

Nicel Karar Verme: Çok Kriterli Yaklaşımlar ve Makine Öğrenmesi Uygulamaları

Editor: Dr. Öğr. Üyesi Şule Bayazit Bedirhanoglu

Nicel Karar Verme: Çok Kriterli Yaklaşımlar ve Makine Öğrenmesi Uygulamaları

Editör:

Dr. Öğr. Üyesi Şule Bayazit Bedirhanoglu



Published by

Özgür Yayın-Dağıtım Co. Ltd.

Certificate Number: 45503

📍 15 Temmuz Mah. 148136. Sk. No: 9 Şehitkamil/Gaziantep

☎ +90.850 260 09 97

📞 +90.532 289 82 15

🌐 www.ozguryayinlari.com

✉ info@ozguryayinlari.com

Nicel Karar Verme: Çok Kriterli Yaklaşımlar ve Makine Öğrenmesi Uygulamaları

Editor: Dr. Öğr. Üyesi Şule Bayazıt Bedirhanoglu

Language: Turkish-English

Publication Date: 2025

Cover design by Mehmet Çakır

Cover design and image licensed under CC BY-NC 4.0

Print and digital versions typeset by Çizgi Medya Co. Ltd.

ISBN (PDF): 978-625-5646-22-4

DOI: <https://doi.org/10.58830/ozgur.pub788>



This work is licensed under the Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0). To view a copy of this license, visit <https://creativecommons.org/licenses/by-nc/4.0/>
This license allows for copying any part of the work for personal use, not commercial use, providing author attribution is clearly stated.

Suggested citation:

Bayazıt Bedirhanoglu, Ş. (ed) (2025). *Nicel Karar Verme: Çok Kriterli Yaklaşımlar ve Makine Öğrenmesi Uygulamaları*. Özgür Publications. DOI: <https://doi.org/10.58830/ozgur.pub788>. License: CC-BY-NC 4.0

Elinizdeki bu derleme eser, alanında uzman birçok farklı yazarın özgün katkılarıyla zenginleşmiştir. Bu doğrultuda, her bölümün içeriğindeki görüş, yorum ve analizlere dair tüm sorumluluk, bölümün kendi yazarına aittir

The full text of this book has been peer-reviewed to ensure high academic standards. For full review policies, see <https://www.ozguryayinlari.com/>



Bilgeliđiyle bana ilham veren ve anısıyla hâlâ yolumu aydınlatan sevgili
Babaannemin aziz hatırasına ithaf ediyorum...

Ön Söz

Bilgi çağının en önemli gereksinimlerinden biri, karmaşık problemlere sistematik ve veriye dayalı çözümler üretebilme yetkinliğidir. Karar verme süreçleri bireylerden topluma ve hatta devletlere kadar her ölçekte stratejik öneme sahiptir. Günümüz dünyasında kararların; doğru olmasının yanı sıra zamanlı, çok boyutlu, dinamik olması gibi özellikleri ile sürekli değişen koşullar altında alınması gerekmektedir. Bu doğrultuda nicel karar verme yaklaşımları özellikle Çok Kriterli Karar Verme (ÇKKV) ve Makine Öğrenmesi yöntemleri karar vericilere güçlü bir yol haritası sunmaktadır. Bu kitap söz konusu iki güçlü metodolojinin teorik temelleri ve güncel uygulamalarını bir araya getirerek alana katkı sunmayı amaçlamaktadır. Farklı disiplinlerden gelen değerli araştırmacıların katkılarıyla şekillenen bur derleme eser, karar verme sürecini anlamak ve iyileştirmek isteyen araştırmacılara disiplinler arası özgün bir perspektif sunmaktadır.

Toplam 8 bölümden oluşan bu kitabın içeriği, okuyucuyu kuramdan uygulamaya doğru uzanan kapsamlı bir yolculuğa çıkarmaktadır. İlk bölüm, ÇKKV yöntemlerinden WENSLO kriter ağırlıklandırma ve CoCoSo sıralama yöntemlerini bir uygulama ile tanıtır. İkinci bölüm, portföy çalışmalarında makine öğrenmesi kullanımını anlamaya yönelik öncü çalışmaların sunulduğu bibliyometrik analizi sunar. Üçüncü bölüm, ENTROPY ve TOPSIS ÇKKV yöntemlerinin birlikte ele alınmasını AB'ne aday ülkeler ile Türkiye'nin sağlık performansını karşılaştırma uygulaması ile gösterir. Dördüncü bölüm, müşteri memnuniyetine yönelik makine öğrenmesi çalışmalarını bibliyometrik bir yaklaşımla analiz eder. Beşinci bölüm, ÇKKV ve makine öğrenmesi entegrasyonunu teorik çerçeve ve uygulama ile açıklar. Altıncı bölüm finansal zaman serisi tahminlemede makine öğrenmesi algoritmalarını inceleyen genel bir çerçeve çizer. Yedinci bölüm FUCOM tabanlı WEDBA güncel ÇKKV yöntemlerinin optimal tedarikçi seçiminde uygulanmasını gösterir. Sekizinci bölüm çeşitli makine öğrenmesi algoritmaları ile çalışanların işten ayrılma olasılığının nasıl tahmin edileceğine yönelik bir uygulama sunar.

Bu kitabın çok kriterli karar verme ve makine öğrenmesi yaklaşımlarıyla nicel karar verme süreçlerini sistematik, veriye dayalı yönetme yetkinliği kazandırmasının yanı sıra, okuyuculara yol gösterici olmasını temenni ediyorum. Kitabın hazırlanmasında katkı sunan tüm yazarlarımıza ve

sürece emek veren herkese teşekkür eder; bu çalışmanın okuyuculara ilham vermesini ve gelecekteki araştırmalar için bir başlangıç noktası oluşturmasını dileriz.

Bilimin çok sesli ve disiplinler arası yapısının, daha adil, etkili ve sürdürülebilir kararlar alınmasında yolumuzu aydınlatmaya devam etmesi dileğiyle...

Editör

Dr. Öğr. Üyesi Şule BAYAZİT BEDİRHANOĞLU

Mayıs 2025

İçindekiler

Ön Söz

iii

Bölüm 1

Beyond Equal Weights: A WENSLO-CoCoSo Assessment of OECD Countries' SDG Performance 1

Hasan Emin Gürler

Mehmet Özçalıcı

Bölüm 2

Portföy Çalışmalarında Makine Öğrenmesi Kullanımı Üzerine Bibliyometrik Bir Değerlendirme 29

Sema Akin Bas

Bölüm 3

Comparison of Healthcare System Performance in EU Candidate Countries Using an Entropy and TOPSIS-Based Multi-Criteria Decision-Making Approach: Türkiye's Position 45

Hamza Doğan

Bölüm 4

Müşteri Memnuniyetinin Makine Öğrenmesi Teknikleriyle Değerlendirilmesi : Bibliyometrik Analiz 67

Sezin Öztürk Uşun

Mehmet Çağlar

Bölüm 5

Çok Kriterli Karar Verme ve Makine Öğrenmesi: Entegrasyon ve Uygulamalar 81

Müzeyyen Özhanzalı

Bölüm 6

Finansal Zaman Serisi Tahminlerinde Makine Öğrenmesi Uygulamaları	101
<i>Özge Dinç Cavlak</i>	

Bölüm 7

FUCOM Tabanlı WEDBA Çok Kriterli Karar Verme Yöntemi ile Optimal Hazır Beton Tedarikçi Firma Seçimi	115
<i>Şule Bayazıt Bedirhanoglu</i>	

Bölüm 8

Predicting and Interpreting Employee Attrition with Machine Learning Models: An Application on the HR Analytics Dataset	135
<i>Cansu Ergenç Özdaş</i>	

Beyond Equal Weights: A WENSLO-CoCoSo Assessment of OECD Countries' SDG Performance

Hasan Emin Gürlür¹

Mehmet Özçalıcı²

Abstract

The Sustainable Development Goals (SDGs) represent a universal agenda for addressing pressing global challenges, yet assessing national progress remains complex due to methodological limitations in existing frameworks. This study evaluates the performance of OECD countries in achieving 15 SDGs using an integrated WENSLO (Weights by Envelope and Slope) and CoCoSo (Combined Compromise Solution) approach, addressing critiques of subjective weighting methods like the UN's equal-weighted index. WENSLO objectively assigns criterion weights based on statistical analysis, while CoCoSo ranks countries through a multi-criteria decision-making process. Results reveal Italy as the top performer, attributed to balanced advancements in economic, social, and environmental dimensions, followed by Austria, Spain, and Portugal. Conversely, Iceland, Luxembourg, and Greece, reflecting disparities in policy integration and socio-economic constraints. The study highlights synergies and trade-offs between SDGs, emphasizing the need for targeted resource allocation, technology transfer, and data standardization. By offering a transparent, adaptable framework, this research advances methodological rigor in sustainability assessments and provides actionable insights for policymakers to prioritize SDG implementation in heterogeneous high-income contexts.

- 1 Dr. Öğr. Üyesi, Kilis 7 Aralık Üniversitesi, İ.İ.B.F., Uluslararası Ticaret ve Lojistik Bölümü, hasan.gurlur@kilis.edu.tr, ORCID: 0000-0002-5813-1631
- 2 Prof. Dr., Kilis 7 Aralık Üniversitesi, İ.İ.B.F., Uluslararası Ticaret ve Lojistik Bölümü, mozcatici@kilis.edu.tr, ORCID: 0000-0003-0384-6872

1. Introduction

Despite notable advancements in enhancing human well-being, the world continues to grapple with pressing social issues, including climate change, urban poverty, and increasing inequality. To motivate global governments to address these challenges, the United Nations has introduced 17 Sustainable Development Goals (SDGs) as a key component of the 2030 Global Agenda (Berrone et al., 2023). SDGs represent a significant transformation in the United Nations' approach, aiming to unify economic and social progress with the principles of environmental sustainability under a single, comprehensive framework (Biermann et al., 2017). UN member states are anticipated to embrace the SDG framework as a guiding blueprint to shape their development and investment strategies, while monitoring their advancements toward meeting the goals throughout the 15-year timeframe (Aly et al., 2022). The 17 SDGs are broken down into 169 interconnected targets, providing a comprehensive framework to guide global development strategies through 2030. These goals and targets address the economic, social, and environmental dimensions of sustainable development in an unprecedented manner. The SDGs integrate the human development focus of the Millennium Development Goals (MDGs) with the sustainability principles of the Rio+ process, while also expanding the scope and depth of the issues addressed. This signals a critical need for transformative changes in governance strategies (Breuer et al., 2019). Achieving the SDGs relies heavily on research, innovation, and sustainable education, which can only be accomplished through substantial investments from both public and private sectors (Salvia et al., 2019).

The SDGs strive to represent a globally shared vision of progress, aiming to create a safe, just, and sustainable environment for all. Grounded in the principle that every individual and nation has a role to play in achieving this vision, the focus extends beyond international collaboration to also address and eliminate discrimination and inequalities within individual countries (Leal Filho et al., 2019). The SDGs adopt a global perspective, but their implementation is carried out at the local level, varying based on each country's progress toward these goals. Furthermore, a nation's level of development and its dedication to sustainability shape its domestic priorities and actions (Salvia et al., 2019). A global indicator framework of 232 indicators is used to track progress on the SDGs. However, data has so far been collected for only 134 indicators. Variations in national data quality and availability across countries make it difficult to reliably assess progress on the SDGs and call into question the relevance of some indicators (Cernev & Fenner, 2020). Many nations have struggled to achieve the SDGs due to

a range of obstacles, including insufficient financial investment from both governments and the private sector in sustainable development, particularly in low-income countries. Additional challenges include difficulties in transferring technology from developed to less developed regions and trade barriers that disproportionately affect middle- and low-income countries (Biglari et al., 2022).

It is important to monitor countries' progress towards the SDGs and identify areas where improvement is needed. For this purpose, many studies have used multi-criteria decision-making techniques such as TOPSIS and AHP. While these methods are reliable, they are often not computationally demanding and require a lot of subjective input (Dwivedi & Sharma, 2025). However, researchers have used methods such as Delphi technique, Principal Component Analysis, fuzzy AHP, Entropy and Data Envelopment Analysis to rank countries according to their SDG progress (Guo et al., 2024). Recently, Guo et al. (2024) assessed the progress of OECD countries on the SDGs using Hierarchical Data Envelopment Analysis. On the other hand, the SDG report published by the UN gives equal weight to each goal and each indicator, which is a highly subjective weighting method and does not correspond to the realities of countries with very different contexts. (Guo et al., 2024). Therefore, this study aims to make an objective assessment of the criteria and comprehensively evaluate the performance of OECD countries towards the Sustainable Development Goals using the integrated WENSLO (Weights by Envelope and Slope) - CoCoSo (Combined Compromise Solution) approach. There is no study in the literature that uses the integrated WENSLO-CoCoSo model to assess the progress of OECD countries towards the Sustainable Development Goals. In the current study, 15 of the 17 SDGs are used as criteria and OECD countries are ranked according to their performance in achieving the SDGs.

This study makes important contributions to the literature on performance assessment of OECD countries in the context of SDGs: By using the WENSLO-CoCoSo integrated model for the first time, it overcomes the limitations of the UN's criticized equal weighting method by adopting a statistically-based objective approach to criteria weighting, and provides a multidimensional and integrated analysis of the 15 SDGs in high-income economies with heterogeneous sustainability profiles, such as OECD countries. The study reveals synergies and trade-offs between economic, social and environmental indicators, while highlighting countries' relative weaknesses and policy priorities, providing concrete guidance on resource allocation, technology transfer and financing. It also highlights the lack and quality of data on SDG indicators, reinforces the need for international

cooperation and standardization, and provides a new framework for future research with its methodological transparency and adaptability.

2. Literature

The detailed framework of targets and indicators supporting the Sustainable Development Goals (SDGs) was introduced in 2015, marking a pivotal moment for both developing and developed nations to advance toward sustainable development. With 17 goals and 169 targets, the SDGs are designed to tackle the diverse and interconnected challenges confronting humanity (Pradhan et al., 2017). Additionally, an initial set of 330 indicators was introduced in March 2015. Some of the SDGs expand upon earlier MDGs, while others incorporate new concepts (Hák et al., 2016). The global SDGs offer a framework grounded in evidence for planning and implementing sustainable development initiatives at national, regional, and global levels, spanning a 15-year timeline until 2030 (Allen et al., 2018). The 17 goals aim to offer a structured framework for policymaking in member states over a 15-year span. These SDGs were officially adopted during the UN summit in New York in September and came into effect starting January 2016, with a target completion date of 2030. The 17 SDGs can be categorized into six thematic areas: “Dignity”, “People”, “Planet”, “Partnership”, “Justice” and “Prosperity”. Figure 1 presents the thematic areas and sustainable development goals (Leal Filho et al., 2018).




Figure 1. Thematic areas and SDGs (Leal Filho et al., 2018).

With the publication of the SDGs, this issue has been the focus of researchers’ attention and many studies have been conducted in this field. For example, Diaz-Sarachaga et al. (2018) assessed whether the SDG index provides an adequate framework for measuring the progress of the 2030 goals. Le Blanc (2015) investigated to what extent the structure of the proposed goals and related targets actually reflects the goal of better integration across sectors. Moyer & Hedden (2020) built a baseline global development scenario by presenting an integrated assessment model to assess

progress towards target values across nine indicators in six thematic areas. Bali Swain & Yang-Wallentin (2020) investigated which of the pillars of the SDGs (economic, social and environmental) are most effective in achieving sustainable development. Donaires et al. (2019) developed an approach to help determine whether efforts towards the SDGs can be expected to be effective. Allen et al. (2016) reviewed and evaluated 80 different quantitative models that have the potential to support national development planning for the SDGs.

In the literature, there are also researches on SDGs that utilize the use of MCDM techniques. For example, Aljaghoub et al. (2022) present some feasible cleaning techniques used to recover the full efficiency of photovoltaic panels and relate each cleaning technique to the SDGs and their related targets using TOPSIS technique. Rad et al. (2024) presented a global framework for maximizing sustainable development indices in agricultural photovoltaic-based renewable systems by integrating DEMATEL and ANP methods. Sousa et al. (2021) conducted a systematic literature review on CCM methods that support decisions focused on achieving the SDGs and implementing the 2030 Agenda for Sustainable Development in regional, national or local contexts. Sreenivasan et al. (2023) examined the research on SDGs using AHP technique with social network analysis. Burhan (2024) focuses on SDG 9 and evaluates EU countries and Turkey in terms of industry, innovation and infrastructure using VIKOR-MAIRCA integrated approach. Stanujkic et al. (2020) aimed to determine the position of EU countries regarding the SDGs in the period 2015-2018 using the Entropy-CoCoSo integrated model.

In the present study, WENSLO technique is preferred to determine the criteria weights and CoCoSo method is preferred to rank the countries. The WENSLO method is a newly developed technique and has been used by researchers to solve different types of MCDM problems. For example, Kara et al. (2025) presented a solution to the problem of sustainable brand logo selection by using artificial intelligence supported PF-WENSLO-ARLON hybrid method. Pamucar et al. (2023) used the integrated WENSLO-ALWAS approach to evaluate green growth performance. Similarly, Kara et al. (2024) used the neutrosophic WENSLO-ARLON model to evaluate sustainable brand equity performance. Trung et al. (2024) used Entropy-CoCoSo integrated approach to solve the problem of material selection in the design phase. They used the WENSLO technique to evaluate the accuracy of their proposed evaluation approach.

The CoCoSo method has been used by researchers to provide solutions to a variety of MCDM problems. For example, Deveci et al. (2021) used the CoCoSo technique to prioritize the advantages of autonomous vehicles in real-time traffic management. Lai et al. (2022) performed blockchain platform evaluation using the fuzzy CoCoSo method. Das & Chakraborty (2022) aimed to optimize green dry milling processes with SWARA-CoCoSo integrated approach. Jafari & Khanachah (2024) evaluated comprehensive information adoption solutions under uncertainty in supply chain through CoCoSo method. Yu et al. (2024) performed risk assessment of liquefied natural gas storage tank leakage using CoCoSo method and failure mode and effects analysis. Ecer & Pamucar (2020) integrated fuzzy BWM and fuzzy CoCoSo techniques to solve the sustainable supplier selection problem. Zhang & Wei (2023) solved the problem of site selection of electric vehicle charging stations by using global fuzzy CPT-CoCoSo and D-CRITIC method. Okursoy & Coşansu (2024) aimed to solve the zero emission electric vehicle selection problem using MEREC-based CoCoSo method.

3. Methodology

In this study, the integrated WENSLO-CoCoSo approach is used to assess the performance of OECD countries in achieving the Sustainable Development Goals. Criteria weights are determined using the WENSLO technique, while countries are ranked according to the CoCoSo method. In the following sections, these two methods are detailed.

The model of the study is presented in Figure 2. First, a decision matrix is constructed. This decision matrix is then subjected to the WENSLO procedure, thereby objectively determining the criterion weights. In the following step, the COCOSO methodology is applied, utilizing the criterion weights previously established through WENSLO. Through COCOSO, countries' scores based on their sustainability activities are obtained and analyzed. Subsequently, a sensitivity analysis is conducted by generating random weight sets. Finally, other techniques with computational steps similar to those of COCOSO are employed in order to examine the correlation among the resulting scores.

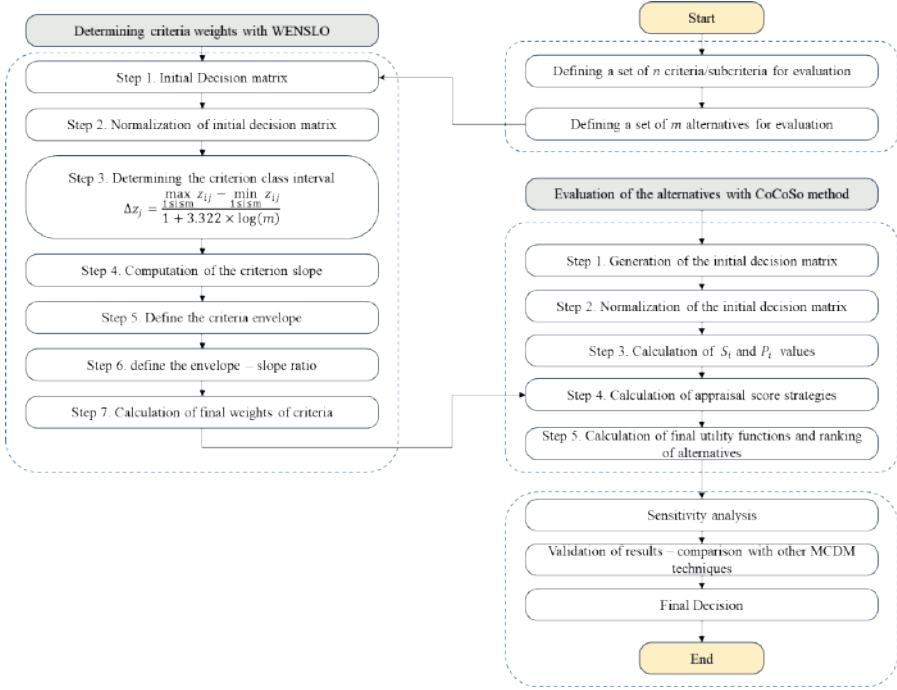


Figure 2. Research model

3.1. WENSLO Method

WENSLO is an objective multi-criteria decision making technique developed by Pamucar et al. (2023). This method is a crucial component of any decision-making process aimed at achieving the most objective final ranking of alternatives. Additionally, a key advantage of the WENSLO method is that it remains unaffected by criteria bias (whether they are benefit or cost criteria), as the normalization process for input data is independent of criteria preferences (Pamucar et al., 2023). The implementation steps of the method are as follows (Pamucar et al., 2023):

Step 1. Construct the decision matrix.

$$[x_{ij}]_{m \times n} = \begin{bmatrix} A/C & C_1 & C_2 & \dots & C_n \\ A_1 & x_{11} & x_{12} & \dots & x_{1n} \\ A_2 & x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots & \dots \\ A_m & x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix} \quad (1)$$

where:

x_{ij} is the value of the i -th alternative according to the j -th criterion.

$A_1, A_2, \dots, A_m$ refers to an alternative vector space representing a set of alternatives.

$C_1, C_2, \dots, C_n$ refers to a criteria vector space representing a set of criteria.

n is the number of criteria.

Step 2. Normalize the decision matrix.

$$z_{ij} = \frac{x_{ij}}{\sum_{i=1}^m x_{ij}}, \forall j \in [1, 2, \dots, n] \quad (2)$$

The normalized decision matrix is:

$$Z(A, C) = [z_{ij}]_{m \times n} = \begin{bmatrix} A/C & C_1 & C_2 & \dots & C_n \\ A_1 & z_{11} & z_{12} & \dots & z_{1n} \\ A_2 & z_{21} & z_{22} & \dots & z_{2n} \\ \dots & \dots & \dots & \dots & \dots \\ A_m & z_{m1} & z_{m2} & \dots & z_{mn} \end{bmatrix} \quad (3)$$

where, z_{ij} refers to each element in the normalized decision matrix, where $0 < z_{ij} < 1$.

Step 3. Determine the final ranking of alternatives based on the identified criteria.

$$\Delta z_j = \frac{\max_{1 \leq i \leq m} z_{ij} - \min_{1 \leq i \leq m} z_{ij}}{1 + 3.322 \times \log(m)}, \forall j \in [1, 2, \dots, n] \quad (4)$$

Step 4. Calculate the criterion slope.

$$\tan \varphi_j = \frac{\sum_{i=1}^m z_{ij}}{(m-1) \times \Delta z_j}, \forall j \in [1, 2, \dots, n] \quad (5)$$

Step 5. Determine the criteria envelope.

$$E_j = \sum_{i=1}^{m-1} \sqrt{(z_{i+1,j} - z_{ij})^2 + \Delta z_j^2}, \forall j \in [1, 2, \dots, n] \quad (6)$$

Step 6. Calculate the envelope-slope ratio.

$$q_j = \frac{E_j}{\tan \varphi_j}, \forall j \in [1, 2, \dots, n] \quad (7)$$

Step 7. Determine the final criteria weights.

$$w_j = \frac{q_j}{\sum_{i=1}^n q_j}, \forall j \in [1, 2, \dots, n] \quad (8)$$

3.2. CoCoSo (COMbined COMpromise SOLUTION) Method

The CoCoSo method was proposed by Yazdani et al. (2019). This approach combines the Simple Additive Weighting (SAW) method with the exponentially Weighted Product Model (WPM). It ranks alternatives by integrating compromise strategies derived from both the WSM and the WPM. The final ranking of alternatives is determined through a compromise criterion function (Deveci et al., 2021). The application steps of the method are as follows (Yazdani et al., 2019):

Step 1. Create the initial decision matrix.

$$x_{ij} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix}; i = 1, 2, \dots, m; j = 1, 2, \dots, n. \quad (9)$$

Step 2. Standardize the decision matrix.

$$r_{ij} = \frac{x_{ij} - \min x_{ij}}{\max x_{ij} - \min x_{ij}}; \text{ for benefit criterion,} \quad (10)$$

$$r_{ij} = \frac{\max_i x_{ij} - x_{ij}}{\max_i x_{ij} - \min_i x_{ij}}, \text{ for cost criterion.} \quad (11)$$

Step 3. Calculate the total weighted comparison (S_i) and exponential weighted comparison (P_i) of the alternatives respectively.

$$S_i = \sum_{j=1}^n (w_j r_{ij}) \quad (12)$$

$$P_i = \sum_{j=1}^n (r_{ij})^{w_j} \quad (13)$$

Step 4. Calculate the relative weights of alternatives using aggregation strategies.

$$k_{ia} = \frac{P_i + S_i}{\sum_{i=1}^m (P_i + S_i)}, \quad (14)$$

$$k_{ib} = \frac{S_i}{\min_i S_i} + \frac{P_i}{\min_i P_i}, \quad (15)$$

$$k_{ic} = \frac{\lambda (S_i) + (1 - \lambda) (P_i)}{\left(\lambda \max_i S_i + (1 - \lambda) \max_i P_i \right)}; 0 \leq \lambda \leq 1. \quad (16)$$

Equation (14) calculates the arithmetic mean of the combined scores from the WSM and WPM methods. Equation (15) sums the relative scores of WSM and WPM in comparison to the best-performing score. Equation (16) provides a balanced compromise between the WSM and WPM scores, where λ (typically set to 0.5) is a parameter determined by decision makers.

Step 5. The final ranking of alternatives is determined by their k_i values. The alternative with the highest k_i is the most important.

$$k_i = (k_{ia} k_{ib} k_{ic})^{\frac{1}{3}} + \frac{1}{3} (k_{ia} + k_{ib} + k_{ic}) \quad (17)$$

4. Analysis and Results

In this study, OECD countries are analyzed in terms of their performance in achieving the Sustainable Development Goals. The data of the countries belong to 2023 and the countries were evaluated according to 15 Sustainable Development Goals. The data were obtained from the World Bank's Statistical Performance Indicators (World Bank, 2024). PDO 14 is excluded since it is not included in the World Bank dataset and PDO 12 is excluded

since it is 1 for all countries. Table 1 shows the set of criteria used in the study (Fleming et al., 2017; World Bank, 2024).

Table 1. Criteria set

Code	Criteria	Explanation
C1	Goal 1: No poverty	End poverty in all its forms everywhere
C2	Goal 2: Zero hunger	End hunger, achieve food security and improved nutrition and promote sustainable agriculture
C3	Goal 3: Good Health and Well-being	Ensure healthy lives and promote well-being for all at all ages
C4	Goal 4: Quality Education	Ensure inclusive and equitable quality education and promote lifelong learning opportunities for all
C5	Goal 5: Gender Equality	Achieve gender equality and empower all women and girls
C6	Goal 6: Clean Water and Sanitation	Ensure availability and sustainable management of water and sanitation for all
C7	Goal 7: Affordable and Clean Energy	Ensure access to affordable, reliable, sustainable and modern energy for all
C8	Goal 8: Decent Work and Economic Growth	Promote sustained, inclusive and sustainable economic growth, full and productive employment and decent work for all
C9	Goal 9: Industry, Innovation and Infrastructure	Build resilient infrastructure, promote inclusive and sustainable industrialization and foster innovation
C10	Goal 10: Reduced Inequalities	Reduce inequality within and among countries
C11	Goal 11: Sustainable Cities and Communities	Make cities and human settlements inclusive, safe, resilient and sustainable
C12	Goal 13: Climate Action	Take urgent action to combat climate change and its impacts
C13	Goal 15: Life on Land	Protect, restore and promote sustainable use of terrestrial ecosystems, sustainably manage forests, combat desertification, halt and reverse land degradation, and halt biodiversity loss
C14	Goal 16: Peace, Justice and Strong Institutions	Promote peaceful and inclusive societies for sustainable development, provide access to justice for all and build effective, accountable and inclusive institutions at all levels
C15	Goal 17: Partnerships for Goals	Strengthen the means of implementation and revitalize the global partnership for sustainable development

All criteria used in the study are utility-oriented. The scores of OECD countries for 2023 for each of the SDGs, in other words, the initial decision matrix is presented in Table 2.

Table 2. Initial decision matrix

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15
Turkey	1.0	0.6	0.92	0.75	0.83	0.714	1.00	1.00	1.0	1.00	1.00	1.0	0.833	0.857	1.000
USA	0.8	0.8	0.88	0.75	0.83	0.857	0.83	1.00	0.9	1.00	1.00	1.0	0.833	0.857	0.800
Canada	0.8	0.9	0.88	0.75	0.83	0.857	0.83	1.00	0.9	1.00	0.75	0.5	0.833	0.857	0.867
France	1.0	0.7	0.84	0.75	1.00	0.857	0.83	1.00	1.0	1.00	1.00	1.0	0.750	1.000	0.867
Netherlands	1.0	0.8	0.8	0.75	1.00	0.857	0.83	1.00	1.0	1.00	1.00	1.0	0.667	1.000	0.867
Belgium	0.8	0.7	0.8	1.00	1.00	0.857	0.83	1.00	1.0	1.00	0.75	0.5	0.750	1.000	0.867
Luxemburg	0.8	0.8	0.8	0.75	0.83	0.857	0.83	0.88	0.9	0.75	0.75	0.5	0.667	1.000	0.867
Germany	0.8	0.7	0.84	0.75	1.00	0.857	0.83	1.00	1.0	1.00	0.75	0.5	0.833	1.000	0.867
Italy	1.0	0.8	0.84	0.75	1.00	1.000	0.83	1.00	1.0	1.00	1.00	1.0	0.833	1.000	0.867
Portugal	1.0	0.7	0.84	0.75	1.00	0.857	0.83	1.00	1.0	1.00	1.00	1.0	0.833	1.000	0.867
United Kingdom	1.0	0.8	0.84	1.00	0.83	0.857	0.83	1.00	0.9	1.00	1.00	1.0	0.750	0.714	0.867
Denmark	1.0	0.7	0.84	1.00	1.00	0.857	0.83	1.00	1.0	0.75	1.00	1.0	0.667	1.000	0.867
Ireland	0.8	0.8	0.84	0.75	1.00	0.857	0.83	1.00	0.9	0.75	0.75	0.5	0.750	1.000	0.867
Greece	0.8	0.8	0.84	0.75	1.00	1.000	0.83	1.00	0.9	0.875	0.50	0.5	0.833	0.857	0.867
Switzerland	1.0	0.8	0.8	0.75	1.00	0.857	0.83	1.00	0.9	0.875	1.00	1.0	0.750	0.857	0.800
Sweden	1.0	0.8	0.76	0.75	1.00	0.857	0.83	1.00	1.0	0.875	1.00	1.0	0.750	1.000	0.867
Austria	1.0	0.8	0.84	0.75	1.00	1.000	0.83	1.00	1.0	1.00	1.00	1.0	0.750	1.000	0.867
Iceland	0.4	0.7	0.84	0.75	1.00	0.714	0.83	1.00	0.9	0.75	0.75	0.5	0.833	0.857	0.867
Norway	0.8	0.9	0.84	1.00	1.00	1.000	0.83	1.00	0.9	0.875	0.75	0.5	0.750	0.857	0.867
Spain	1.0	0.8	0.88	0.75	1.00	0.857	0.83	1.00	1.0	1.00	1.00	1.0	0.833	1.000	0.867
Japan	0.6	0.8	0.88	0.75	0.83	0.714	0.83	1.00	0.9	0.875	1.00	1.0	0.750	0.857	0.867
Finland	1.0	0.7	0.84	0.75	1.00	0.857	0.83	1.00	1.0	0.875	1.00	1.0	0.833	1.000	0.867
Australia	0.6	0.7	0.88	0.75	1.00	0.714	0.83	1.00	0.8	0.875	1.00	1.0	0.833	0.857	0.867
New Zealand	0.6	0.8	0.88	0.75	0.83	0.857	0.83	1.00	0.9	0.750	1.00	1.0	0.750	0.857	0.867

According to the values in Table 2, Turkey has strengths and weaknesses in the United Nations Sustainable Development Goals criteria. In particular, it draws a positive picture by reaching the highest score in criteria such as “Zero Poverty (C1)”, “Affordable and Clean Energy (C7)”, “Decent Work and Economic Growth (C8)”. However, its relatively low scores in criteria such as “Zero Hunger (C2)” and “Clean Water and Sanitation (C6)” indicate that more effort is needed in these areas. Turkey lags behind developed countries in areas such as gender equality and climate action, which highlights the need for policy development in these areas. Developed countries generally perform close to sustainability targets. In particular, European countries (France, Germany, the Netherlands), Scandinavian countries (Sweden, Norway, Finland) and the USA scored high in most criteria. However, these countries also show declines in environmental

sustainability criteria such as “Climate Action (C12)” and “Life on Land (C13)”.

4.1. Weight determination with WENSLO

The first step in determining criterion weights using WENSLO is to normalize the decision matrix. By means of Equation (2), the decision matrix was normalized, and the results are presented in Table 3.

Table 3. Normalized decision matrix

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15
Australia	0.029	0.038	0.043	0.039	0.044	0.035	0.041	0.042	0.035	0.040	0.046	0.050	0.045	0.038	0.042
Austria	0.049	0.043	0.042	0.039	0.044	0.049	0.041	0.042	0.044	0.046	0.046	0.050	0.040	0.045	0.042
Belgium	0.039	0.038	0.040	0.053	0.044	0.042	0.041	0.042	0.044	0.046	0.034	0.025	0.040	0.045	0.042
Canada	0.039	0.049	0.043	0.039	0.036	0.042	0.041	0.042	0.040	0.046	0.034	0.025	0.045	0.038	0.042
Denmark	0.049	0.038	0.042	0.053	0.044	0.042	0.041	0.042	0.044	0.034	0.046	0.050	0.036	0.045	0.042
Finland	0.049	0.038	0.042	0.039	0.044	0.042	0.041	0.042	0.044	0.040	0.046	0.050	0.045	0.045	0.042
France	0.049	0.038	0.042	0.039	0.044	0.042	0.041	0.042	0.044	0.046	0.046	0.050	0.040	0.045	0.042
Germany	0.039	0.038	0.042	0.039	0.044	0.042	0.041	0.042	0.044	0.046	0.034	0.025	0.045	0.045	0.042
Greece	0.039	0.043	0.042	0.039	0.044	0.049	0.041	0.042	0.040	0.040	0.023	0.025	0.045	0.038	0.042
Iceland	0.019	0.038	0.042	0.039	0.044	0.035	0.041	0.042	0.040	0.034	0.034	0.025	0.045	0.038	0.042
Ireland	0.039	0.043	0.042	0.039	0.044	0.042	0.041	0.042	0.040	0.034	0.034	0.025	0.040	0.045	0.042
Italy	0.049	0.043	0.042	0.039	0.044	0.049	0.041	0.042	0.044	0.046	0.046	0.050	0.045	0.045	0.042
Japan	0.029	0.043	0.043	0.039	0.036	0.035	0.041	0.042	0.040	0.040	0.046	0.050	0.040	0.038	0.042
Luxembourg	0.039	0.043	0.040	0.039	0.036	0.042	0.041	0.037	0.040	0.034	0.034	0.025	0.036	0.045	0.042
Netherlands	0.049	0.043	0.040	0.039	0.044	0.042	0.041	0.042	0.044	0.046	0.046	0.050	0.036	0.045	0.042
New Zealand	0.029	0.043	0.043	0.039	0.036	0.042	0.041	0.042	0.040	0.034	0.046	0.050	0.040	0.038	0.042
Norway	0.039	0.049	0.042	0.053	0.044	0.049	0.041	0.042	0.040	0.040	0.034	0.025	0.040	0.038	0.042
Portugal	0.049	0.038	0.042	0.039	0.044	0.042	0.041	0.042	0.044	0.046	0.046	0.050	0.045	0.045	0.042
Spain	0.049	0.043	0.043	0.039	0.044	0.042	0.041	0.042	0.044	0.046	0.046	0.050	0.045	0.045	0.042
Sweden	0.049	0.043	0.038	0.039	0.044	0.042	0.041	0.042	0.044	0.040	0.046	0.050	0.040	0.045	0.042
Switzerland	0.049	0.043	0.040	0.039	0.044	0.042	0.041	0.042	0.040	0.040	0.046	0.050	0.040	0.038	0.038
Turkey	0.049	0.033	0.045	0.039	0.036	0.035	0.050	0.042	0.044	0.046	0.046	0.050	0.045	0.038	0.048
United Kingdom	0.049	0.043	0.042	0.053	0.036	0.042	0.041	0.042	0.040	0.046	0.046	0.050	0.040	0.032	0.042
United States	0.039	0.043	0.043	0.039	0.036	0.042	0.041	0.042	0.040	0.046	0.046	0.050	0.045	0.038	0.038

The subsequent steps consist of, respectively, calculating the interval values (Equation (4)), calculating the slope value (Equation (5)), calculating the envelope value (Equation (6)), calculating the envelope/slope ratio (Equation (7)), and finally determining the final criterion weights. The results of these calculations are presented in Table 4.

