting speed, respectively. In this research, in order to investigate the effects (effects on HAZ widths) of different cutting geometries and cutting parameters on the cut specimens, firstly, the images of the edges of the cut specimens were captured with the help of a microscope and then the HAZ widths were precisely measured on these images with the help of ImageJ software. As depicted in Fig. 9, images taken of specimens cut with laser beam in different geometries are given for each experiment (i.e., between L1 and L9).

As displayed in Fig. 9, it is understood that the HAZ widths of the steel specimens cut with different geometries with the laser beam according to the Taguchi experimental design (DOE) vary according to the applied machining parameters. Moreover, it is observed that the HAZ widths of the specimens cut in triangle geometry with the laser beam are larger than the HAZ widths of the specimens cut in square and circle cutting geometries. Additionally, when the HAZ widths of specimens cut in different laser cutting geometries are compared, it is noticed that the lowest HAZ widths are in the specimens cut in circle geometry. As a matter of fact, when these visual inspections (Fig. 9) and statistical results (Figs. 8) are compared with each other, it can be clearly observed that the experimental and statistical results obtained confirm each other.

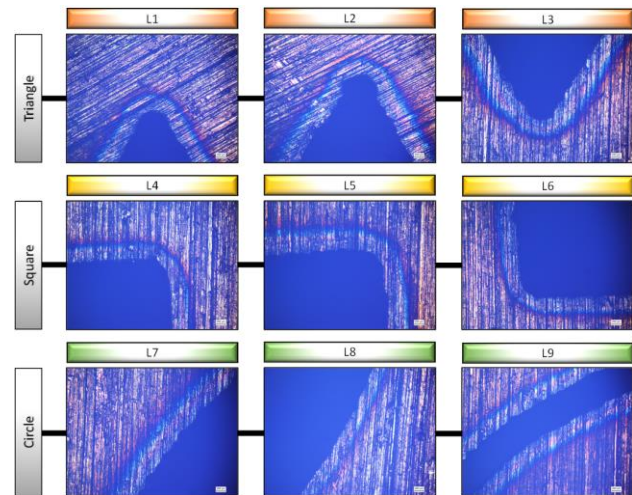


Figure 9. Images of specimens cut at different cutting geometries and cutting parameters

Moreover, it was found that HAZ widths were negatively affected (i.e., HAZ widths increase) as the laser power increased. On the other hand, it was understood that HAZ widths were positively affected (i.e., HAZ widths decrease) as the cutting speed increased. In other words, it was found that the HAZ width had a directly proportional relationship with the laser power but an inversely proportional relationship with the cutting speed. As a matter of fact, when the results found in this research were compared with the results of investigations (regarding HAZ widths) in the literature, it was revealed that there were similar trends [4, 17, 18]. Additionally, in the light of the results obtained within the scope of this investigation, it can be stated that the most suitable machining parameters for the steel workpiece cut with fiber laser are circle cutting geometry, 1000 W laser power and 900 mm/min cutting speed, respectively. In this investigation, the laser cutting lengths (see Fig. 3) were specifically ensured to be the same (96 mm) despite the different laser cutting geometries. Because, due to the nature of laser beam cutting processes, laser cutting lengths are very important [4]. As it is known, in laser beam cutting processes, the metal begins to melt under the effect of the laser beam focused on the workpiece (locally) and subsequently (i.e., after the continuous melting process) the workpiece is cut (i.e., the metal is separated from each other) [4, 5, 19]. During the laser cutting process of metals, O₂ gas (assist gas) is used to both accelerate the cutting process (due to creating extra energy by reacting with the metal workpiece) and remove (i.e., throwing out) the molten metal [4-6, 16]. During this process, parameters such as the duration of the laser beam focused on the metal workpiece, laser power and cutting speed are very important because these parameters have direct effects on the HAZ widths [2, 6, 16]. Furthermore, it is observed that laser cutting geometries are quite effective on the HAZ width. This can be explained by the increase in the HAZ width that occurs because the metal starting to melt as a result of the laser beam focusing on the workpiece, but finding more penetration opportunity (i.e., since it penetrates for a longer time) in the same local area (i.e.,

especially at the corners where two edges meet) due to the effect of the cutting geometries (i.e., triangle and square cutting geometries) [4-6]. On the other side, since this negative situation, which increases the HAZ width, does not occur in the circle cutting geometry, it is less affected than the square and triangle cutting geometries (see Figs. 6 and 9).

Variance and Regression analyses

In this investigation, ANOVA analysis, which is referred to as analysis of variance, was also performed to reveal which machining parameter has the most important impact on the HAZ width. ANOVA analysis was performed based on literature investigations at a confidence level of 95% and a significance level of 5%, and thus the most accurate results were achieved [11, 13, 14, 20, 21]. As illustrated in Fig. 10, the results of the ANOVA analysis (percentage contribution rates) carried out using the HAZ width values obtained within the scope of this investigation are given.




Figure 10. Percentage contribution rates and regression equations

When the ANOVA analysis results given in Fig. 10 are checked, it is clearly observed that the cutting geometry (with a rate of 51.32%) is the most important parameter influencing the HAZ width, in line with the experimental results mentioned above. Besides, the percentage contribution rates of other parameters were found to be 36.46% (cutting speed) and 10.79% (laser power), respectively. Additionally, within the scope of this investigation, regression analyses (in order to analyze the correlation between machining parameters and outputs) were performed for HAZ widths and as a consequence of the analyses, regression equations were developed according to different cutting geometries (Fig 10). As illustrated in Fig. 10, when the regression analysis results (based on quadratic regression models) were checked, it was understood that the R² value had a very high rate (96.79%) as desired (90% and above [11, 22]). As is known, the R² value (i.e., regression coefficient) is considered as an indicator of the effectiveness and success of the developed model [12, 22-25]. In Fig. 11, the comparison graph of actual and predicted HAZ width values is depicted.




Figure 11. Comparison graph of actual and predicted HAZ width values

As illustrated in Fig. 11, it is understood that the results (comparison of actual and predicted HAZ width values) shown as blue dots are collected almost adjacent to the regression line (red colored line). Thus, from these results (Fig. 11), it is understood that the model developed to predict the HAZ width values has a high success rate and reliability [11, 12, 22]. Within the scope of this investigation, Fig. 12 was also drawn to visually demonstrate the success of the model developed to predict HAZ width values.

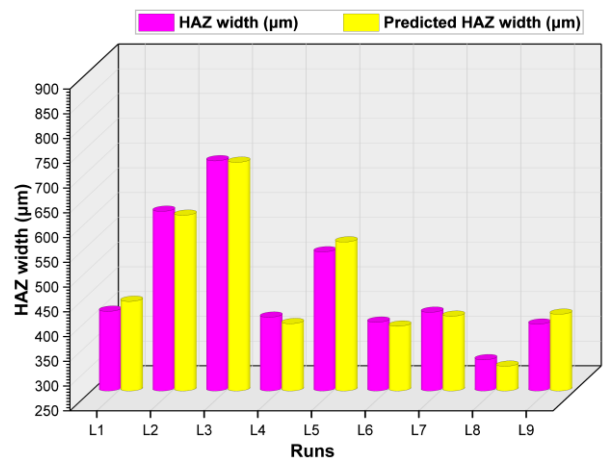


Figure 12. Actual HAZ width results vs predicted HAZ width values

As a matter of fact, as illustrated in Fig. 12, when the actual HAZ width results are compared with the estimated HAZ width values, it is observed that the estimated values are equal to or very close to the actual results. Considering these results (Fig. 12), it once again shows that the success rates and reliability of the models developed to predict the HAZ width values of samples cut with laser beam are quite high.

Conclusions

In this experimental research, an investigation was carried out on HAZ occurring in AISI 4140 steel machined by laser beam in different cutting geometries. The experimental findings and statistical results obtained from this current investigation are presented separately below as a summary:

When the average HAZ widths calculated according to the laser cutting geometries are examined, it is understood that the highest average HAZ width (579 μm) is obtained in the triangle cutting geometry and the lowest average HAZ width (369 μm) is obtained in the circle cutting geometry. What is more, when the average HAZ widths obtained according to laser cutting geometries were compared, it was seen that the average HAZ widths of the specimens cut in triangle geometry were 31.61% and 56.93% larger than the specimens cut in square and circle cutting geometries, respectively.

From the analyses of S/N ratios, it was found that the most suitable machining parameters (based on the cutting geometries applied in this research) for the steel workpiece cut by fiber laser were circle cutting geometry, 1000 W laser power and 900 mm/min cutting speed, respectively. Moreover, it was found that as the laser power increased, the HAZ widths were negatively affected (i.e., HAZ widths increased), but as the cutting speed increased, the HAZ widths were positively affected (i.e., HAZ widths decreased).

From the ANOVA analyses, it was found that the cutting geometry (with a rate of 51.32%) was the most pivotal parameter influencing the HAZ width. Besides, the percentage contribution rates of other parameters were found to be 36.46% (cutting speed) and 10.79% (laser power), respectively.

When the regression analysis results (based on quadratic regression models) were checked, it was understood that the R^2 value had a very high rate (96.79%) as desired. Thus, from these results, it was understood that the model developed to predict the HAZ width values has a high success rate and reliability.

References

- [1] M. Kardan, N. Levichev, S. Castagne, and J. R. Duflou, "Dynamic beam shaping requirements for fiber laser cutting of thick plates," *Journal of Manufacturing Processes*, vol. 103, pp. 287-297, 2023.
- [2] U. Çaydaş and A. Hasçalık, "Use of the grey relational analysis to determine optimum laser cutting parameters with multi-performance characteristics," *Optics & laser technology*, vol. 40, no. 7, pp. 987-994, 2008.
- [3] W. M. Steen and J. Mazumder, "Laser material processing," *Springer science & business media, Fourth Edition*, pp. 1-577, 2010.
- [4] C. Guo and S. C. Singh, *Handbook of Laser Technology and Applications: Lasers Applications: Materials Processing and Spectroscopy (Volume Three)*. CRC Press, 2021.
- [5] E. Kannatey-Asibu, "Principles of Laser Materials Processing: Developments and Applications," *John Wiley & Sons, Inc.*, pp. 1-611, 2023.
- [6] J. Lawrence, "Advances in laser materials processing: technology, research and applications," *Woodhead Publishing*, vol. 2, pp. 1-802, 2017.
- [7] G. C. Rodrigues and J. Duflou, "Effects of different polarization strategies on laser cutting with direct diode lasers," *Physics Procedia*, vol. 83, pp. 302-309, 2016.
- [8] G. C. Rodrigues, M. Cuypers, E. F. Sichani, K. Kellens, and J. Duflou, "Laser cutting with direct diode laser," *Physics Procedia*, vol. 41, pp. 558-565, 2013.
- [9] W. D. Callister and D. G. Rethwisch, *Materials science and engineering: an introduction*, 9 ed. Wiley, New York, 2014.
- [10] V.-H. Nguyen, T.-T. Le, A.-T. Nguyen, X.-T. Hoang, N.-T. Nguyen, and N.-K. Nguyen, "Optimization of milling conditions for AISI 4140 steel using an integrated machine learning-multi objective optimization-multi criteria decision making framework," *Measurement*, p. 115837, 2024.
- [11] D. C. Montgomery, *Design and analysis of experiments*, Ninth ed. John Wiley & Sons, 2017.
- [12] G. Taguchi, *System of experimental design, quality resources* (New York, USA). 1987.
- [13] J. Vora et al., "Experimental investigations and Pareto optimization of fiber laser cutting process of Ti6Al4V," *Metals*, vol. 11, no. 9, p. 1461, 2021.
- [14] S. Tam, L. E. Lim, and K. Quek, "Application of Taguchi methods in the optimization of the laser-cutting process," *Journal of Materials Processing Technology*, vol. 29, no. 1-3, pp. 63-74, 1992.
- [15] P. Patel, S. Sheth, and T. Patel, "Experimental analysis and ANN modelling of HAZ in laser cutting of glass fibre reinforced plastic composites," *Procedia Technology*, vol. 23, pp. 406-413, 2016.
- [16] J. Powell, S. Al-Mashikhi, A. Kaplan, and K. Voisey, "Fibre laser cutting of thin section mild steel: An explanation of the 'striation free' effect," *Optics and Lasers in Engineering*, vol. 49, no. 8, pp. 1069-1075, 2011.
- [17] Y. Wang et al., "Finite element simulation and experimental verification of laser machining of nitinol tubes," *Optics & Laser Technology*, vol. 181, p. 111672, 2025.
- [18] S. Al-Mashikhi, J. Powell, A. Kaplan, and K. Voisey, "Heat affected zones and oxidation marks in fiber

- laser–oxygen cutting of mild steel," *Journal of laser applications*, vol. 23, no. 4, 2011.
- [19] Y. Liu and S. Zhang, "Improving the cutting process and quality of thick plates with high-power fiber laser," *Optical Fiber Technology*, vol. 83, p. 103684, 2024.
- [20] M. Ş. Adin, "Effects of cutting geometries and cutting parameters on the surface roughness and kerf width of X60 steel machined by laser beam," *Journal of Materials Engineering and Performance*, pp. 1-20, 2024.
- [21] A. İpekçi and K. Argun, "Surface Roughness Performance of Cu Electrode on Hardened AISI 4140 Steels in EDM Process," *Journal of Chinese Society of Mechanical Engineers*, vol. 43, no. 4, pp. 355-362, 2022.
- [22] K. Krishnaiah and P. Shahabudeen, "Applied design of experiments and Taguchi methods," *PHI Learning Pvt. Ltd.*, pp. 1-371, 2012.
- [23] A. İpekçi, and K. Argun, "Experimental investigation and optimization of machining parameters of deep cryogenically treated and tempered steels in electrical discharge machining process," *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, vol. 236, no. 5, pp. 1927-1935, 2022.
- [24] M. Şeremet, "Experimental and statistical investigation of surface roughness and vibration during finish turning of AISI 4140 steel workpiece under cooling method," *Surf. Rev. Lett.*, vol. 28, no. 10, p. 2150092, 2021.
- [25] V. K. Tiwary, P. Arunkumar, and V. R. Malik, "Investigations on the effect of Spin Friction Welding parameters on joint strength and cylindricity of similar/dissimilar Material Extrusion (MEX) 3D printed parts," *Journal of Advanced Joining Processes*, vol. 9, p. 100208, 2024.



Numerical Analysis of Dual Slot Pulsating Nanofluid Impinging Jets

Ali TAŞKIRAN¹, Celal KISTAK², Sinan KAPAN³, Nevin ÇELİK^{4*}, İhsan DAĞTEKİN⁵

¹ Şırnak University, Mechanical Engineering Department, taskiranalii@gmail.com, Orcid No: 0000-0001-6810-7291

² Fırat University, Mechanical Engineering Department, ckistak@firat.edu.tr, Orcid No: 0000-0003-4621-5405

³ Fırat University, Mechanical Engineering Department, skapan@firat.edu.tr, Orcid No: 0000-0001-5690-1041

⁴ Fırat University, Mechanical Engineering Department, nevincelik23@gmail.com, Orcid No: 0000-0003-2456-5316

⁵ Fırat University, Mechanical Engineering Department, idagtekin@firat.edu.tr, Orcid No: 0000-0003-0128-7149

ARTICLE INFO

Article history:

Received 16 October 2024

Received in revised form 25 November 2024

Accepted 29 November 2024

Available online 23 December 2024

Keywords:

Nanofluids, Impinging jets,
Pulsating, Numerical simulations,
ANSYS

Doi: 10.24012/dumf.1567752

* Corresponding author

ABSTRACT

Jet impingement is a well-established technique extensively employed in engineering applications, particularly for the thermal management of high-temperature systems such as aircraft engines and electronic devices. This study utilizes numerical analysis, conducted through the ANSYS software platform, to investigate the flow dynamics of dual impinging pulsating nanofluid jets. The research aims to evaluate the combined effects of key parameters, including jet geometry, pulsation frequency, amplitude, nanoparticle volume concentration, and Reynolds numbers, on the efficiency of heat transfer. The impact of aluminum oxide (Al₂O₃) nanofluids with varying concentrations (1%, 2%, 4%, and 5%) on thermal performance is assessed. The findings of the study demonstrate that the pulsating jets generate bidirectional swirling flows and reverse vortices upon impact with the surface, resulting in notable enhancements in local heat transfer rates. These vortices expand and form wall jets, which contribute to an increase in the heat transfer coefficients and Nusselt numbers. The simulations demonstrate that higher pulsation frequencies (30 Hz) result in a 10% increase in heat transfer efficiency compared to lower frequencies (10 Hz). This is attributed to enhanced flow dynamics and improved heat distribution. Moreover, the incorporation of nanoparticles markedly enhances heat transfer efficiency. The Nusselt numbers were observed to increase by 18% when the concentration of nanoparticles reached 5%, in comparison to plain water. Additionally, the study underscores the significance of jet spacing, wherein an optimal separation distance of 100 mm between the dual jets was identified as a means of maximizing heat transfer by fostering effective vortex interactions. Higher Reynolds numbers contribute to the formation of thinner thermal boundary layers, thereby facilitating increased heat transfer rates, particularly at the stagnation points where the flow impinges directly on the surface. Overall, the study demonstrates that substantial enhancements in heat transfer can be achieved by optimizing key parameters such as pulsating frequency, amplitude, nanoparticle volume concentration, and jet distances.

Introduction

Jet impingement is a prominent flow configuration with a wide range of applications across various disciplines of engineering and science. It is a technique that is commonly employed in numerous industries, including those focused on heating, cooling, drying, cutting, and cleaning. The distinctive attributes of this flow pattern have prompted considerable interest, giving rise to extensive research endeavors through both experimental and numerical investigations [1]–[6]. One of the most significant applications of impinging jets is in the cooling of high-temperature systems, such as aircraft engines and electronic devices, where efficient heat dissipation is essential for both optimal performance and safety. In addition to their utility in cooling applications, impinging air jets are indispensable in industrial drying processes across a range of sectors, including textiles, glass, and food production. In these contexts, they facilitate operational efficiency and product quality. Furthermore, this flow pattern is extensively employed in metal processing and cutting operations, where the high-speed jet impact facilitates enhanced precision and productivity.

In conclusion, the field of jet impingement remains a significant area of research interest due to its extensive applicability and its potential to optimize a multitude of industrial processes.

Impinging jets, particularly air jets, find their most widespread application in the fields of heating and cooling. In modern technological systems, these jet flows are employed to cool devices and systems that produce substantial heat or operate at high temperatures. The configuration of these flows enables efficient heat and mass transfer at the impingement region, ensuring effective cooling of the target surface. One of the notable advantages of impinging jets is their ability to achieve high local heat transfer coefficients, making them highly effective for thermal management applications.

The impingement of the fluid on the target surface effectively reduces the thickness of the thermal boundary layer at the impinging zone, thereby enhancing heat transfer and significantly increasing the rate of both heat and mass transfer on the target surface [7].

Furthermore, the utilisation of impinging jets enables the achievement of elevated heat transfer rates with a reduced quantity of fluid, which in turn optimises energy efficiency and reduces operational costs.

Research focused on improving the efficiency of impinging jets has shown that various factors, such as jet fluid properties, jet geometry, configuration (single or multiple jets), surface roughness of the target surface, and the presence or absence of jet pulsation, can significantly affect the jet impingement process [8]–[10]. While these factors have predominantly been examined individually in the literature, studies addressing the combined effects of multiple parameters remain relatively limited. This study aims to comprehensively analyze the simultaneous effects of multiple critical parameters that are known to significantly influence the impingement phenomenon during a jet impingement event.

Asem and Mishra [11] performed a numerical study to analyze the heat transfer characteristics of a high-speed air jet impinging on a flat plate under a constant heat flux boundary condition. The findings revealed a direct correlation between the Reynolds number of the jet and the acceleration of the heat transfer rate. Furthermore, the researchers identified an optimal jet-to-plate distance, which is critical for maximizing heat transfer efficiency under controlled experimental conditions. San and Chen [12] investigated the Nusselt number distribution for five circular air jets impinging vertically on a flat surface. Study revealed that the range of maximum Nusselt numbers increased linearly as the spacing between the jets in the array was widened. Chougule et al. [13] conducted both experimental and numerical investigations into the fluid flow and heat transfer characteristics of multiple air jets impinging on a flat plate. The effects of Reynolds number, target spacing-to-jet diameter ratio, and the average Nusselt number on the target plate were examined using the SST $k-\omega$ turbulence model. The study concluded that the spacing between the air jets is a critical factor influencing the performance of multiple jet impingement systems. Similarly, Caliskan et al. [14] conducted both experimental and numerical studies to evaluate the effects of jet geometry on flow and heat transfer characteristics for elliptical and rectangular jet arrays. A thermal infrared camera was used to obtain detailed heat transfer measurements on smooth surfaces for both jet geometries. The velocity distributions obtained from numerical simulations allowed researchers to analyze the impact of jet geometry on flow dynamics and heat transfer characteristics. Additionally, numerical analyses were performed to investigate the time-dependent heat transfer performance of small-scale impinging jets at various Reynolds numbers and dimensionless H/D ratios, particularly in cases where significant temperature differences existed between the jet and the target plate.

Pakhomov et al. [15] conducted a numerical investigation to analyze the flow structure and heat transfer characteristics of a turbulent air jet impinging on a surface. The objective of their research was to investigate the impact of pulse frequency, jet-to-plate distance, and Reynolds number on the efficiency of heat transfer.

The findings indicated that heat transfer increases as the jet is positioned farther from the pipe edge and target surface. However, this effect diminishes when the distance becomes excessively large. Furthermore, it was determined that an elevated Reynolds number has a detrimental effect on the efficiency of heat transfer.

In the low-frequency range of the pulsed impinging jet, a reduction in heat transfer efficiency was observed in comparison to a steady-state impinging jet. Mladin and Zumbrennen [16] conducted experimental research to investigate the influence of flow oscillations on the complex local heat transfer characteristics of a flat air jet. Their study meticulously synchronized heat transfer measurements with thermal anemometry flow data, thereby enabling a detailed analysis of the intricate link between periodic flow structures and fluctuations and heat transfer dynamics. Sailor et al. [17] in their investigation, examined the effects of a pulsating air jet impinging on a heated surface by varying jet parameters such as jet-to-plate distance, Reynolds number, and pulsation frequency. Results demonstrated that the flow cycles generated by the pulsating impinging jet led to over a 50% increase in heat transfer. Similarly, Zulkifli et al. [18] studied the impact of pulsation frequencies from a heated circular air jet on local heat transfer. By analyzing the velocity profiles of both steady-state and pulsating air jets at frequencies of 10 and 20 Hz, they concluded that the Nusselt number for the pulsating jet was higher than that of the steady jet, as the elevated frequencies enhanced heat transfer efficiency.

Demircan and Türkoğlu [7] investigated the impact of diverse parameters, including the distance ratio between plates, jet velocity, pulsation amplitude, and frequency, on a pulsating air jet discharged from a rectangular nozzle situated on the upper plate and directed onto a heated lower plate within a system comprising two horizontally parallel infinite plates. The findings indicated that as the distance between the plates increased, the stagnation Nusselt number decreased; however, this decrease was minimal when the height-to-width (H/W) ratio exceeded 2. At lower H/W ratio values, the stagnation Nusselt number closely approximated that of a steady jet, while the Nusselt number for the pulsating jet exceeded that of the steady jet. Additionally, Zao and Cheng [19] conducted both experimental and numerical studies to investigate laminar pulsating forced convection in a long tube subjected to uniform heat flux and counterflow air conditions.

In their study, Demircan and Türkoğlu [20] performed a numerical analysis of the flow and heat transfer characteristics of pulsating air jets impinging on a flat surface, wherein the jet velocity demonstrated a sinusoidal variation over time. The numerical simulations examined the effects of Reynolds number, amplitude, and jet pulsation frequency on flow and heat transfer. The results indicated that the Nusselt number exhibited a moderate increase when the jet was pulsating in comparison to a steady-state jet. The principal objective of this study is to conduct a comprehensive investigation into the influence of diverse factors on the performance and characteristics of double impinging jets. Previous research has predominantly focused on analyzing these factors in the context of single jet flows. In contrast, this study seeks to investigate them collectively to provide a comprehensive understanding of their interactions and

combined effects on heat transfer and flow dynamics. In particular, this study focuses on key parameters, including jet geometry, flow characteristics, pulsating frequency and amplitude, nanoparticle volume concentrations, and Reynolds numbers, with the aim of evaluating their impact on heat transfer efficiency and the overall performance of double impinging jets.

Chaugule et al. [21] experimentally investigated the effects of applying pulsation to the impinging surface of a free turbulent jet on fluid dynamics and heat transfer. The study was conducted for two different Reynolds numbers and various conditions, including stationary and pulsating impinging surfaces. Selimefendigil and Öztop [22] conducted a numerical study on nanofluids involving pulsating rectangular jets. Various parameters, such as oscillation frequency, Reynolds number, and nanoparticle volume concentration, were numerically investigated to assess their effects on the fluid flow and heat transfer characteristics.

To achieve this objective, the study employs advanced numerical simulations using ANSYS to evaluate the effects of double impinging nanofluid jets on heat transfer and flow characteristics across a defined range of Reynolds numbers. In order to comprehensively analyze the problem, several key variables are taken into account, including the type of fluid, nanoparticle concentrations, jet geometry, and pulsating patterns. The study specifically utilizes aluminum oxide (Al₂O₃) nanofluids with varying volume concentrations of 1%, 2%, 4%, and 5%. This approach allows for the investigation of how varying concentrations of nanoparticles affect heat transfer performance, thereby providing valuable insights into the optimization of operational conditions for double impinging jet systems. In conclusion, the results of this study will contribute to a more comprehensive understanding of jet impingement dynamics and enhance the efficiency of thermal management applications.

Mathematical Model and Numerical Method

The reliability of turbulence models is contingent upon the utilization of adequately small mesh elements. Nevertheless, the use of excessively small elements can result in a notable increase in solution times. It is therefore imperative to select an appropriate element size. To investigate this, a mesh independence study was conducted. In the simulations, meshes comprising 200,000, 220,000, and 240,000 nodes were utilized. The resulting solutions facilitated the extraction of Nusselt numbers, and values from three of these meshes were employed to extrapolate the results as if an infinite number of nodes were available. This approach indicated that the results obtained from the mesh with 220,000 nodes reached an accuracy of 0.5%. To guarantee the dependability of the findings, it was imperative that all residuals be reduced to 10⁻⁸ or below by the conclusion of the computational run. Figure 1 depicts the comprehensive mesh structure, encompassing the number of nodes subjected to testing and a detailed representation of the mesh configuration.

To accurately simulate turbulent flow fields, this study proposes the numerical solution of the two-dimensional turbulent Navier-Stokes and energy equations using a finite-difference scheme, complemented by the continuity equation.




Figure 1. Mesh structure of model.

This approach employs an eddy viscosity model to capture the effects of turbulence under the assumption that the flow is steady, incompressible, and two-dimensional. Furthermore, this analysis excludes the effects of buoyancy and radiation heat transfer, thereby further simplifying the model. The governing equations for mass, momentum, turbulent kinetic energy, turbulent dissipation rate, and energy in a steady turbulent flow are formulated based on the standard κ - ϵ model, as described in detail below [23];

The momentum, continuity and energy equations, along with the equations of the turbulence model treated as constitutive equations, are presented in the following section [12], [13], [24].

Continuity equation

$$\frac{\partial U_i}{\partial x_i} = 0 \tag{1}$$

The momentum equations, which are the applied form of Newton's Second Law of Motion to fluids, or commonly known as the Navier-Stokes equations applicable for viscous incompressible fluids, are provided below.

$$\rho U_i \frac{\partial U_j}{\partial x_i} = - \frac{\partial P}{\partial x_j} + \frac{\partial}{\partial x_i} \left[\mu \left(\frac{\partial U_i}{\partial x_j} + \frac{\partial U_j}{\partial x_i} \right) - \rho \overline{u_i' u_j'} \right] \tag{2}$$

Energy equation

$$\rho c_p U_i \frac{\partial T}{\partial x_i} = \frac{\partial}{\partial x_i} \left[k \frac{\partial T}{\partial x_j} - \rho c_p \overline{u_i' T'} \right] \tag{3}$$

For the κ - ϵ model, in an incompressible flow, the turbulent kinetic energy κ and the dissipation rate ϵ are provided respectively [23].

$$\rho U_i \frac{\partial \kappa}{\partial x_i} = \frac{\partial}{\partial x_i} \left[\left(\mu + \frac{\mu_t}{\sigma_\kappa} \right) \frac{\partial \kappa}{\partial x_i} \right] + \mu_t \left(\frac{\partial U_i}{\partial x_j} + \frac{\partial U_j}{\partial x_i} \right) \frac{\partial U_i}{\partial x_j} - \rho \epsilon \tag{4}$$

$$\rho U_i \frac{\partial \varepsilon}{\partial x_i} = \frac{\partial}{\partial x_i} \left[\left(\mu + \frac{\mu_t}{\sigma_\varepsilon} \right) \frac{\partial \varepsilon}{\partial x_i} \right] + f_1 C_1 \mu_t \frac{\varepsilon}{k} \left(\frac{\partial U_i}{\partial x_j} + \frac{\partial U_j}{\partial x_i} \right) - f_2 C_2 \rho \frac{\varepsilon^2}{k} \quad (5)$$

In these equations, C_μ , C_1 ve C_2 are empirical constants, while σ_k ve σ_ε are the turbulent Prandtl numbers for the κ ve ε equations, respectively. The symbol μ_t denotes the dynamic viscosity of the fluid. The values of these constants within the turbulence model are specified in equations 4 and 5.

$$\sigma_k = 1, \sigma_\varepsilon = 1,314, C_1 = 1.44, C_2 = 1.92, c_\mu = 0.09, c_d = 0.1643 \quad (6)$$

These equations represent mathematical models that elucidate the behavior of fluids and mathematically model turbulence effects. The continuity equation expresses the conservation of mass for the fluid, while the momentum equations describe the fluid's motion. The energy equation is used to calculate the energy transformations of the fluid.

In contrast, turbulence model equations are supplementary equations utilized to quantify turbulence effects, with variations contingent upon the specific turbulence model in question.

The Reynolds number is calculated as follows:

$$Re = \frac{u D_h}{\nu} \quad (7)$$

Here u represents the jet inlet velocity, D_h hydraulic diameter of the jet, ν represents the kinematic viscosity.

The Nusselt number and local Nusselt number are determined using the following equations.

$$h = \frac{q}{T_w - T_j} \quad (8)$$

$$Nu = \frac{h D_h}{k} \quad (9)$$

Therefore;

$$Nu = \frac{q D_h}{k (T_w - T_j)} \quad (10)$$

In the equation, h represents the heat transfer coefficient, q denotes the constant heat flux, k is the thermal conductivity of the fluid, T_w represents the local temperature of the jet surface, and T_j denotes the temperature at the jet exit.

Determination of Boundary Conditions

Figure 2 illustrates the boundary conditions applied to the defined two-dimensional geometry. Within this framework, a custom function has been implemented in the ANSYS software to model the jet velocity, incorporating both a uniform velocity profile and sinusoidal pulsation. Specifically, the jet inlet temperature is set at 298 K, while the impingement surface is maintained at a constant temperature of 400 K. The exit of the jet is exposed to the surrounding environment, thereby applying a free-stream condition.

All other surfaces within the model are treated as adiabatic, indicating that no heat transfer occurs across these boundaries. This assumption streamlines the analysis by negating the loss or gain of heat through the walls. Moreover, the turbulence intensity at the inlet is set at 1%, which facilitates the precise representation of the initial conditions of the jet flow and its interaction with the impinging surface. It is imperative that these boundary conditions are met in order to guarantee the veracity of the numerical simulations and to ensure the reliability of the results obtained from the study of jet impingement behavior.




Figure 1. Boundary conditions

These conditions,

$$u = u_o + A u_o * \sin(ft) \quad (11)$$

$$T = T_c \quad (12)$$

The boundary conditions are employed for the purpose of establishing the velocity and temperature conditions at the jet inlet. The velocity equations demonstrate how the inlet velocity varies over time in relation to a specific function, while the temperature is assumed to remain constant, denoted as T_c . Adiabatic no-slip wall boundary conditions are applied to the upper walls.

$$u = 0, \quad v = 0, \quad \frac{\partial T}{\partial x} = 0 \quad (13)$$

It is crucial to acknowledge that the adiabatic no-slip wall boundary condition is implemented on the upper walls, signifying that heat transfer is not occurring at these surfaces and that the velocity gradient at the wall surface is zero. This boundary condition permits the transfer of momentum while preventing the transfer of thermal energy. Consequently, the velocity components at the wall surface are zero in the direction parallel to the wall, which results in no heat exchange. Such boundary conditions are frequently employed in the context of high-speed flows and scenarios where energy transfer is deemed to be insignificant. In accordance with these adiabatic conditions, no energy is exchanged at the upper wall, thereby influencing solely the momentum of the flow. This is a crucial point for understanding the behavior and interaction of the jet with the upper wall.

The boundary condition for the impinging surface of the jet is as follows;

$$u = 0, \quad v = 0, \quad T = T_h \quad (14)$$

The boundary conditions applied at the impinging surface of the jet are defined for the velocity components (u and v) and temperature (T). According to this boundary condition, the

velocity components at the impinging surface are assumed to be zero ($u = 0, v = 0$), indicating no-slip conditions. Furthermore, the temperature of the impinging surface is denoted as T_h , signifying that the surface is maintained at a constant temperature. This boundary condition ensures that the flow velocity is zero at the impinging surface, thereby establishing a stationary interaction between the fluid and the surface.

The boundary condition for the side surfaces of the geometry is as follows;

$$\frac{\partial u}{\partial x} = 0, \quad \frac{\partial v}{\partial x} = 0, \quad \frac{\partial T}{\partial x} = 0 \quad (15)$$

The aforementioned boundary conditions indicate that the flow and temperature along the side surfaces of the geometry remain constant in a specific direction, thereby suggesting that the side surfaces are open to the surrounding environment.

Following the model validation, an additional critical step was undertaken: the validation of the numerical study against existing literature. To this end, the accuracy of the numerical study was confirmed by replicating the parameters and features of the previous work conducted by Zumburmen et al. [25].

The results presented in Figure 3, which illustrate the variation of local Nusselt numbers across the average plate, demonstrate a high degree of consistency. It is noteworthy that a maximum discrepancy of 7% was observed between the local Nusselt numbers reported in the referenced study and those obtained from the current validation model. In conclusion, the findings demonstrate that ANSYS-FLUENT is an effective tool for conducting the numerical analyses planned for the subsequent phases of this research.




Figure 2. Comparison of numerical study with literature [25].

Results and Discussion

Figure 4 illustrates the time-dependent velocity contours for a pulsating jet with a height-to-diameter ratio (H/D) of 4, a Reynolds number (Re) of 7500, a frequency (f) of 20 Hz, and an amplitude (A) of 0.5 m/s. As the jet interacts with the surface, it immediately generates bidirectional swirling flows and reverse vortices in the stagnation region. The vortices undergo a process of evolution over time, exhibiting a trajectory that is parallel to the surface in the direction of flow. The formation of these vortices has the effect of enhancing the coefficients of heat transfer and increasing the Nusselt numbers.

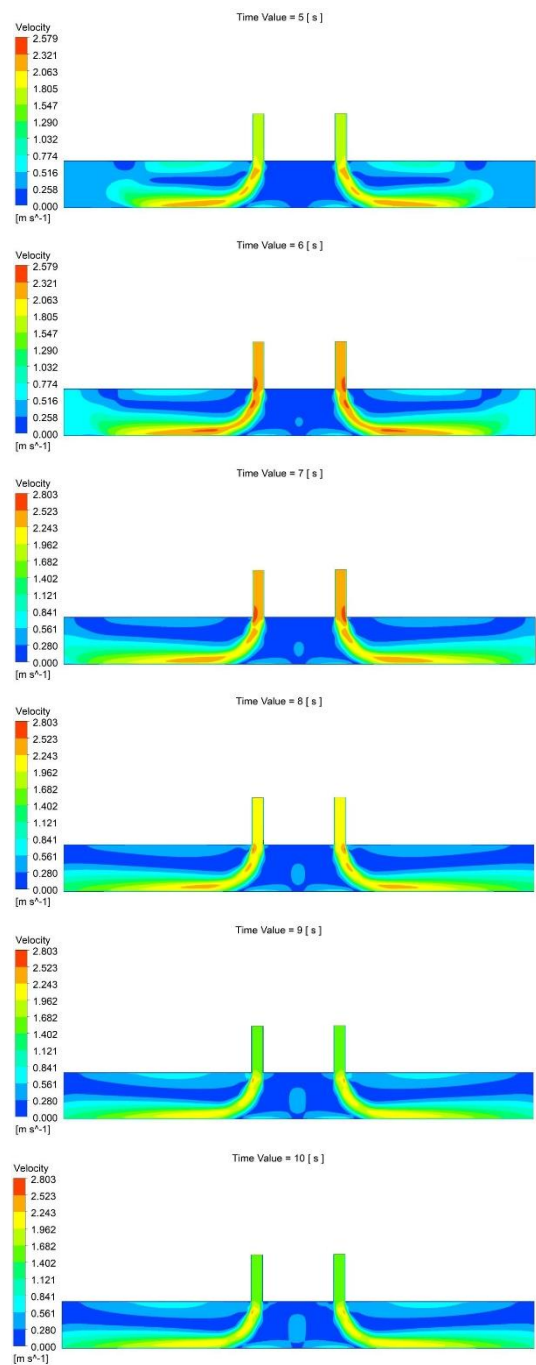


Figure 4. Time-dependent velocity contours of a dual impinging nanofluid jet with $H/D = 4, Re = 7500$ for $t = 5 - 10$ sn.

At the point of jet exit, the flow profile is initially uniform. However, as the jet ascends vertically, there is a notable change in the velocity distribution. The maximum velocity is observed along the axis of the jet, but upon contact with the lower plate, the velocity decreases to zero. Subsequently, the flow undergoes horizontal acceleration along the surface, resulting in the formation of a wall jet. Upon contact with the surface, the jet decelerates to zero, resulting in the formation of an internal vortex. This process ultimately results in the formation of a smaller vortex in close proximity to the target surface, accompanied by the emergence of another vortex in a downstream position.

It is noteworthy that the jet velocity does not reach zero throughout the entire flow period, which accounts for the limited formation of small vortices near the adiabatic wall and heated surface [26]. With regard to Reynolds numbers, a typical impinging jet exhibits characteristics analogous to those of a free jet, including a stagnation or impingement zone and a wall jet region.

the two jets make contact with the surface, the distance between them widens, indicating a divergence upon impact. Moreover, in the analyzed configuration, the adjacent jets remain independent of one another until they reach the impinging surface, resulting in the formation of separate vortices within each jet. Furthermore, the impinging surface causes the thermal boundary layer to experience peak velocities in its upper section, resulting in the formation of additional vortices. At the initial time point of $t = 5$ seconds, the vortices are relatively small in size. However, as time progresses, there is an observable increase in the size of these vortices. At the point of jet exit, the velocity reverts to a uniform profile.

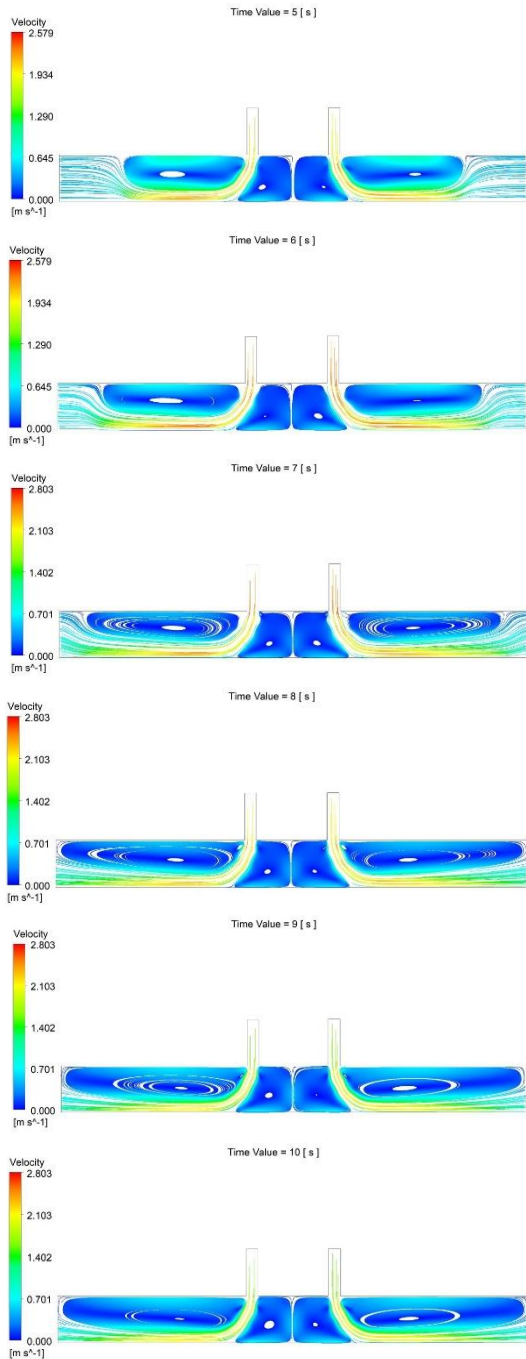


Figure 5. Time-dependent streamlines of a dual impinging nanofluid jet with a $H/D = 4$, $Re = 7,500$ for $t = 5 - 10$ sn.

Figure 5 illustrates the time-dependent streamlines of a dual jet configuration. It becomes evident that the velocity within the wall jet region increases upon impact with the impinging surface over time. Initially, the impinged surface maintains a constant temperature of 400 degrees Celsius. Upon impact, the jets induce a cooling effect on the impinging surface. As




Figure 6. Time-dependent vector representation of a dual impinging nanofluid jet with a $H/D = 4$, $Re = 7,500$ for $t = 5 - 10$ sn.

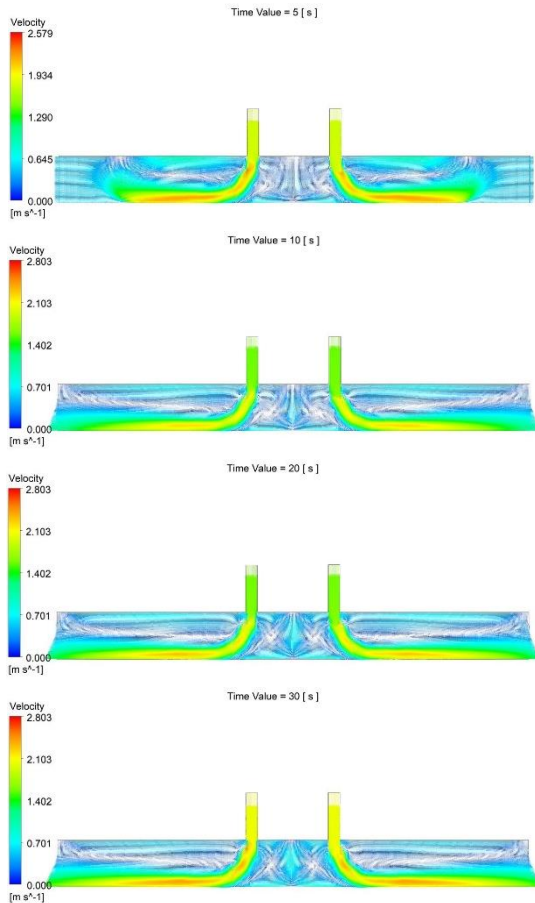


Figure 7. Time-dependent vector representation of a dual impinging nanofluid jet with a $H/D = 4$, $Re = 7,500$ for $t = 5 - 30$ sn.

Figures 6 and 7 illustrate the time-dependent vector fields for a dual pulsating jet with a height-to-diameter ratio (H/D) of 4, a Reynolds number (Re) of 7,500, a frequency (f) of 30 Hz, and an amplitude (A) of 0.4 m/s. Upon impacting the heated lower surface, the formation of two counter-rotating vortices becomes evident, resulting from confinement by the upper adiabatic plate and the inherent sensitivity of the jet. A symmetrical flow pattern is observed in both the flow and thermal fields, centered around the stagnation point.

While slight variations are discernible in the vector plots across different time intervals, the intensity of the vortices exhibits fluctuations. In the wall jet region, an increase in thickness is observed concomitant with a decrease in the normal component of velocity. Moreover, as the volume concentration of nanoparticles increases, the effective thermal conductivity of the nanofluid rises, resulting in enhanced cooling effects upon impingement and a more uniform temperature distribution, thereby improving heat transfer. Moreover, the frequency and amplitude of pulsating in the inlet velocity contribute to a denser arrangement of flow lines in this region, which significantly enhances heat transfer [27].

Figure 8. shows the local Nusselt number variation as a function of 's', the distance between the two jets in a dual-jet setup. The study investigates how the distance between jets affects the change in Nusselt number, with experiments

conducted for $H/D = 4$ and $Re = 10,000$. The findings demonstrate a direct correlation between the distance between the jets and the efficiency of heat transfer. A closer proximity between the jets facilitates enhanced interaction through vortex formation, which has a beneficial impact on the Nusselt number. Conversely, an increase in the distance between the jets has been observed to result in a decline in the Nusselt number.. As shown in Figure 8, the optimal local Nusselt number is achieved when 's' is set at 100 mm, indicating superior heat transfer performance compared to other distances.




Figure 8. Comparison of distances between dual impinging jets.

Figure 9 shows the variation of local Nusselt numbers for different nanoparticle volume concentrations for $Re = 5000$, $f = 20$ Hz, and $A = 0.5$ m/s. In the case of dual impinging jets, the collision generates two distinct peaks in the Nusselt number profile. The highest Nusselt value is observed at the stagnation point, where the thermal boundary layer is relatively thin, resulting in enhanced heat transfer. The incorporation of nanoparticles at varying concentrations markedly enhances the peak Nusselt value, suggesting an acceleration in heat transfer rates. Moreover, an increase in the volume concentration of nanoparticles results in a more pronounced improvement in heat transfer. In comparison to the scenario in the absence of nanoparticles, the Nusselt number demonstrates an 18% increase at a 5% volume concentration, a 16% increase at both 4% and 2% concentrations, and a 13% increase at a 1% concentration.




Figure 9. Local Nusselt number variation for different nanoparticle volume concentrations for $H/D = 4$ and $Re = 5,000$.

Figure 10 illustrates the impact of varying frequencies on the local Nusselt numbers for a dual impinging jet, with a Reynolds number of 7500 and an acceleration coefficient of 0.5 m/s. The occurrence of pulsating flow results in acceleration and elevated speeds, which contribute to augmented heat transfer due to the fact that a fluid with greater velocity carries more energy and interacts with the surface in a more efficacious manner. Pulsating flow has the potential to alter the temperature distribution by facilitating a more rapid and intense mixing between regions of differing temperatures, thereby promoting a more uniform temperature profile. These dynamics are of critical importance in the observed enhancement of heat transfer in pulsating flows. Pulsations facilitate more efficient mixing, enhance energy transport through accelerated fluid movement, and influence temperature distribution, ultimately leading to heightened heat transfer rates. It can be concluded that pulsating flow has a considerable effect on thermophysical performance and heat transfer efficiency [28], [29]. The data analysis indicates that the most substantial enhancement in heat transfer on the impinging surface occurs at a frequency of 30 Hz. A comparison of frequencies at 10 Hz and 30 Hz indicates a 10% increase in heat transfer efficiency. It can thus be concluded that pulsating jets with higher frequencies enhance heat transfer performance in the wall jet region, resulting in a more uniform heat distribution on the target surface, particularly in the vicinity of the stagnation point [26].




Figure 10. Local Nusselt number variation for different frequencies in a dual impinging jet with $Re = 7500$ and amplitude $A = 0.5$ m/s.

Figure 11 illustrates the variation in local Nusselt numbers for different amplitudes, with $Re = 7500$ and $f = 20$ Hz. While the results for all amplitudes are relatively similar, the amplitude of 0.5 m/s exhibits superior performance due to its wider distribution across the impinging surface. The pulsating flow enhances mixing, increases energy transport through accelerated fluid movement, and modulates temperature distribution, resulting in improved heat transfer rates. Therefore, pulsating flow significantly impacts thermophysical performance and heat transfer efficiency [28], [29].




Figure 11. Local Nusselt number variation for different amplitudes in a dual impinging jet with $Re = 7500$ and frequency $f = 20$ Hz.

Conclusion

In this study, the flow dynamics and heat transfer interaction in double-pulsed jets are investigated, focusing on key factors such as jet geometry, vibration frequency, amplitude, nanoparticle concentration and Reynolds numbers. Using advanced numerical simulations in ANSYS, the research investigates how these parameters affect the thermal and flow properties of pulsating nanofluid jets.

This study systematically analyses the impact of diverse factors on the performance and characteristics of double impinging jets, with a particular focus on the crucial interplay between flow dynamics and heat transfer efficiency. The research employs advanced numerical simulations with ANSYS to assess the influence of double impinging nanofluid jets across a defined range of Reynolds numbers. This comprehensive analysis encompasses a multitude of parameters, including jet geometry, pulsating frequency and amplitude, nanoparticle volume concentrations, and Reynolds numbers.

The time-dependent velocity contours of the pulsating jet demonstrate that as the jet makes contact with the surface, bidirectional swirling flows and reverse vortices are produced. These vortices expand and follow parallel paths along the flow direction, resulting in an increased heat transfer coefficient and elevated Nusselt number. The formation of wall jets is observed as the flow transitions from its initial smooth profile at the jet's exit. While the highest velocity is observed at the jet's axis, the impact with the surface results in deceleration and the formation of internal vortices, which contribute to the development of horizontal wall jets along the surface.

The frequency and amplitude of pulsating jets significantly influence heat transfer efficiency. Higher frequencies, such as 30 Hz, have been observed to result in a 10% improvement in heat transfer compared to lower frequencies like 10 Hz. This enhancement is attributed to improved flow dynamics and more uniform heat distribution facilitated by pulsation and the generation of associated vortices. Additionally, the concentration of nanoparticles plays a crucial role in heat transfer performance. For instance, a 5% volume concentration of nanoparticles led to an 18% increase in the Nusselt number compared to cases without nanoparticles,

highlighting the potential of nanoparticle augmentation to enhance heat transfer efficiency.

It would be beneficial to gain an understanding of the characteristics of the thermal boundary layer in order to elucidate the relationship between Reynolds numbers and heat transfer. It seems that an increase in Reynolds number may result in a reduction in the thickness of the boundary layer, thereby enhancing the rate of heat transfer.

It has been observed that the stagnation point exhibits peak Nusselt values due to the thin boundary layer, whereas regions devoid of vortices display lower Nusselt values. The spacing between dual impinging jets is identified as a critical parameter influencing heat transfer performance. Smaller distances between jets enhance vortex interactions, promoting more effective heat transfer, while larger separations weaken these interactions and reduce overall efficiency. This study establishes that an optimal spacing of approximately 100 mm yields the best heat transfer results, underscoring the importance of jet configuration in optimizing heat distribution and thermal efficiency. Moreover, the findings emphasize the need to optimize key parameters, including frequency, amplitude, nanoparticle volume concentration, and jet spacing, to significantly improve heat transfer and thermophysical performance across various applications.

References

- [1] Y. J. Chou and Y. H. Hung, "Impingement cooling of an isothermally heated surface with a confined slot jet," *J. Heat Transfer*, vol. 116, no. 2, pp. 479–482, May 1994, doi: 10.1115/1.2911422.
- [2] A. H. Beitelmal, M. A. Saad, and C. D. Patel, "The effect of inclination on the heat transfer between a flat surface and an impinging two-dimensional air jet," *Int. J. Heat Fluid Flow*, vol. 21, no. 2, pp. 156–163, Apr. 2000, doi: 10.1016/S0142-727X(99)00080-6.
- [3] Y. M. Chung, K. H. Luo, and N. D. Sandham, "Numerical study of momentum and heat transfer in unsteady impinging jets," *Int. J. Heat Fluid Flow*, vol. 23, no. 5, pp. 592–600, Oct. 2002, doi: 10.1016/S0142-727X(02)00155-8.
- [4] B. Sagot, G. Antonini, A. Christgen, and F. Buron, "Jet impingement heat transfer on a flat plate at a constant wall temperature," *Int. J. Therm. Sci.*, vol. 47, no. 12, pp. 1610–1619, 2008, doi: <https://doi.org/10.1016/j.ijthermalsci.2007.10.020>.
- [5] Z. Trávníček, P. Dančová, J. Kordík, T. Vít, and M. Pavelka, "Heat and mass transfer caused by a laminar channel flow equipped with a synthetic jet array," *J. Therm. Sci. Eng. Appl.*, vol. 2, no. 4, Feb. 2011, doi: 10.1115/1.4003428.
- [6] F. Afroz and M. A. R. Sharif, "Numerical study of heat transfer from an isothermally heated flat surface due to turbulent twin oblique confined slot-jet impingement," *Int. J. Therm. Sci.*, vol. 74, pp. 1–13, 2013, doi: <https://doi.org/10.1016/j.ijthermalsci.2013.07.004>.
- [7] T. Demircan and H. Turkoglu, "Numerical analysis of effects of the oscillation characteristics and the nozzle to plate distance on the flow and heat transfer in oscillating impinging jets," *Cilt*, vol. 25, no. 4, pp. 895–904, 2010.
- [8] N. Çelik, "Investigation of the effects of optimum nozzle type on the impinging jet", Ph.D. dissertation, Dept. Mech. Eng., Firat Univ., Elazığ, TR, 2006.
- [9] N. Çelik, D.W. Bettenhausen, D. Ryan Lovik, "Formation of Co-Axial jets and their downstream development", 2012.
- [10] N. Çelik, H. Eren, "Effects of stagnation region turbulence of an impinging jet on heat transfer", *J. Therm. Sci. Technol.*, vol. 30, pp. 91–98, 2010.
- [11] A. Nabadavis, D.P. Mishra, "Numerical investigation of jet impingement heat transfer on a flat plate, *Carbon - Sci. Technol.*, vol. 8, pp. 1–12, 2016.
- [12] J. Y. San and J. J. Chen, "Effects of jet-to-jet spacing and jet height on heat transfer characteristics of an impinging jet array," *Int. J. Heat Mass Transf.*, vol. 71, pp. 8–17, 2014, doi: 10.1016/j.ijheatmasstransfer.2013.11.079.
- [13] S. S. N. Chougule N.K., Parishwad G.V., Gore P.R., Pagnis S., "CFD Analysis of multi-jet air impingement on flat plate," 2011.
- [14] S. Caliskan, S. Baskaya, and T. Calisir, "Experimental and numerical investigation of geometry effects on multiple impinging air jets," *Int. J. Heat Mass Transf.*, vol. 75, pp. 685–703, 2014, doi: 10.1016/j.ijheatmasstransfer.2014.04.005.
- [15] M. A. Pakhomov and V. I. Terekhov, "Numerical study of fluid flow and heat transfer characteristics in an intermittent turbulent impinging round jet," *Int. J. Therm. Sci.*, vol. 87, pp. 85–93, 2015, doi: <https://doi.org/10.1016/j.ijthermalsci.2014.08.007>.
- [16] E. C. Mladin and D. A. Zumbrennen, "Local convective heat transfer to submerged pulsating jets," *Int. J. Heat Mass Transf.*, vol. 40, no. 14, pp. 3305–3321, 1997, doi: 10.1016/S0017-9310(96)00380-8.
- [17] D. J. Sailor, D. J. Rohli, and Q. Fu, "Effect of variable duty cycle flow pulsations on heat transfer enhancement for an impinging air jet," *Int. J. Heat Fluid Flow*, vol. 20, no. 6, pp. 574–580, 1999, doi: 10.1016/S0142-727X(99)00055-7.
- [18] R. Zulkifli, K. Sopian, S. Abdullah, and M. Takriff, "Comparison of local nusselt number between steady and pulsating jet at different jet reynolds number," 2009.
- [19] T. S. Zhao and P. Cheng, "Oscillatory heat transfer in a pipe subjected to a laminar reciprocating flow," *J. Heat Transfer*, vol. 118, no. 3, pp. 592–597, Aug. 1996, doi: 10.1115/1.2822673.
- [20] T. Demircan and H. Turkoglu, "The numerical analysis of oscillating rectangular impinging jets," *Numer. Heat Transf. Part A Appl.*, vol. 58, no. 2, pp. 146–161, 2010, doi: 10.1080/10407782.2010.496669.
- [21] Chaugule, V., Narayanaswamy, R., Lucey, A.D., Narayanan, V., Jewkes, J. (2018). Particle image velocimetry and infrared thermography of turbulent jet impingement on an oscillating surface. *Experimental Thermal and Fluid Science*. 98, 576–593.

- [22] Selimefendigil, F., Öztop, H.F. (2014). Pulsating nanofluids jet impingement cooling of a heated horizontal surface. *International Journal of Heat and Mass Transfer*. 69 54–65.
- [23] E. M. Alawadhi, “Meshing guide,” *Finite elem. simulations using ANSYS*, vol. 15317, no. November, pp. 407–424, 2020, doi: 10.1201/b18949-12.
- [24] “Fluent12,” *ANSYS FLUENT 12.0 User’s Guid.*, no. April, pp. 1–2070, 2009.
- [25] D. A. Zumbrunnen, F. P. Incropera, and R. Viskanta, “A laminar boundary layer model of heat transfer due to a nonuniform planar jet impinging on a moving plate,” *Wärme- und Stoffübertragung*, vol. 27, no. 5, pp. 311–319, 1992, doi: 10.1007/BF01589969.
- [26] P. Li, D. Guo, and R. Liu, “Mechanism analysis of heat transfer and flow structure of periodic pulsating nanofluids slot-jet impingement with different waveforms,” *Appl. Therm. Eng.*, vol. 152, pp. 937–945, Apr. 2019, doi: 10.1016/j.applthermaleng.2019.01.086.
- [27] G. A. Rao, M. Kitron-Belinkov, and Y. Levy, “Numerical analysis of a multiple jet impingement system,” *Proc. ASME Turbo Expo*, vol. 3, no. PART A, pp. 629–639, 2009, doi: 10.1115/GT2009-59719.
- [28] N. C. Roy, “Steady and Oscillating Characteristics of Natural Convection in an Enclosure,” *J. Thermophys. Heat Transf.*, vol. 35, no. 2, pp. 268–278, Oct. 2020, doi: 10.2514/1.T6117.
- [29] W. Liewkongsataporn, T. Patterson, and F. Ahrens, “Pulsating jet impingement heat transfer enhancement,” *Dry. Technol.*, vol. 26, no. 4, pp. 433–442, 2008, doi: 10.1080/07373930801929268.



Investigation of The Effect of Radius of Curvature on Buckling Load in Thin-Walled Beams

Cenk YANEN*

Firat University, Mechanical Engineering Department, cyanen@firat.edu.tr, Orcid No: 0000-0002-5092-8734

ARTICLE INFO

Article history:

Received 25 October 2024
Received in revised form 25 November 2024
Accepted 29 November 2024
Available online 23 December 2024

Keywords:

buckling, thin-walled beam, post-buckling, finite element analysis

Doi: 10.24012/dumf.1573700

* Corresponding author

ABSTRACT

This study examines the effect of curvature radius on the buckling behavior of thin-walled beams, which are commonly used in aerospace, automotive, and structural engineering due to their high strength-to-weight ratios. The buckling phenomenon, which represents a critical failure mode for thin-walled hat-shaped structures, was investigated under axial loading through the utilization of numerical methods. A nonlinear analysis was conducted using ANSYS Workbench to model three distinct geometries with varying curvature angles and identical dimensions. The models were subjected to analysis in order to ascertain the critical buckling loads and reaction forces at a displacement of 1 mm, with a particular focus on both nonlinear and post-buckling behavior. Given its importance in structural applications, Aluminum Alloy NL was selected as the material. The eigenvalue buckling analysis identified the critical loads for the first ten modes, revealing that models with higher curvature angles demonstrated more stable buckling characteristics, whereas those with smaller angles were more prone to local deformation. A post-buckling analysis was conducted to ascertain the nonlinear load-bearing capacities of these structures.

Introduction

Hat-profile structural elements are of critical importance in the design of thin-walled structures in engineering, providing stability under a variety of loading conditions. One of the most notable characteristics of these structures is their capacity to combine lightweight properties with high strength. Hat profiles are commonly employed in fields such as aerospace, automotive, marine, and construction, as they effectively distribute forces across a wide surface area. These elements demonstrate high resilience against impact loads, rendering them particularly well-suited for critical functions such as energy absorption in the event of a collision. The utilization of such profiles in aircraft fuselages, wing structures and rocket components is intended to ensure the maintenance of structural integrity while simultaneously reducing weight. The aforementioned structural elements in aircraft fuselages serve to enhance resistance to dynamic loads, including pressure, tension, and impact, which are experienced during flight [1]–[3]. In the automotive industry, hat-shaped profiles are employed in the construction of chassis structures and in the context of crash testing scenarios. Their function is to absorb impact energy, thereby enhancing passenger safety [4]–[6]. One of the most significant engineering challenges faced by hat-

shaped structural elements is that of buckling. Buckling occurs when a structure loses stability under axial loads, resulting in sudden deformation, which can be particularly hazardous for thin-walled structures. It is of paramount importance to enhance the resistance of structural elements to buckling in order to ensure safety and efficiency. The buckling process is typically analyzed in three stages: pre-buckling, critical buckling and post-buckling. In the pre-buckling stage, the structure displays elastic behavior in response to the applied load and remains stable. Upon reaching the critical buckling stage, the structure experiences a sudden loss of stability, resulting in the onset of deformations. In the post-buckling stage, the structure may continue to bear loads, but the deformations that occur at this stage are permanent and significantly impact the structure's durability. In sectors such as aerospace and automotive, the load-bearing capacity of a structure following buckling is regarded as a pivotal aspect of the design process [7], [8]. The curvature angle of hat-shaped structural elements represents a pivotal parameter that exerts a direct influence on the buckling behavior of such elements. Variations in curvature angle have a direct impact on both the critical buckling load and the post-buckling load-bearing capacity of the structure. In a study conducted by Masood et al., the post-buckling behavior of thin

composite stiffened panels employed in the construction of aircraft fuselages was subjected to experimental investigation. The buckling and post-buckling performance of thirteen panels, designed with various stiffener configurations (T-type, I-type, and J-type), were examined in order to gain insight into the effects of these configurations on the panels' structural behavior [9]. The buckling and post-buckling behaviors of composite panels with M-type stiffeners were investigated by Liu et al. The mechanical stabilities of panels commonly used in aircraft were determined using optical measurement methods and the finite element method [10]. In a study conducted by Wang et al., the stability behaviors of hat-stringer stiffened composite panels were examined both experimentally and through numerical analyses. Two test panels were produced, and the buckling load and ultimate load-carrying capabilities of these panels were determined numerically and compared with experimental results [11]. Hou et al. conducted impact tests on hat-shaped T-joints with weights dropped at three different impact velocities. A nonlinear finite element analysis was conducted to predict the damage and energy dissipation characteristics [12]. The buckling and post-buckling behaviors of hat-stringer reinforced composite flat panels subjected to axial compression were investigated by Mo et al. Based on the experimental data, the stability and deformation processes of the reinforced panel and the hat-stringer were analyzed. To assess the suitability of the hat-stringer section, five different models were evaluated using ABAQUS software [13]. The effects of curved surface composites under impact loads were investigated in a study by Albayrak et al., with a particular focus on their impact on energy dissipation [14]. Hat-shaped structural elements demonstrate high durability not only against axial loads but also against impact and pressure loads. In particular, these profiles are effective in absorbing impact energy while maintaining structural stability in aircraft fuselages. The accurate analysis of both buckling and post-buckling behaviors is essential for ensuring structural stability.

In this context, a precise understanding of the effects of curvature angle is essential for the optimization of structures. In this study, the buckling and post-buckling behaviors of hat-shaped samples with three different curvature angles were investigated numerically using the same geometries employed in the work by Albayrak et al. [14]. Subsequent to the buckling analysis, a post-buckling analysis was conducted to ascertain the load-carrying capacity of the structures in question following the buckling event. Nonlinear analyses conducted using ANSYS Workbench software facilitated a comprehensive assessment of the influence of curvature angle on structural performance.

Material and Method

This study examines the buckling behavior and post-buckling responses of hat-shaped structural elements under varying curvature angles through the use of numerical methods. The profiles under examination are defined by a hat-shaped geometry, which is a prototypical example of thin-walled structures, and were analyzed using a nonlinear

material model. This section presents the sample geometry, material properties, boundary conditions, and the applied numerical analysis methods.

Model Geometry and Material Properties

In the study, hat-shaped models with a fixed sample width ($w = 150$ mm), fixed wall thickness ($t = 1$ mm), and fixed sample height ($h = 25$ mm) were examined. The length of the samples was fixed at $l = 200$ mm, and three distinct curvature angles were employed. For illustrative purposes, the model geometry is depicted in Figure 1. The numerical analysis was conducted using the Aluminum Alloy NL material, which is available in the ANSYS Workbench library. The selected material's mechanical properties are presented in Table 1.

Table 1. Mechanical properties of Aluminum Alloy NL [15]

Material properties	Value
Density (kg/m ³)	2770
Young's Modulus (Pa)	7.1E+10
Poisson's Ratio	0.33
Bulk Modulus (Pa)	6.9608E+10
Shear Modulus (Pa)	2.6692E+10
Yield Strength (Pa)	2.8E+08
Tangent Modulus (Pa)	5E+08

Numerical Analysis and Boundary Conditions

Transformations in the deformation characteristics of numerous elements subjected to loading can result in the destabilization of the deformation state, thereby prompting the system to seek a new stable state. The stable state of a system is defined by its capacity to predict the post-deformation condition, whereas an unstable state is characterized by uncertainty following deformation. The analysis of perfect plates is conducted within the framework of the theory of small deformations, with the assumption that there is no midplane deformation of the plate element due to loading. In contrast, imperfect plates are examined in accordance with the "Great Deformation Theory of Plates," as developed by Von Karman. This theory takes into account the shape changes occurring in the midplane of the differential element during the analysis. In this study, an eigenvalue buckling analysis was conducted to determine the critical buckling loads for the first ten modes of the models. The boundary conditions employed in the analysis are depicted in Figure 2. The results of the analysis yielded load multiplier values for the first ten modes, which were then employed in the calculation of critical buckling loads using the following equation:

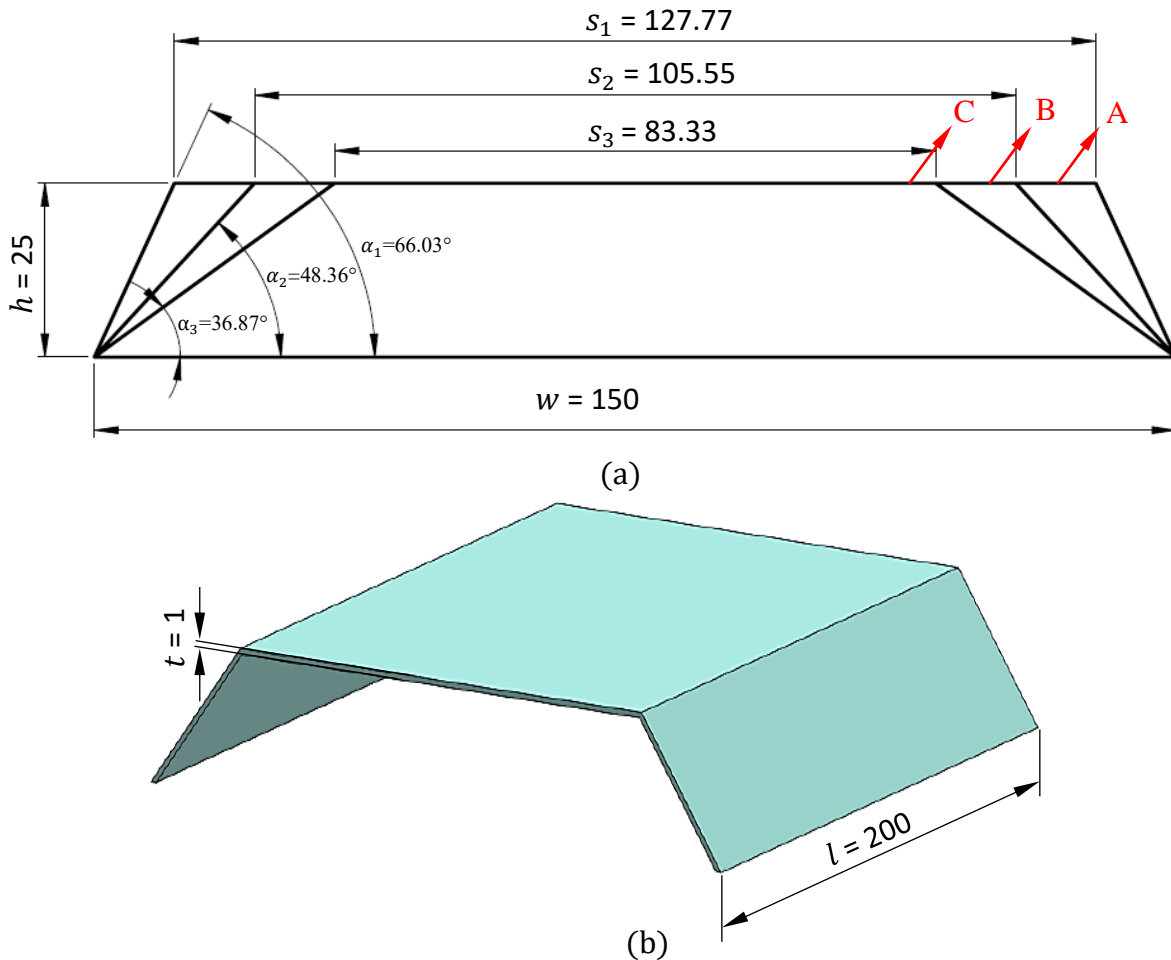


Fig. 1. Model geometries a) dimensions [14] b) solid model

$$\text{Critical buckling load (N)} = \text{Load multiplier} * \text{Force applied (N)}$$

In this study, a post-buckling analysis of a hat-shaped plate was conducted using the ANSYS Workbench. A nonlinear buckling analysis was conducted using both the static structural and eigenvalue buckling modules. The results of a previous eigenvalue buckling analysis of the stiffened plate were incorporated into the static structural module to investigate post-buckling behavior. A displacement range of 1 mm was applied to analyses the post-buckling response and identify the load at which collapse occurs. In the course of the analysis, the scale factor value was selected to be 0.004. The boundary conditions utilized in the numerical analysis are illustrated in Figure 3.

Results and Discussion

The buckling analysis revealed that the buckling behaviors of the three models differed due to their distinct geometric properties. Model A exhibited a more uniform and centralized buckling shape due to its wide upper surface (127.77 mm) and large curvature angle (66.03°). In the initial mode, the distribution of buckling exhibited greater uniformity, whereas higher modes demonstrated a tendency towards localized deformation. Model B, with a narrower

upper surface (105.55 mm) and a lower curvature angle (48.36°), exhibited a more intricate and undulating buckling behavior. The fluctuations observed from the third mode onward indicate that this structure was subjected to greater localized deformation due to its lower curvature angle. Model C, distinguished by the narrowest upper surface (83.33 mm) and the lowest curvature angle (36.87°), exhibited the most intricate buckling behavior. In the initial mode, smaller cellular structures were observed, while pronounced fluctuations occurred in subsequent modes. This outcome demonstrates that the low curvature angle and narrow upper surface result in heightened localized deformation during buckling.

Figure 5 presents a comparative graph of the critical buckling loads obtained for the initial ten modes following the non-linear buckling analysis. Upon examination of the variation in critical buckling loads among the modes, a distinct trend difference is observed. In the initial three modes, Model C exhibits the highest buckling loads. However, as the modes progress, this ranking shifts to $B > A > C$. The observation that Model C, which has the smallest curvature angle, endures higher buckling loads in the initial three modes suggests that structures with lower curvature angles demonstrate enhanced rigidity and resistance to minor deformations.




Fig. 2. Eigenvalue Buckling analysis boundary conditions




Fig. 3. Post-buckling analysis boundary conditions

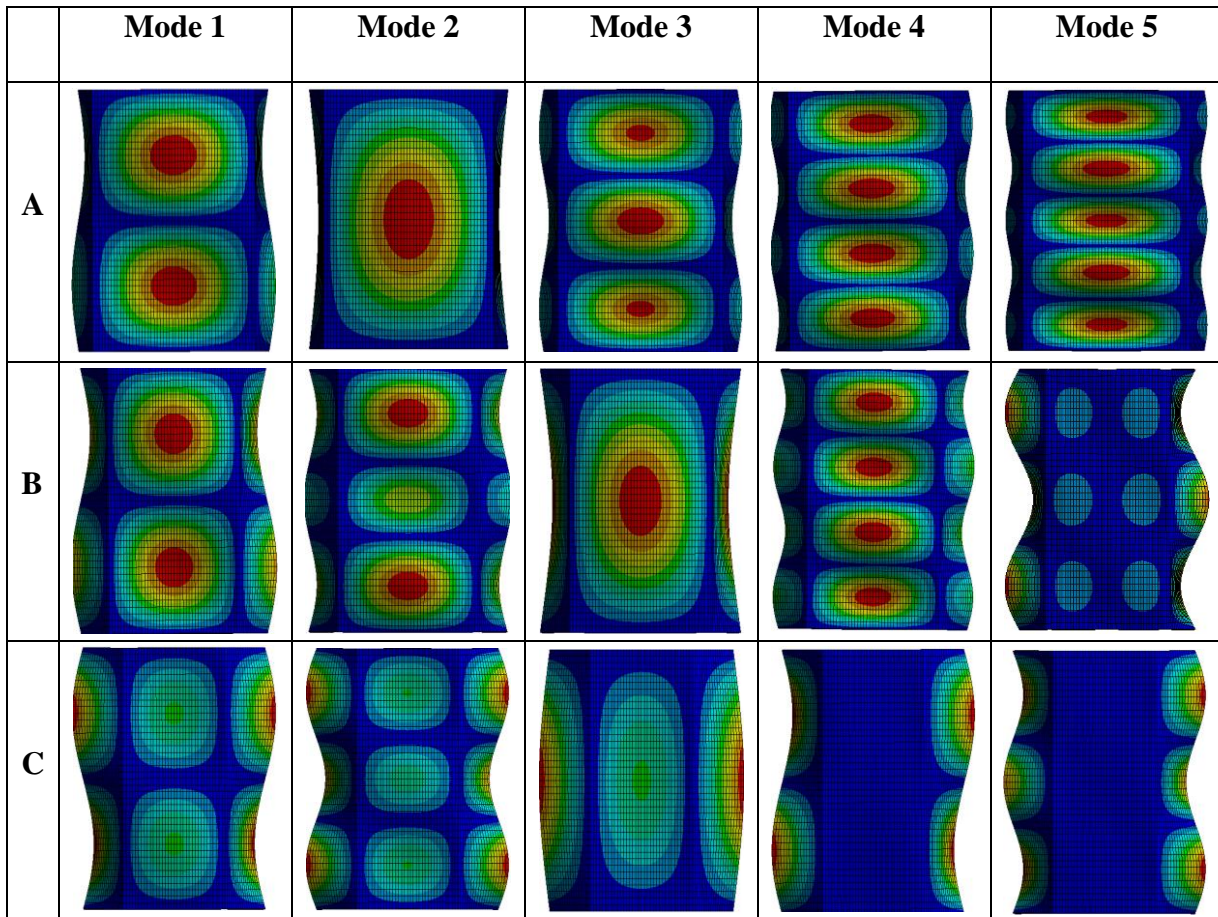


Fig. 4. The first 5 mode shapes of models A, B and C

The Model A's larger curvature angle results in a more flexible structure, enabling it to withstand lower buckling loads. In the fourth mode, Model B demonstrates superior performance, which can be attributed to its medium curvature angle. The occurrence of complex buckling modes serves to elucidate the stability conditions operative in disparate regions of the structures. During this phase, while Model C's high performance in the initial modes declines, Model B maintains a more balanced performance. In the fifth and tenth modes, it has been determined that the large curvature angle of Model A contributes to its greater resilience against buckling. As advanced modes represent complex buckling modes, larger curvature angles facilitate a more uniform distribution of the buckling load, thereby enabling Model A to withstand higher buckling loads. These findings demonstrate that the mode number and curvature angle have a complex interaction with regard to buckling loads, underscoring the importance of considering these loads in different modes during the structural design phase to ensure the creation of optimized and safe structures.