Table 4. Criteria slope values

		Δz_j	Slope $\tan \varphi_j$	Envelope E_j	Ratio q_j	Weights w_j
C1	No Poverty	0.0053	8.127	0.249	0.031	0.236
C2	Zero Hunger	0.0030	14.518	0.133	0.009	0.071
C3	Good Health and Well-being	0.0015	29.944	0.062	0.002	0.016
C4	Gender Equality	0.0024	17.990	0.143	0.008	0.062
C5	Quality Education	0.0013	32.361	0.074	0.002	0.018
C6	Clean Water and Sanitation	0.0026	17.023	0.137	0.008	0.062
C7	Affordable and Clean Energy	0.0015	28.574	0.049	0.002	0.013
C8	Decent Work and Economic Growth	0.0010	45.211	0.031	0.001	0.005
C9	Industry, Innovation and Infrastructure	0.0016	26.866	0.078	0.003	0.023
C10	Reduced Inequality	0.0021	20.712	0.130	0.006	0.049
C11	Sustainable Cities and Communities	0.0042	10.297	0.177	0.017	0.133
C12	Climate Action	0.0046	9.468	0.272	0.029	0.222
C13	Life on Land	0.0016	26.614	0.096	0.004	0.028
C14	Peace and Justice Strong Institutions	0.0024	18.443	0.108	0.006	0.045
C15	Partnerships to achieve the Goal	0.0018	24.626	0.057	0.002	0.018

The criterion weights are presented as a bar chart in Figure 3. An examination of the data in the figure reveals that the goal “No Poverty” has the highest weight (0.236), followed closely by “Climate Action” (0.222). Subsequently, “Sustainable Cities and Communities” holds a considerable share (0.133), while “Zero Hunger” (0.071) and “Clean Water and Sanitation” (0.062) both exhibit moderate levels of importance. In contrast, “Decent Work and Economic Growth” carries the lowest weight (0.005), suggesting that, within this particular analysis, it is considered less critical compared to the other listed criteria.

From these findings, several insights can be drawn. First, the relatively high weights for “No Poverty” and “Climate Action” underscore the paramount importance of socio-economic development and environmental protection. This suggests that poverty reduction and sustainable climate strategies should be prioritized in policy-making and research agendas. Second, “Sustainable Cities and Communities,” with a notable weight, indicates the growing emphasis on urban resilience, infrastructure, and livability—factors

vital for long-term sustainability. Meanwhile, the moderate weights of “Zero Hunger” and “Clean Water and Sanitation” affirm the continued urgency of ensuring basic necessities for all populations.

By contrast, the lower weights allocated to goals such as “Decent Work and Economic Growth” do not imply that these objectives are unimportant; rather, they highlight the need for an integrated approach where social, environmental, and economic dimensions are balanced according to contextual priorities. Overall, the results imply that strategies targeting poverty alleviation and climate resilience are central to this framework, serving as a basis for broader interventions that address interconnected sustainable development.




Figure 3. Criterion weights

4.2. Alternative evaluation with CoCoSo

The first step in determining the alternative scores using COCOSO is to normalize the decision matrix. This procedure is performed using Equation (10 and 11), and the results are presented in Table 5.

Table 5. Normalized decision matrix

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15
Australia	0.333	0.333	0.75	0.0	1.0	0.0	0.0	1.0	0.0	0.5	1.0	1.0	1.0	0.5	0.335
Austria	1.000	0.667	0.50	0.0	1.0	1.0	0.0	1.0	1.0	1.0	1.0	1.0	0.5	1.0	0.335
Belgium	0.667	0.333	0.25	1.0	1.0	0.5	0.0	1.0	1.0	1.0	0.5	0.0	0.5	1.0	0.335
Canada	0.667	1.000	0.75	0.0	0.0	0.5	0.0	1.0	0.5	1.0	0.5	0.0	1.0	0.5	0.335
Denmark	1.000	0.333	0.50	1.0	1.0	0.5	0.0	1.0	1.0	0.0	1.0	1.0	0.0	1.0	0.335
Finland	1.000	0.333	0.50	0.0	1.0	0.5	0.0	1.0	1.0	0.5	1.0	1.0	1.0	1.0	0.335
France	1.000	0.333	0.50	0.0	1.0	0.5	0.0	1.0	1.0	1.0	1.0	1.0	0.5	1.0	0.335
Germany	0.667	0.333	0.50	0.0	1.0	0.5	0.0	1.0	1.0	1.0	0.5	0.0	1.0	1.0	0.335
Greece	0.667	0.667	0.50	0.0	1.0	1.0	0.0	1.0	0.5	0.5	0.0	0.0	1.0	0.5	0.335
Iceland	0.000	0.333	0.50	0.0	1.0	0.0	0.0	1.0	0.5	0.0	0.5	0.0	1.0	0.5	0.335
Ireland	0.667	0.667	0.50	0.0	1.0	0.5	0.0	1.0	0.5	0.0	0.5	0.0	0.5	1.0	0.335
Italy	1.000	0.667	0.50	0.0	1.0	1.0	0.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	0.335
Japan	0.333	0.667	0.75	0.0	0.0	0.0	0.0	1.0	0.5	0.5	1.0	1.0	0.5	0.5	0.335
Luxembourg	0.667	0.667	0.25	0.0	0.0	0.5	0.0	0.0	0.5	0.0	0.5	0.0	0.0	1.0	0.335
Netherlands	1.000	0.667	0.25	0.0	1.0	0.5	0.0	1.0	1.0	1.0	1.0	1.0	0.0	1.0	0.335
New Zealand	0.333	0.667	0.75	0.0	0.0	0.5	0.0	1.0	0.5	0.0	1.0	1.0	0.5	0.5	0.335
Norway	0.667	1.000	0.50	1.0	1.0	1.0	0.0	1.0	0.5	0.5	0.5	0.0	0.5	0.5	0.335
Portugal	1.000	0.333	0.50	0.0	1.0	0.5	0.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	0.335
Spain	1.000	0.667	0.75	0.0	1.0	0.5	0.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	0.335
Sweden	1.000	0.667	0.00	0.0	1.0	0.5	0.0	1.0	1.0	0.5	1.0	1.0	0.5	1.0	0.335
Switzerland	1.000	0.667	0.25	0.0	1.0	0.5	0.0	1.0	0.5	0.5	1.0	1.0	0.5	0.5	0.000
Turkey	1.000	0.000	1.00	0.0	0.0	0.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	0.5	1.000
United Kingdom	1.000	0.667	0.50	1.0	0.0	0.5	0.0	1.0	0.5	1.0	1.0	1.0	0.5	0.0	0.335
United States	0.667	0.667	0.75	0.0	0.0	0.5	0.0	1.0	0.5	1.0	1.0	1.0	1.0	0.5	0.000

After the decision matrix has been rendered dimensionless, the S values (Equation (12)), P values (Equation (13)), and the score appraisal strategies values (Equation (14, 15 and 16)) should be determined in sequence. Following these calculations, alternative scores are computed using Equation (17). The results of all the computational steps are presented in Table 6. In addition, the final column of Table 6 provides the rank values obtained after the scores are determined.

Table 6. S Values

	S Values	P Values	Xi	Psi	Omega	Scores	Ranks
Australia	0.573	10.609	0.038	4.417	0.809	2.271	18
Austria	0.868	12.922	0.047	6.282	0.998	3.109	2
Belgium	0.503	12.643	0.045	4.312	0.951	2.339	15
Canada	0.459	10.708	0.038	3.828	0.808	2.049	20
Denmark	0.812	11.853	0.043	5.848	0.916	2.884	9
Finland	0.803	12.820	0.047	5.923	0.985	2.967	6
France	0.813	12.834	0.047	5.980	0.987	2.990	5
Germany	0.460	11.673	0.042	3.955	0.878	2.150	19
Greece	0.390	10.770	0.038	3.466	0.807	1.912	22
Iceland	0.189	8.760	0.031	2.139	0.647	1.288	24
Ireland	0.410	10.685	0.038	3.560	0.803	1.944	21
Italy	0.882	12.941	0.047	6.358	1.000	3.139	1
Japan	0.576	10.620	0.038	4.437	0.810	2.279	17
Luxembourg	0.369	7.693	0.028	2.956	0.583	1.551	23
Netherlands	0.819	11.888	0.044	5.887	0.919	2.901	8
New Zealand	0.583	10.611	0.038	4.472	0.810	2.291	16
Norway	0.527	12.692	0.045	4.446	0.956	2.394	14
Portugal	0.827	12.853	0.047	6.057	0.990	3.020	4
Spain	0.855	12.905	0.047	6.209	0.995	3.081	3
Sweden	0.805	11.858	0.043	5.807	0.916	2.869	10
Switzerland	0.769	11.809	0.043	5.610	0.910	2.792	11
Turkey	0.765	10.969	0.040	5.484	0.849	2.697	12
United Kingdom	0.824	11.864	0.044	5.913	0.918	2.910	7
United States	0.718	10.787	0.039	5.212	0.832	2.583	13

As a result of the computational steps, the scores obtained were visualized on a map (Figure 4). Scores range approximately from 1.288 to 3.139, suggesting a significant disparity in sustainability performance across countries. European countries generally dominate the top of the ranking, although their specific scores vary.

- **Top Performers:** Italy leads with the highest score (3.139), placing it at rank 1. Austria (3.109) and Spain (3.081) follow closely, at ranks 2 and 3, respectively. These results suggest that Italy, Austria, and Spain exhibit notably strong sustainability outcomes in comparison to other countries listed.
- **Strong European Representation:** Many of the top-ranked countries (Italy, Austria, Spain, Portugal, France, Finland, and the United Kingdom) are in Europe, indicating a regional trend toward higher sustainability scores. Portugal (3.02, rank 4) and France (2.99, rank 5) reinforce the observation that Western and Southern European nations frequently appear among the leaders.

- **Mid-Range Scores:** Countries such as Denmark (2.884, rank 9), Sweden (2.869, rank 10), and Switzerland (2.792, rank 11) occupy mid-to-high positions, still performing well in sustainability. Meanwhile, larger nations like the United States (2.583, rank 13) and Turkey (2.697, rank 12) fall in the mid-range, indicating room for improvement relative to the top performers.
- **Lower Scores:** At the lower end of the rankings are Iceland (1.288, rank 24) and Luxembourg (1.551, rank 23), reflecting comparatively weaker performance in the metrics used to calculate sustainability scores. Greece (1.912, rank 22) and Ireland (1.944, rank 21) also appear in the lower tier, signaling potential challenges in meeting sustainability targets.




Figure 4. WENSLO-CoCoSo scores of the OECD Countries.

4.3. Sensitivity Analysis

In this study, countries' sustainability performances were compared using the weight set determined objectively by the WENSLO method. However, when different weight sets are employed, the ranking may or may not change. To gauge countries' sensitivity to these weights, the analysis was

repeated using ten distinct weight sets. Consequently, observing that certain countries maintain high performance across multiple weight configurations suggests they are performing better overall.

For this study, 10 random numbers were drawn from a uniform distribution on the interval $[0,1]$. Their total sum was then computed. Next, each individual random number was divided by this sum, which yielded a corresponding weight in the interval $[0,1]$. As a result, the final set of 10 weights collectively sums to 1.

The weight sets are presented in Table 7. As can be observed from the table, the weights assigned to the criteria differ from one set to another. In other words, a criterion that carries a high weight in one set may have a lower weight in another.

One clear advantage of this variability is that it allows for greater flexibility and adaptability in the evaluation process. By tailoring weights to different sets, it becomes possible to capture the unique priorities, contexts, or constraints of each scenario more accurately. This approach prevents reliance on a single weighting scheme that may not be applicable in all circumstances, thereby enhancing the robustness and relevance of the overall analysis.

Table 7. Random weight sets

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15
Random set 1	0.0016	0.1421	0.1272	0.0965	0.0139	0.0066	0.0349	0.0773	0.0501	0.0773	0.0767	0.0351	0.0745	0.1688	0.0176
Random set 2	0.0684	0.1134	0.0401	0.0479	0.0058	0.1072	0.0030	0.1170	0.0962	0.0266	0.0699	0.1026	0.0365	0.0996	0.0659
Random set 3	0.0148	0.1089	0.0390	0.1275	0.0388	0.0048	0.0911	0.0524	0.0468	0.1234	0.1012	0.0216	0.1182	0.0784	0.0332
Random set 4	0.0094	0.1798	0.1414	0.0071	0.0683	0.0502	0.0359	0.0729	0.0297	0.0785	0.0535	0.0523	0.1052	0.0298	0.0859
Random set 5	0.1320	0.0709	0.0036	0.1530	0.0944	0.0395	0.1052	0.1703	0.0016	0.0152	0.0151	0.0741	0.0210	0.0141	0.0900
Random set 6	0.0597	0.0607	0.0642	0.0439	0.0820	0.0317	0.0740	0.0799	0.1018	0.1062	0.1122	0.0308	0.0860	0.0267	0.0402
Random set 7	0.0940	0.0356	0.0905	0.0783	0.0705	0.0977	0.1035	0.0813	0.0656	0.0719	0.0673	0.0253	0.0862	0.0319	0.0004
Random set 8	0.0861	0.0823	0.0517	0.1216	0.0760	0.0011	0.0123	0.0128	0.1158	0.0026	0.1086	0.1118	0.0982	0.1073	0.0118
Random set 9	0.1293	0.1409	0.0306	0.0537	0.0116	0.0582	0.0093	0.1393	0.0902	0.0107	0.0918	0.0030	0.1424	0.0526	0.0364
Random set 10	0.0810	0.0108	0.0534	0.1083	0.1009	0.1004	0.1109	0.0362	0.0147	0.0028	0.0866	0.1005	0.0179	0.0976	0.0781

The ranking of countries under different weight sets is presented as a heat map in Figure 5. Certain countries (e.g., Iceland and Luxembourg) maintain the same or very similar ranks across all weight sets. This consistency may suggest that these countries' performance is relatively unaffected by changes in the weighting scheme, implying a robust standing in the overall assessment. Other countries (e.g., Spain and Italy) also tend to rank highly under most configurations, though with slight variations. Their generally strong positions may indicate fundamental advantages or stability in the underlying indicators, making them less sensitive to weight fluctuations.

Some countries experience more pronounced shifts in rank depending on the weighting set (e.g., Denmark, Norway, Turkey, and the United Kingdom). Such movements highlight a potential sensitivity to specific criteria within the assessment. When certain indicators are given higher weight, these countries' standings improve or decline accordingly.

The disparities in rankings across the weight sets underscore the importance of transparency in how weights are assigned. In policy analysis or comparative studies, the choice of weights can substantially influence outcomes. Researchers and decision-makers should conduct sensitivity analyses to determine how robust the results are to different weight configurations. This step is crucial for ensuring that conclusions drawn from such rankings are well-founded and not unduly influenced by arbitrary weighting schemes




Figure 5. Sensitivity Analysis

4.4. Comparison with Other Methods

The Table 8 presents the results of score calculations performed using four different multi-criteria decision-making (MCDM) techniques, namely MOORA, WASPAS, TODIM, and TOPSIS. The rows list the countries

under evaluation, and each column shows the corresponding score derived from one of these MCDM methods.

Each MCDM technique applies a different methodological approach to aggregating and prioritizing criteria. Consequently, while the overall trends may be similar (e.g., countries that score relatively high in one method often perform well in others), variations arise due to the unique weighting and normalization processes of each technique. Countries such as Italy (0.9694) and Austria (0.9666) achieve notably high scores, suggesting strong performance under the combined additive-multiplicative approach of WASPAS. Spain (1.0000) and Italy (0.9896) stand out with the highest TODIM values. TODIM, being a prospect theory-based method, can yield higher sensitivity to improvements in certain criteria compared to other methods. Austria (0.9099) and Italy (0.9107) both score above 0.90, indicating minimal distance from the ideal solution and a significant distance from the negative ideal solution under TOPSIS's geometric-based evaluation.

Some countries (e.g., Iceland in TOPSIS with 0.1539; Luxembourg in TODIM with 0.0000) exhibit relatively low scores in specific methods. These discrepancies can highlight areas where a particular country's indicators align poorly with the criteria emphasized by that specific technique.

When comparing countries, it is critical to consider the decision criteria and their relative weights in each method. A country's performance is multidimensional; hence, results should be interpreted in the context of which indicators (economic, social, environmental, etc.) are prioritized and how the techniques process these indicators.

Although there is some alignment in identifying top-performing countries (e.g., Italy, Spain, Austria), the ranking positions may vary among the four methods. This underscores the importance of employing multiple MCDM techniques for robust decision-making. By doing so, analysts can gain a more comprehensive perspective and reduce the risk of methodological bias.

Table 8. Scores of the other models

	MOORA	WASPAS	TOPSIS	TODIM
Australia	0.1930	0.8259	0.5808	0.5408
Austria	0.2241	0.9666	0.9099	0.9330
Belgium	0.1793	0.7642	0.4484	0.6655
Canada	0.1775	0.7575	0.4493	0.5754
Denmark	0.2208	0.9496	0.8950	0.7135
Finland	0.2194	0.9458	0.8815	0.8711
France	0.2201	0.9492	0.8837	0.8671
Germany	0.1761	0.7530	0.4432	0.7628
Greece	0.1695	0.7189	0.4142	0.5945
Iceland	0.1474	0.6239	0.1539	0.3964
Ireland	0.1742	0.7447	0.4438	0.5808
Italy	0.2247	0.9694	0.9107	0.9896
Japan	0.1941	0.8306	0.5843	0.4809
Luxembourg	0.1727	0.7382	0.4434	0.0000
Netherlands	0.2213	0.9539	0.8989	0.7749
New Zealand	0.1949	0.8336	0.5864	0.5012
Norway	0.1821	0.7741	0.4565	0.6218
Portugal	0.2207	0.9519	0.8843	0.9237
Spain	0.2228	0.9611	0.9019	1.0000
Sweden	0.2204	0.9500	0.8972	0.7470
Switzerland	0.2183	0.9407	0.8929	0.5545
Turkey	0.2161	0.9296	0.8454	0.6537
United Kingdom	0.2220	0.9547	0.9149	0.5936
United States	0.2089	0.9000	0.7555	0.5848

Table 9 reports the correlation relationships among the MCDM (Multi-Criteria Decision-Making) scores. For each correlation value, the p-value was calculated to be less than 0.01. The Proposed Model, MOORA, WASPAS, and TOPSIS are highly correlated with each other (all correlation coefficients are above 0.94). This suggests that these four methods produce very similar ranking or scoring outcomes. TODIM shows relatively lower correlation coefficients in comparison to the other methods (ranging from 0.6286 to 0.7984). This indicates that TODIM's scoring results diverge more significantly from the others. Since all p-values are below 0.01, the correlations observed are statistically significant, underscoring the reliability of these relationships.

Table 9. Correlation Analysis results with other models

	Proposed Model	MOORA	WASPAS	TOPSIS	TODIM
Proposed Model	1.000000	0.962308	0.960867	0.947650	0.798437
MOORA	0.962308	1.000000	0.999887	0.995210	0.648089
WASPAS	0.960867	0.999887	1.000000	0.995658	0.648022
TOPSIS	0.947650	0.995210	0.995658	1.000000	0.628622
TODIM	0.798437	0.648089	0.648022	0.628622	1.000000

5. Conclusion

The application of the WENSLO–COCOSO framework to assess OECD countries’ sustainability performances yielded a comprehensive ranking based on fifteen distinct criteria. In the first stage, WENSLO was employed to assign objective weights to each of the sustainability criteria, minimizing potential researcher bias in the weighting process. Subsequently, the COCOSO technique was used to integrate these weighted criteria into an overall performance score for each country.

Several noteworthy findings emerge from these results. First, Italy tops the ranking, indicating relatively strong performance across the majority of the fifteen sustainability criteria. Interestingly, Austria, Spain, and Portugal also appear at the upper end of the scale, suggesting that these countries may have well-established policies or socio-environmental frameworks that holistically address economic, environmental, and social dimensions of sustainability. The high scores for these countries could stem from their investments in clean energy, effective social welfare systems, and progressive environmental regulations. In contrast, Iceland, Luxembourg, and Greece occupy the lower positions in the ranking. While Iceland is often regarded favorably in certain environmental indices (particularly for renewable energy usage), the aggregated evaluation here suggests that some of the broader sustainability dimensions—potentially related to social or economic indicators—brought down its overall score. Likewise, Luxembourg’s score may reflect challenges in areas beyond pure economic metrics, such as environmental impact per capita or social equity, while Greece’s position could be influenced by socio-economic and fiscal pressures that limit extensive sustainability initiatives.

A major limitation of the study is that the 15 SDG benchmarks used do not cover all 17 targets, and in particular the lack of explanation for the exclusion of SDG 12 and SDG 14. The lack of data on 42% of SDG indicators

limits the depth of analysis, while methodological inconsistencies between OECD countries make comparisons difficult. Moreover, the novelty of the WENSLO and CoCoSo techniques prevents the comparison of results with other MCDM methods and the heterogeneous nature of OECD countries may ignore the unique circumstances of some countries. The study's ad-hoc assessment of SDG performance and its failure to quantitatively measure synergies and trade-offs among the SDGs limit the effectiveness of policy recommendations. To overcome these limitations, it is suggested to include SDGs 12 and 14, address data gaps with fuzzy logic or machine learning, and compare WENSLO-CoCoSo results with other methods. It would also be useful to examine successful policies of top-ranked countries, increase regional cooperation for low-performing countries, map SDG synergies through network analysis, and adapt the methodology to the local level. While green bonds and social impact investments are recommended for policymakers, academically, the applicability of WENSLO in other disciplines should be emphasized. These recommendations will strengthen the contributions of the study and guide future research.

References

- Aljaghoub, H., Abumadi, F., AlMallahi, M. N., Obaideen, K., & Alami, A. H. (2022). Solar PV cleaning techniques contribute to Sustainable Development Goals (SDGs) using Multi-criteria decision-making (MCDM): Assessment and review. *International Journal of Thermofluids*, 16, 100233.
- Allen, C., Metternicht, G., & Wiedmann, T. (2016). National pathways to the Sustainable Development Goals (SDGs): A comparative review of scenario modelling tools. *Environmental Science & Policy*, 66, 199-207.
- Allen, C., Metternicht, G., & Wiedmann, T. (2018). Initial progress in implementing the Sustainable Development Goals (SDGs): A review of evidence from countries. *Sustainability science*, 13, 1453-1467.
- Aly, E., Elsawah, S., & Ryan, M. J. (2022). A review and catalogue to the use of models in enabling the achievement of sustainable development goals (SDG). *Journal of cleaner production*, 340, 130803.
- Bali Swain, R., & Yang-Wallentin, F. (2020). Achieving sustainable development goals: predicaments and strategies. *International Journal of Sustainable Development & World Ecology*, 27(2), 96-106.
- Berrone, P., Rousseau, H. E., Ricart, J. E., Brito, E., & Giuliadori, A. (2023). How can research contribute to the implementation of sustainable development goals? An interpretive review of SDG literature in management. *International Journal of Management Reviews*, 25(2), 318-339.
- Biermann, F., Kanie, N., & Kim, R. E. (2017). Global governance by goal-setting: the novel approach of the UN Sustainable Development Goals. *Current Opinion in Environmental Sustainability*, 26, 26-31.
- Biglari, S., Beiglary, S., & Arthanari, T. (2022). Achieving sustainable development goals: Fact or Fiction?. *Journal of Cleaner Production*, 332, 130032.
- Breuer, A., Janetschek, H., & Malerba, D. (2019). Translating sustainable development goal (SDG) interdependencies into policy advice. *Sustainability*, 11(7), 2092.
- Burhan, H. A. (2024). Sustainability in Industry, Innovation and Infrastructure: A MCDM Based Performance Evaluation of European Union and Türkiye for Sustainable Development Goal 9 (SDG 9). *Verimlilik Dergisi*, 21-38.
- Cernev, T., & Fenner, R. (2020). The importance of achieving foundational Sustainable Development Goals in reducing global risk. *Futures*, 115, 102492.
- Das, P. P., & Chakraborty, S. (2022). SWARA-CoCoSo method-based parametric optimization of green dry milling processes. *Journal of Engineering and Applied Science*, 69(1), 35.

- Deveci, M., Pamucar, D., & Gokasar, I. (2021). Fuzzy Power Heronian function based CoCoSo method for the advantage prioritization of autonomous vehicles in real-time traffic management. *Sustainable Cities and Society*, 69, 102846.
- Diaz-Sarachaga, J. M., Jato-Espino, D., & Castro-Fresno, D. (2018). Is the Sustainable Development Goals (SDG) index an adequate framework to measure the progress of the 2030 Agenda?. *Sustainable Development*, 26(6), 663-671.
- Donaires, O. S., Cezarino, L. O., Caldana, A. C. F., & Liboni, L. (2019). Sustainable development goals—an analysis of outcomes. *Kybernetes*, 48(1), 183-207.
- Dünya Bankası, (2024). İstatistiksel Performans Göstergeleri. [https://databank.worldbank.org/source/statistical-performance-indicators-\(spi\)](https://databank.worldbank.org/source/statistical-performance-indicators-(spi))
- Dwivedi, P. P., & Sharma, D. K. (2025). Performance measures of sustainable development goals using SWI MCDM methods: a case of the Indian states. *International Transactions in Operational Research*.
- Ecer, F., & Pamucar, D. (2020). Sustainable supplier selection: A novel integrated fuzzy best worst method (F-BWM) and fuzzy CoCoSo with Bonferroni (CoCoSo'B) multi-criteria model. *Journal of cleaner production*, 266, 121981.
- Fleming, A., Wise, R. M., Hansen, H., & Sams, L. (2017). The sustainable development goals: A case study. *Marine Policy*, 86, 94-103.
- Guo, Y., Yu, M. M., & See, K. F. (2024). Developing a sustainable development goals index for OECD countries: An effectiveness-based hierarchical data envelopment analysis. *Environmental Science & Policy*, 160, 103836.
- Hák, T., Janoušková, S., & Moldan, B. (2016). Sustainable Development Goals: A need for relevant indicators. *Ecological indicators*, 60, 565-573.
- Jafari, M., & Khanachah, S. N. (2024). Integrated knowledge management in the supply chain: Assessment of knowledge adoption solutions through a comprehensive CoCoSo method under uncertainty. *Journal of Industrial Information Integration*, 39, 100581.
- Kara, K., Ergin, E. A., Yalçın, G. C., Çelik, T., Deveci, M., & Kadry, S. (2025). Sustainable brand logo selection using an AI-Supported PF-WENSLO-ARLON hybrid method. *Expert Systems With Applications*, 260, 125382.
- Kara, K., Yalçın, G. C., Ergin, E. A., Simic, V., & Pamucar, D. (2024). A neutrosophic WENSLO-ARLON model for measuring sustainable brand equity performance. *Socio-Economic Planning Sciences*, 94, 101918.
- Lai, H., Liao, H., Long, Y., & Zavadskas, E. K. (2022). A hesitant Fermatean fuzzy CoCoSo method for group decision-making and an application to

- blockchain platform evaluation. *International Journal of Fuzzy Systems*, 24(6), 2643-2661.
- Lc Blanc, D. (2015). Towards integration at last? The sustainable development goals as a network of targets. *Sustainable Development*, 23(3), 176-187.
- Leal Filho, W., Azeiteiro, U., Alves, F., Pace, P., Mifsud, M., Brandli, L., ... & Disterheft, A. (2018). Reinvigorating the sustainable development research agenda: the role of the sustainable development goals (SDG). *International Journal of Sustainable Development & World Ecology*, 25(2), 131-142.
- Leal Filho, W., Tripathi, S. K., Andrade Guerra, J. B. S. O. D., Giné-Garriga, R., Orlovic Lovren, V., & Willats, J. (2019). Using the sustainable development goals towards a better understanding of sustainability challenges. *International Journal of Sustainable Development & World Ecology*, 26(2), 179-190.
- Moyer, J. D., & Hedden, S. (2020). Are we on the right path to achieve the sustainable development goals?. *World Development*, 127, 104749.
- Okursoy, A., & Coşansu, D. T. (2024). Zero emission electric vehicle selection using the MEREC-based CoCoSo method. *Alphanumeric Journal*, 12(1), 39-58.
- Pamucar, D., Ecer, F., Gligorić, Z., Gligorić, M., & Deveci, M. (2023). A novel WENSLO and ALWAS multicriteria methodology and its application to green growth performance evaluation. *IEEE Transactions on Engineering Management*.
- Pradhan, P., Costa, L., Rybski, D., Lucht, W., & Kropp, J. P. (2017). A systematic study of sustainable development goal (SDG) interactions. *Earth's Future*, 5(11), 1169-1179.
- Rad, M. A. V., Fard, H. F., Khazanedari, K., Toopshekan, A., Ourang, S., Khanali, M., ... & Kasacian, A. (2024). A global framework for maximizing sustainable development indexes in agri-photovoltaic-based renewable systems: Integrating DEMATEL, ANP, and MCDM methods. *Applied Energy*, 360, 122715.
- Salvia, A. L., Leal Filho, W., Brandli, L. L., & Griebeler, J. S. (2019). Assessing research trends related to Sustainable Development Goals: Local and global issues. *Journal of cleaner production*, 208, 841-849.
- Sousa, M., Almeida, M. F., & Calili, R. (2021). Multiple criteria decision making for the achievement of the UN sustainable development goals: A systematic literature review and a research agenda. *Sustainability*, 13(8), 4129.
- Sreenivasan, A., Suresh, M., & Nedungadi, P. (2023). Mapping analytical hierarchy process research to sustainable development goals: Bibliometric and social network analysis. *Heliyon*, 9(8).

- Stanujkic, D., Popovic, G., Zavadskas, E. K., Karabasevic, D., & Binkyte-Veliene, A. (2020). Assessment of progress towards achieving Sustainable Development Goals of the “Agenda 2030” by using the CoCoSo and the Shannon Entropy methods: The case of the EU Countries. *Sustainability*, 12(14), 5717.
- Trung, D. D., Ersoy, N., & Uyen, V. T. N. (2024). Cylinder and piston: Material selection in the design phase. *Journal of Applied Engineering Science*, 22(4), 789-803.
- Yazdani, M., Zarate, P., Kazimieras Zavadskas, E., & Turskis, Z. (2019). A combined compromise solution (CoCoSo) method for multi-criteria decision-making problems. *Management decision*, 57(9), 2501-2519.
- Yu, J., Ding, H., Yu, Y., Wu, S., Zeng, Q., & Xu, Y. (2024). Risk assessment of liquefied natural gas storage tank leakage using failure mode and effects analysis with Fermatean fuzzy sets and CoCoSo method. *Applied Soft Computing*, 154, 111334.
- Zhang, H., & Wei, G. (2023). Location selection of electric vehicles charging stations by using the spherical fuzzy CPT-CoCoSo and D-CRITIC method. *Computational and Applied Mathematics*, 42(1), 60.

Portföy Çalışmalarında Makine Öğrenmesi Kullanımı Üzerine Bibliyometrik Bir Değerlendirme

Sema Akin Bas¹

Özet

Bu çalışma portföy ve makine öğrenmesi alanlarında yapılan akademik yayınları sistematik bir şekilde inceleyerek ortaya çıkan literatürü bibliyometrik yöntemle analiz etmeyi amaçlamaktadır. Web of Science (WoS) veri tabanından elde edilen yayınlar ilgili anahtar kelimeler ile taranmış ve elde edilen yayınların yıllara göre eğilimleri, kurumlar, ülkeler, atıf alan çalışmalar, sık kullanılan anahtar kelimeler detaylı olarak değerlendirilmiştir.

Elde edilen bulgular, portföy yönetimi alanında makine öğrenmesi tekniklerinin kullanımının özellikle son yıllarda hızla arttığını göstermektedir. Tahminleme, sınıflandırma ve optimizasyon problemlerinde yapay sinir ağları, rastgele ormanlar, destek vektör makineleri gibi algoritmaların sıklıkla tercih edildiği tespit edilmiştir.

Bibliyometrik analiz ile çalışılan alanın mevcut durumu kapsamlı bir şekilde ortaya konmuştur. Tematik boşluklar ve gelecekteki çalışmalar için potansiyel yönelimleri de işaret etmektedir. Bu yönü ile çalışma hem araştırmacılar hem de uygulayıcılar için referans niteliği taşımaktadır.

1. Giriş

Portföy yönetimi, finansal piyasalarda paydaşların risk ve getiri dengesini sağlamak amacıyla karşılaşılan en temel ve stratejik problemlerden biridir. Yatırımcıların farklı varlık türlerine ilişkin beklentilerini, risk algılarını ve getiri hedeflerini dengeleyerek etkin yatırım kararları almalarını amaçlayan bu alan, hem teorik modeller hem de pratik uygulamalar açısından zengin bir çerçeve sunmaktadır. Geleneksel portföy teorisi, yatırımcıların risk toleransına bağlı

1 Dr. Öğr. Üyesi, Yıldız Teknik Üniversitesi, Fen Edebiyat Fakültesi, Matematik Bölümü, İstanbul, Türkiye, akins@yildiz.edu.tr, ORCID: orcid.org/0000-0002-9937-316X

olarak varlıklarını çeşitlendirerek optimal bir getiri sağlamayı hedeflerken, günümüzde portföy yönetimi birçok finansal ve finansal olmayan metriklere dayanarak ele alınmaktadır (Leow vd., 2021). Bununla birlikte finansal piyasalar, teknolojik gelişmeler ve dijitalleşmenin etkisiyle yüksek hacimli veri akışına maruz kalarak karmaşık ve veri yoğunluğunun yüksek olduğu bir alan haline gelmiştir. Finansal piyasaların dinamik yapıda olması ve veri kaynaklarının artması ile birlikte büyük ve karmaşık yapıdaki verilerin içerdiği belirsizlikler ile işlenmesi oldukça kritik bir nokta haline gelmiştir. Karar alma süreçlerinde yetersiz kalan geleneksel yatırım stratejileri yüksek boyutlu ve karmaşık verileri işlemek ve anlamlı içgörülere dönüştürmek konusunda çoğu zaman yetersiz kalmaktadır. Yatırımcıların doğru bilgiye zamanında ulaşmasını ve etkili stratejiler geliştirmesini zorlaştırmaktadır. Bu bağlamda büyük veri kümelerinin işlenebilmesi, karmaşık örüntülerin tanımlanması ve veri odaklı tahminlerde bulunabilmek için daha güçlü, adaptif yöntemlerin kullanılması ihtiyacı doğmuştur. Böylece makine öğrenmesi gibi yeni nesil yaklaşımlar portföy yönetimi problemlerinde ön plana çıkmıştır. Gelişmiş makine öğrenmesi teknikleri, geleneksel modellerin gözden kaçırabileceği, veri içerisindeki ilişkileri belirleyerek portföy yönetimi için etkin çözümler sunmaktadır. Portföy yönetimi sürecinde makine öğrenmesi kullanımı, tahmin doğruluğunu artırmanın yanı sıra sürekli değişen piyasa koşullarında risk ve getiri yönetimine daha dinamik bir yaklaşım sunmaktadır (Behara ve Kumar, 2025). Böylece, yatırım kararlarını optimize etme potansiyeli taşıyan güçlü araçlar olarak öne çıkmaktadır.

Büyük veri teknolojilerinin gelişimi, finansal piyasalarda anlık ve yüksek hacimli olan veri akışını işlenebilir hale getirirken, makine öğrenmesi algoritmaları bu verilerden anlamlı örüntüler çıkarma, sınıflandırma, kümeleme, tahmin yapma gibi görevleri yerine getirmede yüksek başarı göstermektedir. Portföy yönetimi düzeyinde öngörü modelleri sayesinde risk-getiri profilleri daha dinamik bir şekilde optimize edilebilmektedir (Paiva vd., 2019). Klasik istatistiksel tekniklere göre makine öğrenmesi algoritmaları daha esnek bir yapıya sahiptir. Ayrıca doğrusal olmayan ilişkileri ve çok boyutlu veri yapılarını öğrenebilme kapasitesine sahiptir. Portföy yönetimi uygulamalarında hem öngörüselsel hem de sınıflayıcı görevler için destek vektör makineleri, rassal ormanlar, karar ağaçları, gradyan arttırmalı ağaçlar gibi topluluk öğrenmesi algoritmaları kullanılmaktadır (Boudabsa ve Filipovic, 2022; Mienye ve Sun, 2022; Zhao ve Ye, 2024; Ferrouhi ve Bouabdallaoui, 2024). Diğer yandan, yapay sinir ağları, derin öğrenme algoritmaları doğrusal olmayan ilişki yapılarını ortaya çıkarmada oldukça başarılı yöntemlerdendir (Huang vd., 2024; Kubo ve Nakagawa, 2025). Uzun-kısa süreli bellek ağları gibi modeller ise zamana duyarlı finansal zaman

serilerinin analizinde kullanılmaktadır (Cao vd., 2019; Muroua ve Lamine, 2023). Bu algoritmaları sayesinde karar süreçlerinde karşılaşılabilecek insan hatasına dayalı önyargılar azaltılabilmektedir. Bu nedenle günümüzde portföy yönetimi uygulamalarında yapay zeka temelli akıllı sistemler ön plana çıkmaktadır.

Bu çalışmada, makine öğrenmesi teknikleri kapsamında portföy yönetimi konularının uluslararası literatürdeki gelişiminin bibliyometrik analiz yöntemiyle incelenmesi amaçlanmaktadır. Çalışma kapsamında atıf analizi, anahtar kelime frekans analizi ve yazar iş birliği ağları gibi teknikler kullanılmış ve alandaki önde gelen araştırmacılar, dergiler, ülkeler, temel temalar ve gelişen eğilimler belirlenmiştir. Elde edilen bulgular araştırma eğilimlerini daha net bir şekilde ortaya koyacağı ve ilgili çalışma alanındaki bilgi boşluklarının belirlenmesine katkı sağlayacağı düşünülmektedir.