The load-end shortening graph, obtained from the post-buckling analysis, is presented in Figure 6. Upon examination of the graph, it can be observed that the initial increase in load corresponds to a linear relationship with the shortening of the end section, indicating that the structure is operating within its elastic region. This demonstrates that

the structural element functions elastically, and as the load magnitude increases, the deformation also increases in proportion.

This linear relationship persists up to a load value of approximately 4000 N, after which a nonlinear behavior is observed. This suggests that the structural element has exceeded its elastic limit and is approaching a state of instability. At this point, the stability of the structure is compromised, and deformation accelerates. It is noteworthy that the load reaches its peak between 0.6 and 0.7 mm and then begins to decline. This indicates that the critical buckling load has been exceeded, resulting in a transition to an unstable state. The observation that increases in load result in significant deformations despite minimal changes indicates a reduction in the structure's rigidity and a complexity in post-buckling behavior.

Notwithstanding the geometric discrepancies among the models, the load-deformation behaviors remain largely analogous, thereby indicating that the models do not exhibit appreciable differences in overall stability and rigidity. The maintenance of fundamental geometric parameters, such as base width and height, has been identified as a primary factor influencing the resistance to buckling. Nevertheless, alterations in the radius of curvature have led to minor discrepancies in peak load capacity and slight divergences in post-buckling behavior.




Fig. 5. Comparison of critical buckling loads in the first 10 modes of models A, B, and C




Fig. 6. Comparison of load-end shortening curves for models A, B, and C

Conclusion

Buckling represents a significant factor affecting structural stability and is a critical design parameter, particularly in the context of thin-walled structures. The buckling capacity of structures is contingent upon not only the material properties but also the geometric parameters. Accordingly, the impact of geometric variables, including curvature angle and upper surface width, on the buckling behavior of structures has prompted the present investigation. In this study, the buckling behaviors of hat-shaped structural

elements, modeled using aluminum alloy NL with varying geometric properties, have been investigated in detail. The findings of the study can be summarized as follows:

- Structures with a large curvature angle demonstrate a more uniform buckling behavior, whereas models with a low curvature angle exhibit more intricate and localized deformations.
- The results of the analyses conducted on hat-shaped structural elements with different curvature angles

demonstrate that the curvature angle has a significant influence on both the buckling load and the post-buckling behavior.

- In the initial three modes, Model C displays the highest buckling loads. However, as the mode number increases, Model B demonstrates a more balanced performance. This suggests that the influence of curvature angle on buckling loads is mode-dependent.

- As the modes progress, it has been determined that Model A's wider curvature angle distributes the buckling load more uniformly, thereby enabling it to withstand higher buckling loads.

- In the post-buckling analyses conducted, the load-deformation curves obtained for the three models exhibited similarities. Despite the presence of geometric differences, all models demonstrated linear behavior up to approximately 4000 N, followed by a nonlinear transition. While minor deviations in peak load values were observed due to slight differences in curvature angle, the overall behaviors remained largely similar.

The findings of this study offer substantial insights with practical implications for engineering disciplines such as aeronautical and automotive engineering. In particular, within the field of aviation, the optimization of curvature angle has the potential to facilitate the creation of aircraft fuselages and wing structures that are both lightweight and durable. In the automotive industry, the determination of design parameters with the objective of enhancing energy absorption capacity can be of paramount importance with regard to crash safety.

References

- [1] B. G. Falzon, "The behaviour of damage tolerant hat-stiffened composite panels loaded in uniaxial compression," *Compos. Part A Appl. Sci. Manuf.*, vol. 32, no. 9, pp. 1255–1262, 2001, doi: [https://doi.org/10.1016/S1359-835X\(01\)00074-4](https://doi.org/10.1016/S1359-835X(01)00074-4).
- [2] B. G. Prusty, "Free vibration and buckling response of hat-stiffened composite panels under general loading," *Int. J. Mech. Sci.*, vol. 50, no. 8, pp. 1326–1333, 2008, doi: <https://doi.org/10.1016/j.ijmecsci.2008.03.003>.
- [3] A. Nagesh, O. Rashwan, and M. Abu-Ayyad, "Optimization of the Composite Airplane Fuselage for an Optimum Structural Integrity." Nov. 09, 2018. doi: 10.1115/IMECE2018-88215.
- [4] E. G. Koricho and G. Belingardi, "An experimental and finite element study of the transverse bending behaviour of CFRP composite T-joints in vehicle structures," *Compos. Part B Eng.*, vol. 79, pp. 430–443, 2015, doi: <https://doi.org/10.1016/j.compositesb.2015.05.002>.
- [5] W. Hou, X. Xu, H. Wang, and L. Tong, "Bending behavior of single hat-shaped composite T-joints under out-of-plane loading for lightweight automobile structures," *J. Reinf. Plast. Compos.*, vol. 37, no. 12, pp. 808–823, Apr. 2018, doi: [10.1177/0731684418764608](https://doi.org/10.1177/0731684418764608).
- [6] W. Hou, X. Xu, X. Han, H. Wang, and L. Tong, "Multi-objective and multi-constraint design optimization for hat-shaped composite T-joints in automobiles," *Thin-Walled Struct.*, vol. 143, p. 106232, 2019, doi: <https://doi.org/10.1016/j.tws.2019.106232>.
- [7] S. Mesmoudi, M. Rammene, Y. Hilali, O. Askour, and O. Bourihane, "Variable RPIM and HOCM coupling for non-linear buckling and post-buckling analysis of transverse FG sandwich beams," *Structures*, vol. 53, pp. 895–907, 2023, doi: <https://doi.org/10.1016/j.istruc.2023.04.103>.
- [8] P. Hao, K. Zhang, D. Liu, X. Wang, S. Feng, and B. Wang, "Intelligent design and buckling experiment of curvilinearly stiffened thin-walled structures," *Int. J. Solids Struct.*, vol. 293, p. 112737, 2024, doi: <https://doi.org/10.1016/j.ijsolstr.2024.112737>.
- [9] S. Nadeem Masood, S. R. Viswamurthy, and K. M. Gaddikeri, "Composites airframe panel design for post-buckling – An experimental investigation," *Compos. Struct.*, vol. 241, p. 112104, 2020, doi: <https://doi.org/10.1016/j.compstruct.2020.112104>.
- [10] X. Liu, K. Han, R. Bai, Z. Lei, and H. Wang, "Buckling measurement and numerical analysis of M-type ribs stiffened composite panel," *Thin-Walled Struct.*, vol. 85, pp. 117–124, 2014, doi: <https://doi.org/10.1016/j.tws.2014.08.008>.
- [11] Y. Wang, F. Wang, S. Jia, and Z. Yue, "Experimental and numerical studies on the stability behavior of composite panels stiffened by tilting hat-stringers," *Compos. Struct.*, vol. 174, pp. 187–195, 2017, doi: <https://doi.org/10.1016/j.compstruct.2017.04.039>.
- [12] W. Hou, X. Xu, L. Sang, and L. Tong, "Failure of single hat-shaped thin-walled tubular composite T-joints under impact loading," *Thin-Walled Struct.*, vol. 154, p. 106815, 2020, doi: <https://doi.org/10.1016/j.tws.2020.106815>.
- [13] Y. Mo, D. Ge, and B. He, "Experiment and optimization of the hat-stringer-stiffened composite panels under axial compression," *Compos. Part B Eng.*, vol. 84, pp. 285–293, 2016, doi: <https://doi.org/10.1016/j.compositesb.2015.08.039>.
- [14] M. Albayrak, M. O. Kaman, and I. Bozkurt, "Experimental and Numerical Investigation of the Geometrical Effect on Low Velocity Impact Behavior for Curved Composites with a Rubber Interlayer," *Appl. Compos. Mater.*, vol. 30, no. 2, pp. 507–538, 2023, doi: [10.1007/s10443-022-10094-5](https://doi.org/10.1007/s10443-022-10094-5).
- [15] "ANSYS Academic Release 2020, Workbench Material Library."



Ultrasonik Emülsifikasyonun Kömürün Yağ Aglomerasyonuna Etkisi

Effect of Ultrasonic Emulsification on Oil Agglomeration of Coal

Ercan Şahinoğlu^{1*}

¹ Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Maden Mühendisliği Bölümü, ercansahinoglu@ktu.edu.tr
ORCID: <https://orcid.org/0000-0001-8881-2553>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 20 Mart 2024
Revizyon 26 Eylül 2024
Kabul 4 Kasım 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

Kömür, Yağ Aglomerasyonu, Atık Yağ, Ultrasonik Emülsifikasyon

ÖZ

Son yıllarda, kömür madenciliği teknolojisi büyük ölçüde mekanize edilmiş, bu da üretilen kömürde önemli oranda ince kömür içeriğine neden olmuştur. İnce kömürlerde temizlenmeden doğrudan kullanıldığında ciddi hava kirliliğine ve katı atıklara yol açarak çevre için büyük bir risk oluşturabilir. Bu nedenle, ince kömürün kullanılmadan önce temizlenmesi çok önemlidir. Yağ aglomerasyonu, ince boyutlu kömürlerin temizlenmesinde kullanılan yöntemlerden biridir. Ancak, bu yöntemde kullanılan yağ miktarının fazla olması nedeniyle yöntem genellikle ekonomik olarak uygun görülmemektedir. Bu sorunu çözmek için, yöntemde bağlayıcı olarak kullanılacak yağın sisteme emülsifiye edilerek verilmesi veya bağlayıcı olarak atık yağların kullanılması olabilir. Yağların sisteme emülsifiye edilerek verilmesi yöntemde kullanılan yağ miktarını azaltabilir. Böylelikle yöntemin en büyük dezavantajı olan yağ maliyeti azaltılabilir. Son yıllarda yağların emülsifikasyonunda ultrasonik dalgalar kullanılmaya başlanmıştır. Bu çalışmada, çok ince boyutlu yüksek kül-kükürt içerikli kömür bitkisel atık yağ ile aglomerasyon işlemine tabi tutulmuştur. Atık yağ emülsifiye edilerek ve emülsifiye edilmeden aglomerasyon deneyleri yapılmış olup elde edilen sonuçlar karşılaştırılmıştır. Ultrasonik cihazla emülsifiye edilen atık yağ (%10 yağ miktarı) ile aglomerasyon deneyi yapıldığında en yüksek yanabilir verim değeri %93,46 olarak elde edilmiştir. Atık yağ emülsifiye edilmeden yapılan aglomerasyon deneyinde ise yanabilir verim değeri %82,87 olarak bulunmuştur. Kül giderimi değerleri ise %39,17-46,92 arasında değişmiştir.

ARTICLE INFO

Article history:

Received 20 March 2024
Received in revised form 26 September 2024
Accepted 4 November 2024
Available online 23 December 2024

Keywords:

Coal, Oil Agglomeration, Waste Oil, Ultrasonic Emulsification

ABSTRACT

In recent years, coal mining technology has been largely mechanized, resulting in significant fine coal content in the coal produced. Direct use of fine coals without cleaning can lead to serious air pollution and solid waste, posing a major risk to the environment. Therefore, it is very important to clean fine coal before use. Oil agglomeration is one of the methods used to clean fine coal. However, due to the high amount of oil used in this method, the method is generally not economically viable. The way to solve this problem is to emulsify the oil to be used as a binder in the method or to use waste oil as a binder. Emulsifying the oils into the system can reduce the amount of oil used in the method. Thus, the oil cost, which is the biggest disadvantage of the method, can be reduced. In recent years, ultrasonic waves have been used in the emulsification of oils. In this study, very fine sized coal with high ash-sulfur content was subjected to agglomeration process with vegetable waste oil. Agglomeration experiments were carried out with and without emulsifying waste oil and the results obtained were compared. When the agglomeration experiment was performed with waste oil emulsified with ultrasonic device (10% oil content), the highest combustible recovery value was 93.46%. In the agglomeration experiment without emulsifying the waste oil, the combustible recovery value was 82.87%. Ash rejection values ranged between 39.17-46.92%.

Doi: 10.24012/dumf.1455988

* Sorumlu Yazar

Giriş

Kömür, en önemli enerji hammaddelerinden biridir. Temiz kömür üretimi, kömürün kullanımı için çok önemli olmakla birlikte sadece kömür kullanımı verimliliğini artırmakla kalmaz aynı zamanda çevreye zarar verebilecek maddelerin emisyonunu da azaltır. Mekanize edilmiş kömür madenciliği teknolojisi ile kömür üretimi yapılırken önemli miktarda ince kömür ortaya çıkmakta olup bu kömürlerin kül içerikleri yüksek olabilmektedir. Dolayısıyla bu kömürlerin kullanılmadan önce temizlenmesi gerekmektedir [1]. İnce kömürlerin temizlenerek ekonomiye kazandırılmasının avantajları, temizlenmemiş haldeki çevresel riskleri göz önünde bulundurduğunda, ince kömürlerin günümüzde temizlenerek değerlendirilmesinin çok önemli olduğu ortaya çıkmaktadır [2]. Flotasyon ve yağ aglomerasyonu yöntemi ince boyutlu kömürlerin temizlenmesinde kullanılabilen iki tekniktir. Ancak, flotasyonundan farklı olarak, yağ aglomerasyonu yöntemi 400 mesh'in altındaki kömürlerde, düşük kaliteli ve oksitlenmiş kömürlerin temizlenmesinde etkin bir şekilde kullanılabilen bir tekniktir. Yağ aglomerasyon prosesinin diğer avantajları arasında kömür kazanımını kolaylaştıran aglomeratların oluşması, işlemin basitliliği [3], düşük nem ve düşük kükürt içeriğine sahip ürünler oluşturması bulunmaktadır [4]. Bu yüzey özelliğine dayalı teknik, karıştırma altında kömür-su pülpüne karışmayan yağ ilavesini içerir ve aglomeratların elde edilmesi ile sonuçlanır. İşlem sırasında, hidrofilik mineral madde su fazında kalarak aglomeratlardan ayrılır. Bu tekniğin kömür türü, kömür tane boyutu, katı oranı, yağ türü, yağ dozajı, karıştırma hızı, aglomerasyon süresi, sıcaklık, pH ve ultrasonik işlem gibi bir dizi faktörden etkilendiği bulunmuştur [3].

Kömürün yağ aglomerasyonu yönteminde gaz yağı, mazot ve bitkisel yağlar bağlayıcı olarak kullanılabilir [5]. Yöntemde bağlayıcı olarak kullanılan yağların maliyeti yağ aglomerasyon sürecinin en büyük engelleyici yönüdür [2], [6],[7]. Bir ince kömür aglomerasyon prosesinin ekonomik uygulanabilirliğini etkileyen ana faktör saf yağ bağlayıcının maliyetidir. Başarılı bir aglomerasyon prosesi için ağırlıkça %10-20'lik bir dozaj gereklidir. Kesin dozaj elbette kömür beslemesinin özelliklerine bağlıdır, ancak her durumda aglomeratlar içindeki boşlukları doldurmak ve bir dereceye kadar hidrofobik partiküllerin yüzey kaplamasını sağlayabilmek için yeterli bağlayıcı hacmi mevcut olmalıdır. Kapiler durum olarak bilinen bu doymuş durum, aglomerat mukavemeti ve küreselliği açısından önemlidir. Ağırlıkça %10-20'nin altındaki dozajlarda aglomeratların yapısal bütünlüğünün sağlam olmaması aglomeratların kazanılması esnasında parçalanmalara neden olabileceğinden proses verimini düşürebilir [6].

Yağ aglomerasyonu yönteminde bağlayıcı olarak kullanılabilen yağlar, suda çözünemediklerinden ve de oldukça fazla viskozitelerinden ötürü kömür taneleri ile temas kurmaları oldukça zordur. Bununla birlikte, yağların kömür-su karışımına emülsifiye edilmeden verilmesi durumunda daha az verim elde edilebilecektir. Bundan dolayı, yağ aglomerasyonunda kullanılacak yağların emülsifiye edilerek sisteme ilave edilmesi verimin artırılması açısından önemlidir. Yağların emülsifiye edilmesi mekanik karıştırma ile yapılabilmektedir. Ancak, mekanik karıştırma ile yağların

emülsifiye edilmesi genellikle stabil olmamakta ve istenen damlacık boyutu elde edilememektedir [8]. Bununla birlikte, ultrasonik işleme emülsiyonu stabilize etmek ve istenen damlacık boyutuna ulaşmak mümkündür. Emülsiyonun ultrasonik işlemi sırasında, kabarcıkların ani çöküşü nedeniyle kavitasyon meydana gelir ve bu da mikro türbülansın gelişmesine neden olur. Sonuç olarak, su ve yağ arasındaki arayüzey gerilimi azalır ve daha büyük yağ damlacıkları daha küçük kararlı damlacıklara bölünür. Bu, küçük boyutlu emülsiyon damlacıkları oluşturarak emülsiyonu daha kararlı hale getirerek sürecin verimliliğini artırır [9].

Yağların emülsifikasyonunda ultrasonik dalgalar etkili bir yöntem olarak benimsenmiş ve bu konuda çalışmalar yapılmıştır [10]-[13]. Emülsiyon, bir sıvının karışmadığı başka bir sıvı içinde ince bir şekilde dağılmasıdır [14]. Ultrason uygulaması emülsifikasyon için gerekli enerji girdisini sağlayabilir. Ultrason ile mikron boyutundan mikron altı boyuta kadar yağ damlacıkları oluşturmak mümkündür. Yağların ultrason destekli emülsifikasyonunda, daha küçük damlacık boyutu, ortamda homojen dağılıma, gelişmiş stabilite, daha düşük güç gereksinimi gibi avantajlar ortaya çıkmaktadır [15]. Bu nedenle ultrason, su içinde yağ emülsiyonları oluşturmak için yaygın olarak kullanılmaktadır [13].

Sahinoglu ve Uslu [16] çalışmalarında yağın ultrasonik cihazla emülsifiye edilerek bağlayıcı olarak kullanıldığı yağ aglomerasyonu deneyinde -0,5 mm tane boyutundaki kömürün temizlenebilirliğini araştırmışlar. Yağın emülsifiye edilerek yapılan aglomerasyon deneyinde kömürden kül ve kükürt giderme işleminin daha başarılı olduğunu bulmuşlardır. Bununla birlikte yanabilir verim üzerinde olumsuz etkisi olduğunu belirtmişlerdir. Yanabilir verim üzerindeki olumsuz etkisinin ultrasonik işlem ile çok küçük boyuta indirilen yağ damlacıklarının çok daha iri boyutta olan kömür tanelerini başarılı bir şekilde aglomera edemediğini, bu olumsuz etkinin ise kömürün daha ince boyutlara indirilmesiyle ortadan kaldırılabilir olduğunu rapor etmişlerdir. Netten vd. [6] araştırmalarında büyük çoğunluğu 100 mikron altında olan bitümlü kömürün emülsifiye edilmiş ve emülsifiye edilmemiş yağlarla aglomera edilebilirliğini araştırmışlar. Araştırmalarında, emülsifiye edilmiş yağın ince kömürü emülsifiye edilmemiş yağa göre 17 kat daha hızlı ve 10 kat daha az yağ ile aglomera edebildiğini bulmuşlardır. Yadav vd. [17] farklı sektörlerden elde edilen atık yağların kömürün yağ aglomerasyonunda bağlayıcı olarak kullanılabilirliğini araştırmışlar. Bu amaçla atık soya yağı, atık motor yağı ve atık trafo yağı kullanmışlar. Çalışmalarında, farklı sektörlerden elde edilen atık yağların, yıkayıcıdan atılan kömür atığı bulamacından kömür ince tanelerinin zenginleştirilmesi ve geri kazanılması için kullanılabileceğini bulmuşlardır. Shukla ve Venugopal [4] çalışmalarında yağ aglomerasyonu yöntemiyle ince kömürün temizlenmesinde atık hardal yağının bağlayıcı olarak kullanılabildiğini araştırmışlar. Atık hardal yağının bağlayıcı olarak ince kömürlerin yağ aglomerasyonunda başarılı bir şekilde kullanılabileceğini bulmuşlardır. Yaşar vd. [18] kömür yıkama tesisi atıklarındaki ince kömürü geri kazanmak için yağ aglomerasyonu yöntemini kullanmışlardır. Yöntemde bağlayıcı olarak kullandıkları atık ayçiçek yağının, kömür yıkama tesisi atıklarından ince kömürü geri


kazanımında düşük maliyetli yağ aglomerasyonu uygulaması için iyi bir seçim olduğunu bulmuşlardır. Esmeli [19] yağ aglomerasyonunda, ince kömürün atık motor yağıyla ultrasonik işlem kullanarak temizlenebilirliğini araştırmıştır. Ultrasonun kömürün yağ aglomerasyonu üzerindeki etkisini, ön işlem aşamasında ve aglomerasyon aşamasında kullanarak belirlemiştir. Ön işlem veya aglomerasyon aşamasında ultrasonun uygulanmasının, kömürün yağ aglomerasyonu sürecini önemli ölçüde etkilediğini belirtmiştir. Ön işlem aşamasında ultrason kullanımının kömürün yağ aglomerasyonunu iyileştirdiğini, ancak aglomerasyon aşamasında ultrason kullanımının yanabilir verim değerini azalttığını rapor etmiştir. Eşmeli [20] Ilgın linyit kömürünün yağ aglomerasyonunda ultrasonik işlemin etkisini araştırmıştır. Araştırma sonucunda, ultrasonik sistemin güç değerinin artışının kömürün kül içeriğini azalttığını, ancak yanabilir verim değerlerinde ise negatif etki ettiğini bulmuştur.

Yağ aglomerasyonu yönteminde bağlayıcı olarak kullanılan yağın miktarı ve maliyeti sürecin en büyük engelleyici yönüdür. İnce kömür aglomerasyonunun ticari bir başarıya ulaşması için yağ miktarının ve dolayısıyla maliyetinin önemli ölçüde azaltılması gerekmektedir. Bu bağlamda, yöntemde kullanılacak olan bağlayıcının sisteme emülsifiye edilerek verilmesi kullanılacak yağ miktarını azaltabilir. Atık yağlarında yöntemde bağlayıcı olarak kullanılması yağ maliyeti anlamında çok büyük katkılar sağlayabilir. Kullanılacak olan gerekli yağ miktarını azaltmak ve atık yağında yöntemde kullanılması ekonomik olarak uygulanabilir bir aglomerasyon prosesi çok önemlidir. Bu çalışmada, yüksek kül-kükürt içerikli çok ince boyutlu Müzret kömürü yağ aglomerasyonu yöntemi kullanılarak bitkisel atık ayçiçek yağı ile aglomera edilmiştir. Yöntemde kullanılacak olan bağlayıcının miktarını azaltmak içinde atık yağ ultrasonik işlem ile emülsifiye edilerek sisteme verilmiştir. Bu çalışma, yüksek kül-kükürt içeren çok ince boyutlu kömürün kullanımı, atık yağın bağlayıcı olarak etkinliği ve atık yağın emülsifikasyon yoluyla uygulanması ile benzer çalışmalardan farklılık göstermektedir. Elde edilen sonuçlar yanabilir verim, kül giderimi ve verim indeksi açısından karşılaştırılmıştır.

Materyal ve Metot

Yaklaşık 100 kg kömür numunesi Müzret (Artvin-Yusufeli) bölgesinden alınmıştır. Laboratuvara getirilen kömür numunesinin miktarı uygun yöntemler kullanılarak azaltılmış ve boyut küçültme işlemine tabi tutulmuştur. Boyut küçültme işlemi çeneli kırıcı, merdaneli kırıcı, çubuklu ve bilyalı değirmen kullanılarak yapılmıştır. Elde edilen malzemenin tane boyut dağılımı Malvern Mastersizer (Hydro 2000MU) cihazı ile belirlenmiş olup $d_{10}=3,29 \mu\text{m}$, $d_{20}=6,11 \mu\text{m}$, $d_{50}=19,57 \mu\text{m}$, $d_{80}=43,47 \mu\text{m}$, $d_{90}=58,65 \mu\text{m}$ 'dir. Kömür numunesi tane boyut dağılımı Şekil 1'de görülmektedir. Kömür numunesinden alınan temsili örnekler ile kimyasal ve mineralojik analizler yapılmıştır. Kömürün nem, kül, piritik kükürt, sülfat kükürt ve kalorifik değer analizleri yapılmıştır. Analiz değerleri Tablo 1'de verilmiştir. Müzret kömürünün yüksek kül-piritik kükürt içerdiği belirlenmiştir. Yapılan X-ışını difraktometresi (XRD) analizinde pirit, kaolinit,


montmorillonit, illit, kalsit, jips ve kuvars minerallerinin kömürle birlikte bulunduğu belirlenmiştir (Şekil 2).



Şekil 1. Kömür numunesi tane boyut dağılımı

Tablo 1. Kömürün analiz değerleri

Bileşenler	Havada Kuru	Kuru
Nem (%)	2,25	–
Kül (%)	34,85	35,65
Sülfat Kükürt (%)	0,99	1,01
Piritik Kükürt (%)	5,44	5,57
Kalorifik Değer (kcal/kg) (Üst Isıl Değeri)	4970	5084



Şekil 2. Kömür numunesinin XRD grafiği

Deneylerde bağlayıcı olarak, kızartma amacıyla kullanılıp atık yağ toplama kaplarında biriktirilmiş olan bitkisel atık ayçiçek yağı kullanılmıştır. Atık yağ içerisindeki gıda parçalarını uzaklaştırmak için filtreleme işlemine tabi tutulmuştur. Daha sonra herhangi bir ek işlem yapılmadan doğrudan kullanılmıştır. Deneylerde kullanılan bitkisel atık ayçiçek yağı Şekil 3'de görülmektedir. Viskozitesi ve yoğunluğu sırasıyla $35,81 \text{ mm}^2/\text{s}$ ve $0,91 \text{ gr}/\text{cm}^3$ 'dir. Yağın viskozitesi Tanaka AKV-202 tipi viskometre ile $40 \text{ }^\circ\text{C}$ 'de, yoğunluğu ise Alla France tipi hidrometre ile $23,8 \text{ }^\circ\text{C}$ 'de belirlenmiştir. Yağın emülsifiye edilerek sisteme verildiği deneylerde bitkisel atık ayçiçek yağının emülsifikasyonu için ultrasonik işlem kaynağı olarak laboratuvar tipi (750 watt

gücünde, 20 kHz frekansında) ultrasonik cihaz (Cole-Parmer) kullanılmıştır.



Şekil 3. Deneysel ortamda kullanılan bitkisel atık ayçiçek yağı

İlk olarak, ultrasonik emülsifikasyon aşaması olmaksızın yağ aglomerasyon deneyleri gerçekleştirilmiştir. Yağ aglomerasyon deneyleri silindirik cam kaptta (11,7 cm çapında) gerçekleştirilmiştir. Kap içerisine dört adet plastik levha yerleştirilmiştir. Karıştırma işlemi RZR 2021 tipi mekanik karıştırıcı ile gerçekleştirilmiştir. Deneysel saf su kullanılmıştır. Deneysel %10 katı oranında 50 g kömür kullanılarak yapılmıştır. Başlangıçta, kömür-su karışımı (450 ml suda 50 g kömür) 3 dakika boyunca 1200 devir/dakika'da şartlandırılmıştır. Daha sonra bağlayıcı olarak kömür ağırlığının %10 atık ayçiçek yağı (5g) eklenmiş ve kömür-su yağ karışımı 1200 devir/dakika'da 10 dakika daha karıştırılmıştır. Çalışmada atık ayçiçek yağı miktarının %10 seçilmesi yazarın daha önce yapmış olduğu çalışmadan yararlanılarak belirlenmiştir [21]. Deneysel, kömür-su yağ karışımının doğal pH'ında (pH: 5,36) gerçekleştirilmiştir. Aglomerasyondan sonra pülp, oluşan aglomeratları, su ve atıklardan ayırmak için 63µm açıklığa sahip bir eleğe aktarılmıştır. Aglomeratlarla birlikte kalmış olabilecek mineral maddeleri uzaklaştırmak için de aglomeratlar 1,5 litre su ile dikkatlice yıkanmıştır. Elekten çıkarılan aglomeratlar vakum filtrede hem susuzlandırılmış hem de aseton ile yıkanarak yağdan arındırılmıştır. Elde edilen temiz kömür 105 ± 5 °C'de kurutulmuştur. Kurutma işleminden sonra tartılmış ve analizler için saklanmıştır.

Daha sonra, ultrasonik yağ emülsifikasyon işlemi içeren yağ aglomerasyon deneyleri gerçekleştirilmiştir. Emülsifikasyon işlemi için, yağ-su karışımları (100 ml suda 5 g yağ ve 100 ml suda 2,5 g yağ) 28,5 W/cm² gücünde 1 dakika ultrasonik işleme tabi tutulmuştur (Şekil 4). Kömür-su karışımı (350 ml suda 50 g kömür) 3 dakika boyunca 1200 devir/dakika'da şartlandırılmıştır. Daha sonra 100 ml suda emülsifiye edilmiş yağlar (Şekil 5) kömür-su karışımına eklenmiş ve kömür-su-emülsifiye edilmiş yağ karışımı 1200 devir/dakika'da 10 dakika daha karıştırılmıştır. Oluşan aglomeratların kazanılmasında ultrasonik yağ emülsifikasyonun yapılmadığı deneysel prosesi aynen uygulanmıştır.



Şekil 4. Atık yağın ultrasonik cihazla emülsifikasyonu



Şekil 5. Ultrasonik emülsifikasyon işleminden sonra yağ-su emülsiyonu, Güç: 28,5 watt/cm², %10 yağ miktarı

Yanabilir verim (YV, %), kül giderimi (KG, %) ve verim indeksi (Vİ, %) aşağıdaki denklemler kullanılarak hesaplanmıştır [21].

$$YV (\%) = \left[\frac{C(100 - c)}{F(100 - f)} \right] \times 100 \quad (1)$$

$$KG (\%) = \left[1 - \frac{C}{F} \frac{c}{f} \right] \times 100 \quad (2)$$


$$Vİ (\%) = [YV (\%) + KG (\%) - 100] \quad (3)$$

Denklemlerdeki;


C, Konsantrenin ağırlığı (g); c, Konsantrenin kül içeriği (%); F, Beslemenin ağırlığı (g); f, Beslemenin kül içeriği (%).

Yukarıda belirtilen testlere ek olarak, ultrasonik olarak emülsifiye edilmiş yağ damlacıklarının ve aglomeratların fotoğrafları sırasıyla optik mikroskop (Leica Dm 4000 M) ve stereo mikroskop (Leica Mz 16) kullanılarak çekilmiştir.

Emülsiyon morfolojisini incelemek için, ultrasonik işlem ile emülsifiye edilmiş yağlar emülsifiye edildikten hemen sonra optik mikroskop ile analiz edilmiş ve elde edilen yağ damlacıkları görüntülenmiştir (Şekil 6). Yağların çok küçük boyutta yağ damlacıklarının dönüştürüldüğü ve küresel oldukları görülmektedir. Şekil 7'de görüldüğü gibi elde edilen aglomeratların farklı şekillerde ve boyutlarda olduğu görülmüştür.



Şekil 6. Ultrasonik işlem ile üretilen yağ damlacıklarının mikroskop görüntüsü, Güç: 28,5 watt/cm², Zaman: 1 dak.



Şekil 7. Yağ aglomerasyon prosesinde üretilen aglomeratların mikroskop görüntüsü, Güç: 28,5 watt/cm², %10 yağ miktarı

Bulgular

Bitkisel yağlar, gaz yağı, mazot vb. yağlar kömürün yağ aglomerasyonunda bağlayıcı olarak yaygın olarak kullanılmaktadır. Bu yağlar suda çözünemedikleri için pülp ortamında dağılma ve partikül yüzeylerine adsorbe olma verimleri düşüktür, bu da yağ aglomerasyonu prosesinde yüksek yağ tüketimine, uzun aglomerasyon süresine ve hatta aglomerasyon performansının düşmesine neden olabilir. Yağların bağlayıcı olarak kömürün yağ aglomerasyonu işleminde eklenmeden önce ultrasonik emülsifikasyon yoluyla ince damlacıklar halinde dağıtılması, yağ aglomerasyon performansının iyileştirilmesi ve yağ tüketiminin azaltılması açısından çok önemli bir konudur.


Şekil 8'den görüldüğü gibi, ultrasonik emülsifikasyon yapılmadığı yağ aglomerasyonu deneyinde kömürün kül içeriği %35,65'den %26,19'a düşürülmüştür. Kül giderimi %46,92 olurken, yanabilir verim %82,87 ve verim indeksi %29,79 olarak bulunmuştur.

Şekil 9'da %10 atık ayçiçek yağı ultrasonik işlemle emülsifiye edildiğinde yapılan yağ aglomerasyonu işleminde elde edilen konsantrenin kül içeriği %26,5 olmuştur. Kül

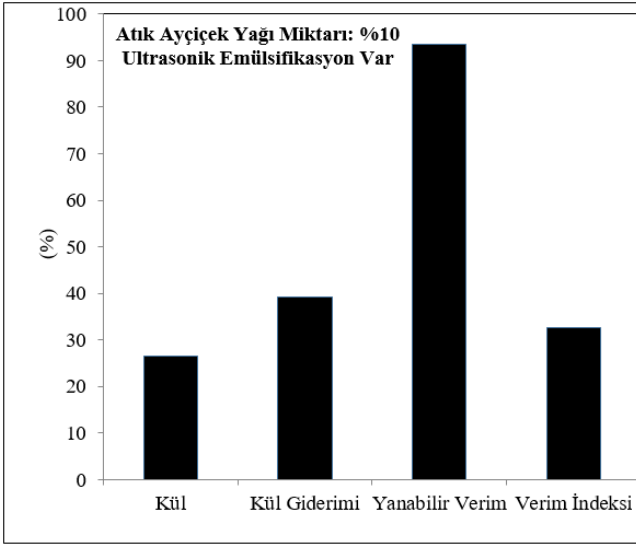
giderimi ve yanabilir verim değerleri sırasıyla %39,17 ve %93,46 olurken, verim indeksi %32,63 olmuştur.

Şekil 10'da %5 atık ayçiçek yağı ultrasonik işlemle emülsifiye edildiğinde yağ aglomerasyonu işleminde konsantrenin kül içeriği %27,3 olarak elde edilmiştir. Kül giderimi ve yanabilir verim değerleri sırasıyla %44,09 ve %82,48 olarak bulunmuştur. Verim indeksi değeri ise %26,57'dir.


Sonuçlardan görüldüğü gibi bitkisel atık ayçiçek yağı çok ince boyutlu kömürün yağ aglomerasyonunda başarılı bir şekilde kullanılabilir. Sonuçları daha da iyileştirmek için ultrasonik işlem ile emülsifiye edilmiş yağlar ile de aglomerasyon deneyleri yapılmış olup sonuçlar geleneksel yağ aglomerasyonu sonuçları ile karşılaştırılmıştır. İlk olarak geleneksel yağ aglomerasyonunda olduğu gibi atık ayçiçek yağı miktarı %10 alınıp ultrasonik dalgalar ile emülsifikasyon işlemine tabi tutulup emülsifiye edilip aglomerasyon deneyleri yapılmıştır. Elde edilen sonuçlar geleneksel yağ aglomerasyonu sonuçlarıyla karşılaştırıldığında geleneksel yağ aglomerasyonunda %82,87 olan yanabilir verimin ultrasonik işlem ile yağların emülsifiye edildiği yağ aglomerasyonunda %93,46'ya yükseldiği görülmüştür. Bununla birlikte geleneksel yağ aglomerasyonunda kül içeriği ve kül giderimi sırasıyla %26,19 ve %46,92 iken, yağların emülsifiye edildiği yağ aglomerasyonunda kül içeriği ve kül giderimi sırasıyla %26,5 ve %39,17 olmuştur. Yağların emülsifiye edildiği yağ aglomerasyonunda yanabilir verimdeki artış, emülsifiye edilmiş yağların çok küçük boyutlara indirilmesi ve ortamda daha homojen bir şekilde dağılması sonucu çok küçük boyutta olan kömür tanelerini daha iyi aglomera ettikleri söylenebilir. Yağ damlacıklarının ortamda homojen şekilde dağılması ortamdaki kömür taneleriyle yağ damlacıkları arasındaki çarpışma olasılığını artırmaktadır. Böylelikle de ortamda daha fazla aglomerat oluşumu sağlanarak yanabilir verim artmaktadır. Ancak, emülsifiye edilmiş yağların kullanıldığı aglomerasyon deneylerinde kül gideriminin azaldığı görülmüştür. Kül giderim değerinin azalması, emülsifiye edilmiş yağlarla yağ aglomerasyonu prosesinde oluşan aglomeratların daha kompakt oldukları, emülsifiye edilmemiş yağlarla yapılan aglomerasyonda oluşan aglomeratlar belirli bir dereceye kadar kompakt oldukları söylenebilir. Oluşan aglomeratların kompakt olması aglomerat oluşumu esnasında kül yapıcı minerallerin aglomeratlar arasına girip aglomeratların yıkanması işlemiyle aglomeratlar arasından uzaklaştırılmadığı sonucuna varılabilir. Atık yağın emülsifiye edildiği (atık yağ miktarı %5) yağ aglomerasyonu deneyinde, yağ miktarı geleneksel yağ aglomerasyonunda kullanılan yağ miktarına göre yarıya düşürülmesine rağmen elde edilen yanabilir verim değeri %82,48 olmuştur. Bu değer geleneksel yağ aglomerasyon deneyinde elde edilen değer olan %82,87 ile karşılaştırıldığında hemen hemen bir birine yakın değerler olduğu görülmüştür. Sonuçlar yağ aglomerasyonu deneyinden önce kullanılacak olan yağların ultrasonik dalgalarla emülsifiye edilerek sisteme dahil edilmesinin ne kadar önemli olduğunu ortaya koymaktadır. Böylelikle kullanılacak olan yağ miktarı yarıya düşürülüp proses maliyeti oldukça azaltılabilir. Bu çalışmada olduğu gibi yöntemde atık yağlarında başarıyla kullanılacak bilecek olması yöntemin ticari anlamda kullanılabilirliği açısından çok önemli bir yer tutmaktadır.



Şekil 8. Ultrasonik emülsifikasyon işleminin yapılmadığı yağ aglomerasyon deneyinde elde edilen sonuçlar.



Şekil 9. Ultrasonik emülsifikasyon işleminin yapıldığı (%10 atık yağ) yağ aglomerasyon deneyinde elde edilen sonuçlar.



Şekil 10. Ultrasonik emülsifikasyon işleminin yapıldığı (%5 atık yağ) yağ aglomerasyon deneyinde elde edilen sonuçlar.

Tüm sonuçlar birlikte değerlendirildiğinde, yağ emülsifikasyonu, yağ aglomerasyonundaki önemli aşamalardan biridir. Mekanik karıştırma yoluyla yağların emülsifikasyonunda istenilen büyüklükte ve sayıda yağ damlacığı elde etmek zor olabilir. Bununla birlikte, ultrasonik işlem ile küçük boyutlu ve istenilen sayıda yağ damlacıkları daha az miktarda yağ kullanılarak elde edilebilir. Emülsifiye edilmiş yağ damlacıkları daha küçük ve geniş yüzey alanına sahiptir ve kömür yüzeylerini tamamen kaplayarak iyi yağ kullanımı ve hızlı aglomerasyon sağlar. Emülsifikasyon, çok ince boyutlu kömürlerin yağ aglomerasyonunda bağlayıcı olarak kullanılan yağların etkinliğini artırmada önemli bir role sahiptir. Yağ damlacığının boyutu, yağ aglomerasyonunu sürecini etkileyen önemli bir parametredir. Özellikle çok ince boyutlu kömürlerin yağ aglomerasyonu yöntemiyle kazanılmasında yağların emülsifiye edilerek ortama eklenmesi yanabilir verimin artırılması açısından önemlidir.

Sonuçlar

Yağ aglomerasyonunun ticari anlamda kullanılabileceği açısından çok önemli olan bağlayıcı miktarının azaltılması ve yöntemde atık yağların kullanılabilirliği bu çalışmada ortaya koyulmuştur. Çok ince boyutlu kömürlerin yağ aglomerasyonu ile temizlenmesinde bitkisel atık ayçiçek yağı bağlayıcı olarak başarılı bir şekilde kullanılabilir. Ultrasonik işlemin emülsifikasyon işlemi için başarılı bir yöntem olduğu görülmüştür. Ultrasonik emülsifikasyon küçük boyutlu yağ damlacıkları üretmiş ve yağ damlacıklarının su içinde homojen dağılımını sağlamıştır. Kömürün yağ aglomerasyonunda bağlayıcı olarak kullanılacak olan yağ miktarı ultrasonik emülsifikasyon işlemiyle azaltılabileceği belirlenmiştir. Geleneksel yağ aglomerasyonu deneyinde bağlayıcı olarak %10 kullanılan atık yağ miktarı, %5'e düşürülüp ultrasonik işlemle emülsifiye edildiğinde elde edilen yanabilir verim değerleri birbirine çok yakın olarak bulunmuştur. Çalışmada yüksek yanabilir verim ve önemli ölçüde kül giderimi değerleri elde edilmiştir. Yanabilir verim değerleri %82,48-93,46 arasında, kül giderimi değerleri ise %39,17-46,92 arasında değişmiştir. Ayırma etkinliği, %10 atık yağ miktarında ultrasonik emülsifikasyon işleminin yapıldığı deneyde maksimum olarak %32,63 bulunmuştur.

Etik kurul onayı ve çıkar çatışması beyanı

“Hazırlanan makalede etik kurul izni alınmasına gerek yoktur”

“Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır”

Kaynaklar

- [1] X. Wang, D. Meng, J. Li, Z. Lu, Z. Zhang, C. Zhang, S. Song, Y. Peng, L. Xia, “Composition and dynamics of bacterial communities during flotation in a coal preparation plant”, *Journal of Cleaner Production*, 385, 135691, 2023, <https://doi.org/10.1016/j.jclepro.2022.135691>.
- [2] S. Chakladar, P.K. Patar, D. Vishwakarma, A. Mohanty, S. Mallick, S. Chakravarty, “Demineralization of high ash coal fines of Indian origin using Mahua oil”, *Cleaner*

- Engineering and Technology, 4, 100222, 2021, <https://doi.org/10.1016/j.clet.2021.100222>.
- [3] S. Kumar, G.H.V.C. Chary, M.G. Dastidar, "Optimization studies on coal-oil agglomeration using Taguchi (L16) experimental design", *Fuel*, 141, 9-16, 2015, <https://doi.org/10.1016/j.fuel.2014.09.119>.
- [4] D. Shukla, R. Venugopal, "Optimization of the process parameters for fine coal-oil agglomeration process using waste mustard oil", *Powder Technology*, 346, 316-325, 2019, <https://doi.org/10.1016/j.powtec.2019.02.001>.
- [5] B.S. Ken, B.K. Nandi, "Desulfurization of high sulfur Indian coal by oil agglomeration using Linseed oil", *Powder Technology*, 342, 690-697, 2019, <https://doi.org/10.1016/j.powtec.2018.10.045>.
- [6] K. Netten, R.M. Atanasio, K.P. Galvin, "Selective agglomeration of fine coal using a water-in-oil emulsion", *Chemical Engineering Research and Design*, 110, 54-61, 2016, <https://doi.org/10.1016/j.cherd.2016.02.029>.
- [7] G. DeJuliis, G. Sahasrabudhe, R. Davis, J. White, K. Galvin, "Effects of emulsifier concentration in a high-internal-phase, W/O emulsion binder on particle agglomeration", *Chemical Engineering Science*, 248, 117098, 2022, <https://doi.org/10.1016/j.ces.2021.117098>.
- [8] E. Kılınç Aksay, V. Arslan, H. Polat, "Toz kömürlerin zenginleştirilmesinde yağ aglomerasyonu yöntemi ve yenilikler", *İstanbul Yerbilimleri Dergisi*, 23 (2), 97-108, 2012.
- [9] S.D. Barma, "Ultrasonic-assisted coal beneficiation: A review", *Ultrasonics Sonochemistry*, 50, 15-35, 2019, <https://doi.org/10.1016/j.ultsonch.2018.08.016>.
- [10] M. Mohsin, M. Meribout, "Oil-water de-emulsification using ultrasonic technology", *Ultrasonics Sonochemistry*, 22, 573-579, 2015, <https://doi.org/10.1016/j.ultsonch.2014.05.014>.
- [11] W.H. Wu, D.G. Eskin, A. Priyadarshi, T. Subroto, I. Tzanakis, W. Zhai, "New insights into the mechanisms of ultrasonic emulsification in the oil-water system and the role of gas bubbles", *Ultrasonics Sonochemistry*, 73, 105501, 2021, <https://doi.org/10.1016/j.ultsonch.2021.105501>.
- [12] Z. Bocek, M. Petkovsek, S.J. Clark, K. Fezzaa, M. Dular, "Dynamics of oil-water interface at the beginning of the ultrasonic emulsification process", *Ultrasonics Sonochemistry*, 101, 106657, 2023, <https://doi.org/10.1016/j.ultsonch.2023.106657>.
- [13] A.P. Udepurkar, C. Clasen, S. Kuhn, "Emulsification mechanism in an ultrasonic microreactor: Influence of surface roughness and ultrasound frequency", *Ultrasonics Sonochemistry*, 94, 106323, 2023, <https://doi.org/10.1016/j.ultsonch.2023.106323>.
- [14] V. Sivakumar, R.P. Prakash, P.G. Rao, B.V. Ramabrahmam, G. Swaminathan, "Power ultrasound in fatliquor preparation based on vegetable oil for leather application", *Journal of Cleaner Production*, 16, 549-553, 2008, <https://doi.org/10.1016/j.jclepro.2007.01.006>.
- [15] I. Adeyemi, M. Meribout, L. Khezzar, N. Kharoua, K. Alhammadi, V. Tiwari, "Experimental and numerical analysis of the emulsification of oil droplets in water with high frequency focused ultrasound", *Ultrasonics Sonochemistry*, 99, 106566, 2023, <https://doi.org/10.1016/j.ultsonch.2023.106566>.
- [16] E. Sahinoglu, T. Uslu, "Use of ultrasonic emulsification in oil agglomeration for coal cleaning", *Fuel*, 113, 719-725, 2013, <https://doi.org/10.1016/j.fuel.2013.06.046>.
- [17] A.M. Yadav, N. Suresh, A. Sundaram, P. Painkra, A.K. Raja, M. Arshad, "Investigation and optimization of the recovery of coal fines using oil agglomeration process: Use of waste oils from different sectors", *Journal of Dispersion Science and Technology*, 39(5), 754-764, 2018, <https://doi.org/10.1080/01932691.2017.1414610>.
- [18] Ö. Yaşar, T. Uslu, E. Şahinoğlu, "Fine coal recovery from washery tailings in Turkey by oil agglomeration", *Powder Technology*, 327, 29-42, 2018, <https://doi.org/10.1016/j.powtec.2017.12.042>.
- [19] K. Esmeli, "Improvement of lignite oil agglomeration by ultrasound process using waste engine oil", *Particulate Science and Technology*, 41(4), 544-554, 2023, <https://doi.org/10.1080/02726351.2022.2124210>.
- [20] K. Eşmeli, "İlgın linyit kömürünün yağ aglomerasyonunun ultrasonik proses ile iyileştirilmesi", *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 39(1), 107-117, 2024, <https://doi.org/10.21605/cukurovaumfd.1459397>.
- [21] E. Sahinoglu, T. Uslu, "Effect of particle size on cleaning of high-sulphur fine coal by oil agglomeration", *Fuel Processing Technology*, 128, 211-219, 2014, <https://doi.org/10.1016/j.fuproc.2014.07.015>.



Demir Tenör Değerlerinin Kestiriminde Makine Öğrenme Yöntemlerinin Karşılaştırılması

Comparison of Machine Learning Methods in Estimation of Iron Grade Values

Fırat ATALAY^{1*}

¹ Hacettepe Üniversitesi, Maden Mühendisliği Bölümü, atalay@hacettepe.edu.tr
ORCID: <https://orcid.org/0000-0001-6349-7745>

MAKALE BİLGİLERİ

ÖZ

Makale Geçmişi:

Geliş 18 Ekim 2024
Revizyon 27 Kasım 2024
Kabul 12 Aralık 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

Makine öğrenmesi, Krigleme,
Demir yatağı

Bu çalışmada günümüzde maden kaynak kestiriminde kullanım yaygınlığı artmaya başlayan derin sinir ağları, destek vektör makineleri ve XGBoost yaklaşımları kullanılarak bir demir yatağında tenör kestirimleri gerçekleştirilmiştir. Elde edilen sonuçlar endüstride yaygın bir şekilde kullanılan krigleme yöntemi ile karşılaştırılmıştır. Çalışma için öncelikle demir yatağı katı modeli yapılmış ve bu katı modeli temsil eden blok model oluşturulmuştur. Daha sonra girdi olarak kompozitlerin X, Y ve Z değerleri kullanılmış çıktı olarak ise tenör değerleri dikkate alınmıştır. Yukarıda değinilen üç makine öğrenmesi yaklaşımı için modeller ayrı ayrı eğitilmiştir. Yaklaşımların kendine has parametrelerinin tahmininde deneme yanılma yöntemi tercih edilmiştir. Eğitilen modeller ile blok model kestirimleri gerçekleştirilmiştir. Sonuçlar makine öğrenme algoritmalarının da yaygın kullanılan krigleme gibi yumuşatma özelliğinin bulunduğunu göstermektedir. Diğer bir deyişle, elde edilen sonuçların standart sapması kompozitlerin standart sapmasından düşüktür. Diğer bir önemli bulgu da makine öğrenme yöntemlerinin veri kümesi dışında bulunan değerleri tahmin edecek şekilde sonuçlar üretmesidir. Bu durum konumsal tenör kestirimlerinde istenilen bir özellik değildir. Ayrıca eğitilen modeller genel itibarı ile kompozitlerin ortalamalarına yakın sonuçlar çıkarsa da Derin Sinir Ağları modeli kompozitlerin ortalamasından ciddi sapma göstermiştir. Bu durum tüm makine öğrenme yaklaşımlarının doğrudan konumsal kestirimde kullanılamayacağını ve elde edilen sonuçların dikkatlice incelenmesi gerektiğini göstermektedir.

ARTICLE INFO

Article history:

Received 18 October 2024
Received in revised form 27 November 2024
Accepted 12 December 2024
Available online 23 December 2024

Keywords:

Machine Learning, Kriging, Iron
ore

Doi: 10.24012/dumf.1569827

* Sorumlu Yazar

ABSTRACT

In this study, grade estimations were performed at an iron deposit using deep neural networks, support vector machines and XGBoost approaches, which are increasingly common in mineral resource estimation today. The results obtained were compared with the kriging method, which is widely used in the industry. To carry out the studies, firstly a solid model of the iron deposit was made and a block model representing this solid model was created. Then, the X, Y and Z values of composites were used as input and the grade values were considered as output. Models were trained separately with the three machine learning approaches mentioned above. The trial-and-error method was preferred in estimating the unique parameters of the approaches. Block model estimations were performed with the trained models. The results show that machine learning algorithms also have smoothing effect such as kriging, which is widely used. In other words, the standard deviation of the results obtained is lower than the standard deviation of the composites. Another important finding is that machine learning methods can be trained to predict values found outside the dataset. This is not a desired feature in spatial grade estimations. In addition, although the trained models generally produced results close to the average of the composites, the Deep Neural Network model showed serious deviation from the average of the composites. This shows that not all machine learning approaches can be used directly in spatial prediction and the results obtained should be examined carefully.

Giriş

Yeryüzünde çeşitli jeolojik süreçler sonucunda oluşan ve ekonomik bir şekilde çıkarılabilen her türlü katı oluşum maden kaynağı olarak nitelendirilebilir. Bu oluşumlar genellikle kalite değişkeni (kalorifik değer, kül, nem vb.) ya da birim kütledeki metal miktarı olarak tanımlanan tenör değerleri ile karakterize edilir. Metalik maden kaynaklarında tenör, oluşum şartları gereği konuma bağlı değişkenlik göstermektedir. Tenör değerlerinin cevher yatağının örneklenmemiş kısımlardaki değerlerinin tahmin edilmesi ise “kestirim” olarak adlandırılmaktadır.

Maden kaynağı kestirimi, madencilik sektöründe ekonomik sürdürülebilirlik, kaynak yönetimi, risk azaltma, mevzuata uygunluk, teknolojik ilerlemeler ve çevresel etkilerin azaltılması için temel sağlayan kritik bir süreçtir [1]. Maden kaynaklarının tahmininde genellikle sondajlardan elde edilen veriler kullanılır. Kaynak modelin, sondaj verileri ile uyumlu olması beklenir. Sondaj verileri ile uyumlu bir kaynak model gerçek rezerve en yakın bilgiye ulaşılmasını sağlar ve bu sayede madencilik yatırım projelerinin daha gerçekçi ve verimli olmasına yardımcı olur. Bu süreç, aynı zamanda maden çıkarma süreçlerinin hassas bir şekilde planlanmasına olanak tanıyarak kaynakların verimli ve sürdürülebilir kullanımını sağlamakla birlikte atıkların ve çevresel etkinin en aza indirilmesine yardımcı olur. Ayrıca güvenilir kaynak tahmini, finansal ve operasyonel riskleri azaltarak, yatırım kararları için sağlam bir temel sunar ve proje finansmanının elde edilmesine katkı sağlar. Kaynak kestiriminde karmaşık jeostatistiksel yöntemlerin ve hesaplamalı modellerin kullanılması aynı zamanda jeoloji bilimi ve maden mühendisliğindeki ilerlemelere de yön vermektedir. Bunlara ek olarak kaynak kestirimi çevresel yönetim ve rehabilitasyon planlamasına yardımcı olarak madencilik faaliyetlerinin çevresel ayak izinin en aza indirilmesinde önemli rol oynamaktadır.

Jeostatistik, modern maden kaynağı kestiriminde çok önemli bir rol oynamaktadır. Jeostatistiksel yöntem, örneklenmemiş konumlardaki içkestirim (interpolasyon) değerlerini modelleyen variogram analizi ve krigleme gibi ileri matematiksel yöntemleri içerir. Sıklıkla kullanılan bir matematiksel yöntem olan krigleme, temel olarak sondajlar sonucunda elde edilen analiz verilerinin kullanılması ile örnek toplanmamış kısımlardaki tenör değerlerinin kestirilmesini sağlar. Yöntemin temel yaklaşımı, içerisinde barındırdığı krigleme denklemleri ile örneklem değerlerinin kestirilmek (tahmin edilmek) istenen alan üzerindeki ağırlıklarının yansız bir şekilde elde edilmesi şeklindedir. Böylece örneklenmemiş alanlardaki tenör değerleri kestirilebilmektedir. Cevher yataklarından sondajlar ile toplanan bu veriler genellikle eş uzunlukta değildir. Ancak, krigleme yaklaşımı eş uzunluklu verilerin kullanılmasını gerektirir. Bu sebepten bu veriler eşit değerlere dönüştürülür. Bu dönüştürülmüş yeni değerler ise kompozit olarak adlandırılmaktadır. Dönüşüm işlemi yani kompozitleme, oldukça basit bir şekilde eş uzunlukta aralıklar içerisinde düşen verilerin uzunluk ağırlıklı ortalamalarının alınmasından ibarettir.

Mevcut klasik yaklaşımlar olan krigleme, ters uzaklık ve en yakın komşu yöntemleri, maden kaynaklarının konumsal değişkenliğini ve dağılımını anlamak için bir çerçeve sağlar.

Öte yandan, sinir ağları, destek vektör regresyonu ve evrişimli sinir ağlarını içeren makine öğrenimi teknikleri, jeolojik veriler içindeki karmaşık, doğrusal olmayan ilişkileri ele almak için güçlü araçlar sunar. Bu yöntemler, kaynak tahminlerinin doğruluğunu artırmak için büyük veri kümeleri üzerinden eğitilmelerine dayanır.


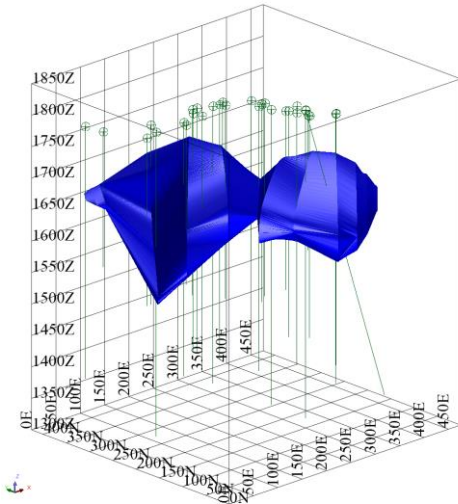
Makine öğrenimi ile jeostatistik tekniklerin karşılaştırılması çeşitli nedenler yüzünden çok önemlidir. Krigleme gibi jeostatistiksel yöntemler, mekansal verileri modelleme ve niceliksel belirsizlikle güvenilir tahminler sağlama konularında başarılı sonuçlar vermek için geliştirilmiştir. Buna karşılık, makine öğrenimi teknikleri büyük veri kümelerini yönetmede ve karmaşık, doğrusal olmayan ilişkileri modellemede başarılıdır. Bu alternatif yaklaşımların karşılaştırılmasına yönelik çalışmalar halen aktif bir araştırma konusudur. Bu çalışmalar temel olarak sadece makine öğrenme algoritmalarının kullanıldığı ve makine öğrenme algoritmaları ile klasik yöntemlerin karşılaştırıldığı araştırmalar olmak üzere iki ana kategoriye ayrılabilir. Mevcut çalışmalar genellikle maden kaynak kestirimine yönelik olmakla birlikte maden varlıklarının varlığının bulunmasına yardımcı olmak amacıyla da gerçekleştirilmiştir. Çalışmalara konu olan maden varlıkları genellikle demir, kurşun, çinko, bakır ve altın gibi metalik yataklardır. Birinci kategoriye giren yani sadece makine öğrenme algoritmalarının maden kaynak kestiriminde kullanılabilirliği konusu demir yatakları bazında gösterilmiştir [2, 3]. Bu çalışmaların ortak yanı, mevcut çalışmada olduğu gibi, Derin Sinir Ağlarının (DSA) demir yataklarında kaynak kestirim amacıyla kullanılmış olmasıdır. Ayrıca yine klasik yöntemlerle kıyas yapılmadan kurşun ve çinko varlıklarının belirlenmesinde de DSA'nın kullanılabilirliği belirtilmiştir [4]. Benzer şekilde başka bazı çalışmalarda Destek Vektör Makinaları (DVM) ve DSA'nın maden kaynak kestiriminde ve varlığının modellenmesinde kullanılabilirliği bildirmiştir [5-11]. İkinci kategoriye düşen, makine öğrenmesi ile kıyas yapan çalışmalar, temel olarak üç alt gruba ayrılabilir. Bu çalışmalardan bazıları krigleme gibi klasik kestirim yöntemlerinin daha iyi sonuçlar ürettiğini belirtmiş [12-15], bazı çalışmalar ise buna zıt olarak makine öğrenme yöntemlerinin krigleme yönteminden daha iyi sonuçlar ürettiğini belirtmiştir [14, 16-21]. Son alt gruptaki çalışmalar ise makine öğrenmesinin Krigleme gibi klasik yöntemlere bir alternatif olarak kullanılabilirliğini belirtmiştir olup kıyas yapmamışlardır [22-26]. Ayrıca makine öğrenmesi yaklaşımlarından DSA ve DVM'nin hangisinin daha iyi sonuçlar ürettiğine ilişkin birbiri ile çelişen yayınlar da mevcuttur [27-29]. Bu çalışmalardan görüldüğü üzere klasik ve yeni gelişen yöntemlerden hangilerinin daha iyi sonuçlar ürettiği halen tartışmaya açık bir konudur. Bu sebepten, bu belirsizliğin azaltılmasına yönelik çalışmalara ihtiyaç duyulmaktadır.

Bu çalışmada, günümüzde sıklıkla kullanılan krigleme yöntemi ile makine öğrenme yöntemlerinden olan Derin Sinir Ağları (DSA), Destek Vektör Makinaları (DVM) ve eXtreme Gradient Boosting (XGBoost) kullanılarak bir demir yatağında kestirimler gerçekleştirilmiştir. Tüm kestirimlerde aynı kompozitler kullanılmış ve bu kompozitlerde koordinatları temsil eden X, Y ve Z değerleri ile Fe tenör değerleri dikkate alınmıştır. Kestirimler için yöntemlerin doğası gereği farklı adımlar izlenmiştir. Ancak makine

öğrenmesinde modellerin eğitilebilmesi için girdi olarak X, Y ve Z değerleri yani kompozit lokasyonları kullanılırken çıktı olarak da Fe değerleri kullanılmıştır. Bilindiği üzere, genellikle, tenör verileri yer yüzünden aşağı doğru yapılan sondajlardan alınan numuneler üzerinden elde edilmektedir. Dolayısı ile sondajlardan elde edilen verilerin koordinatları birbirlerinden farklıdır. Girdi olarak kullanılan X, Y ve Z değerleri eşit uzunluklardaki kompozit değerlerinin orta noktalarının koordinatlarını ifade etmektedir. X değeri nirengi noktasına göre sağa yönünü, Y değeri yukarı yönünü ve Z değeri ise kompozitlerin kotunu temsil etmektedir. Çıktı olarak kullanılan Fe değeri ise bu koordinatlara tekabül eden Demir (Fe) kompozit değerleridir. Önceden belirtildiği gibi, çıktı olarak kullanılan Fe kompozitleri sondajların farklı kotlarından toplanan numuneler üzerinden yapılan kimyasal analizlere dayanmaktadır. Sonuç olarak krigleme, DSA, DVM ve XGBoost ile elde edilen kestirim sonuçları karşılaştırılmıştır. Karşılaştırma için kompozit değerleri baz alınmış ve elde edilen özet istatistiklerin kompozit özet istatistiklerinden sapma değerleri kullanılmıştır.

Çalışma Sahası ve Yöntem

Bu çalışmada krigleme, DSA, DVM ve XGBoost yöntemleri bir demir yatağındaki Fe tenörlerinin kestirimi açısından karşılaştırılmıştır. İlgili saha Türkiye'de bulunmakla birlikte veri gizliliği nedeni ile tam konumu belirtilmemiştir. İlgili başka bir çalışmada sahadaki düşük tenörlü kısımlar değerlendirilmiş olmakla birlikte bu çalışmada sadece yatağın yüksek tenörlü kısımları dikkate alınmıştır [21]. Bu yatağa ilişkin sondajlar, demir cevheri oluşumunu temsil eden katı model ve tenör kestirimlerinin yapıldığı blok model Şekil 1'de gösterilmiştir.



Şekil 1 Yüksek tenörlü zonu temsil eden katı model (üst) ve blok model (alt)

Şekil 1'den görüldüğü üzere yüksek tenörlü zon yatağın ortasında incelenerek birbirleri ile bağlantılı iki küme halinde davranmaktadır. Cevherleşme doğu batı ekseninde yaklaşık olarak 420 m, kuzey güney ekseninde 400 m civarında yayılırken kalınlığı değişken olup 30 m ile 110 m arasında değişmektedir. Cevher derinliği 70 ile 260 m arasında değişmektedir.

Toplamda 30 adet sondaj yapılmış olup bu sondajlardan yüksek tenör olarak tanımlanan kısımlardan toplamda 618 adet veri toplanmıştır. Bu veriler karot numunelerinden yapılan analizlere dayanmaktadır. Belirli aralıktaki karotlar öncelikle ikiye bölünmüş olup, numunelerin bir yarısı şahit olarak karot sandığında saklanmış geriye kalan yarısı ise analize gönderilmiştir. Numune aralıkları eş uzunlukta değildir. Önceden de belirtildiği üzere, eş uzunlukta olmayan veriler üzerinden jeostatistiksel analiz ve kestirimler yapılamayacağından kompozitleme işlemi yapılmıştır. Kompozitleme işleminin temel hedefi eş uzunlukta olmayan ham tenör verilerinin, eş uzunlukta verilere dönüştürülmesidir. Bu dönüşüm işlemi için aşağıdaki formülasyon kullanılmıştır (Denklem (1)).

$$\beta = \sum_{i=1}^n \frac{O_i}{K} Z_i \quad (1)$$

Burada, β kompozit değerini, O_i örneklem uzunluğunu, K kompozit boyunu ve Z_i değeri karotlar üzerinden toplanan örneklem değerini göstermektedir. Z_i değeri sadece ilgili aralığa düşen verileri kapsamaktadır. Kompozitleme işlemi özetle bir sondajda cevher kesen ilk kısımdan başlayıp cevherleşme bitene kadar olan kısımların eş uzunluklardaki aralıklara bölünmesi ile başlar. Daha sonra bu aralıklara düşen veriler belirlenir ve sonrasında bu veriler Denklem (1)'de gösterildiği gibi oluşturulur. Bu işlem tüm sondajlar için tekrarlanır.

Denklem (1)'den de görüldüğü üzere Z_i ve O_i değerleri numunelere dayanmaktadır. Ancak Denklem (1)'de yalnızca K yani kompozit boyu değiştirilebilmektedir. Bu değer genellikle karotlardan toplanan örneklemelerin ortalama uzunluğuna eşit seçilir. Mevcut karot verileri incelendiğinde

ortalama örneklem uzunluğunun 1 m olduğu gözlenmiştir. Bu sebepten, mevcut ham verilerin 1 m boyunda kompozitleri elde edilmiştir. Cevherleşme sondajlar bazında incelendiğinde oldukça değişkendir. Bazı sondajlarda yalnızca 4 m'lik yüksek tenörlü cevherleşme tanımlanmışken bu değer bazı sondajlarda ise yaklaşık olarak 60 m'ye kadar çıkmaktadır. Bu durumda sondajlardan toplanan veri sayısı da aynı olamamaktadır. Bu sayı sondajda kesilen cevher kalınlığına göre artmaktadır. Bu sebepten bazı sondajlarda yalnızca dört adet kompozit veri oluşmuşken bu sayı diğer sondajlarda 60'a kadar çıkmıştır. Oluşan toplam kompozit sayısı 635'tir. Kompozitleme sonucu elde edilen veriler ve ham verilere ait özet istatistikler Tablo 1'de verilmiştir. Kompozitleme, maden kaynak kestiriminde oldukça yaygın kullanıldığından bu işlem için paket programlar kullanılmaktadır. Bu çalışmada kompozitleme için NetproMine isimli madencilik yazılımı kullanılmıştır.

Tablo 1. Ham veriler ve kompozitlere ait özet istatistikler

	Ham veriler	Kompozitler
Veri sayısı	618	635
En düşük	30,76	30,76
Ortalama	54,45	54,50
Ortanca	56,50	57,60
En yüksek	61,43	61,43
Standart Sapma	6,84	6,82

Tablo 1'de görüldüğü üzere ham ve kompozit değerlerin özet istatistikleri oldukça benzerdir. Bu kompozitleme için beklenen ve istenen bir durumdur. Veri sayıları bakımından kompozitlerin sayısının fazla olması örnek toplama sıklığının bazı yerlerde 1 m'den daha yüksek olduğunu göstermektedir. Ham veriler ile kompozitler arasındaki küçük istatistiksel farkların da sebebi bu durumdur.

Yöntem

Bu çalışmada kullanılan krigleme, DSA, DVM ve XGBoost yöntemleri aşağıda açıklanmıştır.

Krigleme

Krigleme, jeoistatistiksel bir içkestirim yöntemi olup, özellikle maden mühendisliği ve çevre bilimlerinde yaygın olarak kullanılır. Bu yöntem, Güney Afrikalı maden mühendisi Daniel Krige tarafından 1950'lerde geliştirilmiştir [30]. Krigleme, belirli bir alanda toplanan örnek verilerin analizine dayanır ve veri noktaları arasındaki mekânsal ilişkiyi tanımlamak için variogram kullanır. Variogram, iki nokta arasındaki mesafe ile bu noktalar arasındaki veri değerlerinin farkının karesi arasındaki ilişkiyi gösterir. Krigleme, genel itibar ile tahmin edilecek noktaya en yakın veri noktalarına daha fazla ağırlık vererek tahmin yapar ve bu ağırlıklar, variogramdan elde edilen konumsal ilişki bilgisine dayanarak hesaplanır. Her bir tahmin noktası için bir değer ve bu tahminin hata oranı sağlanır, bu da tahminlerin güvenilirliğini değerlendirmede önemli bir rol oynar [30]. Krigleme yöntemi oldukça iyi bilindiğinden bu çalışmada matematiksel temellerinin verilmesine ihtiyaç duyulmamıştır.

Derin Sinir Ağları (DSA)

Derin Sinir Ağları (DSA), insan beyninin yapısından ve işlevinden ilham alan karmaşık modellerdir. DSA'lar genel itibari ile girdiler, çıktılar ve bunlar arasındaki ilişkinin modellendiği katmanlardan oluşmaktadır. Bu katmanlar her biri nöron olarak adlandırılan işlemciler kümesinden oluşur. Her nöron, girdilerinin ağırlıklı bir toplamını alıp bu toplama bir yanlılık (bias) terimi ekler ve bir aktivasyon fonksiyonu kullanarak değerleri işler. Aktivasyon fonksiyonun en önemli işlevi doğrusal olmayan ilişkilerin de modellenmesini sağlamaktır. Böylece, oluşan ağ yapısı girdi ve çıktılar arasındaki karmaşık ilişkilerin modellenmesini sağlar [31-33].

Bir DSA'nın işleyişi temel olarak nöronlar üzerinden ağırlıklı toplamaların oluşturulması, sonrasında bu sonuçların aktivasyon fonksiyonları ile değerlendirilmesi ve kayıp fonksiyonunun minimize edilmesine dayanır. Bu minimizasyon için ileri ve geri yayılma gibi teknikler kullanılır. Bu adımlar aşağıda kısaca açıklanmaktadır.

Ağırlıklı Toplam: Her giriş x_i karşılık gelen bir ağırlık olan w_i ile çarpılır. Nöron, girdilerinin ağırlıklı toplamını aşağıdaki gibi hesaplar (Denklem (2)):

$$z = \sum_{i=1}^n w_i x_i + b \quad (2)$$

Burada, b yanlılık terimi olup n toplam nöron sayısını ifade eder.

Aktivasyon Fonksiyonu: Ağırlıklı toplam z daha sonra aktivasyon fonksiyonu olan $\phi(z)$ işlemcisine tabi tutulur. Önceden de belirtildiği üzere bu aktivasyon işlemcisi doğrusal olmayan ilişkilerin modellenmesini sağlar. Yaygın aktivasyon işlemcileri aşağıdaki gibidir (Denklem (3)):

$$\begin{aligned} \text{Sigmoid}(x) &= \frac{1}{1 + e^{-ax}} \\ \text{Tanh}(x) &= \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \\ \text{ReLU}(x) &= \max(0, x) \end{aligned} \quad (3)$$

Bir DSA'nın eğitimi, tahmin edilen çıktı ile gerçek çıktı arasındaki hatayı en aza indirecek şekilde ağırlıkların ve yanlılığın belirlenmesiyle gerçekleştirilir. Önceden belirtildiği üzere, bu süreç temel olarak ileri yayılma, kayıp fonksiyonunun değerlendirilmesi ve sonuçta geri yayılma adımları ile gerçekleştirilir.

İleri Yayılma (forward propagation): Bir çıktı oluşturmak için girdi verilerinin bir ağ üzerinden ileri yönde beslendiği yaklaşımdır.

Kayıp Fonksiyonu: Regresyon amacı ile eğitilen bir ağda Ortalama Hatanın Karesi (OHK) gibi bir kayıp fonksiyonu kullanarak kayıp yani beklenen değerden sapma (hata) hesaplanır (Denklem (4)):

$$\text{OHK} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

Geri yayılım: Denklem (2)'de gösterilen ağırlıkların makul bir süre içerisinde bulunmasını sağlayan adımdır. Genel yapı olarak çıktı katmanındaki nöronların girdi değerlerine göre,

çıkı katmanındaki nöronların bir önceki katmanla arasındaki değerlere göre kısmi türevinin alınarak zincir kuralının uygulanmasına dayanır. Böylece katmandaki ağırlıklar güncellenerek Denklem (4)'deki OHK değerinin en düşük olduğu ağırlıklar bulunur [34]. Böylece DSA modeli eğitilmiş olup yeni girdi değerleri için tahminlerde bulunabilir.

Destek vektör makineleri (DVM)

Destek Vektör Makineleri (DVM), sınıflandırma ve regresyon problemleri için kullanılan denetimli öğrenme yaklaşımlarıdır. DVM'nin temel hedefi iki sınıftan birbirinden ayıran en geniş doğrusal koridorun bulunmasıdır. Diğer birçok makine öğrenme yaklaşımlarında olduğu gibi amaç fonksiyonunun minimizasyonuna dayanmaktadır. Amaç fonksiyonu ise Denklem (5)'teki gibi tanımlanabilir.

$$\frac{1}{2} \| \mathbf{w} \|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (5)$$

Burada, \mathbf{w} ağırlık vektörü, C fonksiyonun düzlüğü ile küçük sapmaları tolere edildiği miktar arasındaki dengeyi belirleyen bir düzenleme parametresi olup değeri 0 ile sonsuz arasındadır, ξ_i ve ξ_i^* ise gerçek değerlerden epsilon tolerans marjına olan mesafeyi temsil eden değişkendir. Diğer taraftan bu değişkenler gevşek değişken olarak da isimlendirilmektedir. Amaç fonksiyonu Denklem (6)'daki kısıtlamalara tabidir.

$$\begin{aligned} y_i - (\mathbf{w} \cdot \mathbf{x}_i + b) &\leq \epsilon + \xi_i \\ (\mathbf{w} \cdot \mathbf{x}_i + b) - y_i &\leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \quad (6)$$

Burada y_i gerçek bir değer, x_i özellik vektörü, b sapma ve ϵ ise toleransı temsil eder.

DVM çözümler için genellikle Lagrange çarpanları kullanılır ve optimizasyon fonksiyonu dual forma dönüştürülür. Genel itibari ile bir çekirdek fonksiyon sayesinde veriler herhangi bir dönüşüme gerek kalmadan doğrudan çalışılabilir durumda olur. Son olarak da nihai kestirici fonksiyon ise Denklem (7)'deki gibi yazılabilir;

$$f(\mathbf{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \quad (7)$$

Burada K ilgili çekirdek fonksiyonu, b ise düşey eksenindeki sapma terimini temsil etmektedir [35, 36].

XGBoost

DSA ve DVM gibi eXtreme Gradient Boosting (XGBoost) yöntemi de denetimli öğrenme için kullanılan bir yaklaşımdır. XGBoost gradyan artırmaya (gradient boosting) dayanan bir yöntemdir. Verimliliği ve doğruluğu nedeniyle makine öğrenimi yarışmalarında ve pratik uygulamalarda yaygın olarak kullanılmaktadır [37].

XGBoost temel olarak karar ağaçlarına dayanmaktadır. Yöntem özünde, her ağacın bir öncekinin hatalarını düzeltmeye çalıştığı, sıralı bir karar ağaçları topluluğu oluşturma yaklaşımını benimsemektedir. XGBoost'taki amaç

fonsiyonu, aşırı uyumu önlemek için bir kayıp fonksiyonu ile bir düzenleme terimini birleştirir. Kayıp fonksiyonu Denklem (8)'deki gibi hesaplanabilir;

$$L(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$

Burada y_i gerçek değer, \hat{y}_i kestirilen değer, n ise veri sayısını ifade eder. Düzenleme terimi ise Denklem (9)'daki gibidir;

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (9)$$

T Ağaçtaki yaprak sayısını, w_j^2 J yaprağındaki ağırlığı, γ ve λ terimleri ise aşırı öğrenmeyi engellemek için kullanılan parametrelerdir.

Sonuç olarak nihai amaç fonksiyonu Denklem (10)'daki gibi ifade edilebilir:

$$\text{Obj} = \sum_{i=1}^n L(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (10)$$

Burada K ağaç sayısını ifade eder.

XGBoost, amaç fonksiyonunu minimize etmek için gradyan artırma kullanır. Temel yaklaşım, önceki ağaçların hatalarını tahmin eden yeni ağaçlar eklemektir. Model Denklem (11)'deki gibi güncellenir:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(\mathbf{x}_i) \quad (11)$$

$f_t(\mathbf{x}_i)$ iterasyondaki tahmini, $\hat{y}_i^{(t-1)}$ ise iterasyondaki yeni ağacın kestirimini ifade eder.

XGBoost'taki her ağaç, aşağıdaki amaç fonksiyonunu minimize etmek için Denklem (12)'de olduğu gibi oluşturulur:

$$\text{Obj}^{(t)} = \sum_{i=1}^n [g_i f_t(\mathbf{x}_i) + \frac{1}{2} h_i f_t(\mathbf{x}_i)^2] + \Omega(f_t) \quad (12)$$

Burada, $g_i = \partial_{\hat{y}_i^{(t-1)}} L(y_i, \hat{y}_i^{(t-1)})$ birinci dereceden gradyan

$(h_i = \partial_{\hat{y}_i^{(t-1)}}^2 L(y_i, \hat{y}_i^{(t-1)}))$ ise ikinci dereceden gradyandır.

XGBoost boş bir ağaç yapısında başlayarak, Denklem (13)'de gösterilen kazanç fonksiyonunu minimize etmek için yaprakları art arda böler.

$$\text{Kazanç} = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (13)$$

G_L ve G_R sol ve sağ bölmeler için gradyanların toplamı iken H_L ve H_R sol ve sağ bölmeler için Hessianların toplamıdır. Yeni bir gözlem (x) için nihai tahmin, tüm ağaçların tahminlerinin toplamıdır (Denklem (14)):

$$\hat{y} = \sum_{k=1}^K f_k(\mathbf{x}) \quad (14)$$

Bu yaklaşım, XGBoost'un yüksek doğruluk ve sağlıklı elde etmesini sağlar [37].

Bulgular ve Tartışma

Krigleme yöntemi günümüzde iyi bir şekilde anlaşıldığı için krigleme adamları ve bu adımlardaki parametrelerin belirlenmesi genel kabul gören bir hal almıştır. Bu genel kabul gören adımlar uygulanarak öncelikle deneysel variogramlar hesaplanmış, sonrasında model variogramlar uyarlanmış, bu variogramların kullanılabilirliği test edilmiş ve sonuç olarak bu model variogramlar kullanılarak blok bazında kestirimler yapılmıştır. Elde edilen variogram modeli izotrop bir küresel modeldir. Bu modelin küre etkisi değeri 1,5, eşik değeri 45 ve yapısal uzaklığı 120 m'dir. Tarama küresi ise tüm blokların tek seferde kestirilmesine yetecek şekilde 200 m yarıçapında seçilmiştir. Tüm yapılan krigleme işlemlerinde NetproMine isimli madencilik yazılımı kullanılmıştır.

Makine öğrenmesine ilişkin yöntemlerde model doğrulama adımları iyi bilinen krigleme yönteminin aksine genel kabul gören bir hal almamıştır. Bu sebepten, bu çalışmada deneme yanılma yöntemi ile model parametreleri belirlenmiştir. Makine öğrenmesine yönelik yapılan tüm işlemlerde Python programlama dili kullanılarak yazılan programlar çalıştırılmıştır. Ayrıca makine öğrenme yaklaşımları genellikle işlem yoğun olduğundan günümüz standartlarında bir bilgisayar ile kestirimler yapılmıştır. Kestirimde kullanılan bilgisayar 3,00 GHz işlem gücüne sahip 13. nesil Intel bir işlemcidir. Bilgisayarda toplamda 32 çekirdek bulunmakla birlikte 64 GB'lık bir RAM bulunmaktadır. Tüm yöntemlerde yapılan kestirimler eğitim işlemi bittikten sonra toplamda 26834 adet blok için kestirimler birkaç saniye sürmüştür. Blok boyutları sabit olup X, Y ve Z yönlerinde sırası ile 10, 10 ve 2 m olarak belirlenmiştir.

Derin sinir ağları ile kestirim için diğer yöntemlerde olduğu gibi girdi olarak kompozitlerin X, Y ve Z değerleri kullanılırken hedef değer (çıkıtı) olarak Fe tenörleri kullanılmıştır. Ayrıca DSA ve DVM ile kestirimlerde tüm girdiler normalize edilmiştir. Birçok normalizasyon yöntemi bulunmakla birlikte bu çalışmada Denklem (15)'te verilen min-maks normalizasyonu kullanılmıştır.

$$D_n = \frac{\tau - \tau_{min}}{\tau_{max} - \tau_{min}} \quad (15)$$

Burada; D_n normalize edilmiş değer, τ değişken, τ_{min} ve τ_{max} ise sırası ile değişkenin en düşük ve en yüksek değerlerini ifade eder. Normalizasyon adımı DSA ve DVM için gerçekleştirilmiş olup, XGBoost için yapılmamıştır. DSA ve DVM için yapılmasının sebebi ise ilgili yaklaşımların normalize edilmiş değerler üzerinden daha hızlı bir şekilde eğitilmesini sağlanmasıdır. Model eğitimleri ve kestirimler aynı normalizasyon değerleri kullanılarak yapıldığından kestirim sonuçları bu adımdan etkilenmemiştir.

Bunun sebebi bloklara da aynı normalizasyonun uygulanmasıdır. Kestirimler normalize edilmiş X, Y ve Z değerleri üzerinden yapılmış olup, bloklar kestirimlerden sonra eski koordinatlarına geri getirilmiştir. Fe değerleri için herhangi bir normalizasyon uygulanmamıştır. Bunun sebebi ise Fe değerlerinin hali hazırda düşük değerler olan 30 ile 61 arasında değişmesidir.

Bu işlem DSA modelinin kısa süre içerisinde eğitilmesini sağlayan bir adımdır. DSA ile yapılan kestirimlerde kompozit verilerin %70 derin sinir ağına eğitmek, %15'i eğitimi doğrulamak ve geriye kalan %15'i ise eğitilen modelin testi için kullanılmıştır.

DSA gizli tabakalarında Tanh aktivasyon fonksiyonu kullanılmış, ancak Fe tenör değerlerine giden son çıktı tabakasında ise doğrusal fonksiyon kullanılmıştır. Maliyet fonksiyonunun minimizasyonunda gradyan azaltma (Gradient descent) yaklaşımı kullanılmıştır. Kullanılan maliyet fonksiyonu ortalama karesel hatadır. DSA'nın yapısı ise koordinatların beslendiği ilk tabaka, 15 düğüm noktasından oluşan iki tabaka ve çıktı tabakası olmak üzere toplamda 4 tabakadan oluşmaktadır. Model MSE'si değerlendirildiğinde 1000 optimizasyon adımında sonra en düşük değerlere ulaşıldığı görülmüştür. Ayrıca eğitim, test ve doğrulama adımlarındaki hedef ve kestirim değerleri arasındaki korelasyon katsayılarının ise sırası ile 0,78, 0,75 ve 0,77 olduğu gözlenmiştir. Değerlerin birbirlerine yakın çıkması modelin genelleme seviyesinin yeterli düzeyde olduğunu göstermektedir. Böylece eğitilen DSA modeli blokların kestirimlerinde kullanılmıştır.

Destek Vektör Makinesi (DVM) ile kestirimde DSA'ya benzer adımlar uygulanmıştır. Girdi olarak kullanılan X, Y ve Z değerleri ile çıktı olan Fe değerleri normalize edilmiştir. DSA dan farklı olarak DVM'ler çekirdek fonksiyonuna ihtiyaç duymaktadırlar. Bu çalışmada alternatifler arasından regresyon amaçlı en sık kullanılan Radyal Temelli Çekirdek fonksiyonu tercih edilmiştir. Diğer optimize edilmesi gereken parametreler ise epsilon ve C ceza parametreleridir. Bu parametrelerin modellenmesi için veri kümesi %80-%20 eğitim ve test olmak üzere iki gruba ayrılmıştır.

Yapılan deneme yanılma işlemi sonucunda C 10, epsilon 0,025 ve sigma parametresi ise 0,15 olarak belirlenmiştir. DSA'ya benzer şekilde blokların X, Y ve Z koordinat değerleri girdi olarak kullanılarak Fe değerleri her bir blok için kestirilmiştir. Kestirim sonuçlarına ve kompozitlere ait özet istatistikler Tablo 2'de verilmiştir.

Tablo 2. Kompozitler ve kestirim sonuçları

	Kompozit	Krigleme	DSA	DVM	XGBoost
Veri sayısı	236	26835	26835	26835	26835
En düşük	30,76	31,0	30,0	31,9	30,8
Ortalama	54,5	55,0	59,8	56,1	53,9
Ortanca	57,6	55,7	58,7	56,4	54,9
En yüksek	61,43	61,4	60,0	65,0	64,8
Standart Sapma	6,82	4,36	4,20	4,48	5,35


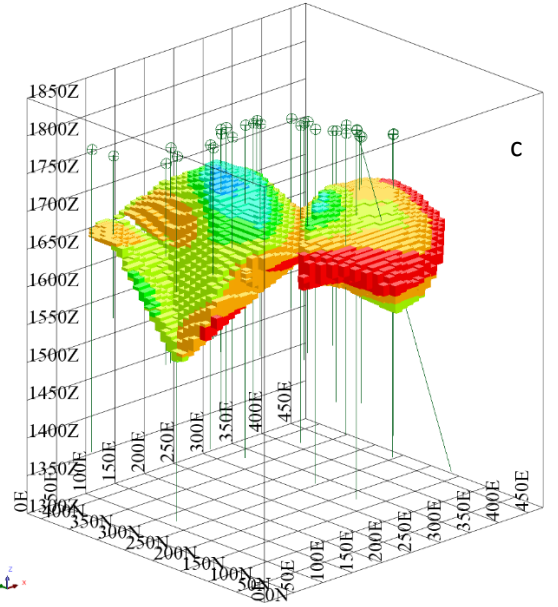


Tablo 2’de görüldüğü üzere tüm yöntemler yumuşatma özelliği göstermektedir. Diğer bir deyişle, elde edilen kestirim varyansları kompozitlerin varyansından düşüktür.

Tablo 3’te gösterilen istatistiklerin karşılaştırılması amacıyla kompozit istatistiklerden sapmaları gösterilmiştir.

Tablo 3. Kestirimlere ait istatistiklerin kompozit istatistiklerinden sapma değerleri.

Yüzdece sapma (%)	Krigleme	DSA	DVM	XGBoost
En düşük	0.8	-2.5	3.7	0.1
Ortalama	0.9	9.7	2.9	-1.1
Ortanca	-3.3	1.9	-2.1	-4.7
En yüksek	0.0	-2.3	5.8	5.5
Standart Sapma	-36.1	-38.4	-34.3	-21.6

Tablo 2’de görüldüğü üzere hiçbir yöntem kompozitler ile aynı istatistikleri üretmemiştir. Tablo 3’te gösterilen istatistiki farkların yüzdeleri incelendiğinde tek bir yöntemin tüm diğer yöntemlere üstünlük sağlaması gibi bir durum da oluşmamıştır. Her bir yöntemin öne çıktığı istatistikler farklıdır. Krigleme Ortalama ve en yüksek değer bazında diğer yöntemlerden öne çıkarken, XGBoost en düşük ve standart sapma bazında kompozitlere en yakın istatistikleri üretmiş olup, DSA ise ortanca bazında diğer yöntemlerden daha iyi sonuç üretmiştir. Şekil 2’de ise blok model kestirim sonuçları gösterilmiştir.



Şekil 2 Kestirimler sonucu oluşan Fe (%) değerleri a) Krigleme b) DSA c) DVM d) XGBoost

Şekil 2’de görüldüğü üzere kestirimlerin birbirlerine benzediği ve ayrıştığı durumlar vardır. Tüm kestirim yöntemleri cevherleşmenin güneydoğusunda yüksek tenörlü bir kısma işaret etmektedir. Benzer şekilde güneybatı kısımlarında ise değişkenliğin yüksek olduğu görece yüksek (%45-60 Fe arası) kısımlar mevcuttur. Genellikle ayrışan kısımlar ise yatağın merkezine yakın olan ve en üst kotlarda bulunan kısımlarda DSA ve DVM yöntemleri görece düşük tenörleri işaret etmektedir. Ayrıca sadece DVM ile yapılan kestirimler yatağın doğu kısmındaki sınırları oldukça yüksek olduğunu göstermektedir. DVM’nin neden böyle bir sonuç ürettiği bilinmemektedir. Bu duruma dikkatle yaklaşmak gerekmektedir. İlgili alandaki yüksek tenörlerin kesinlikle ek sondajlarla teyit edilmesi elzemdir.

Tablo 3’te görüldüğü üzere makine öğrenme yöntemlerinin bazılarında kompozitlerde görülen değerlerin dışında kestirim değerleri tespit edilmiştir. Bu durumla özellikle yatağın sınır kısımlarında karşılaşılmaktadır. Bunun sebebi ise ilgili kısımların eğitimde kullanılan X, Y ve Z değerlerinin dışında kalmasıdır. Diğer bir bakış açısı ile yatak sınırlarında sondaj bulunmadığından eğitilen modeller ilgili kısımlarda ekstrapolasyon yapmıştır. Bu sebepten bu kısımlardaki kestirimlere dikkatli yaklaşmak gerekmektedir. İlgili kısımların doğrulunun testi için ek veri toplanması tavsiye edilmektedir.

Günümüzde kaynak kestirimi, tenör modellemesi amacı ile kullanılan makine öğrenme yöntemleri kara kutu (black box) olarak çalışmaktadırlar. Diğer bir ifade ile elde edilen sonuçlara nasıl ve neden varıldığı bazı kurallara bağlı olarak belirlenirken sonuçlara varmak için eğitilen modellerin yorumlaması oldukça güç olup, genelde mümkün değildir. Bu sebepten mevcut jeostatistiksel yöntemlerde olduğu gibi variograma ait yapısal uzaklık, eşik değer ve külçe etkisi gibi kavramlardan bahsetmek söz konusu değildir. Makine öğrenmesinde, bu kavramlardan söz edilemeyeceği gibi buna benzer olan parametreler de bulunmamaktadır. Bu durum, belirtildiği üzere, makine öğrenme yöntemlerinin kara kutu yapısından kaynaklanmaktadır. Ayrıca makine öğrenmesi yaklaşımlarında kullanılan parametreler deneme yanılma yöntemi ile belirlenmiştir. Bu durum her zaman en uygun parametre değerlerinin bulunduğunu garanti etmemektedir. Bu çalışmada sistematik bir şekilde parametreler taranmış ve kompozitlerin istatistiklerine en yakın sonuçları veren parametreler kestirim parametreleri olarak belirlenmiştir.

Sonuç

Maden kaynaklarının değerlendirmesindeki en önemli adımlardan birisi olan tenör kestirimi için günümüzde yaygın olarak krigleme kullanılsa da makine öğrenme algoritmaları alternatif olarak ortaya çıkmaktadır. Makine öğrenme yöntemlerinden DSA, DVM ve XGBoost algoritmalarının birlikte değerlendirildiği bir çalışma bulunmamaktadır. Bu çalışmada ilgili yöntemler karşılaştırılmıştır. Karşılaştırma

amacı ile bir demir yatağındaki Fe tenörleri belirtilen yöntemler ile kestirilmiştir. Kestirimler için kriglemede model variogramlar uyarlanırken diğer yöntemlerde ise yöntemlere özel parametrelerin tahminleri yapılmıştır. Makine öğrenmesi yöntemlerinin eğitilmesinde girdi olarak kompozitlerin X, Y ve Z değerleri kullanılırken çıktı olarak da Fe değerleri kullanılmıştır. Böylece eğitilen modellerin blok Fe tenörleri kestirilmiştir.

Kestirim sonuçları diğerlerine her açıdan üstünlük sağlayan bir yöntemin olmadığını göstermektedir. Krigleme ortalama ve en yüksek değer açısından üstün görünürken, XGBoost en düşük ve standart sapma açısından daha iyi sonuçlar üretmiştir. DSA ise ortanca değer bakımından en iyi sonucu üretmiştir. DVM’nin ise diğerlerine üstünlük sağladığı bir istatistik bulunamamıştır.

Krigleme diğer tüm yöntemlere her açıdan üstünlük sağlayamasa da kaynak kestiriminde bu yöntemin yaygın olarak kullanılmasının ilk sebebi 1950’lerden günümüze bilinmesi ve bu sebepten konuya aşına kişi sayısının daha çok olmasıdır. Ayrıca günümüzde alternatif olarak gelişen makine öğrenmesi yöntemleri, bu çalışmada görüldüğü gibi, her zaman istenen aralıklarda yani kompozit değerleri aralığında sonuçlar üretmeyi garanti etmemektedir. Bununla birlikte elde edilen sonuçların yorumlanması genellikle mümkün değildir. Makine öğrenme yöntemlerinde, kompozitler üzerinden eğitilen modellerin genel kestirici olarak beklenen özelliklerde sonuçlar üretmesi beklenirken bu beklenen sonuçların ulaşılacağını garanti etmemektedir. Bu duruma örnek olarak, DVM ile yapılan kestirimde yatak sınırlarında beklenmeyen yüksek tenörlü kısımlar ile karşılaşmıştır. Ancak yöntemin doğası gereği bu durumun bir açıklamasının yapılması mümkün değildir. Bu gibi sebeplerden makine öğrenmesi ile kestirimler günümüzde halen akademik olarak araştırma seviyesinde olup, krigleme maden kaynak kestiriminde sıklıkla kullanılmaktadır.

Bu çalışmadan elde edilen bir diğer sonuç da bazı kestirim yöntemlerinin ekstrapolasyon yaparak kompozitlerin bulunduğu değer aralığı dışında kestirimler üretmesidir. Örneğin DSA en düşük değeri yaklaşık olarak kompozit en düşük değerlerinden %2,5 daha düşüktür. Yani kestirim değerlerinin en düşük değeri kompozitlerden daha düşüktür. Benzer şekilde DVM ve XGBoost’da elde edilen kestirim değerlerinin en yüksek değerleri de kompozitlerden yaklaşık olarak %5 daha yüksektir. Bu durum tenör kestirimlerinde istenmeyen bir durumdur. Bunun sebebi ise hedef olan kompozit değerleri aralığı dışındaki bir kestirim değerinin gerçekçiliğinin sorgulanmaya açık bir durum olmasıdır. Krigleme de ise böyle bir durum söz konusu değildir. Bu sebepten makine öğrenmesine dayalı yöntemlerle yapılan kestirimlerde mutlak suretle bir uzmanın eleştirel bir şekilde inceleme yapması gerekmektedir.

Önceden belirtildiği üzere krigleme ile kestirim adımları genel kabul gören bir hal almıştır. Ancak bu genel kabul görmüş yaklaşımlar makine öğrenmesi ile kestirimlerde mevcut değildir. Tenör kestirimlerine ilişkin yapılan

çalışmalarda parametre belirleme yaklaşımları çeşitlilik göstermekle birlikte bu çalışmada deneme yanılma yöntemi kullanılmıştır. Ancak deneme yanılma yöntemi en iyi parametrenin belirlendiğini garanti etmemektedir. Bu sebepten konumsal tenör değerlerinin tahmininde makine öğrenmesine yönelik temel yaklaşımların endüstri pratiklerinden ve iyi örneklerden yola çıkarak daha genel kabul gören bir yapıya büründürülmesi gerekmektedir.

Ayrıca ileri dönem çalışmalarında kriglemenin doğrusal olmayan varyasyonlarının da karşılaştırmaya dahil edilmesi önerilmektedir. Özellikle çarpık dağılıma sahip veri kümelerinde log-normal Krigleme ve verilerin belirli bir kritik değeri aşma olasılıklarının belirlenmesi istenmesi durumunda ise Ayrıcı (disjunctive) Krigleme gibi doğrusal olmayan yöntemlere başvurulabilir. Bu çalışmaya konu olan veri kümesinde konumsal olarak ciddi bir çarpık dağılım gözlenmediğinden doğrusal olmayan krigleme yöntemlerine başvurulmamıştır.

Teşekkür

Yazar, değerlendirme sürecinde bilgi birikimleri ve yapıcı eleştirileri ile makalenin bilimsel kalitesinin iyileştirilmesine katkıda bulunan anonim değerlendirecilere ve editörlere içtenlikle teşekkür eder. Yazar, ayrıca, makalenin yazım aşamasında sunmuş oldukları katkılardan dolayı Dr. S. Yasin Kılıoğlu ve Dr. M. Suphi Ünal'a teşekkürü bir borç bilir.

Kaynaklar

- [1] F. Atalay, M. S. Ünal, and S. Y. Kılıoğlu, "Bir Demir Yatağında Radyal Temelli Fonksiyon ve Ortalamasız Krigleme Kestirimlerinin Karşılaştırılması," *Avrupa Bilim ve Teknoloji Dergisi*, no. 27, pp. 303-310, 2021.
- [2] A. M. Albora, "Investigation of Bingöl Iron Ore Reserves Using Wavelet Cellular Neural Networks," *International Journal Of Scientific Advances*, vol. 2, no. 1, 2021, doi: 10.51542/ijscia.v2i1.9.
- [3] M. Badel, S. Angorani, and M. Shariat Panahi, "The application of median indicator kriging and neural network in modeling mixed population in an iron ore deposit," *Computers & Geosciences*, vol. 37, no. 4, pp. 530-540, 2011, doi: 10.1016/j.cageo.2010.07.009.
- [4] S. Chatterjee, S. Bandopadhyay, and D. Machuca, "Ore Grade Prediction Using a Genetic Algorithm and Clustering Based Ensemble Neural Network Model," *Mathematical Geosciences*, vol. 42, no. 3, pp. 309-326, 2010, doi: 10.1007/s11004-010-9264-y.
- [5] S. Dutta, D. Misra, R. Ganguli, B. Samanta, and S. Bandopadhyay, "A hybrid ensemble model of kriging and neural network for ore grade estimation," *International Journal of Mining, Reclamation and Environment*, vol. 20, no. 1, pp. 33-45, 2006, doi: 10.1080/13895260500322236.
- [6] V. Rodriguez-Galiano, M. Sanchez-Castillo, M. Chica-Olmo, and M. Chica-Rivas, "Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines," *Ore Geology Reviews*, vol. 71, pp. 804-818, 2015, doi: 10.1016/j.oregeorev.2015.01.001.
- [7] B. Samanta, S. Bandopadhyay, and R. Ganguli, "Comparative Evaluation of Neural Network Learning Algorithms for Ore Grade Estimation," *Mathematical Geology*, vol. 38, no. 2, pp. 175-197, 2006, doi: 10.1007/s11004-005-9010-z.
- [8] M. Shabankareh and A. Hezarkhani, "Application of support vector machines for copper potential mapping in Kerman region, Iran," *Journal of African Earth Sciences*, vol. 128, pp. 116-126, 2017, doi: 10.1016/j.jafrearsci.2016.11.032.
- [9] R. Shamsi, H. Dehghani, M. Jalali, and B. Jodeiri Shokri, "Ore grade estimation using the imperialist competitive algorithm (ICA)," *Arabian Journal of Geosciences*, vol. 14, no. 14, 2021, doi: 10.1007/s12517-021-07808-7.
- [10] A. Skabar, "Modeling the Spatial Distribution of Mineral Deposits Using Neural Networks," *Natural Resource Modeling*, vol. 20, no. 3, pp. 435-450, 2008, doi: 10.1111/j.1939-7445.2007.tb00215.x.
- [11] R. Zuo and E. J. M. Carranza, "Support vector machine: A tool for mapping mineral prospectivity," *Computers & Geosciences*, vol. 37, no. 12, pp. 1967-1975, 2011, doi: 10.1016/j.cageo.2010.09.014.
- [12] T. B. Afeni, A. I. Lawal, and R. A. Adeyemi, "Re-examination of Itakpe iron ore deposit for reserve estimation using geostatistics and artificial neural network techniques," *Arabian Journal of Geosciences*, vol. 13, no. 14, 2020, doi: 10.1007/s12517-020-05644-9.
- [13] B. Jafarsteh, N. Fathianpour, and A. Suárez, "Comparison of machine learning methods for copper ore grade estimation," *Computational Geosciences*, vol. 22, no. 5, pp. 1371-1388, 2018, doi: 10.1007/s10596-018-9758-0.
- [14] A. D. Goswami, M. K. Mishra, and D. Patra, "Evaluation of machine learning algorithms for grade estimation using GRNN & SVR," *Engineering Research Express*, vol. 4, no. 3, 2022, doi: 10.1088/2631-8695/ac8912.
- [15] M. M. Zaki et al., "A Novel Approach for Resource Estimation of Highly Skewed Gold Using Machine Learning Algorithms," *Minerals*, vol. 12, no. 7, 2022, doi: 10.3390/min12070900.
- [16] S. Dutta, S. Bandopadhyay, R. Ganguli, and D. Misra, "Machine Learning Algorithms and Their Application to Ore Reserve Estimation of Sparse and Imprecise Data," *Journal of Intelligent Learning Systems and Applications*, vol. 02, no. 02, pp. 86-96, 2010, doi: 10.4236/jilsa.2010.22012.
- [17] S. Soltani-Mohammadi, F. S. Hoseinian, M. Abbaszadeh, and M. Khodadadzadeh, "Grade estimation using a hybrid method of back-propagation artificial neural network and particle swarm optimization with integrated samples

- coordinate and local variability," *Computers & Geosciences*, vol. 159, 2022, doi: 10.1016/j.cageo.2021.104981.
- [18] R. K. Singh, D. Ray, and B. C. Sarkar, "Mineral deposit grade assessment using a hybrid model of kriging and generalized regression neural network," *Neural Computing and Applications*, vol. 34, no. 13, pp. 10611-10627, 2022, doi: 10.1007/s00521-022-06951-w.
- [19] Y. Zhang, S. Song, K. You, X. Zhang, and C. Wu, "Relevance vector machines using weighted expected squared distance for ore grade estimation with incomplete data," *International Journal of Machine Learning and Cybernetics*, vol. 8, no. 5, pp. 1655-1666, 2016, doi: 10.1007/s13042-016-0535-x.
- [20] M. A. Mahboob, T. Celik, and B. Genc, "Review of machine learning-based Mineral Resource estimation," *Journal of the Southern African Institute of Mining and Metallurgy*, vol. 122, no. 11, pp. 1-10, 2023, doi: 10.17159/2411-9717/1250/2022.
- [21] F. Atalay, "Estimation of Fe Grade at an Ore Deposit Using Extreme Gradient Boosting Trees (XGBoost)," *Mining, Metallurgy & Exploration*, pp. 1-10, 2024.
- [22] M. Galetakis, A. Vasileiou, A. Rogdaki, V. Deligiorgis, and S. Raka, "Estimation of Mineral Resources with Machine Learning Techniques," presented at the International Conference on Raw Materials and Circular Economy, 2022.
- [23] X.-l. Li, Y.-l. Xie, Q.-j. Guo, and L.-h. Li, "Adaptive ore grade estimation method for the mineral deposit evaluation," *Mathematical and Computer Modelling*, vol. 52, no. 11-12, pp. 1947-1956, 2010, doi: 10.1016/j.mcm.2010.04.018.
- [24] F. Maepa, R. S. Smith, and A. Tessema, "Support vector machine and artificial neural network modelling of orogenic gold prospectivity mapping in the Swayze greenstone belt, Ontario, Canada," *Ore Geology Reviews*, vol. 130, 2021, doi: 10.1016/j.oregeorev.2020.103968.
- [25] N. Mery and D. Marcotte, "Quantifying Mineral Resources and Their Uncertainty Using Two Existing Machine Learning Methods," *Mathematical Geosciences*, vol. 54, no. 2, pp. 363-387, 2021, doi: 10.1007/s11004-021-09971-9.
- [26] B. Samanta, R. Ganguli, and S. Bandopadhyay, "Comparing the predictive performance of neural networks with ordinary kriging in a bauxite deposit," *Mining Technology*, vol. 114, no. 3, pp. 129-139, 2013, doi: 10.1179/037178405x53980.
- [27] K. Mostafaei, S. maleki, and B. Jodeiri, "A new gold grade estimation approach by using support vector machine (SVM) and back propagation neural network (BPNN)- A Case study: Dalli deposit, Iran," 2022, doi: 10.21203/rs.3.rs-2008568/v1.
- [28] N. B. Tsae, T. Adachi, and Y. Kawamura, "Application of Artificial Neural Network for the Prediction of Copper Ore Grade," *Minerals*, vol. 13, no. 5, 2023, doi: 10.3390/min13050658.
- [29] X. Zhang, S. Song, J. Li, and C. Wu, "Robust LS-SVM regression for ore grade estimation in a seafloor hydrothermal sulphide deposit," *Acta Oceanologica Sinica*, vol. 32, no. 8, pp. 16-25, 2013, doi: 10.1007/s13131-013-0337-x.
- [30] A. G. Journel and C. J. Huijbregts, "Mining geostatistics," 1976.
- [31] T. Hossen, S. J. Plathottam, R. K. Angamuthu, P. Ranganathan, and H. Salehfar, "Short-term load forecasting using deep neural networks (DNN)," in *2017 North American Power Symposium (NAPS)*, 2017: IEEE, pp. 1-6.
- [32] A. L. Maas et al., "Building DNN acoustic models for large vocabulary speech recognition," *Computer Speech & Language*, vol. 41, pp. 195-213, 2017.
- [33] S. Wang, F. Shui, T. Stratford, J. Su, and B. Li, "Modelling nonlinear shear creep behaviour of a structural adhesive using deep neural networks (DNN)," *Construction and Building Materials*, vol. 414, p. 135083, 2024.
- [34] W. Samek, G. Montavon, S. Lapuschkin, C. J. Anders, and K.-R. Müller, "Explaining deep neural networks and beyond: A review of methods and applications," *Proceedings of the IEEE*, vol. 109, no. 3, pp. 247-278, 2021.
- [35] A. J. Smola and B. Schölkopf, "A tutorial on support vector regression," *Statistics and computing*, vol. 14, pp. 199-222, 2004.
- [36] H. Drucker, C. J. Burges, L. Kaufman, A. Smola, and V. Vapnik, "Support vector regression machines," *Advances in neural information processing systems*, vol. 9, 1996.
- [37] T. Chen, "Xgboost: extreme gradient boosting," *R package version 0.4-2*, vol. 1, no. 4, 2015.



Magnezyum oksit içeren hammaddelerin porselen izolatör bünyesi teknik özellikleri üzerine olan etkisi

Effect of magnesium oxide containing raw materials on the technical properties of porcelain insulator body

Ceyda Ayça Avcı^{1,2}, Şefik Baran Tarhan^{1*}

¹ Uşak Üniversitesi, GSF, Seramik Bölümü, ceydaaycaavci@yandex.com
ORCID: <https://orcid.org/0000-0001-9414-9380>

² Ankara Seramik A.Ş., Ar-Ge Merkezi, baran.tarhan@usak.edu.tr
ORCID: <https://orcid.org/0000-0003-0440-4646>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 24 Ekim 2024
Revizyon 20 Kasım 2024
Kabul 4 Aralık 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

Porselen izolatör,
Magnezyum oksit kaynakları,
Manyezit,
Talk

ÖZ

Porselen izolatör massesinde akışkanlaştırıcı olarak genellikle feldspat kullanılmaktadır. Günümüzde stoneware, seramik sağlık gereçleri, anortit bazlı porselenler, kemik porselenleri, seramik karoları üzerinde yapılan çalışmalar ile çeşitli magnezyum oksit kaynakları ile akışkanlaştırıcı özellik sağlanması yanı sıra mukavemet değerlerinde artış ve sinterlenme tepe sıcaklıklarında yaklaşık 50°C'lik azalma görüldüğü gözlemlenmektedir. Porselen izolatörler için yüksek maliyetli feldspatlara alternatif olarak toprak alkali içeren hammaddelerin ikame edilebilirliği hammadde maliyetinin azaltılmasını ve alternatif ergitici kaynakları oluşmasını sağlayacaktır. Ayrıca porselen izolatörlerin; sinterlenme sürelerinin azaltılması, doğal gaz tüketiminin azalmasını sağlayacağından hem enerji kaynaklarının korunmasını sağlayacak hem de daha çevreci bir üretime imkân sağlayacaktır. Bu çalışmada magnezyum oksit içeren ham maddelerden talk ve manyezit, porselen izolatör bünyesinde %0.5-1 ve 3 oranlarında, feldspat ile ikame ettirilerek teknik özellikleri üzerine etkileri araştırılmıştır. Elektroporselen bünyesinde magnezyum oksit kaynağı olarak talk ve manyezit kullanımının oranının artması ile beraber % görünür gözeneklilik, % su emme, % pişme küçülmesi, deformasyon değerlerinde artış ve % görünür katı yoğunluk, sırsız ve sırlı pişme mukavemeti değerlerinde azalma gözlemlenmiştir.

ARTICLE INFO

Article history:

Received 24 October 2024
Received in revised form 20 November 2024
Accepted 4 December 2024
Available online 23 December 2024

Keywords:

Porcelain insulator,
Magnesium oxide sources,
Magnesite,
Talc

ABSTRACT

In porcelain insulator bodies, feldspar is generally used as a flux. Today, studies on stoneware, whiteware, ceramic sanitaryware, anorthite-based porcelains, bone porcelains, and ceramic tiles show that in addition to providing plasticizer properties with various magnesium oxide sources, an increase in strength values and a decrease of approximately 50°C in sintering peak temperatures are observed. Substitutability of alkaline earth raw materials as an alternative to high-cost p feldspars for porcelain insulators will reduce raw material costs and create alternative flux sources. In addition, since lowering the sintering times of porcelain insulators will reduce natural gas consumption, it will protect energy resources and enable a more environmentally friendly production. In this study, talc and magnesite, raw materials containing magnesium oxide, were replaced with feldspar in porcelain insulators with different ratios of 0.5-1 and 3%, and their effects on technical properties were investigated. With the increase in the use of talc and magnesite as magnesium oxide sources in the electroporcelain, an increase in % apparent porosity, % water absorption, % firing shrinkage, deformation values, and a decrease in % apparent solid density, unglazed and glazed firing strength values were observed.

Doi: 10.24012/dumf.1573038

* Sorumlu Yazar

Giriş

İzolatörler, üretim süreçleri ve üretiminde kullanılan hammaddeler açısından diğer porselen ürünlerine benzerlik gösterse de, porselen izolatörlerden beklenen performans ve kalite gereksinimleri farklılık göstermektedir. İzolatörler kullanılmadan önce IEC tarafından belirlenen çeşitli testlerde (flaş, delinme, elektromekanik kırılma, güç frekansı vb.) başarılı olmalıdır [1].

Porselen izolatörlerin masselerine ait çeşitli özellikler (görünür gözeneklilik, yoğunluk, sırsız ve sırlı eğilme mukavemeti, termal şok dayanımı vs.) IEC 672 standardınca garanti altına alınmıştır. Bu standarda göre porselenler beş gruba ayrılır:

- Steatit porselenler (sınıf C-220)
- Kuvars porselenler (sınıf C-110).
- Alümina porselenler (C-120 ve C-130 sınıfı).
- Kristobalit porselen (sınıf C-112).

• Yüksek alümina porselenler (ağırlıkça % 80–86 alümina içeren C-780 sınıfı ve ağırlıkça % 86–94.5 alümina içeren C-786 sınıfı) [2].

Porselen izolatör üretiminde en yaygın kullanılan masse çeşitleri kuvars ve alümina esaslı C110, C120 ve C130 sınıfları olup C110 alçak ve orta, C120 ve C130 ise sahip oldukları yüksek yoğunluk ve sırsız ve sırlı eğilme mukavemeti değerleri ile yüksek ve çok yüksek gerilim hatlarında kullanılmak üzere tercih edilmektedirler.

Elektriksel porselen izolatörlerinin üretiminde kullanılan başlıca hammaddeler kaolen, feldispat ve kuvarstır. Kaolen, karışıma şekillendirme sürecini kolaylaştıran gerekli esnekliği sağlar. Feldispat, karışımın camlaşma sıcaklığını düşüren bir akı görevi görür. Kuvars, gövdenin mekanik dayanıklılığına katkıda bulunan refrakter kristal fazını veya iskeletini sağlar [3]. Kil $[(Al_2Si_2O_5(OH)_4)]$ seramik karışımına esneklik kazandırır, flint veya kuvars $[SiO_2]$ pişirme sırasında oluşan maddenin şeklini korur ve feldispat $[KxNax(AlSi_3)O_8]$ akı görevi görür[4]. Bu üç bileşen, oksit bileşenleri açısından elektriksel porseleni faz sistemine yerleştirir, dolayısıyla üç eksenli porselen terimi kullanılır [5].

Porselen izolatör massesinde akışkanlaştırıcı olarak genellikle potasyum feldispat kullanılmaktadır. Günümüzde stoneware, whiteware, seramik sağlık gereçleri, anortit bazlı porselenler, kemik porselenleri, seramik karoları üzerinde yapılan çalışmalar ile çeşitli kalsiyum ve magnezyum oksit kaynakları ile akışkanlaştırıcı özellik sağlandığı görülmektedir. Birçok çalışmada da farklı alkali kaynakları ve hammaddeler kullanılarak seramik ürünlere olan etkileri incelenmiştir. Bu çalışmalarda yerel alkali kaynakları kullanılarak pişirim sıcaklık ve süreleri düşürülemeye çalışılmış [6-8]. Farklı hammaddeler feldispat ve diğer hammaddeler yerine kullanılarak sinterleme parametreleri incelenmiştir[9,10].

Mukhopadhyay ve ark. (2003) çalışmasında, bünyelerinde illitik kil ihtiva eden kompozisyonlara yapılan talk ilavesinin mekanik, mikroyapı ve ısıl üzerine olan etkilerini araştırılmıştır. Uygun oranda yapılan talk/feldispat

kompozisyonunun vitrifikasyon sıcaklığını düşürdüğü belirlenmiştir. Talk ilavesiyle kompozisyonda bulunan MgO , viskozitesi daha düşük camsı fazı daha düşük sıcaklıklarda oluşturduğu, sinterleşme sıcaklığını düşürdüğünü buna karşın sinterleme aralığını daralttığı gözlemlenmiştir. %3 lük talk ilavesiyle bünyede bulunan kalıntı kuvars miktarı azalmış bu yüzden de termal genleşme katsayısını düşürmüştür. Talk ilave miktarının artmasıyla yapıdaki gözeneklerin genleşmesine dolayısıyla da amorf fazın daha fazla genleşmesine sebep olduğu bildirilmiştir [11].

Daniel Magagnin ve ark.(2014) yaptığı çalışmada, porselen karolarda müllit miktarının ve proses parametrelerinin talk ilavesinin etkisini incelemiştir. Çalışma sonucunda; müllit oluşumunda ana etmenin kaolinit miktarı olduğu talk ilavesinin sinterleme sıcaklığını düşürdüğü bu yüzden müllit oluşumunun azaldığı belirlenmiştir [12].

V. Biasini ve ark.(2003) Porselen stoneware bünyeye talk ve klorit ilave etmişlerdir. İlave sonucunda reaktivitenin arttığı pişme sıcaklığının aynı su emme değerinde $20^{\circ}C$ kadar düştüğü, çoğu kapalı por olmakla birlikte kalıntı porların daha fazla olduğu, yığın yoğunluğun az miktar düştüğü ve pişme küçülmesinin bir miktar arttığını belirlemiştir [13].

M.F. Serra ve ark.(2012) Yaptığı çalışmada, talk, spodümen ve kalsiyum karbonatın seramik bünye üzerine olan etkisini incelemiştir. Çalışma sonucunda düşük sıcaklıklarda ($1100^{\circ}C$ den düşük) talk'ın bir etkisi olmadığı, 1200 derecelerde ise sinterlemenin hızlandığı ve yoğun stoneware bünyeler elde edildiğini bildirmiştir [14].

Z. Bayer Öztürk ve N.Ay'ın(2021) yaptığı çalışmada MgO içeriği yüksek dolomitik kil ve talkın porselen bünyede feldispat yerine kullanımı incelenmiştir.% 4'e kadar kullanımının su emme değerlerini düşürdüğü, pişme yoğunluğu ve mukavemet değerlerini arttırdığı tespit edilmiştir[15].

Bu çalışmada çeşitli toprak alkali içeren hammaddelerden magnezyum oksit kaynağı olarak da talk ve manyezit seçilmiştir. Porselen izolatör bünyesinde % 0.5-1 ve 3 oranında feldispat ile ikame ettirilerek porselen izolatör teknik özellikleri üzerine etkileri araştırılmıştır.

Materyal ve Yöntem

Kullanılan hammaddeler

Elektroporselen reçetesinde kullanılan kil, kaolen, kuvars ve feldispat yurtiçinden ve yurtdışından olmak üzere farklı tedarikçilerden alınmıştır. Potasyum feldispat yerine kullanılan talk ve manyezit hammaddeleri Tecnodieci firmasından 63μ altı tane boyutunda temin edilmiştir. Kullanılan hammaddelerin ait kimyasal analiz sonuçları Tablo 1'de verilmiştir. Oluşturulan reçetelerde farklı özelliklere sahip 2 çeşit kil, 4 çeşit kaolen, kuvars ve feldispat kullanılmıştır.

Tablo 1. Hazırlanan kompozisyonlarda kullanılan hammaddelerin kimyasal analizleri (% ağırlıkça).

Hammaddeler	$SiO_2 + Al_2O_3$	$Fe_2O_3 + TiO_2$	$CaO + MgO$	$Na_2O + K_2O$	Ateş Zayıflığı
Feldispat	86.12	0.18	0.45	12.88	0.37
Kuvars	99.53	0.02	0.06	0.23	0.16

Kil A	83.92	3.66	0.72	2.69	8.90
Kil B	84.43	2.98	1.30	1.78	10.20
Kaolen A	84.88	1.37	0.10	0.30	13.35
Kaolen B	82.33	3.66	0.69	2.76	10.56
Kaolen C	84.05	2.73	0.34	3.60	9.28
Kaolen D	83.46	1.84	0.24	0.37	14.09

Tablo 2’de kullanılan kil ve kaolenlerin fiziksel özellikleri verilmiştir. Yapılan analizlerde kuru mukavemet değerleri killer için 40-70 kg/cm², kaolenler için 15-38 kg/cm² aralığında değişmektedir. Pişme küçülme değerlerinin hepsi %10’dan küçüktür. Yapılan analizlere göre en yüksek kuru mukavemete ve en düşük su emme değerine sahip hammadde Kil A olarak belirlenmiştir. Kaolen D hammaddesi su emme analizine uygun numune elde edilemediği için su emme değerine bakılamamıştır.

Tablo 2. Kil ve kaolenlerin fiziksel özellikleri (% ağırlıkça).

Hammaddeler	Kuru Mukavemet (kg/cm ²)	Pişme Küçülmesi (%)	Su Emme (%)
Kil A	75	9.84	0.35
Kil B	40	8.72	15.00
Kaolen A	23	8.39	14.48
Kaolen B	30	6.56	5.00
Kaolen C	15	7.60	18.00
Kaolen D	38	9.60	-

Manyezit ve talk hammaddelerinin kimyasal bileşimleri Tablo 3’de verilmiştir. Manyezit içinde yaklaşık ağırlıkça % 45 MgO, talk içinde Ağırlıkça % 31.5 MgO bulunmaktadır.

Tablo 3. Manyezit ve talk hammaddelerinin kimyasal analizleri (% ağırlıkça).

	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	CaO	MgO	Ateş Zayıtı
Manyezit	3.00	0.00	0.28	2.50	45.00	49.22
Talk	59.00	1.49	0.29	0.82	31.50	7.00

Bünye Geliştirme Çalışmaları

Bünye geliştirme ve deneysel çalışmalar Ankara Seramik Porselen A.Ş. Ar-Ge Merkezi laboratuvarında ve pilot üretim alanında yapılmıştır. Hammaddeler belirlenen kompozisyon değerlerine göre terazide tartılmış, öğütme işlemlerinde 150 kg kuru madde kapasiteli alümina bilyalı değirmen kullanılmıştır. Değirmenden alınan çamur numunesi Mastersizer 2000 cihazından tane boyutu ve dağılımı ölçümü gerçekleştirilmiştir. Çamur numunelerinin ortalama tane boyutu 8-9 µm aralığına gelene kadar öğütme işlemine devam edilmiştir. Değirmende hazırlanan çamurlar 63 µm elekten elenerek sürekli karıştırılmalı karıştırıcıda 3 saat karıştırılarak homojenleştirilmesi sağlanmıştır. Çamurlar sürekli karıştırıcı tanktan pnömatik pompa ile filter prese aktarılmıştır. Suyu uzaklaştırmış çamur kekleri yaklaşık %19-21 nem değerine gelene kadar 13 bar basınçta filter preste bekletilmiştir. Hazırlanan kekler 9 devir/dak. hızla dönen vakum prestren geçirilerek homojenleştirilmiştir. Vakum prestren çıkan vakumlanmış ve preslenmiş ara ürünün yaklaşık 30 mm çapındaki çubukların rutubeti % 20 ve sıcaklığı 35 °C’ dir. Çubukların kurutma işlemi 110 °C

sıcaklıktaki Nükleon marka etüvde, nem içeriği %1’in altına inene kadar gerçekleştirilmiştir. Çubuklar, 0.3 m³ hacimli doğalgazlı pilot üretim fırında işletme pişirim çevrimi programında maksimum sıcaklığı 1205°C olacak şekilde pişirilmiştir. Çamurların viskozitesi ve yoğunluk değerleri sırasıyla UVE marka fordcup viskozimetre ve TQC VF 2099 marka piknometre ile ölçülmüştür. Çamurların tane boyutu ve dağılımı Mastersizer 2000 cihazı ile 5 ölçümün ortalaması alınarak tayin edilmiştir. Elek analizleri Retsch marka elekler kullanılarak yaş elek analizi metodu ile yapılmıştır. Kuru miktar tayini AND MX-50 marka nem tayin cihazı kullanılarak yapılmıştır. Ekstrüzyon sonrası ürünlerin kuru ve pişme küçülmeleri Mitutoyo marka dijital kumpas kullanılarak ölçülmüştür. Hazırlanan numunelerin fiziksel özellikleri (% pişme küçülmesi, % görünür (açık) gözeneklilik, % su emme, % pişme mukavemeti,) TS11237 EN 60672-2 standardı temel alınarak testler gerçekleştirilmiştir. Kuru ve pişme mukavemet testleri için ekstrüzyon kullanılarak hazırlanmış olan silindir şeklindeki örnekler Zwick/Roell marka 3 noktalı eğme cihazı ile mukavemetleri hesaplanmıştır. Boya nüfus(fuksin) deneyi 1 litre % 50 lik alkol ile 1 gram bazik Fuchsine ilave edilerek hazırlanan çözeltiye pişmiş numuneler koyularak Chemisches Laboratorium Tonindustrie marka test cihazıyla 90 MPa’lık basınçla 3 saat süreyle test gerçekleştirilmiştir. % su emme ve Görünür(açık) gözeneklilik testleri Arşimet prensibi baz alınarak test edilmiş ve hesaplanmıştır. Standartta göre % su emme hesaplamaları pişme sonrası elektroporselen bünyesinden alınan parçalar 3 saat kaynatıldıktan sonra, parçalar su içinde kalacak biçimde oda sıcaklığına kadar soğuduktan sonra ölçülmüştür. Oluşturulan reçetelerin deformasyon ölçümleri için vakum prestren ekstrüde edilen bünye çubukları aynı boyutlarda hazırlanmış ve iki sabit destek arasında işletme pişirim çevrimine göre sinterlenmiştir. Pişme sonrası deformasyon değerleri milimetrik kâğıt ile ölçülerek hesaplanmıştır. XRD-X-ışını kırınımı (Rigaku MiniFlex, Japonya) ile analiz edildi ve fazları belirlemek için monokromatik Cu-Kα radyasyonu (λ = 1,5406 Å) kullanıldı. Numuneler 2°/dak. tarama hızında 10°–70° (2θ) arasında analiz edilmiştir. Mikro yapısal değişimini gözlemek için enerji dağılımlı X-ışını spektrometrisi (Phenom -ProX) ile Elektron mikroskobu (SEM) kullanıldı. Standart izolatör bünyesindeki feldispat miktarı kütlece yüzdesi; sırasıyla % 0.5 -1 ve 3 oranlarında azaltılarak yerine aynı oranlarda magnezyum oksit kaynağı talk ve manyezit ilave edilmiştir. Standart bünyeye ve deneme reçetelerine ait kimyasal analizi sonuçları Tablo 4 ve 5’ de verilmiştir listelenmiştir.

Tablo 4. Standart bünye ve manyezit içerikli deneme reçetelerine ait kimyasal analizi sonuçları.


	SiO ₂ +Al ₂ O ₃	Fe ₂ O ₃ +TiO ₂	CaO+MgO	Na ₂ O+K ₂ O	Ateş Zayıtı
Standart	88.75	1.25	0.42	5.28	4.29
% 0.5 Manyezit	88.33	1.25	0.66	5.22	4.54
% 1 Manyezit	87.92	1.25	0.89	5.15	4.78
% 3 Manyezit	86.25	1.26	1.83	4.89	5.76

Manyezit ilavesiyle (Tablo 4) MgO oranında belirgin bir artış olmuştur. Manyezit ilavesi feldispat yerine yapıldığı için toplam alkali miktarında azalma olmuştur. Manyezit in ateş zayıatının yüksek olmasından dolayı toplam ateş zayıatı da manyezit ilavesi ile yükselmiştir. Toplam $\text{SiO}_2+\text{Al}_2\text{O}_3$ miktarında da bir miktar azalma belirlenmiştir.


Tablo 5. Standart bünye ve talk içerikli deneme reçetelerine ait kimyasal analizi sonuçları.

	$\text{SiO}_2+\text{Al}_2\text{O}_3$	$\text{Fe}_2\text{O}_3+\text{TiO}_2$	$\text{CaO}+\text{MgO}$	$\text{Na}_2\text{O}+\text{K}_2\text{O}$	Ateş Zayıatı
Standart	88.75	1.25	0.42	5.28	4.29
% 0.5 Talk	88.62	1.25	0.58	5.22	4.33
% 1 Talk	88.49	1.26	0.74	5.15	4.36
% 3 Talk	87.98	1.26	1.38	4.89	4.5

Talk ilavesi (Tablo 5) manyezitte olduğu gibi toplam alkali oranı düşmüş toprak alkali miktarı yükselmiştir. Ateş zayıatı manyezite göre daha az yükselmiştir.



Şekil 1. Standart ve manyezitli deneme reçetelerine ait bünyelerinin tane boyutu ve dağılımı.



Şekil 2. Standart ve talklı deneme reçetelerine ait bünyelerinin tane boyutu ve dağılımı.

Tane boyut grafikleri Şekil 1'de verilmiştir. Talk ve manyezit ilave edilmiş porselen izolatör bünyesi için tane boyut dağılımları geniş bir aralıkta homojen bir dağılımı göstermiştir. Geliştirilen reçeteler ve standart reçete arasında bir fark belirlenmemiştir. Tablo 6'da çamurların D_{10} - D_{50} ve D_{90} değerleri verilmiştir. Buna göre bütün çamurlar için ortalama tane boyutu (D_{50}) 7.781-8.518 mikron aralığındadır.

Tablo 6. Standart bünye, manyezit ve talk içerikli deneme reçetelerinin tane boyutu analizi sonuçları (mikron).

Mikron(µm)	D_{10}	D_{50}	D_{90}
Standart	1.334	8.138	33.644
% 0.5 Manyezit	1.517	8.360	33.282

% 1 Manyezit	1.308	7.781	33.383
% 3 Manyezit	1.337	7.849	33.696
% 0.5 Talk	1.399	8.518	35.000
% 1 Talk	1.350	8.204	33.336
% 3 Talk	1.395	8.451	33.197

Bulgular ve Tartışma

Teknolojik Özellikler

Manyezit ve talk hammaddelerinin standart reçetedeki feldispat ile yer değişim oranı arttırıldıkça % pişme küçülme değerinin arttığı belirlenmiştir. Manyezitli numunelerde pişme küçülme değeri standart bünyeye yakın olmakla beraber bir miktar artmıştır. En yüksek küçülme değeri % 3 manyezitli numunedir. Talk ilavesi küçülme üzerinde daha etkili olmuştur. % 3 Talk ilavesi ile küçülme değeri % 10.15'e yükselmiştir. Görünür katı yoğunluğu, görünür gözeneklilik, su emme değerleri değerlendirildiğinde standart ile benzer değerler olduğu belirlenmiştir. % 3 manyezit ilaveli bünyede bu değerler yükselmiş ve standart değerlerin üzerine çıkmıştır.

Deformasyon porselen izolatör üretiminde önemli bir parametredir. Bünye bileşimine oldukça bağlı olan belirli bir sıcaklıkta, seramik malzeme artık sert katı gibi davranmaz ve mekanik bir gerilim uygulandığında piroplastik deformasyon adı verilen kalıcı bir deformasyon meydana gelir. Deformasyonun derecesi, sıvı fazın miktarı ve viskozitesinin yanı sıra uygulanan mekanik stresle de ilgili olan sistemin görünür viskozitesine bağlıdır [16, 17].

Özellikle yüksek gerilim izolatörleri gibi büyük kütle ve hacimlere sahip ürünlerde sinterlenme esnasında kendi ağırlıklarına dayanamayarak şekil bozuklukları ve sünme davranışları oluşabilmektedir. Teknik özellikler incelendiğinde en önemli farklılardan biri deformasyon değerleridir. Toprak alkali ilavesi ile birlikte deformasyon değerlerinde büyük farklar oluşmuştur. Toprak alkaliler, amorf fazın viskozitesi ve yeni oluşan fazların gelişmesi üzerinde yüksek etkiye sahiptir [18-20]. Bu farkın oluşan camsı faz miktarı ve oluşan amorf fazın viskozitesinden kaynaklandığı düşünülmektedir. Bünyede bulunan MgO'nun viskozitesi daha düşük, daha fazla miktarda camsı faz oluşumunu sağlamaktadır. Buda yüksek sıcaklık viskozitesini arttırmaktadır. Sırlı ve sırsız pişme mukavemet değerleri manyezit ve talk ilave miktarının artmasıyla düşmektedir. Bu sonuç kırılğan camsı faz miktarının artmasıyla açıklanabilir. Camsı fazın miktarındaki artış ve viskozitesinin düşmesi ile birlikte porselen bünyelerin deformasyon davranışı kötüleşmektedir [21-23]. XRD sonuçları karşılaştırıldığında oluşan fazlar ve miktarları arasında bir fark gözlemlenmediği için oluşan kristal fazların aynı miktarda olduğu öngörülmüştür (pik yükseklikleri karşılaştırıldığında). TS 11237 EN 60672-3 standardına göre C110 izolatör massesi sırlı olarak en az 60 MPa (611.8 kg/cm²) ve C120 izolatör massesi sırlı olarak en az 110 MPa (1121.6 kg/cm²) eğilme mukavemeti değerine sahip olmalıdır. C110 masse gerekliliklerine % 3 manyezitli ilave standart dışı olarak değerlendirilmiştir. Mukavemetteki bu düşüşün bir sebebi de yoğunluktaki düşüş sebebiyle su emme ve görünür gözeneklilikte artış ile de açıklanabilir. Gözenek miktarının artmasıyla mukavemette düşüş belirlenmiştir.

Manyezit ve talk ilaveli bünyelerin pişirim sıcaklık ve sürelerinin yüksek olduğu değerlendirilmiştir. Bu ilavelerin ilave edilmesiyle daha düşük sıcaklık ve sürelerde denemeler yapılarak camı faz miktarı ve viskozitesi kontrol edilebilir. Bu sayede düşük sıcaklıklarda elektroporselen üretilmesi mümkün olabileceği değerlendirilmiştir.

salınımından kaynaklanan gazları içeren kapalı gözeneklere dönüşür [34]. Artan sıcaklık nedeniyle, kapalı gözeneklerin içinde sıkışan gazın basıncı artar, bu da boyutlarının büyümesine neden olur ve dolayısıyla parçanın genişlemesini yardım eder [34, 35].

Tablo 7. Standart ve Deneme Reçetelerine Ait Bünyelerinin Fiziksel Özellikleri.

	Pişme Küçülmesi (%)	Deformasyon (mm)	Görünür Katı Yoğunluğu (gr/cm ³)	Görünür Gözeneklilik (%)	Su Emme (%)	Sırsız Pişme Mukavemeti (kg/cm ²)	Sırlı Pişme Mukavemeti (kg/cm ²)
Standart Bünye	9.07	14	2.43	0.25	0.10	1041.3	1162.2
% 0.5 Manyezit	9.08	15	2.41	0.13	0.05	1093.0	1102.5
% 1 Manyezit	9.15	23	2.41	0.23	0.09	853.1	965.5
% 3 Manyezit	9.27	65	2.38	1.77	0.77	572.5	580.5
% 0.5 Talk	9.56	23	2.41	0.09	0.03	893.4	1008.7
% 1 Talk	9.85	25	2.40	0.11	0.04	862.7	1008.3
% 3 Talk	10.15	67	2.38	0.24	0.10	665.7	752.3

Yapılan fuksin testinde % 3 manyezitli numune dışındaki bütün numuneler standardı karşılamaktadır (Şekil 3). % 3 manyezitli numunenin görünür gözeneklilik miktarı % 1.77 su emme değeri ise % 0.77 olarak analiz edilmiştir. Her iki değerinde yüksek olmasının sebebi aynı zamanda yoğunluğun düşük olmasından dolayı bu numunenin aşırı pişmiş olabileceği değerlendirilmiştir (over-firing).




Şekil 3. a) % 3 Manyezitli kompozisyon, b) Standart kompozisyon.

Seramik ürünlerin, özellikle yüksek derecede camlaşmaya sahip olanların, pişirmenin son aşamasında genişlemesi veya "şişmesi" yeni veya alışılmadık bir olgu değildir [24]. Daha şiddetli vakalarında, ürünler yüzeyde kabarcık görünümü gösterdiğinden kolayca algılanırlar [25]. Bu olguya aşırı pişirme denir [26] ve birçok durumda pişirme sıcaklığının artması [27], akışkanlaştırıcı maddelerin kullanımı [28, 29] gibi durumlarda gözlenirken, aksine, refrakter hammaddelerin artması görünümünü yavaşlatır [30]. Boyutsal ve estetik yüzey değişikliklerinin ötesinde, aşırı pişirme, mekanik mukavemet [31], sırlı teknik porselen karolar durumunda leke direnci [32] ve elastik modül [27] gibi porselen karoların önemli özelliklerini ve karakteristiklerini olumsuz etkiler. Bunun nedeni, aşırı pişirmenin gözenekliliğin evrimiyle yakından ilişkili olmasıdır, aşırı pişirmenin en yaygın nedeni gözeneklerde gazların tutulması veya şişmeye veya kabarcıklanmaya neden olan gazların evrimidir [26]. Fırına giren üründeki tüm gözenekler açılır. Pişirme sırasında açık gözeneklerin hacmi azalır ve bu da karoların büzülmesine yol açar. Pişirmenin son aşamasında kalan açık gözeneklerin bir kısmı, ürün reaksiyonlarının [33] veya hatta fırının atmosferinin

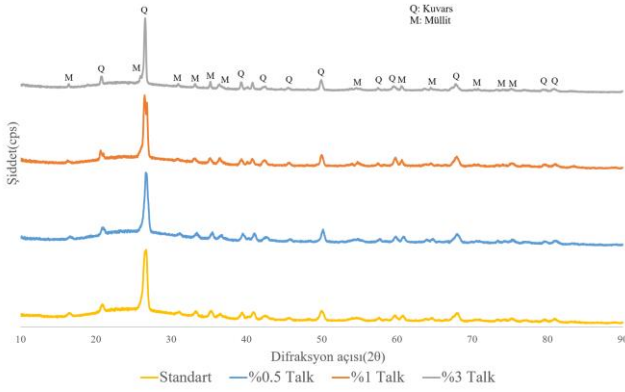
Faz (XRD) Analizi

Şekil 4'de standart ve manyezit numunelerine ait normalize edilmiş X-ışınları difraktometresi sonuçları vardır. Yapılan analizde ana faz olarak kuvars ve müllit belirlenmiştir. Bünyeye ilave edilen manyezit ayrı bir faz oluşturmadığı belirlenmiştir. Kompozisyona ilave edilen farklı oranlardaki manyezitin camı/amorf faz içinde olduğu değerlendirilmiştir [37]. Müllit faz miktarı pik yüksekliklerine göre kıyaslandığında bütün kompozisyonlarda benzer olarak değerlendirilmiştir. Müllit porselen bünyenin mukavemeti üzerinde olumlu etkisi olduğu bilinmektedir. Zoelner, porselen bünyede birbiri içine geçmiş (kenetlenmiş) iğnemsiz müllit tanelerinin mukavemeti artırdığını belirlemiştir [38]. Bunun yanı sıra birçok çalışmada da müllit miktarının artmasıyla doğru orantılı olarak mukavemetin de arttığı belirtilmiştir [39, 40]. İğnemsiz müllitler, yüksek sıcaklıklarda, daha az sayıda büyük iğneler şeklinde büyüyebilirler. Büyük iğnemsiz tanelerin küçük taneler gibi etkili bağlanamaması mukavemetin azalmasına neden olur. Bu yüzden uygun boyutlu ve doğru miktardaki iğnemsiz müllit tanelerinin oluşumu önemlidir. İğnemsiz müllitlerin oluşumunda ve morfolojisinde pişirme sıcaklığı önemlidir [41]. Artan manyezit miktarı ile sırlı ve sırsız mukavemetin (Tablo 7) düşüşü kırılған camı/amorf miktarın fazla olması ve porozite miktarındaki artış ile açıklanabilir.



Şekil 4. Standart ve manyezit kompozisyonlarına ait XRD analizi grafiği.

Şekil 5’de standart ve talk numunelerine ait normalize edilmiş XRD sonuçları vardır. Geliştirilen bünyelerde ana faz olarak kuvars ve müllit belirlenmiştir. Reçetelere ilave edilen farklı oranlardaki talkın camsı/amorf faz içinde dağıldığı ikincil bir faz oluşturmadığı değerlendirilmiştir. Manyezit ilavesinin etkisi ile benzer özellikler gösterdiği belirlenmiştir.



Şekil 5. Standart ve talk kompozisyonlarına ait XRD analizi grafiği.

Mikroyapı Analizi

Şekil 5’de Elektron mikroskobu görüntüleri vardır. 500X büyütmedeki ikincil elektron görüntüleri incelendiğinde mikroyapıların teknik özellikler (Tablo 7) ile uyumlu olduğu belirlenmiştir. Faz dağılımları homojen bir şekildedir. Poroziteler bütün numunelerde dairesel şekillidir. En düşük porozite miktarına % 0.5 manyezitli ve % 0.5 Talk içeren numuneler olduğu belirlenmiştir. En yüksek gözenek miktarı % 3 manyezitli numunedir. Bu numunenin görünür porozite ve su emme değerleri de diğer numuneler ile karşılaştırıldığında daha yüksektir. Kuvars taneleri bütün bünyelerde homojen dağılmıştır. Kalıntı kuvarsların çevresinde mikroskobik çatlaklar vardır. 25-50 mikron arasındaki kuvars çevresindeki çatlaklar mikro çatlak toklaştırma mekanizması olarak hareket ederek mukavemetleri olumlu etkilemektedir [30,42]. Tüm kompozisyonlar için kalıntı kuvars tanelerinin boyutu 40 µm altındadır. % 3 manyezitli numunede görülen gözeneklilik miktarının fazla olması, göreceli olarak kalıntı kuvars miktarının az olması, yüksek piroplastik deformasyon bu bünyenin aşırı pişerek por kabalaşmasına sebep olduğu düşünülmektedir.

Genel Sonuçlar


MgO içeren toprak alkali hammaddelerden talk ve manyezit seçilerek elektro porselen bünyenin teknik özelliklerine olan etkisi incelenmiştir. Porselen izolatör bünyesinde sistematik olarak feldispat yerine % 0.5-1 ve 3 ikame ettirilerek teknik, özellikleri üzerine olan etkisi incelenmiştir.

Manyezit ve talkın kompozisyonlara ilave edilmesi ile mukavemet, yoğunluk azalmış, gözeneklilik, su emme, pişme

küçülmesi ve deformasyon artmıştır. En önemli değişiklik deformasyonda belirlenmiştir. Deformasyon artışı oluşan camsı/amorf faz miktarı artışı ve yüksek sıcaklık viskozitesinin düşmesi ile açıklanmıştır. Mukavemetteki belirgin düşüş ise kırılğan camsı faz miktarındaki artış kaynaklı olduğu değerlendirilmiştir. Yine manyezit ve talk ile sisteme ilave edilen MgO’nun ayrı faz oluşturmadığı ve camsı faz içinde yer aldığı belirlenmiştir.

Mikroyapıda belirgin bir fark gözlemlenmemekle birlikte %3 manyezit ilavesinin bünyenin fazla pişmesine sebep olarak gözeneklerin büyümesine, böylelikle standart fuksin testinden geçemediği belirlenmiştir.

MgO içeren toprak alkali kaynaklarının kullanılarak daha düşük sıcaklıklarda ve sürelerde pişirim gerçekleştirilerek camsı/amorf faz miktarı ve viskozitesinin kontrol edilerek standartlara uygun elektro porselen üretilebileceği öngörülmektedir.



Şekil 6. Geri yansıyan elektron -Elektron mikroskobu görüntüleri-500 X-A: Standart, B: %0.5 Manyezit, C: %0.5 Talk, D:%3 Manyezit, E: %3 Talk.

Teşekkür

Bu çalışmanın gerçekleştirilmesinde büyük katkı sağlayan Ankara Seramik Porselen A.Ş. Ar-Ge Merkezi'ne teşekkür ederiz. Merkez, sunduğu değerli kaynaklar ve teknik destek ile araştırmamızın kalitesini artırmış, ilerlemesine önemli ölçüde katkıda bulunmuştur.

Kaynaklar

- [1] Andrew Ruys, "Alumina Ceramics Biomedical And Clinical Applications", 1st Edition,- October 20, 2018
- [2] Gorur R S, Cherney E A And Burnham J T 1999 Outdoor Insulators (Phoenix, Arizona, USA: Ravi S. Gorur, Inc.) P. 256
- [3] Indigenous manufacture and characterization of electrical porcelain insulator, nigerian journal of technology, vol. 24, no. 1, march 2005, I. U. ANIH, MNSE, MIEEE department of electrical engineering university of Nigeria, Nsukka
- [4] Ceramic Raw Material for Porcelain Insulator (CRMPI) (2006), [online], Accessed 10th June 2006, Available from World Wide Web: <http://www.dart-europe.en/full-php>
- [5] Buchanan R.C. (1991), Ceramic Material for Electronics, Dekker, New York
- [6] B. Tarhan ve M. Tarhan, "Çanakkale bölgesi alkali kaynağının seramik sağlık gereçleri bünyesi ısıl ve mikroyapı özellikleri üzerine etkisi", DÜMF MD, c. 10, sy. 2, ss. 675-687, 2019, doi: 10.24012/dumf.504331
- [7] Tiryaki, A., Avcı, C. A., Karakaya, C., Yıldız, A., vd. (2023). "Eşme/Uşak Alkali Kaynağının Elektroporselen Bünyesinde Kullanılmasının Araştırılması" International Journal of Engineering Research and Development, 15(2), 722-730
- [8] Tarhan, M., ve Tarhan, Ş. B. (2019). "Sırlı Porselen Karo Üretimi için Alternatif Hammadde Olarak Eşme/Uşak Feldspati" Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 19(2), 429-438
- [9] Tarhan, B., Tarhan, M. "Utilization of perlite as an alternative raw material in the production of ceramic sanitaryware" J Therm Anal Calorim 147, 3509-3518 (2022)
- [10] Tarhan, B., & Tarhan, M. (2022). "Alümina Porselen Bünyelerde Spodumen İlavesinin Teknik Özelliklere Etkisinin Araştırılması" International Journal of Engineering Research and Development, 14(1), 262-270

- [11] Mukhopadhyay, T.K., Das, M., Ghosh, S., Chakrabarti, S., Ghatak, S. (2003), "Microstructure and thermo mechanical properties of a talc doped stoneware composition containing illitic clay", *Ceramics International*, 29, 587-597
- [12] Daniel Magagnin, Carla Margarete Ferreira dos Santos, Augusto Wanderlind, Jeanini Justi, Agenor De Noni, "Effect of kaolinite, illite and talc on the processing properties and mullite content of porcelain stoneware tiles", *Materials Science and Engineering: A*, Volume 618, 2014, Pages 533-539
- [13] V. Biasini, M. Dondi, G. Guarini, M. Raimondo, A. Argnani, S. di Primio, "Effect of talc and chlorite on sintering and technological behaviour of porcelain stoneware tiles", *Sil. Ind.* 68 (2003) 67-73
- [14] M.F. Serra, M. Picicco, E. Moyas, G. Suárez, E.F. Aglietti, N.M. Rendtorff, "Talc, Spodumene and Calcium Carbonate Effect as Secondary Fluxes in Triaxial Ceramic Properties", *Procedia Materials Science*, Volume 1, 2012, Pages 397-402
- [15] Z.Bayer Ozturk, N.Ay, An investigation of the effect of alkaline oxides on porcelain tiles using factorial design, *J.Ceram. Processing Res.* Vol. 13, No. 5, pp. 635~640 (2012).
- [16] C. Zanelli, M. Raimondo, G. Guarini, M. Dondi, "The vitreous face of porcelain stoneware: Composition, evolution during sintering and physical properties", *J. Non Cryst. Solids* 357 (2011) 3251-3260
- [17] E. Sánchez, M.J. Orts, J. García-Ten, V. Cantavella, Porcelain tile composition effect on phase formation and end products, *Am. Ceram. Soc. Bull.* 80 (2001) 43-49.
- [18] B.Tarhan ve M.Tarhan, "Development Of Waterproof Engobe Layer For Ceramic Wall Tiles", *Journal Of Thermal Analysis And Calorimetry*, Cilt.140, Sa.2, Ss.555-565, 2020
- [19] M.Tarhan, Porselen Karo Bünyelerinde Sinterleme Hızı - Kompozisyon İlişkiler, *Anadolu Üniversitesi Fen Bilimleri Enstitüsü Seramik Mühendisliği Anabilim Dalı*, 2010
- [20] T.Aydın , M.Tarhan, B.Tarhan, "Addition of cement kiln dust in ceramic wall tile bodies", *Journal Of Thermal Analysis And Calorimetry* cilt.136,sa.2,2018
- [21] Tunçel, D.Y., Özel, E. "Evaluation of pyroplastic deformation in sanitaryware porcelain bodies". *Ceram Int.* 38, (2012).
- [22] Güngör, F., & Ay, N. (2018) "The effect of particle size of body components on the processing parameters of semi-transparent porcelain". *Ceramics International*, 44(9), 10611-10620
- [23] N.Kunduracı , Ş.B.Tarhan, C.Sarısakal, "Seramik Sağlık Gereçleri Ürünlerinde Piroplastik Deformasyonun Azaltılmasına Bağlı Olarak Geliştirilen Kompozisyonların Üretim Maliyeti Açısından Değerlendirilmesi", *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi* cilt 11 sayı 2 sayfa: 474 - 480 2019
- [24] C. Zanelli, M. Raimondo, M. Dondi, G. Guarini, P.M.T. Cavalcante, "Sintering mechanisms of porcelain stoneware tiles", in: *Qualicer 2004 – Congr. Mund. La Calid. Del Azulejo Y Del Paviment, Cerámico, Castellón*, 2004, pp. 247-259
- [25] M.W. Vance, "Relationship of feldspar properties to surface and volume defects in porcelains", Masters thesis, Missouri University of Science and Technology, 1967.
- [26] W.D. Kingery, H.K. Bowen, D.R. Uhlmann, *Introduction to Ceramics*, 2nd ed., John Wiley & Sons, New York, 1976
- [27] E.E. Gültekin, Effect of heating rate and sintering temperature on the elastic modulus of porcelain tiles", 83 (2018) 120-125
- [28] M. Oberzan, J. Holc, M. Buh, D. Kusćer, I. Lavrac, M. Kosec, "High-alumina porcelain with the addition of a Li₂O-bearing fluxing agent", *J. Eur. Ceram. Soc.* 29 (2009) 2143-2152
- [29] T. Tarvornpanich, G.P. Souza, W.E. Lee, "Microstructural evolution on firing soda-lime-silica glass fluxed whitewares", *J. Am. Ceram. Soc.* 88 (2005) 1302-1308
- [30] C. Leonelli, F. Bondioli, P. Veronesi, M. Romagnoli, T. Manfredini, G.C. Pellacani, V. Cannillo, "Enhancing the mechanical properties of porcelain stoneware tiles: a microstructural approach", *J. Eur. Ceram. Soc.* 21 (2001) 785-793
- [31] E. Sánchez, M.J. Ibáñez, ~ J. García-Ten, M.F. Quereda, I.M. Hutchings, Y.M. Xu, "Porcelain tile microstructure: implications for polished tile properties", *J. Eur. Ceram. Soc.* 26 (2006) 2533-2540
- [32] H.J. Alves, F.B. Minussi, F.G. Melchiades, A.O. "Boschi, Porosidade susceptível ao manchamento em porcelanato polido", *Cerâm. Ind.* 14 (2009) 21-26
- [33] F.H. Norton, *Cerámica Fina Tecnología y Aplicaciones*, Ediciones Omega, S.A., Barcelona, 1975
- [34] E.E. Gültekin, G. Topates, S. Kurama, "The effects of sintering temperature on phase and pore evolution in porcelain tiles", *Ceram. Int.* 43 (2017) 11511-11515
- [35] E. Sánchez, J. García-Ten, V. Sanz, A. Moreno, "Porcelain tile: almost 30 years of steady scientific-technological evolution", *Ceram. Int.* 36 (2010) 831-845
- [36] M. Romero, A. Andrés, R. Alonso, J. Viguri, J.M. Rincón, "Sintering behaviour of ceramic bodies from contaminated marine sediments", *Ceram. Int.* 34 (2008) 1917-1924
- [37] Tarhan M. "Whiteness improvement of porcelain tiles incorporated with anorthite and diopside phases". *J Therm. Anal. Calorim.* 2019.
- [38] Zoellner, A., "Same chemical and physical properties of porcelains", *Sprechsaal*, 41,471-73 (1908)
- [39] Sane, S.C ve Cook, R.L., "Effect of grinding and firing treatment on the crystalline and glass content and the physical properties of whiteware bodies", *J. Am. Ceram. Soc.*, 34, 145 (1951)
- [40] Mattyasovszky, L. ve Solnay, Z., "Mechanical strength of porcelain", *J. Am. Ceram. Soc.*, 40, 299-306 (1957).
- [41] Carty, W.M. V. Senapati, U., "Porcelain-raw materials, processing, phase evaluation and mechanical behavior", *J. Anl. Ceram. Soc.*, 81, 3-20 (1998)
- [42] Tarhan, B., Tarhan, M., Aydın, T., "Reusing sanitaryware waste products in glazed porcelain tile production". *Ceram Int.* 43, (2017).



Standart Kuraklık İndeksleri İle Kuraklık Analizi: Konya Kapalı Havzası Örneği

*Drought Analysis with Standard Drought Indices: The Case of Konya Closed Basin*Arman UÇAR^{1*}, Ebru ERİŞ², Fevzi ÖNEN³¹ Dicle Üniversitesi, İnşaat Mühendisliği Bölümü, armucr@gmail.com ORCID: <https://orcid.org/0009-0004-6419-9490>² Ege Üniversitesi, İnşaat Mühendisliği Bölümü, ebru.eris@ege.edu.tr ORCID: <https://orcid.org/0000-0003-0601-7666>³ Dicle Üniversitesi, İnşaat Mühendisliği Bölümü, fonen@dicle.edu.tr ORCID: <https://orcid.org/0000-0002-2368-1035>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 5 Ağustos 2024
Revizyon 8 Eylül 2024
Kabul 11 Eylül 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

Standartlaştırılmış Yağış İndeksi,
Akım Kuraklık İndeksi, Konya
Kapalı Havzası.

ÖZ

Dünya nüfusundaki hızlanan artış ve buna paralel olarak doğal kaynaklarda meydana gelen azalma mevcut kaynakların maksimum verim ile kullanılmasını zorunlu hale getirmektedir. Yetersiz yağış, buharlaşma, jeolojik yapının değişmesi, insan faktörü gibi çeşitli meteorolojik, hidrolojik, jeolojik, sosyolojik olaylar sonrasında bir bölgedeki suyun miktarının azalması ile kuraklık meydana gelir. Kuraklık ile ilgili olarak literatürde temeli matematiksel denklemlere dayanan ve yağış, sıcaklık, evapotranspirasyon vb. verileri kullanan çeşitli kuraklık indeksleri bulunmaktadır. Ülkemizde kuraklık indeksleri ile gerçekleştirilmiş olan kuraklık analizlerinde genel olarak uzun dönemli verilere sahip olunması ve çoğu bölgede gözlem istasyonu bulunması sebebiyle yağış ve akım verileri kullanılmaktadır. Bu çalışmada da yağış ve akım gözlem istasyonlarına ait veriler kullanılarak iki farklı kuraklık indeksi (Standartlaştırılmış Yağış İndeksi, Akım Kuraklık İndeksi) ile kuraklığın yoğun bir şekilde gözlemlendiği Konya Kapalı Havzasında kuraklık analizi yapılmıştır. Çalışmanın amacı özellikle Konya Kapalı Havzası için güncel verilerle ve mümkün olduğu kadar çok sayıda gözlem istasyonu verisi ile yapılmış toplu bir kuraklık analizinin sunulmasıdır. Çalışma sonucunda yağışa bağlı kuraklıkta bariz bir eğilime rastlanmazken akıma bağlı kuraklıkta artma olduğu; akım kuraklığının yağışa göre daha uzun sürdüğü gibi sonuçlara varılmıştır. Ayrıca akımdaki çok şiddetli kuraklık sınıfı oranının yağıştakine göre bariz bir şekilde daha fazla olduğu, orta ve şiddetli kuraklık sınıflarının yağış ile karşılaştırıldığında akım için istasyon bazında daha çok değiştiği görülmektedir. Bu çıkarım akımda görülen kuraklığın yağışa göre daha değişken ve etki bakımından ayrı bir önemle değerlendirilmesi gerektiğini ortaya koymuştur.