2. Yöntem

Bu çalışma, portföy konulu bilimsel çalışmalarda makine öğrenmesi algoritmalarının kullanımı hakkında detaylı bir analiz ortaya koymayı amaçlamaktadır. Bu doğrultuda, 28.05.2025 tarihinde WoS veri tabanında herhangi bir başlangıç tarihi sınırlaması olmaksızın ve verinin alındığı son tarihi ile “tüm alanlar” alanlarında “portfolio selection” OR “portfolio” AND “machine learning” kelimeleri kullanılarak yapılan arama ile 1526 çalışma listelenmiştir ve elde edilen veri kümesi dışa aktarılmıştır. Bibliyometrik analiz yöntemi kullanılarak verinin tamamı analize dahil edilmiştir. Ayrıca, bibliyometrik analiz için R Studio yazılımında Aria ve Cuccurullo (2017) tarafından geliştirilen bibliometrix kütüphanesi üzerinden biblioshiny kullanılmıştır.

Bibliyometrik analiz, bilimsel yayınlara ait bibliyografik bilgilerin makale, anahtar kelime, yazar ve dergi bazında incelenerek belirli bir araştırma alanının genel yapısını nicel verilerle ortaya koymayı amaçlayan bir yöntemdir (Merigo ve Yang, 2016). Bu analiz türünde, belirli bir bilim dalının değerlendirilmesinin yanı sıra ülkeler, kurumlar veya bireyler düzeyinde de bilimsel üretkenlik değerlendirilerek mevcut duruma ilişkin çeşitli çıkarımların yapılmasına olanak tanınmaktadır (Şakar ve Cerit, 2013).

Literatür incelendiğinde, “Portföy Yönetimi” ve “Makine Öğrenmesi” konularının ayrı ayrı ele alındığı çeşitli yıllarda yapılmış bibliyometrik analiz çalışmalarının mevcut olduğu görülmüştür. Goodell vd. (2021) ortak atıf hem de bibliyometrik bağlantı analizlerini kullanarak, 1986 - Nisan 2021 tarihleri arasında finans alanında yapay zeka ve makine öğrenimi araştırmalarının tematik yapısını çıkarmışlardır. Ahmed vd. (2022) Scopus veri tabanından


elde ettikleri 2011-2021 yılları arasındaki 348 adet çalışmadan oluşan veri kümesi ile finans alanında yapay zeka ve makine öğrenimi çalışmalarının bibliyometrik analizini yapmışlardır. Bu çalışmanın tarihsel güncelliği ve konunun başlangıcından itibaren dahil edilmesi ile de literatüre katkı sağlayacağı aşıkardır.

3. Analiz ve Sonuçlar

Bu çalışmada, WoS veri tabanından alınan veri kümesindeki yayınlar üzerinde bibliyometrik analiz gerçekleştirilmiş olup elde edilen bulgular sunulmuştur.

3.1. Tanımlayıcı analiz: Yayınların gelişimi

Portföy probleminde makine öğrenmesi algoritmaları kullanımı üzerine yapılmış bilimsel yayınların sayısının yıllara göre dağılımı Excel’de oluşturulan grafik ile Şekil 1’de gösterilmektedir. Başlangıç yılının 1991 olduğu veri kümesinde ilgili alanda yapılan araştırmaların sayısının 2003 yılına kadar sadece varlığını sürdürdüğü ve sonrasında genel anlamda her geçen yıl arttığı gözlemlenmektedir. Yayın sayılarında, 2003-2013 yılları arasında yer yer artma ve azalma eğilimi gözlenirken 2013’ten sonra her geçen yıl belirgin bir artış izlemiştir. Bu alandaki araştırma sayısı 2017 yılından sonra önemli ölçüde artarak 2023 yılında 291 çalışma ile zirve yapmıştır. 2025 yılının ilk yarısının tamamlanmamış olduğu dikkate alınırca ilgili yıl için yayın sayılarının artacağı yorumu yapılabilir.




Şekil 1. Zaman İçindeki Yıllık Bilimsel Çalışmalar

Çalışma kapsamında elde edilen veri kümesinde hangi türlerde çalışmaların bulunduğu ve çalışma sayıları incelenmiştir. Buna ilişkin veriler Tablo 1’de sunulmuştur. İlgili konuda tamamlanan çalışmaların çoğunun makale türünde olduğu görülmektedir. Ayrıca, kitap türünde yapılan 10 adet çalışma sayısı ile toplam çalışmalar içerisinde binde 6,5’lik paya sahiptir.

Tablo 1. Çalışmaların Türüne Göre Dağılımları

Çalışma Türü	Çalışma Sayısı	Yüzdeliği
Makale	1,049	%68,7
Konferans Bildirisi	396	%26
İnceleme	62	%4,1
Kitap Bölümü	10	%0,65
Diğer	9	%0,59


Şekil 2’de, ilgili alandaki toplam yayınların yaklaşık olarak %14,3’ünü temsil ederek en çok yayını bulunan ilk on dergi listelenmektedir. Bu dergiler arasında Expert Systems with Applications açık ara ilgili alanda en çok yayın bulunan dergidir; 218 makalenin 47’si bu dergide yayınlanmıştır ve yaklaşık %21,6’sını temsil etmektedir.



Şekil 2. Zaman İçinde Öne Çıkan Dergiler


3.2. İş birliği analizi: kurumlar ve ülkeler

Şekil 3'te, ilgili konuda yayın yapan yazarların ülkelerine göre bir grafik oluşturulmuştur. Grafikteki turuncu renk çoklu ülke iş birliği (ÇÜİB)'ni, mavi renk ise yalnızca ilgili kurumu yani tekli ülke iş birliği (TÜİB)'ni temsil etmektedir. Elde edilen bulgulara göre; bu alanda en fazla yayının Amerika Birleşik Devletleri'nde (TÜİB:63 ve ÇÜİB:236) yapıldığı, bunu Çin'in (TÜİB:208 ve ÇÜİB:49) takip ettiği görülmüştür. İlgili konuda en çok yayın yapılan üçüncü ülke ise 35 adet çoklu ülke iş birliği ve 61 adet ülke içi iş birliği ile Almanya'dır (TÜİB:61 ve ÇÜİB:35).



Şekil 3. Sorumlu Yazarın Ülkesi

Analizi yapılan konu ile ilgili literatüre en çok katkıda bulunan kurumlar Şekil 4'te listelenmiştir. Kurum bazında, Almanya'daki Heinrich Heine Üniversitesi 43 yayınlı ilk sırada yer alırken toplam 75 yayınlı en etkili kurumlar listesinde Almanya'daki iki adet üniversite bulunmaktadır. Ayrıca ülke bazındaki listede beşinci sırada bulunan Çin'den de iki farklı üniversite en etkili kurumlar listesinde yer almaktadır.




Şekil 4. Konu ile İlgili Alana Katkıda Bulunan Kurumlar

3.3. Ortak Kelime Analizi ile Kritik Odakların Tespiti

Veri kümesinde en sık kullanılan yazar anahtar kelimeleri Şekil 5'te verilmiştir. Grafik oluşturulurken “portfolio” ve “machine learning” anahtar kelimeleri tarama sırasında kullanıldığı ve zaten araştırmanın konusu olduğu için listeden çıkarılmıştır. Ayrıca, “machine” ve “learning” anahtar kelimeleri tek başlarına anlamlı çıkarımlar ifade etmediğinden listeden çıkarılmıştır. Elde edilen bulgulara göre “portfolio” ve “machine learning” anahtar kelimeleriyle birlikte en sık kullanılan anahtar kelimeler “derin öğrenme”, “tahmin”, “yapay zeka” ve “optimizasyon” olduğu görülmüştür. “pekiştirmeli öğrenme”, “sinir ağları”, “rastgele orman” ve “kümele” gibi makine öğrenmesi teknikleri de alanda en çok kullanılan anahtar kelimeler arasında yer almıştır. Ayrıca, geleneksel yöntemlerle işlenemeyecek kadar hacimli, hızlı ve çeşitli veri kümelerini ifade eden “büyük veri” ve bu büyük veri kümeleri içinden anlamlı desenler, ilişkiler ve bilgiler keşfetme süreci olan “veri madenciliği” anahtar kelimeleri tespit edilmiştir. Listedeki diğer anahtar kelimeler incelediğinde kavramların portföy ile ilişkili alanlarda sıklıkla araştırılan kavramlar olduğu görülmüştür. Veri kümesinde en sık kullanılan anahtar kelimeler Şekil 6'daki kelime bulutu ile de görselleştirilmiştir.


üzerine yapılan araştırmaların 2017 yılından itibaren artış göstermesiyle birlikte (Bkz. Şekil 1), ilgili yıldan itibaren birçok kavram birlikte trend konular arasında bulunmuştur. 2012-2021 yılları arasında uzun bir süre trend konularda varlığını sürdüren “genetik algoritma” ise yerini “kümeleme”, “yapay zeka”, “derin öğrenme”, “rastgele orman” ve “sinir ağları” konularına bırakmıştır. Özellikle, “derin öğrenme”, “yapay zeka” ve “optimizasyon” 2022 yılında trend konuların kullanımında sırasıyla 77, 62 ve 60 kullanım ile zirve yapmıştır. 2024 yılına gelindiğinde bu alanda yapılan çalışmaların sayısında da önemli bir artış olduğu (Bkz. Şekil 1) not edilerek “uzun kısa süreli bellek” kavramının da önem kazandığı görülmektedir. Ayrıca, 2024 yılında 40 kullanım sıklığı ile “tahmin” kavramı da trend olan konular arasında yer almıştır. Öte yandan, 2025 yılı ile birlikte “açıklanabilir yapay zeka” kavramı bu alandaki trend konular arasında yer almıştır.



Şekil 7. Trend Konular


3.4. Bibliyografik Bağlantı Ağlarının Analizi

Şekil 8, anahtar kelimelerin oluşturduğu eş-oluşum ağlarını göstermektedir. Birbiriyle ilişkili üç farklı eş-oluşum kümesinin olduğu görülmektedir. En geniş ağı sahip mavi kümede en belirgin olarak “seçim”, “model”, “performans”, “optimizasyon”, “sinir ağları”, “regresyon” ve “tahmin” gibi anahtar kelimeler yer almıştır. Bu kümede konu ile ilgili diğer anahtar kelimeler de şekilde görülmektedir. Yeşil renkli diğer büyük kümede ise “risk” kavramı ön plana çıkmış olup bu kümede “getiriler”, “kesit” ve “değişkenlik” anahtar kelimeleri yoğun kullanıma sahiptir. Ayrıca, diğer kavramlarla da ilişkili olduğu tespit edilmiştir. Diğer oluşumda öne çıkan belirli bir anahtar kelime bulunmamakla beraber şekilde de görüldüğü gibi diğer kümelerdeki kavramlar ile oluşturulan ağları içermektedir.



Şekil 8. Eş-oluşum Ağı

Son olarak ilgili veri kümesindeki çalışmalar kullanılarak temel, yükselen veya gerileyen, niş ve motor temalar üzerinden kavramlar belirlenmiştir. Oluşturulan tematik harita Şekil 9’da sunulmuştur. Sağ alt köşede yer alan temel temalar, çalışmalar için genel öneme sahip konuları göstermektedir. Bu bölümde iki farklı küme oluştuğu görülmektedir. Bu kümelerde “yön” ile birlikte “enerji” ve “endeksler” kavramları yer alırken “optimizasyon” kavramıyla sıklıkla “ağlar” ve “tasarım” kavramlarının kullanıldığı görülmüştür. Diğer taraftan, sol alt kısımda yer alan yükselen veya gerileyen temalarda sadece “algoritma seçimi” ve “zorluklar” kavramları ayrı kümeler ile belirgin olarak öne çıkmıştır. “Saf çeşitlendirme”, “kovaryans matrisi” ve “Markowitz”, “Bitcoin”, “hisse senetleri” ve “altın” olmak üzere temel iki küme ile bu konulardaki çalışmaların bu alanda niş temalar olduğu tespit edilmiştir. Niş temalar, ilgili kavramların kendi aralarında güçlü bağlantılara sahip olduğunu ve diğer konulardan farklı olduğunu göstermektedir. Son olarak, motor temalarda görece olarak daha büyük iki küme oluşumu bulunmaktadır. Kümelerin büyüklüğü araştırmalarda sıklıkla kullanıldığını göstermektedir. Burada “tahmin”, “optimizasyon” kavramı ile “performans” ve “model” ile “risk” kavramları bir arada ele alınmıştır. Diğer bir deyişle, çalışmalar arasında en önemli ve gelişmiş ana çalışma alanları olarak kabul edilen konulardır.



Şekil 9. Tematik Harita

3.5. Alıntı Analizi: Ana Makaleler ve Yazarlar

Veri kümesindeki çalışmalar toplam atıf sayılarına göre sıralanmış ve en yüksek atıf sayısına sahip 10 çalışma Tablo 2’de listelenmiştir. Listenin %20’sine karşılık gelen 2 yayın ile ilgili konuda en çok atıf alan yayınların “Expert Systems with Applications” dergisinde yayımlandığı görülmektedir.

Tablo 2. En çok atıf alan yayımlar

Yazar(lar)	Başlık	Anahtar Kelimeler	Yıl	Dergi	Atıf Sayısı
Hazan, E., Agarwal, A. ve Kale, S.	<i>Logarithmic regret algorithms for online convex optimization</i>	<i>Online learning; Online optimization; Regret minimization; Portfolio management</i>	2007	<i>Machine Learning</i>	570
Cavalcante, R. C., Brasileiro, R. C., Souza, V. L., Nobrega, J. P. ve Oliveira, A. L.	<i>Computational Intelligence and Financial Markets: A Survey and Future Directions</i>	<i>Financial markets; Computational intelligence; Trading systems; Deep learning; Online learning</i>	2016	<i>Expert Systems with Applications</i>	358
Elmachtoub, A. N., ve Grigas, P.	<i>Smart “Predict, then Optimize”</i>	<i>Prescriptive analytics, Data-driven optimization; Machine learning; Linear regression</i>	2022	<i>Management Science</i>	320
Hutter, F., Xu, L., Hoos, H. H., ve Leyton-Brown, K.	<i>Algorithm runtime prediction: Methods & evaluation</i>	<i>Supervised machine learning; Performance prediction; Empirical performance models; Response surface models; Highly parameterized algorithms; Propositional satisfiability; Mixed integer programming; Travelling salesperson problem</i>	2014	<i>Artificial Intelligence</i>	303
Goodell, J. W., Kumar, S., Lim, W. M., ve Pattnaik, D..	<i>Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis</i>	<i>Artificial intelligence; Bibliometric analysis; Finance; Machine learning; Review</i>	2021	<i>Journal of Behavioral and Experimental Finance</i>	300

Kerschke, P., Hoos, H. H., Neumann, E., ve Trautmann, H.	<i>Automated Algorithm Selection: Survey and Perspectives</i>	2019	<i>Automated algorithm selection; Automated algorithm configuration; Combinatorial optimization; Continuous optimization; Machine learning; Metalearning; Feature-based approaches; Exploratory landscape analysis; Data streams</i>	<i>Evolutionary Computation</i>	255
Wang, X., Wang, B., Liu, S., Li, H., Wang, T., ve Watada, J.	<i>Fuzzy portfolio selection based on three-way decision and cumulative prospect theory</i>	2022	<i>Fuzzy portfolio selection; Three-way decision; Cumulative prospect theory; Expected utility theory</i>	<i>International Journal of Machine Learning and Cybernetics</i>	208
Helmhold, D. P., Schapire, R. E., Singer, Y., ve Warmuth, M. K.	<i>On-line portfolio selection using multiplicative updates</i>	1998	<i>Portfolio selection; Rebalancing; Machine learning algorithms</i>	<i>Mathematical Finance</i>	200
Li, B., ve Hoi, S. C.	<i>Online Portfolio Selection: A Survey</i>	2014	<i>Design; Algorithms; Economics; Machine learning; Optimization; Portfolio selection</i>	<i>ACM Computing Surveys</i>	181
Bustos, O., ve Pomares-Quimbaya, A.	<i>Stock market movement forecast: A Systematic review</i>	2020	<i>Stock market forecast; Machine learning; Financial modeling</i>	<i>Expert Systems with Applications</i>	174

4. Sonuç

Bu çalışma kapsamında, portföy yönetimi ve makine öğrenmesi temalı literatür bibliyometrik analiz ile incelenmiştir. Alandaki akademik eğilimler, yayın yapıları, öne çıkan kurumlar ve dergiler, sıkça kullanılan anahtar kelimeler ve tematik haritaları yorumlanmıştır. Elde edilen bulgular, bu alanda gerçekleşen çalışmaların son yıllarda ivme kazanarak makine öğrenmesi tekniklerinin portföy yönetimi çalışmalarında daha fazla yer bulduğunu gözler önüne sermektedir. Daha sonra çalışmaların yürütüldüğü ülkeler ve kurumlar ile sorumlu yazarların ülkeleri belirlenmiştir. Yazar anahtar kelimeleri kullanılarak veri kümesinde en sık tekrar eden anahtar kelimeler yardımıyla yapılan çalışmalardaki önemli noktalar tespit edilmiştir. Özellikle derin öğrenme, öngörü modelleri ve risk optimizasyonu gibi alt başlıkların da ön plana çıktığı görülmektedir. Ayrıca, ilgili anahtar kelimeler ile bu alandaki trend konular belirlenerek veri kümelemesi aracılığıyla terimler arasında bir ağ ve tematik bir harita oluşturulmuştur. Son olarak, atıf analizi ile en sık atıf alan on yayın listelenmiştir.

Yapılan analiz sonucunda, portföy yönetiminde makine öğrenmesi yöntemlerinin sadece teknik bir araç olarak kullanımı değil, aynı zamanda yatırım karar süreçlerinde stratejik bir bileşen olarak konumlandığını ortaya koymaktadır. Literatürdeki odak değişimleri, bu alanda yeni araştırma fırsatlarının ve metodolojik yaklaşımların geliştiğini göstermektedir. Bu yönüyle çalışma, literatürdeki mevcut boşlukları ve gelişim alanlarını belirlemeye katkı sağlamanın yanı sıra yapılacak olan araştırmalar için yönlendirici bir çerçeve sunmaktadır.

Kaynaklar

- Ahmed, S., Alshater, M. M., Ammari, A. E., ve Hammami, H. (2022). Artificial intelligence and machine learning in finance: A bibliometric review. *Research in International Business and Finance*, 61, 101646.
- Aria, M. ve Cuccurullo, C. (2017). Bibliometrix: a R-tool for comprehensive science mapping analysis. *Journal of Informetrics*, 11(4), 959-975. DOI: 10.1016/j.joi.2017.08.007
- Behera, J., ve Kumar, P. (2025). An approach to portfolio optimization with time series forecasting algorithms and machine learning techniques. *Applied Soft Computing*, 112741
- Boudabsa, L., ve Filipović, D. (2025). Ensemble learning for portfolio valuation and risk management. *Quantitative Finance*, 25(3), 421-442.
- Bustos, O., ve Pomares-Quimbaya, A. (2020). Stock market movement forecast: A systematic review. *Expert Systems with Applications*, 156, 113464.
- Cao, J., Li, Z., ve Li, J. (2019). Financial time series forecasting model based on CEEMDAN and LSTM. *Physica A: Statistical mechanics and its applications*, 519, 127-139.
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L., Nobrega, J. P., ve Oliveira, A. L. (2016). Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, 55, 194-211.
- Elmachtoub, A. N., ve Grigas, P. (2022). Smart “predict, then optimize”. *Management Science*, 68(1), 9-26.
- Ferrouhi, E. M., ve Bouabdallaoui, I. (2024). A comparative study of ensemble learning algorithms for high-frequency trading. *Scientific African*, 24, e02161.
- Goodell, J. W., Kumar, S., Lim, W. M., ve Pattnaik, D. (2021). Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis. *Journal of Behavioral and Experimental Finance*, 32, 100577.
- Hazan, E., Agarwal, A., ve Kale, S. (2007). Logarithmic regret algorithms for online convex optimization. *Machine Learning*, 69(2), 169-192.
- Helmhold, D. P., Schapire, R. E., Singer, Y., ve Warmuth, M. K. (1998). On-line portfolio selection using multiplicative updates. *Mathematical Finance*, 8(4), 325-347.
- Huang, S., Cao, L., Sun, R., Ma, T., ve Liu, S. (2024). Enhancing Portfolio Optimization: A Two-Stage Approach with Deep Learning and Portfolio Optimization. *Mathematics*, 12(21), 3376.
- Hutter, F., Xu, L., Hoos, H. H., ve Leyton-Brown, K. (2014). Algorithm runtime prediction: Methods & evaluation. *Artificial Intelligence*, 206, 79-111.

- Kerschke, P., Hoos, H. H., Neumann, F., ve Trautmann, H. (2019). Automated algorithm selection: Survey and perspectives. *Evolutionary computation*, 27(1), 3-45.
- Kubo, K., ve Nakagawa, K. (2025). Portfolio optimization using deep learning with risk aversion utility function. *Finance Research Letters*, 74, 106761.
- Leow, E. K. W., Nguyen, B. P., ve Chua, M. C. H. (2021). Robo-advisor using genetic algorithm and BERT sentiments from tweets for hybrid portfolio optimisation. *Expert Systems with Applications*, 179, 115060.
- Li, B., ve Hoi, S. C. (2014). Online portfolio selection: A survey. *ACM Computing Surveys (CSUR)*, 46(3), 1-36.
- Merigó, J. M. ve Yang, J. B. (2017). A bibliometric analysis of operations research and management science. *Omega*, 73, 37-48.
- Mienye, I. D. ve Sun, Y. (2022). A survey of ensemble learning: Concepts, algorithms, applications, and prospects. *Ieee Access*, 10, 99129-99149.
- Mroua, M., ve Lamine, A. (2023). Financial time series prediction under Covid-19 pandemic crisis with long short-term memory (LSTM) network. *Humanities and Social Sciences Communications*, 10(1), 1-15.
- Paiva, F. D., Cardoso, R. T. N., Hanaoka, G. P., & Duarte, W. M. (2019). Decision-making for financial trading: A fusion approach of machine learning and portfolio selection. *Expert systems with applications*, 115, 635-655.
- Şakar, G. D., ve Cerit, A. G. (2013). Uluslararası alan indekslerinde türkiye pazarlama yazını: bibliyometrik analizler ve nitel bir araştırma. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 27(4), 274201337-274201362.
- Wang, X., Wang, B., Liu, S., Li, H., Wang, T., ve Watada, J. (2022). Fuzzy portfolio selection based on three-way decision and cumulative prospect theory. *International Journal of Machine Learning and Cybernetics*, 13(1), 293-308.
- Zhao, M., ve Ye, N. (2024). High-Dimensional Ensemble Learning Classification: An Ensemble Learning Classification Algorithm Based on High-Dimensional Feature Space Reconstruction. *Applied Sciences*, 14(5), 1956.

Comparison of Healthcare System Performance in EU Candidate Countries Using an Entropy and TOPSIS-Based Multi-Criteria Decision-Making Approach: Türkiye's Position

Hamza Doğan¹

Abstract

This study employs a multi-criteria decision-making (MCDM) approach based on the Entropy and TOPSIS methods to objectively evaluate the relative performance of the healthcare systems of nine European Union candidate and potential candidate countries. The analysis includes Türkiye, Albania, Montenegro, Serbia, North Macedonia, Bosnia and Herzegovina, Moldova, Georgia, and Ukraine.

The performance comparison is based on six key criteria: life expectancy at birth, infant mortality rate, number of physicians per capita, number of hospital beds per capita, health expenditure as a percentage of Gross Domestic Product (GDP), and Diphtheria-Tetanus-Pertussis (DTP3) vaccination coverage rate. The objective weighting of the criteria was determined using the Entropy method, which measures uncertainty. Subsequently, the performance ranking of the countries was established using the TOPSIS technique, which assesses alternatives based on their relative closeness to the ideal solution.

According to the findings, Montenegro, North Macedonia, and Serbia stand out as the countries with the highest-performing healthcare systems. In contrast, Türkiye ranks as the second-lowest performing country, just above Moldova. These results highlight significant improvement needs in Türkiye's healthcare system, particularly in service quality and human resources. The study provides a valuable contribution to the development of evidence-based recommendations for restructuring health policies in these countries.

1 Asst. Prof. Dr., Dicle University, Faculty of Economics and Administrative Sciences, Department of Health Management, hamza.dogan@dicle.edu.tr, ORCID:0000-0002-4713-8731

1. Introduction

In the 21st century, evaluating the performance of health systems requires a multidimensional approach that extends beyond merely health outcomes. According to the World Health Organization (WHO), the assessment of health systems should be based on the core functions such as governance, financing, and service delivery, as well as the extent to which these functions achieve intermediate and final goals like accessibility, efficiency, fair financing, and quality of care (Papanicolas et al. 2022). In this context, the success level of health systems is associated with their ability to improve the overall health of the population, ensure timely and effective access to services, promote equitable distribution among individuals, and utilize available resources efficiently.

Therefore, evaluating the performance of health systems from a holistic perspective is particularly important in countries undergoing structural transformation, such as candidate countries for European Union (EU) membership. Indeed, Sığırlı et al. (2006), using multidimensional scaling analysis, demonstrated that Türkiye lags behind most EU countries in terms of key health indicators (life expectancy at birth, child mortality rates) and the ratio of health expenditures to GDP. These findings further underscore the significance of conducting comparative analyses of health systems in candidate countries for policymakers.

Comparing health systems across countries enables policymakers to make informed decisions aimed at strengthening their own systems. The HiT (Health Systems in Transition) profiles developed by the European Observatory systematically describe how systems are organized, how funds are allocated, and what types of services are provided using a common template. These profiles allow for an evaluation of countries' health systems both within their historical context and in comparison with other European systems (Rechel et al. 2016).

Over the past two decades, health systems in Southeastern Europe have undergone comprehensive reform processes driven by the pursuit of more effective and efficient service delivery, efforts to ensure the sustainability of health expenditures, financial pressures stemming from technological advancements and an aging population, and the transformative pressures of transitioning from socialist systems to market economies (Bartlett, Bozikov, and Rechel 2012). This historical context reinforces the necessity of comparatively evaluating the performance of health systems in these countries, both from a scientific and structural perspective.

This study aims to systematically evaluate the effectiveness of healthcare services, resource allocation, and investments by conducting a comprehensive analysis of the health systems of Türkiye and other European Union (EU) candidate and potential candidate countries. Using the integrated application of multi-criteria decision-making methods—Entropy and TOPSIS—the study compares health indicators across countries and assesses health system performance within a multidimensional framework. The combined use of these methods provides a more robust and objective analytical foundation while revealing structural differences among countries in greater detail.

At the core of this research lies data obtained from reliable international sources such as the World Bank, with methodological rigor prioritized in the construction of the decision matrix. The six key performance indicators selected for evaluating health systems offer a multidimensional comparison by linking health outcomes with health resources and investments. Life expectancy at birth, which reflects the expected health status of individuals, is considered a critical indicator for assessing a country's overall health conditions. Infant mortality rate, which indicates access to and quality of healthcare services, demonstrates the extent to which populations benefit from essential health services. The number of physicians per 1,000 people reveals the density of health personnel and the capacity for healthcare access, while the number of hospital beds per 1,000 people indicates a country's healthcare infrastructure and service delivery capacity. The share of health expenditures in GDP provides significant insights into the budgeting of health policies by measuring countries' financial investments in the health sector. Lastly, the DTP3 immunization rate reflects the importance placed on preventive healthcare and the effectiveness of basic childhood immunizations in a given country.

These indicators enable cross-country comparisons by objectively evaluating the performance of health systems through data-driven metrics. In the indicator selection process, factors such as data accessibility, international comparability, alignment with EU policies, and the requirements for a structural assessment of health systems were taken into account. The findings of this study will identify Türkiye's position among EU candidate countries, highlighting both the strengths and areas in need of improvement within its health system. In this regard, the research aims to establish an evidence-based framework for the restructuring of health policies and to provide valuable insights for policymakers in enhancing the effectiveness of health investments, improving access to services, and planning reform processes.

Accordingly, the study is structured into five main sections. The introduction presents the conceptual framework and objectives of the research, along with the relevant theoretical background. The literature review section examines existing studies on the evaluation of health systems and discusses findings related to the application of the Entropy and TOPSIS methods in the healthcare field. The methodology section provides a detailed explanation of the implementation steps of these techniques, including data processing procedures and methodological approaches. In the application section, the data collected within the scope of the research are presented, and Türkiye's health system is evaluated comparatively with other EU candidate countries. The conclusion and recommendations section discusses the findings of the study and offers concrete suggestions for restructuring health policies.

The findings clearly reveal Türkiye's position among EU candidate countries by identifying the strengths and areas for improvement in its health system. The study offers a scientific foundation for enhancing health policies and delivers valuable insights for increasing the sustainability and effectiveness of health systems through its methodological approaches and comprehensive data analysis.

2. Literature Review

The health systems of EU candidate countries lag behind the EU average in terms of financial sustainability, service quality, and health outcomes. A comparative study based on EUROSTAT data found that per capita health spending in candidate countries is approximately one-third of the EU average, while infant mortality rates are three times higher. Furthermore, Türkiye has the lowest health expenditure as a share of GDP and ranks lowest in terms of health workforce density (Šantrić Milićević et al. 2020). A report published by the OECD and European Commission (2016) emphasizes significant structural inequalities in the efficiency, accessibility, and sustainability of health systems across EU countries. Notably, there is a life expectancy gap of up to eight years between Western and Central/Eastern European countries, attributed to disparities in access to and quality of healthcare services. The fact that over 550,000 people die prematurely each year due to chronic diseases—resulting in a loss of 3.4 million productive life years—highlights the serious consequences of these inequalities (OECD and EU 2016). Mackenbach and McKee (2013) also note substantial differences in health policy implementation and outcomes across European countries, emphasizing the effectiveness of Northern European countries, while Eastern European nations generally show weak performance. Key

determinants of these performance differences include national income, government effectiveness, and societal values.

The evaluation and comparison of health system performance is critically important for policymakers. The European Union (EU) institutionalized this process, which began with the signing of the Tallinn Charter in 2008, through the establishment of the Health Systems Performance Assessment (HSPA) expert group in 2014. Initially focused on sharing best practices, this group has gradually undertaken concrete evaluation studies in areas such as quality of care, integrated service delivery, and primary health care. The group's success lies in its participatory approach, flexible attitude, and effective integration of findings into policymaking (Paoli et al. 2019). The role of primary health care in these evaluations is particularly significant. Barbazza et al. (2019) emphasize that measuring the performance of primary health care in the European region is critical for achieving the goals of health system sustainability and universal health coverage. For this purpose, they developed the comprehensive PHC-IMPACT performance assessment framework, which includes 139 indicators across various domains such as structural characteristics, service delivery models, and health outcomes. Following the COVID-19 pandemic, the concept of “resilience” has come to the forefront. Vainieri, Caputo, and Vinci (2024) assessed the resilience of health systems in EU countries using six key indicators: addressing unmet health needs, protecting vulnerable groups, resource availability and efficiency, trained personnel, digital health, and strengthening primary care. They emphasized that resilience is not only about crisis management but also a fundamental component of sustainable performance.

The multidimensional nature of health systems necessitates the use of composite indices and multi-criteria decision-making (MCDM) methods in performance evaluations. In the literature, multivariate techniques such as factor analysis, cluster analysis, Data Envelopment Analysis (DEA), and Malmquist Total Factor Productivity (TFP) are widely used. For instance, within the EURO-HEALTHY project, numerous indicators were employed based on the core functions defined by the World Health Organization to classify European countries, highlighting similarities and differences in service delivery, financing, and resource generation (Ferreira et al. 2018). Konca and Demirci (2019), in their analysis using the Malmquist TFP method for G20 countries, noted that Türkiye demonstrated a remarkable increase in productivity between 2000 and 2015, attributed to improvements in technical efficiency and technological change, which may be linked to health reforms. Similarly, Teleş, Cakmak, and Konca (2018), in their DEA study on EU-cycle countries, found that Türkiye used its resources relatively more

efficiently and was frequently referenced. They emphasized that evaluations should focus more on the effective use of resources rather than merely their availability.

Multi-criteria decision-making (MCDM) methods such as Entropy and TOPSIS are increasingly preferred in the evaluation of health systems due to their capacity to assign objective weights to health indicators and provide comprehensive, impartial analyses for cross-country comparisons. Despite methodological challenges such as indicator selection, weighting, and data quality, these methods facilitate systematic comparisons by integrating diverse indicators related to health expenditures, human resources, and service delivery (Popescu et al. 2018). At the EU level, the 23 headline indicators proposed for comparing the performance of health systems have been found useful by policymakers for general guidance. However, more detailed and explanatory indicators are often preferred in data-driven decision-making processes. Furthermore, the limited adaptability of these indicators to national contexts and the lack of appropriate benchmarks for comparison are among the main barriers to their widespread and effective use (Perić et al. 2020). In this context, MCDM methods such as Entropy and TOPSIS offer a valuable methodological alternative for evaluating health systems in a more objective and comparable manner.

Studies using the TOPSIS method in the context of the European Union provide significant insights into the positioning of candidate countries and Türkiye. Türkoğlu (2018) analyzed 26 European countries for the 2010–2014 period using TOPSIS based on indicators such as life expectancy, health expenditures (as a percentage of GDP and per capita), number of hospital beds, fertility rate, infant mortality, and number of physicians. Countries like Norway and Luxembourg ranked at the top, while Slovakia, Serbia, Latvia, and Türkiye consistently appeared at the bottom of the rankings. Kasman, Kasman, and Gökalp (2019) investigated technical efficiency and productivity convergence—specifically β (beta) and σ (sigma) convergence—in the health systems of EU member and candidate countries between 1995 and 2012. They found that countries (including Türkiye) have converged over time, particularly in terms of life expectancy and infant mortality rates, suggesting that candidate countries are progressively aligning with EU standards.

Multi-criteria decision-making (MCDM) studies with a specific focus on Türkiye's performance generally indicate that the country ranks low among OECD countries. Şahin and Cezlan (2023), using criteria weighted by the Analytic Hierarchy Process (AHP) and ranked via the TOPSIS method,

placed Türkiye 29th out of 29 OECD countries, while countries following Beveridge and Bismarck models occupied top positions. Özsarı and Boz (2019) evaluated the health status of 34 OECD countries using TOPSIS and found Japan to have the highest performance, with Türkiye at the lowest rank. Demir Uslu (2021) compared OECD countries using eight health resource indicators from 2019 through TOPSIS and VIKOR methods, ranking Türkiye 25th out of 26 countries in both methods, particularly noting its lag in medical technology. Değirmenci and Yakıcı Ayan (2020), using a combination of Fuzzy Clustering Analysis and TOPSIS, assessed OECD countries based on health resources (e.g., pharmaceutical expenditures, number of doctors, nurses, and beds). They placed Türkiye in the same cluster as Poland, Mexico, and South Korea but in the lowest performance group according to TOPSIS, emphasizing the country's shortage of healthcare personnel. Lastly, Demir Uslu et al. (2023) used TOPSIS to rank OECD countries based on financial indicators such as total, public, and private health expenditures per capita, and health expenditure as a share of GDP. The study ranked the U.S., Switzerland, and Norway at the top, while Türkiye was at the bottom of 35 countries, highlighting its lag relative to economic development and the OECD average.

The composition and structure of health expenditures also provide critical insights for comparative analyses. Boz and Sur (2016), using WHO indicators and Multidimensional Scaling (MDS), analyzed EU member and candidate countries and classified them into two main groups. They found that Türkiye, in terms of health expenditures, was positioned similarly to Poland and Romania, while differing significantly from countries like the Netherlands and Luxembourg. This finding highlights the need to analyze health systems not only by financial magnitude but also by expenditure composition and the public-private balance. Kavas and Ertaş (2023) analyzed 31 OECD countries using the TOPSIS method based on health, economic, and financial indicators. Their study included core health metrics such as life expectancy, health expenditures, and the number of doctors, as well as macro indicators like economic globalization, financial freedom, and GDP per capita. The weights of the criteria were determined according to the principle of intra-group equality and expert opinions. In this multi-criteria decision-making analysis, Türkiye ranked 21st. Such methods enable multidimensional and comparative evaluations of national health system performance and contribute significantly to the policy development process.

The unique contribution of this study to the literature lies in its holistic and objective analysis of the performance of health systems in European Union (EU) candidate and potential candidate countries using Entropy and

TOPSIS-based multi-criteria decision-making (MCDM) approaches. While similar analyses exist in the context of EU member and OECD countries, the literature reveals a notable lack of comprehensive and systematic assessments focused specifically on EU candidate countries. In this regard, the study not only determines Türkiye's comparative position among other candidate countries but also offers decision-makers a data-driven opportunity to analyze the strengths and weaknesses of health systems. By assigning objective weights to indicators through the Entropy method and ranking countries based on their proximity to the ideal solution using TOPSIS, the study stands out methodologically. As such, it contributes to the development of evidence-based health reform recommendations for policymakers.

3. Methodology

3.1. Multi-Criteria Decision-Making Methods and Weighting Approaches

Multi-Criteria Decision-Making (MCDM) methods are analytical tools that enable the systematic evaluation of multiple, and often conflicting, criteria simultaneously. These methods allow for the holistic analysis of both objective and subjective criteria in the decision-making process. The methods used vary depending on whether the criterion weights are known or unknown. Moreover, the literature offers a variety of techniques for determining and comparing criterion weights (Ediz, Altan, and Taşdemir 2025).

3.1.1. Methods Used When Criterion Weights Are Known

In cases where the weights of decision criteria are predetermined, the following methods are commonly used:

DEMATEL (Decision-Making Trial and Evaluation Laboratory): This method analyzes causal relationships among decision criteria to construct a structural influence matrix (Fontela and Gabus 1976).

TOPSIS (Technique for Order Preference by Similarity to Ideal Solution): This method evaluates alternatives based on their distances from the ideal and negative-ideal solutions, identifying the one closest to the ideal as the most appropriate option (Hwang and Yoon 1981).

PROMETHEE (Preference Ranking Organization Method for Enrichment Evaluation): A method in which alternatives are assessed in pairs according to preference functions and ranked using net flow values (Brans and Vincke 1985).

ELECTRE (ELimination Et Choix Traduisant la REalité): A method that makes selections based on dominance relations and threshold values between alternatives, incorporating exclusion relationships in the elimination process (Roy 1991).

MAUT (Multi-Attribute Utility Theory): An MCDM method that calculates an overall utility score for each alternative by aggregating weighted utility functions (Keeney and Raiffa 1993).

VIKOR (VlseKriterijumska Optimizacija I Kompromisno Resenje): A method that balances group utility and individual regret measures to determine a compromise solution close to the ideal in multi-criteria problems (Opricovic and Tzeng 2004).

MOORA (Multi-Objective Optimization by Ratio Analysis): An MCDM approach that separately considers benefit and cost criteria and evaluates alternatives using ratio analysis (Brauwers and Zavadskas 2006).

ARAS (Additive Ratio Assessment): A method that ranks alternatives based on total performance scores normalized and weighted relative to an ideal solution (Zavadskas and Turskis 2010).

3.1.2. Methods Used When Criterion Weights Are Unknown

When the weights of decision criteria are not predetermined, the following methods are frequently employed:

Borda Count Method: An approach in which alternatives are ranked by each decision-maker and scored based on their position, with the alternative receiving the highest total score being selected (Borda 1781).

Condorcet Method: A method that involves pairwise comparisons between all alternatives, selecting the one that wins the most comparisons (i.e., preferred by the majority) as the overall winner (Condorcet 1785).

Copeland Method: This approach calculates the difference between the number of wins and losses each alternative has in pairwise comparisons, selecting the one with the highest net score (Copeland 1951; Henriot 1985).

Lexicographic Method: A decision-making approach where criteria are ordered by importance. The alternative with the best performance in the most important criterion is selected, and in the case of a tie, the next most important criterion is considered (Fishburn 1974).

3.1.3. Methods for Determining Criterion Weights

The following methods are commonly used for assigning weights to decision criteria:

Entropy Method: An objective weighting method based on the information content (entropy) of criteria, assigning higher weights to those with greater variability (Shannon 1948).

AHP (Analytic Hierarchy Process): A widely used MCDM method in which criteria are evaluated via pairwise comparisons, with a consistency ratio to assess the reliability of comparisons and eigenvalue calculation for determining weights (Saaty 1980).

CRITIC (Criteria Importance Through Intercriteria Correlation): An objective method that considers both the standard deviation (information content) of each criterion and its correlation with others to calculate weights (Diakoulaki, Mavrotas, and Papayannakis 1995).

SWARA (Step-Wise Weight Assessment Ratio Analysis): A step-by-step method where decision-makers rank criteria by importance and assess each one's relative importance compared to the previous criterion (Keršulienė, Zavadskas, and Turskis 2010).

BWM (Best-Worst Method): A method in which the best and worst criteria are identified, and all criteria are compared against them to calculate weights (Rezaei 2015).

FUCOM (Full Consistency Method): A method that determines weights using a minimal number of pairwise comparisons, ensuring high consistency in the process (Pamučar, Stević, and Sremac 2018).

3.2. Entropy Method

Entropy method is a technique that enables the objective determination of criterion weights in multi-criteria decision-making (MCDM) processes. This approach is based on the concept of entropy from information theory, which measures the level of uncertainty. As the amount of information contained in a criterion increases, its significance in the decision-making process—and thus its weight—also increases. The Entropy method, whose steps are outlined below, offers a more impartial weighting mechanism by minimizing potential biases stemming from the subjective assessments of decision-makers (Wang and Lee 2009; Shannon 1948; Zeleny 1982; Wu and Lin 2012).

Step 1: Construct the Decision Matrix of Raw Data

The original decision matrix, in which each alternative is evaluated against various criteria, is defined as follows:

$$X = [x_{ij}]_{n \times m} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix} \quad \begin{matrix} i = 1, 2, \dots, n \\ j = 1, 2, \dots, m \end{matrix}$$

Here, n denotes the number of alternatives, and m represents the number of criteria. The term x_{ij} indicates the value assigned to the i^{th} alternative with respect to the j^{th} criterion.

Step 2: Normalize the Decision Matrix

Due to the fact that criteria may be expressed in different units, the decision matrix must be normalized to ensure comparability. The normalized value r_{ij} is calculated as the ratio of the corresponding cell value to the total of its column:

$$r_{ij} = \frac{x_{ij}}{\sum_{i=1}^n x_{ij}}$$

Step 3: Calculate the Entropy Values of the Criteria

For each criterion, the entropy value e_j is calculated using the following formula:

$$e_j = -k \times \sum_{i=1}^n r_{ij} \times \ln(r_{ij})$$

Here, $k = \frac{1}{\ln(n)}$ is a constant multiplier that ensures the entropy value e_j falls within the range $0 \leq e_j \leq 1$.

Step 4: Calculate the Weights of the Criteria

The deviation d_j in the information content of each criterion and the corresponding weight w_j are determined as follows:

$$d_j = 1 - e_j$$

$$w_j = \frac{d_j}{\sum_{i=1}^m d_j}$$

With this method, criteria with lower information diversity (entropy)—meaning they contribute more significantly to the decision-making process—are assigned higher weights.

3.3. TOPSIS Method

The TOPSIS method is a widely used technique for ranking alternatives in multi-criteria decision-making problems. It is based on the principle that the chosen alternative should be closest to the ideal solution and farthest from the negative ideal solution. The steps of the TOPSIS method, outlined below, take into account the decision-maker's preferences and the weights of the criteria to rank the alternatives accordingly (Behzadian et al. 2012; Hwang and Yoon 1981).

Step 1: Constructing the Decision Matrix

The decision matrix X , consisting of n alternatives and m criteria, is formed as follows:

$$X = [x_{ij}]_{n \times m} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \quad \begin{matrix} i = 1, 2, \dots, n \\ j = 1, 2, \dots, m \end{matrix}$$

Here, x_{ij} represents the performance of the i^{th} alternative with respect to the j^{th} criterion.

Step 2: Normalization

The decision matrix is normalized using the vector normalization method. The normalized value r_{ij} is calculated as:

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^n x_{ij}^2}} \quad \begin{matrix} i = 1, 2, \dots, n \\ j = 1, 2, \dots, m \end{matrix}$$

Step 3: Construct the Weighted Normalized Decision Matrix

$$v_{ij} = w_j \cdot r_{ij}$$

$$V = [v_{ij}]_{n \times m} = \begin{bmatrix} v_{11} & v_{12} & \cdots & v_{1m} \\ v_{21} & v_{22} & \cdots & v_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ v_{n1} & v_{n2} & \cdots & v_{nm} \end{bmatrix} = \begin{bmatrix} w_1 r_{11} & w_2 r_{12} & \cdots & w_m r_{1m} \\ w_1 r_{21} & w_2 r_{22} & \cdots & w_m r_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ w_1 r_{n1} & w_2 r_{n2} & \cdots & w_m r_{nm} \end{bmatrix} \quad \begin{matrix} i = 1, 2, \dots, n \\ j = 1, 2, \dots, m \end{matrix}$$

Here, w_j represents the weight of the j^{th} criterion, and it must satisfy the condition:

$$\sum_{j=1}^m w_j = 1$$

Step 4: Determining the Ideal and Negative-Ideal Solutions

The ideal solution A^+ is formed by selecting the maximum values for benefit criteria and the minimum values for cost criteria. Conversely, the negative-ideal solution A^- is defined by selecting the minimum values for benefit criteria and the maximum values for cost criteria.

$$A^+ = \left\{ \max_i v_{ij} \ (j \in \text{benefit}), \min_i v_{ij} \ (j \in \text{cost}) \right\}$$

Step 5: Calculate the Separation Measures

The distances of each alternative from the ideal and negative-ideal solutions are calculated using the Euclidean distance metric:

$$S_i^+ = \sqrt{\sum_{j=1}^m (v_{ij} - v_j^+)^2}$$

$$S_i^- = \sqrt{\sum_{j=1}^m (v_{ij} - v_j^-)^2}$$

Step 6: Calculate the Relative Closeness to the Ideal Solution

The relative closeness C_i of each alternative to the ideal solution is calculated using the following formula:

$$C_i = \frac{S_i^-}{S_i^+ + S_i^-} \ , \ 0 \leq C_i \leq 1$$

Step 7: Ranking

The alternatives are ranked in descending order based on their C_i values. The alternative with the highest C_i value is considered the most preferred option:

$C_i \uparrow \Rightarrow$ Higher preference

This final step provides a clear and data-driven ranking of all alternatives, guiding decision-makers toward the optimal choice.

4. Application

This study was conducted to compare the relative performance of the health systems of nine countries that are candidates or potential candidates for European Union membership. The countries included in the analysis are Türkiye, Albania, Montenegro, Serbia, North Macedonia, Bosnia and Herzegovina, Moldova, Georgia, and Ukraine. These countries were selected because they are undergoing health sector reforms within the framework of the EU's enlargement policy and because their health systems exhibit structurally distinct characteristics. Kosovo was excluded from the analysis due to the unavailability of up-to-date and reliable data for the relevant criteria.

In the decision-making process, six key performance criteria were identified to represent health systems in a multidimensional manner. The criteria used in the evaluation include: life expectancy at birth (LEB), infant mortality rate (IMR), number of physicians per 1,000 people (PhysD), number of hospital beds per 1,000 people (HospBeds), current health expenditure as a percentage of GDP (CHE%GDP), and DTP3 immunization coverage (DTP3). The selection of these indicators was influenced by their frequent use in the literature (e.g., Türkoğlu, 2018; Demirci, Konca, and İlgin, 2020) and their ability to enable a comprehensive assessment that encompasses health system outputs, resources, and investments. Moreover, these indicators were chosen based on the most recent data available from the World Bank databases. Although the data may not pertain to the exact same year for all countries, a complete and comparable decision matrix was constructed in accordance with the principle of comparability.

After constructing the decision matrix, the Entropy method was employed in the criterion weighting stage. The Entropy method enables the calculation of objective weights by analyzing the level of uncertainty among criteria, without requiring input or judgment from the decision-maker. Unlike subjective methods such as the Analytic Hierarchy Process, the Entropy method assigns weights directly based on the variability of the data, which is why it is widely used in multi-criteria decision-making applications.

After the criterion weights presented in Table 1 were determined using the Entropy method, the TOPSIS method was applied based on these

weights to calculate the relative health performance of the countries. This method identifies the best alternative as the one closest to the ideal solution and farthest from the negative-ideal solution. Accordingly:

- First, the decision matrix was normalized (Table 2),
- Then, the normalized values were multiplied by the weights obtained through the Entropy method to form the weighted normalized matrix (Table 3),
- Next, for each criterion, the positive ideal (best) and negative ideal (worst) values were determined (Table 4),
- The distances of each country from these ideal points were calculated, and the closeness coefficients (C_i) were computed using the resulting values (Table 5),
- Finally, the countries' overall health system performance levels were ranked based on their C_i values, revealing their relative health performance (Table 6).

Table 1. Criterion Weights Obtained Using the Entropy Method

LEB	IMR	PhysD	HospBeds	CHE%GDP	DTP3
0,002	0,474	0,197	0,179	0,133	0,015

Table 2. Normalization of the Decision Matrix

Countries	LEB	IMR	PhysD	HospBeds	CHE%GDP	DTP3
Türkiye	0.33880	0.39930	0.23000	0.22320	0.15550	0.37590
Albania	0.34950	0.36420	0.19930	0.21720	0.25760	0.36830
Montenegro	0.34070	0.09210	0.29150	0.28440	0.45890	0.30760
Serbia	0.33470	0.19750	0.30110	0.39940	0.40600	0.35320
N. Macedonia	0.33070	0.12290	0.31380	0.31500	0.32020	0.32660
Bosnia-Herzegovina	0.34180	0.23260	0.24590	0.17470	0.36650	0.27720
Moldova	0.31260	0.59240	0.34450	0.42250	0.29250	0.33040
Georgia	0.32710	0.35100	0.59470	0.36880	0.30470	0.33420
Ukraine	0.32240	0.34230	0.31700	0.46730	0.34460	0.31520

Table 3. Weighted Normalized Decision Matrix

Countries	LEB	IMR	PhysD	HospBeds	CHE%GDP	DTP3
Türkiye	0.00068	0.18943	0.04536	0.03986	0.02070	0.00556
Albania	0.00070	0.17277	0.03930	0.03880	0.03429	0.00545
Montenegro	0.00068	0.04371	0.05749	0.05080	0.06108	0.00455
Serbia	0.00067	0.09367	0.05937	0.07133	0.05404	0.00523
N. Macedonia	0.00066	0.05829	0.06188	0.05626	0.04262	0.00483
Bosnia-Herzegovina	0.00068	0.11033	0.04850	0.03120	0.04878	0.00410
Moldova	0.00063	0.28102	0.06794	0.07546	0.03893	0.00489
Georgia	0.00065	0.16653	0.11727	0.06586	0.04055	0.00495
Ukraine	0.00064	0.16237	0.06250	0.08346	0.04587	0.00466

Table 4. Positive and Negative Ideal Solutions

Ülke	LEB	IMR	PhysD	HospBeds	CHE%GDP	DTP3
Positive A ⁺	0.00070	0.04371	0.11727	0.08346	0.06108	0.00556
Negative A ⁻	0.00063	0.28102	0.03930	0.03120	0.02070	0.00410

Table 5. Distances of Countries to Positive and Negative Ideals and Closeness Coefficient (C_i)

Countries	S_i^+	S_i^-	C_i
Türkiye	0.17300	0.09200	0.34800
Albania	0.16000	0.10900	0.40700
Montenegro	0.06800	0.24200	0.78000
Serbia	0.07800	0.19600	0.71500
N. Macedonia	0.06600	0.22600	0.77400
Bosnia-Herzegovina	0.11000	0.17300	0.61200
Moldova	0.24400	0.05600	0.18600
Georgia	0.12600	0.14400	0.53400
Ukraine	0.13200	0.13400	0.50500

Table 6. Ranking of Countries Based on Closeness Coefficient

Rank	Countries	Closeness Coefficient (C_i)
1	Montenegro	0.780
2	N. Macedonia	0.774
3	Serbia	0.715
4	Bosnia-Herzegovina	0.612
5	Georgia	0.534
6	Ukraine	0.505
7	Albania	0.407
8	Türkiye	0.348
9	Moldova	0.186

5. Conclusion and Recommendations

The integrated analysis model developed using the Entropy and TOPSIS methods has provided a multidimensional and objective evaluation of the health system performances of European Union candidate countries. In the resulting ranking, Montenegro, North Macedonia, and Serbia occupied the top three positions, while Türkiye was ranked eighth, and Moldova demonstrated the lowest performance. Türkiye’s low ranking highlights significant shortcomings in terms of health infrastructure, service delivery capacity, and resource management. Particularly, low physician and hospital bed density, limited health expenditures, and a high infant mortality rate are identified as key weaknesses. On the other hand, Türkiye’s high DTP3 immunization coverage and relatively favorable life expectancy compared to some other countries are considered strengths.

To close the performance gap in Türkiye’s health system, it is essential to first ensure the effective planning and management of resources. Health workforce recruitment should be increased and medical education capacity expanded to balance the growing workload. Infrastructure deficiencies in rural areas must be addressed, and regional inequalities in access to healthcare should be reduced. Financially, the share of health expenditures in GDP should be increased, with a focus on directing resources toward primary care and preventive services. To lower infant mortality rates, the quality of perinatal care must be improved, and digital monitoring systems should be more widely implemented. In the context of EU harmonization, the integration of digital health systems should be accelerated, and resilience indicators should be aligned with EU standards. Additionally, cooperation

with high-performing countries such as Montenegro and North Macedonia should be pursued to develop joint projects in areas such as health technology and workforce training.

The primary limitation of this study stems from the lack of complete data synchronization across countries, which resulted in some indicators reflecting different years. Additionally, the limited number of criteria included in the model and the exclusion of qualitative data—such as quality of healthcare services or patient satisfaction—have narrowed the scope of the evaluation. Future research should consider integrating environmental and socioeconomic factors that influence health systems, such as air pollution and income inequality. To test the model's robustness under uncertainty, sensitivity analyses using methods like Fuzzy TOPSIS or Grey Relational Analysis may also be employed. Particularly in the post-COVID-19 era, examining the resilience performance of health systems within the same methodological framework would contribute meaningfully to the literature. In conclusion, this study objectively identifies Türkiye's position among EU candidate countries and offers a scientific foundation for decision-makers in restructuring health policies, planning infrastructure investments, and allocating resources.

References

- Barbazzaz, E., Kringos, D., Kruse, I., Klazinga, N. S., and Tello, J. E. 2019. Creating performance intelligence for primary health care strengthening in Europe. *BMC Health Services Research* 19 (1): 1006. <https://doi.org/10.1186/s12913-019-4853-z>.
- Bartlett, W., Bozиков, J., and Rechel, B. 2012. *Health reforms in south-east Europe*: Springer.
- Behzadian, M., Khanmohammadi Otaghsara, S., Yazdani, M., and Ignatius, J. 2012. A state-of-the-art survey of TOPSIS applications. *Expert Systems with Applications* 39 (17): 13051-13069. <https://doi.org/https://doi.org/10.1016/j.eswa.2012.05.056>.
- Borda, J. 1781. *M'emoire sur les' elections au scrutin*. Histoire de l'Acad'emie Royale des Sciences.
- Boz, C., and Sur, H. 2016. Avrupa Birliği Üyesi ve Aday Ülkelerin Sağlık Harcamaları Açısından Benzerlik ve Farklılık Analizi. *Sosyal Güvence* 0 (9): 23-46.
- Brans, J. P., and Vincke, P. 1985. Note—A Preference Ranking Organisation Method. *Management Science* 31 (6): 647-656. <https://doi.org/10.1287/mnsc.31.6.647>.
- Brauers, W. K., and Zavadskas, E. K. 2006. The MOORA method and its application to privatization in a transition economy. *Control cybernetics* 35 (2): 445-469.
- Condorcet, M. d. 1785. *Essai sur l'application de l'analyse à la probabilité des décisions rendues à la pluralité des voix*. Paris: Imprimerie Royale.
- Copeland, A. H. 1951. A reasonable social welfare function. University of Michigan, Seminar on Applications of Mathematics to Social Sciences.
- Demirci, Ş., Konca, M., and İlgin, G., (2020). The Impact of Health Financing on Health Systems' Performance: An Assessment for European Union and Candidate Countries. *Sosyoekonomi*, 28(43), 229-242.
- Değirmenci, N., and Yakıcı Ayan, T. 2020. OECD Ülkelerinin Sağlık Göstergeleri Açısından Bulanık Kümeleme Analizi ve TOPSIS Yöntemine Göre Değerlendirilmesi. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* 38 (2): 229-241.
- Demir Uslu, Y. 2021. TOPSIS ve VIKOR yöntemleri kullanılarak OECD ülkelerinin sağlık kaynağı göstergeleri açısından karşılaştırılması. *OPUS International Journal of Society Researches* 18 (44): 7668-7692.
- Demir Uslu, Y., Şahin, K., Aygün, S., and Tuna, M. 2023. OECD ülkeleri ve Türkiye'nin sağlık harcamalarının TOPSIS yöntemi ile incelenmesi. *Gümüşhane Üniversitesi Sağlık Bilimleri Dergisi* 12 (2): 386-395.

- Diakoulaki, D., Mavrotas, G., and Papayannakis, L. 1995. Determining objective weights in multiple criteria problems: The critic method. *Computers & Operations Research* 22 (7): 763-770. [https://doi.org/https://doi.org/10.1016/0305-0548\(94\)00059-H](https://doi.org/https://doi.org/10.1016/0305-0548(94)00059-H).
- Ediz, A., Altan, Ş., and Taşdemir, S. 2025. Hava Savunma Sistemlerinin Performansının Entropi Ağırlıklı TOPSİS Yöntemi İle Değerlendirilmesi. *Savunma Bilimleri Dergisi* 21 (1): 13-32. <https://doi.org/10.17134/khosbd.1452715>.
- Ferreira, P., Tavares, A., Quintal, C., and Santana, P. 2018. EU health systems classification: a new proposal from EURO-HEALTHY. *BMC Health Services Research* 18. <https://doi.org/10.1186/s12913-018-3323-3>.
- Fishburn, P. C. 1974. Lexicographic orders, utilities and decision rules: A survey. *Management science* 20 (11): 1442-1471.
- Fontela, E., and Gabus, A. 1976. The DEMATEL Observer: Battelle Institute. Geneva Research Center: 56-61.
- Henriet, D. 1985. The Copeland choice function an axiomatic characterization. *Social Choice and Welfare* 2 (1): 49-63.
- Hwang, C.-L., and Yoon, K. 1981. "Methods for Multiple Attribute Decision Making." In *Multiple Attribute Decision Making: Methods and Applications A State-of-the-Art Survey*, edited by Ching-Lai Hwang and Kwan-sun Yoon, 58-191. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Kasman, S., Kasman, A., and Gökalp, G. 2019. Efficiency and productivity convergence in health care systems: Evidence from EU member countries. *METU Studies in Development* 46 (2): 227-250.
- Kavas, Y. B., and Ertaş, A. 2023. TOPSIS Yöntemi: OECD Ülkelerinin Ekonomik, Finansal ve Sağlık Göstergelerinin Değerlendirilmesi. *Dicle Üniversitesi Sosyal Bilimler Enstitüsü Dergisi* (34): 273-288.
- Keeney, R. L., and Raiffa, H. 1993. *Decisions with multiple objectives: preferences and value trade-offs*: Cambridge university press.
- Keršulienė, V., Zavadskas, E. K., and Turskis, Z. 2010. Selection of rational dispute resolution method by applying new step-wise weight assessment ratio analysis (SWARA). *Journal of Business Economics and Management* 11 (2): 243-258. <https://doi.org/10.3846/jbem.2010.12>.
- Konca, M., and Demirci, Ş. 2019. G20 ülkeleri ve Türkiye'nin sağlık sistemi performansı: Yıllara göre karşılaştırmalı bir analiz. *Anemon Muş Alparslan Üniversitesi Sosyal Bilimler Dergisi* 7 (4): 175-181.
- Mackenbach, J. P., and McKee, M. 2013. A comparative analysis of health policy performance in 43 European countries. *Eur J Public Health* 23 (2): 195-201. <https://doi.org/10.1093/eurpub/cks192>.
- OECD, and EU. 2016. *Health at a Glance: Europe 2016: State of Health in the EU Cycle*. Paris.

- Opricovic, S., and Tzeng, G.-H. 2004. Compromise solution by MCDM methods: A comparative analysis of VIKOR and TOPSIS. *European Journal of Operational Research* 156 (2): 445-455. [https://doi.org/https://doi.org/10.1016/S0377-2217\(03\)00020-1](https://doi.org/https://doi.org/10.1016/S0377-2217(03)00020-1).
- Özsarı, S. H., and Boz, C. 2019. Comparison of health status and macroeconomic indicators in Organization for Economic Cooperation and Development countries using multidimensional scaling and TOPSIS. *Sağlık Bilimleri ve Meslekleri Dergisi* 6 (3): 545-554.
- Pamučar, D., Stević, Ž., and Sremac, S. 2018. A New Model for Determining Weight Coefficients of Criteria in MCDM Models: Full Consistency Method (FUCOM). 10 (9): 393.
- Paoli, F., Schmidt, I., Wigzell, O., and Ryś, A. 2019. An EU approach to health system performance assessment: Building trust and learning from each other. *Health Policy* 123 (4): 403-407. <https://doi.org/https://doi.org/10.1016/j.healthpol.2019.02.004>.
- Papanicolas, I., Rajan, D., Karanikolos, M., Soucat, A., and Marimont, J. F. 2022. Health system performance assessment: a framework for policy analysis.
- Perić, N., Ullmann, T., Hofmarcher, M., Or, Z., and Simon, J. 2020. Is the EU ready for a generic set of indicators for health system performance? A qualitative study. *European Journal of Public Health* 30 (Supplement_5): v714.
- Popescu, M., Militaru, E., Cristescu, A., Vasilescu, M., and Matei, M. M. M. 2018. Investigating Health Systems in the European Union: Outcomes and Fiscal Sustainability. *Sustainability*. <https://doi.org/10.3390/SU10093186>.
- Rechel, B., Lessof, S., Busse, R., McKee, M., Figueras, J., Mossialos, E., and van Ginneken, E. 2016. "A Framework for Health System Comparisons: the Health Systems in Transition (HiT) Series of the European Observatory on Health Systems and Policies." In *Data and Measures in Health Services Research*, edited by Boris Sobolev, Adrian Levy and Sarah Goring, 1-18. Boston, MA: Springer US.
- Rezaei, J. 2015. Best-worst multi-criteria decision-making method. *Omega* 53: 49-57. <https://doi.org/https://doi.org/10.1016/j.omega.2014.11.009>.
- Roy, B. 1991. The outranking approach and the foundations of electre methods. *Theory and Decision* 31 (1): 49-73. <https://doi.org/10.1007/BF00134132>.
- Saaty, T. L. 1980. *The Analytical Hierarchy Process*. New York: Mc GrawHill.
- Šantrić Miličević, M., Boskovic, N., Vasic, M., Bjegovic-Mikanovic, V., Stamenkovic, Z., Todorovic, J., and Terzic-Supic, Z. 2020. What is the health-related burden of EU-Candidate Countries? A snapshot of public he-

- alth indicators. *European Journal of Public Health* 30 (Supplement_5). <https://doi.org/10.1093/eurpub/ckaa165.1000>.
- Shannon, C. E. 1948. A mathematical theory of communication. *The Bell system technical journal* 27 (3): 379-423.
- Sığırlı, D., Ediz, B., Cangür, Ş., Ercan, İ., and Kan, İ. 2006. Türkiye Ve Avrupa Birliği'ne Üye Ülkelerin Sağlık Düzeyi Ölçütlerinin Çok Boyutlu Ölçekleme Analizi İle İncelenmesi. *Journal of Turgut Ozal Medical Center* 13 (2): 81-85.
- Şahin, K., and Cezlan, E. Ç. 2023. OECD Ülkelerinin Sağlık Göstergeleri ve Sağlık Finansman Modellerinin Karşılaştırılması. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* 41 (1): 44-61. <https://doi.org/10.17065/huniibf.1096257>.
- Teleş, M., Cakmak, C., and Konca, M. 2018. Avrupa Birliği Döngüsündeki Ülkelerin Sağlık Sistemleri Performanslarının Karşılaştırılması. *Yönetim ve Ekonomi Dergisi* 25 (3): 811-835. <https://doi.org/10.18657/yonveek.381561>.
- Türkoğlu, S. P. 2018. Avrupa Ülkelerinin Sağlık Göstergelerinin TOPSIS Yöntemi ile Değerlendirilmesi. *Bolu Abant İzzet Baysal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi* 18 (1): 65-78.
- Vainieri, M., Caputo, A., and Vinci, A. 2024. Resilience dimensions in health system performance assessments, European Union. *Bull World Health Organ* 102 (7): 498-508. <https://doi.org/10.2471/blt.23.291102>.
- Wang, T.-C., and Lee, H.-D. 2009. Developing a fuzzy TOPSIS approach based on subjective weights and objective weights. *Expert Systems with Applications* 36 (5): 8980-8985. <https://doi.org/https://doi.org/10.1016/j.eswa.2008.11.035>.
- Wu, H.-Y., and Lin, H.-Y. 2012. A hybrid approach to develop an analytical model for enhancing the service quality of e-learning. *Computers & Education* 58 (4): 1318-1338. <https://doi.org/https://doi.org/10.1016/j.compedu.2011.12.025>.
- Zavadskas, E. K., and Turskis, Z. 2010. A new additive ratio assessment (ARAS) method in multicriteria decision-making. *Technological economic development of economy* 16 (2): 159-172.
- Zeleny, M. 1982. *Multiple Criteria Decision Making*, McGraw-Hill. New York.

Müşteri Memnuniyetinin Makine Öğrenmesi Teknikleriyle Değerlendirilmesi : Bibliyometrik Analiz

Sezin Öztürk Uşun¹

Mehmet Çağlar²

Özet

Bu çalışma müşteri memnuniyeti ve makine öğrenmesi alanlarında yürütülen akademik çalışmaları sistematik bir şekilde bibliyometrik analiz yöntemiyle incelemeyi amaçlamaktadır. Web of Science (WOS) veri tabanından elde edilen bilimsel yayınlar ‘müşteri memnuniyeti’ ve ‘makine öğrenmesi’ anahtar kelimeleri kullanılarak taranmıştır. İnceleme kapsamında 2025 yılına kadar olan tüm bilimsel çalışmalar dikkate alınmıştır.

Elde edilen bilimsel çalışmaların yıllara göre niceliksel dağılımı, çalışmaları yürüten kurumlar ve ülkeler, en fazla atıf alan makaleler ve sık kullanılan anahtar kelimeler detaylı bir analiz ile değerlendirilmiştir. Elde edilen bulgular neticesinde, müşteri memnuniyeti değerlendirmesi alanında makine öğrenmesi tekniklerinin kullanımının özellikle son yıllarda artış gösterdiği söylenebilmektedir.

Sınıflandırma, optimizasyon, doğal dil işleme, metin madenciliği gibi problemlerde sentiment analizi, derin öğrenme, rasgele orman, yapay sinir ağları gibi algoritmaların sıklıkla tercih edildiği tespit edilmiştir. Bu teknikler en çok müşteri şikayetlerinin sınıflandırılması, yorumların sentiment analizi ve tüketici davranışı tahmini gibi alanlarda kullanıldığı söylenebilir.

Bu çalışmada gerçekleştirilen bibliyometrik analiz ile ilgili alanın mevcut durumu kapsamlı bir şekilde ortaya konmaya çalışılmıştır. Ayrıca, gelecekte yapılacak olan araştırmalar için potansiyel yönelimleri de işaret etmektedir. Bu yönü ile çalışma hem araştırmacılar hem de uygulayıcıların veri temelli kararlar alması noktasında referans niteliği taşımaktadır.

- 1 Araştırma Görevlisi, Yıldız Teknik Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, İstanbul, Türkiye, sezin.ozturk@yildiz.edu.tr, ORCID: orcid.org/0000-0001-5005-3002
- 2 Dr. Öğretim Üyesi, Yıldız Teknik Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, İstanbul, Türkiye, mcaglar@yildiz.edu.tr, ORCID: orcid.org/0000-0002-6859-8972

1. Giriş

Müşteri memnuniyeti, bir ürün veya hizmetin beklentileri karşılayıp karşılamadığına dair tüketicinin yargısı olarak tanımlanmaktadır (Gupta & Zeithaml, 2006). Çok boyutlu bir kavram olan müşteri memnuniyeti farklı amaçlarla değerlendirilebilmektedir. Örneğin, müşteri memnuniyetinin ölçülmesi ve analiz edilmesi, bir şirketin müşteri beklentilerini ne derece karşıladığını gösteren finansal olmayan bir performans göstergesi olarak işlev görebilir (Ittner & Larcker, 1998; Neely vd., 2005; Parmenter, 2015; Akdere & Egan, 2020). Bu değerlendirme mevcut memnuniyet düzeyinin belirlenmesinin yanı sıra, iyileştirilmesi gereken hizmet noktalarının ortaya çıkarılmasına da yardımcı olmaktadır. Böylece strateji geliştirenler için etkin kaynak kullanımı sağlayarak daha hedefe yönelik iyileştirmeler yapılmasını sağlar (Mihelis vd., 2001). Özellikle rekabetin yoğun olduğu pazarlarda, mevcut müşterileri elde tutmak ve yeni müşteriler kazanmak adına önemli bir araçtır (Kotler & Armstrong, 2012; Bhat & Darzi, 2016; Aityassine, 2022; Negassa & Japee, 2023). Müşteri memnuniyetinin artırılması ile birlikte müşteri sadakatinin gelişmesi, şikâyet oranlarının düşmesi, şirket imajının güçlenmesi ve finansal performansın iyileşmesi gibi olumlu sonuçlar da ortaya çıkmaktadır (Otto vd., 2020; Hallencreutz & Parmler, 2021). Kısacası, müşteri memnuniyeti yalnızca bir memnuniyet düzeyi göstergesi değil, aynı zamanda stratejik karar alma süreçlerinde önemli bir araçtır. Bu kavramın etkin yönetimi hem müşteri bağlılığını hem de işletme performansını doğrudan etkileyen kritik bir faktördür.

Makine öğrenimi teknikleriyle müşteri memnuniyetini değerlendirmek, çeşitli sektörlerde müşteri deneyimini iyileştirmek amacıyla gelişmiş algoritmalar ve veri odaklı yöntemlerin kullanılmasını içerir. Şirketler bu teknolojileri giderek daha fazla benimsedikçe müşteri tercihleri, davranışları ve duyguları hakkında daha derin içgörüler elde edebilmektedirler. Bu sayede genel memnuniyeti artıran kişiselleştirilmiş hizmetler sunulabilmektedir (Rahman, 2024; Singh & Agrawal, 2018). Konunun önemi, işletmelerin müşterileriyle kurduğu etkileşim biçimlerini köklü bir şekilde dönüştürme potansiyelinde yatmaktadır. Bu da müşteri sadakati ve elde tutma oranlarının artmasına katkı sağlamaktadır (Singh vd., 2020). Genel olarak makine öğrenimiyle müşteri memnuniyetinin değerlendirilmesi yalnızca müşteri ihtiyaçlarının daha iyi anlaşılmasını sağlamakla kalmaz, aynı zamanda iş stratejilerinde önemli bir dönüşüm yaratarak operasyonel verimliliği de artırır (Badhan vd., 2022; Wahab vd., 2024).

Bu bağlamda müşteri memnuniyeti ve makine öğrenmesi uygulamaları üzerine yürütülen bilimsel çalışmaları sistematik bir şekilde inceleyerek

mevcut literatürün yapısını ve literatürdeki boşlukları ortaya koymak amaçlanmaktadır. Bibliyometrik analiz aracılığıyla yapılan bu değerlendirme ile söz konusu alandaki bilimsel üretimin eğilimini gözler önüne sermiştir. Hizmet sektörü için oldukça kritik bir konu olan müşteri memnuniyetinin günümüzün veri odaklı yaklaşımları ile nasıl değerlendirildiğini gözlemek gelecek çalışmalar için önem arz etmektedir. Ayrıca makine öğrenmesi tekniklerinin müşteri deneyimini analiz etmede artan rolü göz önünde bulundurulduğunda bu çalışma ile alanın mevcut durumuna ilişkin bütüncül bir bakış sunulmuştur.

2. Yöntem


Bibliyometrik analiz, WoS veya Scopus veri tabanı olsun, akademik yayınların çıktıları üzerinde belirli bir alandaki evrensel araştırma eğilimlerini anlamlandırmak için bir tür araştırma yaklaşımıdır (Alsharif v.d., 2020).

Bu çalışma, makine öğrenimi algoritmalarının müşteri memnuniyetiyle ilgili akademik araştırmalarda nasıl kullanıldığını incelemek için bibliyometrik bir analiz yürütmektedir. Bu amaçla, 30 Mayıs 2025'te Web of Science (WoS) veritabanında “tüm alanlar” kategorisinde “müşteri memnuniyeti” ve “makine öğrenimi” anahtar sözcükleri kullanılarak bir arama yapılmıştır. Yayın başlangıç tarihiyle ilgili herhangi bir kısıtlama uygulanmamıştır. Sonuç olarak, 564 ilgili çalışma belirlenmiş ve veri seti daha sonra analiz için dışa aktarılmıştır. Tüm veri seti bibliyometrik analiz teknikleri kullanılarak incelenmiştir. Bu amaçla, Aria ve Cuccurullo (2017) tarafından geliştirilen Bibliometrix paketinin bir parçası olan Biblioshiny arayüzü RStudio ortamında kullanılmıştır.

3. Analiz ve Sonuçlar

Bu bölümde, WoS veri tabanından alınan 564 çalışmadan oluşan veri setindeki çalışmalar üzerinde bibliyometrik analiz gerçekleştirilmiştir. Analiz sonuçları ve yorumları sunulmuştur.

3.1. Tanımlayıcı analiz: Yayınların gelişimi




Şekil 1. Zaman İçindeki Yıllık Bilimsel Çalışmalar

Şekil 1, 1997'den günümüze kadar müşteri memnuniyetinde makine öğrenmesi algoritmaları kullanımı üzerine yapılmış bilimsel yayınların sayısını vermektedir. Genel olarak, yayın yılı dağılımı artan bir eğilim göstermektedir. Yayın sayılarında, 1997-2013 yılları arasında yer yer artma ve azalma eğilimi gözlemlenirken 2013'ten 2022'ye kadar belirgin bir artış izlemiştir. Bu alandaki araştırma sayısı 2024 yılında 124 çalışma ile tepe noktasına ulaşmıştır.

Tablo 1. Çalışmaların Türüne Göre Dağılımları

Çalışma Türü	Çalışma Sayısı	Yüzdeliği
Makale	351	%62,2
Bildiri	182	%32,3
İnceleme	29	%5,1
Kitap Bölümü	2	%0,35


Tablo 1, veri setindeki yayınların kategori bazında sınıflandırılmasına odaklanmaktadır. Yayınlanan çalışmaların %62,2'si ile en fazla sayısının makale kategorisinde, ikinci olarak %32,3'ünün bildiri kategorisinde olduğu ortaya konmaktadır. İnceleme ve kitap bölümü kategorisinde ise, %5,36 olmak üzere az sayıda çalışma yayınlanmıştır.