ARTICLE INFO

Article history:

Received 5 August 2024
Received in revised form 8 September 2024
Accepted 11 September 2024
Available online 23 December 2024

Keywords:

Standardized Precipitation Index,
Streamflow Drought Index, Konya
Closed Basin

Doi: 10.24012/dumf.1528706

* Sorumlu Yazar

ABSTRACT

The accelerating increase in the world population and the consequent parallel decrease in natural resources make it necessary to use the existing resources with maximum efficiency. Drought may occur because of the decrease in water amount in a region; as a result of various meteorological, hydrological, geological and sociological events such as insufficient precipitation, evaporation, change in geological structure, human factor. There are various drought indices developed by researchers in the literature based on mathematical equations and using data such as precipitation, temperature, evapotranspiration, etc. In drought analyses carried out with drought indices in our country, precipitation and flow data are generally used because they have long-term data and there are observation stations in most regions. In this study, drought analysis was carried out with two different drought indices (Standardized Precipitation Index, Streamflow Drought Index) using the data of precipitation and flow observation stations in Konya Closed Basin where drought is intensively observed. The aim of the study is to present a collective and summarized drought analysis with more station data for adequate interpretation, particularly in comparison with the most recent data for the Konya Closed Basin. As a result of the study, it was concluded that although there is no obvious trend in precipitation-related drought, there is an increase in flow-related, drought in flow lasts longer than precipitation. In addition, the proportion of extreme drought classes is significantly higher for flow than for precipitation, and moderate and severe drought classes show more variability on a station basis for flow compared to precipitation. This conclusion revealed that drought in flow is more variable than in precipitation and should be considered separately in terms of its impact.

Giriş

Dünya nüfusunda gözlenen artış ivmesi ve bunun sonucunda doğal kaynaklarda ortaya çıkan hızlı tükenme eğilimi mevcut kaynakların maksimum verim ile kullanılmasını zorunlu hale getirmektedir. Canlı yaşamının temel gereksinimlerinden olan suyun korunması yaşanabilir bir gelecek için büyük bir öneme sahiptir. Yetersiz yağış, buharlaşma, jeolojik yapının değişmesi, insan faktörü gibi çeşitli meteorolojik, hidrolojik, jeolojik, sosyolojik olay bir bölgede suyun miktarının azalmasına neden olmakta, bunun sonucunda kuraklık meydana gelebilmektedir. Kuraklık takibinin yapılabilmesi için, doğa ve doğanın bir parçası canlıların elzem ihtiyacı olan suyun atmosferden yeraltına kadar olan hidrolojik sürecinin gözlenmesi gerekir. Kuraklık hakkında değerlendirme yapılabilmesi için temeli kütle ve enerji korunum esaslı matematiksel denklemlere dayanan, söz konusu denklemlerde girdi verisi olarak yağış, sıcaklık, nem, evapotranspirasyon verisini kullanan farklı kuraklık indeksleri mevcuttur. Matematiksel hesaplamalarda tekil veri kullanımı girdi olarak kullanıldığı gibi kombine edilmiş farklı verilerin birlikte kullanılması da mümkündür. Kuraklık indeksi ile ilgili yapılan çalışmalarda, kolaylıkla temin edilebilmesi nedeniyle daha çok yağış ve akım verileri tercih edilmektedir.

Bu arada, ülkemiz toplam alanının yaklaşık %7'sini kaplayan Konya Kapalı Havzası tarımsal üretim bakımından önemli bir bölgedir. Havza Türkiye'nin tarım yapılabilir arazi varlığının %14'ünü oluştururken, kullanılabilir su kaynakları potansiyelinin sadece %3'üne sahiptir [1]. Havzanın ortalama yağışı Türkiye ortalamasının oldukça altında olup yaklaşık 380 mm civarındadır [2]. Konya Havzası'nın kuraklığa karşı hassasiyeti ile ilgili gerek kamu kurumları tarafından gerekse akademisyenler tarafından yapılmış çalışmalar mevcuttur. SYGM (2015) tarafından sunulan Konya Havzası Kuraklık Yönetim Planında Standartlaştırılmış Yağış İndeksi (SYİ), Palmer Kuraklık Şiddet İndeksi, Erinç Kuraklık İndeksi vb. başta yağış ve sıcaklık olmak üzere meteorolojik değişkenlere dayalı kuraklık analizi yapılmıştır [3]. Atmaca (2011) yalnızca Konya ili için aylık toplam yağış miktarlarını kullanarak L-moment algoritması ile çalışma alanı homojen bölgelere ayırılmış ve SYİ ile kuraklık analizi gerçekleştirmiştir [4]. Doğan (2013) Konya Kapalı Havzası içerisinde yer alan 12 yağış istasyonuna ait 1972-2009 yılları arası yağış verisi ile Normal Yağış Yüzdesi, Yağış Kuyrukları, Z-Skoru, Çin Z İndeksi, SYİ ve Efektif Kuraklık İndeksi yöntemleri ile karşılaştırmalı kuraklık analizi gerçekleştirmiştir [5]. Gürler (2017) yalnızca Beyşehir ve Konya Çumra-Karapınar alt havzalarında SYİ, Standartlaştırılmış Akım İndeksi, Standartlaştırılmış Yeraltısuyu İndeksi, Standartlaştırılmış Depolama Hacmi İndeksi kullanarak karşılaştırmalı kuraklık analizi yapmıştır [6]. Ersoy (2019) Konya bölgesi için Yapay Sinir Ağları (YSA) yöntemini kullanarak 1971-2014 yılları arası aylık toplam yağış verilerinden hesaplanan SYİ değerlerini tahmin etmeye çalışmıştır [7]. Bayer Altın (2019) yine havza içerisinde yer alan 4 akım gözlem istasyonuna ait akım verilerini kullanarak, Akım Kuraklık İndeksi (AKİ) değerlerini bulmuş ve Mann-Kendall yöntemine göre indekslerinin eğimlerini belirlemiştir [8]. Bayçınar (2020) Konya Havzasındaki bazı istasyonların 1981-2010 yılları arasında elde edilen sıcaklık ve yağış verilerinden hareketle

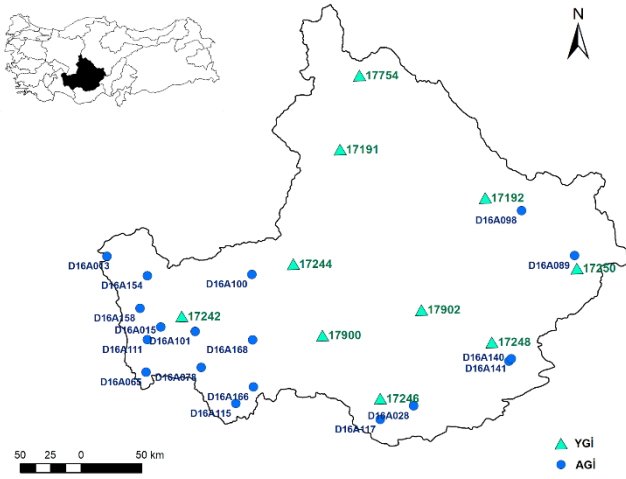
SYİ, Normalin Yüzdesi İndeksi, Aridite İndeksi ve Standartlaştırılmış Yağış Evapotranspirasyon İndeksi ile faktör analizini birleştirerek kuraklık indekslerinin ortak kullanımını değerlendirmiştir [9]. Sarış ve Gedik (2021), Konya Havzası için 11 meteoroloji istasyonunun değişik uzunluklarda kaydedilmiş aylık toplam yağış verilerinden SYİ değerlerini hesaplamış ve gidişler sınaması ile kuraklık indeksi değerlerindeki ısrar bileşenini belirlemiş ve farklı kuraklık sınıflarına göre kuraklığın şiddetini değerlendirmiştir [10]. Tuğrul ve Hınıs (2023) Konya Kapalı Havzası içerisinde yer alan Apa Barajı Havzasına ait yağış ve akım verilerini kullanarak Normalleştirilmiş Yağış İndeksi ve AKİ değerlerinin trend analizini gerçekleştirmişlerdir [11]. Geyikli (2023), Konya Havzası ile birlikte Yeşilirmak ve Kızılırmak Havzaları için SYİ, Standartlaştırılmış Yağış Evapotranspirasyon İndeksi, Standartlaştırılmış Akım İndeksi ve Keşif Kuraklık İndeksi kullanarak kuraklık analizi gerçekleştirmiş, ancak Konya Havzası için herhangi bir akım gözlem istasyonu verisi kullanmamıştır [12].

Bu çalışmada, öneminden dolayı Konya Kapalı Havzası çalışma bölgesi olarak seçilmiştir. Havzanın bütünü temsil edecek şekilde 10 yağış ve 18 akım gözlem istasyonuna ait 1935-2022 yılları arasındaki yağış ve akım verilerinden hesaplanan SYİ ve AKİ karşılaştırmalı olarak kuraklık analizi için sunulmuştur. Çalışmada amaç Konya Kapalı Havzası için güncel verilerle karşılaştırmalı olarak yeterli yorumlanmaya yönelik mümkün olduğu kadar çok sayıda istasyon verisi ile toplu bir kuraklık analizinin sunulmasıdır.

Çalışma Bölgesi ve Veri

İç Anadolu bölgesinde bulunan Konya Kapalı Havzasının kuzeyinde Sakarya ve Kızılırmak, doğusunda Kızılırmak ve Seyhan, güneyinde Doğu Akdeniz ve batısında Antalya ve Akarçay havzaları yer almaktadır. Havza yüzölçümü 49.805,34 km² olup Türkiye'nin yaklaşık %7'sini teşkil etmektedir. Havza arazisinin %56'lık kısmını meralar da dâhil olmak üzere tarım alanları, %37'sini ise orman ve yarı doğal alanlar oluşturur. Havza'daki tarım alanlarının büyük bir kısmı Konya ilinde yer almaktadır. SYGM (2024)'ye göre havzanın en önemli sorunlarını aşırı yeraltı suyu kullanımı, yerüstü sularına endüstriyel ve arıtılmamış kentsel deşarjlar, hidromorfolojik değişiklikler ve kuraklık riski oluşturmaktadır [13].

Havza kuraklık analizi için havza genelinde 10 adet yağış gözlem istasyon (YĞİ) ve 18 adet akım gözlem istasyonu (AGİ) kullanılmıştır. Özellikle AGİ'lerin mümkün olduğunca doğal akım olmasına dikkat edilmiş, bu konuda DSİ ile çeşitli görüşmeler yapılarak kullanılacak AGİ'lere karar verilmiştir. Bu istasyonlara ait genel bilgiler Tablo 1'de, havza konumları ise Şekil 1'de verilmiştir.



Şekil 1. Konya Kapalı Havzasının genel görünümü ve kullanılan yağış ve akım gözlem istasyonlarının konumu

Tablo 1. Çalışmada kullanılan yağış ve akım gözlem istasyonlarının karakteristikleri

	No	Adı	Koordinat		Yük. (m)	Gözlem Periyodu	Ort. Yağış (mm)
			Enlem	Boylam			
Yağış Gözlem İst. (YGI)	17191	Cihanbeyli	38°39'K	32°55'D	968	1958-2021	26.74
	17192	Aksaray	38°22'K	33°59'D	963	1964-2021	28.81
	17242	Beyşehir	37°40'K	31°44'D	1144	1960-2022	41.29
	17244	Konya Hav.	37°59'K	32°34'D	1020	1929-2022	27.47
	17246	Karaman	37°11'K	33°13'D	1026	1959-2022	27.75
	17248	Ereğli	37°31'K	34° 2'D	1047	1964-2020	25.58
	17250	Niğde	37°57'K	34°40'D	1212	1935-2022	28.37
	17754	Kulu	39° 4'K	33° 3'D	1012	1969-2011	32.41
	17900	Çumra	37°33'K	32°47'D	1015	1971-2011	26.99
	17902	Karapınar	37°42'K	33°31'D	998	1967-2011	24.00
Akım Gözlem İst. (AGI)	D16A013	Çelték K.	38°1'K	31°11'D	1145	1960-2020	0.93
	D16A015	Üstünler	37°36'K	31°35'D	1126	1992-2020	1.41
	D16A028	Nalama Ç.	37°9'K	33°28'D	1125	1957-2020	1.68
	D16A065	Derebucak	37°2'K	31°28'D	1212	1976-1998	4.06
	D16A078	Taşagül	37°22'K	31°53'D	1095	1972-2020	3.07
	D16A089	Kırkpınar K.	38° 2'K	34°39'D	1474	1995-2019	0.10
	D16A098	Selime	38°17'K	34°16'D	1129	1999-2020	1.78
	D16A100	K.muhsine	37°55'K	32°16'D	1261	1984-2020	0.97
	D16A101	Aşağıesence	37°35'K	31°50'D	1111	1973-2020	0.95
	D16A111	Yeşildağ K.	37°32'K	31°29'D	1124	1992-2020	3.85
	D16A115	Sorkun	37° 9'K	32° 8'D	1150	1976-2020	2.19
	D16A117	Seyithasan	37° 4'K	33°13'D	1140	1978-2020	0.43
	D16A140	Aydınkent	37°24'K	34°10'D	1161	1984-2020	3.63
	D16A141	Halkapınar	37°25'K	34°11'D	1160	1990-2020	0.86
	D16A154	Tolca	37°55'K	31°29'D	1199	1991-2020	0.12
	D16A158	Gölyaka	37°43'K	31°26'D	1125	1992-2020	0.42
	D16A166	Pınarcık	37°15'K	32°16'D	1125	1999-2020	3.09
	D16A168	Sadıklar	37°32'K	32°16'D	1167	1999-2020	0.23

Yöntem

Standartlaştırılmış Yağış İndeksi (SYİ)

McKee ve diğ. (1993) tarafından geliştirilmiş olan bu indeks olasılıklı bir dönüştürmeye dayanmaktadır [14]. Yağışın gamma dağılımına uyduğu kabul edilmekte, bu dağılım normal dağılıma dönüştürülmekte ve ortalama yağış değeri çıkarılmış yağış standart sapmaya bölünmektedir. Bu şekilde elde edilen standart normal dağılım, kuraklık değerlendirme amacıyla kullanılan bir indekse dönüşmektedir. Standart Yağış İndeksi (SYİ) olarak bilinen bu indeks

$$SPI = \frac{X_{ij} - X_{im}}{\sigma} \quad (1)$$

ile hesaplanmaktadır. Burada, x_{ij} : i yağış istasyonunun j gözlemindeki aylık yağışı, x_{im} : uzun dönemli yağış ortalamasını, σ : standart sapmayı ifade etmektedir. SYİ değerleri 1, 3, 6, 9, 12, 24 ve 48 aylık (SYİ1, SYİ3, ..., SYİ48) indeksler şeklinde farklı zaman ölçekleri için hesaplanabilir.

Akım Kuraklık İndeksi (AKİ)

Nalbantis ve Tsakiris (2009) tarafından geliştirilen bu indekste aylık akım verileri ($Q_{i,j}$) kullanılarak hidrolojik kuraklık değerlendirme yapılabilmektedir [15]. Aylık akım verisi hacimlerine ait zaman serisinin $Q_{i,j}$ ile gösterilmesi halinde i , hidrolojik yılı ve j , su yılı içerisindeki ayı ($j=1$ için Ekim, $j=12$ için Eylül) ifade etmektedir. Buna göre,

$$V_{i,k} = \sum_{j=1}^{3k} Q_{i,j}, \quad i = 1, 2, \dots, j = 1, 2, \dots, 12 \quad k = 1, 2, 3, 4 \quad (2)$$

Burada; i hidrolojik yıl ve k referans periyodu olmak üzere $V_{i,k}$ kümülatif akım hacmini ifade eder. Örneğin; Ekim-Aralık için $k = 1$, Ekim-Mart için $k = 2$, Ekim-Haziran için $k = 3$ ve Ekim-Eylül için $k = 4$.

$V_{i,k}$ kümülatif akım hacmine dayanarak, i hidrolojik yılına ait her bir k referans periyodu için Akım Kuraklık İndeksi (AKİ) aşağıdaki şekilde ifade edilmiştir;

$$SDI_{i,k} = \frac{V_{i,k} - \bar{V}_k}{S_k} \quad i = 1, 2, \dots, \quad k = 1, 2, 3, 4 \quad (3)$$

V_k ve S_k , sırasıyla, uzun bir zaman süresince tahmin edilen k referans periyoduna ait kümülatif akım hacminin ortalama ve standart sapmasını ifade etmektedir. Bu indeksin hesabında, normalizasyon için iki parametrelili log-normal dağılımı kullanılır. Akımın doğal logaritmasının alınması ile AKİ aşağıdaki şekilde ifade edilir:

$$SDI_{i,k} = \frac{y_{i,k} - \bar{y}_k}{S_{y,k}} \quad i = 1, 2, \dots, \quad k = 1, 2, 3, 4 \quad (4)$$

$$y_{i,k} = \ln(V_{i,k}), \quad i = 1, 2, \dots, \quad k = 1, 2, 3, 4 \quad (5)$$

Denklem (4)'te kullanılan $y_{i,k}$; ortalaması \bar{y}_k ve standart sapması $S_{y,k}$ olan kümülatif akımın doğal logaritmasıdır,

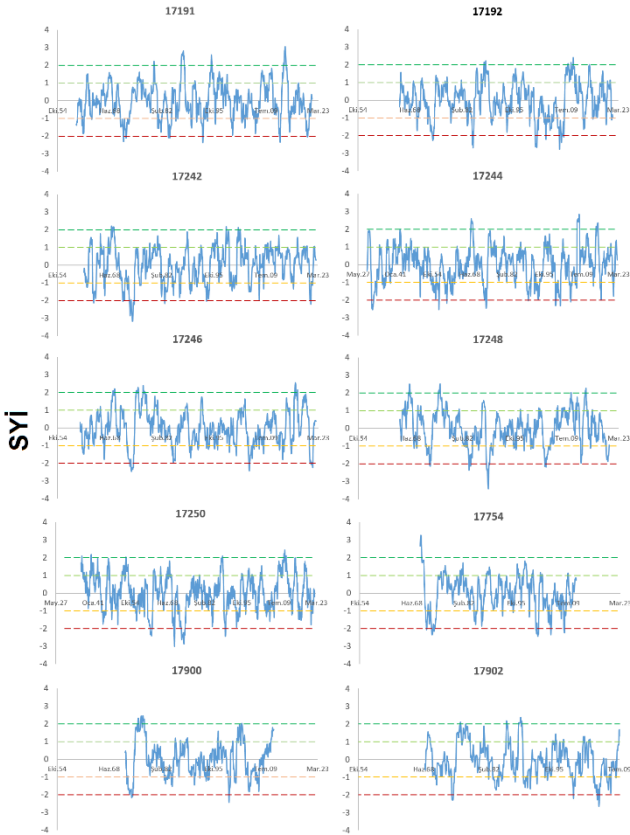
SYİ veya AKİ boyutsuz sayılar olup $-\infty$ ile $+\infty$ arasında değerler almaktadır. Bu indekslerin aldığı değerler kuraklığın şiddetini ifade etmektedir. Bu değerlere bağlı olarak literatürde kuraklık şiddet sınıflandırması Tablo 2'deki gibi yapılmıştır.

Tablo 2. SYİ/AKİ Değerlerine göre kuraklık sınıfı [14, 15]

SYİ/AKİ	Kuraklık Sınıfı
$0 \leq \text{SYİ/AKİ}$	Nemli
$-1.0 < \text{SYİ/AKİ} < 0$	Hafif Kurak
$-1.50 < \text{SYİ/AKİ} \leq -1.0$	Orta Kurak
$-2.0 < \text{SYİ/AKİ} \leq -1.5$	Şiddetli Kurak
$\text{SYİ/AKİ} \leq -2.0$	Çok Şiddetli Kurak

Analiz ve Değerlendirme

Konya Kapalı Havzasında bulunan 10 yağış gözlem istasyonu için hesaplanan SYİ12 değerleri Şekil 2'de toplu olarak sunulmuştur. SYİ hesaplanırken 12 aylık ölçeğin seçilmesinin nedeni önceki çalışmalara da dayanarak SYİ12 yardımıyla akarsu akımı, yeraltı suyu gibi hidrolojik süreçler için kuraklığın uzun dönemdeki etkilerini görebilmektir. Yağış istasyonlarındaki gözlem periyodu içerisinde SYİ değerleri genel olarak -2 ve +2 değerleri arasında değişmekte ve özellikle -1 ile +1 aralığında yoğunlaşmaktadır. Bir başka deyişle hafif ve orta kurak sınıftan şiddetli kurak sınıfa doğru görülme olasılığı azalmaktadır.



Şekil 2. YGI'lere ait SYİ12 değerleri

Şekil 2'de görüleceği üzere kuraklık indeks değerleri için gözlem süresi boyunca kayda değer bir artma ya da azalma

görülmemektedir. Nitekim [12] ve [16] çalışmalarında da havzadaki YGI'lere ait yağış verilerinde belirgin bir artma veya azalma bulunmamıştır.

SYİ12'ye göre en kurak uzun dönemler (Tablo 3) YGI'ler için 30-59 ay arasında değişmekte yani 2 yıldan fazla sürmektedir. İstasyonlarda en uzun kurak dönem boyunca görülen en büyük kuraklık şiddetleri ise -1.71 ile -3.16 arasında değişmektedir. Tüm gözlem periyodu içerisinde en büyük kuraklık şiddeti değerleri en uzun kurak dönemlerde değil (1 YGI hariç) daha kısa kurak dönemlerde yer almaktadır. Tüm gözlem süresince elde edilen en büyük kuraklık şiddetleri -2.35 ile -3.39 arasında değişmektedir ve en uzun kurak dönemde görülen kuraklık şiddetinden daha büyüktür. Bu durum daha kısa ancak daha şiddetli dönem içi kuraklıkların daha etkin olabileceğine işaret etmektedir. Cavus ve Aksoy (2020) ve Aksoy ve diğ. (2021) tarafından kuraklık ve kurak dönem arasında bu nedenle yapılan ayırımı dikkat çekmek gerekir [17, 18]. Öte yandan en uzun kurak dönemler ise tüm YGI'lere bakıldığında bir istasyonda 1958-1963 arası, 4 istasyonda 1970'lerden sonra ilk 5 yıl, 2 istasyonda 1980 yıllarının başı ve son olarak 3 istasyonda ise 2003 ile 2008 yılları arasında gözlenmiş olup tüm havzayı etkisi altına alan tek bir en uzun kurak dönemden bahsedilmektedir (Tablo 3).

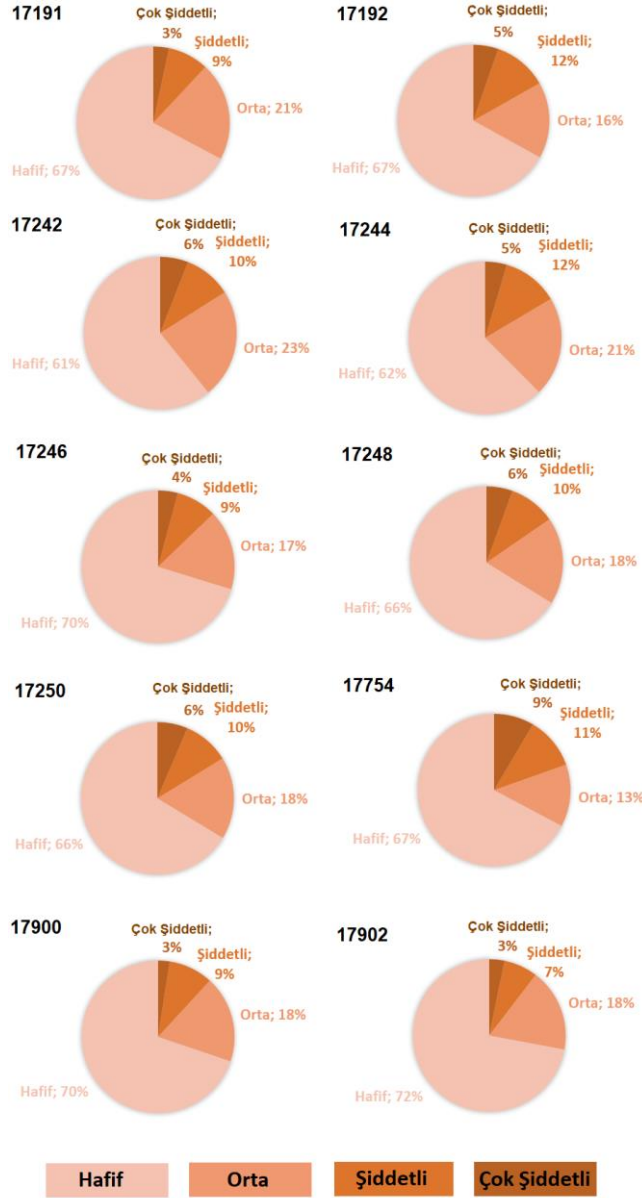
Kuraklık sınıfı görülme olasılıkları da Şekil 3'te her bir YGI için ayrı ayrı verilmiştir. Havzada yalnızca kuraklık açısından bakıldığında hafif kuraklık sınıfının görülme olasılığı %61-%72 arasındadır. Geri kalan kuraklık sınıflarının görülme olasılığı değişiklik göstermekte, genel olarak çok şiddetli kurak sınıfının görülme olasılığının en az olduğu anlaşılmaktadır. SYİ normal dağılıma uyduğundan uç değerlerin görülme olasılığı düşüktür, çok şiddetli kuraklığın görülme olasılığının az olması da bu nedenle beklenen bir durumdur.

Tablo 3. YGI'ler için SYİ12 kurak dönem değerlendirmesi

YGI	En Uzun Kurak Dönem				Gözlem Süresince	
	Periyodu	Uzunluğu (ay)	En Şiddetli Kuraklık	Kuraklık Şiddeti	En Şiddetli Kuraklık	Kuraklık Şiddeti
17191	12/1970-03/1974	40	Şub.72	-2.30	Ara.92	-2.35
17192	04/2003-09/2006	42	Mar.04	-2.20	Eki.07	-2.76
17242	01/1971 -01/1975	49	Haz.74	-3.16	Haz.74	-3.16
17244	06/1958-04/1963	59	Oca.60	-2.17	Eki.32	-2.53
17246	05/2004-05/2007	37	Mar.05	-2.41	Mar.74	-2.46
17248	12/1981-04/1985	41	Kas.83	-2.36	Ara.88	-3.39
17250	03/1972-09/1976	55	Ağu.74	-2.88	Şub.71	-3.02
17754	12/1971 - 05/1975	40	Kas.73	-2.35	Ağu.01	-2.44
17900	04/2004- 04/2008	49	Nis.05	-1.84	Ara.99	-2.43
17902	11/1982-04/1985	30	Eyl.83	-1.71	Nis.05	-2.63

Yine havzada bulunan 18 AGİ'ye ait AKİ4 değerleri Şekil 4'te toplu olarak sunulmuştur. AKİ değerleri ancak $k = 4$ ölçeğinde hesaplandığında SYİ12 ile karşılaştırılabilir. Şekil 4 incelendiğinde 18 AGİ'de AKİ değerlerinin genel olarak

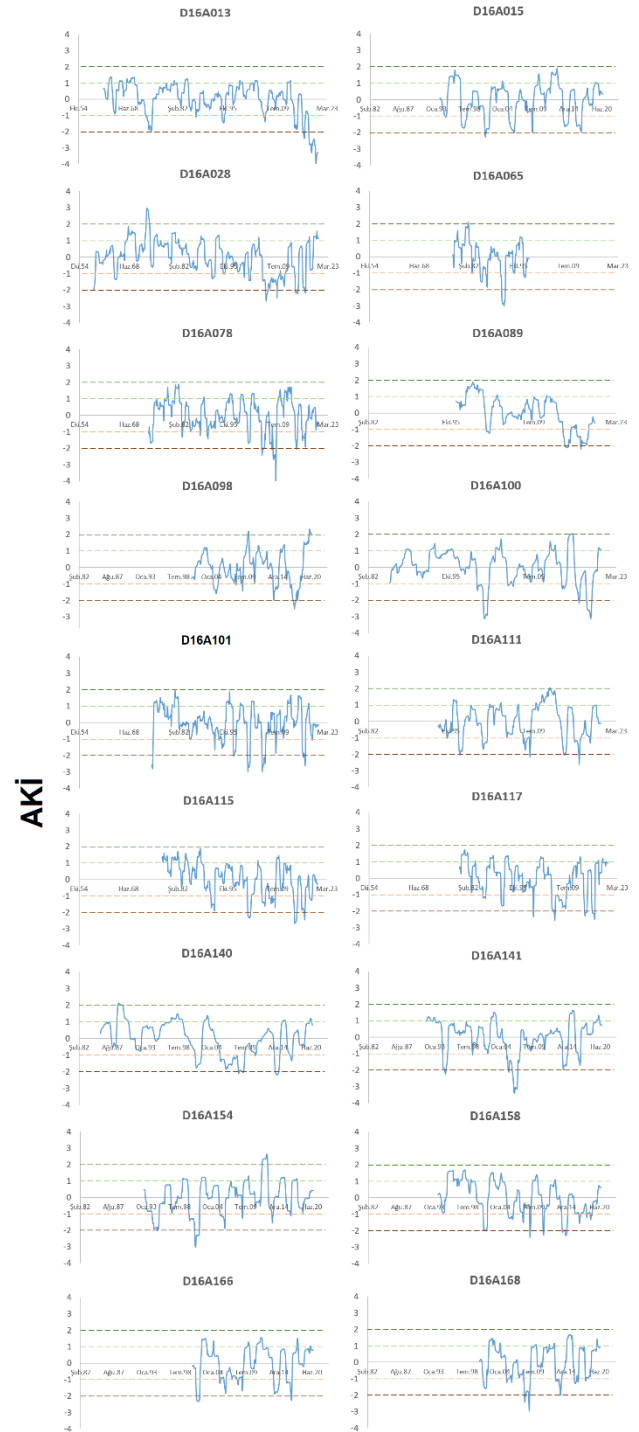
+2'ye ulaşmadığı, özellikle 0 ile -1 ve -1 ile -2 arasında yani hafif kuraklık ile şiddetli kuraklık arasında değiştiği görülmektedir. Şekil 4'ten özellikle D16A013, D16A028, D16A089, D16A115, D16A158 gibi istasyonların AKİ değerlerinde azalma eğilimi görülmektedir. Yine [16] çalışmasında havzadaki AGİ'lerin yaklaşık %80'inde azalma eğilimi tespit edilmiş, bu eğilimlerin ancak bazılarının belirgin olduğu görülmüştür. Yağışa bağlı kuraklıkta herhangi bir eğilime rastlanmazken akıma bağlı kuraklıkta artma net bir şekilde göze çarpmaktadır.



Şekil 3. YGİ'lere ait SY12 kuraklık sınıfı olasılıkları

AKİ12'e göre en kurak uzun dönemler (Tablo 4) AGİ'ler için 23-94 ay arasında değişmekte, bir başka deyişle yağış kuraklığına göre akım kuraklığı daha uzun sürmektedir. En uzun kurak dönemde kuraklık şiddetleri -1.22 ile -4.09 arasında değişmekte, gözlem süresince en büyük kuraklık şiddetine sahip aylar genelde (AGİ toplam sayısının yaklaşık yarısında) en uzun kurak dönem içerisinde görülmektedir. Bir başka deyişle tüm gözlem periyodu içerisinde en büyük

kuraklık şiddet değerleri AGİ'lerin yarısı için en uzun kurak dönemler dışında kalmakta ve -2.17 ile -5.13 arasında değerlerini almaktadır. Bu sonuçtan; akımlarda görülecek uzun kuraklık dönemleri içerisinde pik şiddetlerin görülmesinin olası olduğu anlaşılmaktadır.



Şekil 4. AGİ'lere ait AKİ12 değerleri

Tüm AGİ'lere bakıldığında en uzun kurak dönemlerin genel olarak 2000'li yılların sonrasında görüldüğü anlaşılmaktadır (Tablo 4). Oysa YGİ'lere bakıldığında uzun dönem kuraklıkların 2000 yılından önce görüldüğü, AGİ'lerde ise uzun dönem kuraklıkların günümüze daha yakın tarihlerde

gerçekleştiği anlaşılmaktadır. Yakın tarihte YGİ'ler ciddi bir kuraklık gelişmemesine rağmen AGİ'lerde kuraklık görülmesi son yıllarda kuraklık üzerinde iklim değişikliğinden ziyade insan etkisinin olduğunu düşündürmektedir.

Kuraklık sınıfı görülme olasılıkları AGİ'ler için Şekil 5'te verilmiştir. AGİ'ler için YGİ'lerde olduğu gibi hafif kuraklık sınıfında görülme olasılığı daha fazladır ancak YGİ'lerden farklı olmak üzere AGİ'lerde orta, şiddetli ve çok şiddetli kuraklık sınıfları AGİ'den AGİ'ye daha çok değişmektedir. YGİ'lere topluca bakıldığında görülen homojen dağılım AGİ'lerde görülmemektedir. Bununla birlikte genel olarak AGİ'lerde YGİ'lere göre çok şiddetli kuraklık sınıfının oranı bariz bir şekilde daha fazladır. Bölgede akımda görülen kuraklığın yağışa göre daha değişken ve çok daha etkili olduğu düşünülmektedir.

Tablo 4. Akım Gözlem İstasyonları AKİ Değerlendirmesi


AGİ	En Uzun Kurak Dönem				Gözlem Süresince	
	Periyodu	Uzunluğu (av)	En Şiddetli Kuraklık	Kuraklık Şiddeti	En Şiddetli Kuraklık	Kuraklık Şiddeti
D16A013	03/2016-09/2020	55	Şub.20	-4.09	Şub.20	-4.09
D16A015	02/2000-01/2002	24	Nis.01	-2.28	Nis.01	-2.28
D16A028	01/2005-03/2012	87	Mar.06	-2.65	Mar.06	-2.65
D16A065	12/1984-11/1987	36	Mar.87	-1.84	Kas.91	-2.99
D16A078	12/1984-03/1988	40	Oca.88	-1.22	Ara.08	-5.13
D16A089	08/2013-09/2019	74	May.17	-2.17	May.17	-2.17
D16A098	06/2016-03/2019	34	Eki.17	-2.50	Eki.17	-2.50
D16A100	06/2016-02/2020	45	Oca.19	-3.12	Haz.01	-3.13
D16A101	03/1991-01/1995	47	Şub.92	-1.67	Nis.01	-3.01
D16A111	04/2007-02/2009	23	Ara.08	-2.15	Şub.17	-2.62
D16A115	03/2005-03/2009	49	Ara.08	-1.70	May.14	-2.66
D16A117	02/2005-01/2010	60	Oca.06	-2.57	Oca.06	-2.57
D16A140	08/2004-05/2012	94	Tem.08	-2.11	Kas.14	-2.21
D16A141	05/2004-04/2007	36	Nis.06	-3.40	Nis.06	-3.40
D16A154	01/1993-02/1996	38	Ara.94	-2.02	Nis.01	-3.03
D16A158	03/2016-02/2020	48	Şub.17	-1.54	Ara.08	-2.37
D16A166	02/2005-03/2009	50	Mar.06	-1.83	Eyl.01	-2.33
D16A168	01/2007-03/2009	27	Ara.08	-2.95	Ara.08	-2.95

Sonuçlar ve Öneriler

Bu çalışmada Konya Kapalı Havzasında bulunan 10 yağış ve 18 akım gözlem istasyonuna ait yağış ve akım verileri kullanılarak SYİ ve AKİ indeksleri hesaplanmıştır. Böylece bölge için en güncel verilerle karşılaştırmalı olarak yeterli yorumlamaya yönelik daha çok sayıda istasyon verisi ile toplu bir kuraklık analizi gerçekleştirilmiştir. Yapılan analizden çıkan sonuçlar özetlenirse;

- Yağışa bağlı kuraklıkta bariz bir eğilime rastlanmazken akıma bağlı kuraklıkta artma net bir şekilde göze çarpmaktadır.
- SYİ ve AKİ'lerden hesaplanan en uzun kurak dönemler incelendiğinde, yağış kuraklığına göre akım kuraklığının daha uzun sürdüğü görülmektedir.
- Hem yağış hem de akım için tüm gözlem periyodu içerisinde en büyük kuraklık şiddet değerlerinin en uzun kurak dönemler içerisinde görülmediği anlaşılmaktadır. Bu durum özellikle yağış için belirgindir. Bu da Konya Kapalı havzası için kurak dönem içinde kalan kısa süreli ancak şiddetli tekil kuraklıkların başta tarım olmak üzere su ile ilişkili sektörlerde daha etkin ve tehlikeli olabileceğine işaret etmektedir.
- Akımlarda görülecek uzun dönem kuraklıkların pik şiddetlere ulaşması mümkün görülmemekte, kuraklığın hem şiddetli hem de uzun olmasının ciddi olumsuz etkilere yol açacağı düşünülmektedir.
- Konya Kapalı Havzasında yağıştaki uzun dönem kuraklıkların 2000 yılından önceki dönemlerde gözlemlendiği, akımdaki uzun dönem kuraklıkların ise 2000'li yıllardan sonra gerçekleştiği anlaşılmaktadır. Yakın tarihte yağışta ciddi bir kuraklık gelişmemesine rağmen AGİ'lerde kuraklık görülmesi son yıllarda kuraklık üzerinde iklim değişikliğinden ziyade insan etkisinin olduğunu düşündürmektedir.
- Akımdaki çok şiddetli kuraklık sınıfı oranının yağıştakine göre bariz bir şekilde daha fazla olduğu, orta ve şiddetli kuraklık sınıflarının yağış ile karşılaştırıldığında akımda AGİ'den AGİ'ye daha çok değiştiği görülmektedir. Bu gözlem akımda görülen kuraklığın yağışa göre daha değişken ve etki bakımından ayrı bir önemle değerlendirilmesi gerektiğini ortaya koymuştur.

Önceki çalışmalarla birleştirildiğinde bu çalışma sonuçlarından anlaşılacağı üzere Konya Kapalı Havzasındaki kuraklığın özellikle insani etkiler nedeniyle arttığı anlaşılmaktadır. Bölgede açıldığı bilinen büyük orandaki kayıplar, bilinçsiz su tüketimi bu artışın nedenleri olarak gösterilebilir. Kuyuların kayıt altına alınması ve ücretlendirilmesi, ürün deseninde değişiklikler, sulama sistemlerinin modernleştirilmesi ve su tüketimi ile ilgili bilinçlendirmenin geliştirilmesi bölgedeki kuraklığın olumsuz etkilerini azaltacaktır. Bu çalışmada bölge için yapılan kuraklığın zamansal analizinin devamı niteliğinde olmak üzere sonraki bir çalışmada kuraklığın mekânsal analizinin yapılması uygun olacaktır.



Şekil 5. AGI'lere ait AKI12 kuraklık sınıfı olasılıkları

Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur. Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

Yazar Katkıları

Yazarlar makaleye eşit derecede katkıda bulunmuştur.

Kaynaklar

- [1] Tunçok, İ.K., Bozkurt, O.Ç. (2015) Bütüncül Havza Yönetimi: Konya Kapalı Havzası Uygulaması, 4. Su Yapıları Sempozyumu, Bildiriler Kitabı, 479-488.
- [2] SYGM (2022), Konya Havzası Kuraklık Yönetim Planının Güncellenmesi Projesi, Stratejik Çevresel Değerlendirme Taslak Kapsam Belirleme Raporu, <https://webdosya.csb.gov.tr/db/scd/icerikler/konya-havzasi-kuraklik-yonet-m-plani-20220719131037.pdf> (Erişim: 04.2024)
- [3] SYGM (2015). Konya Havzası Kuraklık Yönetim Planı. Ankara, 329s.
- [4] Atmaca, D. (2011) Standartlaştırılmış Yağış İndeksi (SYİ) Yöntemi İle Konya İli Bölgesel Kuraklık Analizi, Gaziosmanpaşa Üniversitesi, FBE, Yüksek Lisans Tezi.
- [5] Doğan, S. (2013) Konya Kapalı Havzası Kuraklık Karakterizasyonunun Zamansal- Konumsal Analizi, Selçuk Üniversitesi, FBE, Doktora Tezi.
- [6] Gürler, Ç. (2017) Beyşehir Ve Konya-Çumra-Karapınar Alt Havzalarında Standartlaştırılmış İndis Yaklaşımı İle Hidrolojik Kuraklık Değerlendirmesi, Orman ve Su İşleri Bakanlığı, Su Yönetimi Genel Müdürlüğü, Uzmanlık Tezi.
- [7] Ersoy, T. (2019) Konya İli Meteorolojik Kuraklık Analizi, Süleyman Demirel Üniversitesi, FBE, Yüksek Lisans Tezi.
- [8] Bayer Altın, T. (2019) Konya Kapalı Havzasında Akarsu Akımlarının Hidrolojik Kuraklık Analizi, Karaman Araştırmaları- 2, ss.13-24, Palet Yayınları.
- [9] Bayçımar, M. (2020) Konya Kapalı Havzası Örneğinde Faktör Analizi İle Kuraklık İndekslerinin Ortak Kullanımının Değerlendirilmesi, Erzincan Binali Yıldırım Üniversitesi, FBE, Yüksek Lisans Tezi.
- [10] Sarış, F., Gedik, F. (2021). Konya Kapalı Havzası'nda Meteorolojik Kuraklık Analizi, Coğrafya Dergisi, 42: 295-308, 10.26650/JGEOG2021-885519.
- [11] Tuğrul T., Hınıs M.A. (2023) Konya Apa Barajı Havzasında Meteorolojik ve Hidrolojik Kuraklık Trend Analizi, Karaelmas Fen ve Mühendislik Dergisi, 13(1): 151-163.
- [12] Geyikli, M.S. (2023) Investigation of Dry and Wet Periods Characteristics with Different Drought Indices in Yeşilirmak, Kızılırmak and Konya Closed Basins, Hasan Kalyoncu Üniversitesi, FBE, Doktora Tezi.
- [13] Url-1 (2024) <https://www.tarimorman.gov.tr/-SYGM/Sayfalar/Detay.aspx?SayfaId=135>, Erişim tarihi: 05.2024.
- [14] McKee, T.B., Doesken, N.J. and Kleist, J. (1993) The Relationship of Drought Frequency and Duration to Time Scales. 8th Conference on Applied Climatology, Anaheim, 17-22 January 1993, 179-184.
- [15] Nalbantis, I., Tsakiris, G. (2009) Assessment of Hydrological Drought Revisited. Water Resour Manage 23, 881-897, <https://doi.org/10.1007/s11269-008-9305-1>
- [16] SYGM (2023) Konya Havzası Kuraklık Yönetim Planı; Cilt 1: Havzanın Genel Tanıtımı ve Kuraklık Analizleri, Ankara, 281s.
- [17] Cavus, Y., Aksoy, H. (2020) Critical drought severity/intensity-duration-frequency curves based on precipitation deficit, Journal of Hydrology, 584, 124312.
- [18] Aksoy, H., Cetin, M., Eris, E., Burgan, H. I., Cavus, Y., Yıldırım, I., Sivapalan, M. (2021). Critical drought intensity-duration-frequency curves based on total probability theorem-coupled frequency analysis. Hydrological Sciences Journal, 66(8), 1337-1358.



The Impact of Isolation Parameters on Structural Responses due to Strong Earthquake Motion Processed by DWT

Elif Çağda KANDEMİR

İzmir Demokrasi University, Department of Civil Engineering, elifcagda.kandemir@idu.edu.tr Orcid No: 0000-0002-9190-7120

ARTICLE INFO

Article history:

Received 7 August 2024
Received in revised form 27 August 2024
Accepted 31 August 2024
Available online 23 December 2024

Keywords:

base isolation, discrete wavelet transform, earthquake, time response analysis

Doi: 10.24012/dumf.1529376

ABSTRACT

The parameters of the base isolation system play a significant role in structural responses as they directly affect the interaction between the structure and seismic excitation. This study focuses on investigating the impact of base isolation parameters on structural behavior under decomposed earthquake effects. The period and damping ratio of the isolator, which are inherently effective in determining characteristics such as stiffness and damping coefficients, were parametrically varied to discern their effects on the seismic behavior of the structure. Displacement of the base mat on the isolators and roof acceleration responses were obtained through time response analyses. To examine seismic input across different frequency ranges, discrete wavelet transformation was used to decompose the earthquake acceleration. A five-level decomposition was applied. Subsequently, time response analyses were conducted for the original earthquake acceleration scenario and the corresponding approximation coefficients. Decomposition levels yielding responses similar to those obtained under the original earthquake were identified. Additionally, the correlation between acceleration responses and the earthquake and approximation coefficients was calculated to figure out the effect of the frequency ranges of seismic excitation on the seismic behavior of the building. The adequate decomposition levels for the base-isolated structure have been presented. This analysis illustrates how various frequency ranges of seismic excitation impact the structural response by highlighting which decomposition levels are most representative of the original earthquake effects.

Introduction

The base isolation system parameters are of great importance since they directly affect how the structures respond to seismic forces. The stiffness and damping coefficient parameters directly influence a building's ability to withstand earthquakes by controlling flexibility and energy dissipation. The efficacy of base isolation has been extensively studied and validated through both theoretical and experimental works. Notable references in this field include works by Kelly [1] and by Soong and Constantinou [2], providing insights into the behavior of isolation systems under various seismic conditions. These studies enrich our understanding of base isolation as a robust seismic mitigation strategy in structural engineering.

Utilizing advanced mathematical tools are helpful to analyze the system behavior and apply the right choice from a vast of options in the designing process that understands the structural behavior and responding the necessities in terms of durable structure. Wavelet transform pioneered by Mallat [3], offers a powerful means of analyzing signals with versatility, scaling, and translating to different resolutions. They capture both high and low-frequency information by applying low-pass and high-pass filters respectively. Unlike Fourier analysis, which focuses solely

on frequency, Wavelet transform allows for adjusting window size to achieve both time and frequency details. This adaptability is facilitated by a range of wavelet functions such as Symlet, Coiflet, and Daubechies, which can expand or compress over time and amplitude. Consequently, wavelets have become effective tools in fields of engineering, economics, biomedical research etc. Discrete Wavelet Transform (DWT) has been firstly introduced by Mallat [4], demonstrating its efficacy in analyzing nonstationary signals like earthquake motions. Subsequent advancements, including Daubechies wavelets introduced by Ingrid Daubechies [5], have expanded the applicability of wavelet analysis by offering orthogonality and regularity. The evolution of the technique stills goes on to shape signal processing and analysis methodologies across diverse domains.

This study conducts a comprehensive examination of base isolation parameters, particularly focusing on stiffness and damping coefficient, and their influence on structural behavior, which is essential in determining the overall seismic performance of structures. To distinguish their impact, the isolator's period systematically varied from 2 sec to 3 sec while the damping ratio is changed from %30 to %40. Time response analyses yield structural responses focusing on displacement of base mat above isolators and

acceleration at the top of the building. Additionally, DWT, utilizing the Haar wavelet function, is employed to decompose earthquake accelerations into five levels. The low-frequency contents, i.e., approximation coefficients, are then applied to analyze the dynamic behavior of the structure. This decomposition strategy facilitates a thorough investigation of seismic inputs across different frequency bands, to clarify the interaction between structures and ground motion. Subsequently time response analyses are conducted for original earthquake acceleration and its corresponding approximation coefficients. Adequate levels of decomposition which address similar responses obtained by those under original earthquake have been achieved. Furthermore, the correlation between the acceleration responses and the earthquake acceleration as the original and its approximations has been computed to clarify the effectiveness of frequency ranges of the seismic excitation on the seismic behavior of the building.

This research aims to uncover the relationship between structural dynamics, isolation parameters and seismic excitation characteristics. Ultimately, it contributes to a deeper understanding of which level is adequate for decomposition of earthquake acceleration under varying base isolation parameters.

Literature

Wavelet analysis is utilized effectively in denoising earthquake acceleration signals. In the examination of earthquake data, various wavelet decomposition techniques have been employed by researchers. Kamgar et al. [6] conducted a comparative study of Meyer and Daubechies 4 wavelets to identify the most suitable transformation for ground motions. In this study, the findings revealed that Daubechies 4 (db4) is superior to the alternatives.

In another investigation, Kamgar et al. [7] utilized a three-level decomposition with db4 wavelet. Kaloop and Hu [8] chose a two-level decomposition using Daubechies wavelet. Heidari et al. [9] and Heidari et al. [10] took a different approach by employing five decomposition levels to characterize strong earthquake parameters. Nonlinear response spectra were generated for each decomposed signal to show the behavior under decomposed earthquake motions. Kandemir [11] and Kandemir and Jankowski [12] studied viscous dampers between adjacent structures using continuous wavelet transform. In a related study, Yamamoto and Baker [13] proposed that a six to seven decomposition level is suitable for describing ground motions, contributing additional insights to the discourse on optimal decomposition strategies in earthquake analysis.

Additionally, there are valuable studies in the related literature that focus on optimization and application to base-isolation system parameters [14-16].

In this study, earthquake acceleration and its approximations have been applied to the base isolated building to clarify the effect of frequency content on the seismic behavior of the structure.

Discrete Wavelet Transform

The Discrete Wavelet Transform (DWT) focuses on a subset of scales and translations, unlike continuous version, resulting in a discrete representation of the signal through wavelet coefficients at various resolution levels. Unlike the Fourier transform, which only provides frequency information, the DWT captures both time and frequency characteristics, making it ideal for analyzing non-stationary signals, such as earthquakes. The most similar signal processing method to DWT is the Short-Time Fourier Transform (STFT). STFT also provides time-frequency analysis by applying a sliding window to perform Fourier transforms across the signal. However, STFT offers a fixed time-frequency resolution based on the window size, whereas DWT's multi-resolution approach adapts to different scales.

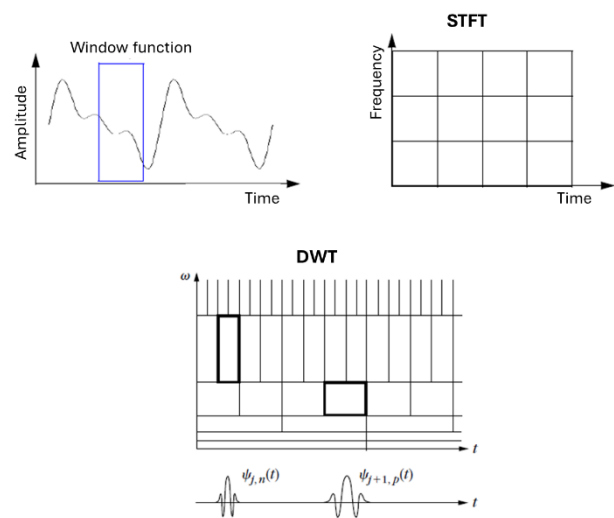


Figure 1. Decomposition of earthquake acceleration signal by discrete wavelet transform (Misiti et al., 2004; Ari et al., 2008)

Losses in frequency or time information occur due to the fixed window function in STFT [17]. Figure 1 illustrates how STFT scans the signal using a window function with a fixed time interval that cannot be stretched or compressed, resulting in a frequency-time graph of the signal within a certain time and frequency band [18]. To overcome these limitations, wavelet transform has been developed as an effective method for decomposing the frequency information of a signal. Using a wavelet function that can be both scaled and shifted, frequency information can be obtained for multiple time intervals [19]. High-frequency information is obtained in narrow time intervals, while low-frequency information is captured in wider time intervals.

In each decomposition level of DWT, a high-pass filter eliminates low-frequency components, and a low-pass filter removes high-frequency components. This procedure results in detail and approximation coefficients, respectively [4]. The DWT of a signal is expressed as,

$$DWT(j, k) = \sum_n f(n) \cdot \psi_{j,k}(n) \tag{1}$$

where j represents the scale parameter indicating the level of resolution or frequency band, and k represents the translation parameter indicating the time location, $\psi_{j,k}(n)$ represents the scaled and translated version of the mother wavelet function $\psi(t)$ used to analyze the signal. It is defined as:

$$\psi^*(t) = \begin{cases} 1 & 0 \leq t < 0.5 \\ -1 & 0.5 \leq t < 1 \\ 0 & otherwise \end{cases} \tag{2}$$

The decomposition process is achieved through a series of low-pass and high-pass filters, often referred to as scaling and wavelet functions, respectively [4]. Subsequently, the signal is downsampled by a factor of two, as illustrated in Figure 1. This downsampling process reduces the number of samples (N) by half while retaining the essential features at different scales.

Iteratively, the decomposition process is applied to the approximation coefficients, resulting in a multi-level representation of the signal. Each level of decomposition provides information at a different scale as shown in Figure 2. In this paper, approximation coefficients, which capture the low-frequency contents of seismic ground accelerations, have been utilized.

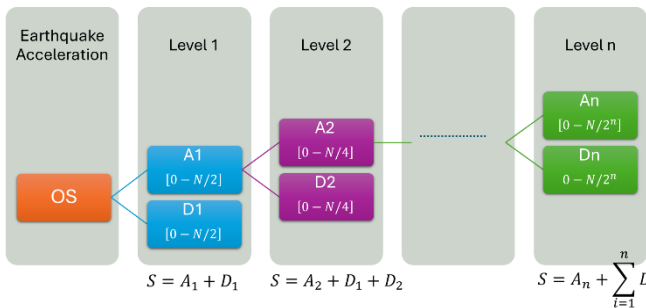


Figure 2. Decomposition of earthquake acceleration signal by discrete wavelet transform

Considered Ground Motion and Its Decompositions

A devastating earthquake struck the southwestern region of Turkey on February 6th, 2023, causing widespread destruction and significant seismic activity. Acceleration records from the seismic event in Kahramanmaraş in 2023 are employed for analysis in this study. Specifically, the acceleration record from Elbistan station (TK4612) is utilized due to its high peak ground acceleration. Details regarding the seismic record of the station are provided in Table 1.

Table 1. Selected ground motion

Earthquake-Station	Component	Magnitude	PGA (g)
Kahramanmaraş-Elbistan	NS	7.6	0.648

The wavelet transform is a valuable tool for understanding the characteristic frequency contents that define the presentation of the original earthquake signal. The identification of these frequencies varies depending on the number of decomposition levels used. To quantify and understand these frequency characteristics, one can calculate the frequency ranges and corresponding time intervals of a given time series as given in Table 2 for the earthquake.

Table 2. Frequency ranges and corresponding time intervals of the ground motion

Level	Frequency range (Hz)	Time interval (s)
1	0.097656-0.19531	52.50-104.99
2	0.19531-0.39063	26.25-52.50
3	0.39063-0.78125	13.12-26.25
4	0.78125-1.5625	6.56-13.12
5	1.5625-3.125	3.28-6.56
6	3.125-6.25	1.64-3.28
7	6.25-12.5	0.82-1.64
8	12.5-25	0.41-0.82
9	25-50	0.21-0.41
10	50-100	0-0.21

Figure 3 illustrates the original acceleration signal and its decomposition into five levels (details and approximations) for Elbistan earthquake. Notably, the first, second and third level approximations (A1, A2 and A3, respectively) exhibits the most significant similarity in shape with the original signal. This is because, most of the energy from the initial signal is stored in the approximations, providing a coarse representation while retaining essential features at a lower resolution. As the decomposition progresses to higher levels, the detail coefficients capture finer details and high-frequency components, but may introduce more noise and less relevant information [4].




Figure 3. Decomposition of earthquake acceleration signal by discrete wavelet transform




Figure 4. Fourier spectrum of the earthquake

Figure 4 illustrates that the Fourier spectrum of the earthquake record exhibits a notable amplitude for frequencies up to 3 Hz. Therefore, it is verified that for this earthquake, the DWT method performs better due to its frequency content being dominated by low-pass frequencies.

Numerical Outcomes

The examination is conducted on a 3-story base isolated building exposed to the original earthquake acceleration signal (denoted as OS) and its approximations up to five levels (A1, A2, A3, A4, A5). The building is idealized as lumped mass-stiffness model. The design of base-isolated structures aims to ensure that the structure's dynamic behavior remains elastic [20]. To achieve this, the base isolation system is designed to interrupt the transmission of seismic waves, thereby ensuring that the superstructure behaves linearly. Consequently, base-isolated structures typically exhibit linear behavior.

In the current section, the displacement responses of the base mat and acceleration response of the top story under the selected earthquake acceleration are provided. The study investigates the effects of varying isolator periods, specifically 2, 2.5, and 3 seconds, alongside damping ratios of 30% and 40%. The resulting time responses for each scenario have been derived and analyzed.

The results of the time response analyses focus on the acceleration response of the top story, divided by the peak ground acceleration (PGA). Table 3 presents peak

responses for various isolator periods and 30% damping ratio. It is observed that as the period increases, the acceleration response decreases, while the displacement response increases. Additionally, upon examining the decomposed signal of ground acceleration, it is noted that the building exhibits consistent behavior when exposed to OS, A1, A2, and A3 scenarios, similar to the time histories given in Figure 2. However, the behavior significantly alters under A4 and A5 scenarios. This highlights the importance of determining the optimal decomposition level for both the structure and earthquake under consideration.

Table 3. Peak Acceleration and Displacement Responses for the Varied Isolator Period of $T_b=2$ to 3 sec and $\xi_b=30\%$

Isolator parameters	OS	A1	A2	A3	A4	A5
$T_b=2$ sec	0.797	0.797	0.797	0.794	0.785	0.733
$\xi_b=30\%$	39.251	39.251	39.250	39.115	38.715	37.282
$T_b=2.5$ sec	0.597	0.597	0.596	0.594	0.586	0.562
$\xi_b=30\%$	44.247	44.240	44.220	44.138	43.801	42.511
$T_b=3$ sec	0.437	0.437	0.436	0.434	0.427	0.420
$\xi_b=30\%$	46.929	46.920	46.890	46.766	46.274	44.458

Table 4 also demonstrates consistent results across various isolator periods, maintaining a damping ratio of 40%. Notably, a distinct trend emerges compared to the 30% damping scenario, the acceleration response increases, while the displacement response decreases. This underscores the critical influence of the damping ratio on structural behavior during seismic events. Employing first-level decomposition produces precise results, with A2 and A3 also yielding outcomes near those obtained by OS. However, it's important to acknowledge that A4 and A5 scenarios yield significantly different outcomes, especially for displacement responses, highlighting the sensitivity of structural response to seismic input decomposition levels.

Table 4. Peak Responses for the Varied Isolator Period of $T_b=2$ to 3 sec and $\xi_b=40\%$

Isolator parameters	OS	A1	A2	A3	A4	A5
$T_b=2$ sec	0.750	0.750	0.748	0.743	0.727	0.666
$\xi_b=40\%$	32.695	32.691	32.667	32.571	32.319	30.976
$T_b=2.5$ sec	0.590	0.589	0.5890	0.588	0.582	0.541
$\xi_b=40\%$	36.715	36.713	36.697	36.633	36.369	35.281
$T_b=3$ sec	0.457	0.457	0.457	0.456	0.451	0.425
$\xi_b=40\%$	43.423	43.413	43.384	43.266	42.805	41.105

Structures designed with base isolators of 2 and 3 second periods corresponded to natural frequencies of 0.5 Hz and 0.33 Hz, respectively. These frequencies fell between the first and third decomposition levels used in the earthquake analysis (see Table 2). The appropriate decomposition level was identified as A1, A2 and A3; and it was observed that the seismic response results closely matched the preliminary predictions.

The correlation between the acceleration responses and the approximations up to seven levels of decomposition has also been investigated using the following equation,

$$Ratio_c = \frac{\sum_i(A_i)_n(\ddot{x}_i)_n}{\sqrt{\sum_i(A_i)_n^2} \sqrt{\sum_i(\ddot{x}_i)_n^2}} \quad (3)$$

where i is the time step, n is level of decomposition ($n = 1, \dots, 7$) and A is approximation coefficients while \ddot{x} is the acceleration response of the structure. In this section, the analyses are performed up to seven levels of decomposition to capture the highest rate of correlation. The results are presented in Tables 5 and 6.

Table 5. Correlation for $T_b = 2$ to 3 sec and $\xi_b = 30\%$

Isolator parameters	A1	A2	A3	A4	A5	A6	A7
$T_b = 2$ sec $\xi_b = 30\%$	-0.030	0.005	0.082	0.254	0.539	0.888	0.485
$T_b = 2.5$ sec $\xi_b = 30\%$	-0.071	-0.039	0.032	0.194	0.454	0.819	0.681
$T_b = 2.5$ sec $\xi_b = 30\%$	-0.057	-0.027	0.039	0.188	0.419	0.761	0.792

Table 6. Correlation for $T_b = 2$ to 3 sec and $\xi_b = 40\%$

Isolator parameters	A1	A2	A3	A4	A5	A6	A7
$T_b = 2$ sec $\xi_b = 40\%$	0.127	0.167	0.254	0.443	0.717	0.948	0.396
$T_b = 2.5$ sec $\xi_b = 40\%$	0.054	0.092	0.176	0.361	0.626	0.912	0.587
$T_b = 3$ sec $\xi_b = 40\%$	0.036	0.072	0.152	0.328	0.575	0.869	0.710

Figures 5 and 6 illustrate the correlation values for seven-level decomposition. The lowest correlation occurs for the first three decomposition levels, while the highest peaks,

indicating a larger correlation between acceleration response and approximation, occur at the sixth-level decomposition. At high decomposition levels, where low-frequency components prevail (see Table 2), the correlation increases due to the base isolator lowering the structure's overall frequency.




Figure 5. Correlation values between acceleration response and approximations for $\xi_b = 30\%$




Figure 6. Correlation values between acceleration response and approximations for $\xi_b = 40\%$

To further validate the results and enhance the study, a 4-story benchmark building given in the study of Kandemir and Mortazavi [15] has been examined through DWT. The optimal parameters identified in their study are a 2.507-second isolator period and 30% damping ratio. For the 1994 Northridge earthquake record (SYL360), Kandemir and Mortazavi [15] reported the base displacement of 36.215 cm and PGR/PGA ratio of 0.400. Table 7 shows the comparative responses obtained from the original signal and its approximations up to the fifth level. We identified the appropriate decomposition levels as A1, A2, and A3, and observed that the results closely aligned with the previous outcomes given by Table 3 and 4.

Table 7. Peak Responses for the Varied Isolator Period of $T_b = 2.507$ sec and $\xi_b = 30\%$

OS [15]	A1	A2	A3	A4	A5
0.400	0.395	0.385	0.355	0.329	0.300
36.215	36.209	36.149	35.904	34.942	31.286

Conclusions

The study investigates the dynamics of structural response under seismic loading conditions, with a focus on the displacement response of the base mat and the acceleration response of the top story in a 3-story base isolated building. It explores the effects of varying isolator periods and damping ratios, considering both the original earthquake acceleration (OS) and its approximations (A1, A2, A3, A4, A5). The outcomes of the study can be listed as follows:

- As the analysis progresses by changing the isolator parameters, a noticeable pattern emerges: an increase in isolator period correlates with a decrease in acceleration response and a simultaneous increase in displacement response. This trend underscores the tangled relationship between isolator periods and structural dynamics, highlighting their crucial role in mitigating seismic forces.
- Regardless of base isolation parameters, the adequate decomposition levels for the corresponding earthquake and the structure are achieved as A1, A2 and A3 where the responses are similar to those obtained for the original acceleration.
- The frequencies of structures designed using base isolators with periods of 2 and 3 seconds correspond to 0.5 Hz and 0.33 Hz, respectively. These frequency ranges fall between the first- and third-decomposition levels of the decomposed earthquake levels. In this context, the appropriate decomposition level was carefully identified, and it was found that the results of seismic response closely aligned with the preliminary outcomes given in Table 2. This alignment demonstrates the effectiveness of the decomposition approach in accurately capturing the seismic behavior of the structures at these frequencies.
- The computational time for the time response analyses conducted using A1, A2, and A3 was reduced to approximately half, one-quarter, and one-eighth of the original time, respectively.
- The relation between the ground motion and the acceleration responses increases while the damping of the isolator increases. However, the dynamic behavior of the base-isolated structure shows low degree of correlation proportional to

the resonance experienced in the low frequency band of the earthquake.

In summary, the discrete wavelet transform proves to be a beneficial tool for deriving seismic responses with reduced acceleration record length, thereby resulting in low computational cost.

Acknowledgements

This study was supported by İzmir Demokrasi University Scientific Research Projects Coordination Unit project No. HIZDEP-MHF/2202.

Conflict of Interest

The authors have no conflicts of interest to declare.

References

- [1] J.M. Kelly, "Base Isolation: Linear Theory and Design", *Earthquake Spectra*, vol. 6, no. 2, pp. 223-244, 1990.
- [2] T.T. Soong and Constantinou, M.C., "Passive and Active Structural Vibration Control in Civil Engineering", Springer-Verlag: New York, NY, USA, 1994.
- [3] S.G. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation", *IEEE Trans Pattern Anal Mach Intell.*, vol. 11, pp. 674-93, 1989.
- [4] S.G. Mallat, "A wavelet tour of signal processing", Elsevier, 1999.
- [5] I. Daubechies, "The wavelet transform, time-frequency localization and signal analysis", *IEEE Trans Inf Theory*, vol. 36, pp. 961-1005, 1990.
- [6] R. Kamgar, R. Tavakoli, P. Rahgozar and R. Jankowski, "Application of discrete wavelet transform in seismic nonlinear analysis of soil-structure interaction problems" *Earthquake Spectra*, vol. 37, no.3, pp. 1980-2012, 2021.
- [7] R. Kamgar, M. Dadkhah and H. Naderpour, "Earthquake-induced nonlinear dynamic response assessment of structures in terms of discrete wavelet transform", *Structures*, vol. 39, pp. 821-847, 2022.
- [8] M.R. Kaloop and J.W. Hu, "Seismic response prediction of buildings with base isolation using advanced soft computing approaches", *Advances in Materials Science and Engineering*, vol. 2017, pp. 1-12, 2017.
- [9] A. Heidari, J. Raeisi and S. Pahlavan Sadegh, "A new method for calculating earthquake characteristics and nonlinear spectra using wavelet theory", *Journal of Rehabilitation in Civil Engineering*, vol. 8, no. 1, pp. 50-62, 2020.

- [10] A. Heidari, J. Raeisi and R. Kamgar, "Application of wavelet theory with denoising to estimate the parameters of an earthquake", *Scientia Iranica*, vol. 28, no. 1, pp. 49-64, 2021.
- [11] E.C. Kandemir, "Alternate approach for calculating the optimum viscous damper size," *Građevinar*, vol. 75, no. 02, pp. 153-162, 2023.
- [12] E.C. Kandemir and R. Jankowski, "Effect of soil on the capacity of viscous dampers between adjacent buildings," *Građevinar*, vol. 75, no. 04, pp. 329-342, 2023.
- [13] Y. Yamamoto and J.W. Baker, "Stochastic model for earthquake ground motion using wavelet packets", Technical Report Blume Center Report 176. Stanford, CA: Stanford University, 2011.
- [14] E.C. Kandemir and A. Mortazavi, "Optimizing base isolation system parameters using a fuzzy reinforced butterfly optimization: A case study of the 2023 Kahramanmaraş earthquake sequence," *Journal of Vibration and Control*, vol. 30, no. 3-4, pp. 502-515, 2024.
- [15] E.C. Kandemir and A. Mortazavi, "Optimization of seismic base isolation system using a fuzzy reinforced swarm intelligence," *Advances in Engineering Software*, vol. 174, article 103323, 2022.
- [16] A. Mortazavi, "Size and layout optimization of truss structures with dynamic constraints using the interactive fuzzy search algorithm," *Engineering Optimization*, vol. 53, no. 3, pp. 369-391, 2021.
- [17] E.C. Kandemir, "Sismik taban izolatörlü yapıların yakın ve uzak fay depremleri altındaki davranışlarının dalgacık dönüşümü ile incelenmesi," *Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, vol. 27, no. 2, pp. 257-268, 2022.
- [18] N. Arı, Ş. Özen and Ö.H. Çolak, "Dalgacık Teorisi (Wavelet), Matlab Uygulamaları ile," Palme Yayıncılık, Ankara, 2008.
- [19] M. Misiti, Y. Misiti, G. Oppenheim and J.M. Poggi, "Wavelet Toolbox," The MathWorks, 2004.
- [20] A. Alhan and M. Sürmeli, "Shear building representations of seismically isolated buildings," *Bulletin of Earthquake Engineering*, vol. 9, pp. 1643, 2011.



CBS Tabanlı AHP Çok Kriterli Karar Verme Yöntemi (ÇKKVY) Kullanılarak Van Gölü Güzelsu Alt Havzası Taşkın Risk Haritalarının Çıkarılması ve Değerlendirilmesi

Evaluation and Mapping of Flood Risk In Van Lake Güzelsu Sub-Basin Using GIS Based AHP Multiple Criteria Decision Making (MCDM) Method

Erdi Tanış^{1*}, Recep Çelik²

¹ Dicle Üniversitesi, İnşaat Mühendisliği Bölümü, taniserdi@gmail.com
ORCID: <https://orcid.org/0009-0002-5053-3152>

² Dicle Üniversitesi, İnşaat Mühendisliği Bölümü, recep.celik@dicle.edu.tr
ORCID: <https://orcid.org/0000-0002-0739-6146>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 19 Ağustos 2024
Revizyon 2 Ekim 2024
Kabul 17 Ekim 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

Van Gölü Güzelsu Alt Havzası,
Taşkın risk analizi, CBS,
ÇKKVY (Çoklu Kriterli Karar
Verme Yöntemi), AHP (Analitik
Hiyerarşi Prosesi)

ÖZ

Taşkın; bir akarsuyun çeşitli sebeplerle yatağından taşarak, çevresindeki arazilere, yerleşim yerlerine, altyapı tesislerine ve canlılara zarar vererek o bölgedeki ekonomik ve sosyal faaliyetleri kesintiye uğratan bir tabii olaydır. Taşkınlar her yıl can kaybı yanında büyük sosyo-ekonomik zararlara yol açmaktadır. Son yıllarda küresel iklim değişikliği ve yanlış arazi kullanımı etkisi ile yaşanan taşkınların sayısında ve etkisinde önemli artışlar olmaktadır. Bu nedenle farklı karakteristikleri temsil eden veri katmanlarının bir arada değerlendirilmesi, taşkın riski taşıyan bölgelerin belirlenmesinde önemlidir. Coğrafi Bilgi Sistemleri (CBS) potansiyel taşkın risk alanlarının belirlenmesinde büyük kolaylıklar sağlayan bir platformdur. Coğrafi Bilgi Sistemleri potansiyel taşkın risk alanlarının belirlenmesi amacıyla mevcut verilerin toplanması, işlenmesi ve analizinin yapılmasında kullanılmaktadır. Güzelsu havzası Türkiye'nin doğusunda yer alan Van Gölü çevresindeki alt su toplama havzasıdır. Güzelsu Alt Havzası, coğrafi ve ekolojik olarak önemli bir bölgedir ve su kaynakları yönetimi, su akışı, özellikle taşkın riski değerlendirmeleri için dikkatle incelenmesi gerekir. Bu çalışmada da CBS aracılığıyla Van Gölü Güzelsu alt havzasının taşkın risk alanları belirlenmiştir. Modelleme aşamasında, Çok Kriterli Karar Verme Yönteminde, taşkın oluşumuna etki eden; yükselti, yağış, jeoloji, eğim, baki, nehre uzaklık, toprak grubu ve arazi kullanım parametreleri kullanılmıştır. Tüm parametrelerin olaydaki etki ağırlıkları AHP yöntemi ile belirlenmiş, ArcGIS programında da belirlenen ağırlık oranları tematik haritalara işlenerek çakıştırılmış ve sonuçta bölgede taşkın esnasında etkilenecek alanların risk haritaları elde edilmiştir. Üretilen taşkın risk haritasına göre, "Çok Yüksek Riskli" alanlar %6.6, "Yüksek Riskli" alanlar %14.5, "Riskli" alanlar %29.7, "Az Riskli" alanlar %31.9 ve "Risksiz" alanlar %17,2 oranında yer kaplamaktadır.

ARTICLE INFO

Article history:

Received 19 August 2024
Received in revised form 2 October 2024
Accepted 17 October 2024
Available online 23 December 2024

Keywords:

Analytic Hierarchy Process, Flood
Risk Analysis, Multiple Criteria
Decision Making Method, GIS,
Güzelsu Sub-basin of Lake Van

Doi: 10.24012/dumf.1534940

ABSTRACT

Flood is a natural phenomenon where a river overflows its banks due to various factors, causing damage to surrounding lands, settlements, infrastructure, and living beings, thereby disrupting the economic and social activities in the area. Floods cause significant socio-economic damage each year, along with the loss of life. In recent years, there has been a significant increase in the number and impact of floods due to global climate change and improper land use. Therefore, evaluating data layers representing different characteristics together is crucial for identifying areas at risk of flooding. Geographic Information Systems (GIS) provide a valuable platform for identifying potential flood risk areas. GIS is used to collect, process, and analyse existing data for the purpose of determining potential flood risk areas. Güzelsu Basin is a sub-watershed located around Lake Van in eastern Turkey. The Güzelsu Sub-basin is geographically and ecologically significant and requires careful examination for water resource management, water flow, and especially flood risk assessments. In this study, flood risk areas in the Güzelsu sub-basin of Lake Van were identified using GIS. In the modelling phase, factors affecting flood formation such as elevation, precipitation, geology, slope, aspect, major soil group, and land use parameters were used in the Multiple Criteria Decision Making method. The weights of all parameters were determined using the AHP method, and the determined weight ratios were processed into thematic maps in ArcGIS and overlaid to produce flood risk maps showing the areas affected during a flood. According to the generated flood risk map, "Very High Risk" areas cover 6.6%, "High Risk" areas cover 14.5%, "Risky" areas cover 29.7%, "Low Risk" areas cover 31.9%, and "No Risk" areas cover 17.2% of the region.

Giriş

Dünyada birçok ülke ve kıtada insanların hayatına ekonomik ve sosyal bakımdan etki eden önemli doğal afetlerden birisi taşkındır. Akarsu havzalarının taşıyabileceğinden fazla olan ve kapasitesinin üzerindeki suyun gelmesi ile doluluk oranının artması taşkın olayını tetikleyen en büyük sebeptir.. Akarsu yataklarından geçen su miktarının, akarsunun yatak kapasitesini aşması sonucunda sel, su basması ve taşkın gibi doğa olayları meydana gelir [1]. Dünya çapında en sık gerçekleşen ve en geniş coğrafi dağılıma sahip doğal afet taşkınlardır[2]. Taşkınlar, toprağı sular altında bırakarak tarım arazilerine, yerleşim alanlarına zarar verebilir ve hatta can kaybına yol açacak derecede tehlikeli boyutlara ulaşabilir [3][4]. Taşkın afeti, akarsu yatağı boyunca hızlı ve çarpık kentleşme ve ormansızlaşma ile yakından bağlantılıdır [5]. Taşkın olayı sonucunda oluşacak zararları önlemek için yapılacak çalışmalarda; dere ıslahı ve taşkın koruma yapısında kullanılacak malzemenin seçimi oldukça önemlidir [6]. Akarsu yataklarında yapılacak dere ıslah çalışmaları, tersip bentleri, göletler, barajlar vb. yapılarda uygulama ve hesaplama adımlarında yapılan hatalar, taşkınların insan kaynaklı olarak da meydana gelmesine neden olmaktadır [7]. Devlet Su İşleri (DSİ) Genel Müdürlüğünden alınan verilere göre Türkiye’de gerekli görülen yerlerde sel kapanı, tersip bendi, taşkın kontrol yapıları, baraj, gölet, vb. gibi yapı ve tesislerde artış meydana gelmesine rağmen son 40 yılda yaklaşık 600 den fazla ölüm gerçekleşmiş, 800.000 hektardan fazla tarım arazisi taşkından zarar görmüştür [8].

Genel olarak bakıldığında birçok faktör taşkın afetine sebep olabilmektedir. Taşkın oluşması üzerinde etkisi büyük olan faktörlerden birisi de mevsimlerdir. Bir doğal afet olan taşkın olayının meydana gelmesinin en büyük sebebi ise, akarsu havzalarına gelen suyun bir müddet sonra havza kapasitesinin üzerine çıkması ile doluluk oranının artmasıdır. Taşkın etkileyen mevsim faktörüne bakılarak yorumlama yapıldığında, kış mevsiminde karların eriyerek akışa geçmesi ile ilkbahar ve sonbahar aylarında yağışların çok fazla miktarda ve şiddetli bir biçimde gelmesi taşkın oluşum riskini büyük ölçüde etkiler. Taşkın analizi, özellikle su baskınları gibi doğal afetlerin etkilerini değerlendirme ve bu afetlerle mücadele stratejileri geliştirme amacıyla kullanılan kritik bir yöntemdir. Bu analiz yöntemi, altyapı planlaması, risk yönetimi ve çevre koruma gibi alanlarda önemli bir rol oynamaktadır [9][10][11]. Taşkın analizi, büyük ölçekli su yönetimi projelerinde ve çevresel sürdürülebilirlik çalışmalarında kullanılmakta ve karar vericilere güçlü bir analitik araç sunmaktadır.

Çok kriterli karar verme (ÇKKV) yöntemleri ise, günümüzde karar verme süreçlerinde önemli bir rol oynamakta olup, çeşitli sektörlerde kompleks


problemlerin çözümünde kullanılan etkili araçlardan biridir. ÇKKV, karar vericilere farklı alternatifler arasında objektif bir değerlendirme yapma imkânı sunarak en uygun seçeneğin belirlenmesine katkıda bulunur. Bu yöntem, birçok karar verme sürecinde kullanılan ve karar alma sürecini sistemli bir şekilde yapılandıran matematiksel ve analitik bir yaklaşımdır [12][13][14]. Özellikle son yıllarda CBS tabanlı haritalama yöntemleri ile taşkın oluşum riskinin belirlenmesi kapsamında önemli bir yöntem olmuştur. Son yıllarda, CBS tabanlı çoklu kriterli değerlendirme metodunun Taşkın analizi üzerindeki etkisini inceleyen araştırmalar artmıştır. Zhang ve diğerleri (2018), ÇKKV'nin su baskını yönetiminde nasıl kullanılabileceğini ve bu yöntemin karar alıcıların sel riskini azaltma stratejileri üzerindeki etkisini araştırmışlardır [15]. Bu çalışmalar, ÇKKV'nin karar verme süreçlerine getirdiği sistematik yaklaşımı vurgulamaktadır. Ayrıca, Sahu ve Patil (2020), CBS'nin taşkın risk haritalarının oluşturulmasında nasıl kullanılabileceğini ve ÇKKV yöntemlerinin bu haritaların iyileştirilmesindeki rolünü incelemiştir [16]. Bu çalışma, CBS ve ÇKKV'nin entegrasyonunun taşkın yönetimi stratejilerinin optimize edilmesine nasıl katkı sağlayabileceğini göstermektedir. ÇKKV'nin karar alıcılar için bilgi temelli ve veri odaklı kararlar alma sürecini güçlendirdiği, böylece su yönetimi gibi karmaşık sorunların etkin bir şekilde çözülebildiği belirtilmektedir.

Coğrafi Bilgi Sistemleri ile geniş alanda ve devamlı algılama yapabilen uydu görüntüleri, taşkın afetine karşı önceden planlamaların yapılmasında, riskli alanların tespitinde ve oluşacak taşkın sonucunun çıkartılmasında önemli bir kaynak olmuştur. Uzaktan algılama ile uydu görüntülerinden gerekli doneler elde edilerek ve taşkın risk analizi yapılarak, meydana gelebilecek afet için önceden bir analiz yapılabilir. Bunun sonucunda da alınması gereken önlemler belirlenebilir. Taşkın konusunda planlama yapılarak taşkın önlenmesi açısından coğrafi konuma bağlı yersel ve öznitelik verilerinin sağlanması, alınacak verinin güncelleştirilerek saklanması, analiz edilmesi ve taşkın risk haritalarının oluşturulması önemli bir yere sahiptir [17]

2- Materyal Ve Yöntem

2.1-Çalışma Alanı

Çalışma alanı, Van ilinin Gürpınar ilçesinin büyük bir kısmı ile Gevaş, Edremit ve Çatak ilçelerinin az bir kısmını kapsamaktadır (Şekil 1). Güzelsu Alt Havzası geniş ve eğimi yüksek bir havzadır. Havzanın eğiminin fazla olması, arazi kullanım ve zemin özellikleri nedeniyle özellikle ilkbahar ve sonbahar aylarında gelen yağışlar sonucunda bölgede sıkça taşkın olayları meydana gelmektedir. Havzaya ait aşağıdaki şekilde gösterilen yükselti haritası <https://urs.earthdata.nasa.gov> sitesinden alınan DEM Haritasının ArcMap programında sayısallaştırılması sonucunda oluşturulmuştur.



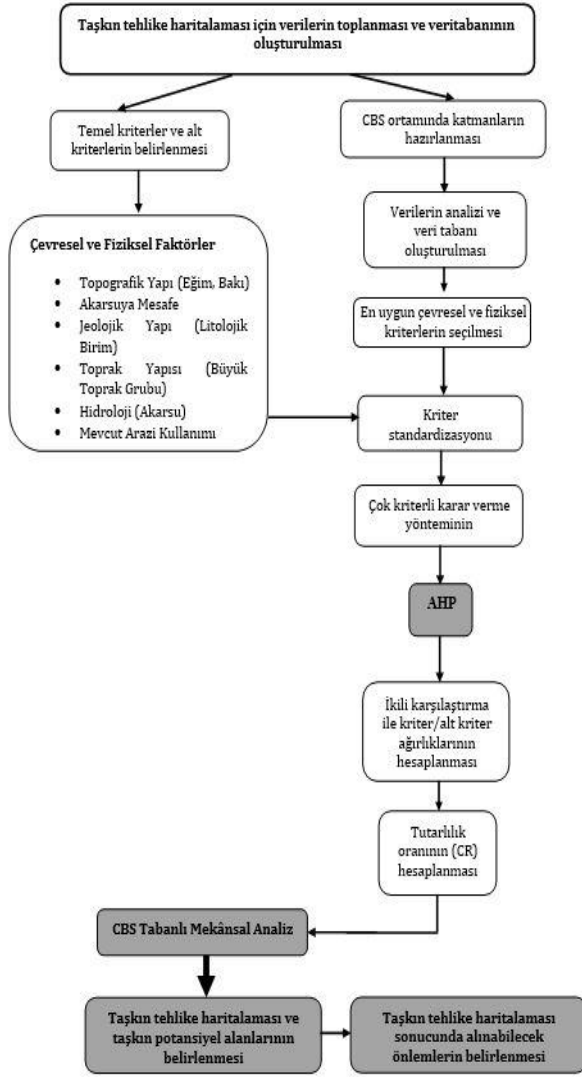
Şekil 1 – Çalışma alanına ait yükselti haritası

2.2-Veri Temini

Bu çalışmada kullanılan jeoloji verileri, DSİ 17.Bölge Müdürlüğü Jeoteknik Hizmetler Şube Müdürlüğünden temin edilmiştir. Toprak verisi olarak kullanılan büyük toprak grubu verisi, Tarım Reformu Genel Müdürlüğünden alınmıştır. Yağış haritasındaki yağış verileri Meteoroloji Genel Müdürlüğünün web sitesinden temin edilmiştir. Yağış haritası hazırlanırken yağışın mekânsal dağılışı Schreiber formülü ile hesaplanarak veri enterpolasyonuna tabi tutulmuştur. Arazi kullanımı haritası verisi ise Copernicus Arazi İzleme Hizmeti tarafından oluşturulan 2018 yılı CORINE verisidir. Bakı ve eğim haritaları urs.earthdata.nasa.gov web sitesinden temin edilmiş Sayısal Yükselti Modeli (SYM) verisinin ArcMap 10.8 programında analiz edilmesiyle oluşturulmuştur. Tüm bu haritalar ArcMap ortamında ED_1950_UTM_Zone_38N projeksiyon sisteminde hazırlanmıştır.

2.3-Yöntem

Çalışmada, Güzelsu Alt Havzasının taşkın duyarlılık analizi, CBS teknikleriyle analiz edilip yorumlanmıştır. Coğrafi Bilgi Sistemleri tabanında yapılan analizlerde kullanılan kriterlerin (jeoloji, akarsuya uzaklık, eğim, bakı, toprak, yağış, arazi kullanımı) ağırlıkları Çok Kriterli Karar Verme (ÇKKV) Yöntemi'nin bir alt metodu olan Analitik Hiyerarşi Prosesi (AHP) ile belirlenmiştir. Analitik Hiyerarşi Prosesi, Çok Kriterli Karar Verme Yöntemleri arasında uygulanacak amaca bağlı olmakla beraber en çok kullanılan yöntemlerdendir. Sonuçları 3 etkileyen kriterler oransal olarak bir dağılım oluşturur ve bu şekilde karar verilir. Bu yöntemde belirlenen kriterler ele alınarak hiyerarşik bir yapı oluşturulur, ele alınan kriterler ikili karşılaştırmalar matrisi şeklinde belirlenir ve modelleme yapılır [20][21]. AHP yöntemiyle kriterlerin (jeoloji, akarsuya uzaklık, eğim, bakı, toprak, yağış, arazi kullanımı) ağırlıkları 1-9 önem derecesi arasında değişen değerlendirme ölçeğine göre değerlendirildikten sonra ArcMap 10.8 yazılımında Weighted Sum (ağırlıklı toplam) aracı kullanılarak tüm kriterler toplanıp çalışma alanının taşkın risk haritası üretilmiştir. Yöntemin akış şeması Şekil 2'de ayrıntılı olarak verilmiştir.



Şekil 2 – Yöntemin akış diyagramı

2.3.1- AHP (Analitik Hiyerarşi Prosesi)

Yağış, bakı, eğim, arazi kullanımı, jeoloji, büyük toprak grubu ve akarsuya mesafe kriterlerinin her birinin göreceli ağırlığını belirlemek için bu çalışmada bir ikili karşılaştırma yöntemi olan AHP kullanılmıştır. Birden çok kriterli olan problemlerde karar verme işlemi, karar mekanizmasına dayalı subjektif bir işlemdir [22]. Bu teknik, öznel olarak daha kolay değerlendirilebilen ve daha kolay anlaşılabilen alt sorunların bir hiyerarşisi içerisinde problemlerin çözümlenmesini sağlayan bir araçtır. Öznel değerlendirmeler, sayısal bir ölçek şeklinde sıralanan sayısal değerlere dönüştürülmektedir [23]. AHP'nin temelinde ikili karşılaştırma matrislerinin oluşturulması yer almaktadır.

İkili karşılaştırma matrisi bir karar aşamasına gereksinim duymaktadır. İkili karşılaştırmaların oluşturulmasında karar vermek için 1 den 9 a kadar olan

bir puanlama ölçeği kullanılmaktadır. Burada 1 değeri eşit öneme sahip olmayı ifade ederken 9 değeri en önemli kriteri ifade etmektedir [13]. Karşılaştırma matrisinde her bir faktörün önem derecesini saptayabilmek için Tablo 1'de verilen Saaty (1980) tarafından geliştirilmiş olan önem dereceleri ölçeğinden yararlanılmaktadır.

Tablo 1 – AHP Değerlendirme Ölçeği

Önem Değerleri	Değer Tanımları
1	Her iki faktör eşit öneme sahipse
3	1. faktör 2. faktöre göre daha önemliyse
5	1. faktör 2. faktöre göre çok önemliyse
7	1. faktör 2. faktöre göre çok güçlü bir öneme sahipse
9	1. faktör 2. faktöre göre mutlak üstün bir öneme sahipse
2,4,6,8	Ara değerler

Bu çalışmada Saaty'nin özvektör yöntemi kullanılmış olup bu yöntemin formülü aşağıda verilmiştir.

$$W_i = \frac{1}{n} \sum_{j=1}^n \frac{a_{ij}}{\sum_{j=1}^n a_{ij}}$$

Özvektör hesaplandıktan sonra her bir kriterle ait göreceli önem dereceleri belirlenerek karşılaştırma matrisinin tutarlılığı (CR) hesaplanır [24]. Burada CR 0.10'un üzerinde çıkarsa karar vericinin tutarsızlığından dolayı matrise girdiği değerlerin tekrar gözden geçirilmesi gerekmektedir [25][26]. Saaty, karşılaştırma matrisinde tutarlılığı hesaplamak için aşağıdaki formülün kullanılmasını tercih etmiştir [27][28]:

$$CR = \frac{CI(\text{Tutarlılık Göstergesi})}{RI(\text{Rassallık Göstergesi})}$$

Bu formüldeki tutarlılık göstergesinin (CI) hesaplanması için de aşağıdaki formülden yararlanılır.

$$CI = \frac{\lambda_{\max} - n}{n - 1}$$

Maksimum özdeğer (λ_{\max}) hesaplanırken aşağıdaki formül kullanılır.

$$\lambda_{\max} = \frac{1}{n} \sum_{i=1}^n \frac{(AW)_i}{W_i}$$

Karşılaştırma matrisinin sütunları ile görelî öncelikler çarpılıp toplanarak ağırlıklı toplam vektör bulunur. Ağırlıklı toplam vektörün elemanları kendisine karşılık gelen görelî önceliğe bölündükten sonra sonucun aritmetik ortalaması λ_{max} 'ı vermektedir [29].

RI oranlarının, matris ölçüsüne karşılık gelen değerleri aşağıdaki tabloda gösterilmiştir [30][31].

Tablo 2 – Rassallık Göstergeleri

n	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
RI	0	0	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49	1,51	1,54	1,56	1,57	1,59

2.3.2- Kriterlerin Puanlanması

Taşkın tehlike haritası oluşturulması için bu çalışmada yağış, eğim, büyük toprak grubu, bakı, arazi kullanımı, jeoloji ve akarsulara uzaklık kriterleri çevresel ve fiziksel kriterler olarak dikkate alınarak değerlendirme yapılmıştır. Bu kriterler taşkın tehlike haritalamasındaki etki düzeyine göre Tablo 2'de verilmiş olan literatür bilgilerine dayalı olarak; alt kriterlere ayrılmış ve her bir alt kriter 1 ile 5 değerleri arasında puanlanmıştır.

Tablo 3 - Seçilen Ana Kriterler, Alt Kriterler ve Alt Kriterlerin Puanları

Ana Kriterler	Alt Kriterler	Puan	Taşkın Riski
Eğim (°)	0-5	5	Çok Yüksek
	5-15	4	Yüksek
	15-25	3	Orta
	25-50	2	Düşük
	50-73,12	1	Çok Düşük
Bakı	Batı	5	Çok Yüksek
	Güney	4	Yüksek
	Kuzey	2	Düşük
	Doğu	1	Çok Düşük
Yağış (mm)	783 – 1282	5	Çok Yüksek
	672 – 783	4	Yüksek
	590 – 672	3	Orta
	483 – 590	2	Düşük
	339 – 483	1	Çok Düşük
Büyük Toprak Grubu	Alüvyal Topraklar	5	Çok Yüksek
	Kolüvyal Topraklar	4	Yüksek
	Regosoller	3	Orta
	Çorak Topraklar	2	Düşük
	Kahverengi Topraklar	1	Çok Düşük
Akarsulara Uzaklık (m)	250	5	Çok Yüksek
	500	4	Yüksek
	1000	3	Orta
	1500	2	Düşük
	> 2000	1	Çok Düşük
Jeoloji	Alüvyon	5	Çok Yüksek
	Kireçtaşı	4	Yüksek
	Kuarsit-Kuars Şist	2	Düşük
	Bazalt	1	Çok Düşük
Arazi Kullanımı	Şehir Yapısı	5	Çok Yüksek
	Sürekli Ürünler	4	Yüksek
	Ekilebilir Alanlar, Meralar ve Otsu Bitkiler	3	Orta
	Karışık Tarım Alanları	2	Düşük
	Orman, Bitki Örtüsü	1	Çok Düşük
	Seyrek ya da Hiç Olmayan Alanlar		

3- Araştırma Bulguları

3.1 – Kriterlerin Değerlendirilmesi

Eğim

Eğim, yüzeydeki suların akışının düzenlenmesinde rol oynayan önemli bir topografik etkidir. Yağışın akarsunun akışına katkısı konusunda eğim, yüksek derecede etkilidir. Özellikle bir alana ulaşan yüzey suları veya yeraltı sularının yönünü ve miktarını etkilemektedir [32]. Eğimin yüksek olduğu alanlarda su akışa geçerken düşük eğimli alanlarda bu durum suyun durgunlaşmasına ve göllenmeye neden olmaktadır [33].

Yağış

Taşkına sebep olan en önemli iklim değişkeni yağıştır. Yağışların şiddeti, süresi ve meydana geli şekilleri son derece önemlidir. Yağış şiddetinin fazla olduğu durumda sızma için yeterince vakit olmaz ve bundan dolayı yüzeydeki sular daha fazla olur. Akarsu havzasında bulunan akarsu yatağının dolmasıyla birlikte yağış suları yüzeysel akışa geçer ve böylelikle taşkın hadisesi başlar. Havzaya düşen bu yağışlar, bölgedeki bitkilenme sayesinde tutulduğundan olayın etkisi çok fazla olmaz ancak, sızma kapasitesi dolduktan sonra havzaya düşen yağışlar akışa geçer ve taşkın hadisesine sebep olur [34].

Akarsuya olan uzaklık

Akarsulara yakın olan alanların, şiddetli yağışlar sırasında veya sonrasında nehirlerin taşması sonucunda taşkına maruz kalma ihtimalinin yüksek olması sebebiyle taşkın risk analizlerinde sıkça kullanılan akarsuya mesafe faktörü önemli bir kriterdir [35]. Akarsu kıyılarına yakın olan alanlar taşkınlardan en fazla etkilenen alanlar olarak ortaya çıkmaktadır [36].

Jeoloji

Jeolojik durum taşkından etkilenme olasılığı yüksek yerlerin belirlenmesinde önemli bir faktördür, çünkü taşkın şiddetini artırma veya azaltma etkisi vardır. Geçirgen kaya formasyonları, iyi bağlantılı gözeneklere sahip olduklarından dolayı suyun yer altına en iyi şekilde sızmasına destek olurlar. Geçirimsiz kaya formasyonları ise bunun aksine daha küçük, daha az birbirine bağlı gözenekler ile daha ince taneli veya karışık tane boyutuna sahiptirler ve bu sebeple suyun yer altına sızmasına engel olurlar [37].

Toprak

Taşkın riskinde etkili bir ölçüt olan toprak grupları suyun sızmasını farklı şekillerde etkilerler. Toprak türüne bağlı olarak yağışın toprak içerisindeki sızma oranı düşük olan toprak türlerinde yüzey drenajının artması ile beraber taşkın riskinin arttığı görülmektedir. Killi topraklar kolay aşınabildiği için geçirimsiz özellik


gösterdiğinden taşkına karşı yüksek duyarlılıktadırlar [38].

Bakı

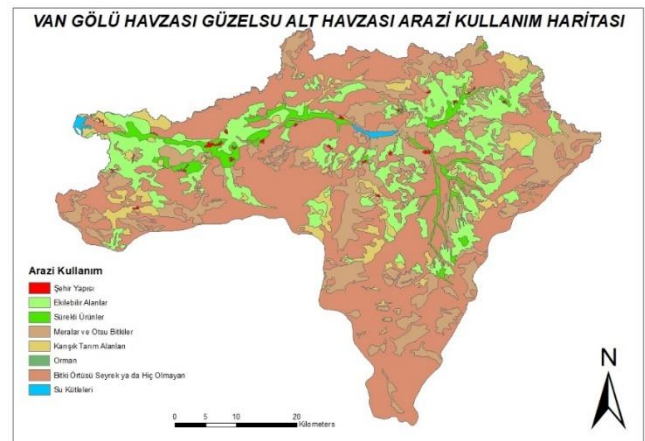
Bakı; yağış miktarı ve sıcaklığa etki ederek dolaylı olarak taşkın üzerinde rol oynamaktadır. Güzelsu Alt Havzasında bulunan akarsuların genel olarak batı ve güney yönlerine doğru mansaplandığı görülmektedir. Bu nedenle taşkın açısından en riskli yönler bunlardır.

Arazi kullanımı

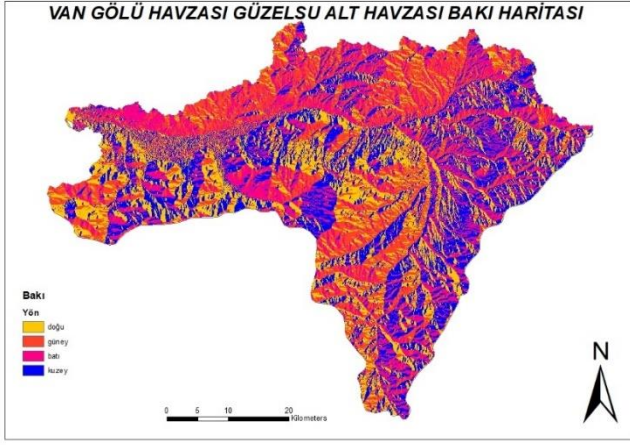
Taşkında etkili olan diğer bir etken de arazi kullanımı'dır. Yüzeydeki suların yer altına sızması arazi kullanımı ile doğrudan bağlantılıdır. Arazi kullanımının uygunsuz, bitki örtüsü seyrek veya bitki örtüsünden tamamen yoksun olduğu arazilerde yağmur suları direkt akışa geçer. Bitki örtüsünün yoğun, arazi kullanımının ise uygun olduğu alanlarda akış daha azdır. Ormanlar ve bitki örtüsünün yoğun olduğu yerler yüzey suyunun yer altına sızmasını desteklerken, kentleşmenin yoğun olduğu yerler, yüzeydeki suların toprağa sızmadan akışa geçmesine neden olur.



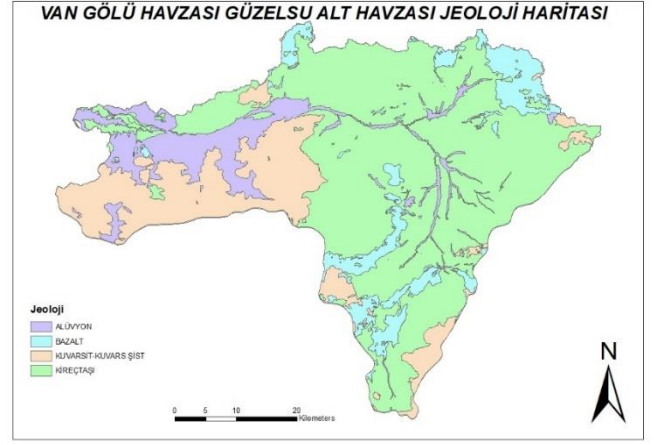
Şekil 3.a – Akarsuya Uzaklık Haritası



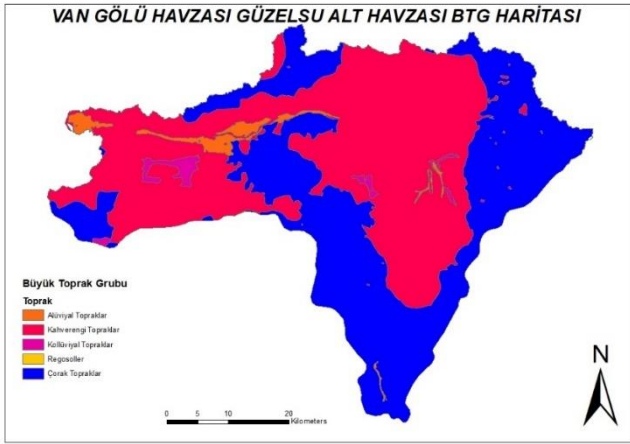
Şekil 3.b – Arazi Kullanım Haritası



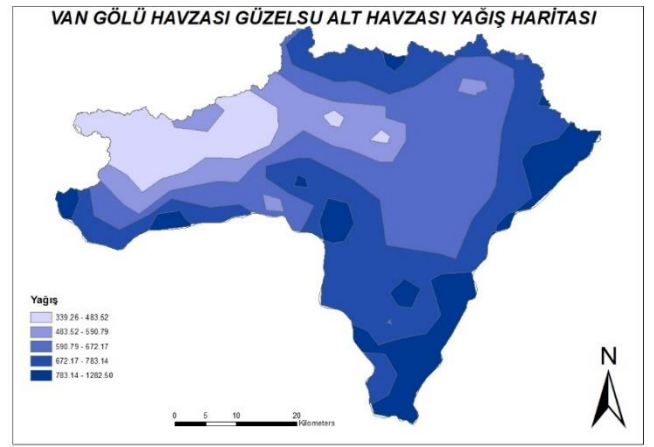
Şekil 3.c – Baki Haritası




Şekil 3.f – Jeoloji Haritası



Şekil 3.d – Büyük Toprak Grubu Haritası



Şekil 3.g - Yağış Haritası




Şekil 3.e – Eğim Haritası

3.2- Taşkın Tehlike Analizi ve Haritalaması

Tablo 4 – Kriterlerin karşılaştırılması ve kriterlere ait ağırlık dereceleri

Kriterler	[1]	[2]	[3]	[4]	[5]	[6]	[7]	Ağırlık Derecesi
(1) Akarsulara Uzaklık	1	2	3	5	7	7	7	0.347
(2) Eğim	1/2	1	3	5	7	7	7	0.282
(3) Yağış	1/3	1/3	1	3	5	5	5	0.161
(4) Arazi Kullanımı	1/5	1/5	1/3	1	3	3	3	0.084
(5) Büyük Toprak Grubu	1/7	1/7	1/5	1/3	1	3	3	0.058
(6) Bakı	1/7	1/7	1/5	1/3	1/3	1	2	0.038
(7) Jeoloji	1/7	1/7	1/5	1/3	1/3	1/2	1	0.030
Tutarlılık Oranı (CR):								0.09

Bu çalışmada AHP analizine dayalı yapılan değerlendirme sonucunda; 7 adet kriter için CR değeri hesaplanmış ve sonuç 0.09 bulunmuştur. Bulunan bu CR değeri 0,1'den küçük olduğu için elde edilen sonuçların tutarlı olduğu kabul edilmiştir. Yapılan bu analiz sonucuna göre; akarsulara uzaklık ve eğim kriterleri taşkın risk haritalamasında en yüksek ağırlık değerine sahip kriterler iken; bakı ve jeoloji kriterleri ise en düşük ağırlık değerine sahip kriterler olduğu görülmüştür (Tablo 3). CBS-AHP tabanlı oluşturulmuş olan taşkın risk haritasının sonucunda ortaya çıkan risk kategorileri “çok yüksek riskli (% 5.49)”, “yüksek riskli (% 14.92)”, “riskli (% 26.74)”, “az riskli (% 36.69)” ve “risksiz (% 16.16)” şeklinde 5 farklı sınıf ile temsil edilmiştir. Güzelsu Alt Havzasının bir kısmı taşkın riski bakımından “çok yüksek riskli” sınıfında yer alırken bir kısmı da “yüksek riskli” sınıfında yer almıştır. Güzelsu Alt Havzasında eğimin ve yükseltinin çok düşük olması, jeolojik birim açısından alüvyal malzemelerin yoğun olması ve yıllık toplam yağış miktarının fazla olması bu durumun en büyük sebeplerindedir. İlerleyen zamanlarda bu bölgedeki yerleşim alanlarının ve tarım arazilerinin olası bir taşkın afetinde yüksek tehdit arz edebileceği göz ardı edilmemelidir.



Şekil 4 – Çalışma Alanına Ait Taşkın Risk Haritası

4- Sonuçlar ve Öneriler

Bu çalışma Van Gölü Havzasının Güzelsu Alt Havzasını kapsamaktadır. Güzelsu Alt Havzası sınırları içerisinde taşkını etkileyecek 7 adet faktör (eğim, arazi kullanımı, toprak, bakı, jeoloji, yağış ve akarsuya olan uzaklık) ele alınarak bölgede meydana gelecek olası bir taşkın, taşkın maruz kalacak riskli alanlar tespit edilmiştir. AHP yöntemiyle bu 7 kriter (jeoloji, akarsuya uzaklık, eğim, bakı, toprak, yağış, arazi kullanımı) değerlendirilerek ArcMap 10.8 yazılımında Weighted Sum (ağırlıklı toplam) aracıyla 7 adet harita çakıştırılarak çalışma alanının taşkın risk haritası üretilmiştir. Üretilen taşkın risk haritasına göre, “Çok Yüksek Riskli” alanlar %6,6 , “Yüksek Riskli” alanlar %14,5 , “Riskli” alanlar %29,7 , “Az Riskli” alanlar %31,9 ve “Risksiz” alanlar %17,2 oranında yer kaplamaktadır.

Bu çalışmada kullanılan yöntem, çalışma alanı olan Güzelsu Alt Havzasında taşkın yönetimi için önerilebilecek bir yöntemdir. Taşkınların tahmin edilemeyen ve yıkıcı sonuçları nedeniyle olası bir taşkın afetinde zarar görebilecek alanların belirlenmesi, risklerin minimum seviyeye indirilmesi açısından oldukça önemlidir. Özellikle çok yüksek riskli, yüksek riskli ve riskli bölgelerin mikro düzeyde sahada da analizlerin yapılması gerekmektedir. Elde edilecek neticeler yardımıyla yapısal veya yapısal olmayan önlemlerle bu risklerin asgari seviyeye indirilmesi gerekmektedir. Bu bölgedeki yerleşim ve tarım alanları ile hayvancılık tesisleri gözden geçirilmeli, muhtemel bir taşkın esnasında erken uyarı sistemlerinin aktifliği ve devamlılığı sağlanmalı, meteoroloji radarlarından faydalanılmalı, taşkın tahliye haritaları ve toplanma alanları taşkın afetinde önce hazır ve belirli olmalıdır [39]. Çalışma bütün olarak ele alındığında; olası bir taşkın zarar görebilecek alanlarda yapılaşma ve kentsel gelişim kontrol altına alınarak bu alanlardaki alt yapı konularında ilgili mevzuat ve standartlar ölçüsünde

gereken iyileştirmeler yapılmalıdır. Böylelikle olası bir taşkında riskli alanların zarar görme ihtimali büyük ölçüde azaltılacaktır.

Teşekkür

Bu çalışma aşamasında hiçbir kaynağı esirgemeyen DSİ 17.Bölge Müdürlüğüne ve danışmanım Doç. Dr. Recep Çelik'e teşekkürü borç bilirim.

Kaynakça

[1] Akman, M.U., Taşkın Koruma ve Kontrol Yapılarının Değerlendirilmesi, 2021

[2] Rudari, R. (2017). Flood hazard and risk assessment.

[3] Huang, X., Tan, H., Zhou, J., Yang, T., Benjamin, A., Wen, S.S., Li, S., Liu, S., Liu, A., Li, X., et al., 2008. Flood hazard in Hunan province of China: an economic loss analysis. *Nat Hazards*, 47, 6573.

[4] Veerbeek, W., Zevenbergen, C., 2009. Deconstructing urban flood damages: increasing the expressiveness of flood damage models combining a high level of detail with a broad attribute set. *Flood Risk Manag.*, 2, 4557

[5] Tehrany, M.S., Pradhan, B. & Jebur, M.N. (2013). Spatial prediction of flood susceptible areas using rule based decision tree (DT) and a novel ensemble bivariate and multivariate statistical models in GIS. *Journal of Hydrology*, 504, 69–79.

[6] Koç, C., Bayazıt, Y., Bakış, R., Yıldız, A. Karaelmalar Deresi Taşkın Koruma Yapısının Yapılma Amacının Coğrafi Bilgi Sistemleri Yardımıyla Ortaya Konulması, 2015

[7] Özdemir, H. Taşkınların Tahmini ve Risk Analizinde CBS-Uzal ve Hidrolik Modellemenin Entegrasyonu, 2008.

[8] Mahnamfar, F., Moradi Y. A. & Ağralıoğlu, N. (2020). Flood Risk Analysis of Residential Areas at Downstream of the Elmali Dam. *Academic Platform Journal of Natural Hazards and Disaster Management*, 1(1), 49-58.

[9] Kates, R. W., Travis, W. R., & Wilbanks, T. J. (2005). Transformational adaptation when incremental adaptations to climate change are insufficient. *Proceedings of the National Academy of Sciences*, 102(9), 7465-7466.

[10] Mysiak, J., & Di Mauro, M. (2003). Integrated evaluation of floodplain management plans through multicriteria analysis. *Environmental Management*, 31(6), 792-803.

[11] Jankowski, P., & Richard, L. (1994). Integrating geographical information systems and multiple criteria decision-making methods. *International Journal of Geographical Information Systems*, 8(3), 221-239.

[12] Belton, V., & Stewart, T. J. (2002). Multiple criteria decision analysis: An integrated approach. Springer Science & Business Media.

[13] Saaty, T., 1980. The Analytic Hierarchy Process. McGrawHill, New York

[14] Keeney, R. L., & Raiffa, H. (1993). Decisions with multiple objectives: Preferences and value tradeoffs. Cambridge University Press.

[15] Zhang, Q., Zhao, G., & Zhang, X. (2018). Flood risk assessment under climate change using a Bayesian network with a Gaussian copula. *Journal of Hydrology*, 558, 267-279.

[16] Sahu, M., & Patil, S. (2020). Application of GIS-based multicriteria decision analysis for flood hazard mapping: A review. *Environmental Monitoring and Assessment*, 192, 224.

[17] Toprak, A. Günek, H. 2015 "Taşkın Çalışmalarında Çok Kriterli Karar Verme Analizinin Ve Hidrolojik Modelin Karşılaştırılması: Derme (Battalgazi Malatya) Deresi Havzası Örneği" *UJES 2015, IV. Ulusal Jeomorfoloji Sempozyumu, SAMSUN.*

[18] <https://urs.earthdata.nasa.gov>

[19] <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k=A&m=VAN>

[20] Özcan, O., Musaoğlu, N., ve Şeker, D. Z. (2009). "Taşkın Alanlarının Cbs ve Uzaktan Algılama Yardımıyla Belirlenmesi ve Risk Yönetimi; Sakarya Havzası Örneği". 12. Türkiye Harita Bilimsel ve Teknik Kurultayı, 11-15 Mayıs 2009, Ankara

[21] Tokgözlü, A., ve Özkan, E. (2018). "Taşkın risk haritalarında AHP yönteminin uygulanması: Aksu Çayı Havzası örneği". *Süleyman Demirel Üniversitesi Fen-Edebiyat Fakültesi Sosyal Bilimler Dergisi*, (44), 151-176.

[22] Kontos, T.D., Komilis, D.P. ve Halvadakis, C.P., 2005. Siting MSW landfills with a spatial multiple criteria analysis methodology. *Waste Management*, 25, 818– 832.

[23] Bhushan, N.& Rai, K. (2004). Strategic DecisionMaking: ApplyingtheAnalyticHierarchyProcess, London: SpringerPress.

- [24] Hafeez K., Malak N. ve Zhang Y. (2007), "Outsourcing Non-Core Assets and Competences of A Firm Using Analytic Hierarchy Process", *Computers and Operations Research*, 34(12): 3592-3608.
- [25] Donegan H.A., Dodd F.J. ve McMaster T.B.M. (1992), "A New Approach To AHP Decision Making", *The Statistician*, 41(3): 295-302.
- [26] Stain, W.E. ve Mizzi P.J. (2007), "The Harmonic Consistency Index For The Analytic Hierarchy Process", *European Journal of Operational Research*, 177(1): 488-497.
- [27] Zhou Y.-D. ve Shi M.-L. (2009), "Rail Transit Project Risk Evaluation Based on AHP Model", *Second International Conference on Information and Computing Science*, 3: 236-238.
- [28] Saaty T.L. ve Ozdemir, S.M. (2003), "Why The Magic Number Seven Plus or Minus Two", *Mathematical and Computer Modelling*, 38(3-4): 233-244.
- [29] Güngör İ. ve İşler D. B. (2005), "Analitik Hiyerarşi Yaklaşımı İle Otomobil Seçimi", *Zonguldak Karaelmas Üniversitesi Sosyal Bilimler Dergisi*, 1(2): 21-33.
- [30] Karagiannidis A., Papageorgiou A., Perkoulidis G., Sanida G. ve Samaras P. (2010), "A Multi-Criteria Assessment of Scenarios On Thermal Processing of Infectious Hospital Wastes: A Case Study For Central Macedonia", *Waste Management*, 30(2): 251-262.
- [31] Wang H.S., Che Z.H. ve Wu C. (2010), "Using Analytic Hierarchy Process and Particle Swarm Optimization Algorithm For Evaluating Product Plans", *Expert Systems with Applications*, 37(2): 1023-1034.
- [32] Hagos Y.G., Andualem T. G., Yibeltal M., Mengie M. A., 2022. Flood Hazard Assessment and Mapping Using GIS Integrated with Multi-Criteria Decision Analysis in Upper Awash River Basin, Ethiopia. *Applied Water Science* 12 (7), 148.
- [33] Dash, P., and Sar, J. (2020). "Identification And Validation of Potential Flood Hazard Area Using GIS-Based Multi-Criteria Analysis And Satellite Data-Derived Water Index". *Journal of Flood Risk Management*, 13(3), E12620.
- [34] Binici, F. & Aksoy, T. (2022). Şehirleşmenin Taşkın Üzerindeki Etkisi. *GSI Journals Serie C: Advancements in Information Sciences and Technologies (AIST)*, 5 (1): 64-76.
- [35] Dutta, M., Saha, S., Saikh, N.I., Sarkar, D., Mondal, P., 2023. Application of Bivariate Approaches for Flood Susceptibility Mapping: A District Level Study in Eastern India. *HydroResearch*, 6, 108-121.
- [36] Özşahin, E., ve Kaymaz, Ç. (2015). "Cbs Ve Ahs Kullanılarak Doğal Çevre Bileşenleri Açısından Kentsel Mekânın Yerleşime Uygunluk Analizine Bir Örnek: Antakya (Hatay)". *Doğu Coğrafya Dergisi*, 20(33), 111-134.
- [37] Sütüncü, H.S. , Yavuz, V.S. 2022 "Taşkın Risk Alanlarının Analitik Hiyerarşi Süreci Kullanılarak Mikro-Havza Ölçeğinde Değerlendirilmesi"
- [38] Bitek, D. 2023 "Edirne Oğulpaşa Deresi Havzasının Coğrafi Bilgi Sistemleri Yöntemleri Taşkın Risk Analizi"
- [39] Yurteri, C., (2024). Coğrafi Bilgi Sistemleri (Cbs) Ortamında Analitik Hiyerarşi Yöntemi (Ahy) Yöntemi Kullanılarak Taşkın Risk Analizi: Karabük İli Örneği, *Mühendislik Bilimleri ve Tasarım Dergisi*, 12(2), 298-318.



Geleneksel Yapılarda Kullanılan Kerpiç Malzemenin SEM-EDX Analizlerinin Değerlendirilmesi: Diyarbakır Karaçalı (Tilalo) Mahallesi'ndeki Güvercin Evleri (Boranhane) Örneği

Evaluation of SEM-EDX Analysis of Adobe Material Used in Traditional Buildings: The Example of Pigeon Houses (Boranhane) in Diyarbakır Karaçalı (Tilalo) Neighborhood

Berfin Aydınalp^{*}, Nursen Işık²

¹ berfinaydinalp12@gmail.com

ORCID: <https://orcid.org/0000-0001-9048-6451>

² Dicle Üniversitesi, Mimarlık Fakültesi, isiknc@gmail.com

ORCID: <https://orcid.org/0000-0002-6125-1896>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 20 Ağustos 2024
Revizyon 9 Aralık 2024
Kabul 15 Aralık 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

Boranhane, Diyarbakır, Güvercin Evleri, Karaçalı (Tilalo), Kerpiç, SEM- EDX

ÖZ

Dünyada, insanoğlu var oluşundan beri barınma ve beslenme gibi temel ihtiyaçlarını karşılamak için uygun yerler aramışlardır. Doğa olaylarından dolayı ve insanların konfor isteğinin artmasıyla birlikte barınma ihtiyaçları için daha elverişli mekanlara geçmişlerdir. Yerleşik hayata geçiş ile birlikte su ve toprak karışımı olan kerpiç malzemenin inşaat edilmiş yapılar kullanılmaya başlanmıştır. Anadolu'nun birçok bölgesinde kerpiç malzeme ile geleneksel konut ve hayvan barınakları inşa edilmiştir. Bu çalışmada, kapsamlı literatür araştırması yapılmıştır. Diyarbakır ilinin Karaçalı (Tilalo) Mahallesi'ndeki kerpiç malzemenin inşa edilen güvercin evlerinin(boranhane) mimari özellikleri, mevcut durumu ve yapısal sorunları ele alınmıştır. Günümüze ulaşan biri arkeolojik kalıntı şeklinde toplam yedi adet güvercin evinin (boranhane) bulunduğu bölgede alan çalışması yapılmıştır. Alan çalışmasında öncelikle güvercin evlerinin (boranhane) röleve projeleri çıkartılmıştır. Az, orta ve ağır hasarlı altı adet güvercin evlerinin(boranhane) mevcut durumları ve yapısal sorunları gözlemsel olarak tespit edilerek bu sorunlar ayrıntılı fotoğraflarla belgelenmiştir. Güvercin evlerinin (boranhane) inşasında kullanılan kerpiç malzemenin içeriğinin belirlenmesi amacıyla altı adet güvercin evlerinden(boranhane) deneysel çalışmada kullanılmak üzere toplam sekiz adet kerpiç numune alınmıştır. Alınan numuneler üzerinde DÜBTAM laboratuvarında SEM-EDX analizleri yapılmıştır. Diyarbakır kent tarihinde, kültürel ve mimari miras olarak kabul edilen güvercin evlerinde (boranhane) yapı malzemesi olarak kullanılan kerpiçin içerik analizi deneysel çalışmalarla belirlenmiştir. Deneysel çalışmalar sonucunda içeriği belirlenen kerpiç malzemenin, güvercin evlerine (boranhane) yönelik yapılacak onarım ve restorasyon çalışmaları için güncel bir rehber olması hedeflenmiştir. Güvercin evlerinin (boranhane) korunarak gelecek nesillere aktarılması ve bu yöndeki akademik çalışmaların yaygınlaştırılması önemli ve gereklidir. Bu bağlamda, yapılan çalışmanın güvercin evleri (boranhane) kültürlerinin yaşatılması, mimaride sürdürülebilirlik özelliği kazandırılması bakımından katkı sağlayacağı düşünülmektedir.

ARTICLE INFO

Article history:

Received 20 August 2024
Received in revised form 9 December 2024
Accepted 15 December 2024
Available online 23 December 2024

Keywords:

Boranhane, Diyarbakır, Pigeon Houses, Karaçalı (Tilalo), Adobe, SEM- EDX

Doi: 10.24012/dumf.1535958

* Sorumlu Yazar

ABSTRACT

In the world, human beings have been looking for suitable places to meet their basic needs such as shelter and nutrition since their existence. Due to natural events and with the increase in people's desire for comfort, they have moved to more favorable places for their shelter needs. With the transition to settled life, structures built of adobe material, which is a mixture of water and soil, began to be used. In many regions of Anatolia, traditional houses and animal shelters were built with adobe material. In this study, a comprehensive literature research was conducted. The architectural features, current status and structural problems of the pigeon houses (boranhane) built of adobe material in Karaçalı (Tilalo) Neighborhood of Diyarbakır province are discussed. A field study was conducted in the region where there are a total of seven pigeon houses (boranhane), one of which is an archaeological relic. In the field study, first of all, the survey projects of the pigeon houses (boranhane) were prepared. The current conditions and structural problems of six pigeon houses (boranhane) with minor, moderate and severe damage were determined observationally and these problems were documented with detailed photographs. In order to determine the content of adobe material used in the construction of the pigeon houses (boranhane), a total of eight adobe samples were taken from six pigeon houses (boranhane) to be used in the experimental study. SEM-EDX analyses were performed on the samples in the laboratory of DUBTAM. The content analysis of the adobe used as building material in the pigeon houses (boranhane), which are accepted as cultural and architectural heritage in Diyarbakır city history, was determined by experimental studies. It is aimed that the adobe material, whose content was determined as a result of the experimental studies, will be an up-to-date guide for the repair and restoration works to be carried out for the pigeon houses (boranhane). It is important and necessary to preserve pigeon houses (boranhane) and transfer them to future generations and to expand academic studies in this direction. In this context, it is thought that the study will contribute to the preservation of the culture of pigeon houses (boranhane) and to provide sustainability in architecture.

Giriş

İnsanoğlu tüm tarih boyunca iklim koşullarından, çevresel faktörlerden ve doğa olaylarından korunmak amacıyla sürekli mekân arayışı içerisinde olmuşlardır [1]. İlk yaşadığı mekanlar ise mağara ve ağaç kovukları olmuştur [2]. Zaman içerisinde insanlar yerleşik hayata geçerek toprak yapılar inşa etmeye başlamışlardır. Yerleşik hayatla birlikte bazı hayvan türlerini de evcilleştirmeye başlayan insanlar onları da korumak için toprak esaslı kerpiçten hayvan barınakları inşa etmişlerdir.

Eski tarihlere bakıldığında zaman Anadolu'da da çok amaçlı kullanım için kerpiç yapılar görülmüştür. İnsanlar için konut, büyükbaş hayvanlar için ahır, küçükbaş hayvanlar için kümes ve güvercinler için ise güvercin evleri inşa edilmiştir.


Türkiye'nin birçok bölgesine inşa edilen bu barınaklar bölgelere göre yöresel, kültür ve gelenek olarak mimari ve malzeme açısından farklılıklar göstermektedir. Selçuklu Döneminde çift başlı kuş tasvirleri iradenin gücünü ve egemenliğini ifade etmiştir [3]. İslamiyet'in kabulünden sonra kuş tasvirlerinin çoğu alanlarda kullanılması kuşlara verilen önem ve değeri göstermiştir. Serçe, kırlangıç, kumru, güvercin ve leylek gibi birçok kuş türü, kutsal bölgelere seyahat edip döndükleri için kutsal olarak kabul edilmiştir [4]- [5].

Osmanlı Döneminde kuşlar için inşa edilen barınaklar güvercinlikler ve kuş evleri olarak iki ayrı işlevde yapılmıştır. Güvercin evleri kuşların gübrelerinden yararlanmak için yapılmasına rağmen kuş evleri sadece barınmaları amacıyla yapılmıştır [5]. Günümüzde Türkiye'de güvercin evleri çok az sayıda kalmış ve bu amaçla yeni yapılar inşa edilmemiş, mevcut yapılar doğa koşulları ve bakımsızlık, terk nedeniyle yok olma sürecine girmiştir.

Diyarbakır ilinin kırsal bölgelerinde de, güvercin gübrelerinin tarımda kullanılması amacıyla güvercin evleri (boranhane) inşa edilmiştir [6]. Zaman içerisinde suni gübrenin artışı ile birlikte güvercin evlerinin (boranhane) kullanımı azalmaya başlamıştır. Kullanılmayan güvercin evlerinin (boranhane) bazıları günümüze ulaşamamış, bazıları kısmi ya da ağır hasarlı olarak ulaşmıştır. Güvercin evlerinin (boranhane) sınırlı sayıda günümüze ulaşarak aktif olarak kullanılmaktadır.

Bu çalışma, Diyarbakır ilinin Karaçalı (Tilalo) Mahallesi'ndeki güvercin evlerinin (boranhane) mimari özelliklerini kapsamaktadır. Diyarbakır ili Karaçalı (Tilalo) Mahallesi alınarak çalışma alanı sınırlandırılmıştır (Şekil 1). Kapsamlı literatür araştırması yapılarak alan çalışmasındaki güvercin evlerinin (boranhane) rölöve projeleri çıkartılmış olup

güvercin evlerinin (boranhane) nem, yağmur, sıcaklık değişimi, deprem, bakımsızlık ve hatalı tasarım gibi etkenlerden dolayı zaman içerisinde oluşan hasarlar görsel olarak ele alınmıştır. Altı tane kuş evlerinden (boranhane) alınan sekiz adet numuneler DÜBTAM laboratuvarında taramalı elektron mikroskopu (SEM) ve enerji dağılımlı X-ışını spektroskopisi (EDX) deneyleri yapılmış olup veriler elde edilmiştir. Elde edilen veriler değerlendirilmiştir. Makalenin amacı, Diyarbakır Karaçalı (Tilalo) Mahallesi'ndeki güvercin evlerinin (Boranhane) mevcut hasar sorunları tespit edilip, elde edilen deneysel veriler ile birlikte restorasyon sürecine gidilmesi ve özgün yapım sistemi ile inşalarının yapılmasıdır. İncelenen yapı hasarları doğrultusunda güvercin evlerinin (boranhane) korunmasına yönelik öneriler sunulmuştur. Ayrıca, halk tarafından bölgeye özgü yapım sistemi ile inşa edilen bu güvercin evleri (boranhane), kültürel miras açısından büyük önem taşımakta olup gelecek nesillere aktarılması büyük önem taşımaktadır.



Şekil 1. Diyarbakır, Karaçalı (Tilalo) Mahallesi'ndeki güvercin evlerinin (boranhane) yerleşim düzeni (2024)

Materyal ve Metod

Karaçalı (Tilalo) Mahallesi'ndeki Borahanelerin Yapısal Sorunların Gözlemsel Olarak Tespiti

Kerpiç yapılar, kerpiç malzemenin gözenekli olması ve suya dayanıklılığının az olması nedeniyle zaman içinde bozulmaya uğramaktadır. Bu bozulmalar, sıcaklık değişimleri, rüzgâr, yağmur şiddeti ve yoğunluğu, kar yağışları, don olayları gibi birçok iklim değişiklikleri ve depremler gibi etkenlere bağlı olarak artarak yapısal sorunlara neden olmaktadır. Kerpiç yapılarıdaki bozulmalara, belirli aralıklarla bakım yapılması gerekmektedir. Bu bakımların yapılmaması sonucu yapılarda hasarlar oluşmaktadır.

Kerpiç malzemesi fazla gözenekli yapıya sahip olmasından kaynaklı diğer bazı yapı malzemelerine göre daha fazla nemi içinde tutabilirler [8]. Su ve nem gibi doğal faktörler özellikle kerpiç yapılarda daha fazla sorunlara ve hasarlara yol açmaktadır. Yapıların temeli için yağmur suyuna karşı doğru uygulamalar yapılmadığı zaman özellikle toprak esaslı yapıların alt kısımlarında hasarlar oluşmaktadır [7]. Yağmurun yoğun olması ve rüzgârın etkisi ile yapıya sert darbelerle dik veya açılı şekilde çarparak temas etmesi sonucu kerpiç yapılarda aşınmalar meydana gelmektedir. [2]. Cephede ve üst örtüde yağmur ve kar sularının etkisiyle nem miktarı artarak yapı duvarlarında yumuşama, çatlama ve parçalanmaya bağlı bozulmalar oluşmaktadır. Kerpiç yapılardaki nem ve suyun tahliyesinin sağlandığı saçak ve çevresel drenajların bulunmaması bozulmalar ile bozulmalara bağlı yapısal sorunların artmasına yol açmaktadır [2].

Sıcaklık değişimleri sonucu kerpiç yapılarda büzülme ve genişleme olayları gerçekleşmektedir. Yapının iç yapısında gerilmeler oluşarak yapı duvarlarında çatlaklar ve yapı elemanlarında (pencere ve kapı gibi) hasarlar meydana gelmektedir [9]. Ek olarak her yağış ve sıcaklık artışı sonucu yapı duvarlarında düzensiz çatlaklar oluşumu gözlenir [7].

Kerpiç yapılarda zaman içerisinde su ve nemden kaynaklı bitki oluşumları görülmektedir. Bitki oluşumları sonucu yapılarda çatlaklar meydana gelmektedir. Bu bitki oluşumları(çiçeklenme) yağmur veya kar suyu teması ile daha fazla gürleşerek hasar oranını arttırmaktadır. Ek olarak, bitki oluşumları(çiçeklenme) ile birlikte bazı kemirici hayvanlar kerpiç duvarlarda oyuk veya delik gibi hasarlara neden olmaktadır [9].

Kerpiç yapılardaki duvar kalınlıklarının fazla olması ve üst örtülerin ahşap kirişle desteklenen toprak dam ile kaplanması, yapıların kütlece ağır yapmakta olup, bu durum deprem etkisi açısından olumsuz yönde etkilemektedir [7]- [9].

Diyarbakır Karaçalı (Tilalo) Mahallesi'nde bulunan güvercin evleri (boranhane) genellikle bakımsızlık, terk nedeniyle yapısal sorunları bulunan hasarlı bir şekilde günümüze ulaşmıştır. 7 adet güvercin evinden (boranhane) bir tanesi tümüyle yıkılmış arkeolojik kalıntı şeklindedir (Şekil 2).



Şekil 2. Güvercin evlerinin (boranhane) genel görünümü

1 numaralı güvercin evi (boranhane) dışında kalan diğer beş adet güvercin evinin üst örtüleri tümüyle yıkılmıştır. 1 no'lu güvercin evi sahipleri tarafından nitelsiz malzeme ve tekniklerle kapatılmış olup, diğer güvercin evlerine göre doğa koşullarına karşı daha korunaklı hale gelmiştir. Güvercin evlerinde (boranhane) bakımsızlık, terk, doğa koşulları ve deprem etkisi sonucu oluşan hasarlar ve hasarlara bağlı olarak yapısal sorunlar meydana gelmiştir.

Nem Etkisiyle Oluşan Hasarlar

Alan çalışmasında gözlemlenen güvercin evlerinde (boranhane) doğa koşulları (yağmur ve kar) sonucu nem kaynaklı, yapılardaki duvarların alt ve üst kısımlarda kerpiç malzemede kayıplar olduğu görülmüştür. Yapıların cephelerinde aşınmalar meydana gelerek pürüzlü yüzeyler oluşmuştur.

Üst örtüsü yıkılan yapının üst duvarlarında kısmi kayıplar mevcuttur. Nemden kaynaklı aşınma sonucu kerpiç malzemede samanlar ortaya çıkmıştır. Ayrıca, dış cephe duvarının alt kısımlarda parça kopmalarına bağlı malzeme kayıpları olduğu görülmektedir (Şekil 3).



Şekil 3. 2 numaralı güvercin evinde(boranhane) meydana gelen nem hasarları

Üst örtüsü yıkılan yapının duvarlarında çatlak ve ayrışma hasarları bulunmaktadır. Boranhane de drenaj borusu ve saçak elemanlarının bulunmaması ve dış ortam koşulları nedeniyle yapının alt kısımlarında ve duvarlar ile payandalarda parça kopmalarına bağlı malzeme kayıpları ile ve aşınmalar meydana gelmiştir. Ayrıca, aşınma sonucu yüzey düzgünlüğü bozulmuştur (Şekil 4).



Şekil 4. 3 numaralı güvercin evinde(boranhane) meydana gelen nem hasarları

Üst örtünün eksikliğine bağlı dış ortam koşullarına maruz kalan yapıda, su ve neme bağlı dış cephe duvarının alt kısmında aşınma ve parça kopması meydana gelmiştir. Bu kayıplarla kerpiç malzemede saman ve diğer malzemelerde bozulmalar görülmektedir (Şekil 5).



Şekil 5. 4 numaralı güvercin evinde (boranhane) meydana gelen nem hasarları

Üst örtüsü yıkılan yapının duvarlarının üst ve alt kısımlarında nem kaynaklı bozulmalara bağlı malzeme kayıpları bulunmaktadır. Yapı elemanları saçak ve yağmur tahliye borularının olmaması nedeniyle, yapının iç kısmı olup duvarın alt kısımlarında yine aşınmalar ve parça kayıpları Ayrıca duvarlarda neme bağlı şişmeler olduğu görülmektedir (Şekil 6).



Şekil 6. 5 numaralı güvercin evinde (boranhane) meydana gelen nem hasarları

Üst örtüsünün yıkıldığı yapının iç ve dış duvarlarının alt kısımlarında aşınma, parça kopmaları ve kayıplar ile neme bağlı bozulmalar bulunmaktadır (Şekil 7).



Şekil 7. 6 numaralı güvercin evinde (boranhane) meydana gelen nem hasarları

Bitki Oluşumlarına Bağlı Oluşan Hasarlar

Bitki oluşumları, kerpiç yapıya zarar veren su ve nem etkisiyle oluşan bozulmalardır. Güvercin evlerinin üst örtülerinin yıkılması ve dış ortam koşullarına karşı korunaksız olmalarına yol açmıştır. Doğal bir malzeme olan kerpiğin bünyesindeki tuzun sıcaklık etkisiyle yok olması zamanla duvarlarda bitki oluşumlarına neden olmuştur. Bitki oluşumlarının mevcut olduğu alanlarda malzeme kaybına bağlı boşalmalar ve ayrışmalara bağlı hasarlar ve yapısal sorunlar meydana gelmiştir. Bu durum Karaçalı (Tilalo) Mahallesi'ndeki tüm kerpiç yapılarda bulunmaktadır (Şekil 8).



2 no'lu güvercin evi (boranhane)



3 no'lu güvercin evi (boranhane) 4 no'lu güvercin evi (boranhane)



5 no'lu güvercin evi (boranhane)



6 no'lu güvercin evi (boranhane)

Şekil 8. Güvercin evlerinde (boranhane) meydana gelen bitki oluşumları

Bakımsızlık ve Terk Nedeniyle Oluşan Hasarlar

Güvercin evleri (boranhane), güvercin besleme geleneğinin sürdürüldüğü, güvercin gübrelere toplandığı ve tarımda kullanıldığı kerpiç malzemeden yapılan geleneksel kuş evleridir. Zaman içinde, suni gübrelere yaygınlaşması ve köyden kente göç vb. gibi birçok nedenlerle, güvercin evleri (boranhane) kullanılmamıştır. Güvercin evlerine bakımlar ve onarımlar yapılmamış ve terk edilmiştir. Bakımsızlık ve terk bu yapıların doğa koşulları etkisine bağlı bozulma ve hasarlarının artmasına neden olmuştur. Karaçalı (Tilalo) Mahallesi'ndeki güvercin evlerinin (boranhane) sadece bir tanesinin üst örtüsü yenilenmiş diğer beş adet güvercin evinin üst örtüsü yıkılmış ve yenilenmemiştir. (Şekil 9).



2 no'lu güvercin evi (boranhane) 3 no'lu güvercin evi (boranhane)



4 no'lu güvercin evi (boranhane) 5 no'lu güvercin evi (boranhane)



6 no'lu güvercin evi (boranhane)

Şekil 9. Bakımsızlık ve terk sonucu üst örtüsü yıkılan güvercin evleri (boranhane)

Deprem Etkisiyle Oluşan Hasarlar

Deprem yapıların taşıyıcı sistemini etkileyen en önemli doğal afetlerden biridir. Bu nedenle bozulmalara uğramış ve yapısal sorunları bulunan yapılarda deprem etkisi mevcut hasarları arttırabilmektedir. Karaçalı (Tilalo) Mahallesi'nde yer alan yapısal bozulmalar ile hasarları

olan güvercin evlerinde (boranhane) 6 Şubat 2023 tarihinde meydana gelen Kahramanmaraş depremi etkisine bağlı yapısal sorunların arttığı görülmüştür. Özellikle duvarlarda strüktürel çatlaklar, ayrışma hasarları ve yıkılmalar meydana gelmiş, yapıların mevcut strüktürleri bozulmuştur (Şekil 10).



1 no'lu güvercin evi(boranhane)



2 no'lu güvercin evi(boranhane)

3 no'lu güvercin evi(boranhane)



4 no'lu güvercin evi(boranhane)

5 no'lu güvercin evi(boranhane)



6 no'lu güvercin evi(boranhane)

Şekil 10. Güvercin evlerinde (boranhane)deprem etkisiyle oluşan strüktürel çatlaklar ve ayrışmalar

Sonuç olarak; gözlemsel tespit sonucu 2010 ve 2024 yıllarına ait mevcut olan güvercin evlerinin(boranhane) yapısal hasarları görülmektedir (Şekil 11). Suni gübre atışı ile yapıların terk edilmesi sonucu yapılarda bakımsızlıktan dolayı hasarlar meydana gelmiştir. Ek olarak, sıcaklık etkisi kerpiçin bünyesindeki tuzun yok olması, yapım sistemlerinin yanlış uygulanması ve saçak ile çevresel drenaj eksikliği nedeniyle su ve nemden kaynaklı yüzey bozukluğu, yüzeysel kılcal çatlaklar, parça ve kerpiç blok kayıpları ve bitki oluşumları gibi hasarlar olmuştur. 6 Şubat 2023 Kahramanmaraş depremi sonrası güvercin evlerinde(boranhane) yapısal çatlaklar ve parça parça kerpiç duvar kayıpları meydana gelmiştir. Meydana gelen hasarlar 2024 yılında çekilen resimlerde görülmektedir.



2010 yılındaki güvercin evleri

2024 yılındaki güvercin evleri


Şekil 11. 2010 ve 2024 yılında güvercin evleri(boranhane)

Karacalı (Tilalo) Mahallesi'ndeki Güvercin Evlerinde (Boranhane) Meydana Gelen Yapısal Sorunların Deneysel Olarak İncelenmesi

Güvercin evlerinden(boranhane) alınan sekiz adet numune çift taraflı bant yardımıyla her bir numuneden ayrı ayrı küçük parçalar alınarak sırası ile "QUANTA FEG 250" makinesine yerleştirilmiştir. Cihaza yerleştirilen numuneler ile yüksek enerjili elektronlar etkileşerek foton ve elektron sinyalleri oluşturmuştur. Farklı açılarla saçılan elektronlar dedektör (algılayıcı) tarafından toplanmıştır. Toplanmış olan sinyaller ise mikroskop yazılımı ile işlenerek, alınan numunelerden görüntüler elde edilmiştir [12].

SEM-EDX Deney Yöntemi ve Kullanılan Cihazlar

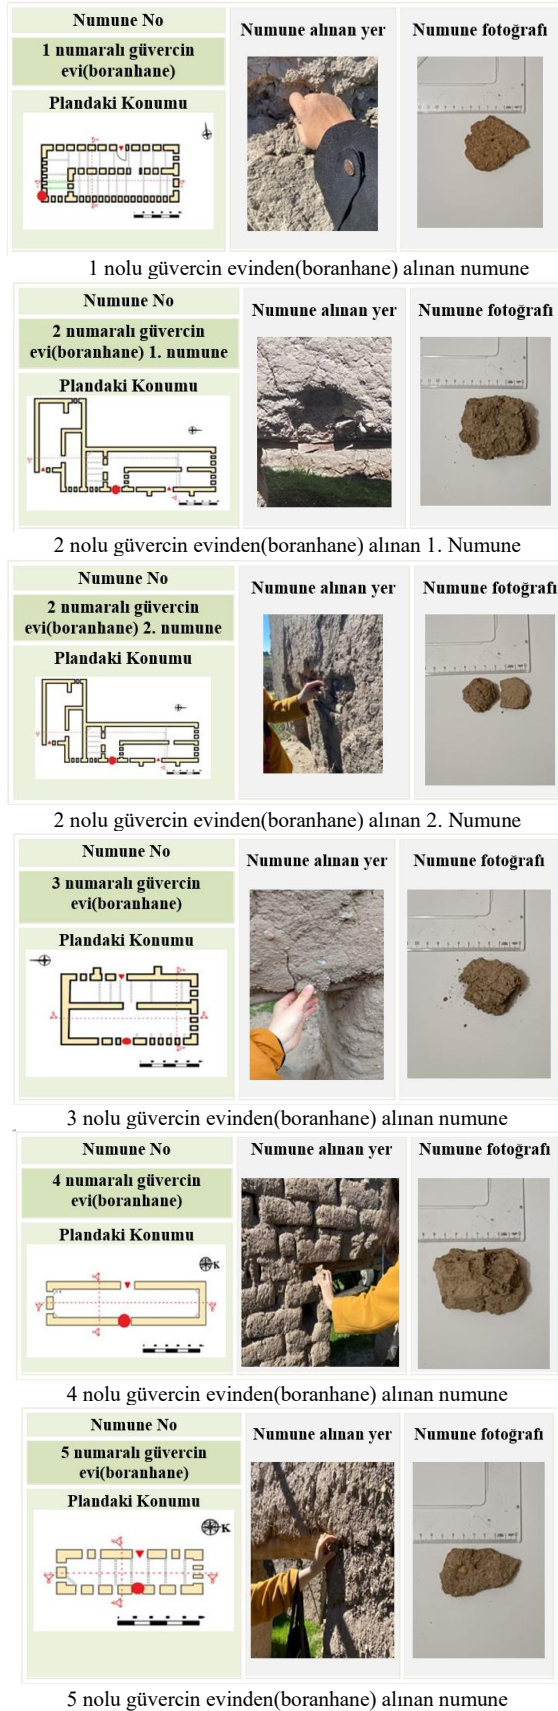
Taramalı elektron mikroskobu, odaklanmış elektron demeti numune yüzeyini tarayarak görüntüler elde eden bir elektron mikroskop türüdür. Elektronlar numunedeki atomlar ile etkileşerek numune yüzeyindeki topografi ve kompozisyon hakkında bilgiler içeren farklı sinyaller üretir. Bu sinyaller dedektörler tarafından toplanarak bilgisayar ekranına aktarılıp görüntüler elde edilir [10]. EDX analizi ise numunenin elementel bileşimlerini elde etmek için kullanılır [11] (Şekil 12).



Şekil 12. SEM-EDX deneyi için kullanılan Quanta Feg 250 makinesi (2024)

Numunelerin Elde Edilmesi ve Hazırlanması

Diyarbakır ilinin Karacalı(Tilalo) Mahallesi'nde alan çalışması yapılarak biri arkeolojik kalıntı olan yedi adet güvercin evlerinin(boranhane) duvarlarından sekiz adet numune alınmıştır. Numunelerin plandaki yeri, alınan yeri ve numune fotoğrafları gösterilmiştir(Şekil 13).




Şekil 13. SEM-EDX deneyi için hazırlanan numuneler (2024)

Numuneler Üzerinde Yapılan SEM-EDX Deneylerinin Yapılması

Alan çalışmasından biri arkeolojik kalıntıdan alınan sekiz adet numune çift taraflı bant yardımı ile küçük parçalar alınmıştır. Sonrasında SEM-EDX cihazına yerleştirilen numuneler taramalı elektron mikroskobu(SEM) ile yüzeylerin morfolojisine hakkında bilgi edinilmiştir. Ayrıca numunenin belirli boyutlarda görüntüleri bu cihaz ile elde edilmiştir. Enerji dağılımlı X-ışını spektroskopisi(EDX) ile numuneler içerisindeki hangi elementlerin olduğu ve mevcut elementlerin yüzdeleri hakkında bilgiler elde edilmiştir. Deneyler sonucu elde edilen bilgiler SEM görüntüleri, EDX grafiği ve elementlerin yüzdeleri tablo şeklinde verilmiştir[13]-[16].

1 Numaralı Güvercin Evi (Boranhane) SEM-EDX Analizi


Çift taraflı bantla alınan numune örneği taramalı elektron mikroskobu (SEM) ile 500x-1000x-5000x görüntüleri alınmıştır (Şekil 14). Alınan SEM görüntüleri sonucu yüzeyin gözenekli, düzensiz ve homojen yapıda olmadığı tespit edilmiştir [14]. Enerji dağılımlı X-ışını spektroskopisi(EDX) ile yapılan deney sonucu alınan numunede oksijen (O), magnezyum (Mg), alüminyum (Al), silisyum (Si), potasyum (K), kalsiyum (Ca) ve demir (Fe) elementlerine rastlanılmıştır[17]. Deney sonucu; oksijen miktarı %53.50, magnezyum %1.78, alüminyum %7.27, silisyum %23.16, potasyum %1.73, kalsiyum %7.39 ve demir %5.18 değerlere sahiptir (Tablo 1) [18]. Numunede en yüksek değere sahip olan element oksijen olup, en az değere sahip olan element ise potasyum olarak ölçülmüştür (Şekil 15). SEM görüntüsünde numunenin gözenekli yapıya sahip olmasının nedeni hapsolmuş havadan kaynaklı olduğu görülmektedir. Ayrıca, potasyum (K) ve magnezyum (Mg) yüzdeleri düşük olması, kerpiç harcına eklenen atıklar ve katkı maddelerinden dolayı olması olasıdır[19].



Şekil 14. 1 numaralı güvercin evinin(boranhane) numunesine ait 500x-1000x-5000x SEM görüntüleri

Tablo 1. 1 numaralı güvercin evinin(boranhane)numunesine ait EDX element yüzdeleri


EDX	Element Türleri						
	O K	Mg K	AlK	Si K	K K	Ca K	FeK
%	53.5	1.78	7.27	23.16	1.73	7.39	5.18



Şekil 15. 1 numaralı güvercin evinin(boranhane) numunesine ait EDX grafiği

2 Numaralı Güvercin Evi (Boranhane) SEM-EDX Analizi


Çift taraflı bantla alınan 1. numune örneği taramalı elektron mikroskopu(SEM) ile 500x-1000x-5000x görüntüleri alınmıştır(Şekil 16) [13]. Alınan SEM görüntüleri sonucu yüzeyin gözenekli, düzensiz ve homojen yapıda olmadığı tespit edilmiştir. Enerji dağılımlı X-ışını spektroskopisi(EDX) ile yapılan deney sonucu alınan numunede oksijen(O), magnezyum(Mg), alüminyum(Al), silisyum(Si), fosfor(P), potasyum(K), kalsiyum(Ca) ve demir(Fe) elementlerine rastlanılmıştır. Deney sonucu; oksijen miktarı %53.07, magnezyum %2.01, alüminyum %6.24, silisyum %21.52, fosfor %1.34, potasyum %1.88, kalsiyum %9.95 ve demir %3.99 değerlere sahiptir (Tablo 2). Numunede en yüksek değere sahip olan element oksijen olup, en az değere sahip olan element ise fosfor olarak ölçülmüştür (Şekil 17). Ayrıca, 1 numaralı güvercin evinden(boranhane) ek olarak fosfor elementine de rastlanılmıştır. SEM görüntüsünde numunenin gözenekli yapıya sahip olmasının nedeni hapsolmuş havadan kaynaklı olduğu görülmektedir. Ayrıca, potasyum(K) ve magnezyum(Mg) yüzdelik değerlerinin düşük olması, kerpiç harcına eklenen atıklar ve katkı maddelerinden dolayı olması olasıdır[18]- [19].



Şekil 16. 2 numaralı güvercin evi(boranhane) 1. numunesine ait 500x-1000x-5000x SEM görüntüleri

Tablo 2. 2 numaralı güvercin evinin(boranhane) 1. numunesine ait EDX element yüzdeleri


EDX	Element Türleri							
	OK	MgK	AlK	Si K	PK	KK	CaK	FeK
%	53.07	2.01	6.24	21.52	1.34	1.88	9.95	3.99



Şekil 17. 2 numaralı güvercin evinin(boranhane) 1.numunesine ait EDX grafiği

2 Numaralı Güvercin Evi (Boranhane) SEM-EDX Analizi


Çift taraflı bantla alınan 2. numune örneği taramalı elektron mikroskopu(SEM) ile 500x-1000x-5000x görüntüleri alınmıştır [15]. Alınan SEM görüntüleri sonucu yüzeyin gözenekli, düzensiz ve homojen yapıda olmadığı tespit edilmiştir (Şekil 18). Enerji dağılımlı X-ışını spektroskopisi(EDX) ile yapılan deney sonucu alınan numunede oksijen(O), magnezyum(Mg), alüminyum(Al), silisyum(Si), fosfor(P), potasyum(K), kalsiyum(Ca) ve demir(Fe) elementlerine rastlanılmıştır. Deney sonucu; oksijen miktarı %53.75, magnezyum %2.17, alüminyum %7.37, silisyum %24.39, fosfor %1.07, potasyum %1.52, kalsiyum %6.22 ve demir %3.51 değerlere sahiptir (Tablo 3). Numunede en yüksek değere sahip olan element oksijen olup, en az değere sahip olan element ise fosfor olarak ölçülmüştür (Şekil 19)[16].Ayrıca, 1 numaralı güvercin evinden(boranhane) ek olarak fosfor elementine de rastlanılmıştır.SEM görüntüsünde numunenin gözenekli yapıya sahip olmasının nedeni hapsolmuş havadan kaynaklı olduğu görülmektedir. Ayrıca, potasyum(K) ve magnezyum(Mg) yüzdelik değerlerinin düşük olması, kerpiç harcına eklenen atıklar ve katkı maddelerinden dolayı olması olasıdır[17] -[19].



Şekil 18. 2 numaralı güvercin evi(boranhane) 2. numunesine ait 500x-1000x-5000x SEM görüntüleri

Tablo 3. 2 numaralı güvercin evinin(boranhane) 2. numunesine ait EDX element yüzdeleri


EDX	Element Türleri							
	O K	MgK	AlK	Si K	PK	KK	CaK	FeK
%	53.75	2.17	7.37	24.39	1.07	1.52	6.22	3.51



Şekil 19. 2 numaralı güvercin evinin(boranhane) 2.numunesine ait EDX grafiği

3 Numaralı Güvercin Evi (Boranhane) SEM-EDX Analizi


Çift taraflı bantla alınan numune örneği taramalı elektron mikroskopi (SEM) ile 500x-1000x-5000x görüntüleri alınmıştır (Şekil 20). Alınan SEM görüntüleri sonucu yüzeyin gözenekli, düzensiz ve homojen yapıda olmadığı tespit edilmiştir. Enerji dağılımlı X-ışını spektroskopisi (EDX) ile yapılan deney sonucu alınan numunede oksijen (O), magnezyum (Mg), alüminyum (Al), silisyum (Si), potasyum (K), kalsiyum (Ca) ve demir (Fe) elementlerine rastlanılmıştır. Deney sonucu; oksijen miktarı %49.71, magnezyum %1.76, alüminyum %14.36, silisyum %23.40, potasyum %6.00, kalsiyum %2.31 ve demir %2.46 değerlere sahiptir (Tablo 4) [19]. Numunede en yüksek değere sahip olan element oksijen olup, en az değere sahip olan element ise magnezyum olarak ölçülmüştür (Şekil 21). SEM görüntüsünde numunenin gözenekli yapıya sahip olmasının nedeni hapsolmuş havadan kaynaklı olduğu görülmektedir. Ayrıca, potasyum (K) ve magnezyum (Mg) yüzdelik değerlerinin düşük olması, kerpiç harcına eklenen atıklar ve katkı maddelerinden dolayı olması olasıdır [14]- [15].



Şekil 20. 3 numaralı güvercin evinin(boranhane) numunesine ait 500x-1000x-5000x SEM görüntüleri

Tablo 4. 3 numaralı güvercin evinin(boranhane) numunesine ait EDX element yüzdeleri


EDX	Element Türleri						
	O K	MgK	Al K	Si K	KK	Ca K	FeK
%	49.71	1.76	14.36	23.40	6.00	2.31	2.46



Şekil 21. 3 numaralı güvercin evinin(boranhane)numunesine ait EDX grafiği

4 Numaralı Güvercin Evi (Boranhane) SEM-EDX Analizi


Çift taraflı bantla alınan numune örneği taramalı elektron mikroskopi (SEM) ile 500x-1000x-2500x görüntüleri alınmıştır (Şekil 22). Alınan SEM görüntüleri sonucu yüzeyin gözenekli, düzensiz ve homojen yapıda olmadığı tespit edilmiştir. Enerji dağılımlı X-ışını spektroskopisi (EDX) ile yapılan deney sonucu alınan numunede oksijen (O), magnezyum (Mg), alüminyum (Al), silisyum (Si), potasyum (K), kalsiyum (Ca) ve demir (Fe) elementlerine rastlanılmıştır. Deney sonucu; oksijen miktarı %54.32, magnezyum %2.14, alüminyum %6.98, silisyum %25.94, potasyum %1.56, kalsiyum %4.61 ve demir %4.46 değerlere sahiptir (Tablo 5) [13]- [16]. Numunede en yüksek değere sahip olan element oksijen olup, en az değere sahip olan element ise potasyum olarak ölçülmüştür (Şekil 23). SEM görüntüsünde numunenin gözenekli yapıya sahip olmasının nedeni hapsolmuş havadan kaynaklı olduğu görülmektedir. Ayrıca, potasyum (K) ve magnezyum (Mg) yüzdelik değerlerinin düşük olması, kerpiç harcına eklenen atıklar ve katkı maddelerinden dolayı olması olasıdır [13]-[19].