Şekil 2. Zaman İçinde Öne Çıkan Dergiler


En etkili dergilerin genel bir görünümünü sağlamak için, Şekil 2’de ilk on dergi listelenmektedir. Bu dergiler arasında 20 adet çalışma ile IEEE Access açık ara ilgili alanda en çok yayın bulunan dergidir; öne çıkan dergilerdeki toplam yayınların yaklaşık %26’sını temsil etmektedir.

3.2. İş birliği analizi: kurumlar ve ülkeler




Şekil 3. Sorumlu Yazarın Ülkesi

Şekil 3'te, ilgili konuda yayın yapan yazarların ülkelerine göre bir grafik oluşturulmuştur. Grafikteki koyu gri renk tek ülke yayını (TUY)'nı, açık gri renk ise birden fazla ülke yayını (BFUY)'nı temsil etmektedir. Elde edilen bulgulara göre; bu alanda en fazla yayının Hindistan'da (TUY:73, BFUY:9) yapıldığı, bunu Çin'in (TUY:63, BFUY:17) takip ettiği görülmektedir. İlgili konuda en çok yayın yapılan üçüncü ülke ise 47 adet sadece tek ülke yayını ve 20 adet birden fazla ülke yayını ile Amerika Birleşik Devletleri'dir (TUY:47, BFUY:20). Ayrıca bu konuda en çok yayın yapan ilk 20 ülke listesinde 13 adet tek ülke yayınıyla Türkiye'nin de bulunduğu tespit edilmiştir (TUY:13, BFUY:0).



Şekil 4. Konu ile İlgili Alana Katkıda Bulunan Kurumlar


Şekil 4, en yüksek yayın çıktısına sahip ilk yirmi kurumu göstermektedir. Listenin başında Malezya'daki Sains Malezya Üniversitesi 17 yayına katkıda bulunmaktadır. İkinci sırada, 14 yayınlı Çin'deki Tsinghua Üniversitesi ve üçüncü sırada 11 yayınlı Amerika Birleşik Devletleri'ndeki Illinois Üniversitesi takip etmektedir. Özellikle, ülke sıralamasında Çin'in ikinci sıradaki konumunu yansıtan üç Çin üniversitesi de en etkili kurumlar arasında temsil edilmektedir. Yine ülke sıralamasındaki yerlerini doğrular nitelikte iki adet Amerika Birleşik Devletleri ve dört Suudi Arabistan üniversiteleri de en etkili kurumlar arasındadır. Ayrıca, Akdeniz Üniversitesi, İstanbul Teknik Üniversitesi ve Sakarya Üniversitesi olmak üzere, en etkili kurumlar listesinde toplam 22 yayınlı Türkiye'deki üç adet devlet üniversitesi bulunmaktadır.



Şekil 7. Trend Konular

Şekil 7, 2017’den 2025’e kadar trend konuların gelişimini ve eğilimini göstermek için anahtar kelimelerin zaman çizelgesi görünümünü göstermektedir. Özellikle, 2017 ile 2020 arasında daha çok ‘görüş madenciliği’, ‘twitter’, ‘metin sınıflandırma’, ‘sosyal medya’ ve ‘veri madenciliği’ konularına odaklanılmıştır. 2020 ile 2024 yılları arasındaki çalışmalarda ‘doğal dil işleme’, ‘büyük veri’, ‘telekomünikasyon’, ve ‘metin madenciliği’ kelimelerine daha fazla dikkat çekilmiştir. ‘Regresyon’, ‘doğal dil işleme’ ve ‘duygu analizi’ anahtar kelimeleri en çok 2021 yılında ortaya çıkmıştır. Son üç yılda yayınlarda ‘derin öğrenme’, ‘tahmin’, ‘e-ticaret’, ‘metin madenciliği’ ve ‘servis kalitesi’ gibi anahtar kelimelerin kullanımı tercih edilmiştir. Bu nedenle dergideki yayınların anahtar kelimeleri zaman içinde genel anlamda değişmiştir.

3.4. Bibliyografik Bağlantı Ağlarının Analizi



Şekil 8. Eş-geçiş Ağı

Şekil 8, yayınların anahtar kelime eş-geçiş ağını göstermektedir. Her bir düğüm bir anahtar kelimeyi temsil edip düğüm ne kadar büyükse, anahtar kelimenin o kadar çok atfı olmaktadır. Farklı renk gruplarından oluşan 7 adet küme bulunmaktadır. Daha spesifik olmak gerekirse, en büyük küme olan yeşil kümede ‘duygu analizi’, ‘yapay zeka’, ‘veri madenciliği’ ve ‘e-ticaret’ gibi anahtar kelimeler yer alır; kırmızı kümede ‘regresyon’, ‘tahmin’ ve ‘müşteri davranışı’ öne çıkar; mor kümede ‘kümeleme’ ve ‘sınıflandırma’ bulunur; mavi kümede ‘sinir ağları’, ‘yapay’ ve ‘zeka’ etiketlenir; pembe kümede ‘tedarik zinciri’ ve ‘performans’ öne çıkar; sarı kümede ‘doğruluk’, ‘kalite’ ve ‘servis’ yer alır; kahverengi kümede ‘büyük veri’ ve ‘optimizasyon’ vurgulanır.

3.5. Alıntı Analizi: Ana Makaleler ve Yazarlar

Veri setinde yer alan yayınlar toplam atıf sayılarına göre sıralanmış olup, en çok atıf alan on çalışma Tablo 2’de sunulmuştur. Ahani, A., Nilashi, M., ve Sanzogni, L.’nin iki adet çalışmalarının listede bulunduğu görülmektedir.

Yazar(lar)	Başlık	Anahtar Kelimeler	Yıl	Dergi	Atıf Sayısı
Soleymani, M., Garcia, D., Jou, B., Schuller, B., Chang, S. F., & Pantic, M.	<i>A survey of multimodal sentiment analysis</i>	<i>Sentiment, Affect, Sentiment analysis, Human behavior analysis, Computer vision, Affective computing</i>	2017	<i>Image and Vision Computing</i>	326
Yadollahi, A., Shahraki, A. G., & Zaiane, O. R.	<i>Current State of Text Sentiment Analysis from Opinion to Emotion Mining</i>	<i>Emotion detection, Text mining, Polarity classification, Opinion mining, Sentiment analysis, Data mining, Machine learning</i>	2017	<i>ACM Computing Surveys</i>	267
Mustak, M., Salminen, J., Plé, L., & Wirtz, J.	<i>Artificial intelligence in marketing: Topic modeling, scientometric analysis, and research agenda</i>	<i>Marketing, Artificial intelligence, AI, Natural Language Processing, Big Data, Digital</i>	2021	<i>Journal of Business Research</i>	233
Ragini, J. R., Anand, P. R., & Bhaskar, V.	<i>Big data analytics for disaster response and recovery through sentiment analysis</i>	<i>Big data, Disaster management, Natural language processing, Sentiment analysis, Text classification, Social media analysis</i>	2018	<i>International Journal of Information Management</i>	227

Mozer, M. C., Wolniewicz, R., Grimes, D. B., Johnson, E., & Kausbansky, H.	Predicting subscriber dissatisfaction and improving retention in the wireless telecommunications industry	Boosting, Churn, Customer satisfaction, Decision trees, Logistic regression, Prediction, Profit maximization, Retention, Telecommunications, Wireless industry	2000	IEEE Transactions on neural networks	199
Mukherjee, D., Gupta, K., Chang, L. H., & Najjarian, H.	A Survey of Robot Learning Strategies for Human-Robot Collaboration in Industrial Settings	Human-Robot Collaboration, Human-Robot Interaction, Artificial Intelligence, Machine Learning, Adaptive Industrial Robotics, Multimodal Communication	2022	Robotics and Computer-Integrated Manufacturing	170
Ahani, A., Nilashi, M., Ibrahim, O., Sanzogni, L., & Weaven, S.	Market segmentation and travel choice prediction in Spa hotels through TripAdvisor's online reviews	Spa hotels, Market segmentation, Traveller preference, Online review, Social big data, TripAdvisor, Machine learning	2019	International Journal of Hospitality Management	159
Jain, P. K., Pamula, R., & Srivastava, G.	A systematic literature review on machine learning applications for consumer sentiment analysis using online reviews	Machine Learning, Online reviews, Sentiment analysis, Fake review, Recommendation prediction, Hospitality and tourism	2021	Computer science review	157
Ahani, A., Nilashi, M., Yadegaridehkordi, E., Sanzogni, L., Tarik, A. R., Knox, K., ... & Ibrahim, O.	Revealing customers' satisfaction and preferences through online review analysis: The case of Canary Islands hotels	Customer satisfaction, Preferences analysis, Online reviews, Hotel, Market segmentation, Canary islands, Multi-criteria decision making, Machine learning	2019	Journal of Retailing and Consumer Services	152
Cho, S., Asfour, S., Onar, A., & Kaundinya, N.	Tool breakage detection using support vector machine learning in a milling process	Tool breakage detection, Multiple sensors, Support vector machine	2005	International Journal of Machine Tools and Manufacture	136

4. Sonuç

Müşteri memnuniyeti ve makine öğrenmesi temalı literatür bibliyometrik analiz yöntemiyle ele alınmıştır. Alandaki akademik eğilimler, öne çıkan kurum ve dergiler, sık kullanılan anahtar kelimeler değerlendirilmiştir. Elde edilen bulgular dahilinde, bu alanda yapılan çalışmaların özellikle son yıllarda oldukça fazla olduğu görülmüştür. Makine öğrenmesi tekniklerinin müşteri memnuniyetinin değerlendirilmesi noktasında literatürde giderek daha

fazla yer bulmaktadır. Yazar anahtar kelimeleri kullanılarak veri kümesinde en sık tekrar eden anahtar kelimeler kelime bulutu ile görselleştirilmiş ve çalışmalardaki önemli noktalar tespit edilmiştir. Özellikle sentiment analizi, doğal dil işleme ve derin öğrenme gibi alt başlıkların ön plana çıktığı görülmektedir. Ayrıca, ilgili anahtar kelimeler ile bu alandaki trend konular belirlenerek veri kümelemesi aracılığıyla terimler arasında bibliyografik bağlantı haritası oluşturulmuştur. Burada hangi anahtar kelimelerin birlikte ele alındığı açıkça görülmektedir. Son olarak, atıf analizi ile en sık atıf alan on yayın listelenmiştir.

Yapılan analiz sonucunda, müşteri memnuniyetinin değerlendirilmesi noktasında makine öğrenmesi yöntemlerinin sadece teknik bir araç olarak kullanımı değil, tüketici davranışlarını anlamlandırmak için de bir bileşen olarak kullanıldığı görülmektedir. Literatürdeki değişim, bu alanda yeni araştırma fırsatlarının ve metodolojik yaklaşımların gelişmekte olduğunu göstermektedir. Bu yönüyle çalışma, literatürdeki mevcut boşlukları ve gelişim alanlarını belirlemeye katkı sağlamanın yanı sıra yapılacak olan araştırmalar için yönlendirici bir çerçeve sunmaktadır.

Kaynaklar

- Ahani, A., Nilashi, M., Ibrahim, O., Sanzogni, L., & Weaven, S. (2019). Market segmentation and travel choice prediction in Spa hotels through TripAdvisor's online reviews. *International Journal of Hospitality Management*, 80, 52-77.
- Ahani, A., Nilashi, M., Yadegaridehkordi, E., Sanzogni, L., Tarik, A. R., Knox, K., ... & Ibrahim, O. (2019). Revealing customers' satisfaction and preferences through online review analysis: The case of Canary Islands hotels. *Journal of Retailing and Consumer Services*, 51, 331-343.
- Alsharif, A. H., Salleh, N. O. R. Z. M. D., & Baharun, R. O. H. A. I. Z. A. T. (2020). Bibliometric analysis. *Journal of Theoretical and Applied Information Technology*, 98(15), 2948-2962.
- Aria, M. ve Cuccurullo, C. (2017). Bibliometrix: a R-tool for comprehensive science mapping analysis. *Journal of Informetrics*, 11(4), 959-975. DOI: 10.1016/j.joi.2017.08.007
- Cho, S., Asfour, S., Onar, A., & Kaundinya, N. (2005). Tool breakage detection using support vector machine learning in a milling process. *International Journal of Machine Tools and Manufacture*, 45(3), 241-249.
- Jain, P. K., Pamula, R., & Srivastava, G. (2021). A systematic literature review on machine learning applications for consumer sentiment analysis using online reviews. *Computer science review*, 41, 100413.
- Mozer, M. C., Wolniewicz, R., Grimes, D. B., Johnson, E., & Kaushansky, H. (2000). Predicting subscriber dissatisfaction and improving retention in the wireless telecommunications industry. *IEEE Transactions on neural networks*, 11(3), 690-696.
- Mukherjee, D., Gupta, K., Chang, L. H., & Najjaran, H. (2022). A survey of robot learning strategies for human-robot collaboration in industrial settings. *Robotics and Computer-Integrated Manufacturing*, 73, 102231.
- Mustak, M., Salminen, J., Plé, L., & Wirtz, J. (2021). Artificial intelligence in marketing: Topic modeling, scientometric analysis, and research agenda. *Journal of Business Research*, 124, 389-404.
- Ragini, J. R., Anand, P. R., & Bhaskar, V. (2018). Big data analytics for disaster response and recovery through sentiment analysis. *International Journal of Information Management*, 42, 13-24.
- Soleymani, M., Garcia, D., Jou, B., Schuller, B., Chang, S. F., & Pantic, M. (2017). A survey of multimodal sentiment analysis. *Image and Vision Computing*, 65, 3-14.
- Yadollahi, A., Shahraki, A. G., & Zaiane, O. R. (2017). Current state of text sentiment analysis from opinion to emotion mining. *ACM Computing Surveys (CSUR)*, 50(2), 1-33.

- Singh, N., Singh, P., & Gupta, M. (2020). An inclusive survey on machine learning for CRM: a paradigm shift. *Decision*, 47(4), 447-457.
- Singh, P., & Agrawal, R. (2018). A customer centric best connected channel model for heterogeneous and IoT networks. *Journal of Organizational and End User Computing (JOEUC)*, 30(4), 32-50.
- Rahman, B. (2024). Optimizing Customer Satisfaction through Sentiment Analysis: A BERT-based Machine Learning Approach to Extract Insights. *IEEE Access*.
- Wahab, M. S. A., Shazali, S. T. S., Mohamed, N. H. N., Abdullah, R. A., & Mohamaddan, S. (2024). Enriching Operational Efficiency in Industry 4.0 Through Machine Learning: A Case Study. *International Journal Of Technical Vocational And Engineering Technology*, 5(2), 22-31.
- Badhan, I. A., Hasnain, M. N., & Rahman, M. H. (2022). Enhancing Operational Efficiency: A Comprehensive Analysis of Machine Learning Integration in Industrial Automation. *Journal of Business Insight and Innovation*, 1(2), 61-77.
- Hallencreutz, J., & Parmler, J. (2021). Important drivers for customer satisfaction—from product focus to image and service quality. *Total quality management & business excellence*, 32(5-6), 501-510.
- Ittner, C. D., & Larcker, D. F. (1998). Are nonfinancial measures leading indicators of financial performance? An analysis of customer satisfaction. *Journal of accounting research*, 36, 1-35.
- Akdere, M., & Egan, T. (2020). Transformational leadership and human resource development: Linking employee learning, job satisfaction, and organizational performance. *Human Resource Development Quarterly*, 31(4), 393-421.
- Parmenter, D. (2015). *Key performance indicators: developing, implementing, and using winning KPIs*. John Wiley & Sons.
- Neely, A., Gregory, M., & Platts, K. (2005). Performance measurement system design: A literature review and research agenda. *International journal of operations & production management*, 25(12), 1228-1263.
- Mihelis, G., Grigoroudis, E., Siskos, Y., Politis, Y., & Malandrakis, Y. (2001). Customer satisfaction measurement in the private bank sector. *European Journal of Operational Research*, 130(2), 347-360.
- Aityassine, F. L. Y. (2022). Customer satisfaction, customer delight, customer retention and customer loyalty: Borderlines and insights. *Uncertain Supply Chain Management*, 10(3), 895-904.
- Negassa, G. J., & Japee, G. P. (2023). The effect of bonding, responsiveness and communication on customer retention: the mediating role of customer satisfaction. *Journal of relationship marketing*, 22(2), 115-131.

- Bhat, S. A., & Darzi, M. A. (2016). Customer relationship management: An approach to competitive advantage in the banking sector by exploring the mediational role of loyalty. *International Journal of Bank Marketing*, 34(3), 388-410.
- Kotler, P., & Armstrong, G. (2012). *Principles of marketing: An introduction* (14th ed.). Pearson.
- Otto, A. S., Szymanski, D. M., & Varadarajan, R. (2020). Customer satisfaction and firm performance: insights from over a quarter century of empirical research. *Journal of the Academy of Marketing science*, 48(3), 543-564.
- Gupta, S., & Zeithaml, V. (2006). Customer metrics and their impact on financial performance. *Marketing science*, 25(6), 718-739.

Çok Kriterli Karar Verme ve Makine Öğrenmesi: Entegrasyon ve Uygulamalar

Müzeyyen Özhavzalı¹

Özet

Günümüzde karar verme süreçleri, çok sayıda alternatif ve çelişkili kriterlerin varlığı nedeniyle karmaşıklaşmıştır. Çok Kriterli Karar Verme (ÇKKV) yöntemleri, bu tür problemleri sistematik ve matematiksel yaklaşımlarla çözmeyi sağlar. Ancak, artan veri hacmi ve karmaşık yapı, klasik ÇKKV yöntemlerinin sınırlarını zorlamaktadır. Makine Öğrenmesi (MÖ) ise veriden öğrenme yeteneğiyle, karar destek sistemlerinde önemli avantajlar sunmaktadır. Makina öğrenme dilleri arasında yer alan denetimli, denetimsiz ve pekiştirmeli öğrenme yöntemleri, kriter ağırlıklandırma, alternatif sınıflandırma ve dinamik karar modellerinde kullanılarak ÇKKV yöntemleriyle hibrit yaklaşımlar geliştirilmiştir. Bu birleşim hem karar sürecinin açıklanabilirliğini artırmakta hem de veri tabanlı adaptif karar mekanizmaları sağlamaktadır. Ayrıca, model açıklanabilirliği ve etik karar verme konusu, günümüzdeki araştırmaların önemli odak noktalarındandır. Bu çalışma, ÇKKV yöntemleriyle MÖ yöntemlerinin entegrasyonunu kuramsal ve uygulamalı bir çerçevede ele alarak, karmaşık karar problemlerine yönelik daha esnek, veri odaklı ve açıklanabilir çözümler sunmayı amaçlamaktadır. Geleneksel ÇKKV yöntemleri, yapılandırılmış karar süreçleri oluşturmada güçlü araçlar sunarken; dinamik, büyük ve belirsiz veri ortamlarında yetersiz kalmaktadır. MÖ algoritmaları, geçmiş verilere dayanarak karar fonksiyonlarını öğrenebilir, kriter ağırlıklarını otomatik olarak çıkarabilir ve alternatifleri sınıflandırabilir. Bu bağlamda, denetimli, denetimsiz ve pekiştirmeli öğrenme türleri karar süreçlerine farklı katkılar sağlamaktadır. Uygulamalı örnek olarak, tedarikçi seçiminde Random Forest sınıflandırıcısı ve SMOTE kullanılarak, azınlık sınıfların başarıyla tahmin edilebildiği ve model doğruluğunun %15 oranında arttığı gösterilmiştir. Ayrıca açıklanabilir yapay zekâ (XAI) tekniklerinin, şeffaf ve etik karar sistemlerinin geliştirilmesinde rolü vurgulanmaktadır. Sonuç olarak, ÇKKV ve MÖ'nün birleşimi, karar destek sistemlerini daha güvenilir,

1 Dr.Öğr.Üyesi, Kırıkkale Üniversitesi, Fatma Şenses Sosyal Bilimler MYO, thavzalizmuezeyyen@hotmail.com-ORCID ID 0000-0003-0518-3021

çevik ve kullanıcı dostu hale getirme potansiyeli taşımakta; açıklanabilirlik, etik ve yasal uyumluluk gibi alanlarda ise ileri araştırmaların gerekliliğini ortaya koymaktadır.

1. Giriş

Karmaşık karar verme problemleri, özellikle çok sayıda alternatif ve çelişkili kriterin bulunduğu durumlarda, geleneksel sezgisel yaklaşımlarla yönetilemez hâle gelmiştir. Günümüz iş dünyası ve kamu yönetiminde, büyük veri kaynaklarının artmasıyla birlikte nicel ve analitik karar destek sistemlerine olan ihtiyaç derinleşmiştir (Delen & Zolbanin, 2018). Özellikle karar vericilerin hem niteliksel hem niceliksel faktörleri değerlendirildiği ÇKKV problemleri, matematiksel modelleme teknikleri ile daha rasyonel çözümler sunmaktadır (Zopounidis & Doumpos, 2002).

Günümüzün belirsizliklerle dolu tedarik zinciri, enerji yönetimi ve stratejik planlama gibi alanlarında karar vericilerin çoklu ve çoğu zaman çelişen kriterleri dengelemesi gerekmektedir. Bu tür karmaşık karar durumları için ÇKKV yöntemleri, karar sürecini sistematikleştirerek alternatiflerin nesnel biçimde değerlendirilmesini sağlar. Ağırlıklandırma, sıralama, kıyaslama gibi yapılandırılmış adımlar sayesinde karar verme süreçleri daha rasyonel ve tekrar edilebilir hale gelir (Saaty, 1980).

Makine öğrenmesi ise veriye dayalı örüntü tanıma, sınıflandırma ve tahminleme yetenekleriyle son yıllarda karar destek sistemlerinin önemli bir bileşeni haline gelmiştir. Geleneksel karar yöntemlerinden farklı olarak, makine öğrenmesi algoritmaları geçmiş verilere dayanarak öğrenir ve bu öğrenme süreci sayesinde geleceğe yönelik öngörülerde bulunabilir (Bishop, 2006). Özellikle büyük, dinamik ve yapısal olmayan veri kaynaklarının analizinde makine öğrenmesi güçlü bir araçtır.

ÇKKV yöntemleri, karar sürecini sistematikleştirirken; MÖ ise veriden öğrenerek geleceğe yönelik tahminleme ve sınıflandırma yeteneği sağlar (Bishop, 2006). Bu iki alanın birleşimi, yalnızca statik verilerle değil, değişen çevresel koşullarla da başa çıkabilen hibrit modellerin geliştirilmesine zemin hazırlamaktadır (Tsai & Hsu, 2013). Örneğin, tedarikçi seçiminde hem AHP gibi yapısal ÇKKV yöntemleriyle kriter ağırlıkları belirlenebilir hem de geçmiş performans verilerinden makine öğrenmesi algoritmalarıyla sınıflandırma yapılarak daha dinamik kararlar alınabilir.

Bu hibrit yaklaşım, karar verme sürecini daha esnek, veri odaklı ve çevresel değişimlere duyarlı hale getirir. Ayrıca, SHAP gibi açıklanabilirlik araçlarıyla makine öğrenmesi modellerinin iç karar mekanizmaları da ortaya konularak hem şeffaflık sağlanmakta hem de kullanıcı güveni artırılmaktadır (Lundberg

& Lee, 2017). Dolayısıyla, ÇKKV ve MÖ'nün entegrasyonu yalnızca teknik başarı değil, aynı zamanda açıklanabilir ve etik karar sistemlerinin geliştirilmesi açısından da önemlidir.

Makine öğrenmesinin veri temelli öğrenme becerisi, karar vericinin geçmiş karar örüntülerinden yola çıkarak benzer durumlarda hangi kararın daha uygun olduğunu belirleyebilmesine olanak tanır (Quinlan, 1993). Öte yandan, ÇKKV yöntemlerin avantajı, karar sürecinin şeffaf, hesap verebilir ve metodolojik olarak izlenebilir olmasıdır (Saaty, 1980; Hwang & Yoon, 1981).

Son yıllarda denetimli öğrenme algoritmaları (Random Forest, SVM), denetimsiz yöntemler (K-means, PCA) ve pekiştirmeli öğrenme algoritmaları (Q-learning, DQN) gibi farklı MÖ tekniklerinin ÇKKV çerçevesine entegrasyonu büyük ilgi görmektedir (LeCun et al., 2015). Ancak, etik sorunlar, modelin yorumlanabilirliği ve karar sürecinin açıklanabilirliği gibi konular da önem kazanmıştır (Ribeiro et al., 2016; Vellido et al., 2012).

Bu bölümde, ÇKKV ve MÖ yaklaşımlarının birleşik kullanımı kuramsal bir çerçevede ele alınmakta; farklı yöntemlerin avantajları, entegrasyon stratejileri ve uygulamalı örnekler üzerinden tartışılmaktadır. Ayrıca, derin öğrenme, model yorumlanabilirliği ve etik karar yapıları gibi güncel konulara da değinilmektedir (Kahneman, 2011; Rawls, 1971; Shapley, 1953).

2. ÇKKV Yöntemleri: Genel Bakış

ÇKKV, birden fazla çelişkili kriter altında karar verilmesi gereken durumlar için geliştirilmiş matematiksel ve sistematik yöntemlerin genel adıdır (Zopounidis & Doumpos, 2002). Bu yöntemler, karar vericinin tercihlerini formalize ederek alternatiflerin sıralamasını veya sınıflandırmasını sağlar.

2.1 ÇKKV Yöntemleri: Klasikten Moderne Bir Bakış

Analitik Hiyerarşi Süreci (AHP), Thomas L. Saaty tarafından geliştirilen bir karar verme yöntemidir ve karar problemlerini hiyerarşik yapıya dönüştürerek çözmeyi amaçlar. AHP, karar vericilerin tercihlerini ikili karşılaştırmalar yoluyla belirleyerek, her bir kriterin göreceli önemini hesaplar. Bu sayede, niteliksel uzman görüşleri sayısal verilere dönüştürülerek karar sürecine dahil edilebilir (Saaty, 1980). Yöntemin en önemli avantajı, kullanıcı dostu olması ve karar vericilerin bilişsel yapısına uygun bir değerlendirme süreci sunmasıdır. Ancak, ikili karşılaştırmalarda kullanılan öznel değerlendirmeler ve tutarlılık sorunları, özellikle büyük boyutlu problemlerde yöntemin doğruluğunu etkileyebilir. Ayrıca, AHP çoğunlukla

statik bir yapıya sahiptir; dolayısıyla dinamik ve veri yoğun ortamlarda esnekliği sınırlı olabilir.

TOPSIS (Technique for Order Preference by Similarity to Ideal Solution) yöntemi, Hwang ve Yoon (1981) tarafından geliştirilmiştir. Bu yöntem, ideal ve anti-ideal çözümlerle alternatiflerin arasındaki geometrik uzaklıkları dikkate alarak, en iyi alternatifin ideal çözüme en yakın ve anti-ideale en uzak olan olarak seçilmesini sağlar. TOPSIS'in en önemli katkılarından biri, karar problemlerini nicel olarak ele alabilmesi ve oldukça sistematik bir sıralama mekanizması sunmasıdır (Hwang & Yoon, 1981). Bununla birlikte, kriterler arasındaki korelasyonların dikkate alınmaması ve ağırlıklandırma sürecindeki dengesizlikler, yöntemin performansını zayıflatabilir. Özellikle yüksek boyutlu veya yüksek oranda ilişkilendirilmiş kriterlere sahip modellerde, sonuçlar karar vericiyi yanıltabilir.

VIKOR (VlseKriterijumska Optimizacija I Kompromisno Resenje) yöntemi, çelişkili kriterler altında uzlaşmaya dayalı çözümler üretmeyi hedefleyen bir yöntemdir. Opricovic ve Tzeng (2004) tarafından geliştirilen bu yaklaşım hem grup kararlarını hem de bireysel tercihleri dengeleyerek, karar vericilerin en iyi çözüm konusunda uzlaşmalarını sağlar. VIKOR yöntemi, ideal çözüme yakınlık ile en kötü duruma olan uzaklığı birlikte değerlendirerek alternatiflerin sıralamasını oluşturur (Opricovic & Tzeng, 2004). Bu yöntem özellikle sosyal bilimler, kamu politikası ve mühendislik gibi disiplinlerde çelişkili kriterlerin olduğu durumlarda etkili çözümler sunar. Ancak karar vericilerin tercih ettiği uzlaşma düzeyi (örneğin, strateji katsayısı “v”) sonuçlar üzerinde doğrudan etkili olduğundan, sonuçların hassasiyet analizi ile desteklenmesi önerilir.

PROMETHEE (Preference Ranking Organization Method for Enrichment Evaluations), tercih fonksiyonlarına dayalı bir sıralama yöntemidir. Brans ve Mareschal (2005) tarafından geliştirilen bu yaklaşım, her bir alternatifin diğerlerine göre üstünlüğünü (pozitif ve negatif akış değerleri) hesaplayarak, bir sıralama ortaya koyar. PROMETHEE, özellikle GAIA düzlemi gibi grafiksel araçlarla desteklenerek karar vericilerin modeli daha iyi anlamalarını sağlar (Brans & Mareschal, 2005). Bu yöntem, karar vericilerin subjektif tercihlerini doğrudan modele entegre edebildiği için esnek bir yapı sunar. Bununla birlikte, tercih fonksiyonlarının doğru tanımlanması, yöntemin başarısı açısından kritik öneme sahiptir; yanlış veya eksik tanımlanan tercihler, sıralamanın anlamlılığını zayıflatabilir.

2.2 Güncel ve Modern ÇKKV Yöntemleri:

BWM (Best-Worst Method), ÇKKV alanında Rezaei (2015) tarafından geliştirilen yenilikçi ve etkin bir karar verme yöntemidir. Bu yöntem, geleneksel ikili karşılaştırma temelli yöntemlerde (örneğin AHP) karşılaşılan karşılaştırma yükünü azaltarak karar vericilere daha yalın ve tutarlı bir değerlendirme süreci sunar. BWM'in temel mantığı, karar vericiden öncelikle problemde yer alan kriterler arasından en önemli (best) ve en önemsiz (worst) olan kriterleri belirlemesini istemektir. Ardından, karar vericiden en iyi kriterin diğer tüm kriterlere göre ne derece daha önemli olduğunu ve aynı şekilde, diğer tüm kriterlerin en kötü kritere göre ne derece daha önemli olduğunu değerlendirmesi beklenir (Rezaei, 2015).

Bu değerlendirmeler sonucunda bir optimizasyon modeli kurularak kriter ağırlıkları hesaplanır. Buradaki temel avantaj, karar vericinin tüm kriter çiftleri arasında ikili karşılaştırmalar yapmasına gerek kalmadan, sınırlı sayıda değerlendirme ile karar sürecinin tamamlanabilmesidir. Bu da yöntemin hem zaman açısından verimliliğini artırmakta hem de tutarlılık düzeyini yükseltmektedir. Rezaei (2015), BWM'nin özellikle AHP'ye kıyasla daha yüksek tutarlılık oranlarına sahip olduğunu ve daha az karşılaştırma gerektirdiğini göstererek, yöntemin pratik uygulamalarda ne kadar etkili olabileceğini ortaya koymuştur.

BWM'in bir diğer önemli özelliği ise öznel yargıların sistematik ve matematiksel bir şekilde modellenmesini sağlamasıdır. Bu, karar vericinin sezgisel bilgilerini nicel veriye dönüştürürken karşılaşılan belirsizlikleri azaltır. Ayrıca, bu yöntemin kolay uygulanabilirliği ve analitik yapısı, özellikle sınırlı bilgiye sahip karar ortamlarında güvenilir sonuçlar üretmesini mümkün kılar. Bu nedenlerle BWM, tedarik zinciri yönetimi, sürdürülebilirlik analizi, risk değerlendirmesi, proje yönetimi gibi birçok farklı alanda yaygın bir şekilde kullanılmaktadır.

DEMATEL (Decision Making Trial and Evaluation Laboratory) yöntemi, çok kriterli karar verme (ÇKKV) yaklaşımlarından biri olarak, kriterler arasındaki nedensellik ilişkilerini ortaya koymak amacıyla geliştirilmiştir. Bu yöntem, özellikle karmaşık ve dinamik sistemlerde, karar verme sürecinde hangi kriterin diğerleri üzerinde daha etkili olduğunu belirlemeye yardımcı olmaktadır. DEMATEL yöntemi, karar kriterleri arasındaki etkileşimleri hem sayısal hem de görsel biçimde analiz ederek, neden-sonuç ilişkilerini ortaya koymakta ve böylece karar vericilere daha bilinçli bir değerlendirme olanağı sunmaktadır (Tzeng, Chiang, & Li, 2007).

DEMATEL'in temel yaklaşımı, kriterler arasında doğrudan ve dolaylı etkileri dikkate alarak bir etkileşim matrisi oluşturmak ve bu matrisi kullanarak kriterlerin toplam etkilerini hesaplamaktır. Elde edilen bu bilgiler, hangi kriterlerin sistemin işleyişinde “neden” ve hangilerinin “sonuç” rolü üstlendiğini belirlemeyi sağlar (Fontela & Gabus, 1976). Bu yönüyle DEMATEL, karar vericilerin sistemin genel yapısını daha iyi anlamalarına ve müdahale edilecek alanları tespit etmelerine yardımcı olan güçlü bir araçtır.

ANP (Analytic Network Process) yöntemi, Thomas Saaty tarafından geliştirilen ve AHP'nin daha gelişmiş bir versiyonu olan bir karar verme yöntemidir. AHP'nin aksine, ANP yöntemi karar verme yapısını hiyerarşik değil, ağ (network) formunda ele alır. Bu ağ yapısı sayesinde kriterler arasında karşılıklı bağımlılıklar, geri beslemeler ve iç içe geçmiş ilişkiler dikkate alınarak daha bütüncül bir analiz yapılabilir (Saaty, 1996). ANP, bu özelliği sayesinde daha karmaşık ve çok boyutlu karar problemlerinde kullanıma uygundur.

ANP'nin önemli katkılarından biri, karar sürecinde yalnızca yukarıdan aşağıya bir akış değil, aynı zamanda kriterler ve alt kriterler arasında çift yönlü etkileşimleri de analiz edebilmesidir. Özellikle sistemsel düşünme gerektiren mühendislik, tedarik zinciri yönetimi, sürdürülebilirlik analizi gibi alanlarda ANP, karar vericilere daha gerçekçi ve etkileşimli bir değerlendirme zemini sunmaktadır. Ancak modelin karmaşık yapısı ve hesaplama yoğunluğu, kullanıcılar açısından öğrenme eğrisini artırabilir.

MACBETH (Measuring Attractiveness by a Categorical Based Evaluation Technique) yöntemi, özellikle kantitatif verilerin mevcut olmadığı, niteliksel değerlendirmenin daha ön planda olduğu durumlarda etkin biçimde kullanılan çok kriterli karar verme yöntemlerinden biridir. Bu yöntemin temelinde, karar vericilerin alternatifler arasındaki çekicilik farklarını sözel yargılarla ifade etmeleri yatmaktadır. Bu sözel yargılar daha sonra sayısal ölçeklere dönüştürülerek karar matrisleri oluşturulur (Bana e Costa & Vansnick, 1994).

MACBETH'in öne çıkan özelliği, psikolojik tutarlılığı ön plana alarak karar vericilerin duygusal ve sezgisel değerlendirmelerini yapay olarak nicelleştirmeye çalışmamasıdır. Böylece daha doğal bir değerlendirme süreci sağlanmakta, karar vericilerin bilişsel yükü azaltılmaktadır. Ayrıca MACBETH, diğer birçok yönteme kıyasla karar vericilerin tutarsızlıklarını sistematik olarak belirleyip düzeltmeye yönelik araçlar da sunar, bu da yöntemin karar kalitesini artırmasına katkı sağlar.

Fuzzy yöntemi ÇKKV klasik yöntemlerine bulanık mantık ile entegre edilmesi sonucu geliştirilmiştir. Bu yöntemler, karar vericilerin değerlendirmelerinde karşılaşılan belirsizlikleri, sözel ifadeleri ve eksik bilgileri daha iyi modelleyebilmek amacıyla geliştirilmiştir. Örneğin Fuzzy AHP, Fuzzy TOPSIS gibi türevler, klasik AHP ve TOPSIS yaklaşımlarında kullanılan kesin sayısal değerler yerine, bulanık sayılarla çalışarak karar vericilerin daha esnek yargılar oluşturmalarına olanak tanır (Zadeh, 1965; Chen et al., 1992).

Fuzzy yöntemler, özellikle bilgi eksikliği, belirsizlik ve insan faktörünün yoğun olduğu durumlarda klasik yöntemlere göre daha gerçekçi sonuçlar üretmektedir. Bu yöntemlerin avantajı, sözel yargılar (örneğin “biraz daha önemli”, “çok daha önemli”) gibi bulanık ifadelerin matematiksel modellere entegre edilebilmesidir. Böylece karar süreci hem daha esnek hem de karar vericiye daha yakın hale gelir.

Entropy Tabanlı Ağırlıklandırma yöntemi, çok kriterli karar problemlerinde kriter ağırlıklarını belirlemek amacıyla kullanılan nesnel ve veri tabanlı bir yaklaşımdır. Bu yöntemin temelinde bilgi teorisi yer alır ve her bir kriterin sağladığı bilgi miktarı (belirsizlik düzeyi) esas alınarak ağırlıklar hesaplanır (Shannon, 1948). Entropi değeri ne kadar düşükse, kriterin bilgi değeri o kadar yüksektir ve dolayısıyla ağırlığı artar.

Bu yöntem özellikle büyük veri setleriyle çalışılan, uzman görüşlerinin yetersiz veya bulunmadığı durumlarda tercih edilmektedir. Diğer öznel yöntemlerin aksine, Entropy yaklaşımı tamamen gözlemlenen verilere dayanır. Bu nedenle istatistiksel geçerliliği daha yüksektir ve sonuçların objektifliği artırılır. Tedarik zinciri, çevresel etki değerlendirme ve finansal analiz gibi alanlarda sıkça kullanılmaktadır.

GRA (Grey Relational Analysis) yöntemi, Deng (1989) tarafından geliştirilen ve özellikle veri eksikliği, belirsizlik ya da sınırlı bilgi içeren durumlarda tercih edilen çok kriterli karar verme yöntemidir. GRA, alternatiflerin ideal çözümle olan benzerliğini ölçerek, karar sürecinde en iyi seçeneğin belirlenmesini sağlar. Bu yöntem, özellikle az veriyle çalışıldığı durumlarda oldukça etkilidir.

GRA'nın temel gücü, karmaşık matematiksel modellemelere ihtiyaç duymadan, sınırlı verilerle karar desteği sağlayabilmesidir. Diğer yöntemlerin aksine, GRA verilerin tam, normal dağılmış ya da istatistiksel özellik taşımasını zorunlu kılmaz. Bu özelliği, yöntemi mühendislik, kalite kontrol, sürdürülebilirlik analizi ve çevresel etki değerlendirme gibi birçok alanda pratik ve güçlü bir araç haline getirmiştir.

2.3 Veri Boyutu ve Klasik ÇKKV Yöntemlerinin Sınırları

Klasik yöntemler, küçük ve yapılandırılmış veri setlerinde başarılı sonuçlar verirken, günümüzde artan veri hacmi, yüksek boyutluluk (curse of dimensionality) ve veri dengesizliği gibi problemler performansı düşürmektedir. Azınlık sınıfların baskılandığı veri setlerinde karar hataları yaşanabilir (Chawla et al., 2002).

Ayrıca, kriterler arasındaki bağımlılık, boyut indirgeme teknikleri (PCA gibi) kullanılarak azaltılabilir (Jain, 2010). Kriter ağırlıkları ise geçmiş performans verilerinden makine öğrenmesi algoritmaları ile öğrenilebilir (Breiman, 2001).

Model açıklana bilirliliği, veri büyüdükçe zorluk kazanır. Bu nedenle, açıklanabilir yapay zekâ (XAI) tekniklerinin ÇKKV süreçlerine entegre edilmesi gereklidir (Ribeiro et al., 2016; Vellido et al., 2012).

3. Makine Öğrenmesi: Temel Kavramlar

Makine Öğrenmesi (MÖ), verilerden örüntü ve ilişkileri keşfederek, gelecekteki karar ve tahminleri otomatikleştiren yapay zekâ dalıdır (Bishop, 2006). MÖ, karar destek sistemlerinde giderek yaygınlaşmakta ve Çok kriterli karar problemlerin yeni çözümler sunmaktadır (Tsai & Hsu, 2013).

3.1 MÖ'nün Kategorileri

- **Denetimli Öğrenme:** Girdi-çıkı ilişkisi bilinen veri üzerinden model eğitilir. Sınıflandırma (SVM, C4.5) ve regresyon problemleri içerir (Quinlan, 1993; Cortes & Vapnik, 1995). ÇKKV'de alternatiflerin sınıflandırılması için kullanılır (Zhang et al., 2020).
- **Denetimsiz Öğrenme:** Etiketlenmemiş veriden yapısal bilgi çıkarılır. Kümeleme (K-means, DBSCAN) ve boyut indirgeme (PCA, t-SNE) yöntemleri dahildir (Jain, 2010). Yüksek boyutlu ÇKKV verilerinde alternatifi grulamada etkilidir (Tsai & Chou, 2014).
- **Pekiştirmeli Öğrenme:** Ajan, ortamla etkileşim kurarak ödül-ceza sinyallerinden karar politikası öğrenir (Sutton & Barto, 2018). Dinamik karar problemlerinde kullanılır (Mnih et al., 2015).

3.2 Veri Dengesizliği ve Artırma Teknikleri

Gerçek dünyada veriler dengesizdir; bazı alternatifler azınlıkta kalabilir, bu da öğrenmeyi zorlaştırır (He & Garcia, 2009). SMOTE gibi teknikler, azınlık sınıfı artırarak model başarısını yükseltir (Chawla et al., 2002).

3.3 Model Açıklanabilirliği ve Etik Boyut

MÖ modelleri karmaşılaştıkça açıklanabilirlik zorlaşır. Açıklanabilir Yapay Zekâ (XAI) yöntemleri, karar süreçlerini şeffaflaştırır (Ribeiro et al., 2016; Lundberg & Lee, 2017). Shapley değerleriyle kriter katkıları niceliksel olarak analiz edilir (Shapley, 1953).

Etik ilkeler de önemlidir; veri gizliliği, tarafsızlık ve adalet gibi konular MÖ modellerinin güvenilirliği için kritik unsurlardır (Veale & Binns, 2017; Mittelstadt et al, 2016).

3.4 ÇKKV ve Makine Öğrenmesinin Kesişimi: Öğrenme Türlerinin Karar Süreçlerindeki Rolü

ÇKKV yöntemleri, karar vericilerin birden fazla, kimi zaman çelişkili kriteri göz önünde bulundurarak en uygun alternatifi seçmesini sağlayan sistematik yaklaşımlardır. Geleneksel ÇKKV yöntemleri, karar sürecini yapılandırma ve kriterler arasında önem düzeyi belirleme açısından güçlüdür; ancak değişken, büyük ve karmaşık veri ortamlarında sınırlı kalabilir. Bu nedenle, son yıllarda MÖ algoritmaları, ÇKKV süreçlerinin hem otomatikleştirilmesi hem de çevresel değişkenliklere uyum sağlaması açısından tamamlayıcı bir rol üstlenmektedir (LeCun, Bengio, & Hinton, 2015; Tsai & Hsu, 2013).

MÖ ile ÇKKV'nin entegrasyonunda, farklı öğrenme türlerinin karar sürecine katkısı önemlidir. **Denetimli öğrenme (supervised learning)**, etiketlenmiş geçmiş karar verilerinden örüntüleri öğrenerek gelecekteki karar durumları için tahminleme veya sınıflandırma yapar. Örneğin, geçmişteki başarılı tedarikçi seçimlerini analiz ederek, benzer özelliklere sahip yeni tedarikçilerin başarı olasılığını öngörebilir (Zhang, Zhao, & Kumar, 2020). Bu, karar destek sistemlerinin öngörücü hale gelmesini sağlar.

Denetimsiz öğrenme (unsupervised learning) ise verinin etiketlenmemiş olduğu durumlarda kullanılır ve alternatifler arasındaki benzerliklere göre gruplanmasını (clustering) sağlar. Bu yaklaşım, örneğin pazar segmentasyonu, tedarikçi kümelendirme veya kriter ilişkilerinin keşfi gibi yapılarda kullanılabilir (Tsai & Chou, 2014). Böylece karar vericiye önceden farkında olmadığı veri yapıları ve örüntüler sunularak yeni stratejik bakış açıları kazandırılır.

Pekiştirmeli öğrenme (reinforcement learning), dinamik ve geribildirim içeren ortamlarda, ajanların eylemlerine karşılık aldığı ödül-ceza sistemine göre strateji geliştirmesine olanak tanır. Tedarik zinciri optimizasyonu, kaynak planlama ya da üretim çizelgeleme gibi zamanla

değişen karar ortamlarında bu yaklaşım güçlü bir çözüm sağlar (Sutton & Barto, 2018).

Bu bağlamda, MÖ yöntemleri yalnızca büyük veri ile başa çıkmak için değil, aynı zamanda ÇKKV süreçlerinin öğrenen, kendini uyarlayabilen ve dinamik ortamlarda karar kalitesini sürdürebilen yapılar haline gelmesi için kritik önemdedir. ÇKKV ve MÖ'nün kesişiminde yer alan hibrit yaklaşımlar, klasik yöntemlerin sezgisel gücünü, MÖ'nün veri odaklı esnekliğiyle birleştirerek çağdaş karar destek sistemlerinin temelini oluşturmaktadır.

Kısacası Denetimli öğrenme geçmiş karar verilerini modelleyerek öneri sunar (Zhang et al., 2020). Denetimsiz öğrenme alternatiflerin gruplanmasını sağlar (Tsai & Chou, 2014). Pekiştirmeli öğrenme dinamik ortamlar için stratejiler geliştirir (Sutton & Barto, 2018). Bu nedenle MÖ, ÇKKV süreçlerinin otomatikleşmesi ve adaptasyonu için vazgeçilmezdir (LeCun et al., 2015; Tsai & Hsu, 2013).

4. ÇKKV ile MÖ Entegrasyonu: Neden ve Nasıl?

4.1 Entegrasyonun Gerekçesi

Günümüzde ÇKKV problemleri, büyük ve karmaşık veri setleriyle tanımlanmakta; klasik yöntemler bu karmaşıklığı yönetmekte zorlanmaktadır. MÖ, doğrusal olmayan ilişkileri modelleyebilir, ağırlıklandırma süreçlerini otomatikleştirebilir ve sınıflandırma yapabilir (Chen et al., 2021; Tsai & Hsu, 2013). Ayrıca MÖ'nün esnekliği sayesinde karar sistemleri değişen ortamlara uyum sağlar (LeCun et al., 2015).

4.2 Entegrasyon Stratejileri

1. **Ağırlıklandırma için MÖ Kullanımı:** Kriter ağırlıkları geçmiş veriden tahmin edilir (Breiman, 2001; Chen et al., 2021).
2. **Alternatiflerin Kümeleme ile Ön Sınıflandırılması:** K-means, DBSCAN gibi algoritmalar alternatifleri gruplar (Jain, 2010; Tsai & Chou, 2014).
3. **Karar Fonksiyonlarının Öğrenilmesi:** SVM, Random Forest, XGBoost gibi algoritmalar karar modelleri oluşturur (Zhang et al., 2020; Chen & Guestrin, 2016).
4. **Optimizasyon Tabanlı Entegrasyon:** Genetik algoritmalar, pekiştirmeli öğrenme ile parametreler optimize edilir (Holland, 1992; Sutton & Barto, 2018).

5. **Model Seçimi ve Uyumlandırma:**Farklı karar problemleri, farklı makine öğrenmesi algoritmalarıyla daha etkili çözülür. Bu nedenle, problem türüne (sıralama, sınıflandırma, regresyon vb.) göre en uygun algoritmanın seçilmesi kritik bir adımdır. Ayrıca hiperparametre ayarlamaları, çapraz doğrulama ve model uyumu testleri ile öğrenme algoritmaları ÇKKV yapısına entegre edilir (Bishop, 2006; Guyon et al., 2006). Bu strateji, karar modelinin hem doğruluk hem de açıklanabilirlik açısından optimize edilmesini sağlar.

5. Uygulama Örneği: Tedarikçi

Tedarikçi seçimi, maliyet, kalite, teslimat süresi gibi birçok kriteri içeren klasik ÇKKV problemidir (Chan et al.,2017). Bu çalışmada, geleneksel AHP ve TOPSIS yöntemlerine ek olarak, geçmiş performans verileri üzerinde Random Forest sınıflandırıcısı geliştirilmiş ve bu yöntemleri yanında, geçmiş performans verileri üzerinden Random Forest sınıflandırıcısı eğitilmiş; azınlık tedarikçi kategorileri için SMOTE uygulanmıştır. Bu örnekteki veri seti özelliklerine bakıldığında

- Veri seti, 500 tedarikçiye ait maliyet, kalite puanı, teslimat süresi, geçmiş performans skorları gibi 8 farklı özelliği içermektedir.
- Sınıflar, yüksek, orta ve düşük performans olarak üç kategoriye ayrılmıştır.
- Düşük performanslı tedarikçiler, toplam veri setinin %10'unu oluşturarak azınlık sınıfını temsil etmektedir.
- Veri ön işleme aşamasında, eksik değerler ortalama ile doldurulmuş, kategorik veriler one-hot encoding yöntemi ile sayısal hale getirilmiştir.

Bu uygulamadaki Model eğitimi ve parametre ayarlamada ise aşağıdaki yer almaktadır:

- Random Forest modeli, başlangıçta varsayılan parametrelerle eğitilmiş, ardından Grid Search yöntemi ile hiperparametre optimizasyonu yapılmıştır.
- En iyi sonuçlar için, ağaç sayısı (n_estimators) 100, maksimum derinlik (max_depth) 10, minimum yaprak düğümü örnek sayısı (min_samples_leaf) 5 olarak belirlenmiştir.
- Model eğitiminde %70 eğitim ve %30 test veri seti kullanılmıştır.
- Sınıf dengesizliğinin giderilmesi için SMOTE uygulanmıştır; böylece düşük performanslı tedarikçi sayısı artırılarak modelin azınlık sınıflar üzerindeki başarısı desteklenmiştir.

Daha sonra uygulamanın Performans Değerlendirme Metrikleri oluşturulmuş ve Model performansı aşağıdaki metriklerle değerlendirilmiştir:

Tablo 1. Performans Değerlendirme Metrikleri ve Model Performansı Metrikleri

Model	Doğruluk (Accuracy)	Kesinlik (Precision)	Geri Çağırma (Recall)	F1 Skoru
Random Forest (SMOTE)	%89	%87	%85	%86
Random Forest (Orijinal)	%74	%72	%70	%71

Uygulanmanın sonunda ise SMOTE yöntemi ile desteklenen Random Forest modeli, sınıflandırma doğruluğunu %15 oranında artırdığı; özellikle azınlık sınıfı olan düşük performanslı tedarikçilerin doğru sınıflandırılmasında belirgin iyileşme sağlandığı görülmüştür. Bu hibrit yaklaşım, ÇKKV süreçlerinde makine öğrenmesi tekniklerinin etkin entegrasyonunun, tedarikçi seçiminde daha dengeli, güvenilir ve doğru kararlar alınmasına olanak verdiğini ortaya koymuştur.

6. Makine Öğrenmesi Tabanlı Çok Kriterli Karar Destek Sistemleri (ÇKKDS)

Günümüzde ÇKK ve problemlerinin çözümünde, yalnızca klasik karar yöntemlerinin uygulanması yeterli olmamakta; karar vericilerin etkileşimli ve dinamik ortamlarda desteklenmesi gerekmektedir. Bu bağlamda, makine öğrenmesi tabanlı çok kriterli karar destek sistemleri (ÇKKDS) önem kazanmakta ve karar sürecini hem hızlandırmak hem de doğruluk oranını artırmak amacıyla kullanılmaktadır (Delen & Zolbanin, 2018).

6.1 Sistem Mimarisi ve Bileşenleri

ÇKKDS genellikle veri toplama, ön işleme, kriter ağırlıklandırma, alternatiflerin değerlendirilmesi, sonuçların görselleştirilmesi ve kullanıcı etkileşimi bileşenlerinden oluşmaktadır (Kahraman, Cebeci & Ulukan, 2007). Makine öğrenmesi algoritmaları, ön işleme ve ağırlıklandırma adımlarında kritik rol oynamaktadır. Özellikle, algoritmalar geçmiş karar verilerinden öğrenerek kriterlerin önem derecelerini belirleyebilir (Breiman, 2001).

Örneğin, yapay sinir ağları ve destek vektör makineleri gibi denetimli öğrenme yöntemleri, karar vericinin tercihlerine göre karar modellerini eğitebilir (Cortes & Vapnik, 1995). Pekiştirmeli öğrenme tabanlı sistemlerde

ise, ajan karar süreci içerisinde ödül-ceza mekanizmasıyla kendi stratejisini geliştirebilir (Sutton & Barto, 2018).

6.2 Uygulama Alanları

ÇKKDS, finansal risk yönetimi, sağlık hizmetleri, lojistik optimizasyonu, enerji yönetimi ve üretim planlaması gibi çeşitli alanlarda etkin biçimde kullanılmaktadır (Tsai & Hsu, 2013; Wang, Zhang, & Yang, 2018, Bilgin, 2021, Göksu ve et al., 2025). Özellikle enerji sektöründe, yenilenebilir enerji kaynaklarının etkin seçimi için veri odaklı karar destek sistemleri geliştirilmektedir (Cheng, Zhang, & Xia, 2020).

7. Derin Öğrenme ve Çok Kriterli Karar Verme: Yeni Ufuklar

Derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla karmaşık veri yapılarından anlamlı örüntüler çıkarabilme kapasitesiyle, ÇKKV alanında yeni fırsatlar sunmaktadır (LeCun et al., 2015). ÇKKV birçok alternatifi farklı kriterler açısından değerlendirilerek en uygun kararın verilmesini amaçlayan klasik bir yöntemler bütünüdür. Ancak geleneksel ÇKKV yöntemlerindeki, genellikle karar verici uzmanlığının sınırlı olduğu, büyük ve karmaşık veri kümeleriyle başa çıkmakta zorlanır. Bu noktada derin öğrenme, büyük hacimli, yapısal ya da yapısal olmayan verilerden otomatik olarak anlamlı örüntüler çıkartabilme kapasitesiyle, ÇKKV süreçlerini dönüştürme potansiyeli taşımaktadır (LeCun et al., 2015).

Derin öğrenme, özellikle çok sayıda kriterin etkileşimli olarak değerlendirildiği durumlarda avantaj sunar. Örneğin, akıllı şehir planlamasında hem ekonomik hem çevresel hem de sosyal etkenler göz önünde bulundurularak altyapı yatırımlarının önceliklendirilmesi gerekir. Geleneksel ÇKKV yöntemleri, bu kriterler arasında sabit ağırlıklar atarken, derin öğrenme modelleri kriterler arasındaki doğrusal olmayan ilişkileri öğrenerek daha esnek ve veri odaklı çözümler üretebilir (Goodfellow et al., 2016). Bu, karar vericilere daha gerçekçi ve bağlama duyarlı öneriler sunar.

Örnek olarak, bir sağlık hizmetleri dağıtım sisteminde; hasta memnuniyeti, tedavi süresi, maliyet, kaynak kullanımı gibi kriterler arasında denge kurmak gerekir. Derin öğrenme, geçmiş hastane verileri üzerinden bu kriterler arasındaki karmaşık ilişkileri öğrenerek, farklı senaryolar için optimal çözümler sunabilir. Bu noktada, derin öğrenme kararları açıklanabilirlik açısından desteklemek için karar ağacı gibi yöntemlerle de hibrit modeller oluşturmak mümkündür (Zhang et al., 2020).

Sonuç olarak, derin öğrenme ÇKKV'nin yerine geçmekten ziyade, onu destekleyen ve genişleten bir araçtır. Özellikle yüksek boyutlu ve karmaşık

veri ortamlarında, klasik yöntemlerin ötesinde sezgisel çıkarımlar yapılmasını sağlar. Gelecekte, derin öğrenme tabanlı karar destek sistemlerinin, insan uzmanlığıyla entegre şekilde çalışarak, çok kriterli karar süreçlerini daha etkili ve özerk hale getirmesi beklenmektedir.

7.1 Derin Öğrenmenin ÇKKV'ye Katkısı

ÇKKV problemleri yüksek boyutlu ve heterojen veri setleri içerdiğinde, derin öğrenme modelleri ön plana çıkar (Goodfellow, Bengio, & Courville, 2016). Özellikle görüntü, metin ve zaman serisi verilerinin entegre edildiği karar problemlerinde derin öğrenme, diğer yöntemlere kıyasla üstün performans sağlamaktadır (Zhang, Yang, & Xu, 2020).

Örneğin, sağlık sektöründe hastaların medikal görüntüleri ile elektronik sağlık kayıtlarının birlikte değerlendirilerek kişiselleştirilmiş tedavi planlarının oluşturulması mümkündür (Esteva et al., 2017).

7.2 Derin Öğrenme Modellerinin Açıklanabilirliği

Derin öğrenme modelleri genellikle “kara kutu” olarak adlandırılmakta, bu da karar süreçlerinde güvenilirlik sorunlarına yol açmaktadır. Bu nedenle açıklanabilir yapay zekâ (XAI) yöntemleri geliştirilmiş ve derin modellerin kararlarını şeffaflaştırmak amaçlanmıştır (Samek, Wiegand, & Müller, 2017).

SHAP (SHapley Additive exPlanations) ve LIME (Local Interpretable Model-agnostic Explanations) gibi yöntemler, kriterlerin karar üzerindeki etkisini sayısal ve görsel olarak analiz etmeye olanak tanımaktadır (Ribeiro, Singh, & Guestrin, 2016; Lundberg & Lee, 2017).

8. Model Performansının Değerlendirilmesi

ÇKKV ile MÖ modellerinin başarısı, uygun performans ölçütleri ile değerlendirilmelidir. Bu ölçütler hem doğruluk hem de modelin açıklanabilirliğini içermektedir.

8.1 Performans Ölçütleri

- **Doğruluk, Hassasiyet, Geri Çağırım (Accuracy, Precision, Recall):** Sınıflandırma tabanlı modeller için temel ölçütlerdir (Powers, 2011).
- **ROC Eğrisi ve AUC (Area Under Curve):** Modelin genel performansını gösterir (Fawcett, 2006).
- **Kappa İstatistiği:** Sınıflandırma modellerinin rastgele tahminden farkını ölçer (Cohen, 1960).

- **Model Karmaşıklığı:** Parametre sayısı ve hesaplama süresi de göz önünde bulundurulmalıdır (Bishop, 2006).

8.2 Model Kararının Açıklanabilirlik Değerlendirmesi

Modelin karar sürecini ne kadar iyi açıkladığı, kullanıcı güveni açısından önemlidir. Açıklanabilirlik yöntemlerinin uygulanması, sistemin benimsenmesini kolaylaştırır (Vellido et al., 2012).

9. Etik, Güvenlik ve Yasal Düzenlemeler

ÇKKV ve MÖ entegrasyonunda etik ve yasal konular kritik öneme sahiptir. Özellikle karar destek sistemleri insanların hayatını etkileyen sonuçlar doğurabileceğinden, tarafsızlık, gizlilik ve şeffaflık temel unsurlardır (Mittelstadt et al, 2016).

9.1 Etik İlkeler

- **Adalet:** Modellerin önyargısız ve ayrımcı olmayan kararlar vermesi gerekir (Veale & Binns, 2017).
- **Gizlilik:** Veri sahiplerinin haklarına saygı gösterilmeli ve kişisel bilgiler korunmalıdır (Dwork, 2006).
- **Şeffaflık:** Karar süreçleri kullanıcılar ve paydaşlar için anlaşılır ve izlenebilir olmalıdır (Doshi-Velez & Kim, 2017).

9.2 Güvenlik Riskleri

Makine öğrenmesi modelleri, özellikle derin öğrenme tabanlı olanlar, manipülasyona açıktır. Adversarial saldırılar ve veri sızıntıları, sistemlerin güvenilirliğini ciddi şekilde tehdit etmektedir (Szegedy et al., 2014). Bu nedenle, güvenlik protokolleri geliştirilmesi ve modellerin sürekli izlenmesi zorunludur (Papernot et al., 2018).

9.3 Yasal Düzenlemeler

Avrupa Birliği'nin Genel Veri Koruma Yönetmeliği (GDPR), kişisel verilerin korunması konusunda sıkı standartlar getirmiştir (Voigt & Von dem Bussche, 2017). Bu tür yasal düzenlemeler, ÇKKV ve makine öğrenmesi sistemlerinin tasarım ve uygulama süreçlerinde dikkate alınmalıdır.

10. Gelecek Araştırma Yönelimleri

ÇKKV ve makine öğrenmesinin entegrasyonunda halen pek çok açık konu bulunmaktadır:

- **Gerçek zamanlı karar destek sistemleri geliştirilmesi:** Hızla değişen ortamlara uyarlabilir modeller (Nguyen et al., 2020).
- **Açıklanabilir derin öğrenme yöntemlerinin geliştirilmesi:** Kullanıcı dostu, güvenilir modeller (Adadi & Berrada, 2018).
- **Çoklu karar verici sistemleri:** Farklı paydaşların tercihlerinin bütünleştirilmesi (Nguyen & Nahavandi, 2017).
- **Etik ve sosyal etkilerin modellenmesi:** Kararların toplumsal etkilerinin analiz edilmesi (Greene, Hoffmann, & Stark, 2019).

11. Sonuç ve Öneriler

Çok kriterli karar verme problemlerinin çözümünde makine öğrenmesi yaklaşımları, klasik yöntemlerin sınırlarını aşmakta ve daha dinamik, veriye dayalı karar süreçleri geliştirmektedir. Bu yöntemin başarı anahtarları problemlerdeki modellerin daha açıklanabilir ve etik sorumlulukların olması olarak belirtilebilir.

Bu çalışma, çok kriterli karar verme yöntemleri ile makine öğrenmesinin entegrasyonunun teorik ve uygulamalı yönlerini kapsamlı biçimde ele almıştır. Veri odaklı ve dinamik karar problemlerinde bu hibrit yaklaşımlar performans ve esneklik açısından önemli avantajlar sağlamaktadır. Ancak açıklana bilirlik, etik, güvenlik ve yasal uyumluluk gibi alanlarda halen aşılması gereken zorluklar bulunmaktadır. Birçok ülkede yapılan çalışmalar da bu doğrultuda gelişmekte olup, özellikle yerel veri setleriyle uyumlu modellerin geliştirilmesi, alan için kritik bir gereklilik olarak öne çıkmaktadır (Özdemir & Şahin, 2021; Yıldırım & Kaya, 2019).

Gelecekte, derin öğrenme tabanlı XAI yöntemlerinin, gerçek zamanlı karar destek sistemlerinde kullanımı, pekiştirmeli öğrenme ile çevresel değişimlere adaptasyon ve etik karar yapılarının matematiksel modellenmesi araştırma alanları olacaktır (Rawls, 1971; Kahneman, 2011).

Kaynakça

- Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: A survey on explainable artificial intelligence (XAI). *IEEE Access*, 6, 52138–52160. <https://doi.org/10.1109/ACCESS.2018.2870052>
- Bana e Costa, C. A., & Vansnick, J. C. (1994). MACBETH—An interactive path towards the construction of cardinal value functions. *International Transactions in Operational Research*, 1(4), 489–500. <https://doi.org/10.1111/j.1475-3995.1994.00369.x>
- Bilgin, G. (2021). Makine öğrenmesi algoritmaları kullanarak erken dönemde diyabet hastalığı riskinin araştırılması. *Journal of Intelligent Systems: Theory and Applications*, 4(1), 55-64.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Brans, J. P., & Mareschal, B. (2005). PROMETHEE methods. In J. Figueira, S. Greco, & M. Ehrgott (Eds.), *Multiple criteria decision analysis: State of the art surveys* (pp. 163–195). Springer. https://doi.org/10.1007/978-1-4939-3094-4_6
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Chan, F. T. S., Kumar, V., Tiwari, M. K., Lau, H. C. W., & Choy, K. L. (2017). Supplier selection: A review of literature and an integrated framework. *Computers & Industrial Engineering*, 106, 212-223.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMO-TE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357. <https://doi.org/10.1613/jair.953>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *KDD*.
- Chen, S. J., Hwang, C. L., & Hwang, F. P. (1992). Fuzzy multiple attribute decision making: Methods and applications. Springer.
- Chen, W., Liu, L., Xu, X., & Li, J. (2021). Integrating machine learning in multi-criteria decision-making. *Expert Systems with Applications*, 173, 114624.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. Çelik, F., & Yılmaz, S. (2020). Enerji sektöründe çok kriterli karar verme yöntemlerinin uygulanması. *Enerji ve Yönetim Dergisi*, 12(2), 89-102.
- Delen, D., & Zolbanin, H. M. (2018). The analytics paradigm in business research. *Journal of Business Research*, 90, 186–195.
- Deng, J. (1989). Introduction to grey system theory. *The Journal of Grey System*, 1(1), 1–24.
- Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. arXiv preprint arXiv:1702.08608.

- Dwork, C. (2006). Differential privacy. In Proceedings of the 33rd International Colloquium on Automata, Languages and Programming (ss. 1-12).
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Fontela, E., & Gabus, A. (1976). The DEMATEL Observer: DEMATEL 1976 Report. Battelle Geneva Research Center.
- Greene, D., Hoffmann, A. L., & Stark, L. (2019). Better, nicer, clearer, fairer: A critical assessment of the movement for ethical artificial intelligence and machine learning. In *Proceedings of the 52nd Hawaii International Conference on System Sciences* (pp. 2122–2131). University of Hawai'i at Manoa. <https://doi.org/10.24251/HICSS.2019.258>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press.
- Göksu, S., Sezen, B., & Balcıoğlu, Y. S. (2025). Production performance prediction using machine learning. *Kahramanmaraş Sütçü İmam University Journal of Engineering Sciences*, 28(1), 65–79.28(1), 65–79.
- He, H., & Garcia, E. A. (2009). Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9), 1263–1284.
- Holland, J. H. (1992). Genetic algorithms. *Scientific American*, 267(1), 66-73.
- Hwang, C. L., & Yoon, K. (1981). *Multiple Attribute Decision Making*. Springer.
- Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*, 31(8), 651–666.
- Kahneman, D. (2011). *Thinking, Fast and Slow*. Farrar, Straus and Giroux.
- Kahraman, C., Cebeci, U., & Ulukan, Z. (2007). Multi-criteria supplier selection using fuzzy AHP. *Logistics Information Management*, 16(6), 382–394. <https://doi.org/10.1108/09576050310503367>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *NIPS*. 30, 4765–4774.
- Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S., & Floridi, L. (2016). The ethics of algorithms: Mapping the debate. *Big Data & Society*, 3(2), 2053951716679679.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529–533. <https://doi.org/10.1038/nature14236>

- Nguyen, T., & Nahavandi, S. (2017). Multi-criteria decision making: An overview of different methods and applications. *IEEE Systems Journal*, 11(4), 4119–4121. <https://doi.org/10.1109/JSYST.2016.2600721>
- Opricovic, S., & Tzeng, G. H. (2004). Compromise solution by MCDM methods: A comparative analysis of VIKOR and TOPSIS. *European Journal of Operational Research*, 156(2), 445–455. [https://doi.org/10.1016/S0377-2217\(03\)00020-1](https://doi.org/10.1016/S0377-2217(03)00020-1)
- Özdemir, A., & Şahin, S. (2021). The Impact of Data Preprocessing Techniques on Performance in Machine Learning-Based Decision Support Systems. *Journal of Information Technologies*, 14(2), 112–123.
- Quinlan, J. R. (1993). *C4.5: Programs for Machine Learning*. Morgan Kaufmann.
- Papernot, N., McDaniel, P., Goodfellow, I., Jha, S., Celik, Z. B., & Swami, A. (2018). Practical black-box attacks against machine learning. In *Proceedings of the 2017 ACM on Asia Conference on Computer and Communications Security* (ss. 506–519).
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63.
- Rawls, J. (1971). *A Theory of Justice*. Harvard University Press.
- Rezaei, J. (2015). Best-worst multi-criteria decision-making method. *Omega*, 53, 49–57. <https://doi.org/10.1016/j.omega.2014.11.009>
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “Why should I trust you?”: Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 1135–1144). ACM. <https://doi.org/10.1145/2939672.2939778>
- Saaty, T. L. (1980). *The Analytic Hierarchy Process*: Planning, priority setting, resource allocation. McGraw-Hill.
- Saaty, T. L. (1996). *Decision making with dependence and feedback: The analytic network process*. RWS Publications.
- Samek, W., Wiegand, T., & Müller, K. R. (2017). Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models. *IEEE Signal Processing Magazine*, 34(6), 52–65. <https://doi.org/10.1109/MSP.2017.2745201>
- Shannon, C. E. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27(3), 379–423. <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>
- Shapley, L. S. (1953). A value for n-person games. *Contributions to the Theory of Games*, 2, 307–317.
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction*. MIT Press.

- Szegedy, C., Zaremba, W., Sutskever, I., Bruna, J., Erhan, D., Goodfellow, I., & Fergus, R. (2014). Intriguing properties of neural networks. arXiv preprint arXiv:1312.6199.
- Tsai, C.-F., & Hsu, Y.-F. (2013). Combining decision trees and data mining techniques for MCDM. *Expert Systems with Applications*, 40(9), 3525-3536.
- Tsai, C.-F., & Chou, S.-C. (2014). Hybrid MCDM and clustering approaches. *Applied Soft Computing*, 24, 76-84.
- Tzeng, G. H., Chiang, C. H., & Li, C. W. (2007). Evaluating intertwined effects in e-learning programs: A novel hybrid MCDM model based on factor analysis and DEMATEL. *Expert Systems with Applications*, 32(4), 1028-1044. <https://doi.org/10.1016/j.eswa.2006.02.004>
- Wang, J., Zhang, X., & Yang, Y. (2018). Multi-criteria decision-making approach for power plant site selection. *Energy*, 165, 765-776.
- Veale, M., & Binns, R. (2017). Fairness in machine learning. *IEEE Symposium on Security and Privacy Workshops*.
- Vellido, A., Martín-Guerrero, J. D., & Lisboa, P. J. G. (2012). Making machine learning models interpretable. In *Proceedings of the 20th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN 2012)* (pp. 163-172). i6doc Publishing.
- Voigt, P., & Von dem Bussche, A. (2017). The EU General Data Protection Regulation (GDPR). Springer.
- Yıldırım, E., & Kaya, Ö. (2019). Application of Multi-Criteria Decision-Making Methods in the Healthcare Sector: The Case of Turkey. *Journal of Industrial Engineering*, 30(4), 245-256.
- Zhang, Z., Zhao, L., & Wang, J. (2020). A hybrid deep learning framework for multi-criteria decision making. *Expert Systems with Applications*, 159, 113571. <https://doi.org/10.1016/j.eswa.2020.113571>
- Zopounidis, C., & Doumpos, M. (2002). Multicriteria classification and sorting methods: A literature review. *European Journal of Operational Research*, 138(2), 229-246. [https://doi.org/10.1016/S0377-2217\(01\)00153-6](https://doi.org/10.1016/S0377-2217(01)00153-6)

Finansal Zaman Serisi Tahminlerinde Makine Öğrenmesi Uygulamaları 6

Özge Dinç Cavlak¹

Özet

Mevcut çalışma, finansal zaman serisi tahminlerinde kullanılan çeşitli makine öğrenmesi algoritmalarını inceleyerek, genel bir çerçeve çizmeyi amaçlamaktadır. Çalışmada, finansal zaman serisi tahminlerinde yaygın olarak kullanılan ağaç tabanlı Rastgele Ormanlar (Random Forests, RF), Aşırı Gradyan Artırma (Extreme Gradient Boosting, XGBoost), CatBoost (Categorical Boosting), Hafif Gradyan Artırma Makinesi (Light Gradient Boosting Machine, LightGBM) ve Doğal Gradyan Artırma (Natural Gradient Boosting, NGBoost) modelleri hakkında bilgi verilmektedir. Ardından, girdi değişkenlerin katkısını ölçerek, makine öğrenmesi modellerinin yorumlanabilirliğini arttıran SHAP yaklaşımı açıklanmaktadır. Son olarak, makine öğrenmesi algoritmaları kullanılarak gerçekleştirilen finansal zaman serisi tahminleri, hisse senedi, tahvil ve emtia piyasaları üzerinden tartışılarak, bu modellerin tahmin performansı ve etkililiği gösterilmektedir. Makine öğrenmesi modellerinin hisse senedi ve tahvil piyasalarının yanı sıra, ham petrol, doğal gaz, altın, tarımsal ürünler gibi emtia fiyatlarını tahminde üstün performans gösterdikleri belirtilmektedir. Ayrıca, bu modellerin yeşil enerji hisse senedi ve yeşil tahvil fiyatlarını tahmin etmede etkili oldukları öne sürülerek; yatırım kararları, politika oluşturma ve sürdürülebilir enerji dönüşümü için önemi vurgulanmaktadır. Sonuç olarak yenilikçi makine öğrenmesi modelleri, finansal zaman serisi tahminlerinde oldukça üstün performans göstermekte; tahmin doğruluğu, yorumlanabilirlik ve doğrusal olmayan örüntüleri yansıtabilme gibi avantajlar sunması bakımından önem arz etmektedir.

1 Dr. Öğr. Üyesi, Ankara Hacı Bayram Veli Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, ozge.dinc@hvb.edu.tr, ORCID: <https://orcid.org/0000-0002-7728-983X>

1. Giriş

Tahmin, bireylerin ve örgütlerin proaktif karar alma ve politika geliştirme süreçlerinde önemli rol oynamaktadır (Kumar vd., 2023). Tahmin doğruluğu kadar, tahmin modeli çıktıları doğru bir biçimde yorumlayabilmenin de kritik bir öneme sahip olduğu ifade edilmektedir (Lundberg ve Lee, 2017). Özellikle finansal zaman serisi modellerinde, yüksek düzeyde rastgelelik ve artıkların bulunmaması gibi durumlar nedeniyle tahmin zorlukları söz konusu olabilmektedir (Kumar vd., 2023). Bu doğrultuda, finansal zaman serisi tahminlerinde doğruluğu artıran ve karmaşık yapıları öngörebilen makine öğrenmesi modelleri tercih edilmektedir. Murphy (2012) makine öğrenmesini, verideki örüntüleri otomatik bir biçimde tespit edebilen bir dizi yöntemi içeren ve bu örüntüleri, gelecek verileri tahmin etmede veya diğer belirsizlik altında karar verme durumlarında kullanan bir yöntem olarak tanımlamaktadır. Bertolini vd. (2021) bu tanımlı genişleterek makine öğrenmesini, veriden bilgi üreten bir dizi yöntem ve algoritma olarak tanımlarken; deneyimden öğrenme yeteneğini sürekli olarak geliştirdiğini ifade etmektedir. Geleneksel istatistiksel yöntemler, örnekleme ilişkin dağılımlar ve doğrusallık gibi birtakım varsayımlar gerektirdiğinden, bu yöntemlerin durağan olmayan ve doğrusal olmayan zaman serisi verileri üzerinde etkisi sınırlı olmakta; makine öğrenmesi modellerinin, örneklem dağılımına ilişkin az sayıda varsayım ile doğrusal olmayan örüntüleri yansıtabilmesi bakımından, zaman serileri analizlerinde güvenilir yöntemler olduğu belirtilmektedir (Lv vd., 2022). Bunun yanı sıra, ağaç tabanlı modeller, yaygın kullanılan denetimli makine öğrenmesi yöntemleri arasında yer almakta; tahmin modellerinin doğruluğunu ve yorumlanabilirliğini iyileştirme, doğrusal olmayan ilişkileri yansıtabilme, sınıflandırma ve regresyon problemlerine uyarlanabilme yetenekleriyle ön plana çıkmaktadır (Rady vd., 2021).