Şekil 22. 4 numaralı güvercin evinin(boranhane) numunesine ait 500x-1000x-2500x SEM görüntüleri

Tablo 5. 4 numaralı güvercin evinin(boranhane) numunesine ait EDX element yüzdeleri


EDX	Element Türleri						
	O K	MgK	AlK	Si K	KK	Ca K	FeK
%	54.32	2.14	6.98	25.94	1.56	4.61	4.46



Şekil 23. 4 numaralı güvercin evinin(boranhane) numunesine ait EDX grafiği

5 Numaralı Güvercin Evi (Boranhane) SEM-EDX Analizi


Çift taraflı bantla alınan numune örneği taramalı elektron mikroskobu(SEM) ile 500x-1000x-5000x görüntüleri alınmıştır(Şekil 24). Alınan SEM görüntüleri sonucu yüzeyin gözenekli, düzensiz ve homojen yapıda olmadığı tespit edilmiştir [15]- [16]. Enerji dağılımlı X-ışını spektroskopisi (EDX) ile yapılan deney sonucu alınan numunede karbon (C), oksijen (O), magnezyum (Mg), alüminyum (Al), silisyum (Si), potasyum (K), kalsiyum (Ca) ve demir (Fe) elementlerine rastlanılmıştır. Deney sonucu; karbon miktarı %16.60, oksijen miktarı %52.66, magnezyum %1.64, alüminyum %4.87, silisyum %16.61, potasyum %1.17, kalsiyum %4.20 ve demir %2.25 değerlere sahiptir (Tablo 6). Numunede en yüksek değere sahip olan element oksijen olup, en az değere sahip olan element ise potasyum olarak ölçülmüştür (Şekil 25). Ayrıca, diğer güvercin evlerinden(boranhane) alınan numunelerden ek olarak karbon elementine rastlanılmıştır. SEM görüntüsünde numunenin gözenekli yapıya sahip olmasının nedeni hapsolmuş havadan kaynaklı olduğu görülmektedir. Ayrıca, potasyum (K) ve magnezyum (Mg) yüzdelik değerlerinin düşük olması, kerpiç harcına eklenen atıklar ve katkı maddelerinden dolayı olması olasıdır [17]- [18].



Şekil 24. 5 numaralı güvercin evinin(boranhane) numunesine ait 500x-1000x-5000x SEM görüntüleri

Tablo 6. 5 numaralı güvercin evinin(boranhane) numunesine ait EDX element yüzdeleri

EDX	Element Türleri							
	C K	O K	MgK	AlK	Si K	KK	CaK	FeK
%	16.60	52.66	1.64	4.87	16.61	1.17	4.20	2.25




Şekil 25. 5 numaralı güvercin evinin(boranhane) numunesine ait EDX grafiği

6 Numaralı Güvercin Evi (Boranhane) SEM-EDX Analizi

Çift taraflı bantla alınan numune örneği taramalı elektron mikroskobu (SEM) ile 500x-1000x-5000x görüntüleri alınmıştır (Şekil 26). Alınan SEM görüntüleri sonucu yüzeyin gözenekli, düzensiz ve homojen yapıda olmadığı


tespit edilmiştir [13]- [18]. Enerji dağılımlı X-ışını spektroskopisi (EDX) ile yapılan deney sonucu alınan numunede oksijen (O), magnezyum (Mg),alüminyum (Al), silisyum (Si), potasyum (K), kalsiyum (Ca) ve demir (Fe) elementlerine rastlanılmıştır. Deney sonucu; oksijen miktarı %58.54, magnezyum %2.12, alüminyum %7.49, silisyum %21.28, potasyum %1.04, kalsiyum %6.63 ve demir %2.90 değerlere sahiptir (Tablo 7). Numunede en yüksek değere sahip olan element oksijen olup, en az değere sahip olan element ise potasyum olarak ölçülmüştür(Şekil 27). SEM görüntüsünde numunenin gözenekli yapıya sahip olmasının nedeni hapsolmuş havadan kaynaklı olduğu görülmektedir. Ayrıca, potasyum (K) ve magnezyum (Mg) yüzdelik değerlerinin düşük olması, kerpiç harcına eklenen atıklar ve katkı maddelerinden dolayı olması olasıdır [15]- [16].



Şekil 26. 6 numaralı güvercin evinin(boranhane) numunesine ait 500x-1000x-5000x SEM görüntüleri

Tablo 7.6 numaralı güvercin evinin(boranhane) numunesine ait EDX element yüzdeleri

EDX	Element Türleri						
	O K	MgK	AlK	Si K	KK	Ca K	FeK
%	58.54	2.12	7.49	21.28	1.04	6.63	2.90




Şekil 27. 6 numaralı güvercin evinin(boranhane) numunesine ait EDX grafiği

7 Numaralı Güvercin Evi (Boranhane) SEM-EDX Analizi

Çift taraflı bantla alınan numune örneği taramalı elektron mikroskobu (SEM) ile 500x-1000x-5000x görüntüleri alınmıştır (Şekil 28). Alınan SEM görüntüleri sonucu yüzeyin gözenekli, düzensiz ve homojen yapıda olmadığı tespit edilmiştir [13]- [19]. Enerji dağılımlı X-ışını spektroskopisi(EDX) ile yapılan deney sonucu alınan numunede oksijen (O), magnezyum (Mg), alüminyum (Al), silisyum (Si), potasyum (K), kalsiyum (Ca) ve demir (Fe) elementlerine rastlanılmıştır. Deney sonucu; oksijen miktarı %54.53, magnezyum %2.22, alüminyum %6.41, silisyum %25.71, potasyum %1.91, kalsiyum %5.37 ve demir %3.86 değerlere sahiptir (Tablo 8). Numunede en yüksek değere sahip olan element oksijen


olup, en az değere sahip olan element ise potasyum olarak ölçülmüştür (Şekil 29). SEM görüntüsünde numunenin gözenekli yapıya sahip olmasının nedeni hapsolmuş havadan kaynaklı olduğu görülmektedir. Ayrıca, potasyum (K) ve magnezyum (Mg) yüzdeleri değerlerinin düşük olması, kerpiç harcına eklenen atıklar ve katkı maddelerinden dolayı olması olasıdır [15]- [16].



Şekil 28. 7 numaralı güvercin evinin(boranhane) numunesine ait 500x-1000x-5000x SEM görüntüleri

Tablo 8. 7 numaralı güvercin evinin(boranhane) numunesine ait EDX element yüzdeleri

EDX	Element Türleri						
	O K	Mg K	Al K	Si K	K K	Ca K	Fe K
%	54.53	2.22	6.41	25.71	1.91	5.37	3.86



Şekil 29. 7 numaralı güvercin evinin(boranhane) numunesine ait EDX grafiği

SEM-EDX Deney Sonuçlarının Genel Değerlendirilmesi

Deneyleri yapılan sekiz adet numunenin içeriğinde bulunan elementler: oksijen (O), magnezyum (Mg), alüminyum (Al), silisyum (Si), potasyum (K), kalsiyum (Ca), demir (Fe), fosfor (P) ve karbon (C)'dur.

- Oksijen elementinin en yüksek değere %58.54 ile 6 numaralı güvercin evi(boranhane) olup, en düşük değere %49.71 ile 3 numaralı güvercin evi(boranhane) olduğu tespit edilmiştir.
- Magnezyum elementinin en yüksek değeri % 2.22 ile arkeoloji kalıntı olan 7 numaralı güvercin evi(boranhane) olup en düşük değeri %1.64 ile 5 numaralı güvercin evi(boranhane) olduğu tespit edilmiştir.
- Alüminyum elementinin en yüksek değeri %14.36 ile 3 numaralı güvercin evi(boranhane) olup , en düşük değeri %4.87 ile 5 numaralı güvercin evi(boranhane) olduğu tespit edilmiştir.
- Silisyum elementinin en yüksek değeri %25.94 ile 4 numaralı güvercin evi(boranhane) olup, en düşük değeri %16.61 ile 5 numaralı güvercin evi(boranhane) olduğu tespit edilmiştir.
- Potasyum elementinin en yüksek değeri %6 ile 3 numaralı güvercin evi(boranhane) olup, en

düşük değeri %1.04 ile 6 numaralı güvercin evi(boranhane) olduğu tespit edilmiştir.

- Kalsiyum elementinin en yüksek değeri %9.95 ile 2 numaralı güvercin evinin(boranhane) 1. numunesi olup, en düşük değeri %2.31 ile 3 numaralı güvercin evi(boranhane) olduğu tespit edilmiştir.
- Demir elementinin en yüksek değeri %5.18 ile 1 numaralı güvercin evi(boranhane) olup en düşük değeri %2.25 ile 5 numaralı güvercin evi(boranhane) olduğu tespit edilmiştir.
- Fosfor elementi sadece 2 numaralı güvercin evinde (boranhane) bulunmuştur. 2 numaralı yapıdan iki adet numune alınmıştır. 2 numaralı güvercin evinin(boranhane) 1. numunesindeki fosfor elementinin değeri %1.34 olup, 2. numunesindeki değeri ise %1.07 olarak ölçülmüştür.
- Karbon elementi ise %16.60 değeri ile sadece 5 numaralı güvercin evinde (boranhane) mevcut olduğu tespit edilmiştir.

Sonuç olarak; numunelerden elde edilen veriler değerlendirildiği zaman en yüksek değere elementler ; oksijen, silisyum, karbon, alüminyum ve kalsiyumdur. En az değerlere sahip olan elementler ise fosfor, magnezyum, potasyum ve demir olduğu tespit edilmiştir.

Sonuçlar ve Öneriler

Genel olarak, kuş evleri ve tarihi hakkında geniş araştırmalar yapılarak, kullanılan malzemeler, yapım teknikleri anlatılmış olup çeşitli fotoğraflarla belgelenmiştir.

Kerpiç, kırsal mimaride kullanılan doğal ve önemli yapı malzemelerinden biridir. Kuş evleri Türkiye'deki birçok kentte camilerde, ağaç kovuklarında, kervansaray vb. yapıların dış cephelerinde ayrı bir bölüm bırakılarak inşa edilmiştir.

Güvercin evleri (boranhane), kırsal alanlarda bağımsız olarak inşa edilen yapılardır. Genel olarak gübrelerinden yararlanmak için inşa edilen güvercin evleri (boranhane) günümüze sınırlı sayıda ulaşabilmiştir. Zaman içinde suni gübre artışıyla birlikte güvercin gübresinin kullanımının azalması güvercin evlerinin (boranhane) kullanımı ve işlevinin azalmasına yol açmıştır. Bu durumun sonucunda, güvercin evleri (boranhane) terk edilmiş ve bakımsızlıktan dolayı hasar almaya ve yok olmaya başlamıştır.

Diyarbakır Karaçalı (Tilalo) Mahallesi'nde yer alan güvercin evleri (boranhane) özgün mimarisiyle ulaşmış kültür miraslarından biridir. Bu çalışmada, Karaçalı (Tilalo) Mahallesi'nde yer alan güvercin evlerinin (boranhane) mimari özellikleri ve mevcut yapısal sorunları ve hasarları yapılan alan çalışmasıyla incelenmiştir. İncelenen altı adet güvercin evinin (boranhane) mevcut hasarları görsel olarak incelenip,

mevcut sorunlar ve hasarlar fotoğraflarla belgelenmiştir. Alan çalışması ile sınırlı sayıda günümüze ulaşan güvercin evlerinin (boranhane) rölöve projeleri çıkartılarak güncel arşiv oluşturulmuştur.

Kullanılmayan güvercin evlerinde (boranhane) nem sorunlarına bağlı bitki oluşumları, malzeme kayıpları, duvarlarda şişme, bakımsızlık, terk nedeniyle üst örtülerinin yıkılması, yapılarda onarımların yapılmaması ve bu durumlara bağlı hasarların oluştuğu tespit edilmiştir.6 Şubat 2023'te meydana gelen Kahramanmaraş depreminin etkisiyle hasarlı duvarların bir kısmı yıkılmış mevcut olanlarda strüktürel çatlaklar ve ayrışmalar meydana gelmiştir.

Alan çalışmasında biri arkeolojik kalıntı yedi adet güvercin evlerinden(boranhane) alınan sekiz adet numune DÜBTAM laboratuvarında taramalı elektron mikroskopu (SEM) ve enerji dağılımlı X-ışını spektroskopisi (EDX) deneyleri yapılmıştır. İlk aşamada sekiz adet numuneler, çift taraflı bant yardımı ile küçük parçalar alınarak SEM-EDX cihazına yerleştirilmiştir. Yerleştirilen numunelerin 500x-1000x-5000x boyutlarında SEM görüntüleri alınmış olup EDX ile de numuneler içerisindeki hangi elementlerin olduğu ve mevcut elementlerin yüzdelikleri elde edilmiştir. Elde edilen bilgiler EDX grafiğine aktarılmıştır. Son aşamada ise elde edilen sonuçlar doğrultusunda öneriler sunulmuştur.

Yapılan SEM-EDX Analizlerinde;

Tablo 9. Güvercin evlerindeki(boranhane) mevcut element tablosu

Numune alınan güvercin evleri (boranhane)	ELEMENTLER								
	O	Mg	Al	Si	K	Ca	Fe	P	C
1 numaralı güvercin evi(boranhane)	+	+	+	+	+	+	+	-	-
2 numaralı güvercin evi(boranhane)1. numune	+	+	+	+	+	+	+	+	-
2 numaralı güvercin evi(boranhane)2. numune	+	+	+	+	+	+	+	+	-
3 numaralı güvercin evi(boranhane)	+	+	+	+	+	+	+	-	-
4 numaralı güvercin evi(boranhane)	+	+	+	+	+	+	+	-	-
5 numaralı güvercin evi(boranhane)	+	+	+	+	+	+	+	-	+
6 numaralı güvercin evi(boranhane)	+	+	+	+	+	+	+	-	-
7 numaralı güvercin evi(boranhane)	+	+	+	+	+	+	+	-	-

(+): Elementlerin yapıda mevcut olduğunu gösterir. (-): Elementlerin yapıda mevcut olmadığını gösterir

Sonuç olarak, tüm güvercin evlerinde (boranhane) SEM-EDX analizleri sonucu oksijen (O), magnezyum (Mg), alüminyum (Al), silisyum (Si), potasyum (K), kalsiyum (Ca) ve demir (Fe) elementleri rastlanılmıştır. Tüm

güvercin evlerinde (boranhane) kalsiyum (Ca) elementinin görülmesi yağışlı havalardan kaynaklı olduğu düşünülmektedir.2 numaralı güvercin evinde(boranhane) ek olarak fosfor (P) elementi bulunmaktadır. Kaya ve minerallerin parçalanarak fosfor (P) elementinin numunede kullanılan toprağa karıştığı düşünülmektedir. Ayrıca, fosfor (P) elementi bitki gelişimine etkisi olumludur. Böylelikle fosfor(P) elementinin güvercin evlerindeki(boranhane) alınan numunelerde bulunması yapılardaki bitki oluşumlarına olumsuz bir etki yaratmaktadır (Toros tarım). 5 numaralı güvercin evinde (boranhane) de karbon (C) elementi bulunmaktadır. Karbon (C) elementi; toprağın fiziksel özelliklerinin iyileşmesine ve killi toprakların yapısal dengesini geliştirmeye katkı sağlar (Teknobiyojoloji). Yapılarda en yüksek değere sahip olan element oksijen olurken en düşük elementler potasyum, magnezyum ve fosfor olarak ölçülmüştür.

Kentlerin kırsal alanlarında yer alan, kent sosyo-kültürel yaşantısı ile geleneğinde önemli yeri olan güvercin evleri günümüzde kaybolma tehlikesi ile karşı karşıyadır.

Bu bağlamda, az, orta ve ağır hasarlı güvercin evlerinin (boranhane) korunması ve yeniden kullanımı için bazı öneriler şu şekildedir:

- Güvercin evlerinin (boranhane) özgün işlevlerini kaybetmiş olmalarına rağmen ivedilikle rölöve ve restorasyon projeleri çıkartılmalıdır.
- Özgün mimarisinin korunarak günümüz teknolojisine uygun çözümler üretilerek yenilenmelidir.
- Çalışmaların titiz bir şekilde yürütülmesi ve özgün işlevlerini geri kazandırılması sağlanmalıdır.
- Bakımsızlık ve terk edilmiş olan güvercin evleri(boranhane) temizlenmelidir.
- Üst örtüsü mevcut olmayan güvercin evleri(boranhane) koruyucu örtü ile kapatılmalıdır.
- Rölöve ve restorasyon projeleri sonrası güçlendirme projeleri uygulanmalıdır.
- Yapı elemanları kaybına uğrayan güvercin evlerine (boranhane) özgün tamamlamalar yapılmalıdır.

Diyarbakır Karaçalı (Tilalo) mevkiindeki günümüze sınırlı sayıda ulaşan güvercin evlerinin (boranhane), yakın zamanda onarımları yapılmamış ve terk edilerek doğa koşullarına karşı savunmasız bırakılmıştır. Güvercin evlerinin (boranhane) özgün yapı teknikleriyle onarılabilir duruma getirilmesi, kültürel mirasın korunması ve kent hafızasının yaşatılması açısından oldukça önemlidir.

Güvercin evlerinin (boranhane) özgün mimarisiyle yeniden kullanımı güvercin besleme kültürü ve

geleneğinin yaşatılmasına yönelik çalışmaların yapılmasının benzer yapılar için güncel bir kaynak olması ile bu geleneğin gelecek nesillere aktarılmasına katkı sağlayacağı düşünülmektedir.

Not: Bu çalışma “Diyarbakır Karaçalı (Tilalo) Mahallesiindeki Güvercin Evlerinin (Boranhane) Yapısal Sorunlarının Belirlenmesi İle Kerpiç Malzemenin SEM-EDX Analizlerinin Yapılması” başlıklı yüksek lisans tezinden üretilmiştir.

Kaynaklar

[1] Azbağ, M. (2022). Boğazköy ve Büklükale kazılarında ele geçen M.M. II. bine ait kerpiçlerin arkeometrik analizi. (Yüksek Lisans Tezi). Çukurova Üniversitesi Fen Bilimleri Enstitüsü: Adana.

[2] Bozyel, E. (2021). Betonarme kullanıcılarının kerpiç yapılar hakkındaki görüşlerinin bilimsel veriler doğrultusunda incelenmesi. (Yüksek Lisans Tezi). Fatih Sultan Mehmet Vakıf Üniversitesi Eğitim Enstitüsü: İstanbul.

[3] Ülgen, A. (1994). Türk mimarisinin minyatür yapıları: Kuş evleri, tarih ve medeniyet, Sayı (7), s.55-58.

[4] Özen, H. (2021). Yaşayan mimari gelenek: Santa Fe kenti kerpiç mimarı. Tasarım Kültürü Dergisi, sayı (104), 3-10.

[5] Özçakı, M. (2020). Geleneksel kuş evleri ve yeni uygulamalar için öneri. Güzel Sanatlar Fakültesi Sanat Dergisi, sayı (25), cilt (13), 1-19.

[6] Aydınalp, B., Yakut B. ve Ergin Ş. (2022). The roof repair of a boranhane. Medipol University, Kerpic'22 9 th International Conference Proceedings, 1-8.

[7] Noei, S. (2011). Güvercinkeyası kerpiç karakterizasyonu. (Yüksek Lisans Tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü Taşınabilir Kültür Varlıklarını Koruma ve Onarım Anabilim Dalı: İstanbul.

[8] Noei, S. (2017). Tarih öncesi Anadolu'da (MÖ 8500-3500) yapı malzemesi olarak kerpiç'in arkeolojik ve arkeometrik değerlendirilmesi. (Doktora Tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü: İstanbul.

[9] Ölmez, B. (2022). Geleneksel kerpiç mimarisinin korunması: Van İli Erciş ilçesi Tekler mahallesi örneği. (Yüksek Lisans Tezi). Çankaya Üniversitesi Fen Bilimleri Enstitüsü: Ankara.

[10] Esogü, (2018). <https://arum.ogu.edu.tr/Sayfa/Index/65/taramali-elektron-mikroskobu-sem>

[11] Eurolab. <https://www.laboratuvar.com/testler/kimyasal-testler/sem-taramali-elektron-mikroskopisi/>

[12] Ankara Üniversitesi., Elektron mikroskobu laboratuvarı. <http://emb.ankara.edu.tr/sem>

[13] Aras, Ü.G.H. (2011). Borlu Aktif Belit Çimentolu Betonların Taramalı Elektro mikroskop (SEM) ve XRD Işınlarıyla Analizi. Yüksek Lisan Tezi, Atatürk Üniversitesi Fen Bilimleri Enstitüsü.

[14] Uzbaşı, B. (2019). “Çimento Esaslı Silis Dumanlı Uçucu Küllü Kompozitlerin SEM Ve XRD Destekli Görsel Analizlerin Yapay Sinir Ağları İle Modellenmesi. Yüksek Lisans Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Erzurum.

[15] Kumar, D. v.d. (2024). Laterite used as pigment source- Analysis of Geological cum Anthropogenic specimen found in the Kaimur range, India through SEM-EDX and WD-XRF.

[16] Krishnan, S. v.d. (2024). FTIR, XRD, EDX with SEM Spectroscopic Studies on Sedimentary Rocks of Bodamalai Hills, South India.

[17] Işık, N. v.d. (2023). Elazığ Hüseyinik(Ulukent Mahallesi'ndeki Kerpiç Evlerin Yapısal Sorunlarının Gözlemsel Tespiti Ve Kerpiç Malzemede XRD - SEM Analizi Yöntemlerinin Kullanımı.

[18] Putranto, A. v.d. (2024). Evaluation of Physical Properties in Carboxymethyl Chitosan Modified Glass Ionomer Cements and the Effect for Dentin Remineralization: SEM/EDX, Compressive Strength, and Ca/P Ratio.

[19] Ratnayake, S. v.d. (2023). Combined X-ray absorption and SEM-EDX spectroscopic analysis for the speciation of thorium in soil.

[20] Güneri, M. (2023). Ayçiçeği sapı ilavesi ile kerpiç malzemenin fiziksel ve mekanik özelliklerinin araştırılması. (Yüksek Lisans Tezi). Trakya Üniversitesi Fen Bilimleri Enstitüsü: Edirne.

[21] Arpacıoğlu, Ü. (2006). Geçmişten günümüze kerpiç malzeme üretim teknikleri ve güncel kullanım olanakları. 3. Ulusal Yapı Malzemesi Kongresi ve Sergisi, 4-6.

[22] Aruntaş, Y. v.d. (2015). Sürdürülebilir bir yapı malzemesi olarak kerpiç. 2. International Sustainable Buildings Symposium, 2-9.

[23] Işık, N. v.d. (2023). Baghdadi wall techniques used in traditional buildings: The Example of Diyarbakır Suriçi. Kerpic'23 – Gain Information from the Traditional Earthen Architecture, 1-9.

[24] Işık, N. v.d. (2011). Soil turning into pigeon houses (boranhane: güvercin evleri). Ceramics Technical, sayı (32), 7-10.

[25] Işık, N. v.d. (2023). Hüseyinik (Ulukent) mahallesiindeki geleneksel evlerde gözlemsel olarak belirlenen yapısal hasarlarının tek yapı ölçeğinde değerlendirilmesi. 4. International Anatolian Congress on Scientific Research, 58-69.



Mechanical and microstructural properties of stone units in the masonry building stock of Urla peninsula

Uğur DEMİR^{1*}

¹ İzmir Institute of Technology, Architecture Department, ugurdemir@iyte.edu.tr, Orcid No: 0000-0001-8319-2535

ARTICLE INFO

Article history:

Received 22 August 2024
Received in revised form 26 October 2024
Accepted 31 October 2024
Available online 23 December 2024

Keywords:

BET, limestone, masonry, sandstone, SEM

Doi: 10.24012/dumf.1537224

* Corresponding author

ABSTRACT

This experimental study focuses on two most commonly used stone types in masonry building stock in the Urla Peninsula of İzmir: sandstone and limestone. The compressive behavior of these stones, which is critical to the structural integrity of historic and contemporary stone masonry buildings in the region, was analyzed in detail. To assess their mechanical performance under compressive stress, uniaxial compressive loads were applied to the stone samples, which were gathered after an extensive field survey. Scanning Electron Microscopy (SEM) and Brunauer-Emmett-Teller (BET) analyses were employed to characterize their microstructure. SEM analysis provided detailed insights into the surface morphology and microstructural composition of the stones, revealing differences in grain size and bonding. BET analysis was used to determine the specific surface area and pore size distribution, which are key factors influencing the stones' mechanical strength and durability. The results demonstrated that limestone exhibits significantly superior mechanical properties under compressive stress compared to sandstone. Specifically, the denser and more homogeneous microstructure of limestone, characterized by smaller pores and fewer micro-cracks, contributes to its higher compressive strength. This was corroborated by BET analysis, which showed that limestone has a larger surface area and less porous structure, enhancing its load-bearing capacity. In contrast, sandstone, with its relatively higher porosity, displayed lower resistance to compressive forces, making it more susceptible to deformation and failure under axial loads. The study underscores the importance of microstructural characteristics in determining the mechanical performance of natural building materials.

Introduction

The masonry building stock of İzmir predominantly consists of structures built with locally available stone types, primarily limestone, and sandstone. These materials have been favored for their availability, workability, and durability, making them ideal for the city's traditional construction practices. Limestone and sandstone are often categorized and used based on their finish and size, typically classified as ashlar or rubble stone. Ashlar masonry refers to finely dressed stones with even surfaces, usually cut into rectangular shapes. This type of masonry is often used in more formal, monumental, or high-status buildings due to its aesthetic appeal and the precision required in its construction. In İzmir, ashlar limestone and sandstone are common in historic buildings, such as government structures, religious buildings, and affluent residences. The smooth, regular appearance of ashlar masonry provides not only visual appeal but also structural integrity due to the tight fit between stones. Rubble masonry, on the other hand, involves using irregularly shaped stones that are either minimally dressed or left in their natural state. This type of masonry is more commonly found in vernacular architecture, including rural homes, boundary walls, and utility structures. Rubble limestone and

sandstone are prevalent in İzmir's traditional buildings, particularly in areas where quick and cost-effective construction methods were necessary. Despite the irregular shapes, rubble masonry can be highly durable, especially when skilled masons ensure good bonding and packing of the stones.

In response to the increasing seismic activities and associated losses observed recently around the Aegean Sea, the İzmir Metropolitan Municipality, authorized under the Provincial Risk Reduction Plans (IRAP), collaborated with Boğaziçi University to develop the İzmir Earthquake Master Plan (IEMP). Within the IEMP project framework, the focus was on estimating the structural damage and associated losses in buildings under the standard design earthquake (with a 10% probability of being exceeded in 50 years). In the scope of IEMP project, a comprehensive building inventory study was conducted with an aim for classifying buildings based on their structural characteristics, construction date, project and construction quality, and occupancy characteristics. According to the inventory study, a total of 217,824 buildings were investigated, involving 190,419 reinforced concrete buildings (87%), 23,362 stone masonry buildings (11%), and 4,043 buildings of other types (2%). Analyzing a pilot area in the city center under the IEMP project revealed that

stone masonry structures constitute the most vulnerable ones within the building stock.

Although its usage has decreased in the last few decades with the emergence of new construction and techniques, stone is still widely utilized in many regions where it is abundant and alternative materials are not readily available. However, it is well-recognized that stone masonry structures predominantly constructed in rural areas using stone units (kayrak, andesite, granite, limestone, etc.) are highly vulnerable against earthquakes. Nevertheless, due to their high prevalence in the building stock, it seems economically unfeasible to demolish and rebuild all risky stone masonry structures. Therefore, an urgent comprehensive inventory study should be conducted on existing stone masonry structures, to classify them accordingly. Subsequently, risk prioritization activities should be carried out for each group, and relevant structures should be either demolished and rebuilt or strengthened. However, rich diversity in local materials and construction practices in stone masonry structures complicates implementation of this process, necessitating regional solutions. When the literature is mined, it is clearly observed that there are several studies reporting the properties of locally available stone units around İzmir [1-4]. Tunçoku et al. [5] classified rural structures in İzmir based on architectural features and identified stone masonry structures as one of the most commonly used types around İzmir. This study also mentioned that, in the rural building stock of İzmir, one to two-story stone masonry structures with different wall textures are frequently observed. Stones, such as neatly cut ashlar stones extracted for centuries from existing quarries in Balıklıova (Urla) and Alaçatı (Çeşme), are commonly used in the construction of stone masonry structures found in the narrow streets of the Urla peninsula. It is evident that the demand for these stones has increased due to their characteristics, such as not requiring plaster and whitewash applications. Biçer [6] characterized Alaçatı stone as a lightweight, porous sedimentary rock composed of volcanic ash, sand, and lava particles. The research pointed out the stone's limitations in structural applications due to its low compressive strength, high water absorption rate, and significantly higher abrasion rate when compared to other local stone types. Despite these weaknesses, the study proposed that the stone's low unit volume weight could make it an appealing option for use in earthquake-prone areas like İzmir. It should be noted that this claim is debatable, as the increase in axial stress on masonry walls does not necessarily deteriorate their seismic performance. Yavuz [7] also examined the durability of Alaçatı stone, reporting compressive strength, water absorption, and thermal conductivity values similar to that of Biçer [6]. In addition, in the studies by Milosevic et al. [8], Demir et al. [9], and Gönen and Soyöz [10], experiments were conducted under compressive loads, and the mechanical behaviors of stone masonry walls were experimentally obtained. When examining studies that investigate the behavior of masonry walls under compression, it is observed that the compressive strengths of stone units vary widely between 4 MPa and 160 MPa, the compressive strengths of walls can range between 1 MPa and 22 MPa,

and the modulus of elasticity of the walls shows a distribution between 560 MPa and 7000 MPa. Upon reviewing studies within this broad spectrum, it is evident that the behavior of masonry structures under compressive effects varies significantly depending on the masonry unit, mortar, wall size, and number of layers. Therefore, it is crucial to consider these extensive local variations when determining the behavior of such structures. It is also noteworthy to mention that identifying the mechanical and microstructural properties of stone units forms the first step in order to understand the behavior of stone masonry structures under service and seismic loads. This study offers essential data on mechanical and microstructural behavior of locally available sandstone and limestone samples for consideration in design and structural performance assessment of existing vulnerable stone masonry buildings on Urla peninsula. According to the "Peninsula Sustainable Development Strategy" document prepared by the İzmir Development Agency [11], the Urla peninsula encompasses five of İzmir's thirty districts, namely Urla, Cesme, Karaburun, Guzelbahce, and Seferihisar, accounting for approximately 25% of the total area of the city [12]. Besides, in the last 20 years, İzmir has experienced 4 earthquakes with magnitudes of $M_w=5.7$ and above, all of which occurred in the Urla peninsula. This situation indicates the necessity and importance of the presented study. Moreover, despite the potential for severe casualties and economic losses in the stone masonry structures during a possible earthquake, there is a limited number of research on this topic for the Urla peninsula, particularly focusing on the relationship between the mechanical and microstructural properties of locally available stone units. As such, first, compressive behavior of different stone units gathered from the existing building stock was estimated under uniaxial compressive loads. At the second step, SEM analyses have been carried out for examination and analysis of micro and nanoparticle imaging characterization of the stone units. Finally, BET analyses were conducted for revealing specific surface areas and pore size distributions in stone units. Such a holistic approach, which has been performed for the first time to identify the characteristics of the locally available stone units in the investigated peninsula, has the potential to serve to eliminate the uncertainties on modelling the behavior of vulnerable stone masonry structures in the investigated region. The findings of the study may also aid the development of reliable risk mitigation strategies by serving to the inventory studies aligned with the current attempts within the region.

Mechanical and Microstructural Properties

As a part of an extensive field survey conducted in Urla peninsula, the most observed stone samples were taken with the aim of identifying their mechanical and microstructural properties. Compressive tests were conducted to determine the mechanical properties of the stone units. For these tests, the specimens were prepared in accordance with the ASTM C170M [13] standard. As per this standard, cross sectional dimensions of the rectangular prism specimens should be at least 50.8 mm and the height to width ratio should be at least one. Therefore, in the scope of this study, $100 \times 100 \times 100$

mm cube samples were cut using a rotating saw from specimens gathered during the field survey. The specimens were kept under ambient conditions for about 2 weeks to ensure that they reached their natural water content prior to compressive tests. Besides, unit weights of the specimens were measured at three successive days until weight change due to the humidity variations has been stabilized. Unit weights of the limestone and sandstone specimens were measured to be around 2384 kg/m³ and 1789 kg/m³, respectively. Sandstone specimens were tested with a 250 kN capacity Schimadzu AG-I universal testing machine, whereas limestone samples were tested using a Utest compression press with a capacity of 3000 kN, since they necessitated a higher capacity. A total of 10 specimens were tested namely, five out of 10 specimens were sandstone whereas the remaining five were limestone. Displacement-controlled tests were performed for the purpose of uniaxial compressive loading of the specimens. The rate of loading should not exceed 690 kPa/s, but this requirement may be considered as being met if the speed of the loading head is not more than 1.3 mm/min. as per ASTM C170M [13]. Considering this phenomenon, a loading rate of 0.3 mm/min. was applied and kept constant during the uniaxial compressive tests. Figure 1 demonstrates the appearances and failure modes of the limestone and sandstone samples, respectively. Sandstone samples exhibited a relatively more ductile behavior which can be identified with a smooth descending branch in the stress-strain responses. On the other hand, limestone samples explosively failed corresponding to a considerably brittle response. This difference can be attributed to the alteration of the natures for the stone samples in terms of chemical and pore composition, which is investigated below in the present study. Axial stress - strain responses of the limestone and sandstone specimens are shown in Figures 2 and 3, respectively. In these figures, the stress was calculated as the ratio of the applied load to the initial cross-section area (100×100 mm²) of the specimen, whereas the axial strains were calculated as the ratio of the average vertical deformation measured with the two LVDTs integrated within the test machine over a full gage length between the loading plates (along 100 mm height).




Fig. 1. Appearances of a) limestone, b) sandstone samples after compression tests.

Mechanical properties of limestone and sandstone units are summarized in Table 1. In this table, f_{co} is the compressive strength, ϵ_{co} is the compressive strain corresponding to the peak stress and E is the elastic modulus of the stone samples. Letters L and T stand for limestone and sandstone units of each series (i.e., L1 is the first limestone specimen),

respectively, M is the median value, SD refers to the standard deviation and CoV is coefficient of variation (SD/M). It should be noted for Table 1 that properties of L5 sample were excluded from the calculations of compressive strength and elastic modulus of the limestone samples due to the problems encountered during the test of this specimen. As seen in Figs. 2- 3 and Table 1, limestone displayed a better behavior compared to sandstone in terms of encountered compressive strength. The average compressive strength, f_{co} , calculated from the tests were 83.1 MPa and 11.2 MPa for limestone and sandstone samples, respectively. The modulus of elasticity, E , for the specimens are determined as the secant modulus in the range of 30% and 60% of the ultimate compressive strength in the ascending branch of the stress-strain diagram as indicated by Binda et al. [14]. The average values for the elastic modulus were calculated to be 7611 MPa and 696 MPa for the limestone and sandstone, respectively. Due to the lower axial stiffness of the sandstone samples, strain corresponding to the peak stress is remarkably larger for these samples with respect to the limestone units. This behavior led to a more ductile response for the sandstone samples. The high compressive strength makes limestone more suitable for load-bearing applications in construction, especially in historical and monumental structures. On the other hand, sandstone should be used in construction for decorative purposes or in areas where load bearing is less critical. The studies conducted after the 2023 Kahramanmaraş earthquakes also indicated that the stone masonry buildings with poor quality of materials exhibited a worse earthquake performance [15]

With an aim to better understand the reason behind the variation in the mechanical behavior, SEM analyses were used for high-resolution imaging and composition analysis by energy-dispersive X-ray microanalysis (EDS) on a FEI Quanta FEG 250 instrument present in Centre for Materials Research in İzmir Institute of Technology. Figures 4-9 show SEM results at 1000x, 2500x and 5000x magnification for the limestone and sandstone samples, respectively. The result of several SEM analyses through different portions of the grained stone powder indicated the presence of elements of Ca, C, and O, which are components of carbonate phases $CaCO_3$ (calcite) in the limestone samples, whereas the analysis of sandstone indicated silicon dioxide or quartz (SiO_2) formations as shown in Figures 10-11 via their EDS spectra at a selected point.




Fig. 2. Axial stress – strain response of the limestone samples.




Fig. 3. Axial stress – strain response of the sandstone samples.

Table 1. Mechanical properties of stone units.

Type	f_{c0} (MPa)	ϵ_{c0}	E (MPa)
L1	82.9	0.022	4754
L2	65.7	0.016	5507
L3	92.5	0.016	11498
L4	91.1	0.013	8685
L5*	155.8	0.012	17337
M	83.1	0.016	7611
SD	10.7	0.004	2686
CoV	0.13	0.25	0.35
T1	12.1	0.024	575
T2	9.6	0.026	688
T3	13.8	0.018	947
T4	12.4	0.023	586
T5	7.9	0.026	684
M	11.2	0.023	696
SD	2.4	0.003	134
CoV	0.21	0.13	0.19

* The properties of L5 specimen were not considered in the calculations.

In addition, weight and atomic percentages of the elements for limestone and sandstone samples obtained from the EDS microanalysis are shown in Tables 2-3, respectively. Figs. 4-9 show that the microstructure of the limestone samples appears to be compact and very tightly knit compared to sandstone. The homogeneity of limestone’s microstructure contributes to its higher compressive strength and durability

compared to sandstone. On the other hand, as seen in Figs. 7-9, the presence of the pores in sandstone samples resulted in a more porous microstructure with respect to the limestone. The porous nature of sandstone led to a lower compressive strength. The cementing material between the grains can significantly affect sandstone’s mechanical properties. A weaker cement results in more voids and cracks, leading to lower strength. The presence of pores also enabled material to deform more remarkably under compressive stress, resulting in higher compressive strain but lower stiffness. These gaps in the microstructure also allowed the sandstone samples to absorb some of the stress through deformation, which spreads the load over time and reduces the exhibited peak strength. On the other hand, the homogeneous structure of limestone, with fewer gaps, results in higher axial stiffness (Fig. 2). This behavior indicated that limestone could resist greater stress without deforming as much as sandstone, leading to a higher peak compressive strength. However, this also means that limestone fails at lower compressive strain, as the material is less capable of absorbing stress through deformation. As a result, the SEM analyses effectively illustrated why limestone, with its more compact and uniform structure, exhibits higher compressive strength and lower strain, whereas sandstone’s more porous structure results in the opposite behavior. The presence of microcracks in limestone samples is less prominent compared to sandstone, indicating better overall structural integrity. This bond between the microstructure and the mechanical properties is crucial in understanding how these materials will perform in different structural applications.




Fig. 4. Limestone after 1000x magnification.




Fig. 5. Limestone after 2500x magnification.




Fig. 6. Limestone after 5000x magnification.




Fig. 7. Sandstone after 1000x magnification.




Fig. 8. Sandstone after 2500x magnification.




Fig. 9. Sandstone after 5000x magnification.




Fig. 10. EDS spectra of limestone.

Table 2. Weight and atomic percentages of the elements in limestone samples.

Element	Weight (%)	Atomic (%)
O	53.06	58.79
Ca	25.35	11.21
C	19.45	28.71
Al	0.87	0.57
Si	0.49	0.31
Mg	0.40	0.29
Fe	0.38	0.12




Fig. 11. EDS spectra of sandstone.

Table 3. Weight and atomic percentages of the elements in sandstone samples.

Element	Weight (%)	Atomic (%)
O	58.77	71.88
Si	27.34	19.05
Al	6.07	4.41
K	3.77	1.89
Na	2.22	1.89
Ca	1.83	0.89

Performing BET (Brunauer-Emmett-Teller) analyses on limestone and sandstone samples would provide valuable insights into the surface area and pore structure of the materials, which could further correlate with SEM

observations and compressive responses of the samples. Therefore, enriched by BET analysis, variation in crystal morphology of the stone samples can be understood more clearly. Figure 12 shows the variations in BET surface area and average pore width between limestone and sandstone samples. As seen in Fig. 12a, specific surface areas for the limestone and sandstone samples are 9.47 and 5.98 m²/g, respectively. Based on BET analyses, Fig 12b shows that a similar trend was observed in the average pore widths such that limestone and sandstone samples had 79.6 Å and 68.9 Å of average pore width, respectively. When the BET surface areas and average pore widths are compared, it was observed that these values tend to decrease with increasing porosity, which was observed in SEM analyses in the stone samples as well (Figs. 4-9, 12). In other words, the particles having smaller pores also may have a larger specific surface area and average pore width as stated in the literature [16]. Although these relationships are not well defined due to a limited number of analyses conducted within the scope of the present study, a trend may exist that warrants further investigation.

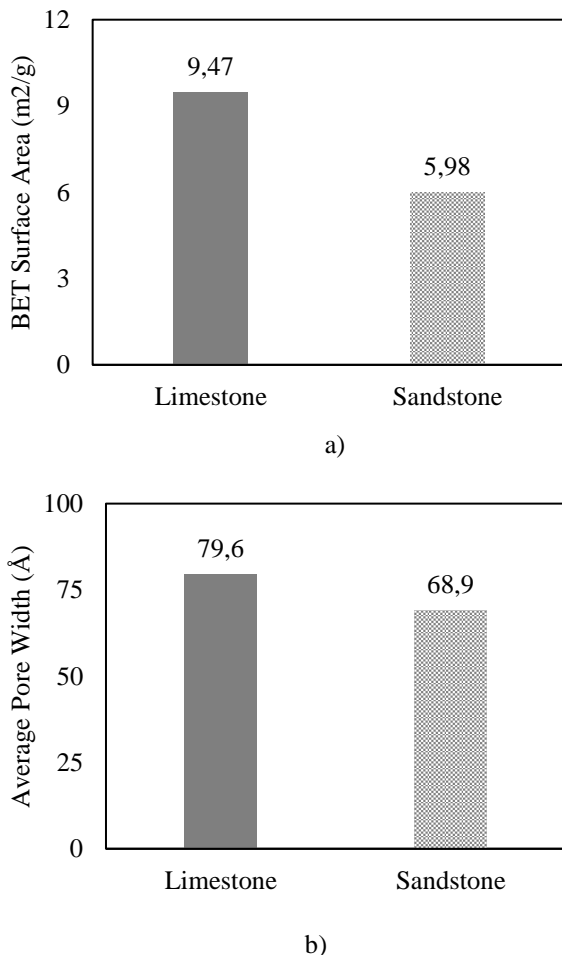


Fig. 12. Results of BET analyses a) BET surface areas, b) average pore width.

Conclusions

In the scope of the study, mechanical and microstructural properties of stone units in the masonry building stock of Urla peninsula was investigated. In the light of the

experimental results, the following conclusions can be drawn.

1. Limestone units exhibited a better compressive behavior in terms of encountered compressive strength, but in a quite brittle failure mode with respect to sandstone samples. Due to the lower axial stiffness of the sandstone samples, strain corresponding to the peak stress is remarkably larger for these samples with respect to the limestone units. This behavior led to a more ductile response for the sandstone samples. The average compressive strengths were 83.1 MPa and 11.2 MPa for limestone and sandstone samples, respectively, pointing out the significant difference of the units under compression.

2. SEM analyses indicated that the microstructure of the limestone samples was compact and tightly knit compared to sandstone, whereas the presence of the large pores in sandstone samples resulted in a more porous microstructure. This behavior led to a lower compressive strength for the sandstone samples as well as enabled sandstone samples to deform more remarkably under compressive stress, resulting in higher compressive strain but lower stiffness. Besides, BET analyses showed that BET surface areas and average pore widths tend to decrease with increasing porosity.

3. Superior compressive behavior makes limestone more suitable for load-bearing applications in construction, especially in historical and monumental structures, whereas sandstone should be used in construction for decorative purposes or in areas where load bearing is less critical.

Ethics committee approval and conflict of interest statement

There is no need to obtain permission from the ethics committee for the article to be prepared.

There is no conflict of interest with any person / institution in the article prepared.

Acknowledgement

The help of Elif Naz Çelik and staff of Integrated Research Centers (Tümleşik Araştırma Merkezleri, TAM) in İzmir Institute of Technology, particularly Dr. Şeyda Horzum Şahin, Mutlu Devran Yaman and Burcu Akdağ Çağlar, is gratefully acknowledged.

References

- [1] M. Y. Çelik, "Characterization of İscehisar Andesite (Afyonkarahisar-Turkey), Used as a Building Stone Source of Historical Heritages from Ancient Times to the Present". *Geoheritage*, 16(3), 1-19, 2024.
- [2] A. B. Yavuz, N. Turk, & M. Y. Koca, "Material properties of the Menderes massif marbles from SW Turkey". *Engineering geology*, 82(2), 91-106, 2005.
- [3] E. Teomete, E. Aktaş, "Structural analyses and assessment of historical Kamanlı Mosque in İzmir,

- Turkey". *Journal of Performance of Constructed Facilities*, 24(4), 353-364, 2010.
- [4] E. T. Uzun, I. Gucu, T. Arslan, & S. O. Kalkan, "Retrofitting of masonry structures considering the architectural perspective: A case study in Foca, Izmir". In *IOP Conference Series: Materials Science and Engineering* (Vol. 471, No. 2, p. 022003). IOP Publishing, 2019.
- [5] S. S. Tuncoku, U. Incekose, T. Akis, M. A. Yalcin, "Assessment of construction techniques and material usage in İzmir rural houses". *International Journal of Architectural Heritage*, 9(8), 1005–1022, 2015.
- [6] A. Biçer, "The thermal and mechanical properties of building stones from the Afyon, Izmir, Muğla and Denizli region". *Naturengs*, 3(1), 1, 2022.
- [7] A. B. Yavuz, "Durability assessment of the Alaçatı tuff (Izmir) in western Turkey". *Environmental Earth Sciences*, 67(7), 1909–1925, 2012.
- [8] J. Milosevic, A. S. Gago, M. Lopes, & R. Bento, "Experimental assessment of shear strength parameters on rubble stone masonry specimens". *Construction and Building Materials*, 47, 1372-1380, 2013.
- [9] C. Demir, & A. Ilki, "Characterization of the materials used in the multi-leaf masonry walls of monumental structures in Istanbul, Turkey". *Construction and Building Materials*, 64, 398-413, 2014.
- [10] S. Gonen and S. Soyoz, "Investigations on the elasticity modulus of stone masonry", *Structures*, 30, 378-389, 2021.
- [11] URL: www.izka.org.tr, accessed on 22/08/2024.
- [12] M. Emiroğlu, "Urla yarımadasında nüfusun gelişmesi". *Ankara Üniversitesi Dil ve Tarih-Coğrafya Fakültesi Dergisi*, 32(1-2), 237-267, 1988 (In Turkish).
- [13] ASTM C170M-17, "Standard test method for compressive strength of dimension stone". ASTM International, West Conshohocken, PA, 2017.
- [14] L. Binda, J. Pina Henriques, A. Anzani, A. Fontana and P. B. Lourenço, "A contribution for the understanding of load-transfer mechanisms in multi-leaf masonry walls: Testing and modelling", *Engineering Structures*, 28, 1132-1148, 2006.
- [15] B. Bozyigit, A. Ozdemir, K. Donmez, K. D. Dalgic, E. Durgut, C. Yesilyurt, ... & S. Acikgoz, "Damage to monumental masonry buildings in Hatay and Osmaniye following the 2023 Turkey earthquake sequence: The role of wall geometry, construction quality, and material properties" *Earthquake Spectra*, 87552930241247031, 2024.
- [16] D. Benavente, M. G. Del Cura, R. Fort & S. Ordóñez, "Durability estimation of porous building stones from pore structure and strength", *Engineering Geology*, 74(1), 113-127, 2004.



Araştırma Makalesi / Research Article

Hareketli tabana sahip T-bağlantılı kanal sisteminde akım ve taban özelliklerinin
nümerik incelenmesi*Numerical investigation of flow and bed features at a T-linked channel system with
mobile-bed*Fırat Gümgüm^{1*}¹ Dicle Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Diyarbakır, Türkiye fiat.gumgum@dicle.edu.tr
ORCID: <https://orcid.org/0000-0003-2707-3122>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 28 Ağustos 2024
Revizyon 3 Ekim 2024
Kabul 4 Ekim 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

Akım bölünmesi, çevirme kanalı,
hareketli taban, nümerik analiz

ÖZ

Alüvyal akarsuların kıyılarına inşa edilen çevirme kanallarında oluşan aşırı sediment birikimi nedeniyle kanalda ciddi sığlaşmalar meydana gelebilmektedir. Bu olgu akım bölünmesi ile birlikte araştırmacılar tarafından sıklıkla laboratuvar deneyleriyle araştırılmaktadır. Laboratuvar deneylerinin fiziksel ve ekonomik limitleri göz önüne alındığında nümerik çalışmaların önemi ön plana çıkmaktadır. Bu çalışmada laboratuvar ortamında gerçekleştirilen bir deney nümerik olarak modellenerek olarak test edilmiştir. Simülasyon sonucunda elde edilen bulgularda her iki kanaldaki akım ve taban özelliklerinin laboratuvar deneylerinden elde edilen sonuçlarla uyumlu olduğu saptanmıştır.

ARTICLE INFO

Article history:

Received 28 August 2024
Received in revised form 3 October 2024
Accepted 4 October 2024
Available online 23 December 2024

Keywords:

Division of flow, diversion channel,
mobile-bed, numerical analysis

ABSTRACT

Severe shoaling may occur in the diversion channels built on alluvial river banks due to excessive sediment deposition. The phenomenon, together with flow division, is frequently investigated by researchers with laboratory experiments. Considering the physical and economic limits of laboratory experiments, the importance of numerical studies becomes obvious. In this study, an experiment carried out in the laboratory was numerically modeled and tested. The simulation results indicate that the flow and bed features in both channels are in coherence with the results obtained from laboratory experiments.

Doi: 10.24012/dumf.1539964

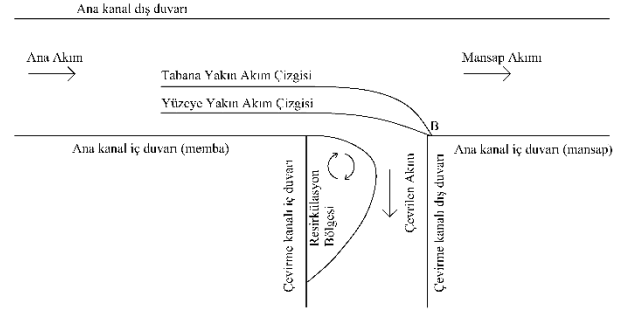
* Sorumlu Yazar

Giriş

Çevirme kanalları, akışın doğal yönünü sulama, katı atık yönetimi, taşkın kontrolü, içme suyu temini vb. amaçlarla değiştirmek için inşa edilmektedir. Bu yapıların alüvyal nehirlerin kıyılarına inşa edilmesi durumunda kanala akım ile birlikte büyük miktarda sediment girebilir. Sık karşılaşılan ve arzu edilmeyen bu durum, kanalda sığlaşmaya ve varsa mansapta bulunan teçhizatlarda arızaya neden olabilmektedir. Aynı zamanda akım bölünmesi nedeniyle çatallanma bölgesinde karmaşık ve üç boyutlu akım yapıları oluşmakta, çevirme kanalı girişinde aşağı yönlü akımlar ve ikincil çevrıntiler sonucu yerel oyulmalar meydana gelebilmektedir. Bu olgu genellikle laboratuvar ortamında, akarsuyu temsilen, ana kanalı hareketli tabana sahip, çevirme kanalı ise hareketli ya da rijit tabana sahip kanal sistemlerinde deneysel olarak araştırılmaktadır.

Ana kanal membasından gelen (yaklaşan) akım, çevirme kanalı girişine ulaşırken akımın bir kısmı bölünerek çevirme kanalına doğru yönelir. Ana kanal doğrultusundaki momentum bileşeninden dolayı bölünen (çevrilen) akım, çevirme kanalı iç duvarına hemen temas edemeyerek kanalın memba köşesinden belirli bir açı ile ayrılır ve çevirme kanalı içerisinde bir süre hareket ettikten sonra iç duvarına yeniden bağlanır [1]. Bu ayrılma ve yeniden birleşme noktaları arasında akım hızlarının çok düşük olduğu ve çeşitli çevrıntilerin olduğu bir resirkülasyon bölgesi oluşur. Akımın düşük hız profili göz önüne alındığında su yüzeyine yakın bölgedeki hızlar, tabana yakın bölgedeki hızlardan daha yüksektir. Dolayısıyla bölünen akımın tabana yakın akım çizgileri çevirme kanalına daha geniş bir açı ve yumuşak bir eğrilikle girecekken yüzeye yakın akım çizgileri ise daha dar bir açı ve keskin bir eğrilikle girecektir [1], [2]. Aynı nedenle bölünen akım tabana yakın kısımda daha geniş olacak ve yüzeye doğru daralacaktır. Bölünen akımın ana kanal yönündeki momentum bileşeninin yüzeye yakın bölgede daha büyük olması sonucunda ise resirkülasyon bölgesi su yüzeyi civarında daha geniş olacak, tabana doğru daralacak ve çevrilen akımın su yüzeyine yakın kısmı, resirkülasyon bölgesi tarafından daha çok bloke edilecektir. Tabana yakın akım çizgilerinin yukarıda belirtilen özellikleri de göz önüne alındığı zaman çevrilen suyun büyük kısmının tabana yakın bölgeden alındığı görülmektedir [1], [2]. Bu durum, literatürde Bulle Etkisi olarak bilinen, çevrilen su debisiyle orantısız miktarda büyük sediment debisinin çevirme kanalına girmesine yol açabilmektedir. Ana kanal, çevirme kanalı ve akım bölünmesi sonucu oluşan akım yapıları Şekil 1’de gösterilmiştir. Bölünen akım çizgileri tam olarak çevirme kanalı mansap köşesinde (B noktası) birleşmemekte, ana kanal mansabı yönünde küçük bir miktar uzamaktadır [3].

Çevrilen akımın B noktasına bitişik duvarlara (ana kanal iç duvar mansabı ve çevirme kanalı dış duvarı) çarpması ile birlikte duvarlarda meydana gelen aşağı yönlü akımlar neticesinde biri ana kanal iç duvarı, diğeri ise çevirme kanalı dış duvarı boyunca sekonder akımlar gelişmektedir.



Şekil 1. Kanal sisteminin temsili

Bu sekonder akımlar [4] tarafından bağımsız vorteksler olarak tanımlanmış, daha sonra [3] tarafından tıpkı at nalı vorteksinde olduğu gibi aşağı yönlü akımların kanal doğrultusundaki akımlarla etkileşerek iki kollu bir vorteks sistemi oluşturduğu ve bu sekonder akımların aynı vorteks sisteminin birer kolu olduğu ileri sürülmüştür. Bu vorteks kolları, buldukları kanal tabanında aşağı yönlü akım nedeniyle başlayan oyulmayı artırmakla birlikte çevirme kanalındaki vorteks kolu, aynı zamanda ana kanaldan taşınan sedimentin akım hızlarının küçük olduğu resirkülasyon bölgesinde depolanmasına ve bu bölgede sığlaşmaya neden olmaktadır.


Hareketli tabana sahip açık kanal akımlarının hidromorfodinamik doğasının detaylı olarak incelenerek bu olumsuz durumların engellenmesine ya da en aza indirilmesine dikkat edilmesi gerekmektedir. Bunun için de akım bölünmesi nedeniyle akım yapılarında ve tabanda meydana gelebilecek değişiklikler önceden tahmin edilebilmelidir. Bu amaçla [3] tarafından gerçekleştirilen, her iki kanalın da hareketli tabana sahip olduğu bir deney Flow-3D Hydro paket programında simüle edilmiş, çatallanma bölgesindeki akım yapıları ve taban gelişimi incelenmiş ve tartışılmıştır.

Model Özellikleri

[3]’ün laboratuvar deneylerini gerçekleştirdikleri açık kanal sistemi aynı boyutlarda modellenmiştir. Ana kanal 9 m uzunluğunda ve $B = 0,67$ m genişliğinde, ana kanala memba ucundan 3,2 m uzaklıkta ve $\theta = 90^\circ$ açıyla bağlı olan çevirme kanalı ise 2,17 m uzunluğunda ve $b = 0,25$ m genişliğindedir. Test bölgesi bu ölçülerle aynı olup, 0,85 mm medyan tane çapına sahip üniform taban malzemesi ile kaplanmıştır. Taban malzemesinin kalınlığı ana kanal mansap ucunda 0,17 m’dir ve ana kanal başlangıç taban eğimi memba eşiği ile 0,001 olacak şekilde, deney düzeneğine paralel olarak, modellenmiştir.

Her biri üç doğrultuda da eşit uzunlukta hücrelere sahip olan beş adet mesh bloğu tanımlanmıştır. Ana kanalın ilk 2 ve son 5 m’si ile çevirme kanalının son 1,2 m’sinin hücre uzunluğu 0,02 m, kalan iki mesh bloğunun hücre uzunluğu akım ayırımının daha yüksek doğrulukla simüle edilebilmesi için 0,01 m olarak belirlenmiştir. Tanımlanan mesh ağı toplamda 657120 hücreye karşılık gelmektedir. Ana kanal memba sınır şartlarında başlangıç akım derinliği 0,08 m’ye tekabül eden sabit su seviyesi belirlenmiş, su ve sediment (besleme) debileri deneyle aynı olacak şekilde sırasıyla $0,029 \text{ m}^3/\text{s}$ ve $12 \text{ kg}/\text{sa}$ sabit

olarak tanımlanmıştır. Ana kanal mansabındaki su derinliği 0,07 m olarak sabitlenmiştir. Mesh bloklarının ortak yüzeyleri yazılım tarafından otomatik olarak belirlenmektedir, diğer sınırlar ise duvar olarak tanımlanmıştır. Bu durumda çevirme kanalındaki çıkış debisinin sağlanması için bu kanalın mansabında bir adet “kütle momentum kaynağı” tanımlanmış ve 2,2 L/s debideki akım bu kaynaktan çekilerek sistemden çıkarılmıştır. Çevirme kanalında batık akımın mevcut olduğu deneysel koşullarda da aynı miktardaki debi pompa ile çekildiğinden seçilen yöntemin deneysel karşılığına göre uygun olduğu görülmektedir. Başlangıç şartlarına 0,07 m derinliğinde ve 0,45 m/s ortalama hıza sahip bir akım tanımlanarak başlangıç akımının tabanda yaratacağı etkiler en aza indirilmiştir. Modelin genel görüntüsü Şekil 2’de koordinat sistemi ile birlikte verilmiştir. Şekilde mesh blokları numaralandırılarak MB ile ifade edilmiştir, A noktası $(x,y) = (0,0)$ koordinatını ifade etmekte birlikte $z = 0$ koordinatı sediment tabakasının en alt seviyesine denk gelmekte ve yukarı yönde artmaktadır.



Şekil 2. Modelin genel görüntüsü

Kullanılan Denklemler

Akım Denklemleri

Flow-3D Hydro yazılımı VOF (Akışkan Hacmi) yöntemini kullanır ve üç boyutlu süreklilik (Denklem 1) ve Navier-Stokes (Denklem 2) denklemlerini aynı anda çözer. Akım ayrımı bölgesindeki üç boyutlu akım yapılarının karmaşıklığı oyulmanın zamana bağlılığı göz önüne alındığında, LES türbülans modelinin kullanılması uygun görüldü. Çok sayıda çalışma [5]-[7] LES türbülans modelinin, simülasyon süresi pahasına $k-\omega$, $k-\epsilon$ veya RNG gibi RANS modellerinden daha hassas bir şekilde akışın karşılıklı ve üç boyutlu özelliklerini temsil ettiğini öne sürmektedir.

$$\frac{\partial}{\partial x_i} u_i A_i \quad (1)$$

$$\frac{\partial u_i}{\partial t} + \frac{1}{V_f} \left(u_j A_j \frac{\partial u_i}{\partial x_j} \right) = -\frac{1}{\rho_f} \frac{\partial P}{\partial x_i} + G_i + f_i \quad (2)$$

Burada u_i , i yönündeki hızı; A_i , i yönündeki kısmi alanı; V_f , akıma açık kısmı hacmi; ρ_f , suyun yoğunluğunu; P , basıncı; G_i , cisim ivmelerini, f_i , viskoz ivmeleri temsil eder.

LES modeli, hesaplanmayacak kadar küçük olan türbülansın etkilerini temsil etmesi için Denklem (3) ile hesaplanan mesh ağının uzunluk ölçeğine (L) ihtiyaç duyar [8]:

$$L = (\delta_x \delta_y \delta_z)^{1/3} \quad (3)$$

Burada δ_x , δ_y , ve δ_z , x , y ve z yönlerindeki hücre boyutudur. Bu durumda LES türbülans modelindeki kinematik türbülans viskozitesi (ν_T) Denklem (4) ile hesaplanır:

$$\nu_T = c_s^2 \sqrt{2e_{ij}e_{ij}} \quad (4)$$

olarak tanımlanır. Smagorinsky katsayısı, c_s , varsayılan olarak 0,1 alınmıştır. e_{ij} kayma gerinimi hız tensörü Denklem (5)’ten bulunur:

$$e_{ij} = \frac{1}{2} \left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right) \quad (5)$$

Son olarak momentum denklemlerinde kullanılmak üzere ν_T dinamik viskozite (μ) denkleminde (Denklem 6) dahil edilir:

$$\mu = \rho_f (\nu + \nu_T) \quad (6)$$

Burada ν , akışkanın kinematik viskozitesidir.

Sediment Taşınımı Denklemleri

Flow-3D Hydro’nun sediment taşınımı modülü, kohezyonsuz sedimentinin toplam yükünü: i) askıdaki yükü, ii) sürüklenen yükü (tanelerin yükselmesi ve çökmesi) ve iii) taban yükünü (tanelerin yuvarlanması, sıçraması, kayması) ayrı ayrı hesaplayarak simüle eder.

Kaldırma hızı, taban malzemesinin askıdaki yüke dönüşecek miktarını belirlemek için (ω_l) [9] Denklem (7) ile hesaplanır:

$$\omega_l = \alpha n_s d_*^{0,3} (\theta - \theta_c)^{1,5} \sqrt{\frac{\|g\| d (\rho - \rho_f)}{\rho_f}} \quad (7)$$

Burada α , 0,018 olarak tavsiye edilen sürüklenme parametresi [9]; n_s , tabanın dışına doğru yönelen normal vektör; θ , yerel Shields parametresi; θ_c , tabanda sediment hareketinin başlaması için kritik Shield değeri; $\|g\|$ yerçekimsel ivmenin büyüklüğü; d , tane medyan çapıdır. d_* boyutsuz tane çapı ise Denklem (8)’den hesaplandıktan sonra:

$$d_* = d \left[\frac{\rho_f (\rho - \rho_f) \|g\|}{\mu^2} \right]^{1/3} \quad (8)$$

taban kayma gerilmesi (τ) ile birlikte yerel Shields parametresinin hesaplanmasında (Denklem 9) kullanılmaktadır:

$$\theta = \frac{\tau}{\|g\| d (\rho - \rho_f)} \quad (9)$$

Kritik Shields değeri ise Shields diyagramından $\theta_c = 0,032$ olarak bulunmuştur. Sürüklenen yükünü elde

etmede kullanılan çökeltme hızı [10]'un denkleminde (Denklem 10) hesaplanmaktadır:


$$\omega_s = \frac{g}{\|g\|} \frac{v}{d} [(10,36^2 + 1,049 \cdot d_*^3)^{0,5} - 10,36] \quad (10)$$

Son olarak toplam hacimsel sediment yükünün (q_s) hesaplanması için [11]'in önerdiği denklem (Denklem 11) kullanılmıştır:

$$q_s = 8(\theta - \theta_{cr})^{1,5} \left[\|g\| \left(\frac{\rho - \rho_f}{\rho_f} \right) d^3 \right]^{0,5} \quad (11)$$

Bulgular ve Tartışma


Testin ilk saniyelerinden itibaren sediment taşınımı sonucu ana kanal taban seviyesinde azalma meydana gelmiş ve ana kanal boyunca mansaba doğru hareket eden kumul oluşumları gözlenmiştir. Özellikle mesh çözünürlüğünün daha yüksek olduğu MB2 bölgesinde (Şekil 2) belirginleşen (Şekil 3) kumulların ortalama yüksekliği 2 cm, ortalama uzunluğu 1,5 m olarak kaydedilmiştir. Kumulun şekline göre ana kanal iç duvar tarafından kısmi çevirme çekilmiştir ve orta kısmı da bu doğrultuda bir eğimle ana kanalda harekete devam etmiştir. Çevirme kanalına çekilen sedimentin büyük çoğunluğu bu kumul geçişleri sırasında meydana gelmektedir [12]. Çevirme kanalının memba köşesinde bitişen iki duvarın tabanlarında başlangıç taban seviyesine göre $\Delta z = -10$ cm'e kadar derinleşen oyulma hendekleri görülebilmektedir. Oyulma hendeklerinin en büyük derinlikleri yaklaşık aynı olmakla birlikte ana kanaldaki hendek çok daha uzundur ve mansaba doğru genişliği artmaktadır. Çevirme kanalının her iki duvarı boyunca sediment yükünden dolayı taban seviyesinde bir yükselme görülmektedir. Bu yükselmenin bir sebebi, su debisi ile orantısız miktarda çekilen sediment debisi, diğer sebebi de çevirme kanalındaki akımın sahip olduğu kayma hızının sediment hareketi için yeterince büyük olmamasıdır. Bulgular önceki çalışmalar [3],[4] ile uyumlu olup, çevrilen akımın kayma hızı yeterli seviyeye gelene kadar taban seviyesinin yükselmesi beklenmektedir. Orijinal deneyde tabanın denge durumuna ulaşması yaklaşık 18 saat sürmüştür, denge durumuna ulaşıldıktan sonra zamana bağlı (kararsız) değişimlerin yorumlanabilmesi için ise deney 6 saat daha devam ettirilmiştir. Mevcut modelin 24 saatlik bir simülasyonu 360 günde tamamlayacağı öngörüldüğünden taban şekilleri ve akım yapıları yorumlanabilecek ölçüde geliştikten sonra simülasyon sonlandırılmıştır. Çalışma kapsamında nihai oyulmalar ve sediment debileri araştırılmadığı için taban denge durumuna ulaşmadan simülasyonun sonlandırılmasının mevcut bulgu ve tartışmalara önemli ölçüde etki etmeyeceği düşünülmektedir.



Şekil 3. Test sonunda çatallanma bölgesinin taban morfolojisi


Taban yakın akım çizgileri Şekil 4'te verilmiştir. Şekilde görülebileceği üzere tabana yakın akımın ana kanal dış duvarından itibaren $0,17B$ genişliğindeki kısmı, görülebilir bir sapma yapmadan aynı doğrultuda devam etmiştir. Tabana yakın akımın ana kanal iç duvarından yine $0,23B$ genişliğindeki kısmı ise çevirme kanalına sapmıştır. Ana kanalın orta bölgesindeki kalan $0,6B$ genişliğindeki akım ise ana kanal doğrultusundan çevirme kanalına doğru sapmış, fakat çevirme kanalına girmeden ana kanalda devam etmiştir. Yüze yakın akım analiz edildiğinde akım çizgilerinin ana kanal iç duvarına çok yakın ($\approx 0,1B$) kısmı çevirme kanalına girdiği ve resirkülasyon bölgesine girmeden çevirme kanalı dış duvarı boyunca devam ettiği görülmüştür. Bu durumda tabana yakın ayrılan akım sınırının su yüzeyine yakın ayrılan akım sınırına göre ana kanal iç duvarından 2,3 kat daha uzaktadır. [1] tarafından pürüzlü cidarlar için bu oran yaklaşık 2,2 olarak bulunmuştur ve elde edilen bulgularla uyumludur.

Çevrilen akımın mansapta kontrol ediliyor olması nedeniyle bu kanalda batık akım durumu mevcuttur ve dolayısıyla her iki kanalın su yüzeyi seviyelerinde önemli ölçüde bir değişim gözlenmemiştir. Yalnızca çevirme kanalı mansap köşesi etrafında ayrılan akımın duvara çarpması nedeniyle $d/4 = 2$ cm yüksekliğinde yerel bir kabarma görülmüştür.




Şekil 4. Tabana yakın bölgedeki akım çizgileri

Çevirme kanalı girişi mansap köşesinden ana kanal mansabına doğru 0,2b uzaklıkta ($x = 3,5$ m) bir enkesit alınarak bu enkesitteki hız bileşenleri Şekil 5'te incelenmiştir. Bu enkesit aynı zamanda ana kanaldaki oyulma hendeğini de içermektedir. Akımın ana kanal doğrultusundaki hız bileşeni, u , beklenileceği üzere tabana doğru azalmakla birlikte akımın çevirme kanalına doğru sapmış olmasından ve enkesit genişlemesinden dolayı ana kanal dış duvarında iç duvarına oranla daha küçüktür. Benzer şekilde [12] de akım hızının ana kanal iç duvarı bölgesinde yüksek olduğunu gözlemlemiştir. Oyulma hendeğinin en derin noktasında ise u bileşeninin negatif bölgeye geçtiği görülmektedir. Akımın ana kanal iç duvarına doğru saptığı, hızın yatay doğrultudaki v bileşeninden görülebilir. Ana kanal dış duvarı boyunca bu bileşen çok küçükken iç duvara doğru artmakta ve duvar ile temas ettiği noktada tamamen aşağı yönlü akım oluşmaktadır. Aşağı yönlü akım bu bölgedeki oyulmanın başlıca sebebi olmakla birlikte ana akım ile birleşmesi neticesinde oluşan vorteks (Şekilde kaba hatları ile gösterilmiştir), oyulma hendeğinin boyutlarını daha çok büyütmektedir. Bu vorteks, giriş kısmında bahsedilen iki kollu vorteks sisteminin ana kanaldaki koludur.


Şekil 5. $x = 3,5$ m'de ana kanal enkesiti ve hız bileşenleri

Çevirme kanalı girişinden çevirme kanalı mansabına doğru 0,2b uzaklıkta ($y = -0,05$ m) bir enkesit alınarak bu enkesitteki hız bileşenleri Şekil 6'da incelenmiştir. Akımın hız bileşeni v 'nin en yüksek değerleri çevirme kanalı dış duvarı boyunca, daralma bölgesinde kaydedilmiştir. Çevirme kanalı iç duvarına doğru bu değer azalarak sıfıra ulaşmakta ve resirkülasyon bölgesi

içinde v bileşeni yön değiştirmektedir. Resirkülasyon bölgesinin tabana doğru daralan kesiti de şekilde görülebilir. Çevirme kanalı dış duvarı civarında akımın düşey yöndeki hız bileşenine (w) göre kuvvetli bir aşağı yönlü akım mevcuttur. Aşağı yönlü akım ile çevrilen akımın birleşimi, vorteks sisteminin çevirme kanalındaki kolunu oluşturmaktadır. Aşağı yönlü akımın başlattığı oyulmayı büyüten bu vorteks, hem bu bölgeden oyulan hem de ana kanaldan çekilen sedimenti resirkülasyon bölgesi içine taşımaktadır.

Şekil 7. $y = -0,05$ m'de çevirme kanalı enkesiti ve hız bileşenleri

Şekil 7'de resirkülasyon bölgesinin su yüzeyine yakın kısmındaki hız bileşenlerine örnek olarak 0,24 cm su seviyesinde alınan kesit sunulmuştur. Akımın u ve v hız bileşenlerine dikkat edildiğinde çevrilen akımın çevirme kanalı memba köşesinden ayrılması, çevirme kanalı iç duvarında yeniden birleşmesi ve bu arada kalan resirkülasyon bölgesi görülebilir. Daha önce de belirtildiği üzere en yüksek hızlar çevirme kanalı dış duvarı civarında kaydedilmiş, mansaba doğru enkesit genişlemesi nedeniyle çevirme kanalı iç duvarına doğru görece bir artış ve sapma meydana gelmiştir.

Şekil 7. $z = 0,24$ m'de çevirme kanalı kesiti ve hız bileşenleri

Sonuçlar

Hareketli tabana sahip 90°'lik bir çevirme kanalında kararlı akım şartlarında Flow-3D Hydro paket programı ile nümerik bir çalışma gerçekleştirilmiştir. Çevirme kanalının mansap köşesine bağlı her iki duvar boyunca derin oyulma hendekleri oluşmuştur. Ana kanal oyulma hendeği içinden çıkan malzeme bu hendeğin mansabına, çevirme kanalı oyulma hendeğinden çıkan malzeme ise bu hendeğin mansabı ile birlikte çevirme kanalı iç duvarına yakın bölgeye taşınmıştır. Oyulma hendeklerinin oluştuğu bölgelerde aşağı yönlü akımlar ve bu akımların sonucu olarak oyulma hendekleri içinde gelişen vorteks sistemleri tespit edilmiştir. Literatür ile uyumlu olarak akımın daha büyük bir bölümünün tabana yakın bölgeden çevirme kanalına girdiği gözlenmiş, tabana yakın ayrılan akım sınırının su yüzeyine yakın ayrılan akım sınırına göre iç duvardan 2,3 kat daha uzakta olduğu tespit edilmiştir. Çevirme kanalında batık akım olması nedeniyle su yüzü seviyelerinde önemli bir değişim gözlenmemiş, yalnızca çevirme kanalı mansap köşesinde çarpma etkisi nedeniyle $d/4 = 2$ cm yüksekliğinde bir kabarma gerçekleşmiştir.

Kaynaklar

- [1] V. S. Neary, and A. J. Odgaard, "Three-dimensional flow structure at open-channel diversions," *J. Hydraul. Eng.*, vol. 119, no. 11, pp. 1223-1230, Nov. 1995.
- [2] R. N. S. Lakshmana, K. Sridharan, and M. Y.A. Baig, "Experimental study of the division of flow in an open channel," in *Australasian Conf. on Hydraul. and Fluid Mech.*, Sydney, Australia, 1968, pp. 139-142.
- [3] F. Gungum, and A. H. Cardoso, "Effect of diversion angle and vanes' skew angle on the hydro-morphodynamics of mobile-bed open-channel bifurcations controlled by submerged vane-fields," *Phys. Fluids.*, vol. 36, no. 7, July. 2024. DOI: 10.1063/5.0211623
- [4] A. Herrero, A. Bateman, and V. Medina, "Water flow and sediment transport in a 90 channel diversion: an experimental study," *J. Hydraul. Res.*, vol. 53, no. 2, pp. 253-263, Jan. 2015.
- [5] W. Rodi, "Comparison of LES and RANS calculations of the flow around bluff bodies," *J. Wind Eng. Ind. Aerod.*, vol. 69-71, pp.55-75 July-Oct. 1997.
- [6] G. Kirkil, S.G. Constantinescu, and R. Ettema, "Coherent structures in the flow field around a circular cylinder with scour hole," *J. Hydraul. Eng.*, vol. 134, no. 5, pp. 572-587, May. 2008.
- [7] H. Li, S. Balachandar, and J. Sansalone, "Large-eddy simulation of flow turbulence in clarification systems," *Acta Mech.*, vol. 232, no. 4, pp. 1389-1412, Feb. 2021.
- [8] Flow-3D Hydro 2022R1 User Manual, 2022.
- [9] D. R. Mastbergen, and J.H. Van Den Berg, "Breaching in fine sands and the generation of sustained turbidity currents in submarine canyons," *Sedimentology*, vol. 50, no. 4, pp. 625-637 July. 2003.
- [10] R. L., Soulsby, "Dynamics of Marine Sands," Thomas Telford, 1997.
- [11] E. Meyer-Peter, and R. Müller, "Formulas for bed-load transport," in *IAHSR 2nd meeting*, Stockholm, Sweden, 1948, appendix 2.
- [12] B. D. Barkdoll, R. Ettema, and A. J. Odgaard, "Sediment control at lateral diversions: limits and enhancements to vane use," *J. Hydraul. Eng.*, vol. 125, no. 8, pp. 862-870, Aug. 1999.
- [13] A. A. Shettar, and K. Keshava Murthy, "A numerical study of division of flow in open channels," *J. Hydraul. Res.*, vol. 34, no. 5, pp. 651-675 June. 1996.



Comparative Analysis of HEC-RAS, SWMM, and THDH Approaches in Highway Culvert Design

Kağan CEBE¹, Ömer BİLHAN^{2*}, Renan SINANMIŞ BALCI³

¹ Ondokuz Mayıs University, Civil Engineering Department, kagan.cebe@omu.edu.tr, Orcid No: 0000-0003-1288-1362

² Nevşehir Hacı Bektaş Veli University, Civil Engineering Department, omerbilhan@nevsehir.edu.tr, Orcid No: 0000-0002-8661-6097

³ Nevşehir Hacı Bektaş Veli University, Civil Engineering Department, renansinanmisbalci@nevsehir.edu.tr, Orcid No: 0009-0000-7750-9073

ARTICLE INFO

Article history:

Received 23 September 2024

Received in revised form 3

November 2024

Accepted 6 November 2024

Available online 23 December 2024

Keywords:

culvert, hec-ras, swmm, rational method, hydrodynamic model

Doi: 10.24012/dumf.1555019

* Corresponding author

ABSTRACT

In this study, Hydrologic Engineering Center River Analysis System (HEC-RAS), Storm Water Management Model (SWMM) and Turkish Highway Design Handbook (THDH) approaches were examined in highway culvert design and the methods were compared on a sample highway culvert to show the differences in design calculations. A box type culvert, made of reinforced concrete and with dimensions of 3 meters in width and 2 meters in height, will be constructed at the intersection of the Kocaçay stream and the Nevşehir Avanos D302 highway at KM:800m. The culvert is designed to carry the 10-year and 100-year design flow rates calculated using the Rational method. The design flow conditions, and water levels of the culvert is originally designed according to THDH. The culvert along with the flow route up to a certain distance, upstream and downstream is modelled by using HEC-RAS and SWMM. The water levels obtained from the models were compared with the THDH design results. The hydraulic design of the culvert is conducted under inlet control conditions in all methods, however, with the discrepancies in the calculated headwater and tailwater depths. The nomogram method suggested in the THDH provides a practical means for determining headwater depth, tailwater depth and culvert dimensions. However, it does not adequately address the channel sections upstream and downstream of the culvert and the relevant flow conditions. To evaluate the environmental effects of the design flow rates of culverts, especially those located near residential areas, it is recommended to use HEC-RAS and similar GIS-supported modeling tools in hydraulic calculations.

Introduction

Culverts are tunnel-like structures that have been built since ancient times to cross roads and waterways and provide transportation over streams. Culvert structures, which are typically buried to be surrounded by soil, may consist of a pipe, or be made of reinforced concrete or another material. A culvert may cause an increase in upstream water surface elevations due to its restrictive cross-section forcing the upstream flood levels to be several meters higher than they would be without the culvert and the embankment [1].

The hydraulic design of culverts on highways is carried out with equations and nomograms obtained depending on the type of culvert and the upstream and downstream conditions created by the flow. The equations and nomograms are based on experimental data to estimate the flow characteristics of culverts. These equations and nomograms, such as those developed by Barr, Hydrologic Engineering Center (HEC), and Federal Highway Administration (FHWA), provided standardized methods for estimating flow capacity based on culvert size, shape, and other parameters. Hydraulic Design of Highway Culverts introduced by the Federal Highway Administration aims to provide information for the planning and hydraulic design of culverts. [2]. The FHWA

has devised a methodical process for culvert analysis, which relies on different flow types as categorized by the U.S. Geological Survey. These flow types are determined by factors such as inlet and outlet submergence, flow regime within the culvert, and downstream brink depth [3]. The hydraulic design of culverts in Turkey is carried out according to the Turkish Highway Design Handbook (THDH) published by the General Directorate of Highways [4].

The HEC-RAS program operates on the principles of Saint-Venant hydraulic equations, which facilitate the estimation of floodplain dimensions, determination of water surface elevations, and distribution of flood velocities. The utilization of mathematical models is crucial and valuable in such hydrological simulations [5]. It can be inferred that HEC-RAS demonstrates a high degree of accuracy in forecasting water levels and areas impacted by flooding during extreme hydrological events, even when input data are relatively limited [6].

When it comes to creating safety and control during extreme flooding situations, HEC-RAS is a helpful tool [7]. Hydrodynamic models can be classified as one-dimensional (1D), two-dimensional (2D) and three-dimensional (3D) models according to the size of the physical phenomenon.

In many applications of river flow modeling, a one-dimensional hydrodynamic modeling system is used. The Hydrological Engineering Center-River Analysis System (HEC-RAS) is a well-known model that simulates 1D and 2D unsteady flow in open channels and floodplains [8]. In 2016, Maharjan and Shakya [9] conducted one-dimensional and two-dimensional surface flow analyses in Nepal using HEC-RAS and other software. Wang performed a water surface profile analysis on an existing project using the HEC-RAS model in his study [10]. Model performance evaluation was conducted using observed data collected from five nested measurement sites in a mixed land-use watershed of the central United States by Zeiger J.S. et al. [11]. In their study, the authors used an integrated modeling approach to combine the Soil and Water Assessment Tool (SWAT version 2012) with the Hydrological Engineering Center's River Analysis System (HEC-RAS version 5.0.7).

Thalakkottukara et al. [12] mapped the flood inundation in Huron Creek watershed, Michigan, USA for an extreme rainfall event in 2018 (Father's Day Flood) using the Height Above Nearest Drainage (HAND) model and a synthetic rating curve developed from the Laser Imaging Detection and Ranging Digital Elevation Model (LIDAR DEM). The flood was evaluated as 1000-year return period flood and its inundation characteristics predicted by two hydrodynamic models, viz., HEC-RAS and Sedimentation and River Hydraulics 2 Dimensional Model (SMSSRH 2D).

The Storm Water Management Model (SWMM), on the other hand is used for planning, analysis, and design regarding storm water runoff, combined and sanitary sewers, and other drainage systems. SWMM calculates water profiles of unsteady flows of open and/or closed free-surface channel systems using dynamic flow routing [13].

Culverts are often engineered to accommodate a designated discharge without causing an excessively high depth of water upstream. Therefore, for an engineer to effectively design a culvert, they must be able to accurately forecast the depth of water upstream for the designated discharge. To achieve this, the design discharge and flow conditions are calculated through hydrologic and hydraulic analysis in the water collection area of the flow reaching the culvert. Since the 1980, computer programs and hydrodynamic models have begun to be used in culvert design, especially to obtain water surface profiles. The use of geographical information systems (GIS) has greatly simplified the development of input data necessary for most hydrologic and hydraulic calculations for the design of culverts. In this study, the methods were applied to an example of a highway culvert calculation in order to compare the HEC-RAS, SWMM, and THDH approaches in highway culvert design.

Materials and Methods

Study Area

The study area is located on a branch of the Kocacay stream, which is in the Kizilirmak basin in the Central Anatolia region and passes through the city center of Nevsehir province, Cappadocia, Türkiye. (Fig. 1). Nevsehir, located in Central Anatolia, lies between approximately 38-39°

north latitude and 34-35° east longitude. Geographically, it is situated almost in the center of Turkey. The area of the city is 5,467 km². Brown soils, a common soil type in Central Anatolia, cover a wide range in Nevsehir. The Erciyes volcanic region is also positioned near the borders of this area. Nevsehir, located at the heart of Cappadocia, where nature, history, and culture come together, welcomes around 4 million tourists from all over the world annually [14].



Figure 1. Study area [15]

The Kocacay stream originates from a basin spanning 3688 ha area near the center of Nevsehir city. It flows during rainy seasons and remains dry during dry seasons. After passing through an open reinforced concrete channel and two culverts along Nevsehir city center, Kocacay stream merges with Karaagac stream near Nar district and reaches Kizilirmak river. General Directorate of Highways of the Republic of Türkiye is planning to build a reinforced concrete culvert with dimensions of 3m (horizontal) x 2m (vertical) at the point where the Kocacay stream intersects the Nevsehir - Avanos D302 highway at 800m (Fig. 2).

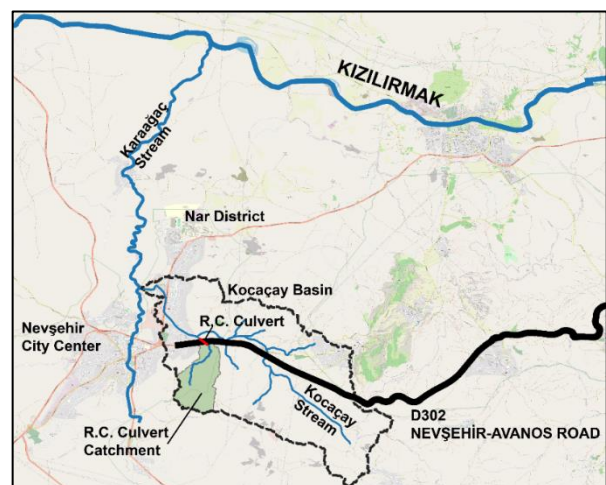


Figure 2. Kocacay stream and location of RC culvert

The sections upstream of the culvert are natural land sections. Downstream of the outlet of the culvert, the city municipality constructed an open channel with a trapezoidal cross-section, characterized by a concrete slab base with 2m width and side slopes covered with concrete grass stones (Fig. 3).



Figure 3. Culvert inlet (a), outlet (b) and open channel downstream of the culvert (c, d)

The elevation map of the study area was created using digital elevation maps (DEM) with globally 12.5m high resolution ALOS PALSAR (Advanced Land Observing Satellite Phased Array L-band Synthetic Aperture Radar) remote sensing tool, compiled by the Alaska Satellite Facility (ASF), using satellite radar interferometry within the scope of the Radiometric Terrain Correction Project [16]. According to the elevation map prepared by using QGIS 3.28.3 [17] geographic information system (GIS) software, the Kocacay stream basin have a surface area of 3688ha. The hill formations are generally seen in the southern and eastern parts of the basin, where the drainage area of the culvert is located. (Fig. 4). Although the catchment of the culvert has a small surface area, the location of the culvert is sensitive to flood risks due to its proximity to Nevşehir central residential areas.




Figure 4. Elevation map of Kocacay stream basin

The lowest altitude is 1124m, the highest altitude is 1522m in the Kocacay basin, and the average altitude of the basin is 1314m. Surface runoff within the catchment area is

channeled through densely packed hill formations to the lower regions in the north. The flow rate transmitted by the reinforced concrete culvert facing north consists of surface flow accumulated in a 278ha drainage area.

The culvert's drainage area is narrower downstream but widens significantly upstream. In such a configuration, the flood flow rate is higher compared to the reverse scenario, contrarily the time taken to reach the peak and sustain the flood is shorter [18].

In the culvert drainage area, which is mostly covered with a low permeable soil surface and small trees such as shrubs and fruit trees, the lowest altitude is 1207m, the highest altitude is 1634m and the average altitude is 1397m. In the Kocacay basin, the minimum slope was determined as 0%, the maximum slope was 38.00% and the average slope was 6.65%. In the drainage area of the culvert, the minimum slope was calculated as 0.61%, the maximum slope was 61.92% and the average slope was 20.63%. While a general slope of 0-10° is observed in the basin, when the reinforced concrete culvert and its surroundings are examined, it is seen that the slope values increase and are predominantly in the range of 20-30°.

Calculation of Design Flow Rate with Rational Method

When designing culverts, the initial step involves delineating the boundaries of the basin area and estimating the precipitation within these regions. The flow of floodwater triggered by precipitation can be computed using a selected method based on the basin area (drainage area). Typically, the Rational Method is suitable for rainfall basins up to 15 km², while the synthetic unit hydrograph method is preferred for larger areas [18].

In both approaches, the 10-year, 100-year, and 500-year flood recurrence flows can be calculated based on meteorological data. The flow rates originating from the drainage area of the culvert for both the 10-year and 100-year recurrence intervals were determined using the Rational Method.

The maximum flow to the culvert is calculated using parameters such as the runoff coefficient (C, %), which shows the ratio of flow to precipitation, precipitation intensity according to recurrence years (i, mm/hour) and runoff area (A_r, km²). According to the Rational Method, the flood flow rate (Q) that may occur as a result of the precipitation intensity (i) is calculated with the Eq.1 assuming that precipitation falls homogenously in every region of the basin [18], [19], [20]:

$$Q_{max} = \frac{CiA_r}{3.6} \quad (1)$$

The runoff coefficient (C) in Eq.1 varies depending on factors such as the topographic condition of the basin, the type of ground near the surface, and the density of vegetation [21]. While C takes values between 0.70-0.95 on impermeable surfaces, it takes values between 0.25-0.35 in gardens with heavy soil where the slope is higher than 7% [22]. The hydrological parameters of the drainage area of

the culvert and the maximum flow rate calculated using the Rational Method are shown in Table 1.

Table 1. Hydrological parameters of culvert drainage area and design flow rate

Area (km ²)	Meteorological Station / No	I ₁₀ (mm/h)	I ₁₀₀ (mm/h)	Flow Coefficient C	Design discharge for 10year return period Q ₁₀ (m ³ /s)	Design discharge for 100year return period Q ₁₀₀ (m ³ /s)
2.780	Nevsehir/17193	27.00	41.00	0.60	12.51	19.00

The time of concentration (T_c) is the time that it takes for runoff to travel from the most remote upstream point in the drainage area to the downstream point and comprises two components: (1) the time taken for precipitation to travel from the catchment basin surfaces to the channel entrance at the top (t₀, in minutes), and (2) the time required for water within the channel to reach the outlet point at the bottom (Σt_i, in minutes). It is defined by the Eq. 2, 3 and 4 as outlined by Şen [20]:

$$T_c = t_0 + \Sigma t_i \tag{2}$$

$$t_0 = 60 \left[0,87 \frac{d^3}{dh} \right]^{0,385} \tag{3}$$

$$t_i = \frac{d_i}{60v_i} \tag{4}$$

In Eq. 2, 3 and 4, d(km) is the longest distance that runoff water will travel until it enters the channel, d_h(m) is the altitude difference between the beginning and end of the flow path, d_i(m) is the drainage length, v_i(m/s) is the design velocity within the drainage area. When determining the time required to reach the outlet point at the downstream, it is necessary to calculate the total number of distinct channels within the drainage area based on the specific design velocity for each channel [20].

The topographic parameters of the runoff area are shown in Fig.5. The L₁, L₂ distances, H₁, H₂, H₃ elevations, average slope of each distinct channel, design flow velocity of the runoff and the collection time calculated according to the Rational Method are listed in Table 2.




Figure 5. Topographic parameters of the Rational Method

Table 2 Topographical parameters of the drainage area and time of concentration

Elevation (m)			Distance (m)		Slope		Flow velocity (m/s)		Concentration time (min.)		Total concentration time (min.)
H ₁	H ₂	H ₃	L ₁	L ₂	J ₁	J ₂	v ₁	v ₂	t ₀	t ₁	T _c
1570	1480	1210	209	3375	0.431	0.080	0.300	0.219	11.61	26.86	38

Application of the THDH Approach in Determining Culvert Dimensions

The culvert was originally designed according to the THDH [4]. To determine the culvert design dimensions, the culvert operating condition must be selected. Similar to Federal Highway Administration’s Hydraulic Design of Highway

Culverts two operating conditions are defined for culvert design [23]. These are:

- Inlet control: The culvert barrel is capable of conveying more flow than the inlet will accept.
- Outlet control: The culvert barrel is not capable of conveying as much flow as the inlet opening will accept.

The studied culvert was considered to be operated in inlet control conditions, and two types of operating conditions for inlet control are given in Fig. 6, namely unsubmerged and submerged inlet [4].




Figure 6. Operating conditions for inlet control (Type I and Type II) [4]

According to THDH [4], in Type I inlet control culverts, since the inlet water height (H_w) is less or equal to 1.2 times culvert height (a), no surge is to be considered at the inlet. This type of flow condition occurs when the natural stream bed is relatively low-sloping and wide and are the culvert dimensions are chosen to adequately accommodate the design flow. Critical velocity condition occurs at the outlet section of the Type I culvert. In Type II inlet control culverts, since the inlet water height (H_w) is greater than 1.2 times culvert height (a), the culvert is operating in submerged inlet condition. In both types of inlet-controlled culverts, the amount of surge at the inlet is calculated according to the Surge Determination Nomogram for inlet control culverts in the THDH [4].

Culvert dimensions are verified with the help of nomograms based on the culvert width (b). By using the design discharge (Q_{10} , Q_{100}), culvert slope (S_m) and critical slope (S_k) as variables in the nomograms, normal depth (D_n) and normal velocity (V_n) as well as critical depth (D_k) and critical velocity (V_k) are calculated. Manning's equation is used to verify the flow rate in selected culvert dimensions:

$$Q = \frac{1}{n} AR^{2/3} S^{1/2} \tag{5}$$

where n is the Manning roughness coefficient, flow rate (Q), cross-sectional area (A), hydraulic radius (R), and slope (S). Critical velocity inside culvert is calculated by using Eq. 6:

$$Dk = \sqrt[3]{\frac{Q^2}{b}} / g \tag{6}$$

The entry loss coefficient in reinforced concrete box culverts is determined from a table in THDH [4], according to the geometry of the culvert head wall and side walls.

Governing Equations of HEC-RAS and SWMM

HEC-RAS (Hydrologic Engineering Center's River Analysis System) and SWMM (Storm Water Management

Model) are both widely used in hydraulic modeling, particularly in the field of water resources engineering. While they share some similarities in their purpose of simulating and analyzing hydraulic systems, they have different primary focuses and functionalities.

HEC-RAS is primarily designed for river hydraulics and is widely used for modeling steady and unsteady flow in rivers, channels, and floodplains. It's often used for tasks such as floodplain mapping, bridge and culvert design, and flood risk assessment. The HEC-RAS system encompasses four distinct one-dimensional river analysis components: (1) steady flow water surface profile computations; (2) unsteady flow simulation (one-dimensional and two-dimensional hydrodynamics); (3) Quasi unsteady or fully unsteady flow movable boundary sediment transport computations (1D and 2D); and (4) analysis of water quality [8].

On the other hand, SWMM is specifically designed for urban drainage systems, including stormwater runoff, sanitary sewers, and green infrastructure. It is used to simulate the quantity and quality of runoff within urban areas, helping with stormwater management, flood control, and pollution prevention [13]. The model idealizes the channel/conduit system to links connected to nodes or junctions, which transmit flow from node to node [24].

HEC-RAS and SWMM model uses the conservation of mass and momentum namely Saint-Venant equations. HEC-RAS model either uses one-dimensional (1D) unsteady flow routing (full Saint Venant equations), two-dimensional (2D) unsteady flow routing (Full Saint Venant equations or Diffusion wave equations); or level pool routing. SWMM uses gradually varied, one-dimensional unsteady flow equations to model unsteady flow ([24]; [25]). St Venan equations for gradually varied one-dimensional unsteady flow are shown in Eq. 7-8:

$$\frac{\partial A}{\partial t} + \frac{\partial Q}{\partial x} = 0 \tag{7}$$

$$\frac{\partial Q}{\partial t} + \frac{\partial \left(\frac{Q^2}{A} \right)}{\partial x} + gA \frac{\partial H}{\partial x} + gAS_f = 0 \tag{8}$$

where, $Q = AV$, V : average velocity, A : cross-sectional area, t : time, x : length of the channel or conduit, Q : flow rate, g : gravitational acceleration, H : hydraulic head, S_f : friction slope. The bottom slope is incorporated into gradient of H .

HECRAS and SWMM uses the Manning equation (Eq.1) to model steady uniform flow, expressing the relationship between flow rate, cross-sectional area, hydraulic radius, and slope.

HEC-RAS uses implicit finite differences and solve one-dimensional equations of motion numerically using the Newton-Raphson iteration technique [25]. SWMM v.5 uses an implicit backwards Euler method to provide stability, whereas previous versions are based on explicit twostep

Modified Euler method to calculate the continuity and momentum equations [24].

HECRAS can handle a full network of channels, a dendritic system, or a single river reach by modeling subcritical, supercritical, and mixed flow regime water surface profiles, considering the effects of various obstructions such as bridges, culverts, dams, weirs, and other structures in the flood plain [8].

The roughness within an irregular, natural channel section is changes according to the type and size of materials that compose the bed and banks of a channel and the shape of the channel. HEC-RAS determines the value of Manning's n of a channel by using Cowan's (1956) procedure [26]:

$$n = (n_0 + n_1 + n_2 + n_3 + n_4)m \tag{9}$$

Where, n_0 is base value for a straight, uniform channel, n_1 is the additive value to account for the effect of cross-section irregularity, n_2 is the additive value to account for the variations in size and shape of the channel, n_3 is the additive value to account for the effect of obstructions, n_4 is the additive value to account for the type and density of vegetation and m is the adjustment factor for the degree of channel meandering; determined by the ratio of channel meander length (L_m) to valley or straight channel length (L_s).

For determination of Manning coefficient for an irregular open channel, both model uses equivalent roughness coefficient n_c [27] as shown in Equation 10 [24], [25].

$$n_c = \left[\frac{\sum_{i=1}^N (P_i n_i^{1.5})}{P} \right]^{2/3} \tag{10}$$

where n_c is the composite coefficient of roughness, n_i Manning roughness for subdivision i , P is the wetted perimeter of the channel and P_i is the wetted perimeter of subdivision i .

Culvert Hydraulics in HEC-RAS and SWMM

HEC-RAS is equipped to model nine widely utilized culvert geometries, including circular, rectangular, arch, pipe arch, low profile arch, high profile arch, elliptical, semi-circular, and Con/Span shapes. These culverts can be configured individually, in groups, or in combination with weirs, gates, rating curves, and time series outlets. Additionally, culverts can be assigned to specific station points along a river reach as defined within HEC-RAS or can be georeferenced [8].

The head losses due to the contraction and expansion of flows upstream and downstream of a culvert are calculated by user-defined loss coefficients. Typical lateral cross section of a culvert is shown in Fig 7 [25].




Figure 7. Typical lateral cross section of a culvert [25]

Headwater (HW in Figure 6) is the depth from the culvert inlet invert to the energy grade line, in Section (3), where Tailwater (TW in Figure 6) is the depth on Section (2). Upstream water surface (WSU in Figure 6) is the water depth at the entrance of the culvert. The flow type through a culvert can be defined as “inlet control” or “outlet control”. Inlet control culvert flow occurs when the flow capacity of the culvert entrance is less than the flow capacity of the culvert barrel, contrarily outlet control flow occurs when the culvert flow capacity is limited by downstream conditions (high tailwater) or by the flow carrying capacity of the culvert barrel [25].

The inlet control equations for submerged and unsubmerged inlet conditions are developed according to the laboratory tests by the National Bureau of Standards, the Bureau of Public Roads, and are the basis of the Federal Highway Administrations inlet control nomographs HEC-RAS provide solutions for inlet control computations for submerged and unsubmerged and carries the water surface profile through the structure and maintains the approach velocity [2].

For outlet control culvert flow, HEC-RAS uses s Bernoulli's equation to compute the change in energy through the culvert [25]:

$$Z_3 + Y_3 + \frac{a_3 V_3^2}{2g} = Z_2 + Y_2 + \frac{a_2 V_2^2}{2g} + H_L \tag{11}$$

Where, Z_3 : upstream invert elevation of the culvert, Y_3 : the depth of water above the upstream culvert inlet, V_3 : the average velocity upstream of the culvert, a_3 : the velocity weighting coefficient upstream of the culvert, g : the acceleration of gravity, Z_2 : downstream invert elevation of the culvert, Y_2 : the depth of water above the downstream culvert inlet, V_2 : the average velocity downstream of the culvert, a_2 : the velocity weighting coefficient downstream of the culvert, H_L . total energy loss through the culvert (from section 2 to 3).

In SWMM, a culvert designation is assigned to any conduit link by specifying its shape, which may be circular, rectangular, ellipsoidal, or arch. During each time step of a simulation, the flow through the culvert is initially computed using the standard dynamic wave method, which represents the outlet control condition. Subsequently, an

inlet-controlled flow is computed to assess whether it imposes a flow rate limitation. Under inlet control, a rating curve establishes the relationship between culvert flow rate and inlet head [24].

Under inlet control conditions, a rating curve defines the relationship between the flow rate through a culvert and the inlet head, influenced by the culvert's shape, material, and the geometry of its inlet opening. When the inlet is submerged, the culvert functions as an orifice, whereas it operates as a weir when unsubmerged. Similar to the

procedures employed in HEC-RAS, SWMM utilizes equations delineated in Hydraulic Design of Highway Culverts [23] to determine the flow under unsubmerged inlet control conditions [24].

Results and Discussion

THDH Approach to Culvert Design

Design discharges (Q_{10} , Q_{100}), dimensions (a, b) and other design parameters for the culvert at D302 KM:800 are shown in Table 3.

Table 3. Design parameters of the culvert

Design discharge for 10year return period Q_{10} (m^3/s)	Design discharge for 100year return period Q_{100} (m^3/s)	Design Parameters of Inlet-Controlled Box Type Culvert					
		Cross-sectional width b (m)	Cross-sectional height a (m)	Unit discharge for 10y.r.p. q_{10} ($m^3/s/m$)	Unit discharge for 100y.r.p. q_{100} ($m^3/s/m$)	Manning's roughness coefficient n	Culvert slope S (%)
12.51	19.00	3.00	2.00	4.17	6.33	0.016	4.10

The culvert hydraulic values calculated for Q_{10} and Q_{100} with the nomogram method defined in the THDH [4] are used to calculate the headwater (HW) and tailwater (TW) depths. The design results calculated for the selected culvert

dimensions are given in Table 4. Since the calculated water height inside the culvert is less than the critical flow height, it is not necessary to perform surge control at the culvert outlet.

Table 4. Culvert design results by THDH approach

Design discharge (m^3/sn)	Normal water depth inside the culvert D_n (cm)	Normal velocity inside the culvert V_n (m/sn)	Critical depth D_k (cm)	Critical velocity V_k (m/s)	HW depth (m)	TW depth (m)
$Q_{10}=12.51$	80	7.8	121	3.4	1.80	0.80
$Q_{100}=19.00$	109	8.7	160	4.0	2.40	1.09

According to Table 4, at Q_{10} discharge, a 1.80m HW is expected to occur at the culvert inlet, and at Q_{100} discharge, a 2.40m HW is expected to occur at the culvert inlet. Following the nomogram method proposed in the THDH, while the water depth at the inlet does not exceed the culvert height at the 10-year flow, it does at the 100-year design flow. Still, both flow scenarios are still categorized as Type-I (unsubmerged) inlet control flow as stated in the handbook, given that the headwater level remains within 1.2 times the culvert height.

Application of HEC-RAS in Culvert Design

To simulate the culvert in the HEC-RAS software, the stream sections encompassing the water collection area, as well as the natural cross sections of the stream upstream and

downstream of the culvert are also included to the model. RAS Mapper v.2 software was used to perform these operations in the GIS environment. Using digital maps compiled by ALOS PALSAR [16], natural stream sections in areas close to the culvert were transferred to the model. The flow path line and bank lines to define the main channel banks for the cross sections are prepared using RAS Mapper. The cross-sections were taken every 100m along the flow route on the Kocacay stream, starting 850m upstream of the culvert and continuing to 450m downstream of the culvert. To analyze the variations in water levels at the entrance and exit of the culvert, the model was executed with link lengths of 5 meters over a distance ranging from 400 to 500 kilometers. Flow path line, bank lines and the cross-sections of Kocacay stream prepared using RAS Mapper is shown in Fig. 8.




Figure 8. Flow path line, bank lines and the cross-sections of Kocacay stream

Between KM: 0 and KM: 416m are the flow path downstream of the culvert which is an open channel with a trapezoidal cross-section. The sections upstream of the culvert (KM:452 to KM:1300) are natural land sections. Manning roughness coefficients of the sections defined in the model are shown in the Table 5. The culverts centerline is positioned at KM: 435 along the streamline, designated

as a reinforced concrete box-type culvert with specified dimensions of 3 meters in width, 2 meters in height, and a length of 30 meters. The inlet loss coefficient was determined as 0.5, as recommended by FHWA [2], and the outlet loss coefficient was determined as 0.5, taking into account the outlet conditions of the culvert.

Table 2 Manning coefficients used for cross-sections [26], [27]

STKM	Channel Type	Manning Coefficient		
		Right Bank n_1	Channel Bed n_2	Left Bank n_3
0-438	Concrete bed & grassstone banks	0.035	0.016	0.035
438-468	Reinforced concrete rectangular culvert	0.016	0.016	0.016
468-3750	Natural irregular riverbed	0.035	0.035	0.035

The upstream and downstream boundary conditions in the model are set to the normal depth according to the natural bed ream slope at those sections (Table 6). The model was run in steady condition with Q_{10} and Q_{100} design flow rates

estimated according to the Rational Method, and the hydraulic conditions that may arise according to the topographic model and the culvert section are determined with the HEC-RAS model.

Table 6 Upstream and downstream boundary conditions

StKM	Channel Type	Boundary Condition	
		Type	Slope (J)
0	Concrete bed & grassstone banks	normal depth	0.04
1300	Natural irregular riverbed	normal depth	0.03

The water levels formed with Q_{10} discharge in the cross-sections at the upstream and downstream and in the cross-sections at the inlet and outlet of the culvert are shown in

Fig. 9. The water levels formed with Q_{100} discharge at same cross-sections are shown in Fig. 10. The water surface profiles along the culvert for Q_{10} and Q_{100} discharges are shown in Fig. 11.

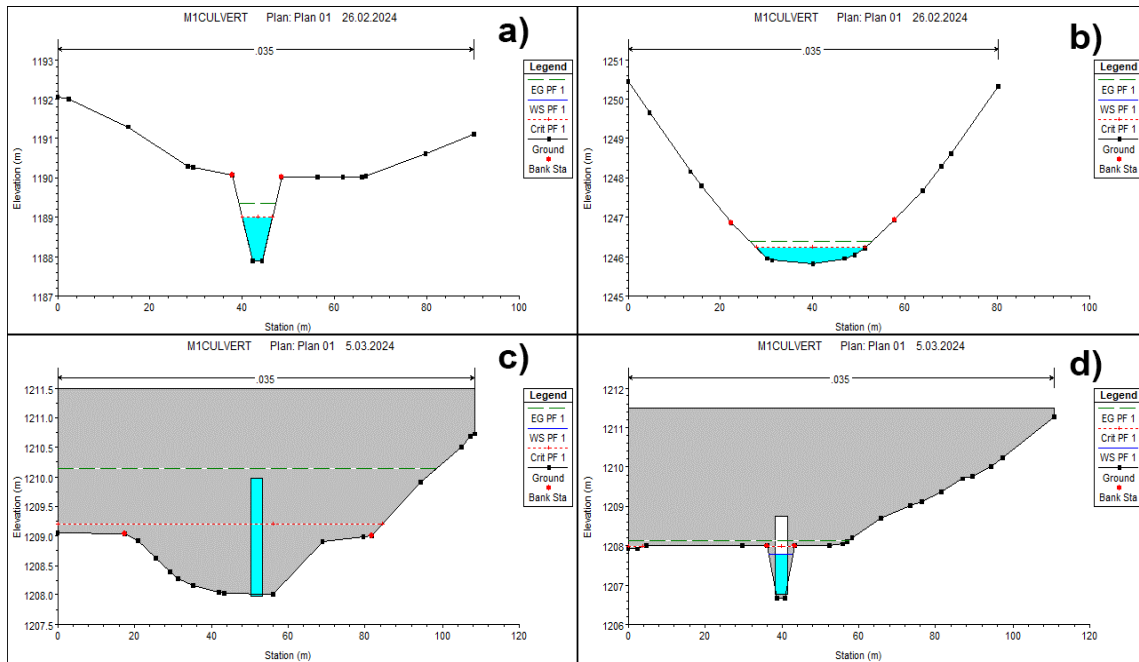


Figure 1. Channel cross-section and water level at the downstream (a), upstream (b) of the channel and culvert inlet (c) and outlet (d) for Q10 discharge




Figure 10. Channel cross-section and water level at the downstream (a), upstream (b) of the channel and culvert inlet (c) and outlet (d) for Q100 discharge

Upon examining the profiles and sections in Figures 9, 10 and 11, it becomes evident that the culvert can convey both Q_{10} and Q_{100} discharges and both flow type can be classified as inlet control USGS Type 5 flow since the headwater depth (HW) exceeds culvert height in both cases (submerged inlet) [3]. In the natural stream section preceding the culvert entrance, characterized by a higher roughness value, HW surpasses the culvert height. The inlet end is submerged and the outlet end flows freely. The control section of the culvert is located just inside the entrance and near this location critical depth occurs. Subsequently, within the culvert featuring a lower roughness and a steep bottom slope, the flow persists at a

depth below the critical depth for both discharge conditions and the flow regime downstream is supercritical. Figure 11's profiles indicates that the flow, corresponding to the Q_{10} and Q_{100} discharges, the flow approaches normal depth at the culvert outlet end. Hydraulic characteristics downstream of the inlet control section do not affect the culvert capacity. In both instances, a higher headwater level results in ponding at the upstream side of the culvert, particularly pronounced during Q_{100} discharge conditions. The perspective view of the hydraulic sections for Q_{100} flow rate by the model is shown in Fig. 12.

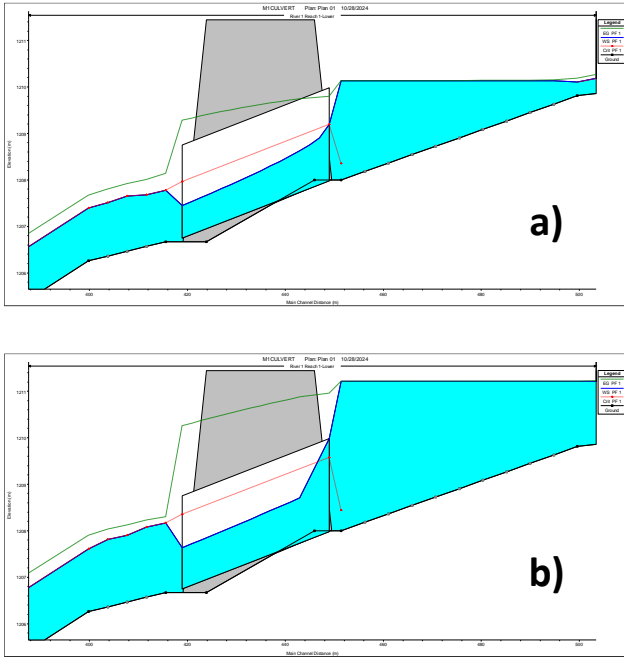


Figure 11. The water surface profiles along the culvert for Q_{10} (a) and Q_{100} (b) discharge




Figure 2. Perspective view of culvert for Q_{100} discharge

Fig. 13 displays the ponding area at the culvert entrance, generated by RAS-Mapper based on the water surface profile computed in the HEC-RAS model. Upstream from the culvert entrance, the natural stream bed forms a sharp bend, with several public buildings situated along the right edge of the ponding area. It's crucial to acknowledge that such sharp turns in the natural stream bed can lead to erosion and potentially increase sediment deposition, posing a flood risk to the nearby buildings.




Figure 13. Ponding area for Q_{100} discharge

Application of SWMM in Culvert Design

The EPA Storm Water Management Model (SWMM) is a dynamic rainfall-runoff simulation model used for single event or long-term (continuous) simulation of runoff quantity and quality from primarily urban areas. Typical applications of SWMM include design and sizing of drainage system components for flood control and sizing of detention facilities and their appurtenances for flood control. SWMM can generate profile plots showing how water surface depth varies across a path of connected nodes and links [24].

The cross-sections obtained from DEM every 100 m along the route were transferred to the SWMM model and defined as nodes. The lines between these calculation points defined along the route are defined as links. The links and nodes defined along the stream route in the SWMM model are shown in Fig. 14.



Figure 14. Stream centerline, links, and nodes of Kocacay
The cross-section of each link was calculated based on the cross-sections defined at the node and obtained from the DEM. The lowest point of the sections at the node points is

defined as the channel talweg/base point in the model, and the invert elevation is defined at the calculation points. In the model created in SWMM, natural stream sections at the upstream and the downstream of channel, at the inlet and the outlet of the culvert are shown in Fig. 15.

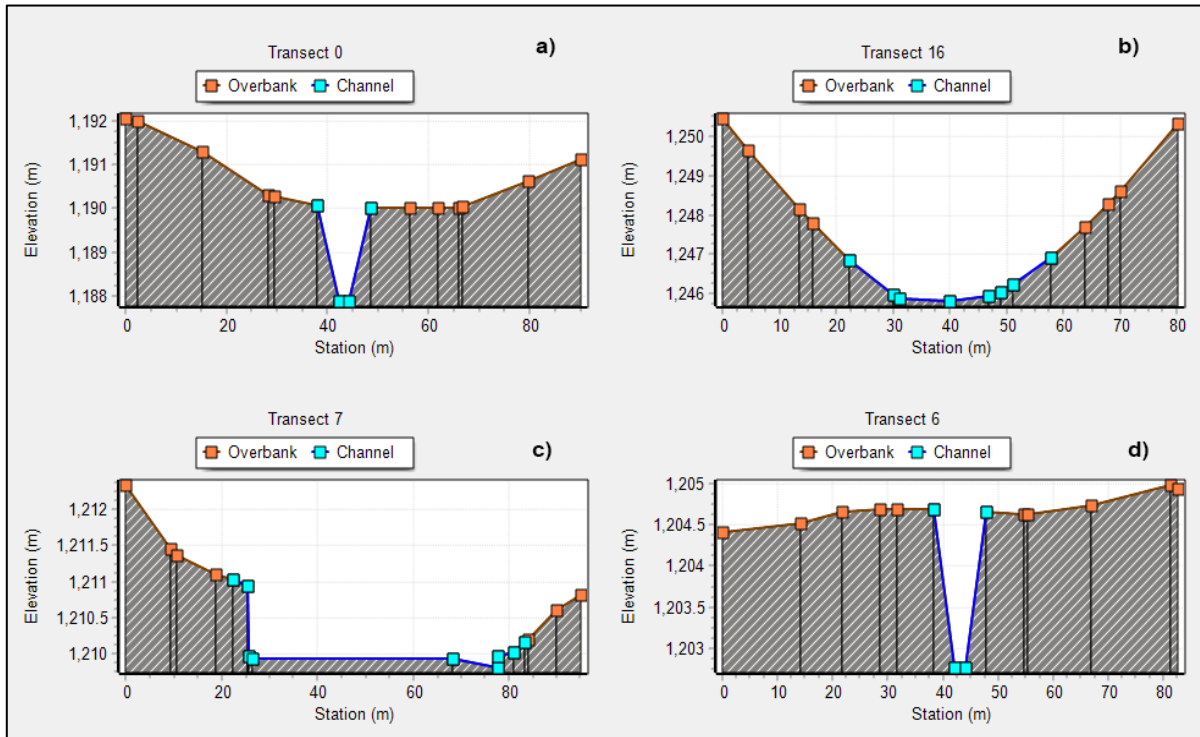


Figure 15. Channel cross-sections at the upstream (a), downstream (b) of the channel and culvert inlet (c) and outlet (d) in SWMM

The link section from KM:416 to KM:452 was designated as a reinforced concrete box culvert with a rectangular cross-section and 30-75 deg. flared wingwalls. The dimensions, roughness coefficients for the walls and foundation of the culvert, and inlet-outlet loss coefficients were configured to match the parameters in the HEC-RAS model. Subsequently, the model was simulated under steady flow conditions for both Q_{10} and Q_{100} discharges. Fig. 16 displays the water surface profiles recorded upstream and downstream of the culvert.

When utilizing the SWMM model for Q_{10} and Q_{100} flow rates, the Figure 16 reveals that the culvert functions under

both inlet control. For Q_{10} flow, a surge is evident at the entrance of the culvert, attributed to changes in cross-section and inlet losses. However, according to the model's calculations, the surge height is determined to be lower than the culvert height for Q_{10} discharge. On the other hand, for Q_{100} flow the HW surpasses the height of the culvert and the inlet is submerged. In both cases the flow regime inside the culvert is supercritical. SWMM model results shows USGS Type-1 flow through an unsubmerged inlet control culvert for Q_{10} and USGS Type-5 flow through a submerged inlet control culvert for Q_{100} discharge.




Figure 16. Water surface profile for flow rates Q10 (a) and Q100 (b)

Comparison of the Results

The hydraulic calculations made using nomograms in the THDH [4] for the culvert to be built in the Kocaçay stream

on Nevsehir Avanos highway were compared with HEC-RAS and SWMM models, and the water depths calculated at the culvert inlet and outlet for Q₁₀ and Q₁₀₀ discharges are shown in Table 7.

Table 3. Headwater (HW) and tailwater (TW) depth of the culvert

Flow (m ³ /s)	Calculated water depth (m)					
	THDH		HEC-RAS		SWMM	
	HW	TW	HW	TW	HW	TW
Q10 (12.51)	1.80	0.80	2.14	1.10	2.13	0.86
Q100 (19.00)	2.40	1.09	3.21	1.50	3.31	1.06

Upon reviewing Table 7, the assessment of culvert flow focuses on inlet control across all calculation methods. As per the methodology outlined in the THDH [4], at Q₁₀ discharge, an unsubmerged inlet condition is observed. However, at Q₁₀₀, the calculated headwater depth (HW) surpasses the culvert height. Despite this variation, both flow scenarios are still categorized as Type-I (unsubmerged) inlet control flow as stated in the handbook, given that the HW remains within 1.2 times the culvert height. Unlike the calculations according to THDH, in both conditions the headwater level exceeds culvert height

according to HEC-RAS model calculations. The flow is considered as inlet control USGS Type 5 flow as submerged inlet occurs in both Q₁₀ and Q₁₀₀ discharge conditions.

SWMM model results for Q₁₀ shows an unsubmerged inlet control culvert with supercritical USGS Type-1 flow inside the culvert. On the other hand, for Q₁₀₀ flow the HW surpasses the height of the culvert and the inlet is submerged. The flow inside the culvert is supercritical matching USGS Type-5 flow conditions.


Although all calculation methods yield relatively similar results for water depths at the tailwater, the methodology outlined in the THDH produces higher values for tailwater depths compared to the model results. Notably, discrepancies in the method utilized, result in more significant differences in water heights calculated at the headwater. The THDH method yielded the lowest headwater depth for both discharge cases, which could lead to inaccuracies in determining culvert dimensions and surge levels. While THDH and SWMM give relatively closer results to each other, HEC-RAS produces significantly higher depth values at headwater than the other two methods.

While according to THDH, hydraulic calculations can only be made for the culvert inlet and outlet by using formulas and nomograms, in HEC-RAS and SWMM models,

hydraulic calculations can be made up to the desired distance upstream and downstream, apart from the culvert entrance and exit.

In HEC-RAS and SWMM models, water depths were calculated at cross-sections every 100 m on a 1300 m route on the Kocaya stream. In both models, the geometries, roughness coefficients of the naturally irregular sections were kept identical to constitute a comparison between the water depth results for both models.

Fig. 17 compares the water depths calculated by HEC-RAS and SWMM models at each cross-section for Q_{10} and Q_{100} discharges. The comparison excludes water depths at the headwater and tailwater, where calculation methods differ between the models, as well as at KM:0 and KM:1300, where boundary conditions influence the results.






Figure 17. Water depths calculated for Q_{10} (a) and Q_{100} (b) discharge in the HEC-RAS and SWMM models

Although the water depths calculated by the HEC-RAS and SWMM models were close to each other at the calculation points upstream of the culvert along the Kocaçay Stream, except the ponding area close to the inlet of the culvert, the water depths calculated by the HEC-RAS model were generally higher than those calculated by SWMM at the same cross-section.

While both models utilize the same fundamental equations, the HEC-RAS model incorporates the meander effect into hydraulic calculations by considering reach lengths for the left and right overbank and channel between two cross-sections. In cases where the distances between cross-sections for both the channel and overbanks vary, HEC-RAS determines a discharge-weighted reach length. [25]. Conversely, in SWMM, floodplain access distances are not computed by the model, and users must define the meander effect in natural sections [24]. Additionally, HEC-RAS and SWMM utilize different numerical methods and algorithms to simulate hydraulic behavior, which leads to variations in results.

The difference between SWMM and HEC-RAS results increases with increasing water depth at the cross-sections downstream from the station point where the culvert is located and downstream of the culvert outlet. The presence of the culvert itself introduces complexities in flow dynamics downstream, such as changes in flow velocity, turbulence, and water surface profiles. SWMM and HEC-RAS handle these effects differently, leading to discrepancies in predicted water depths. This situation is observed in the model results, especially between KM: 416, and KM: 0 at the downstream of the culvert.

Conclusions

After reviewing the water depths calculated using three distinct methods at the culvert entrance, exit, and nearby points along the channel, it becomes apparent that while the nomogram method suggested in the THDH provides a practical means for determining headwater depth, tailwater depth and culvert dimensions. However, it does not adequately address the channel sections upstream and downstream of the culvert and the relevant flow conditions. This oversight leads to an underestimation of culvert

headwater depth during design flow conditions and may cause the water to surge to undesirable levels during floods.

With the model made with SWMM, an urban infrastructure modeling tool, it was observed that the flow conditions at the culvert inlet and outlet and in the natural sections at the upstream and downstream were taken into consideration, but it was observed that the flow conditions did not fully reflect the flow conditions since the effect of some river features such as meanders on the flows was not directly calculated by the model.

It has been determined that HEC-RAS, can model many hydraulic features of a natural stream and reflects the flow conditions on the channel more accurately, both at the inlet and outlet of the culvert and at the upstream and downstream of the culvert. With the GIS tools in HEC-RAS, the water collection areas created by the design flow rates around the culvert can be shown on the map and the regional effect of the flow can be evaluated with this tool.

To evaluate the environmental effects of the design flow rates of culverts, especially those located near residential areas, it is recommended to use HEC-RAS and similar GIS-supported modeling tools in hydraulic calculations.

In summary, While the THDH and SWMM methods have their useful insights, HEC-RAS integrates comprehensive modelling and GIS tools for better accuracy and reliability of culvert performance assessment and flood management, in particular for complex and residential areas. It is therefore suggested that future studies should focus on prioritizing and integrating HEC-RAS and GIS based technologies to enhance detailed flow dynamics and environmental impacts.

Ethics committee approval and conflict of interest statement

There is no need to obtain permission from the ethics committee for the article prepared. There is no conflict of interest with any person / institution in the article prepared

Authors' Contributions

Cebe K: Writing the main manuscript text, assessing and preparing the data for the models, constructing models, and assessing their performances. Reading and approving the final manuscript.

Bilhan O: Field works, study conception and design, interpretation of data, drafting of manuscript. Reading and approving the final manuscript.

Balci RS: processed, curated and stored the original data used in this study. Reading and approving the final manuscript.

References

- [1]. H. Methods, G. Dyhouse, J. Hatchett, J. Benn, "Flood plain modeling using HEC-RAS", *Haestad press*, 696 p, 2003.
- [2]. J. M. Normann, R. J. Houghtalen, W. J. Johnston, "Hydraulic design of highway culverts", U.S. *Department of Transportation*, Report No. FHWA-IP-85-15. Hydraulic Design Series No. 5, Washington, September 1985.
- [3]. G. L. Bodhaine, "Measurement of peak discharge at culverts by indirect methods", *U.S. Geological Survey Techniques of Water-Resources Investigations*, Book 3, Chap. A3, 60 p. 1968. <https://pubs.usgs.gov/twri/twri3-a3/>
- [4]. KGM, "Karayolu tasarım el kitabı", *Karayolları Genel Müdürlüğü*, Ankara, Türkiye, 2016.
- [5]. G. Dorin, C. Pricop, F. Stătescu, T. A. Hrănciuc, D. Toma, "Mathematical modelling and numerical analysis of hydraulic system behaviour. A case study with application in HEC-RAS", *IOP Conference Series: Materials Science and Engineering*, 1256(1), 2022. <https://doi.org/10.1088/1757-899x/1256/1/012027>.
- [6]. N. N. Zainal, S. H. A. Talib, "Review paper on applications of the HEC-RAS model for flooding, agriculture, and water quality simulation", *Water practice and technology*, 1 July 2024, 19 (7), p. 2883–2900, 2024. doi: <https://doi.org/10.2166/wpt.2024.173>.
- [7]. M. Iosub, M. Ionut, O. Hapciuc, G. Romannescu, "The use of EC-RAS modelling in flood risk analysis", *The International Conference Air and Water - Components of The Environment*, 20-22 March 2015.
- [8]. HEC (2023) HEC-RAS user's manual version 6.3. *U.S. Army Corps of Engineers, Hydrologic Engineering Center*. <https://www.hec.usace.army.mil/confluence/rasdocs/rasum/latest>
- [9]. L. B. Maharjan, N. M. Shakya, "Comparative study of one dimensional and two dimensional steady surface flow analysis", *Journal of Advanced College of Engineering and Management*, Vol. 2, 2016.
- [10]. C. H. Wang, "Application of HEC-RAS model in simulation of water surface profile of river", *Applied Mechanics and Materials*, pp. 232–235, 2014. <https://doi:10.4028/www.scientific.net/amm.641-642.232>
- [11]. S. J. Zeiger, J. A. Hubbart., "Measuring and modeling event-based environmental flows: An assessment of HEC-RAS 2D rain-on-grid simulations", *Journal of environmental management*, 285, 2021, <https://doi.org/10.1016/j.jenvman.2021.112125>.
- [12]. N. T. Thalakkottukara, J. Thomas, M. K. Watkins, B. C. Holland, T. Oommen, H. Grover, "Suitability of the height above nearest drainage (HAND) model for flood inundation mapping in data-scarce regions: a comparative analysis with hydrodynamic models",

- Earth Science Informatics*, 17(3), 2024. <https://doi.org/10.1007/s12145-023-01218-x>
- [13]. Rossman, L.A.; Simon, M.A. Storm Water Management Model User's Manual Version 5.2; United States Environmental Protection Agency, 2022. Available online: <https://www.epa.gov/water-research/storm-water-management-model-swmm> (accessed on 1 September 2024).
- [14]. O. Bilhan, "Analysis of sediment transport and accumulation in Kızılırmak watershed by using numerical models and fieldworks", *Nevşehir HBV University Scientific Research Projects Coordination Unit*, Project No: NEUBAP14F4, p. 56, Nevşehir, Türkiye, 2017.
- [15]. Google Earth, 2024 Google Earth Pro v. 7.3.6.9750 (64-bit), 38°55'49.16"N 34°59'50.04"E.
- [16]. ASF DAAC, Advanced land observing satellite phased array L-band synthetic aperture radar (ALOS PALSAR). Contains modified copernicus sentinel data 2015, processed by ESA. *Alaska Satellite Facility*.
- [17]. QGIS, 2023, *QGIS Geographic Information System*, v. 3.28.3. QGIS association. <http://www.qgis.org>
- [18]. H. Özdemir, "Uygulamalı taşkın hidrolojisi", *DSİ Genel Müdürlüğü Genel Yay. No: 873, Özel Yay. No: 34*, Ankara, 1978.
- [19]. M. Bayazıt, I. Avcı, Z. Şen, "Hidroloji uygulamaları", *Birsen Yayınevi*, İstanbul. ISBN:9789755112688, p. 266, 2009.
- [20]. Z. Şen, "İklim değişikliği içerikli taşkın afet ve modern hesaplama yöntemleri", *Su Vakfı*, İstanbul, 2009
- [21]. A. Ahiskali, "Karayolu ve altyapı tasarımı". *Nobel Akademik Yayıncılık*. ISBN978-625-417-683-8, 296p, 2022.
- [22]. M. Wanielista, R. Kersten, R. Eaglin "Hydrology: water quantity and quality control", *John Wiley & Sons Inc.*, New York, 1997.
- [23]. J. D. Schall, P. L. Thompson, S. M. Zerges, R. T. Kilgore, J. L. Morris, "Hydraulic design of highway culverts third edition", *Federal highway administration, national highway institute*, Washington, 2012. https://www.fhwa.dot.gov/engineering/hydraulics/library_arc.cfm?pub_number=7&id=13
- [24]. L. A. Rossman, "Storm Water Management Model Reference Manual Volume II – Hydraulics", *U.S. environmental protection agency, office of research and development*, Cincinnati, USA, 2017. <https://www.epa.gov/water-research/storm-water-management-model-swmm>
- [25]. G. W. Brunner "HEC-RAS, river analysis system hydraulic reference manual version 6.0 beta", *US Army Corps of Engineers, Hydraulic Engineering Center (HEC)*, Davis, CA, 2020. <https://www.hec.usace.army.mil/confluence/rasdocs/ras1dtechref/latest/>
- [26]. W. L. Cowan, "Estimating hydraulic roughness coefficients", *Agricultural Engineering*. 37(7), p. 473-475, 1956.
- [27]. V. T. Chow, "Open channel hydraulics", *McGraw-Hill book company*, NY, 1959.



Araştırma Makalesi / Research Article

Birleşik deprem etkilerinin ve ek dışmerkezliğin betonarme binaların davranışına etkisi

*Effect of combined earthquake effects and additional eccentricity on the behaviour of reinforced concrete buildings*Gürkan Tam^{1*}, Burak Yön²¹ Munzur Üniversitesi, Lisansüstü Eğitim Enstitüsü, gtam@munzur.edu.tr
ORCID: <https://orcid.org/0009-0003-9948-2141>² Munzur Üniversitesi, İnşaat Mühendisliği Bölümü, burakyon@munzur.edu.tr
ORCID: <https://orcid.org/0000-0001-5155-6963>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 8 Ekim 2024
Revizyon 9 Kasım 2024
Kabul 13 Kasım 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

Birleşik Deprem Etkileri, Ek Dışmerkezlik, Zemin Sınıfı, Plastik Mafsalsal, Kapasite Eğrisi

ÖZ

Bu çalışmada birleşik deprem etkilerinin ve ek dışmerkezliğin betonarme binaların davranışına etkisi incelenmiştir. Çalışma kapsamında modellenen betonarme yapının beş zemin sınıfına (ZA, ZB, ZC, ZD ve ZE) göre X ve Y yönlerinde olmak üzere toplam 30 adet doğrusal olmayan statik itme analizleri yapılmıştır. Kiriş ve kolonların doğrusal olmayan davranışları toplanmış plastik mafsalsal kabulüne göre, perde duvarların doğrusal olmayan davranışları ise yayılı plastik mafsalsal kabulüne göre yapılmıştır. Analizler sonucunda birleşik deprem etkileri ve ek dışmerkezlik dikkate alınarak her zemin sınıfı için kapasite eğrileri, X ve Y yönleri için en düşük yük faktöründe oluşan plastik mafsalsal dağılımları, ilk mafsalsal oluştuğu andaki yük faktörü ve maksimum yük faktörü değerleri elde edilmiştir. Analizler sonucunda zemin sınıfı ZA'dan ZE'ye doğru gidildikçe hem kapasite değerlerinde hem de yük faktörü değerlerinde azalmanın olduğu belirlenmiştir. Bununla birlikte, ek dışmerkezlik ve birleşik deprem etkileri dikkate alındığı modellerde zemin sınıfındaki değişime bağlı olarak plastik mafsalsal dağılımlarının yoğunlaştığı tespit edilmiştir. Sonuç olarak betonarme yapıların tasarımlarında ve performans değerlendirmelerinde zemin sınıflarına ilave olarak birleşik deprem etkilerinin ve ek dışmerkezliğin dikkate alınması gereken önemli parametreler olduğu tespit edilmiştir.

ARTICLE INFO

Article history:

Received 8 October 2024
Received in revised form 9 November 2024
Accepted 13 November 2024
Available online 23 December 2024

Keywords:

Combined Earthquake Effects, Additional Eccentricity, Soil Class, Plastic Hinge, Capacity Curve

ABSTRACT

In this study, the effects of combined earthquake effects and additional eccentricity on the behaviour of reinforced concrete buildings were investigated. Within the scope of the study, a total of 30 nonlinear static pushover analyses of the modelled reinforced concrete structure were performed in X and Y directions according to five soil classes (ZA, ZB, ZC, ZD and ZE). The nonlinear behaviour of beams and columns is based on lumped plastic hinge and the nonlinear behaviour of shear walls is based on distributed plastic hinge. As a result of the analyses, capacity curves for each soil class, plastic hinge distributions at the lowest load factor for X and Y directions, load factor at the moment of the first hinge and maximum load factor values were obtained considering the combined earthquake effects and additional eccentricity. As a result of the analyses, it was determined that both capacity values and load factor values decrease as the soil class moves from ZA to ZE. However, in the models where additional eccentricity and combined earthquake effects were considered, it was found that plastic hinge distributions intensified due to the change in soil class. As a result, it was determined that in addition to soil classes, combined earthquake effects and additional eccentricity are important parameters that should be considered in the design and performance evaluations of reinforced concrete structures.

Doi: 10.24012/dumf.1563505

* Sorumlu Yazar

Giriş

Depremler, yer kabuğundaki enerji birikiminin fay hatları boyunca serbest bırakılması sonucu oluşan dinamik kuvvetlerdir. Bu kuvvetlerin doğru bir şekilde analiz edilerek yapıların depreme dayanıklı tasarımında kullanılması temel bir gerekliliktir [1]. Bu nedenle farklı yönlerde etki eden deprem kuvvetlerinin birleştirilerek yapısal hesaplamaların yapılması, binaların sismik performansını belirlemede önemli bir rol oynamaktadır [2-4]. Deprem kuvvetlerinin birleştirilmesi, yapı mühendisliğinde karmaşık bir analiz süreci gerektirir. Bu süreç, yapının sismik yükler altındaki davranışını tahmin etmek için çeşitli matematiksel ve hesaplamalı yöntemlerin kullanılmasını içermektedir. Özellikle, çoklu deprem senaryolarının bir araya getirilmesi, yapının gerçek zemin koşullarına daha uygun bir şekilde tasarlanmasını sağlar [5]. Bu yaklaşım hem yapıların güvenliğini hem de sürdürülebilirliğini artırmayı amaçlayarak büyük genlikli deprem hareketlerinin yapılar üzerindeki etkilerini en aza indirgenmesi hedeflemektedir [6].

Yapı tasarımında dikkat edilmesi gereken diğer bir kritik parametre ise ek dış merkezliktir. Ek dış merkezlik, yapının ağırlık merkezinin, taşıyıcı sistemin merkezine olan uzaklığı olarak tanımlanmaktadır. Bu durum, yapının depremler ve diğer yükler altındaki davranışını önemli ölçüde etkilemektedir [7]. Yapıların sismik performansını değerlendirmek ve güvenliğini artırmak için ek dış merkezliğin etkilerini anlamak ve buna göre tasarım yapmak büyük önem taşımaktadır. Ek dış merkezlik, yapı tasarımında mimari dış merkezlik ve yapısal dış merkezlik olarak iki ana bileşen olarak ele alınmaktadır. Mimari dış merkezlik, yapı elemanlarının yerleşimi ve fonksiyonları nedeniyle ortaya çıkan ağırlık merkezinin kayması olarak açıklanırken, yapısal dış merkezlik ise yapının dinamik davranışını etkileyen taşıyıcı sistemdeki asimetric yük dağılımından kaynaklanmaktadır [8-9]. Dış merkezlik, yapının burulma momentlerine ve sismik yükler altındaki deformasyonlarına doğrudan etkide bulunduğu için binaların sismik performansını değerlendirirken dikkate alınmalıdır [10]. Özellikle büyük yapılarda ve yüksek binalarda, dış merkezliğin etkileri daha karmaşık bir şekilde ortaya çıkmaktadır [6]. Türkiye Bina Deprem Yönetmeliği-2018 (TBDY-2018)'de ise yapıların tasarımında, yapıda herhangi bir düzensizlik bulunmasa bile %5'lik minimum ek dış merkezliğin dikkate alınması gerekliliği belirtilmiştir [11]. Böylelikle, yapıda daha sonradan yapılacak olası değişikliklerden ve yük dağılımındaki belirsizliklerden kaynaklanan düzensizliklerin bertaraf edilmesi amaçlanmaktadır.

Bu nümerik çalışmada; deprem kuvvetlerinin birleştirilmesinin ve ek dış merkezlik etkisinin betonarme binaların sismik davranışına etkisi incelenmiştir. Doğrusal olmayan statik itme analizi yöntemi kullanılarak binaların TBDY-2018'de verilen beş farklı zemin türüne göre analizleri yapılmıştır. Analizler sonucunda; seçilen binanın

kapasite eğrileri, plastik mafsallı dağılımları ve yük faktörü değerleri elde edilmiştir.

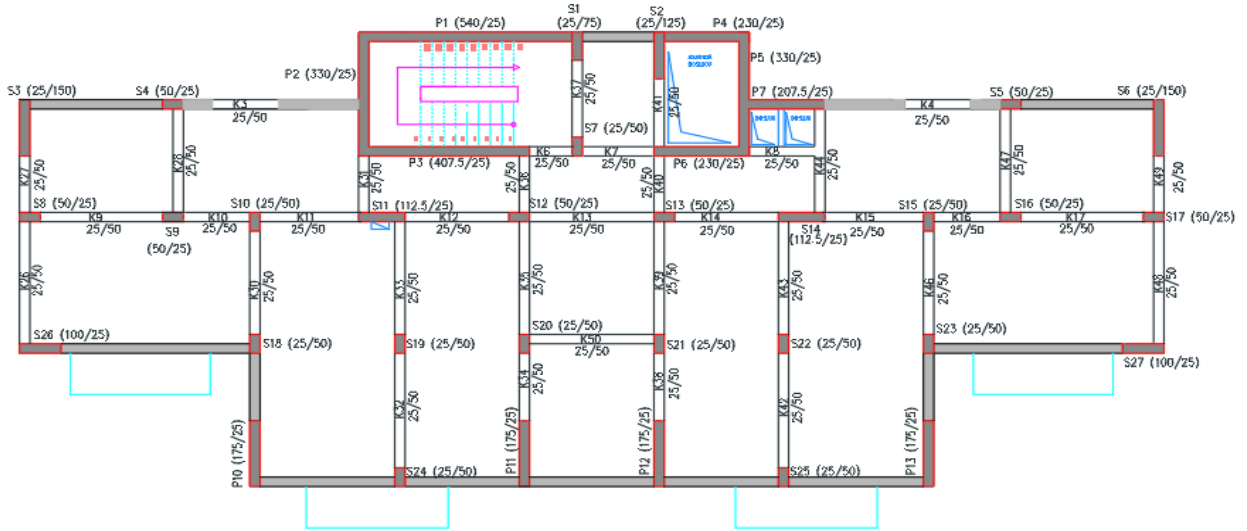
Materyal ve Metot

Seçilen betonarme binanın doğrusal olmayan analizleri için statik itme analizi yöntemi kullanılmıştır. Bu yöntem, yapı mühendisliğinde özellikle bina türü yapıların tasarımında ve performanslarının değerlendirilmesinde doğru sonuçlar veren pratik bir analiz yöntemidir. Bu nedenle birçok araştırmacı tarafından sıklıkla kullanılmaktadır [12]-[18]. Bu analiz yönteminde depremden kaynaklanan kuvvetler simüle edilerek incelenen binaya monolitik şekilde artan yanal bir yük uygulanmasını içermektedir. Analiz sonucunda elde edilen kapasite eğrisi mühendisin tasarladığı veya performans analizini yürüttüğü binanın sismik koşullar altında yapısal kapasitesini, göçme mekanizmalarını değerlendirmesine olanak tanıyan, taban kesme kuvveti ile çatı deplasmanı arasındaki ilişkiyi göstermektedir. Analiz, yapıların elastik durumdan elastik olmayan davranışa nasıl geçiş yaptığına dair ayrıntılı bilgiler vererek, gerçek sismik yükleme altında yapısal hasarlara yol açabilecek plastik mafsalların olduğu bölgeleri tespit etmede büyük kolaylık sağlamaktadır. Bu çalışmada, seçilen binanın statik itme analizi, deprem kuvvetleri birleştirilerek ve %5'lik ek dış merkezlik uygulanarak yapılmıştır. Bu parametreler TBDY-2018'de tanımlandığı şekilde binaya uygulanmıştır. Yönetmelikte ifade edilen bu kuvvetlerin birleştirilmesi işlemi Denklem (1)'de tanımlanmıştır.


$$E_d^H = \pm E_d^X \pm 0.3 E_d^Y ; E_d^H = \pm E_d^Y \pm 0.3 E_d^X \quad (1)$$

Burada $E_d^{(X)}$ ve $E_d^{(Y)}$ birbirine dik (X) ve (Y) doğrultularındaki depremlerin etkisi altında tanımlanan ve ayrı ayrı hesaplanan deprem etkilerini, $E_d^{(H)}$ ise birleştirilmiş kuvvetleri göstermektedir.

Sayısal çalışma için seçilen betonarme bina Tunceli/Merkez'de, 39.046200 enlem, 39.507956 boylam konumunda bulunan B+Z+3 normal katlı konut yapısıdır. Şekil 1-2'de seçilen binanın normal kat planı ve üç boyutlu görünümü sırasıyla verilmiştir. Binada kat yüksekliği 3 m, döşeme kalınlığı 15 cm, kiriş boyutları 25/50 cm ve 25/75 cm olarak seçilirken, kolon boyutları 25x50 cm, 25/75 cm, 25/100 cm, 25/112.5 cm ve 25/150 cm olarak alınmıştır. Binada malzeme olarak S420'lik donatı ve basınç dayanımı 25 N/mm² beton kullanılmıştır. Doğrusal olmayan davranış sağlamak için eleman uçlarında toplanmış plastik mafsallı kabulü yapılırken, bodrum perdelerinde yayılı plastik mafsallı kullanılmıştır. Malzeme davranış modeli olarak beton için Mander Sargılı Beton modeli [19], donatı için Manetto-Pinto [20] davranış modeli kullanılmıştır. Analizler için Seismostruct V24 yapı analiz programı kullanılmıştır.



Şekil 1. Seçilen binanın normal kat planı



Şekil 2. Seçilen binanın 3 boyutlu görünümü


Araştırma Bulguları

Bu bölümde incelenen yapının X ve Y yönlerindeki beş zemin sınıfına göre birleşik deprem etkilerinin ve ek dışmerkezliliğin dikkate alınarak yapılan analizleri sonucunda elde edilen kapasite eğrileri, plastik mafsalları dağılımları, ilk mafsalları için yük faktörü değerleri ve maksimum yük faktörü değerleri sunulmuştur.

Kapasite Eğrileri


Seçilen binanın kapasite eğrileri bina çatı deplasmanının bina yüksekliğinin %3'üne ulaşmaya kadar itirilerek oluşturulmuştur. İncelenen binanın X yönünde birleştirilmiş kesme kuvvetleri etkisi altında elde edilen kapasite eğrileri Şekil 3'te sunulmuştur. Bu eğriler değerlendirildiğinde ZA zemin sınıfı için taban kesme kuvvetleri Modal X yüklemesinde 16709.04 kN, Modal X-eccY yüklemesinde 16277.36 kN, Modal X+0.3Y-eccY yüklemesinde 15113.15 kN olarak tespit edilmiştir. ZB zemin sınıfı için taban kesme kuvvetleri Modal X yüklemesinde 16518.47 kN, Modal X-eccY yüklemesinde 16086.88 kN, Modal X+0.3Y-eccY yüklemesinde ise 14804.4 kN olduğu görülmüştür. ZC zemin sınıfı için taban kesme kuvvetleri incelendiğinde Modal X yüklemesinde 16027.08 kN, Modal X-eccY yüklemesinde 15635.89 kN ve Modal X+0.3Y-eccY yüklemesinde 14335.01 kN olduğu görülmüştür. ZD zemin sınıfı için

taban kesme kuvvetleri değerlendirildiğinde Modal X yüklemesinde 15718.47 kN, Modal X-eccY yüklemesinde 15324.87 kN, Modal X+0.3Y-eccY yüklemesinde 13996.60 kN olduğu görülmüştür. ZE zemin sınıfı için elde edilen taban kesme kuvvetlerinde ise Modal X yüklemesi için 15465.88 kN, Modal X-eccY yüklemesinde 15088.24 kN ve Modal X+0.3Y-eccY yüklemesinde 13814.84 kN olduğu görülmüştür.



Şekil 3. İncelenen binanın X yönünde beş farklı zemin sınıfına göre elde edilen kapasite eğrileri

İncelenen binanın Y yönünde birleştirilmiş kuvvetler etkisi altında elde edilen kapasite eğrileri ise Şekil 4'te gösterilmiştir.



Şekil 4. İncelenen binanın Y yönünde beş farklı zemin sınıfına göre elde edilen kapasite eğrileri

Kapasite eğrileri değerlendirildiğinde; ZA zemin sınıfı için taban kesme kuvvetleri Modal Y yüklemesinde 15355.72 kN, Modal Y+eccX yüklemesinde 14172.07

kN, Modal Y+0.3X+eccX yüklemesinde 13448.73 kN olarak tespit edilmiştir. ZB zemin sınıfı için taban kesme kuvvetleri Modal Y yüklemesinde 15038.44 kN, Modal Y+eccX yüklemesinde 13838.5 kN, Modal Y+0.3X+eccX yüklemesinde 13132.53 kN olduğu görülmüştür. ZC zemin sınıfı için ise taban kesme kuvvetleri Modal Y yüklemesinde 14660.42 kN, Modal Y+eccX yüklemesinde 13447.39 kN ve Modal Y+0.3X+eccX yüklemesinde 12776.13 kN olduğu görülmüştür. ZD zemin sınıfı için ise taban kesme kuvvetleri Modal Y yüklemesinde 14365.35 kN, Modal Y+eccX yüklemesinde 13183.46 kN ve Modal Y+0.3X+eccX yüklemesinde 12528.70 kN olduğu görülmüştür. ZE zemin sınıfında yer alan binanın taban kesme kuvvetleri Modal Y yüklemesinde 14150.21 kN, Modal Y+eccX yüklemesinde 12963.31 kN ve Modal Y+0.3X+eccX yüklemesinde 12321.45 kN olduğu görülmüştür

X Yönünde Elde Edilen Plastik Mafsalları Bölgesi

X yönündeki kuvvetlerin etkinliğinin fazla olduğu yüklemeler için beş zemin sınıfına ve üç farklı yüklemeye (Modal X, Modal X-eccY ve Modal X+0.3Y-eccY) göre elde edilen plastik mafsalları dağılımlarının binanın perspektif ve arka cepheden görünüşleri sırasıyla Tablo 1-2'de verilmiştir. Yapısal elemanlarda oluşan plastik mafsalları dağılımları üç farklı yüklemeye için en düşük yük faktörü olan 1.55 referans alınarak belirlenmiştir.

Elde edilen plastik mafsalları dağılımları incelendiğinde, ZA ve ZB zeminleri için seçilen yüklemeler altında plastik mafsalları oluşmazken, ZC ve ZD zeminlerinde Modal X-eccY ve Modal X+0.3Y-eccY yüklemeleri altında kirişlerde plastik mafsalları oluştuğu görülmüştür. Bununla birlikte, Modal X+0.3Y-eccY yüklemesinde plastik mafsalları arttığı belirlenmiştir. ZE zemin sınıfında elde edilen plastik mafsalları değerlendirildiğinde, Modal X-eccY yüklemesinde kolon ve perdelerde plastik mafsalları oluştuğu görülürken Modal X+0.3Y-eccY yüklemesi altında oluşan plastik mafsalları tüm yapısal elemanlara dağıldığı tespit edilmiştir.

Tablo 1. İncelenen binanın X yönünde perspektif görünüşe göre elde edilen plastik mafsallı bölgeleri

Zemin	Modal X	Modal X-eccY	Modal X+0.3Y-eccY
ZA			
ZB			
ZC			
ZD			
ZE			

Tablo 2. İncelenen binanın X yönünde arka cepheden görünüşe göre elde edilen plastik mafsalları bölgeleri

Zemin	Modal X	Modal X-eccY	Modal X+0.3Y-eccY
ZA			
ZB			
ZC			
ZD			
ZE			

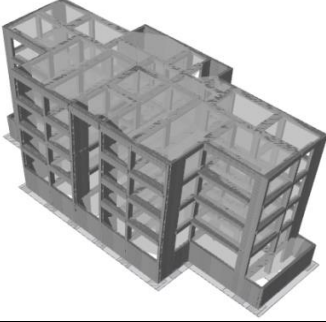
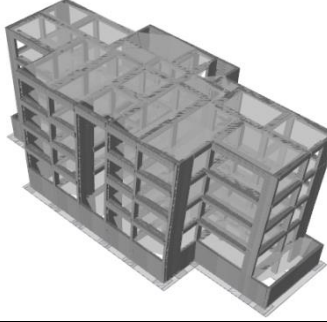
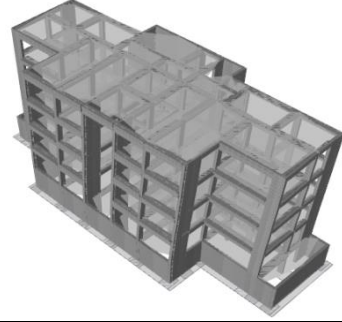
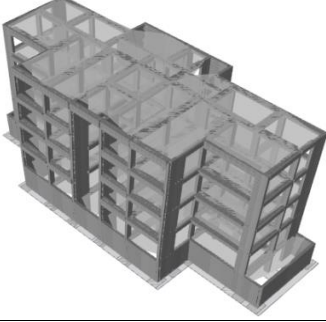
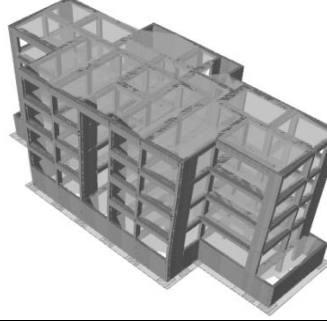
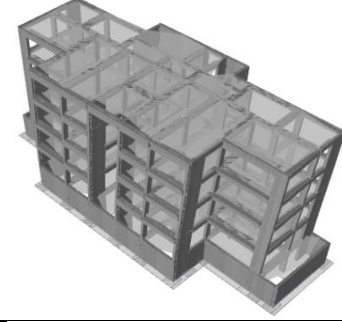
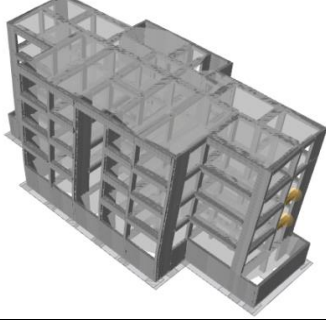
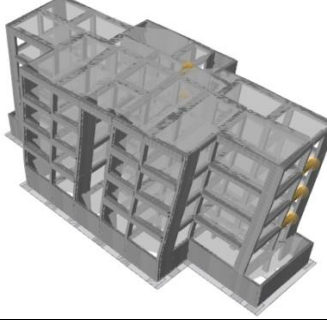
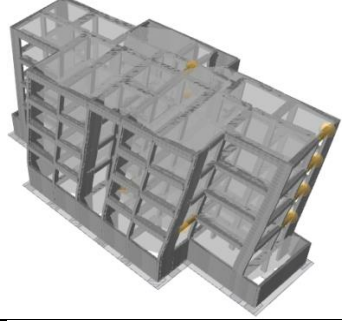
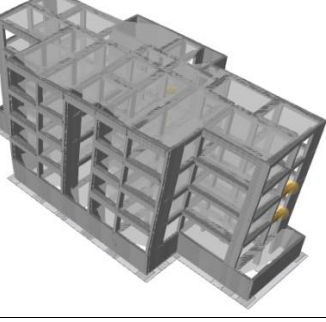
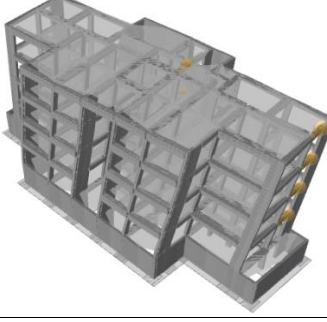
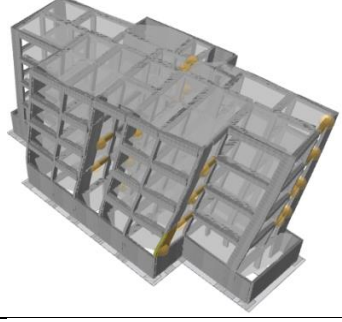
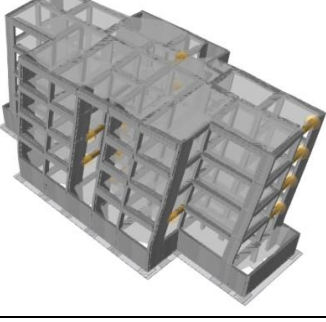
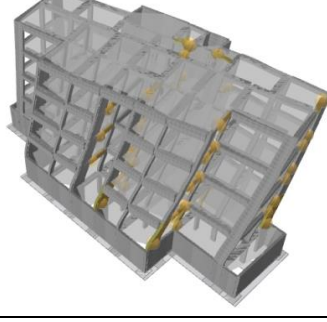
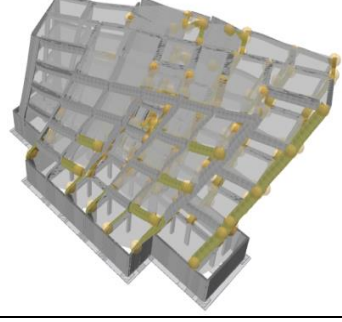
Y Yönünde Elde Edilen Plastik Mafsalları Bölgeleri

Y yönündeki kuvvetlerin etkinliğinin fazla olduğu yüklemeler dikkate alınarak beş zemin sınıfına ve üç farklı yüklemeye (Modal X, Modal X-eccY ve Modal X+0.3Y-eccY) göre elde edilen plastik mafsalları dağılımlarının binanın perspektif ve arka cepheden görünümü sırasıyla Tablo 3-4'te sunulmuştur. Yapısal elemanlarda oluşan plastik mafsalları dağılımları üç farklı yükleme için en düşük yük faktörü olan 0.98 referans alınarak belirlenmiştir.