Makine öğrenmesi modellerinin zaman serisi tahminlerinde sunduğu bu avantajlar değerlendirildiğinde, bu modellerin, doğruluk, yorumlanabilirlik ve etkili tahminler sunarak finansal zaman serisi tahmini literatürüne derin bir anlayış kazandırdığı görülmektedir. Bu kapsamda, mevcut çalışma, ağaç tabanlı makine öğrenmesi algoritmalarını özetleyerek; bu algoritmaların, hisse senedi, tahvil ve emtia piyasalarını tahmin performanslarını değerlendirmektedir. Ayrıca, yeşil enerji hisse senedi, yeşil tahvil ve temiz enerji gibi araçların tahmin performanslarına odaklanan çalışmalara yer vererek, yatırımcılar ve politika yapımcılar için önemli çıkarımlar sunmaktadır.

2. Ağaç Tabanlı Makine Öğrenmesi Modelleri

Mevcut çalışma, finansal zaman serisi tahminlerinde yaygın olarak kullanılan ağaç tabanlı makine öğrenmesi modellerini ele alarak, tahmin bağlamında özetlemeyi amaçlamaktadır.

2.1. Rastgele Ormanlar

Breiman (2001) tarafından geliştirilen Rasgele Ormanlar (Random Forests, RF), her bir karar ağacı için bağımsız ve aynı dağılıma sahip rastgele vektörler üreterek birden çok karar ağacı oluşturan bir topluluk öğrenimi yöntemidir. Buna göre, bu vektör ve eğitim seti kullanılarak ağaç büyütülür ve bir sınıflandırıcı üretilir. Ormandaki ağaç sayısı arttıkça, genelleme hatası belirli bir değere yakınsamaktadır. Bir ormandaki ağaç sınıflandırıcılarının genelleme hatası, ormandaki bireysel ağaçların gücüne ve aralarındaki korelasyona bağlı olmakta; daha düşük genelleme hatası, rastgele ormanların sınıflandırıcılar arasında daha düşük korelasyona ve daha yüksek güce sahip olduğunu göstermektedir. Büyük sayılar kanunu sayesinde daha fazla ağaç eklendikçe aşırı öğrenme söz konusu olmamakta; bu da RF algoritmasının etkili bir tahmin aracı olduğunu göstermektedir. Rastgele bir vektöre bağlı birden çok karar ağacından oluşan ve bu ağaçların ortalaması alınarak oluşturulan RF tahmin modeli, Eşitlik 1’de verilmektedir;

$$\hat{Y} = \frac{1}{q} \sum_{i=1}^q g_i(x) \quad (1)$$

Burada $g_i(x)$, i. rastgele ağaçlar kümesini ve x , girdi özellikleri vektörünü ifade etmektedir.

2.2. Gradyan Artırma Modelleri

Friedman (2002) tarafından geliştirilen Gradyan Artırma (Gradient Boosting), fonksiyon tahminini parametre uzayından ziyade fonksiyon uzayında sayısal optimizasyon perspektifinden ele alan; sınıflandırma ve regresyon temelli bir topluluk öğrenimi yöntemidir. Gradyan Artırma, en küçük kareler yöntemi ile bir zayıf öğreneni ardışık olarak mevcut sözde artıklar üzerine modelleyerek, eklemeli regresyon modelleri oluşturmaktadır. Sözde artıklar, her bir eğitim veri noktasındaki model değerlerine göre minimize edilmekte olan kayıp fonksiyonunun gradyanı olarak ifade edilmektedir. Sürece rastgeleliğin dahil edilmesi, yakınsama doğruluğunu ve çalışma hızını arttırmaktadır. Her bir adımda eğitim verisi setinin tümünden rastgele olarak bir alt küme çekilerek, bu rastgele seçilen altkümenin zayıf öğreneni eğitmek ve model güncellemesini hesaplamak amacıyla kullanıldığı

ifade edilmektedir. Gradyan Artırma algoritmasının doğruluğunun bu rastgeleştirme süreci sayesinde arttığı; bu artışın derecesinin eğitim seti büyüklüğü, doğru hedef fonksiyon, koşullu dağılım ve zayıf öğrenenin kapasitesine bağlı olduğu belirtilmektedir.

Gradyan Artırma, farklı durumlarda son teknoloji sonuçlar elde edebilen güçlü bir makine öğrenmesi tekniği olarak heterojen özellikler, gürültülü veriler ve karmaşık bağımlılıkların bulunduğu öğrenme problemleri için temel bir yöntem olarak uygulanmaktadır (Prokhorenkova vd., 2018). Bu yöntem, işlevsel bir uzayda zayıf modellerin yinelemeli olarak birleştirilmesiyle güçlü tahminleyicilerin nasıl oluşturulabileceğini teorik olarak açıklamaktadır (Dorogush vd., 2018).

Mevcut çalışmada, *Aşırı Gradyan Artırma* (Extreme Gradient Boosting, XGBoost), *CatBoost* (Categorical Boosting), *Hafif Gradyan Artırma Makinesi* (Light Gradient Boosting Machine, LightGBM) ve *Doğal Gradyan Artırma* (Natural Gradient Boosting, NGBost) modellerine yer verilmektedir.

2.2.1. Aşırı Gradyan Artırma

Chen ve Guestrin (2016) tarafından geliştirilen Aşırı Gradyan Artırma (Extreme Gradient Boosting, XGBoost), ölçeklenebilir ağaç artırımına dayalı bir topluluk öğrenimi yöntemidir. Böylelikle, seyrek verilerin işlenebilmesi, öğrenme sürecinin hızlanması ve daha hızlı model keşfine olanak vermektedir. XGBoost, seyrek veriye duyarlı algoritma, ağırlıklı çeyreklik özetleme, önbellek erişim örüntüleri, veri sıkıştırma ve parçalama gibi önemli sistemler ve algoritmik optimizasyonlar kullanarak en az küme kaynağı ile daha büyük çapta örnekleri modelleyebilmektedir. XGBoost algoritmasına ilişkin tahmin modeli, Eşitlik 2'de belirtilmektedir;

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), \quad f_k \in F \quad (2)$$

Burada, $\hat{y}_i$ model tahminini, K toplam ağaç sayısını; f_k , k . ağaç tahminini, x_i , girdi özellik vektörünü ve F olası regresyon ağaçları kümesini ifade etmektedir.

2.2.2. CatBoost

Yandex araştırmacıları tarafından geliştirilen gradyan artırma tabanlı CatBoost (Categorical Boosting) algoritması, klasik algoritmaya alternatif olarak permütasyona dayalı sıralı artırma tekniğinin uygulanması ve kategorik özelliklerin işlenmesine yönelik yenilikçi bir alternatif sunmaktadır

(Prokhorenkova vd., 2018). Bu yöntem, kategorik özellikleri başarılı bir şekilde işleyebilen ve bu özellikleri ön işleme aşamasında ele almak yerine eğitim süreci sırasında ele alan bir gradyan artırma algoritması sunmaktadır. CatBoost algoritması, ağaç yapısı seçiminde yeni bir şema kullanarak aşırı öğrenmeyi azaltmakta; hızlı bir eğitim süreci sağlayarak benzer büyüklükteki topluluk modelleri uygulamalarından daha iyi performans gösteren puanlama uygulamaları içermektedir (Dorogush vd., 2018). Sıralı artırma prosedürü uygulanarak geliştirilen tahmin modeli, Eşitlik 3'te verilmektedir;

$$h^t = \arg \min_{h \in H} \frac{1}{n} \sum_{k=1}^n \left(-g^t(x_k, y_k) - h(x_k) \right)^2 \quad (3)$$

Burada $g^t(x_k, y_k)$, koşullu gradyan dağılımını ve $h(x_k)$, temel tahminleyiciyi göstermektedir.

2.2.3. Hafif Gradyan Artırma Makinesi

Hafif Gradyan Artırma Makinesi (Light Gradient Boosting Machine, LightGBM) algoritması, geleneksel gradyan artırmalı karar ağaçlarının büyük veriyi işlerken karşılaştığı hesaplama karmaşıklığı ve işlem süresi problemlerini gidermek amacıyla Ke vd. (2017) tarafından geliştirilmiştir. Bu algoritma, gradyan tabanlı tek taraflı örnekleme ve ayrıcalıklı özellik desteleme olmak üzere iki yenilikçi teknik kullanarak, hesaplama hızı, doğruluk ve verimli bellek kullanımı açısından üstünlük sağlamaktadır. LightGBM, karar ağaçlarının eğitilmesi sürecinde diğer gradyan artırma algoritmalarında kullanılan seviye bazlı büyüme stratejisi yerine, yaprak bazlı büyüme stratejisini kullanmaktadır (Ke vd., 2017; Üstüner vd., 2020). LightGBM modeli, Eşitlik 4'te verilmektedir.

$$\hat{Y} = \sum_{i=1}^T g_i(x) \quad (4)$$

Burada $g_i(x)$, regresyon ağaçlarını; T ağaç sayısını göstermektedir (Kocaarslan ve Mushtağ, 2024).

2.2.4. Doğal Gradyan Artırma

Duan vd. (2020) tarafından geliştirilen Doğal Gradyan Artırma (Natural Gradient Boosting, NGBoost) algoritması, gradyan artırma temelli olasılıksal regresyon tahmin modelleri ortaya koymaktadır. Buna

göre NGBoost, çok parametrelili bir artırma algoritmasını doğal gradyan ile birleştirerek, varsayılan çıktı dağılımı parametrelerinin gözlemlenen özelliklere göre nasıl değiştiğini verimli bir biçimde ortaya koyan, olasılıksal bir tahmin yöntemidir. NGBoost, gradyan artırma yöntemini olasılıksal regresyona genelleyerek, koşullu dağılımın parametrelerini çok parametrelili bir artırma algoritmasının hedefleri olarak ele almaktadır. Bu bağlamda algoritma, temel öğrenen, sürekli parametrelili herhangi bir dağılım ailesi ve herhangi bir puanlama kuralı ile kullanılabilir; esneklik, ölçeklenebilirlik ve genel uygulanabilirlik gibi avantajlar sağlamaktadır. NGBoost, gerçek değerli parametreler kümesiyle tanımlanan bir dağılım ailesinin seçimine ve parametrelerin değişkenler arasında değişimine olanak vermektedir. Ayrıca NGBoost, geleneksel artırma algoritmalarının aynı verimli karmaşıklığı ile çok sayıda özellik veya gözleme ölçeklenmekte; sınıflandırma ve regresyon problemlerini etkili bir biçimde ele alabilmektedir. Duan vd. (2020) gerçekleştirdikleri deneylerinde çok parametrelili artırma ve doğal gradyanın birlikte çalışarak performansı artırdığını belirtmektedir. Bu algoritma, olasılıksal tahmin için denetimli bir öğrenme yöntemi olarak tanımlanmakta; koşullu olasılık dağılımı $P_\theta(y|x)$ parametrelerini, artırma kullanarak x 'in bir fonksiyonu olarak tahmin etmektedir.

3. SHAP

Oyun teorisine dayalı (Shapley, 1953) SHAP (SHapley Additive exPlanations) değerleri, Lundberg ve Lee (2017) tarafından geliştirilerek, topluluk ya da derin öğrenme gibi karmaşık modellerin yorumlanabilmesine olanak sağlayan bütünlüklü bir SHAP yaklaşımı sunmaktadır. Yazarlar, basit modellerin daha rahat yorumlanabildiğini ancak bu tür modellerde tahmin doğruluğu sorunları yaşanabildiğini belirterek; karmaşık modellerin daha doğru sonuçlar ürettiğini ifade etmektedirler. Bu kapsamda, karmaşık modellerin kullanılmasıyla birlikte model çıktılarının doğruluğu ve yorumlanabilirliği arasındaki dengenin ön plana çıktığı; bütünlüklü yenilikçi bir yaklaşım sunularak, model tahminlerinin yorumlanabilmesine olanak verildiği belirtilmektedir. SHAP yaklaşımının, eklemeli özellik katkı yöntemlerini birleştirerek, yerel doğruluk, eksiklik ve tutarlılık özelliklerini barındıran bir yapı ortaya koyduğu ifade edilmektedir.

Lundberg vd. (2018), SHAP değerlerini etkileşim öğelerini kapsayacak şekilde geliştirerek, ağaç topluluk yöntemlerinden elde edilen tahminlerin yorumlanmasında kullanmakta; üstel hız kazanımları, denetimli kümeleme, SHAP bağımlılık grafikleri ve SHAP özet grafikleri ile bu modellere daha derin bir anlayış kazandırmaktadır.

SHAP yaklaşımı, her bir açıklayıcı değişkenin katkısını ölçerek makine öğrenmesi modellerini açıklamakta; doğruluk ve tutarlılık gibi avantajlar sağlayarak modelin yorumlanabilmesine olanak sunmaktadır (Choi vd., 2025).

4. Finansal Piyasaların Tahminlerinde Makine Öğrenmesi Modelleri

Finansal piyasalar, makroekonomik risk faktörleri, jeopolitik riskler, piyasa oynaklıkları ve petrol fiyatı belirsizlikleri gibi pek çok faktörden etkilenmekte; bu nedenle bu piyasaların doğru ve etkin bir biçimde tahmini zorlu bir süreç halini almaktadır. Finansal piyasaların geleneksel zaman serisi modelleri kullanılarak tahmin edilmesinin yanı sıra, yenilikçi makine öğrenmesi yöntemlerinin özellikle hisse senedi, tahvil, enerji, emtia piyasaları ve oynaklık tahminlerinde kullanıldığı örnekler, ilgili yazında yer almaktadır (bkz. Ghallabi vd., 2025; Jabeur vd., 2021; Kocaarslan ve Soytas, 2023; Lahmiri, 2024; Prasad ve Bakhshi, 2022; Soltani vd., 2024). Makine öğrenmesi algoritmaları, ekonomik ve finansal faktörlerin karmaşık ve doğrusal olmayan özelliklerini dikkate alarak önemli avantajlar sağlamaktadır (Jabeur vd., 2021). Bu nedenle mevcut çalışma, ilgili literatürde son yıllarda yapılan çalışmaları inceleyerek, yenilikçi makine öğrenmesi algoritmalarının finansal zaman serisi tahminlerindeki performanslarına odaklanmaktadır.

4.1. Hisse Senedi Piyasaları

Hisse senedi piyasaları, küresel finansal sistemin temel unsurlarından biri olarak oldukça karmaşık ve kaotik bir yapıya sahip olup; hisse senedi tahminleri, yatırımcıların, analistlerin ve araştırmacıların odak noktası haline gelmiştir (Gupta vd., 2025). Ancak bu karmaşık yapı, hisse senedi fiyat hareketlerinin etkili bir şekilde tahminini güçleştirmektedir (Kara vd., 2011). Bu bağlamda, yenilikçi makine öğrenmesi modellerinin hisse senedi tahminindeki performanslarını değerlendirmek, etkili portföy ve riskten kaçınma stratejileri geliştirebilmek için kritik bir öneme sahiptir. Ghallabi vd. (2025) temiz enerji hisse senedi fiyatlarını ESG (Environmental, Social, Governance) hisse senedi piyasalarını analiz ederek makine öğrenmesi modelleriyle tahmin etmişlerdir. Bu bağlamda, ESG hisse senedi fiyatlarının temiz enerji fiyatları üzerindeki tahmin edici gücünü karşılaştırmak amacıyla RF, XGBoost, CatBoost, LightGBM, SVM (Destek Vektör Makineleri) ve NGBoost algoritmaları kullanılmaktadır. Model performansları, Doğruluk Skoru, F1 Skoru, ortalama karesel hata (Mean Squared Error, MSE) ve Eğri Altında Kalan Alan metrikleri ile karşılaştırılarak, en iyi performans gösteren modelin NGBoost olduğu gösterilmektedir. Araştırmanın sonuçları,

NGBoost modelinin diğer modellere üstünlük sağladığını; temiz enerji hisse senedi fiyatları ile ESG piyasaları değişkenleri arasında güçlü bir ilişki olduğunu ileri sürmektedir. Ayrıca araştırmacılar, SHAP yöntemi kullanılarak şeffaflığın ve yorumlanabilirliğin arttırıldığını belirtmektedirler. Son olarak, makine öğrenmesi modellerinin yeşil enerji hisse senedi fiyatlarını tahmin etmede başarılı olduğu, bu bulgunun yatırım kararları, politika oluşturma ve sürdürülebilir enerji dönüşümü için önemi vurgulanmaktadır.

Bunun yanı sıra, çeşitli ülkelerin hisse senedi piyasaları, makine öğrenmesi yöntemleriyle tahmin edilmekte ve bu modellerin üstün performans gösterdikleri ortaya konmaktadır. Zhao (2021), Nepal örneği üzerinden hisse senedi piyasalarının tahmininde SVM ve XGBoost'un en iyi performans gösteren modeller olduğunu belirtmektedir. Choi vd. (2024), Kore hisse senedi getirilerini çeşitli makine öğrenmesi modelleri kullanarak tahmin etmekte; LightGBM modelinin üstün performans sergilediğini belirtmektedir. Sharma ve Jain (2023), hisse senedi tahminlerinde çeşitli makine öğrenmesi modelleri kullanarak, XGBoost'un hisse senedi tahmininde etkin bir model olduğunu ortaya koymaktadırlar.

4.2. Tahvil Piyasaları

Kocaarslan ve Soytaş (2023) geleneksel tahvil, hisse senedi ve enerji emtia piyasaları ile ekonomik risk faktörlerinin ABD belediye yeşil tahvilleri üzerindeki etkilerini RF, XGBoost, CatBoost ve LightGBM algoritmaları kullanarak COVID-19 öncesi ve sonrası dönem için tahmin etmektedirler. Model performanslarının değerlendirilmesi amacıyla, ortalama mutlak hata (Mean Absolute Error, MAE), belirtme katsayısı (R^2), ortalama karesel hata (Mean Squared Error, MSE) ve kök ortalama karesel hata (Root Mean Squared Error, RMSE) metrikleri kullanılmış ve modellerin tahmin edici güçleri ortaya konmuştur. Veri, eğitim ve test setleri olarak ayrılarak en uygun parametre kombinasyonunu belirlemek amacıyla çapraz doğrulama tekniği uygulanmıştır. Araştırmanın sonuçları, COVID-19 öncesinde en iyi performans gösteren modelin XGBoost; COVID-19 dönemi için ise en iyi performans gösteren modelin CatBoost olduğunu göstermektedir. Ardından SHAP yaklaşımı kullanılarak girdi değişkenlerin yanıt değişkeni üzerindeki göreceli etki büyüklükleri ve önem düzeyleri ortaya konmakta; kısmi etki grafikleri ile piyasalar arasındaki etkileşimler gösterilmektedir. COVID-19 pandemisi öncesinde hisse senedi ve yeşil tahvil piyasaları arasında zayıf bir ilişki bulunurken, geleneksel tahvil piyasaları ile yeşil tahvil piyasaları arasında güçlü bir ilişki olduğu belirtilmektedir. COVID-19 döneminde ise hisse senedi ve enerji emtia piyasalarının yeşil tahvil piyasaları üzerinde

oldukça önemli etkileri olduğu; ayrıca piyasaların makroekonomik risk ve belirsizlik faktörleri ile etkileşim içinde olduğu ifade edilmektedir.

Kocaarslan ve Mushtaq (2024), ABD belediye yeşil tahvil piyasaları ile enerji emtia ve hisse senedi piyasaları arasındaki dinamik koşullu korelasyonları ortaya koyarak, CatBoost, XGBoost ve LightGBM algoritmaları ile dinamik korelasyonları tahmin etmeyi amaçlamaktadırlar. Bunun yanı sıra, döviz kuru, çeşitli ekonomik ve belirsizlik faktörleri ile SHAP yaklaşımı kullanarak, değişkenlerin göreceli önem düzeylerini ortaya koymaktadırlar. Araştırmacılar SHAP analizinin, girdi değişkenlerine sayısal değerler atayarak makine öğrenmesi modellerinin ürettiği tahminlere ilişkin daha derin bir anlayış kazandırdığını; her bir girdi değişkenin tahmine ne ölçüde ve hangi yönde katkı sunduğunun ortaya konduğunu ifade etmektedirler. Araştırmanın sonuçları, XGBoost ve CatBoost modellerinin tahmin doğruluğunun LightGBM modelinden daha üstün olduğunu ortaya koymaktadır.

İşgüzar vd. (2024), Japonya yeşil tahvil endeksini, çeşitli makine öğrenmesi algoritmaları kullanarak tahmin etmekte; RF ve XGBoost modellerinin test veri setinde daha başarılı tahminler ürettiklerini ortaya koymaktadır.

4.3. Emtia Piyasaları

Jabeur vd. (2021), COVID-19 pandemisi sürecinde petrol fiyatlarını tahmin etmek amacıyla LightGBM, CatBoost, XGBoost, RF, Yapay Sinir Ağları (Artificial Neural Networks, ANN) modelleri kullanarak model performanslarını karşılaştırmışlardır. Bu bağlamda, yeşil enerji kaynakları, ESG endeksleri, hisse senedi piyasaları, oynaklık endeksi, çeşitli emtialar, döviz kuru ve Bitcoin gibi faktörlerin petrol fiyatlarını tahmin etmedeki önem düzeyleri, SHAP analizi kullanılarak ortaya konmuştur. Çalışmanın sonuçları, XGBoost modelinin petrol fiyatlarını tahmin etmede diğer makine öğrenmesi modellerinden daha üstün olduğu bulgusuna ulaşırken; makine öğrenmesi modellerinin genel performanslarının, diskriminant analizi ve lojistik regresyona kıyasla daha iyi olduğunu göstermektedir. Ayrıca, petrol, yeşil enerji kaynakları ve altın birbirleriyle oldukça yüksek korelasyon ortaya koymakta; araştırmacılar piyasalar arasındaki bu etkileşimlerin risk yayılımı ve portföy yönetimi bağlamında önemine dikkat çekmektedir. Jabeur vd. (2024), altın fiyatlarını tahmin etmek amacıyla çeşitli makine öğrenmesi modelleri kullanarak, XGBoost algoritmasının diğer modellere üstün geldiğini göstermektedir. Ardından, SHAP yaklaşımı kullanılarak, ham petrol, gümüş, demir fiyatları, döviz kurları, S&P 500 endeksi ve ABD enflasyon oranı açıklayıcı değişkenlerinin, altın fiyatlarını açıklama

kapasitelerini ve XGBoost model çıktıları yorumlamadaki etkinliği ortaya konmaktadır.

Lahmire (2024), ham petrol, doğal gaz, benzin gibi fosil enerji piyasası emtialarının tahminlerinde çeşitli makine öğrenmesi sistemlerini, Bayes optimizasyon yöntemi kullanarak optimize etmekte; Gauss regresyon sürecinin fosil enerji piyasalarını tahmin etmede en üstün yöntem olduğunu ifade etmektedir. Jin ve Xu (2025), Çin emtia fiyat endeksinin tahmininde, eğitim süreci için çapraz doğrulama ve Bayes optimizasyonu, analiz süreci için ise Gauss süreç regresyonları kullanarak; belirtilen zaman periyodu için modellerin doğru bir şekilde tahmin edildiğini belirtmektedir. Ludovico vd. (2022), şeker, canlı sığır, kahve, etanol, mısır ve soya fasulyesi gibi ürünleri içeren tarımsal emtia piyasalarının tahminlerinde, RF, ANN, SVM, XGBoost gibi çeşitli makine öğrenmesi modelleri kullanmakta; SVM algoritmasının en doğru tahmin veren model olduğunu ifade etmektedirler. Rady vd. (2021) altın fiyatlarını tahmin etmede, karar ağaçları, rastgele ormanlar ve gradyan artırma ağaçlarını kullanmakta; rastgele ormanların, tahmin doğruluğu bakımından en iyi model olduğunu belirtmektedir.

5. Sonuç

Makine öğrenmesi algoritmalarının kullanıldığı finansal zaman serileri çalışmaları incelendiğinde, yatırımcılara, yöneticilere ve politika yapıcılara yönelik birtakım çıkarımlar ve öneriler sunulmakta; çalışma sonuçları bu bağlamlarda tartışılmaktadır. Ghallabi vd. (2025), araştırmalarından elde edilen bulguların, makine öğrenmesi algoritmalarının yeşil enerji hisse senedi fiyatlarını tahmin etmedeki doğruluğunu vurguladığını; yatırımcılara, portföy yöneticilerine ve politika yapıcılara portföy çeşitlendirmesi bağlamında çıkarımlar sunduğunu belirtmektedir. Jabeur vd. (2024), doğru bir tahmin yöntemi kullanmanın yatırımcılara ve politika yapıcılara uygulamada çıkarımlar sunduğunu; merkez bankalarının işlem güvenliği ve rezerv stratejileri bağlamında altın fiyatlarında meydana gelen dalgalanmalar hakkında bilgi sahibi olmaları gerekliliğini vurgulamaktadır. Tang vd. (2022), finansal verinin doğrusal olmayan, karmaşık ve düzensiz yapısı nedeniyle finansal zaman serisi tahminlerinin önemine dikkat çekmekte; yenilikçi modeller geliştirilerek çeşitli araştırmalar yapıldığını belirtmektedir. Ayrıca araştırmacılar, doğru tasarlanmış tahmin modellerinin daha iyi stratejiler geliştirmede ve kararlar almada hükümetlere yardımcı olabileceğini; karlılığı artırmada ise bireylere ve kurumlara yol gösterebileceğini belirtmektedir. Kocaarslan ve Mushtaq (2024), yeşil tahvil piyasalarının tahmininde makine öğrenmesi modellerinin geleneksel tahmin modellerinden daha doğru çıkarımlar sunduğunu belirterek, COVID-19 pandemi dönemi için yeşil

tahviller ile riskli varlıklar arasındaki bağlantılılığa dikkat çekmektedirler. Jabeur vd. (2021), finansal piyasaların ve emtia piyasalarının, COVID-19 pandemisinin başlamasıyla birlikte önemli kayıplar verdiğini; petrol fiyatlarındaki dalgalanmaların tahmin doğruluğunun, geleneksel modellerden ziyade gelişmiş makine öğrenmesi modelleri kullanılarak artırılmasının önemine vurgu yapmaktadır. Soltani vd. (2024), temiz enerji, emtia, yeşil tahvil ve ESG endeksi fiyatlarını, makine öğrenmesi modelleri kullanarak COVID-19 salgını ve Rusya-Ukrayna çatışması dönemleri kapsamında tahmin ederek, risk yönetimi uygulamaları, yeşil varlıkların denetlenmesi ve politika yapıcılar bağlamında değerlendirmektedir. Ayrıca, etkili tahminlerin, optimal portföy dağılımı ve riskten korunma stratejileri bağlamında önemini vurgulamaktadırlar.

Mevcut çalışma, yenilikçi makine öğrenmesi algoritmalarının finansal zaman serisi uygulamaları üzerindeki performanslarını değerlendirerek, yatırımcılara, uzmanlara ve politika yapıcılara yönelik birtakım çıkarımlar sunmayı amaçlamaktadır. Buna göre, mevcut araştırmalar incelendiğinde, yenilikçi makine öğrenmesi algoritmalarının, finansal zaman serisi uygulamalarında tahmin doğruluğu ve model çıktılarının yorumlanabilirliği bağlamında oldukça üstün performans gösterdikleri ortaya konmaktadır. Bu modellerin, geleneksel yatırım araçlarının yanı sıra, yeşil tahvil, temiz enerji hisse senetleri, ESG hisse senetleri gibi sürdürülebilir yatırım araçlarının tahminlerinde de iyi performans sergilediği anlaşılmaktadır. Özellikle iklim riskleri, finansal krizler ve jeopolitik riskler söz konusu olduğunda; bu araçlar yatırımcılara ve uzmanlara portföy çeşitlendirmesi, riskten korunma ve güvenli liman stratejileri sunabilmektedir. Bu bağlamda ESG varlıkları, iklim riski ve jeopolitik riske karşı çeşitlendirme aracı olarak kullanılmakta (Cepni vd., 2023; Yang vd., 2024); ESG hisse senetlerinin Rusya-Ukrayna çatışması sürecinde güvenli liman olduğu belirtilmekte (Katsampoxakis vd., 2024) ve ESG hisse senetlerinin yüksek jeopolitik risk dönemlerinde riskten korunma ve güvenli liman olma özellikleri taşıdığı ifade edilmektedir (Nittayakamolphon vd., 2024). İklim kaynaklı ve jeopolitik küresel risklerin yüksek olduğu dönemlerde finansal piyasaların oynaklığı artmakta; bu durum yatırımcıları önemli ölçüde etkilemektedir. Piyasadaki belirsizliklerin arttığı bu dönemlerde politika yapıcıların sürdürülebilir yatırımları teşvik etmeleri önem arz edecektir.

Kaynakça

- Bertolini, M., Mezzogori, D., Neroni, M., & Zammori, F. (2021). Machine Learning for industrial applications: A comprehensive literature review. *Expert Systems with Applications*, 175, 114820.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Cepni, O., Demirer, R., Pham, L., & Rognone, L. (2023). Climate uncertainty and information transmissions across the conventional and ESG assets. *Journal of International Financial Markets, Institutions and Money*, 83, 101730.
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
- Choi, J. E., Shin, J. W., & Shin, D. W. (2025). Vector SHAP Values for Machine Learning Time Series Forecasting. *Journal of Forecasting*, 44(2), 635-645.
- Choi, W., Jang, S., Kim, S., Park, C., Park, S., & Song, S. (2024). Return prediction by machine learning for the Korean stock market. *Journal of the Korean Statistical Society*, 53(1), 248-280.
- Dorogush, A. V., Ershov, V., & Gulin, A. (2018). CatBoost: gradient boosting with categorical features support. *arXiv preprint arXiv:1810.11363*.
- Duan, T., Anand, A., Ding, D. Y., Thai, K. K., Basu, S., Ng, A., & Schuler, A. (2020, November). Ngboost: Natural gradient boosting for probabilistic prediction. In *International conference on machine learning* (pp. 2690-2700). PMLR.
- Friedman, J. H. (2002). Stochastic gradient boosting. *Computational Statistics & Data Analysis*, 38(4), 367-378.
- Ghallabi, F., Souissi, B., Du, A. M., & Ali, S. (2025). ESG stock markets and clean energy prices prediction: Insights from advanced machine learning. *International Review of Financial Analysis*, 97, 103889.
- Gupta, S., Nachappa, S., & Paramanandham, N. (2025). Stock market time series forecasting using comparative machine learning algorithms. *Procedia Computer Science*, 252, 893-904.
- İşgüzar, S., Fendoğlu, E., Şimşek, A. İ., & Türkoğlu, M. (2024). Green Bond Index Price Forecasting: Comparative Analysis of Machine Learning Models. *Marmara Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 46(3), 568-589.
- Jabeur, S. B., Khalfaoui, R., & Arfi, W. B. (2021). The effect of green energy, global environmental indexes, and stock markets in predicting oil price crashes: Evidence from explainable machine learning. *Journal of Environmental Management*, 298, 113511.

- Jabeur, S. B., Mefteh-Wali, S., & Viviani, J. L. (2024). Forecasting gold price with the XGBoost algorithm and SHAP interaction values. *Annals of Operations Research*, 334(1), 679-699.
- Jin, B., & Xu, X. (2025). Machine learning predictions of China commodity price indices. *Discrete Mathematics, Algorithms and Applications*, 2550043.
- Kara, Y., Boyacioglu, M. A., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications*, 38(5), 5311-5319.
- Katsampoxakis, I., Xanthopoulos, S., Basdekis, C., & Christopoulos, A. G. (2024). Can ESG Stocks Be a Safe Haven during Global Crises? Evidence from the COVID-19 Pandemic and the Russia-Ukraine War with Time-Frequency Wavelet Analysis. *Economies*, 12(4), 89.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., ... & Liu, T. Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, 30.
- Kocaarslan, B., & Mushtaq, R. (2024). The impact of liquidity conditions on the time-varying link between US municipal green bonds and major risky markets during the COVID-19 crisis: A machine learning approach. *Energy Policy*, 184, 113911.
- Kocaarslan, B., & Soytas, U. (2023). The role of major markets in predicting the US municipal green bond market performance: New evidence from machine learning models. *Technological Forecasting and Social Change*, 196, 122820.
- Kumar, A., Chauhan, T., Natesan, S., Pham, N. T., Nguyen, N. D., & Lim, C. P. (2023). Towards an efficient machine learning model for financial time series forecasting. *Soft Computing*, 27(16), 11329-11339.
- Lahmiri, S. (2024). Fossil energy market price prediction by using machine learning with optimal hyper-parameters: A comparative study. *Resources Policy*, 92, 105008.
- Ludovico, S. N., Salgado, R. M., Beijo, L. A., Miguel, E. C., & Rezende, M. L. (2022). Commodity price forecasting via machine learning models. *Sigmas*, 11(2), 45-69.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30.
- Lundberg, S. M., Erion, G. G., & Lee, S. I. (2018). Consistent individualized feature attribution for tree ensembles. *arXiv preprint arXiv:1802.03888*.
- Lv, S. X., Peng, L., Hu, H., & Wang, L. (2022). Effective machine learning model combination based on selective ensemble strategy for time series forecasting. *Information Sciences*, 612, 994-1023.
- Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press.

- Nittayakamolphon, P., Bejrananda, T., & Pholkerd, P. (2024). Green bonds and ESG stocks as safe haven or hedging asset for other financial assets. *Kasetsart Journal of Social Sciences*, 45(4), 1307-1318.
- Prasad, A., & Bakhshi, P. (2022). Forecasting the direction of daily changes in the India VIX index using machine learning. *Journal of Risk and Financial Management*, 15(12), 552.
- Prokhorenkova, L., Gusev, G., Vorobey, A., Dorogush, A. V., & Gulin, A. (2018). CatBoost: unbiased boosting with categorical features. *Advances in Neural Information Processing Systems*, 31.
- Rady, E. H. A., Fawzy, H., & Fattah, A. M. A. (2021). Time series forecasting using tree based methods. *Journal of Statistics Applications & Probability*, 10(1), 229-244.
- Shapley, L. (1953). A Value for n-Person Games. In: Kuhn, H. and Tucker, A., Eds., *Contributions to the Theory of Games II*, Princeton University Press, Princeton, 307-317.
- Sharma, P., & Jain, M. K. (2023, November). Stock market trends analysis using extreme gradient boosting (XGBoost). In *2023 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)* (pp. 317-322). IEEE.
- Soltani, H., Taleb, J., Ben Hamadou, F., & Boujelbène-Abbes, M. (2024). Using machine learning to forecast clean energy, commodities, green bonds and ESG index prices: How important is financial stress?. *Euro-Med Journal of Business*.
- Tang, Y., Song, Z., Zhu, Y., Yuan, H., Hou, M., Ji, J., ... & Li, J. (2022). A survey on machine learning models for financial time series forecasting. *Neurocomputing*, 512, 363-380.
- Üstüner, M., Abdikan, S., Bilgin, G., & Şanlı, F. B. (2020). Hafif gradyan artırma makineleri ile tarımsal ürünlerin sınıflandırılması. *Türk Uzaktan Algılama ve CBS Dergisi*, 1(2), 97-105.
- Yang, J., Agyei, S. K., Bossman, A., Gubareva, M., & Marfo-Yiadom, E. (2024). Energy, metals, market uncertainties, and ESG stocks: Analysing predictability and safe havens. *The North American Journal of Economics and Finance*, 69, 102030.
- Zhao, S. (2021, May). Nepal stock market movement prediction with machine learning. In *Proceedings of the 2021 5th International Conference on Information System and Data Mining* (pp. 1-7).

FUCOM Tabanlı WEDBA Çok Kriterli Karar Verme Yöntemi ile Optimal Hazır Beton Tedarikçi Firma Seçimi

Şule Bayazıt Bedirhanoglu¹

Özet

Değişen dünya düzeni işletmelerin rekabet yarışını gittikçe zorlaştırmaktadır. İşletmeler; küreselleşme, dijital dönüşüm ve belirsizlik gibi faktörlerin etkisinde esnek, verimli ve yenilikçi politikalar sergilemek zorundadır. Bu zorlu rekabet ortamında, işletmelerin sürdürülebilir bir avantaj elde edebilmeleri için tedarik zinciri yönetimi, operasyonel verimin sağlanmasından müşteri memnuniyetine kadar uzanan kritik bir süreç haline gelmiştir. Tedarik zincir yönetiminin stratejik aşamalarından biri olan tedarikçi seçimi, işletmelerin maliyet, kalite, teslimat süresi gibi faaliyetlerini optimize etmesinin yanı sıra uzun vadede amaçları da doğrudan etkilemektedir. Tedarikçi seçimi, birden fazla kriter ve alternatif arasından kapsamlı olarak çözülmesi gereken problemlerdir. Çok kriterli karar verme yöntemleri aynı anda değerlendirilmesi gereken kriter ve alternatiflerin olduğu böylesi karmaşık yapıları problemlerin çözümünde kullanılan yöntemlerdir. Bu çalışmada, bir inşaat firması için hazır beton tedarikçi seçim problemi FUCOM tabanlı WEDBA çok kriterli karar verme yöntemleri ile gerçekleştirilmiştir. Tedarikçi seçimi; maliyet, kalite, teslimat süresi, teknik yeterlilik, firma itibarı, konum, kalite belgesi ve referans kriterleri çerçevesinde 5 firma arasından bir firmanın belirlenmesi ile tamamlanmıştır. Firmada karar vericiler 1 proje müdürü, 1 proje müdür yardımcısı, 1 inşaat mühendisi ve 1 mali işler uzmanı olmak üzere 4 kişiden oluşmaktadır. FUCOM yöntemi ile elde edilen sonuçlara göre kalite kriteri en yüksek öneme sahip kriter olarak belirlenmiştir. Alternatif beş firma arasından A5 alternatifi en iyi alternatif olarak ilk sırada yer almıştır.