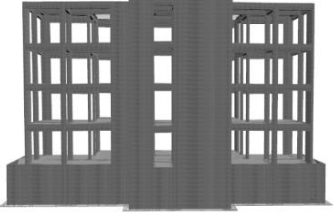
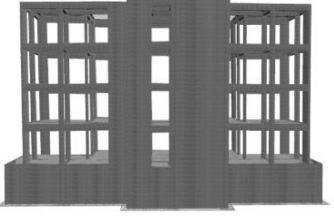
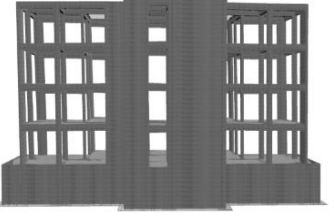
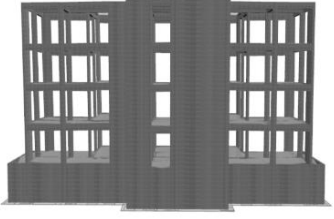
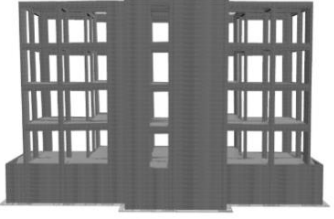
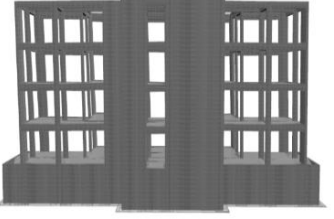
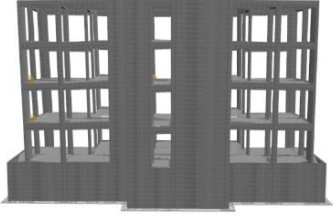
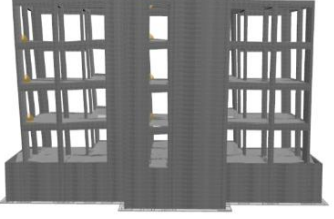
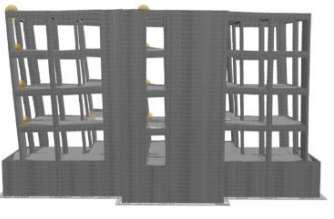
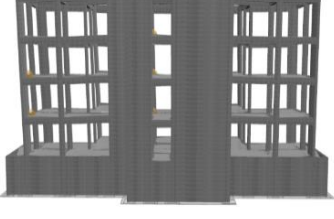
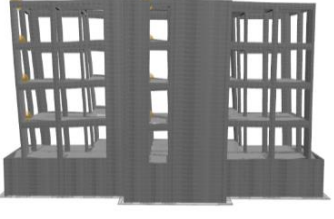
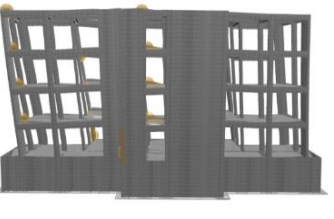
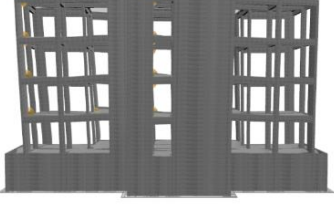
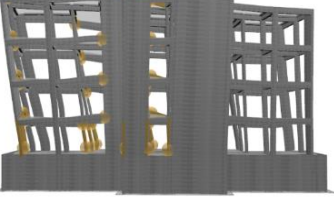
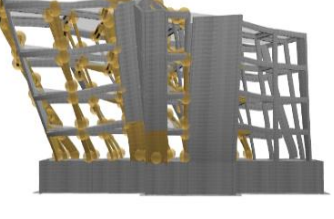
Oluşan plastik mafsalları dağılımları değerlendirildiğinde, X yönündekine benzer şekilde ZA ve ZB zeminleri için

seçilen tüm yüklemeler için hiçbir yapısal elemanda plastik mafsalları oluşmamıştır. ZC ve ZD zeminlerinde ise tüm yüklemeler için kirişlerde plastik mafsalları meydana gelmiştir. Bununla birlikte Modal X+0.3Y-eccY yüklemesi altında zemin kat kolonlarında plastik mafsalları oluşmuştur. ZE zemin sınıfında elde edilen plastik mafsalları incelendiğinde, Modal X-eccY yüklemesinde kolon ve perdelerde X yönündeki plastik mafsalları dağılımlardan daha yoğun olduğu tespit edilmiştir. Modal X+0.3Y-eccY yüklemesi altında oluşan plastik mafsalları tüm yapısal elemanlara dağıldığı belirlenmiştir.

Tablo 3. İncelenen binanın Y yönünde perspektif görünüşe göre elde edilen plastik mafsalları

Zemin	Modal Y	Modal Y+eccX	Modal Y+0.3X+eccX
ZA			
ZB			
ZC			
ZD			
ZE			

Tablo 4. İncelenen binanın Y yönünde arka cepheden görünüşe göre elde edilen plastik mafsal bölgeleri

Zemin	Modal Y	Modal Y+eccX	Modal Y+0.3X+eccX
ZA			
ZB			
ZC			
ZD			
ZE			

Yük Faktörleri

Seçilen binanın zemin sınıflarına ve üç farklı yüklemeye göre ilk plastik mafsallın oluştuğu andaki yük faktörü, maksimum yük faktörü X ve Y yönleri için sırasıyla Tablo 5 ve Şekil 5-8'de sunulmuştur. Buna göre, X yönünde ilk mafsallın oluştuğu andaki yük faktörü ve maksimum yük faktörü değerlerinin ZA'dan ZE zemin sınıfına doğru gidildikçe bütün yükleme durumları için azaldığı görülmüştür.

İlk mafsall için yük faktörü Modal X yüklemesinde ZA zemin sınıfı 2.23 iken aynı yükleme için ZE zemin


sınıfında bu değer 1.19 olmuştur. Diğer zemin sınıflarında buna benzer şekilde lineer bir azalış meydana gelmiştir. Ek dışmerkezliğin dikkate alındığı X-eccY yüklemesinde ilk mafsallın oluştuğu andaki yük faktörü ve maksimum yük faktörü değerleri ZA için sırasıyla 2.15 ve 3.14 olurken ZE için bu değerler 1.15 ve 1.70 olarak elde edilmiştir. Ek dışmerkezlik ve deprem kuvvetlerinin birleştirildiği X+0.3Y-eccY yüklemesinde ilk mafsallın oluştuğu andaki yük faktörü ve maksimum yük faktörü değerleri ZA için sırasıyla 1.98 ve 2.89 olarak belirlenirken ZE zemin sınıfı için bu değerler 1.04 ve 1.55 olarak tespit edilmiştir.

Y yönü için elde edilen sonuçlar değerlendirildiğinde X yönündeki sonuçlara paralel değerler elde edilmiştir. İlk mafsalsız için yük faktörü Modal Y yüklemesinde ZA zemin sınıfı 1.54 iken aynı yüklemeye için ZE zemin sınıfında bu değer 0.81 olmuştur. Maksimum yük faktörü açısından bakıldığında aynı zemin sınıfı ve aynı yüklemeye için bu değerler 2.12'ye karşılık 1.12 olmuştur. Ek dışmerkezliğin dikkate alındığı Y+eccX yüklemesinde ilk mafsalsız oluştuğu andaki yük faktörü ve maksimum yük faktörü değerleri ZA için sırasıyla 1.21 ve 1.85 olarak belirlenirken ZE zemin sınıfı için bu değerler 0.64'e karşılık ve 0.98 olarak elde edilmiştir.


faktörü değerleri ZA için sırasıyla 1.31 ve 1.95 olurken ZE için bu değerler 0.69 ve 1.03 olarak elde edilmiştir. Ek dışmerkezlik ve deprem kuvvetlerinin birleştirildiği Y+0.3X+eccX yüklemesinde ilk mafsalsız oluştuğu andaki yük faktörü ve maksimum yük faktörü değerleri ZA için sırasıyla 1.21 ve 1.85 olarak belirlenirken ZE zemin sınıfı için bu değerler 0.64'e karşılık ve 0.98 olarak elde edilmiştir.

Tablo 5. Tüm zemin sınıfları için ilk mafsalsız oluştuğu yük faktörü ve maksimum yük faktörü değerleri


Zemin Sınıfı	Yük Faktörü	X	X-eccY	X+0.3Y-eccY	Y	Y+eccX	Y+0.3X+eccX
ZA	İlk Mafsalsız Oluştugu Andaki	2.23	2.15	1.98	1.54	1.31	1.21
	Maksimum	3.23	3.14	2.89	2.12	1.95	1.85
ZB	İlk Mafsalsız Oluştugu Andaki	2.00	1.93	1.78	1.43	1.23	1.15
	Maksimum	2.88	2.81	2.61	1.97	1.82	1.73
ZC	İlk Mafsalsız Oluştugu Andaki	1.41	1.37	1.24	0.95	0.81	0.75
	Maksimum	2.05	1.99	1.93	1.32	1.21	1.15
ZD	İlk Mafsalsız Oluştugu Andaki	1.35	1.31	1.17	0.91	0.77	0.71
	Maksimum	1.96	1.91	1.74	1.26	1.16	1.1
ZE	İlk Mafsalsız Oluştugu Andaki	1.19	1.15	1.04	0.81	0.69	0.64
	Maksimum	1.74	1.70	1.55	1.12	1.03	0.98




Şekil 5. X yönünde ilk mafsalsız oluştuğu yük faktörü değeri



Şekil 6. X yönünde maksimum yük faktörü değeri



Şekil 7. Y yönünde ilk mafsalsız oluştuğu yük faktörü değeri



Şekil 8. Y yönünde maksimum yük faktörü değeri

Sonuçlar

Bu çalışmada birleşik deprem etkilerinin ve ek dışmerkezliğin betonarme binaların davranışına etkisi statik itme yöntemiyle incelenmiştir. Sayısal çalışma için seçilen betonarme binanın beş zemin sınıfına (ZA, ZB, ZC, ZD ve ZE) göre toplam 30 adet doğrusal olmayan itme analizleri yapılmıştır. Analizler sonucunda ek dışmerkezliğin bulunmadığı durum için Modal X ve Y yüklemesi, ek dışmerkezlik için en olumsuz sonucu veren X-eccY, Y+eccX yüklemeleri ve ek dışmerkezliğe ilaveten deprem kuvvetlerinin de birleştirildiği durum olan Y+0.3X+eccX, X+0.3Y-eccY yüklemeleri seçilmiştir. Yapılan analizlere göre elde edilen sonuçlar aşağıda maddeler halinde verilmiştir.

- Analizler sonucunda zemin sınıfının binanın kapasitesini etkileyen önemli bir faktör olduğu görülmüştür. En yüksek kapasite eğrileri ZA zemin sınıfı için elde edilirken, en düşük eğriler ZE zemin sınıfı için elde edilmiştir.
- Kapasite değerlerini etkileyen diğer faktörün ek dışmerkezlik olduğu tespit edilmiştir. Ek dışmerkezlik dikkate alınarak yapılan analizlerde kapasite eğrilerinde azalmalar görülürken yapısal elemanlardaki plastik mafsalları sayısının arttığı belirlenmiştir. Bununla birlikte ek dışmerkezlik hem ilk mafsalları oluşturduğu andaki hem de maksimum yüklemeye faktörlerinin azalmasına neden olmuştur.
- Deprem kuvvetlerinin birleştirilmesiyle yapılan analizlerde ise hem kapasite eğrilerinin hem de hasarın önemli ölçüde etkilendiği görülmüştür. Birleşik deprem kuvvetleri özellikle ZC, ZD ve ZE zemin sınıflarında yapısal elemanlardaki plastik mafsalları sayısını artırmıştır. Bu etki yük faktörlerini de ek dışmerkezlik gibi etkileyerek zemin sınıfına bağlı olarak yaklaşık %50 oranında azaltmıştır.

Sonuç olarak betonarme binaların tasarımında daha doğru ve sağlıklı sonuçlar elde edilmesi için zemin sınıfının doğru bir şekilde tespit edilmesi ve sayısal hesaplamalarda birleşik deprem etkilerinin ve ek dışmerkezliğin dikkate alınması gerektiği bu çalışmayla önerilmektedir.

Kaynaklar

- [1] D. Dismukes, M. Kreger, and R. Tso, "Seismic load combinations and their effects on building performance," *Earthquake Engineering & Structural Dynamics*, 49(1), pp.22-38, 2020.
- [2] A. J. Kappos, M. Papadrakakis, I. Koutromanos, "Performance-Based seismic design of structures," *CRC Press*, 2019.
- [3] A. Askan, and E. Kalkan, "Improved seismic performance assessment of structures using combined seismic load cases" *Journal of Structural Engineering*, 144(3), 2018, 04017121.
- [4] S. L. Kramer, "Geotechnical earthquake engineering," *Prentice Hall*, 2021.

- [5] A. K. Chopra, "Dynamics of structures: Theory and applications to earthquake engineering," *Pearson*, 2017.
- [6] J. P. Moehle., "Building performance assessment: Lessons from the past, challenges for the future," *Journal of Structural Engineering*, 140(3), 2014, 04014007.
- [7] J. H. Kuo, Y. T. Chen, and L. C. Hsu, "Effects of eccentricity on structural seismic response," *Engineering Structures*, 214, 2020, 110408.
- [8] J. Jankowski, "Structural analysis: Principles methods and applications," *Springer*, 2019.
- [9] M. H. El Naggar, and M. Elgawady, "Seismic performance of structures with eccentricities: A comprehensive study," *Earthquake Engineering and Structural Dynamics*, 47(7), pp.1416-1436, 2018.
- [10] J. Kozak, "Dynamic response of eccentric structures under seismic loads. *Journal of Structural Engineering*, 147(5), 2021, 04021052.
- [11] *Türkiye Bina Deprem Yönetmeliği*, 2018
- [12] G. Mucedero, D. Perrone, and R. Monteiro, "Nonlinear static characterisation of masonry-infilled RC building portfolios accounting for variability of infill properties," *Bulletin of Earthquake Engineering*, 19(6), pp.2597-2641, 2021.
- [13] G. Srinath, S. Swain, and K. Gopikrishna, "Seismic capacity estimation for composite multi-storeyed RC buildings," *Materials Today: Proceedings*, 93, pp.362-369, 2023.
- [14] R. Kurniawan, A. L. Budi, and S. H. Sourkan, "Pushover analysis of 10-floors reinforced concrete building (Case study: Mahkota Majolelo Sati Boutique Hotel)," *In IOP Conference Series: Materials Science and Engineering*, Vol. 1041, No. 1, p. 012003. IOP Publishing, 2021.
- [15] B. Yön, and Y. Calayır, "Effects of confinement reinforcement and concrete strength on nonlinear behaviour of RC buildings," *Computers and Concrete: An International Journal*, 14(3), pp.279-297, 2014.
- [16] O. Onat, B. Yön, and Y. Calayır, "Seismic assessment of existing RC buildings before and after shear-wall retrofitting," *Gradevinar*, 70(8), pp.703-712, 2018.
- [17] M. E. Öncü, and M. Şahin Yön, "Assessment of nonlinear static and incremental dynamic analyses for RC structures," *Computers and Concrete*, 18(6), pp.1195-1211, 2016.
- [18] K. K. Kuria, O. K. Kegyes-Brassai, "Nonlinear static analysis for seismic evaluation of existing RC Hospital Building," *Applied Sciences*, 13(21), 2023, 11626.
- [19] J. B. Mander, M. J. N. Priestley, R. Park, "Theoretical stress-strain model for confined concrete," *J Struct Eng*, 114:1804-26, 1988.
- [20] M. Menegotto, P. E. Pinto, "Method of Analysis for Cyclically Loaded RC. plane frames including changes in geometry and non-elastic behavior of elements under 106 combined normal force and bending. *Symposium on the Resistance and Ultimate Deformability of Structures Acted on by Well Defined Repeated Loads, International Association for Bridge and Structural Engineering*, Zurich, Switzerland, pp. 15-22, 1973.



Geleneksel Urfa Evlerinin Yapım Teknikleri: Temeller ve Duvarlar

*Construction Techniques of Traditional Urfa Houses: Foundations and Walls*Şeyda İNCE GAYBERİ^{1*}, Neslihan DALKILIÇ²¹ Harran Üniversitesi, Güzel Sanatlar Fakültesi, Mimarlık Bölümü, seydaincegayberi@gmail.comORCID: <https://orcid.org/0000-0002-0981-4022>² Dicle Üniversitesi, Mimarlık Fakültesi, nesdalkilic@gmail.comORCID: <https://orcid.org/0000-0003-3920-9904>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 16 Kasım 2024
Revizyon 1 Aralık 2024
Kabul 10 Aralık 2024
Online 23 Aralık 2024

Anahtar Kelimeler:

Geleneksel Yapım Teknikleri,
Malzeme,
Urfa,
Restorasyon

ÖZ

Geleneksel Urfa evleri, yöresel malzeme olan kireç taşları kullanılarak yığma yapım tekniğiyle inşa edilmiştir. Bu yapılar, bölgenin iklim ve topografyasına uygun olarak tasarlanmıştır. Ancak, günümüzde geleneksel yapım tekniklerine hâkim taş ustalarının azalması ve nesiller arası bilgi aktarımındaki kesintiler, bu bilgilerin unutulmasına neden olmakta, geleneksel yöntemlerle inşa edilmiş Urfa evlerinin restorasyonunda çeşitli sorunlara yol açmaktadır. Bu bağlamda, geleneksel Urfa evlerinin inşa tekniklerinin detaylı incelenmesi hem restorasyon sorunlarının çözümüne hem de bu yapıların kültürel değerinin sürdürülebilirliğine katkı sağlayacaktır. Bu makale, geleneksel Urfa evlerinin temel ve duvar yapım tekniklerini detaylı bir şekilde incelemektedir. Geleneksel Urfa evlerinde temeller genellikle sağlam kaya zemin üzerine inşa edilmiş, yapımında çoğunlukla yöresel kireç taşı kullanılmıştır. Temel yapım yöntemleri çok katmanlı kültürel yapının korunmasına da katkı sağlamıştır. Geleneksel Urfa evlerinde duvar yapım teknikleri ise taş duvarın örülme biçimine, taşların yontulma biçimlerine ve duvarların konumlarına göre irdelenerek değerlendirilmiştir. Bu kapsamda, geleneksel Urfa evlerinde bulunan ve zengin birer tasarım örneği olan duvar elemanlarının da detaylarına yer verilmiştir. Çalışma sonunda, geleneksel malzeme ve yapım tekniği kullanımının önemine vurgu yapılırken geleneksel evlerin özgün niteliklerinin korunarak yaşatılması için öneriler sunulmuştur.

ARTICLE INFO

Article history:

Received 16 Kasım 2024
Received in revised form 1 Aralık 2024
Accepted 10 Aralık 2024
Available online 23 December 2024

Keywords:

Traditional Construction technique,
Material,
Urfa,
Restoration.

Doi: 10.24012/dumf.1586669

* Sorumlu Yazar

ABSTRACT

Traditional Urfa houses were built with masonry construction technique using limestone, which is a local material. These structures were designed in accordance with the climate and topography of the region. However, today, the decrease in the number of stonemasons who have mastered traditional construction techniques and the interruptions in the transfer of knowledge between generations cause this knowledge to be forgotten, leading to various problems in the restoration of Urfa houses built with traditional methods. In this context, a detailed examination of the construction techniques of traditional Urfa houses will contribute to both the solution of restoration problems and the sustainability of the cultural value of these buildings. This article analyses the foundation and wall construction techniques of traditional Urfa houses in detail. The foundations of traditional Urfa houses were generally built on solid rock ground and local limestone was mostly used in their construction. Foundation construction methods also contributed to the preservation of the multi-layered cultural structure. Wall construction techniques in traditional Urfa houses were analyzed and evaluated according to the way the stone wall was built, the way the stones were chipped and the position of the walls. In this context, the details of the wall elements in traditional Urfa houses, which are rich examples of design, are also included. At the end of the study, while emphasizing the importance of the use of traditional materials and construction techniques, suggestions are presented for the preservation of the original qualities of traditional houses.

Giriş

Dünyanın en eski yerleşim yerlerinden biri olan Urfa, tarih boyunca birçok medeniyetin merkezi konumunda yer almıştır. Günümüzde ise tarihin sıfır noktası olarak kabul edilen ve UNESCO Dünya Miras Listesi'ne giren Göbeklitepe'nin keşfiyle küresel ölçekte bilinirliği artmıştır. Roma, Bizans, Emeviler, Abbasiler, Selçuklular, Eyyubiler ve Akkoyunlular gibi birçok büyük medeniyete ev sahipliği yapmış olan kent, anıtsal ve sivil mimari örneklerinin bir arada bulunduğu zengin bir mimari mirasa sahiptir. Urfa'nın tarihi kent dokusu, artan turizm etkisiyle kapsamlı bir restorasyon ve dönüşüm sürecine girmiştir. Bu dönüşüm sürecinde, kentin geleneksel mimarisinin en önemli unsurlarından biri olan geleneksel Urfa evleri, bölgenin tarihi ve kültürel kimliğini yansıtan yapılar olarak ön plana çıkmaktadır.

Tarihi yapıların restorasyonunda özgün mimari ve yapım tekniklerinin korunması önem arz etmektedir. Geleneksel Urfa evleri, kentin çevresinde yoğun olarak bulunan kireç taşı ile yığma yapım tekniğinde inşa edilmiştir. Bu yapılar, bölgenin iklimsel ve topografik özelliklerine uyum sağlayacak şekilde tasarlanmıştır. Günümüzde geleneksel yapım tekniklerine hâkim olan taş ustalarının sayısının azalması ve nesiller arası bilgi aktarımının kesintiye uğraması, restorasyon uygulamalarında nitelikli iş gücü bulma zorluğunu da beraberinde getirmiştir. Bu durum, geleneksel yapım teknikleriyle inşa edilmiş Urfa evlerinin restorasyon süreçlerinde sorunlar yaratmaktadır. Yapılan restorasyon uygulamalarında, bilinçsiz bir şekilde, çağdaş malzeme kullanımına yönelmenin de özgün mimari karakterin bozulmasına neden olduğu gözlemlenmektedir.

Geleneksel yapım tekniklerini anlatan bilimsel çalışmaların ve yayınların azlığı, geleneksel bilgi birikiminin geleceğe aktarılmasını da engellemektedir. Mevcut kaynakların yetersizliği, restorasyon süreçlerinin bilimsel doğruluktan uzaklaşmasına ve yerel mimari kimliğin zayıflamasına neden olmaktadır. Ancak bazı restorasyon uygulamalarında, geleneksel yapım teknikleri konusunda uzman az sayıdaki taş ustasının aktif olarak çalışmaya devam etmesi, bu tekniklerin yaşatılmasına ve sonraki nesillere aktarılmasına olanak tanımaktadır. Bu ustaların bilgileri, gelecek nesiller için büyük bir kültürel miras niteliği taşımaktadır.

Urfa'nın tarihi kent dokusunun ve geleneksel yapılarının korunmasına yönelik bilimsel restorasyon uygulamalarının yapılması gerekliliği, geleneksel yapım tekniklerine olan ilgiyi artırmıştır. Ancak bu alanda

yapılmış bilimsel araştırmalar hâlâ yetersizdir. Geleneksel yapım tekniklerinin çağdaş malzeme ve tekniklerle entegrasyonu konusunda daha fazla araştırmaya ihtiyaç duyulmaktadır. Bu bağlamda, restorasyon süreçlerinin bilimsel temellere dayandırılması, tarihi yapıları gelecek nesillere sağlam bir şekilde aktarabilmek adına hayati önem taşımaktadır.

Bu çalışma kapsamında, geleneksel Urfa evlerinin temel ve duvar yapım teknikleri incelenmiş, özgün malzeme ve yapım yöntemlerine dair tespitler yapılmıştır. İncelemeler sırasında, özgün yapım tekniklerinin korunmasının yanı sıra restorasyon süreçlerine adaptasyonunun önemi de vurgulanmıştır. Bu tekniklerin günümüzde ve gelecekte kullanılmaya devam edebilmesi amacıyla, hayatta kalan en eski taş ustalarının uygulamaları yerinde incelenerek geleneksel yapım tekniklerine dair detaylı bilgiler elde edilmiştir. Bu çalışma, geleneksel yapım tekniklerinin korunması ve uygulanmasına yönelik önemli bir kaynak oluşturmayı amaçlamaktadır.

Geleneksel Urfa Evlerinin Genel Karakteristik Özellikleri

Geleneksel Urfa evlerinin mimarisi, sosyo-kültürel yapı, jeolojik özellikler ve iklim koşullarının etkisiyle biçimlenmiştir. Geleneksel Urfa evleri, geniş aile yapısına uygun şekilde tasarlanmış; birkaç kuşak bir arada yaşarken mahremiyeti sağlamak amacıyla haremlik ve selamlık bölümleri oluşturulmuştur. Evlerin boyutları, aile nüfusu ve ekonomik durum gibi faktörlere bağlı olarak değişkenlik göstermektedir. Bu evler, coğrafi koşullara uygun olarak yığma taş yapı tekniğiyle inşa edilmiş, kalın duvarları ve serinliği sağlayan açık alanlarıyla bölgenin iklimine uyum sağlamıştır [1-3].

Geleneksel Urfa evleri, avlu, eyvan, oda, gezenek¹ ve servis mekânlarından oluşan işlevsel bir planlama düzenine sahiptir. Bu evlerde, avlu merkezli bir planlama anlayışı benimsenmiş; avlu, günlük yaşamın geçtiği ve mekânlar arasındaki bağlantıyı sağlayan bir odak noktası olarak tasarlanmıştır. Çoğunlukla dörtgen planlı olan avlular; odalar, eyvanlar ve tandırlık gibi birimlerle çevrilmiş, yüksek sağır duvarlarla sınırlandırılmıştır. Avluların ortasında genellikle bir süs havuzu, kuyu ve bitki yetiştirme alanı bulunmaktadır [1-2] (Şekil 1).

Zemin katta, genellikle avlu seviyesinden birkaç basamak yüksekte tasarlanan oda, eyvan, tandırlık gibi günlük yaşam alanları ile ahır, tuvalet ve ender olarak hamam gibi servis mekânları yer alır. Hamamlar, tandırlık ile bağlantılı ve genellikle evin içinden ulaşılan bağımsız birimlerdir. Avlu kotunun altında bulunan ve

¹Geleneksel Urfa evlerinde üst katta bulunan eyvanların önünde yer alan, avluyu yukarıdan dolaşan ve mekânlar arasındaki bağlantıyı sağlayan üstü açık, ince uzun balkon.

“zerzembe” adı verilen kilerler, yiyeceklerin sıcak havadan korunmasını sağlayan serin depolama

alanlarıdır. Üst katlarda ise odalar, eyvanlar, gezenekler ve nadiren tuvalet gibi birimler bulunmaktadır [1-3].



Şekil 1: Geleneksel bir Urfa evi

Geleneksel Urfa evlerinin odaları, yazlık ve kışlık kullanım ayırımına göre tasarlanmış, günlük yaşamın çeşitli ihtiyaçlarını karşılayacak işlevsellikte planlanmıştır. Bu odalar hem gündüz hem de gece kullanılabilir şekilde düşünülmüş, yerleşim ve kullanım açısından oldukça pratik mekânlardır. Odaların duvarlarında, halk arasında “camhane” olarak bilinen, yatak ve eşyaların depolanması için kullanılan kapaklı ya da kapaksız gömme nişler yer alır. Bu mimari unsurlar hem düzen hem de işlevsellik açısından büyük önem taşır [3].

Odalara girişte, oda seviyesinin yaklaşık 15-20 cm altında yer alan ve kapı genişliği boyunca uzanan “gedemeç” adı verilen alan, ayakkabıların çıkarıldığı bir geçiş bölgesi olarak işlev görmektedir. Buradan esas oturma alanına geçiş sağlanır. Zemin kattaki odaların pencereleri avluya açılırken, üst katta bulunan odaların pencereleri hem avluya hem de sokağa bakacak şekilde yerleştirilmiştir. Özellikle “başoda” olarak adlandırılan ana odalarda, zengin ahşap süslemelerle donatılmış duvar kaplamaları dikkat çekmektedir [4]. Bu süslemeler, odanın statüsüne ve ev sahibinin ekonomik durumuna göre farklılık gösterebilir ve geleneksel Urfa evlerinin estetik anlayışını yansıtır [1].

Geleneksel Urfa Evlerinde Temellerin Yapım Teknikleri

Geleneksel Urfa evlerinin inşasında kullanılan temel yapım teknikleri, zemin koşulları ve bölgedeki malzeme olanaklarına bağlı olarak çeşitlenmektedir. Bu teknikler,

geleneksel Urfa evlerinin dayanıklılığını ve bölgenin iklim koşullarına uygunluğunu sağlamış, aynı zamanda yapının uzun ömürlü olmasına katkıda bulunmuştur.

Urfa'nın eski kent dokusu kayalık bir zemin üzerine kurulmuştur ve evlerin temelleri genellikle bu sağlam kaya yapısına oturtulmuştur. Temel kazısı sırasında, önceki yapı kalıntılarında rastlandığında, mevcut temellerin üzerine yeni yapılar inşa edilirdi. Bu durum, özellikle araştırma kazılarında ve sondaj çalışmalarında, birden fazla kültürel katmanın ortaya çıkmasına olanak tanımaktadır. Ayrıca, bazı evlerin bodrum döşemelerinde, bölgenin çok katmanlı yapısının önemli bir kanıtı olan antik dönem yapılarına ait mozaik kalıntıları bulunmuştur [3] (Şekil 2, 3).

Temel inşasında genellikle taş ocaklarının üst kısımlarından çıkarılan, hava koşullarına daha dayanıklı kireç taşları tercih edilmiştir. Bu taşlar, yerel malzeme olan kireç taşının suya karşı hassasiyeti dikkate alınarak seçilmiştir. Bazı temel yapılarında ise bazalt taşı kullanımı da görülmüştür. Temelin sağlam bir şekilde oturması için, kaya zeminine ulaşmaya kadar kazı yapılmış; kaya yapısına rastlanmadığında ise büyük ebatlı taşlar kullanılarak temeller güçlendirilmiştir. Bu taşlar, yaklaşık 35x45x90 cm veya 35x50x100 cm büyüklüğünde olup tek parça ve kaba yontulmuş şekilde kullanılmıştır [3].



Şekil 2: a. b. Geleneksel bir Urfa evinin avlusunda kazılar sonucunda ortaya çıkan eski dönemlere ait yapı kalıntıları



Şekil 3: Urfa tarihi kent dokusundaki geleneksel bir Urfa evinin bodrum zemininde ortaya çıkarılan mozaikler

Temel yapımında, yapının yük dağılımına ve zeminin dayanıklılığına göre farklı yöntemler uygulanmıştır. Kaya zeminine oturan temeller daha dar ve yüzeye yakın olurken, kaya yapısına rastlanmayan bölgelerde temeller daha geniş ve derin yapılmıştır. Kaya zeminine ulaşıldığında, yüzey düzeltilip tarak ve çekiç gibi aletlerle işlenerek temel duvarları için uygun zemin hazırlanmıştır.

Temelerde sadece duvar örülecek yerlerde hatıl yerleri kazılıp doldurulur, odaların orta kısımlarındaki boşluklar taş ve toprak ile dolgu yapıp tesviye edilir, üzerine oda döşemesi yapılırdı.

Blokaj sistemi, temel yapımının önemli bir parçası olarak karşımıza çıkar. Bu sistemde, toprağın sağlam zemine kadar kazıldığı çukurlara taş dolgu yapılmış ve böylece yapı ile zemin arasındaki nem, su ve tuz etkileri en aza indirilmeye çalışılmıştır. Blokaj yapımında kullanılan taşlar, genellikle dere kenarlarından toplanan ve yerel halk arasında “*çakmak taşı*” veya “*dere taşı*” olarak bilinen, yaklaşık 10-25 cm çapında ve 5-10 cm kalınlığında doğal taşlardır. Bu malzemelerin, zeminin sıkışmasını ve temelin sağlamlığını artırdığı bilinmektedir [5].

Blokajın ardından, temel duvarlarının altı çamur harcı ile düzeltilir ve üzerine büyük ebatlı taşlar dizilirdi. Bu taşlar, sağlam ve düz bir temel oluşturulması için tek sıra halinde yerleştirilirdi. Temelin sağlam olması için her taş özenle yerleştirilir ve boşluk kalmamasına dikkat edilirdi. Temel yapıları, taşıyıcı duvarlardan daha geniş yapılır ve yük geniş bir alana dağıtılarak sağlamlık sağlanırdı. Örneğin, taşıyıcı duvar 60-70 cm genişliğinde ise temeller genellikle 100-120 cm genişliğinde ve 100-150 cm derinliğinde kazılırdı. Temel dolgusu yapıldıktan sonra üzerine 50-60 cm kalınlığındaki “*ebatlı taşlar*” koyulurdu.

Temel zemininin yeterince sağlam olmadığı durumlarda, kademe sistemi uygulanır ve duvar genişliğine göre 2-3 kademeli temel ayakları inşa edilirdi. Bu kademeler, yapıların yüklerini düzgün bir şekilde zeminine ileterek sağlamlık sağlardı. Özellikle tonoz ve kemerlerin taşıdığı ağırlıklar göz önünde bulundurularak, ayaklar ve revaklarda sütunların altına kademeli basamaklı temeller yapılırdı.

Temel yapımının son aşamasında, düzgünleştirilmiş zeminin üzerine yapı temelleri, moloz taş örgü sistemiyle inşa edilirdi. Çaplanmış moloz taşlar düzgün bir şekilde örülür, aralarına küçük moloz taşları ve çamur harç ile dolgu yapılırdı. Zemin kotu altında kalan bu moloz taş duvarlar, oldukça sağlam ve dayanıklıydı (Şekil 4). Temel duvarlarının üzerlerine ise, yük taşıyıcı kaba veya ince yonu taşlar yerleştirilerek sağlam taşıyıcı duvarlar oluşturulurdu.




Şekil 4: Moloz temel duvarı

Temel duvarlarının üzerine, düzgün bir zemin oluşturacak şekilde tesviye edilmesinin ardından, yapının taşıyıcı duvarlarının yapımına geçilir, kaba veya ince yonu taşlarla “*taşıyıcı duvarlar*” inşa edilirdi. Bu taşıyıcı duvarların sağlam temeller üzerine oturması, binanın dayanıklılığını artırır ve yapının uzun ömürlü olmasını sağlardı. Düzgün bir duvar tabanı oluşturmak için, moloz temel duvarların üzerine büyük boyutlu taşlar dikkatlice

dizilirdi. Daha sonra yapının taşıyıcı duvarlarının örülmesine geçilirdi.

Geleneksel Urfa evlerinde, temel ve bodrum katlarda kullanılan teknikler doğal su ve nem yalıtımı sağlardı.

Kireç taşlarının hava geçirgenliği ve duvar örgüsünde kullanılan teknikler, temellerde oluşabilecek rutubet ve nemin uzaklaştırılmasını sağlardı (Şekil 5).



Şekil 5: Geleneksel Urfa evlerindeki temel ve duvar sistemi (Gayberi, 2019)

Geleneksel Urfa evlerinin inşasında en sık kullanılan harç malzemesi “kül kireç harcı” idi. Temel yapımında da harç malzemesi olarak kullanılan kül kireç harcı; kül ve kireç karışımıyla (kül kireç karışımı) elde edilir ve taş tozu (kireç taşı tozu) ve su ile karıştırılarak kullanılırdı. Kül kireç harcı; özellikle hamam ocaklarında (külhan) yakılan kireç taşlarının ateş etkisiyle dökülmesiyle elde edilen kül ile karıştırılan kireçten üretilirdi. Kireç taşları külhanın içine dizilir, taşlar yandıkça dökülen parçalar kül ile karıştırılır ve dışarıda elenerek yabancı maddelerden arındırılıp ince bir malzeme haline getirilirdi. Bu malzeme “kül kireç” olarak adlandırılırdı

ve taş tozu ile su karıştırılarak harç haline getirilirdi. Kül kireç harcı, taş tozu ve su ile karıştırılarak kullanılabilirdi gibi sadece kül kireç ve su karışımıyla da elde edilebilirdi.

Evlerin temellerinde kullanılan kül kireç harcı, temel duvarlarının dayanıklılığını artırır ve yapı ömrünü uzatırdı. Bazı durumlarda ise, temel inşasında “çamur harcı” da tercih edilirdi. Çamur harcı, toprak, kireç ve suyun karıştırılmasıyla elde edilir ve genellikle temel dolgusunda akışkan bir harç olarak kullanılırdı. Bu çamur harç, temel dolgusundaki moloz taşların arasına inceltilmiş şekilde dökülerek taşların arasındaki

boşlukların tamamen doldurulmasını sağlardı. Bu harç taşların arasına nüfuz ederek temel duvarlarının sağlamlığını artırır. Kimi yapılarda ise, temel duvarlarının örgüsünde kül kireç harcı kullanılırken, temel dolgusunda çamur harcı tercih edilirdi. Bu yöntemler, yapının hem dayanıklılığını hem de bölgenin iklim koşullarına uyumunu sağlardı [3].

Geleneksel Urfa Evlerinde Taş Duvarlar ve Yapım Teknikleri

Geleneksel Urfa evlerinde duvarlar; örgü sistemine göre, taşların işlenmişlik durumlarına göre ve buldukları yere göre incelenmiştir.

Örgü Sistemine Göre Duvarlar

Duvarlar, örgü sistemine göre, tek cidarlı duvarlar (misafat duvarlar) ve üç cidarlı duvarlar (sandık duvarlar) olarak ikiye ayrılır.

Tek Cidarlı Duvar

Taşıyıcı niteliğe sahip olmayan tek cidarlı duvarlar, genellikle ayırıcı elemanlar ya da iç mekân bölme duvarları olarak tercih edilmektedir. Bu tür duvarlar, tek bir sıra halinde inşa edilmekte olup herhangi bir dolgu malzemesi ile desteklenmemektedir. Tek cidarlı duvar

yapımında, yüzeyleri düzgün yontulmuş kesme taşlar kullanılmaktadır. Urfa'da halk arasında bu duvarlara "misafat duvar" denir ve kullanılan düzgün kesme taşlar da "misafat taşı" olarak bilinir. Misafat taşlarının yaklaşık boyutları derinlik 15-25 cm, yükseklik 25 cm ve uzunluk 50 cm olacak şekilde belirlenmiştir. Bu duvarlar genellikle ayırıcı (bölücü) duvar olarak kullanılmakla birlikte, bazı durumlarda taşıyıcı duvar işlevi de görebilir.

Kesme taşlardan yapılan tek cidarlı duvarlarda, çok ince bir harç (1-2 mm) ile taşlar birbirine bağlanırdı (Şekil 6). Harç, kireç, beyaz toprak ve su karışımından elde edilen, macun kıvamındaki kireç harcıdır. Tek cidarlı duvarlarda taşların yan yüzeylerine "külünk" denilen "şerbet kanalları" açılır ve arasına "şerbet harcı" dökülürdü. Şerbet harcı; kırmızı, siyah veya beyaz kumun ince elekte elenip, yaklaşık olarak yarısı kireç yarısı elenmiş kum olacak şekilde su ile karıştırılıp akışkan bir harç olarak hazırlanan malzemedir. Kırmızı kum, dere kenarlarından elde edilir, siyah kum Fırat Nehri'nin bulunduğu bölgeden alınırdı. Beyaz kum ise kireç taşının ezilmesi/öğütülmesiyle elde edilirdi. Kırmızı kum/toprak, Urfa'da eski ustalar arasında "felhan" olarak adlandırılmıydı.



Şekil 6: a. b. İç mekânlarda kullanılan "tek cidarlı duvar" örnekleri

Üç Cidarlı (Sandık) Duvar

Üç cidarlı duvarlar, taşıyıcı duvar olarak kullanılmakta ve halk arasında "beden duvarı" olarak adlandırılmaktadır. Bu duvarların kalınlıkları bulunduğu yere ve taşıdığı yüke bağlı olarak değişir. Zemin katlarda duvar kalınlığı 120 cm'ye kadar çıkabilirken, üst katlarda bu kalınlık 60-100 cm arasında değişmektedir. Üç cidarlı duvarlarda, her iki yüzde kullanılan ince yonu veya kaba yonu taşlar, ortadaki moloz taş dolgusuyla birleşir. Taşların ebatları; derinlik 12-25 cm, yükseklik 20-32 cm ve uzunluk 25-80 cm arasında değişir. Ortadaki 20-60 cm'lik dolgu kısmı ise moloz taş ve harç ile doldurulur (Şekil 7).

Üç cidarlı duvarlarda, taşlar arkadaki moloz dolguyla harç yardımıyla bağlanır. Moloz dolguda kırmızı toprak (felhan) ve su karışımından elde edilen "çamur harç" kullanılırdı ve bu harca bağlayıcılığı artırmak için kül kireç malzemesi eklenirdi. Ayrıca, bazı uygulamalarda harca "kendir ipi" doğranarak bağlayıcılık güçlendirilirdi. Moloz dolgular bir sıra moloz taş ve bir sıra harç şeklinde uygulanırdı.

Bu duvarlarda, genellikle şerbet kanalları açılmasına gerek duyulmazdı. Ancak, bazı yapılarda ince yonu taşların iki yanına tarakla şerbet kanalları açılarak şerbet harcı dökülürdü. Taşların birbirini daha iyi tutması için,

taşların iç kısımları murçlanarak pürüzlü hale getirilir ve örgüye daha kolay yerleşmesi sağlanırdı. Taşların kısa kenarlarına içeri doğru eğim verilerek taş-harç tutuculuğu artırılırdı (Şekil 8).




Şekil 7: Üç cidarlı duvar yapım aşamaları

Moloz taş ile yapılan üç cidarlı duvarlar genellikle yapının temel duvarlarında ve giriş katında, görsel açıdan önem taşımayan bölümlerde uygulanmıştır. Temel duvarları bittikten sonra zemin kotundan 1-2 sıra aşağıdan üç cidarlı duvar örülmeye başlanırdı.



Şekil 8: a. Geleneksel Urfa evinde yapılan üç cidarlı bir duvar kesiti ve b. Yonu taşın duvar içerisindeki görüntüsü


Bu duvarlar örülürken, bazı taşlar uzunlamasına moloz dolgunun içine yerleştirilirdi. “saplama taş” veya “kenet taşı” olarak adlandırılan bu taşlar, duvarın stabilitesini sağlamak için belirli aralıklarla kullanılırdı. Yaklaşık 25 cm yüksekliğinde, 30-40 cm genişliğinde ve 50-60 cm uzunluğundaki bu taşlar, duvarın içine uzunlamasına yerleştirilerek hatıl görevi görürdü (Şekil 9). Bu taşların duvarın içine doğru yontulup diğer taşlardan daha derin yerleştirildiği görülmektedir. Bu yöntemle, duvarın sağlamlaştırılması hedeflenirdi [6].



Şekil 9: Üç cidarlı duvar detayı ve saplama taş detay görünüşü (Gayberi, 2019)

Taşların İşlenmişlik Durumlarına Göre Duvarlar

İç mekânlarda tonoz başlangıç seviyesine kadar olan duvarlar ve avluya bakan duvarlar, ince yonu taşlarla örülmüştür [7]. Evlerin sokağa bakan zemin kat duvarlarında ve avlu duvarlarının sokağa bakan alt kısımlarında genellikle özen gösterilmemiş moloz taş veya kaba yonu taş örgü duvarlar yapılmıştır. Ayrıca, bazı temellerin moloz taş duvarlardan yapıldığı tespit edilmiştir (Şekil 10).



Şekil 10: Taşların işleme derecesine göre türleri [7]. a- Moloz Taş b/c- Kaba Yonu Taş d- İnce Yonu Taş e/f- Kesme Taş

Moloz Taş Duvarlar

Moloz taşların kaba bir şekilde köşeleri düzeltilerek düzensiz bir örgü sistemi ile inşa edilen duvarlara “*moloz taş duvar*” denir. Bu tür duvarlarda, taşların düzgün yüzeyli olmaması nedeniyle farklı boyut ve biçimlerde taşlar kullanılır ve taşlar harç ile bir arada tutulur. Moloz taş duvarların kalınlıkları genellikle en az 50 cm olarak uygulanır [7].

Duvarlar içerisine moloz dolgu yapılır ve bağlayıcı malzeme olarak kül kireç harcı tercih edilirdi. Moloz taş duvarlar bazen sıvasız bırakılır, bazı durumlarda ise kül kireç ya da kendir sıvası ile sıvanarak kullanılırdı.

Geleneksel yapım tekniklerinde, bu duvarlar genellikle temel duvarlarında, giriş katında görünmeyen kısımlarda, taşıyıcı duvarlarda, avlu duvarlarının sokağa bakan yüzlerinde ve iç örgüde kullanılmıştır (Şekil 11).




Şekil 11: Moloz taş duvar örneği

Kaba Yonu Taş Duvarlar

Kaba yonu taş duvarlar, görünen yüzeyleri tarak aleti ile düzeltilerek dikdörtgene yakın bir şekil verilen taşların düzgün örgülü bir sistemde kullanıldığı duvarlardır. Bu tür duvarlar, moloz taş duvarlardan farklı olarak yatay taş sıralarının daha düzenli olmasıyla ayırt edilir. Taşlar genellikle aynı yükseklikte dizilirken, boyutları değişkenlik gösterebilir [7]. Kaba yonu taş duvarlarda da bağlayıcı malzeme olarak kül kireç harcı kullanılmıştır.

Bu duvar türü, zemin kat avlu ve sokak duvarlarında sıklıkla tercih edilmiştir (Şekil 12).



Şekil 12: Kaba yonu taş duvarlar

İnce Yonu Taş Duvarlar

İnce yonu taş duvarlar, tarak aleti ile görünen yüzeylerinin dikkatlice düzeltilerek, düzgün ve keskin köşeli taşlarla inşa edilen duvarlardır. Bu tür duvarlarda, dikdörtgen şekilli taşlar kullanılarak, düzgün yüzeyler oluşturulur ve yatay taş sıraları aynı yükseklikte olurken, taşların boyutları değişkenlik gösterebilir [7].

Duvarlar düzenli bir örgü sistemine sahip olup yatay derzler kesintisiz, derz aralıkları ise oldukça düzenlidir. (Şekil 13). Geleneksel Urfa evlerinde ince yonu taş duvarların örgüsünde kireç taşı tozu, kireç ve su karışımıyla elde edilen kireç harcı ince bir tabaka halinde kullanılırdı. Bu duvarlarda sıva yapılmaz, doğal görünüm korunurdu. İç mekânlarda, tonoz seviyesine kadar duvarlar sıvasız, tonoz başlangıcından itibaren kendir ya da kül kireç sıvası uygulanırdı. İnce yonu taş duvarlar hem zemin katta hem de üst katlarda, özellikle avluya ve sokağa bakan cephelerde kullanılmıştır.



Şekil 13: İnce yonu taş duvar örneği

Geleneksel Urfa evlerinde kullanılan üç cidarlı taş duvarların inşasında, taş bloklar arasındaki bağlayıcı malzeme olarak genellikle kireç harcı tercih edilmekteydi. Bu harç; kireç taşı tozu (beyaz ince kum), kireç ve suyun karışımıyla oluşturulurdu. Kireç harcı, macun kıvamına getirilerek kesme taşların arasına ince bir tabaka halinde sürülürdü. Ayrıca, bazı durumlarda

bağlayıcı malzeme olarak kül karışımı kireç harcı da kullanılırdı. Duvar örme işlemi sırasında, duvarın iki ucuna gerilen bir ip yardımıyla taş sıraları hizaya alınır ve derzlerin düzgün olması sağlanırdı. Taşlar arasındaki küçük boşluklar harç ile doldurularak kapatılırdı. Keser ile şekillendirilen taşların yan yüzeylerinin pürüzlü (dişli) olması, taşların birbirine sıkıca kenetlenmesini sağlardı.

Kesme Taş Duvarlar

Kesme taş duvarlar, tüm yüzeyleri tarak aleti veya taş kesme makineleri ile işlenerek düzgün bir dikdörtgen prizma formu kazandırılan taşların örgüde kullanıldığı duvarlardır [7]. Kesme taşlar derzli veya derzsiz olarak örülebilir. Geleneksel Urfa evlerinde, derzsiz duvar yapımında taşlar arasında 1-2 mm'lik ince bir harç tabakası kullanılarak taşlar birbirine sıkıca bağlanır, böylece çatlama riskleri azaltılırdı (Şekil 14). Bu duvarlara halk arasında “akçe geçmez duvar” da denir.



Şekil 14: Kesme taş duvar örneği (Şanlıurfa Mutfak Müzesi-Hacıbanlar Evi)

Buldukları Yere Göre Duvarlar

Sokak Duvarları

Geleneksel Urfa evlerinde, avlu duvarları zengin süslemelere sahipken, sokağa bakan duvarlar daha sade ve işlevseldir. Sokak duvarları genellikle moloz, kaba yonu ve ince yonu taşlardan inşa edilmiştir. Bazen bu taş türleri birlikte kullanılır; alt kısımlar moloz taş, üst kısımlar ise kesme taş olabilir. Sokak duvarları dışarıdan

Derzli duvarlarda 7-8 cm uzunluğunda ve 1 cm çapındaki demir çubuklar taşlar arasında boşluk bırakmak için yana gelerek iki taşın arasına konular, sonrasında derzler harç ile doldurulurdu. Kesme taş duvarlarda da kullanılan harç; kireç ve su karışımından oluşan kireç harcıdır. Geleneksel uygulamalarda, taşların yüzeyleri birbirini tam tutmadığında testere ile düzeltilerek taşlar birbirine kiltilenirdi.

Kesme taş duvarlarda, taşların iki yanına tarak aletiyle açılan şerbet kanallarından dökülen şerbet harcı kullanılarak taşların birbirine bağlanması uygulaması geçmişte yaygın olarak tercih edilmiştir. Ancak, geniş moloz dolgu ile desteklenen kesme taş duvarlarda, taşlar arasında şerbet kanalları açılması gereksinimi bulunmamaktadır.

avlunun içinin görülmesini engelleyecek yükseklikte yapılmıştır (Şekil 15).

Sokak duvarlarında; avlu kapıları, zemin kat pencereleri, üst katlardaki sokağa bakan pencereler ve çıkmalar bulunur. Çıkmalar ve kabaltılar, sokak cephelerine zengin bir görünüm kazandırır. Ayrıca, ev sahibinin ekonomik durumu ve evin büyüklüğüne bağlı olarak oldukça görkemli avlu kapıları, sokak duvarlarının öne çıkan önemli bir mimari öğesidir.



Şekil 15:Urfa tarihi kent dokusunda sokak duvarları

Avlu Cephe Duvarları

Evlerin avluya bakan duvarları sokak duvarlarına kıyasla daha hareketlidir. Büyük ailelere ait evlerde, kapı, pencere ve eyvan kemerleri gibi öğelerle birlikte çeşitli

taş bezemeleri zengin bir mimari sunar. Avlu duvarlarında ayrıca, kuşların yuva yapması için yapılan ve “kuş takası” olarak adlandırılan nişler ile pencere üstlerindeki madalyon şeklindeki havalandırma pencereleri dikkat çeken özgün elemanlardır (Şekil 16).



Şekil 16: Geleneksel Urfa evlerinde avlu cepheleeri

Ayırıcı Duvarlar- İç Duvarlar

Taşıyıcı olmayan tek cidarlı duvarlar, genellikle ayırıcı veya iç duvarlar olarak kullanılır. Bu duvarlar tek sıra olarak örülüp dolgu kullanılmaz (Şekil 6). Üç cidarlı duvarlara göre daha zayıf bir yalıtım sağlarlar. Bazen avlu duvarları tek sıra yapılırken, alt kısımları üç cidarlı duvar, üst kısımları ise tek sıra olarak inşa edilirdi.

Ayırıcı tek cidarlı duvarlar, genellikle 15-30 cm kalınlığında olup yük taşıma kapasiteleri oldukça yüksektir. Ancak, üst örtüdeki ahşap kirişlerin taşındığı/desteklendiği yerlerde üç cidarlı duvarlar tercih edilirdi.

Cumba Duvarları

Geleneksel Urfa evlerinde, parsellerin düzensiz olmasından dolayı üst katlardaki bazı odalar sokağa doğru "çıkma" yapar (Şekil 17). Çıkmaların yapıldığı iç mekânlar "cumba veya çardak" olarak adlandırılmaktadır. Çıkmalar, sokağı daha iyi görebilmek

ve üst katta daha düzgün mekânlar elde etmek için yapılır. Bu yapılan çıkmaların altında yer alan "taş konsollar ve kemerler", sokak cephelerini hareketlendirir. Bazı evlerde çıkmalar, sokağın üzerinde tonozlu kabaltılar oluşturacak kadar uzundur.

Geleneksel Urfa evlerinde cumbalar; taş konsolların taşıdığı, ağırlık binmemesi için tek cidarlı duvarlar ile yapılmış, taş konsolların (taş bingilerin) ve ahşap hatılların/metal profillerin oluşturduğu bindirme tekniği kullanılan taşıyıcı sistemlerdir (Şekil 18, 19). Cumbaların üzerine yapılan duvarlar (cumba duvarları), taş konsollarla desteklenmiş ve ağırlık binmemesi için tek cidarlı duvarlar şeklinde yapılmıştır. Ana taşıyıcı sistemini, kalın taşıyıcı duvarlara yerleştirilen taş bingiler ve ahşap hatıllar oluşturur. Taşlar birbirinin üzerine kaydırılarak konsol yapılır, en alt bingi taşı duvara saplanır. Cumbaların üzeri ahşap saçak veya toprak dam ile örtülür.



Şekil 17: Çıkma duvarları (Cumbalar) ve bingi taşları

Cumbaların taşıyıcı sistemlerinde kullanılan taş bingiler, kalınlıkları 125 cm'ye kadar ulaşabilen ana duvarın içine en az üçte biri kadar yerleştirilmiş birkaç sıra taş bingiden oluşmaktadır. Bu taşlar, 15-25 cm aralıklarla birbirinin üzerine kaydırılarak yerleştirilir. Çıkmanın en altındaki bingi taşı, taşıyıcı duvara yaklaşık 20-25 cm kadar saplanır. Uzunluğu yaklaşık 50 cm olan bu taşın üzerine yerleştirilen ve uzunlukları giderek artan diğer bingi

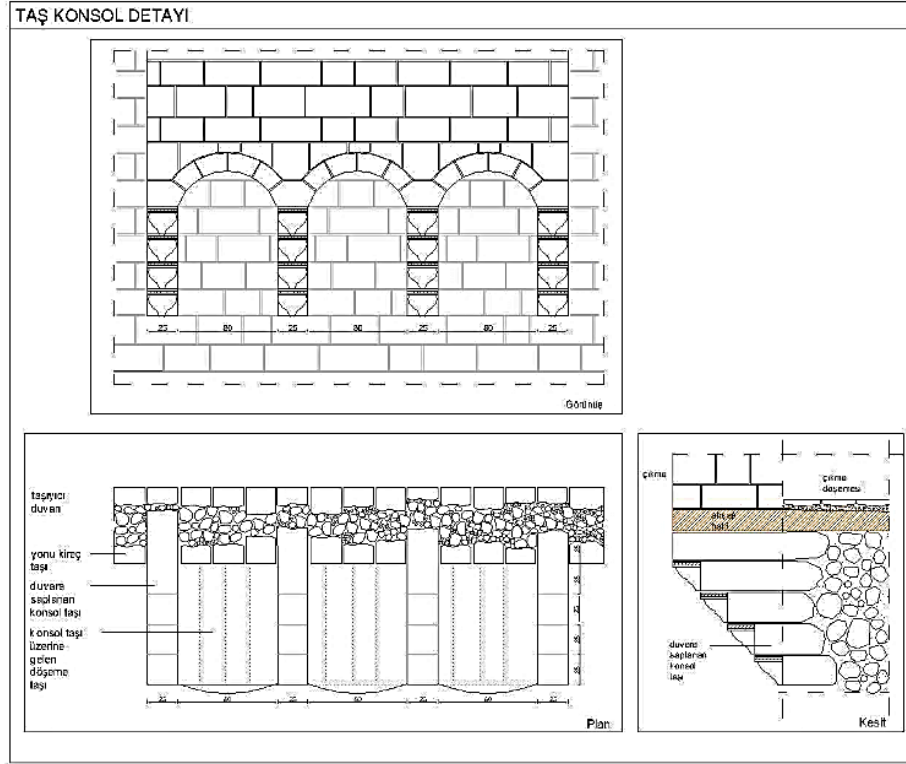
taşları, birbirlerinin önüne doğru yaklaşık 25 cm kaydırılarak konsol oluşturur. Yan yana 50-80 cm aralıklarla yerleştirilen taş bingiler, kemerlerle birbirine bağlanır ve çıkmanın ağırlığı, kemerler aracılığıyla iki yandaki taş bingilere (basamaklara) aktarılmaktadır. Basamakların sayısı genellikle üç ila beş arasında değişir. Cumbaların döşemeleri üzerine tek sıra taş duvarlar

örülerek tamamlandıktan sonra, üst kısımlar ahşap saçak ya da toprak damla kapatılmaktadır.

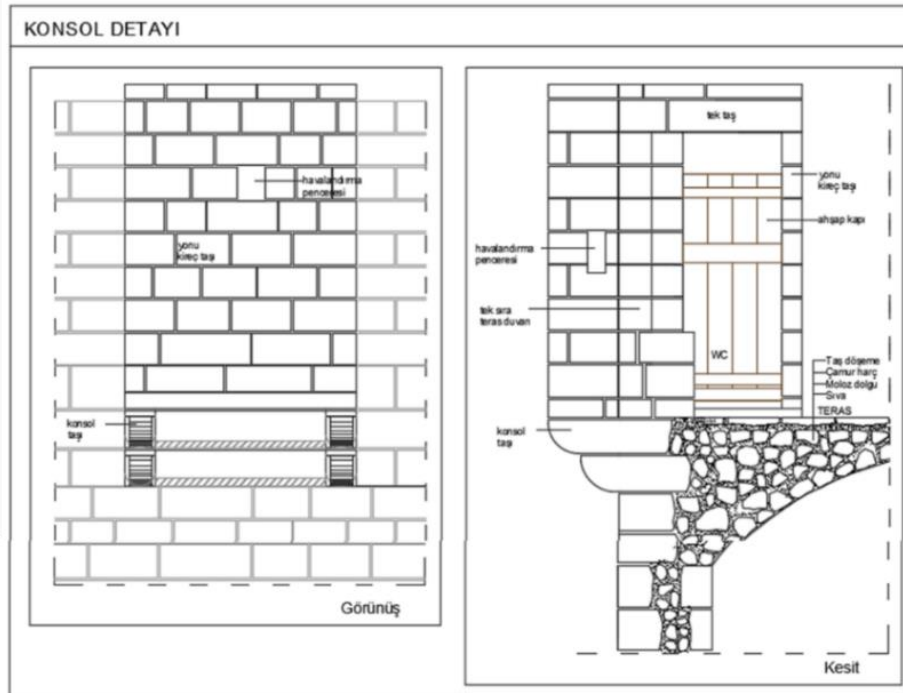
Cumba pencereleri, evlerin birbirini göremeyeceği şekilde konumlandırılmıştır. Genellikle yan duvarlara birer pencere açılır, uygun olduğu durumlarda ise ön cepheye de birkaç pencere yerleştirilirdi.

Geleneksel Urfa evlerinin sokağa bakan cepheleri oldukça yalın yapılmıştır. Buna rağmen sokağa bakan

cephelere, çıkma ögesiyle zenginlik katılmıştır. Bu çıkmalarda bulunan süslemelerin özgün karaktere sahip olması, çıkmaların kademeli biçimde olması, ahşap ve taş malzemelerin birlikte kullanılması, bingilerin geçişlerinde sarmal motiflerin yer alması ve süsleme kuşaklarının bulunması bu çıkmaların özgünlüğüne katkı sunmaktadır [8].



Şekil 18: Geleneksel Urfa evlerinde uygulanan bir çıkma/taş konsol detayı (Gayberi, 2019)



Şekil 19: a. Cumba duvarı, b. Cumba altında bulunan taş konsol detay çizimi (Gayberi, 2019)

Duvar Elemanlarının Yapımı

Niş (Camhane)


Geleneksel Urfa evlerinde, odaların duvarlarına yerleştirilen ve “camhane” olarak adlandırılan gömme nişler, kapaklı veya kapaksız şekilde tasarlanmıştır. Evlerin kalın duvarları, özellikle eyvan ve odalarda bu nişlerin oluşturulmasına elverişliydi. Nişler, evin inşası sırasında duvarlar örülürken bırakılan boşluklar ile oluşturulurdu ve genellikle oda duvarlarının dört tarafında da yer alırdı. Mimari olarak, büyük kemerli bir nişin her iki yanında daha küçük nişler olacak şekilde bir düzenleme yaygındı. Çoğunlukla sağır duvarlarda yer alan bu nişler, bazen de iki pencere arasında veya bir

pencerenin iki yanında konumlandırılırdı. Üstü düz olan ender örnekler de mevcuttur. Daha büyük boyutlu olan ve “yükük” olarak adlandırılan nişler ise yatak, yorgan ve yastık gibi eşyaların saklandığı alanlardı. Bu nişler genellikle kemerli olup ortada yüksek, iki yanında ise daha alçak olacak şekilde farklı şekillerde tasarlanmıştır (Şekil 20, 21).

Nişlerin ahşap kapakları, camlı, aynalı, süslemeli ya da sade şekilde yapılırdı. Bazı evlerde kapaksız olan nişler, perde ile kapatılırdı. Ekonomik durumu iyi olan ailelerde, özellikle eyvanlarda arka duvarda yer alan nişlerin kenarlarında ve kemerlerinde özenle işlenmiş taş bezemeler dikkat çekmekteydi (Şekil 21).




Şekil 20: Geleneksel Urfa evlerinde Niş (Camhane) örnekleri



Şekil 21: Camhane-niş ve ahşap kepenkli pencereler (Gayberi, 2019)

Döner Dolap (Yemek Servis Dolabı)

Geleneksel Urfa evlerinde, haremlik bölümünden selamlık bölümüne yemek servisi yapılırken mahremiyetin korunması amacıyla kullanılan bir duvar elemanıdır. Döner dolaplar, genellikle haremlik avlusundan selamlık bölümüne, avluya veya gezenek adı verilen bölümlere açılırdı. Ahşap malzemeden yapılan bu elemanlar, silindirik formda olup tamamen açık veya kısmen kapalı ve iki katlı olarak tasarlanırdı. Duvar içerisine monte edilen dolap, alt ve üst kısımlardan sabitlenir ve kendi ekseninde dönmeye elverişli şekilde yerleştirilirdi. Dolabın raflarına konulan tabaklar, dolabın döndürülmesiyle diğer tarafa iletilir, bu tabaklar daha sonra selamlık bölümüne taşınmak üzere tepsilere yerleştirilirdi (Şekil 22).



Şekil 22: geleneksel bir Urfa evinde "Döner dolap (Yemek servis dolabı)"


Kuş Takaları

Geleneksel Urfa evlerinin avlu cephelerinde, oda pencerelerinin üst kotunda veya gezenek konsolları arasında yer alan, kuşların yuva yapması ve barınması için tasarlanan nişler, mimaride "kuş takası" olarak adlandırılmaktadır. Bu nişler, elips, dikdörtgen, madalyon ya da dairesel formlarda düzenlenmiş olup bazı örneklerde üçlü kompozisyonlar halinde de görülmektedir. Tekil bir niş olarak tasarlandıkları gibi,

daha büyük bir ana niş içerisinde birden fazla küçük niş barındıran varyasyonlar da mevcuttur. Urfa yerelinde bu mimari elemanlara "matar" ismi verilmektedir. Geleneksel Urfa evlerinde kuş takaları, hayata (avluya) bakan oda pencerelerinin üstünde veya avlu duvarlarında birkaç adet ve dikey şekilde yapılırdı. Ayrıca avlu duvarlarındaki konsolların arasında da sıra halinde kuşların yuva yapması için kuş takaları yer alırdı. Takaların etrafında taş süslemeler ve motifler bulunurdu [9] (Şekil 23).



Şekil 23: Kuş takası "Matar" örnekleri



Şekil 24: Su kuyusu ve üzerindeki "Matar" detay çizimi (Gayberi, 2019)

Ocaklar ve Bacalar

Geleneksel Urfa evlerinde, mutfaklarda bir veya birden fazla ocak bulunur (Şekil 25). Bu ocaklar, tek bir bacaya bağlanır (Şekil 26). Kesme taş ile inşa edilen ocaklar, dikdörtgen planlı ve basık kemerli olarak yapılmıştır. Ocakların içinde, büyük kazanları oturtmak için taştan

yükseletiler yapılırdı. Mutfaktan dama uzanan bacaların duvarlarında, hava sirkülasyonu sağlamak amacıyla küçük pencereler açılırdı. Bazı geleneksel Urfa evlerinde, mutfaktan geçilen bir kapı aracılığıyla hamamlara ulaşıldı. Ocaklarda ısıtılan su hamamlarda kullanılır, ayrıca ocakta yanan ateşin ısısından hamamın ısıtılması için de yararlanılırdı.



Şekil 25: Mutfak ocakları a. İki gözlü ocak, b. Tek gözlü ocak



Şekil 26: a. Ocak, b. Ocak içerisindeki baca boşluğunun içten görünümü

“Kim O” Takası (Gezenek Takası)

Sokak kapısına gelen kişiyi görmek amacıyla kullanılan ve gezenekten sokağa açılan küçük pencereler, mimari literatürde “kim o takası” veya “gezenek takası” olarak bilinmektedir (Şekil 27). Bu pencereler, bir kişinin başını dışarı rahatlıkla çıkarabileceği boyutta tasarlanmıştır.

Bazı geleneksel Urfa evlerinde bu takalar kemerli bir formda, bazılarında ise duvar içinde oluşturulmuş basit bir boşluk şeklinde inşa edilmiştir [1]. Ayrıca, birçok geleneksel evde, bu pencerelerin önüne mahremiyet sağlamak amacıyla ahşap kafesler eklenmiştir.

Badgir (Rüzgâr Yakalayıcıları)

Rüzgâr yakalayıcılar, doğal havalandırma sağlamak amacıyla tasarlanan geleneksel yapı elemanlarıdır.

Urfa’da “badgel” olarak da adlandırılan bu rüzgâr yakalayıcılar, özellikle sıcak hava koşullarına karşı eyvanların havalandırılması ve soğutulması için kullanılan fonksiyonel ve mimari bir öğe olarak dikkat çeker [10] (Şekil 28, 29).

Baca formunu andıran badgellerin bir ucu evin damının üzerinde, diğer ucu ise alt kattaki eyvanlardaki nişlere uzanır. Dam üzerindeki badgelin üst kısmından giren rüzgâr, nişlerin içinde bulunan dikey kanallar aracılığıyla hava akışı sağlar (Şekil 29). Rüzgâr hızının artmasıyla kanallardan içeriye taşınan hava miktarı artar ve bu sayede iç mekanlar soğutulur. Rüzgârın az olduğu veya hiç olmadığı durumlarda ise, içeride ısınan havanın dışarı atılmasıyla tek yönlü soğutma mekanizması devam eder [11-12].



Şekil 27: Kim o takası (Gezenek takası) a. Avludan görünüş, b. Sokaktan görünüş



Şekil 28: a. Eyvanın genel görünüşü, b. Eyvan içinde hava kanalının yeri, c. Hava kanalının içten görünümü



Şekil 29: “Rüzgar yakalayıcıları (badgir)” nın sokaktan ve damdan görünüşü [10].

Genel Değerlendirme ve Sonuç

Bu çalışma, önemli bir kültürel miras unsuru olan geleneksel Urfa evlerinin, temel ve duvar yapım tekniklerini ayrıntılı bir şekilde belgeleyerek, mimari ve yapısal analiz süreçlerine bilimsel bir katkı sunmuş; bu bağlamda geleneksel yapı tekniklerinin korunması ve gelecek nesillere aktarılmasına yönelik bir bilgi kaynağı oluşturmuştur.

Geleneksel Urfa evlerinin yapımında kullanılan teknikler ve malzemeler üzerine mevcut literatürün sınırlı olması, bu yapı kültürüne ilişkin bilgilerin zamanla unutulmasına yol açmıştır. Çalışma kapsamında, geleneksel kent dokusunda özgünlüğünü koruyabilmiş birçok Urfa evi yerinde incelenmiş ve temel ile duvar yapım teknikleri, kullanılan malzemeler detaylı şekilde belgelenmiştir. Bazı yapılarda özgün mimari detayların günümüze kadar ulaşmış olması, geçmiş yapım tekniklerinin anlaşılabilmesi açısından büyük önem taşımaktadır.

Urfa'daki mimari yapının şekillenmesinde yapı ustalarının oynadığı kritik rol, geleneksel Urfa mimarisinin oluşum sürecinde belirleyici olmuştur. Ancak günümüzde geleneksel yapım tekniklerine vakıf olan usta sayısının kayda değer ölçüde azaldığı tespit

edilmiştir. Özellikle Urfa'da yürütülen restorasyon projelerinde çalışan taş ustalarının büyük çoğunluğunu Suriye'den göçle gelen ustaların oluşturduğu gözlemlenmiştir. Bu durum, yerel zanaat bilgisinin kaybolma tehlikesiyle karşı karşıya olduğunu ve geleneksel yapım tekniklerinin yeni nesillere aktarılmasında ciddi bir boşluk yaşandığını göstermektedir.

Geleneksel Urfa evlerinde kullanılan yapı malzemelerinin ve yapım tekniklerinin araştırılarak belgelenmesi, bu bilgilerin tarihi yapıların restorasyon süreçlerinde değerlendirilmesi açısından büyük bir önem taşımaktadır. Bu araştırma, geleneksel üretim yöntemlerinin ve unutulmaya yüz tutmuş yapım tekniklerinin yeniden canlandırılması ile bu tekniklerin modern restorasyon uygulamalarına entegre edilmesine önemli katkılar sunma potansiyeline sahiptir. Günümüzde, bazı hatalı restorasyon uygulamalarına rağmen, kimi uygulamalarda geleneksel yapım tekniklerinin kullanılması, bu yöntemlerin hala geçerli ve uygulanabilir olduğunu ortaya koymaktadır.

Bu çalışmanın en önemli katkısı, Urfa'da yok olma tehlikesiyle karşı karşıya olan geleneksel yapım teknikleri, yapı malzemeleri ve harçların bilimsel bir

yaklaşım ile belgelenmesi ve yeniden canlandırılması sürecine öncülük etmesidir. Ayrıca, bu tekniklerin günümüz restorasyon süreçlerine entegre edilmesi ve bu doğrultuda sürdürülebilirlik açısından değerlendirilmesi, mimari mirasın korunmasında önemli bir adımdır. Uluslararası restorasyon ilkeleri ve tüzükler dikkate alındığında, bilinçli restorasyon uygulamalarının özgün malzeme ve tekniklere uygun olarak gerçekleştirilmesinin önemi daha net anlaşılmaktadır.

Sonuç olarak, Urfa'daki geleneksel evlerde yürütülen ve ileride gerçekleştirilecek restorasyon projelerinde, evrensel kabul gören koruma ilkeleri ışığında, yapı ustalarının ve işverenlerin bilinçlendirilmesi büyük bir gereklilik arz etmektedir. Bu yapıların özgün yapı teknikleri ve malzemelerine sadık kalınarak korunması, en az müdahale ile onarılması ve sürdürülebilirliğinin sağlanması, kültürel mirasın geleceği için öncelikli hedef olmalıdır. Geleneksel Urfa evlerinin bir kısmı yıkılmaya yüz tutmuşken, bazıları için restorasyon çalışmalarının başlamış olması, bu mirasın korunması açısından umut verici bir gelişmedir. Restorasyon uygulamalarında ise modern yapı tekniklerinin yerine, yapıların özgün mimarisini koruyan, en az müdahale ilkesine dayanan, sürdürülebilirliği sağlayacak yaklaşımlar tercih edilmelidir.

Kaynaklar

- [1] Akkoyunlu, Zahide. Geleneksel Urfa Evlerinin Mimari Özellikleri, Gazi Üniversitesi Fen Bilimleri Enstitüsü Mimarlık Ana Bilim Dalı Yüksek Lisans Tezi, Ankara 1988.
- [2] Ören, Sevil Işıl. Traditional Urfa Dwellings: An Investigation of Part of the Old Town Center, Ortadoğu Teknik Üniversitesi Yayınlanmamış Yüksek Lisans Tezi, Ankara 1996.
- [3] Gayberi, Şeyda. Geleneksel Urfa Evlerinin Yapım Teknikleri, Dicle Üniversitesi Fen Bilimleri Enstitüsü Mimarlık Ana Bilim Dalı Yüksek Lisans Tezi, Diyarbakır 2019.
- [4] İnce Gayberi, Şeyda ve Dalkılıç, Neslihan. "Geleneksel Urfa Evlerinin Ahşap Tavan Yapım Teknikleri ve Süslemeleri", DÜFED, 10(2), 2021, ss. 133-146.

- [5] Akman, M. Süheyl. "Yapı Malzemelerinin Tarihsel Gelişimi." Türkiye Mühendislik Haberleri Dergisi (THM), 4, Ankara 2003, s. 30-36.
- [6] İnşaat Teknolojisi, Taş Duvarlar. 2014.T.C. Millî Eğitim Bakanlığı yayını, Ankara.
- [7] İnşaat Teknolojisi, Doğal Taşları Sınıflandırma ve Tespit Etme. 2013. T.C. Millî Eğitim Bakanlığı yayını, Ankara.
- [8] Erçetin, Sedat "Geleneksel Urfa Evlerinde Çıkma" Akdeniz Sanat Dergisi, 14 (26), 2020, s. 151-168.
- [9] Özçakı, Meltem "Türk Kültüründe Güvercinlik ve Kuş Evleri ve Günümüze Yansımalar" Sanat ve Tasarım Dergisi, 10(2), 2020, ss. 238-261
- [10] Melikoğlu, Yahya. Geleneksel Yaşam Alanlarından Öğrenilen Sürdürülebilir Dersler: Şanlıurfa'nın Geleneksel Rüzgâr Yakalayıcıları, Dicle Üniversitesi Fen Bilimleri Enstitüsü Mimarlık Ana Bilim Dalı Yüksek Lisans Tezi, Diyarbakır 2018.
- [11] Bekleyen, Ayhan ve Melikoğlu, Yahya. "Antik Rüzgâr Yakalayıcıların Anadolu'daki Örnekleri: Şanlıurfa'nın Badgelleri." Art-Sanat Dergisi, 12, 2019, ss. 109-128
- [12] Bekleyen, Ayhan ve Melikoğlu, Yahya "An Investigation on the Thermal Effects of Windcatchers." Journal of Building Engineering, 2021, s. 34

Etik Kurul İzni

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur.

Teşekkür

Bu araştırma; Dicle Üniversitesi Fen Bilimleri Enstitüsü Mimarlık Ana Bilim Dalı bünyesinde, Prof. Dr. Neslihan DALKILIÇ'ın danışmanlığında, Şeyda İNCE GAYBERİ tarafından hazırlanan, "Geleneksel Urfa Evlerinin Yapım Teknikleri" başlıklı yüksek lisans tezinden üretilmiş olup Dicle Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi Koordinatörlüğü'nce desteklenmiştir (Proje Numarası: DÜBAP MİMARLIK.19.001).

Çıkar Çatışması

Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.