1 Dr. Öğr. Üyesi, Bitlis Eren Üniversitesi, e-Mail: sbbedirhanoglu@beu.edu.tr
ORCID ID: <https://orcid.org/0000-0001-7545-7222>

1. Giriş

Günümüzde küreselleşme, dijital dönüşüm ve artan rekabet durumları işletmelerin tedarik zincir yönetimine olan bakışını kökten değiştirmiştir. Tedarik zinciri yönetimi, maliyetlerin optimize edilmesinin yanı sıra, verimliliğin artırılması, süreç yönetiminde kalitenin sağlanması ve müşteri memnuniyetinin gerçekleştirilmesi açısından stratejik öneme sahiptir. Tedarik zincir yönetimi bir süreçtir ve bu sürecin en kritik aşamasını tedarikçi seçimi oluşturmaktadır. Tedarikçi seçimi, işletmelerin uzun vadede başarısını doğrudan etkilemektedir. Rekabet avantajını sağlamak ve sürdürmek isteyen işletmeler kaliteli mal ve hizmet sunumunu gerçekleştirmek için tedarikçi seçimini sistematik bir şekilde değerlendirmeli ve bu süreci işletmenin hayati bir işlevi olarak benimsemelidir (Karamaşa vd., 2021).

Tedarikçi seçimi sadece maliyet, kalite gibi unsurları değil aynı zamanda teslimat süresi, güvenilirlik, sürdürülebilirlik gibi unsurları da içeren çok boyutlu bir karar problemidir (Taşkent ve Delice, 2021). Teknolojik değişimlerin sınırları zorladığı, sürekli dönüşüm ve yenilik rüzgarlarının estiği bir dünyada, tek bir alternatif ve kriter etkisinde karar vermek mümkün olmamaktadır. Birden fazla kriterin ve alternatifin söz konusu olduğu çok boyutlu karar problemlerinin çözümünde çok kriterli karar verme yöntemleri etkin bir araç olarak kullanılmaktadır. Kriter ve alternatifler arasından iyi/kötü değerlendirmesi yapmak durumunda olan karar verici(ler) çok kriterli karar verme yöntemleri sayesinde bilişsel yükü en aza indirip karar alma sürecini hızlandırmış olur (George ve Balaguru, 2024).

İnşaat sektöründe gerçekleştirilen projeler, sektörün dinamik ve kapsamlı yapısı nedeni ile ülke ekonomileri üzerinde önemli bir etkiye sahiptir. Bu sektör sadece ekonomik etkileriyle değil aynı zamanda insan hayatını da yakından ilgilendiren yönüyle de büyük önem taşımaktadır. Zira ülkemizde 6 Şubat 2023 tarihinde yaşanan ve “asrın felaketi” olarak nitelendirilen depremler, inşaat sektörünün insan hayatı üzerindeki kritik rolünü bir kez daha gözler önüne sermiştir. İnşaatın yapılacağı alanın belirlenmesinden projenin gerçekleştirilmesine kadar olan süreç ve devamında uzun süreli sağlıklı kullanım için sağlam yapıların inşası kurumların ve bireylerin sosyal ve vicdanı sorumluluğunu gerektirmektedir. İnşaat yapım sürecinde kullanılan hazır beton en kritik malzemelerden biridir. Doğru firma seçimi, inşaat projesinin kalite, dayanıklılık gibi özelliklerini temsilde belirleyici faktörlerdir. Aynı zamanda maliyet ve zaman unsurları proje yüklenicisi firmanın başarısı üzerinde önemli unsurlar arasında yer almaktadır.

Birçok sektörde olduğu gibi inşaat sektöründe de malzeme maliyetleri toplam maliyetlerin önemli bir bölümünü oluşturmaktadır. İnşaat

firmaları rekabetçi piyasada en iyi kalitede ve en uygun maliyetle ürün elde edebilmek ve sürdürülebilirliği sağlamak amacıyla tedarikçi seçimini önemli bir problem olarak görüp çözümler aramaktadır. Tedarikçi seçim süreci, birden çok çelişkili kriteri içeren karmaşık yapıda bir problemdir. Çok kriterli karar verme yöntemleri tedarikçi seçim sürecinde, nitel ve nicel kriterleri değerlendirmesi, en uygun alternatifi seçmesi yönü ile güvenilir ve mantıklı sonuçlar elde etmeyi sağlayan yöntemlerdir (Aytekin vd. 2023). Bu çalışmada amaç; bir inşaat firması için hazır beton tedarikçi seçimini gerçekleştirmektir. Bu seçim; 5 firma arasından, 4 uzman karar vericinin değerlendirdiği 8 ayrı kriter çerçevesinde FUCOM tabanlı WEDBA çok kriterli karar verme yöntemleri ile gerçekleştirilmiştir.

Çalışmanın diğer bölümleri şu şekilde organize edilmiştir: İkinci bölümde tedarik zinciri yönetimi, tedarikçi seçimi, çok kriterli karar verme ve FUCOM ve WEDBA yöntemlerinin kullanıldığı çalışmaların yer aldığı literatür incelemesi yer almaktadır. Üçüncü bölümde FUCOM ve WEDBA çok kriterli karar verme yöntemlerinin uygulama adımları ve dördüncü bölümde bir inşaat firması için beton tedarikçi seçimi yer almaktadır. Çalışma sonuçlar ve önerilerin sunulduğu sonuç bölümü ile tamamlanmaktadır.

2. Literatür İncelemesi

Tedarikçi seçimi, işletmenin rekabet gücünü artırmak ve müşteri memnuniyetini sürdürmek üzere gerçekleştirilen tedarik zinciri yönetiminin en önemli bileşendir. Tedarikçi seçimi, her sektörde iş akışlarının verimlilik, maliyet kontrolü, kalite ve sürdürülebilirliğinde kritik öneme sahiptir. Doğru tedarikçi seçimi, müşteri memnuniyetinin artırılması, rekabet ortamında ayakta kalabilmek ve uzun vadede başarı elde edebilmek adına temel bir unsurdur. Tedarikçi seçim sürecinin iyi yönetilememesi sadece iş akışında aksamalara neden olmamakta aynı zamanda kalitede sorunlara, maliyet artışına ve hatta itibar kaybına da neden olabilmektedir. Bu nedenle, işletmeler tedarikçi seçim sürecinde dikkatle kapsamlı bir değerlendirme yapmalıdır. Bu sayede hem riskler azaltılabilir hem de hedeflere daha kolay ulaşılabilir. Tedarikçi seçimi konusunda yapılan araştırmalar bu sürecin önemini ortaya koymaktadır.

Çok kriterli karar verme yöntemleri; karar vericilerin birden çok alternatif ve kriter çerçevesinde objektif ve bilimsel karar vermelerine yardımcı yöntemlerin genel adıdır. Tedarikçi seçim problemleri, yapısı itibari ile çok kriterli karar verme yöntemleri ile çözülen problemlerdir. Birden fazla kriteri aynı anda değerlendirme imkanı sunan bu yöntemler tedarikçi seçim problemlerine sistematik ve objektif çözümler üreterek literatürde pek çok

çalışmaya konu olmuştur. Çok kriterli karar verme yöntemleri ile yapılan çalışmalar incelendiğinde, AHP ve ANP (He ve Zhang, 2018; Nguyen, 2019), TOPSIS (Zhang, 2018; Chen, 2020) yöntemleri ile kriterlerin belirlenmesi ve tedarikçi sıralamaları üzerine çalışmalar yapıldığı gözlemlenmiştir. Supçiller ve Çapraz 2011, karton üretim firması için tedarikçi seçimini AHP ve TOPSIS yöntemleri ile gerçekleştirmiştir. Elektrikli araç tedarikçi seçimi VIKOR yöntemi ile on dört kriter etkisinde incelenmiştir (Wei ve Zou, 2022).

İnşaat sektörü, proje alanının belirlenmesinden personel seçimi, malzeme tedarikçi seçimi gibi konularda literatürde birçok çalışmaya konu olmuştur. Ömürbek vd. (2016), inşaat yapı denetim firma seçimini AHP ve ELECTRE yöntemlerinin bütünleşik kullanımı ile belirlemiştir. Cengiz vd. (2017), inşaat malzemesi tedarikçi seçimini ANP çok kriterli karar verme yöntemi ile incelemiştir. Matić vd. (2019), bir inşaat şirketi için sürdürülebilir tedarikçi seçimini FUCOM, COPRAS, ARAS, WASPAS, SAW ve MABAC çok kriterli karar verme yöntemlerinin bütünleşik kullanımı ile gerçekleştirmiştir. Tedarikçi seçimi maliyet, kalite, teslimat, esneklik, teknolojik yeterlilik, mali yeterlilik, ortaklık ilişkileri, itibar, güvenlik, eğitim vb. bir çok kriter kapsamında gerçekleştirilmiştir. Koç (2020), bulanık TOPSIS yöntemi ile hazır beton sektöründe dört tedarikçi firma arasından seçim gerçekleştirmiştir. Hoseini vd. 2021 yılında yaptıkları çalışmada sürdürülebilir tedarikçi seçimi için bulanık en iyi-en kötü yöntemi ile bulanık çıkarım sistemi yöntemini hibrit olarak kullanmıştır. Ghafoori ve Abdallah (2024), inşaat malzemesi ve tedarikçi seçim sürecini geliştirdikleri MSSM-malzeme ve tedarikçi seçim modeli ile incelemiştir. TOPSIS çok kriterli karar verme yöntemi ile malzeme seçimini gerçekleştirmiştir.

Pamucar vd. (2018) tarafından geliştirilen FUCOM yöntemi kriter ağırlıklarının subjektif olarak belirlenmesinde kullanılan bir yöntemdir. Yöntem az sayıda ikili karşılaştırma gereksinimi ve kriterler arasında tutarlı bir ikili karşılaştırması yönü ile diğer çok kriterli karar verme yöntemlerine göre daha avantajlıdır. Nouredine ve Ristic, (2019), tehlikeli madde taşımacılığında rota kriterlerini FUCOM ile önceliklendirmiş ve TOPSIS-MABAC ile tedarikçileri değerlendirmiştir. Bir işletme için bulut hizmet sağlayıcı seçimi (Arman ve Kundakcı, 2023), kireç üretiminde sürdürülebilir tedarikçi seçimi (Durmić, 2019), sürdürülebilir tedarikçi seçimi (Stević vd., 2019) FUCOM yöntemi ile incelenmiştir. Yazdani (2020), lojistik merkezi lokasyon tercih sıralamasını veri zarflama, FUCOM ve CoCoSo yöntemlerinin kaba küme teorisine entegrasi ile belirlemiştir.

WEDBA yönteminin kullanıldığı çalışmalar incelendiğinde, çeşitli alanlarda, farklı yöntemlerle entegre kullanıldığı görülmüştür. Türk üniversitelerinin akademik performanslarını MEREC tabanlı WEDBA yöntemleri ile sıralamıştır (Kara vd., 2024). Işık, finansal performans analizinde kriterleri AHP ve CRITIC yöntemleri ile ağırlıklandırmış ve sıralamada WEDBA yöntemini kullanmıştır. Garg vd., (2017), AHP, COPRAS ve WEDBA yöntemlerinin bulanık kümeler ile kullanımını e-öğrenme web sitesi seçiminin belirlenmesinde kullanmıştır. Ulutaş (2020), istifleyici seçimi, Basar ve Tolga (2020), dikey akıllı tarama seçimi problemlerini WEDBA yöntemi ile çözümlenmiştir. Al-Hawari vd. (2019), otomotiv üretim şirketi için beş tedarikçi değerlendirmesini bulanık WEDBA yöntemi ile gerçekleştirmiştir.

Literatür incelendiğinde FUCOM ve WEDBA yöntemlerinin çeşitli çalışmalarda kullanıldığı gözlemlenmiştir. Her iki yöntemin birlikte kullanıldığı sınırlı sayıda çalışmaya rastlanmıştır. Bu çalışmada bir inşaat firması için hazır beton tedarikçi seçiminde kriterlerin ağırlıkları FUCOM yöntemi ile belirlenmiştir. FUCOM yöntemi subjektif değerlendirmelerde karar vericilerin görüşlerini dikkate alarak değerlendirme imkânı sunmaktadır. Elde edilen kriter ağırlıkları WEDBA yöntemine entegre edilerek hazır beton tedarikçi beş firma sıralanmıştır.

3. Metodoloji

Birden fazla kriter etkisinde ve birden fazla alternatif arasından seçim yapmaya dayalı karar verme problemlerinin çözümünde çok kriterli karar verme yöntemlerinden yararlanılır. Alternatifler arasından seçim yaparken kararı etkileyen en önemli faktör, söz konusu kriterlerin alternatifler üzerindeki önem derecesini-ağırlıklarını belirlemektir. Kriterler farklı önem ağırlıklarına sahip olması nedeniyle, alternatif seçimi de bu ağırlıklara bağlı olarak değişecektir. Bu bölümde kriterlerin ağırlıklandırılmasında kullanılan FUCOM yöntemi ve alternatiflerin sıralamasında kullanılan WEDBA yöntemlerinden bahsedilecektir.

3.1. FUCOM Yöntemi

Pamucar vd. (2018) tarafından literatüre sunulan FUCOM –Tam Tutarlılık Yöntemi (Full Consistency Method) doğrusal programlama temelli bir yaklaşımdır. Subjektif ağırlıklandırma amacı ile kullanılan yöntem diğer ağırlıklandırma yöntemlerinden (AHP, ANP, SAW vs.) şu özellikleri ile farklılaşmaktadır:

- n adet kriter, n-1 adet ikili karşılaştırmaya tabidir.

- Grup karar verme süreçlerinde kullanılabilir.
- Kriter ağırlıklarının güvenilir şekilde hesaplanmasını sağlar (Ecer, 2020, Özdağoğlu vd., 2021).

Yöntem; kriter ağırlıklarının elde edilmesi için; kriterlerin ağırlık katsayıları arasındaki ilişkilerin kriterlerin karşılaştırmalı önceliklerine eşit olması ve matematiksel geçişliliğin sağlanması koşullarının yerine getirilmesini gerektirir (Pamucar ve Ecer, 2020). Kısıtlamaların belirlenmesi ve modelinin çözülmesi ile elde edilen optimal ağırlıklara ek olarak tam tutarlılık sapma (TTS) derecesi elde edilir. TTS derecesi kriter ağırlıklarının kriterlerin tahmini karşılaştırmalı önceliklerden sapma değerini göstermektedir. TTS değeri kriter ağırlıklarının güvenilir olduğunu gösterir ve değerin 0'a yaklaşması bu güveni daha da artırır. FUCOM yönteminin üç adımdan oluşan işleyişi aşağıda sunulduğu gibidir (Pamucar, 2018, Ecer, 2021, Aşşin ve Aşan, 2021,):

1. Adım: Kriterler sıralanır: Kriterler ($C = C_1, C_2, \dots, C_n$) en yüksek ağırlık katsayısına sahip olması beklenenden, en az önem derecesine sahip olması beklenene doğru, diğer bir ifade ile en önemliden en az önemliye doğru denklem (1)'de verildiği gibi sıralanır.

$$C_{j(1)} > C_{j(2)} > \dots C_{j(k)} \quad (1)$$

k gözlenen kriter sayısını göstermek üzere eğer kriterler arasında aynı öneme sahip iki veya daha fazla kriter varsa, kriterler arasına ">" simgesi yerine "=" simgesi yerleştirilir.

2. Adım: Kriterlerin karşılaştırmalı önemi belirlenir: Sıralan kriterler karşılaştırılarak karşılaştırmalı önemi ($\varphi_{k/(k+1)}$) belirlenir. Değerlendirme kriterlerinin karşılaştırmalı önem vektörleri denklem (2)'de verildiği gibi elde edilir.

$$\Phi = \Phi_{1/2}, \Phi_{2/3}, \dots, \Phi_{k/k+1} \quad (2)$$

FUCOM yöntemi, kriterlerin ikili karşılaştırılmasını tamsayı, ondalık değer veya önceden tanımlı bir ölçek değeri kullanarak gerçekleştirme imkânı sunar.

3. Adım: Kriterlerin önem ağırlıkları hesaplanır: Kriter ağırlıklarının nihai değerleri ($w_1, w_2, \dots, w_n$)^T hesaplanır. Ağırlık katsayılarının nihai değerlerinin hesaplanması için şu iki koşulu sağlanmalıdır:

Ağırlık katsayılarının oranı, 2. adımda tanımlanan gözlemlenen kriterler arasındaki karşılaştırmalı önceliğine ($\varphi_{k/k+1}$) eşittir (denklem 3).

$$\frac{w_k}{w_{k+1}} = \varphi_{k/(k+1)} \quad (3)$$

Ağırlık katsayılarının son değerleri matematiksel geçişlilik koşulunu ($\varphi_{k/(k+1)} \otimes \varphi_{(k+1)/(k+2)} = \varphi_{k/(k+2)}$) sağlamalıdır. Aynı zamanda, $\varphi_{k/(k+1)} = \frac{w_k}{w_{k+1}}$ ve $\varphi_{(k+1)/(k+2)} = \frac{w_{k+1}}{w_{k+2}}$ olduğundan dolayı $\frac{w_k}{w_{k+1}} \otimes \frac{w_{k+1}}{w_{k+2}} = \frac{w_k}{w_{k+2}}$ elde edilir. Böylece değerlendirme de yer alan kriterlerin ağırlık katsayılarının nihai değerlerinin gerçekleştirilmesi gereken bir başka koşul denklem (4)'te verildiği gibi elde edilmiş olur.

$$\frac{w_k}{w_{k+2}} = \varphi_{k/(k+1)} \otimes \varphi_{(k+1)/(k+2)} \quad (4)$$

Minimum TTS ($\mathcal{X}$) diğer bir ifade ile tam tutarlılık yalnızca geçişliliğe tam olarak uyulduğu zaman gerçekleşir. Yani denklem (3) ve denklem (4) koşulları sağlandığında minimum TTS elde edilmiş olur. Böylece maksimum tutarlılık (0.000) sağlanır ve TTS değeri $\mathcal{X} = 0$ olur. Bu koşulların sağlanabilmesi için $(w_1, w_2, \dots, w_n)^T$ değerlerinin, $\mathcal{X}$ değerinin minimizasyonu için;

$$\begin{aligned} \text{i. } & \left| \frac{w_k}{w_{k+1}} - \varphi_{k/(k+1)} \right| \leq \mathcal{X}, \\ \text{ii. } & \left| \frac{w_k}{w_{k+2}} - \varphi_{k/(k+1)} \otimes \varphi_{(k+1)/(k+2)} \right| \leq \mathcal{X} \quad \text{koşullarının gerçekleşmesi} \\ \text{gerekir.} & \end{aligned}$$

Son olarak değerlendirme kriterlerinin ağırlık katsayılarının nihai değerleri denklem (5)'te verilen doğrusal programlama modelinin çözümü ile belirlenir.

$$\begin{aligned}
& \min \mathcal{X} \\
& \text{öyle ki,} \\
& \left\{ \begin{aligned} & \left| \frac{w_j(k)}{w_j(k+1)} - \varphi_{\frac{k}{k+1}} \right| \leq \mathcal{X}, \forall_j \\ & \left| \frac{w_j(k)}{w_j(k+2)} - \varphi_{\frac{k}{k+1}} \otimes \varphi_{\frac{(k+1)}{(k+2)}} \right| \leq \mathcal{X}, \forall_j \\ & \sum_{j=1}^n w_j = 1, w_j \geq 0, \forall_j \end{aligned} \right. \quad (5)
\end{aligned}$$

Denklem (5)'te yer alan modelin çözümü ile değerlendirme kriterlerinin nihai değerleri $(w_1, w_2, \dots, w_n)^T$ ve TTS ($\mathcal{X}$) derecesi elde edilir.

3.2. WEDBA Yöntemi

WEDBA yöntemi, 2011 yılında literatüre girmiştir. Ağırlıklı Öklid uzaklık mesafesine dayanmaktadır. Yöntem, seçeneklerin en iyi ve en kötü olma durumlarına olan uzaklığı dikkate alarak değerlendirme yapmaktadır. Yapılan bu değerlendirmeler; nesnel ağırlıklar, öznel ağırlıklar ve nesnel ve öznel ağırlıkların kombinasyonu olmak üzere üçe ayrılmaktadır. Yöntemin uygulama adımları aşağıda verildiği gibi altı adımdan oluşmaktadır (Rao ve Singh, 2012, Bozkurt ve Şimşek, 2024).

1. Adım: Karar matrisinin oluşturulması: m seçenek ve n kriterden oluşan karar matrisi denklem (6)'da gösterildiği gibi oluşturulur.

$$D = [x_{ij}]_{m \times n} \quad (6)$$

2. Adım: Karar matrisinin normalize edilmesi: Karar matrisi fayda yönlü kriterler için denklem (7) ve maliyet yönlü kriterler için denklem (8) aracılığı ile normalize edilir.

$$x_{ij} = \frac{y_{ij}}{\max(y_{ij})} \quad (7)$$

$$x_{ij} = \frac{\min(y_{ij})}{y_{ij}} \quad (8)$$

3. Adım: Normalize değerlerin standartlaştırılması: Denklem (9)'da x_{ij} 'nin standartlaştırılmış değeri Z_{ij} verilmiştir.

$$Z_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \quad (9)$$

μ_j , j. kriterin ortalama değeri denklem (10) ve σ_j , j. kriterinin standart sapması denklem (11) aracılığı ile hesaplanır.

$$\mu_j = \frac{\sum_{i=1}^m x_{ij}}{m} \quad (10)$$

$$\sigma_j = \sqrt{\frac{\sum_{i=1}^m (x_{ij} - \mu_j)^2}{m}} \quad (11)$$

4. Adım: İdeal ve anti-ideal noktaların belirlenmesi: En çok arzu edilen kriter değerlerinin kümesi ideal nokta (Z_{ij}^+), hiç arzu edilmeyen veya en az arzu edilen kriter değerlerinin kümesi anti-ideal nokta (Z_{ij}^-) standartlaştırılmış karar matrisinden denklem (12) ve denklem (13) aracılığı ile elde edilir.

$$Z_{ij}^+ = \max(Z_{ij}) \quad (12)$$

$$Z_{ij}^- = \min(Z_{ij}) \quad (13)$$

5. Adım: Karar alternatiflerinin ağırlıklı Öklid uzaklıkları ve indeks skorlarının hesaplanması: İndeks skorunun hesaplanması için ağırlıklı Öklid uzaklıkları denklem (14) ve (15) aracılığı ile hesaplanır.

$$WED_i^+ = \sqrt{\sum_{j=1}^n \left\{ W_j \times (y_{ij} - y_{ij}^+) \right\}^2} \quad (14)$$

$$WED_i^- = \sqrt{\sum_{j=1}^n \left\{ W_j \times (y_{ij} - y_{ij}^-) \right\}^2} \quad (15)$$

Denklem (16) ile her bir alternatif için indeks puanı elde edilir. En düşük indeks puanına (IS_i) sahip olan alternatif en iyi performansa sahip alternatif olarak değerlendirilir.

$$IS_i = \frac{WED_i^-}{WED_i^- + WED_i^+} \quad (16)$$

İndeks puanı, bir alternatifin ideal çözüme göre yakınlığını temsil etmektedir. Belirli bir alternatifin indeks puanı ne kadar yüksek ise alternatif ideal çözüme o kadar yakın olur. Diğer bir ifade ile en yüksek indeks puanına sahip olan alternatif en iyi alternatif olarak değerlendirilir (Rao ve Singh, 2012).

4. Bir İnşaat Firması için Hazır Beton Tedarikçi Seçimi

Bu çalışmada, bir inşaat firması için hazır beton tedarikçi firma seçimi FUCOM tabanlı WEDBA çok kriterli karar verme yöntemleri ile gerçekleştirilmiştir. Çalışmada temel amaç karar vericilere en uygun hazır beton tedarikçi firmayı belirlemede yardımcı olmaktır. İnşaat firmasının temel yapı malzemelerinden biri hazır betondur. Firmanın zamanında, sağlam ve düşük maliyette inşaat yapımı, tedarikçi firma seçimi ile yakından ilişkilidir. Birden fazla kriter ve alternatifin olduğu seçim problemlerinde en önemli belirleyici kriterlerin alternatifler üzerinde ne derecede önemli olduğunun belirlenmesidir. Kriterlerin farklı ağırlıklara sahip olması alternatif seçimlerini de değiştirecektir. Bu nedenle hazır beton tedarikçi firma belirlenirken öncelikle seçimde etkili olan kriterlerin FUCOM yöntemi ile ağırlık değerleri belirlenmiştir. Tedarikçi firma seçiminde etkili olan kriterler literatür incelemesi ve uzman görüşlerine başvurarak belirlenmiştir. Çalışmada yer alan kriterler ve kodları Tablo 1'de verilmiştir.

Tablo 1: Hazır Beton Tedarikçi Seçimi için Değerlendirme Kriterleri ve Kodları

KRİTERLER
K1- Maliyet
K2- Kalite
K3- Teslimat süresi
K4- Teknik yeterlilik
K5- Firma itibarı
K6- Konum
K7- Kalite belgesi
K8- Referans

İnşaat firmasında hazır beton tedarikçi firma seçimi için karar vericilerin görüşlerine başvurulmuştur. Bu karar vericiler 1 proje müdürü, 1 proje müdür yardımcısı, 1 inşaat mühendisi ve 1 mali işler uzmanı olmak üzere dört kişiden oluşmaktadır. Tablo 1'de verilen kriterler çerçevesinde faaliyette

bulunan 5 hazır beton firması karşılaştırılmıştır. Öncelikle FUCOM yöntemi ile kriter ağırlıkları elde edilmiştir. Karar vericiler tarafından yapılan değerlendirmeler doğrultusunda kriterlerin önem sıralamaları Tablo 2’de verilmiştir.

Tablo 2. Kriterlerin Önem Sıralamaları

Karar Verici 1	K4>K2>K7>K8>K1>K3>K6>K5
Karar Verici 2	K2>K3>K4>K1>K5>K8>K7>K6
Karar Verici 3	K1>K2>K4>K6>K3>K5>K8>K7
Karar Verici 4	K2>K7>K3>K6>K1>K4>K5>K8

Karar vericiler, kriterlerin karşılaştırmalı önceliklerini Saaty tarafından önerilen 1-9 skalasına göre değerlendirmiştir. İkili karşılaştırmalar iki şekilde gerçekleştirilebilir. Birincisi; önce kriterler sıralanır sonra kendi aralarında karşılaştırılır. İkinci şekil karşılaştırma ise en önemli kriterin diğer kriterler ile karşılaştırılması şeklinde gerçekleştirilir (Pamucar vd, 2018). Bu çalışmada kriter karşılaştırmaları en önemli kriterin diğer kriterler ile karşılaştırılması şeklinde gerçekleştirilmiştir. Tablo 3’de karar verici değerlendirmeleri ile elde edilen kriter önceliklerine göre değerlendirmeler yer almaktadır.

Tablo 3. Kriterlerin Önceliklerine Göre Değerlendirilmeleri

Önem Sırasına Göre Kriterler		1	2	3	4	5	6	7	8
Karar Verici 1	Kriter	K4	K2	K7	K8	K1	K3	K6	K5
	Değerlendirme	1	2	4	5	6	7	8	9
Karar Verici 2	Kriter	K2	K3	K4	K1	K5	K8	K7	K6
	Değerlendirme	1	3	4	5	6	7	8	9
Karar Verici 3	Kriter	K1	K2	K4	K6	K3	K5	K8	K7
	Değerlendirme	1	2	3	4	5	6	7	8
Karar Verici 4	Kriter	K2	K7	K3	K6	K1	K4	K5	K8
	Değerlendirme	1	3	4	5	6	7	8	9

Karar vericilerin değerlendirmeleri sonrasında denklem (5)’te verilen modelin LINGO paket programında çözümü ile kriterlerin ağırlıkları elde edilmiştir. Karar vericilerin ayrı ayrı görüşleri ile elde edilen kriter ağırlıkları Tablo 4’te verilmiştir. Karar vericiler için hesaplanan kriter ağırlıklarının aritmetik ortalaması alınarak nihai ağırlıklar elde edilmiş olur.

Tablo 4. Hazır Beton Tedarikçi Seçimi için Kriterlerin Ağırlıkları

Kriterler	Karar Verici 1	Karar Verici 2	Karar Verici 3	Karar Verici 4	Kriterlerin Nihai Ağırlıkları
K1	0,067	0,086	0,368	0,072	0,148
K2	0,200	0,429	0,184	0,429	0,310
K3	0,058	0,143	0,074	0,107	0,096
K4	0,400	0,107	0,122	0,061	0,172
K5	0,045	0,072	0,061	0,053	0,058
K6	0,050	0,048	0,092	0,086	0,069
K7	0,100	0,054	0,046	0,143	0,086
K8	0,080	0,061	0,053	0,048	0,061

Tablo 4’de görüldüğü üzere K2 (kalite) 0,310 ağırlık skoru ile en önemli kriter olarak belirlenmiştir. K2 kriterini sırası ile K4 (teknik yeterlilik), K1 (maliyet), K3 (teslimat süresi), K7 (kalite belgesi), K6 (konum), K8 (referans) ve K5 (firma itibarı) kriterleri izlemektedir. Bunlara ek olarak tüm karar vericiler için TTS (tutarlılık sapma derecesi), karar verici 1 için 0,00022, karar verici 2 için 0,00022 karar verici 3 için 0,00021 ve son olarak karar verici 4 için 0,00022 olarak elde edilmiştir. Tüm karar vericiler için TTS değeri sıfıra çok yakın olup bu durum kriter ağırlıklarının güvenilirliğini ortaya koymaktadır.

FUCOM yöntemi ile kriterlerin ağırlıkları belirlendikten sonra WEDBA yöntemi uygulanarak alternatifler sıralanmıştır. Hazır beton tedarikçi seçimi için karar matrisi Tablo 5’de verildiği gibi oluşturulur.

Tablo 5. Hazır Beton Tedarikçi Seçimi için Karar Matrisi

Alternatifler	K1	K2	K3	K4	K5	K6	K7	K8
Kriter Yönü	min	max	min	max	max	min	max	max
A1	3,83365863	3,872983	5,803009	2,54573	4,28139	3,935979	4,582576	7,968565
A2	6,16014058	4,355877	4,325308	2,710806	7,325683	5,825901	4,527019	3,722419
A3	3,20108587	3,984283	6,735368	5,00997	7,706943	2,632148	6,928203	6,653712
A4	4,11953429	4,242641	2,114743	5,825901	4,409334	4,820571	5,421612	2,44949
A5	4,35587717	4,738137	4,680695	3,0274	6,0548	4,924298	3,08007	1,934336

Denklem (7) ve denklem (8) aracılığı ile başlangıç karar matrisi normalize edilerek Tablo 6’da sunulmuştur.

Tablo 6. *Normalize Karar Matrisi*

Alternatifler	K1	K2	K3	K4	K5	K6	K7	K8
A1	0,83499502	0,817406	0,364422	0,436968	0,555524	0,66874	0,661438	1
A2	0,51964494	0,919323	0,488923	0,465302	0,95053	0,451801	0,653419	0,467138
A3	1	0,840896	0,313976	0,859948	1	1	1	0,834995
A4	0,77705043	0,895424	1	1	0,572125	0,546024	0,782542	0,307394
A5	0,73488892	1	0,451801	0,519645	0,785629	0,534522	0,44457	0,242746

Tablo 6’da, x_{11} minimizasyon yönlü maliyet kriteri için denklem (8) aracılığı ile $x_{11} = \frac{3,20108587}{3,83365863} = 0,83499502$ değeri elde edilir. Denklem (9) ile elde edilen standardize karar matrisi Tablo 7’de verilmiştir.

Tablo 7. *Standardize Karar Matrisi*

Alternatifler	K1	K2	K3	K4	K5	K6	K7	K8
A1	0,17816511	-1,20384	-0,64796	-0,9569	-1,1752	0,147962	-0,2582	1,445111
A2	-0,7327484	0,385349	-0,14187	-0,83332	0,961679	-0,97742	-0,30229	-0,34759
A3	0,65479496	-0,83756	-0,85302	0,88786	1,229296	1,866381	1,60348	0,889988
A4	0,01078758	0,012692	1,935628	1,498676	-1,08539	-0,48863	0,407727	-0,88501
A5	-0,11099924	1,643355	-0,29277	-0,59632	0,06961	-0,5483	-1,45071	-1,1025

Normalize karar matrisi standardize edildikten sonra ideal (Z_{ij}^+) ve anti-ideal (Z_{ij}^-) noktalar denklem (12) ve (13) aracılığı ile Tablo 8’de sunulduğu gibi hesaplanmıştır.

Tablo 8. *İdeal ve Anti-İdeal Değerler*

	K1	K2	K3	K4	K5	K6	K7	K8
(Z_{ij}^+)	0,65479496	1,643355	1,935628	1,498676	1,229296	1,866381	1,60348	1,445111
(Z_{ij}^-)	-0,7327484	-1,20384	-0,85302	-0,9569	-1,1752	-0,97742	-1,45071	-1,1025

Son aşamada alternatiflerin ideal noktalara olan uzaklıkları (WED_i^+) denklem (14) ve alternatiflerin ideal olmayan uzaklıkları (WED_i^-) denklem (15) kullanılarak hesaplanır. Denklem (16) kullanılarak hesaplanan indeks skorları (IS_i) ve alternatiflerin sıralamaları Tablo 9’da sunulduğu gibi hesaplanmıştır.

Tablo 9. İndeks Skorları ve Alternatiflerin Sıralaması

Alternatifler	WED_i^+	WED_i^-	IS_i	Sıralama
A1	1,044418	0,243435	0,189024	5
A2	0,693112	0,524453	0,430739	3
A3	0,822102	0,545397	0,398828	4
A4	0,587357	0,656714	0,527875	2
A5	0,571198	0,894613	0,610319	1

Tablo 9’da sunulan indeks skorları ve sıralamalar incelendiğinde A5 alternatifinin 0,610319 değeri ile ilk sırada yer aldığı görülmektedir. A5 alternatifini sırası ile A4, A2, A3 ve A1 alternatifleri izlemekte olup sıralamaları; $A5 > A4 > A2 > A3 > A1$ olarak elde edilmiştir.

Sonuç

Tedarikçi seçimi, diğer sektörlerde olduğu gibi inşaat projelerinde de kalite, maliyet ve zamanında tamamlama üzerinde stratejik etki oluşturacaktır. Özellikle deprem, sel gibi doğal afet riskinin yüksek olduğu ülkemizde standartlara uygun, dayanıklı, uzun ömürlü yapılar hayati rol oynamaktadır. İnşaat projelerinde kapsamlı tedarikçi seçimi uzun vadeli performansları doğrudan etkilemektedir. Tedarikçi seçim kararı, kalite, maliyet, zaman gibi unsurlar açısından birden fazla kriter etkisinde ve alternatif arasından gerçekleştirilmektedir. Bu nokta da çok kriterli karar verme yöntemlerinden yararlanır.

Bu çalışmada bir inşaat firması için hazır beton tedarikçi seçimi FUCOM tabanlı WEDBA çok kriterli karar verme yöntemleri ile gerçekleştirilmiştir. İnşaat firması 6 Şubat 2023 depremlerinden önemli düzeyde etkilenen illerden birinde 456 adet konut yapımını üstlenmiştir. Bu büyük çaplı proje, zaman ve süreç yönetimi ve tedarikçi seçiminde üzerinde kapsamlı araştırılma yapılmasını gerektirmektedir. İnşaat firmasının faaliyetlerinde önemli bir alan tutan hazır beton tedarikçi seçimi bütünlük çok kriterli karar verme yöntemleri ile gerçekleştirilmiştir. FUCOM yöntemi ile tedarikçi seçiminde etkili olan maliyet, kalite, teslimat süresi, teknik yeterlilik, firma itibarı, konum, kalite belgesi ve referans kriterlerinin önem düzeyleri (ağırlık skorları) belirlenmiştir. Değerlendirme; inşaat firmasında üst düzey kararlara imza atan 1 proje müdürü, 1 proje müdür yardımcısı, 1 inşaat mühendisi ve 1 mali işler uzmanı olmak üzere 4 uzman görüşü çerçevesinde gerçekleştirilmiştir. Proje müdürü, yüksek inşaat mühendisi unvanına sahip olup inşaat sektöründe 16 yıllık tecrübeye sahiptir. Proje müdür yardımcısı

elektik mühendisi olup sektörde 9 yıllık tecrübeye sahiptir. İnşaat mühendisi karar verici, sahada çalışmakta olup benzer projelerde 7 yıllı aşkın bir süredir çalışmaktadır. Uzman olarak görüşüne başvurulmuş bir diğer karar verici mali işler uzmanı işletme mezunu olup finansal konularda yetkindir. FUCOM yöntemi ile yapılan analiz sonucunda K2 (kalite) kriteri 0,31 skor ile en yüksek öneme sahip kriter olarak belirlenmiştir. K4 (teknik yeterlilik) kriteri 0,172 skor ile ikinci önemli kriter olarak belirlenmiştir. Bu kriterleri önem derecelerine göre sırası ile K1 (maliyet), K3 (teslimat süresi), K7 (kalite belgesi), K6 (konum), K8 (referans) kriterleri izlemiştir. K5 (firma itibarı) kriteri ise 0,058 skor ile en düşük öneme sahip kriter olarak belirlenmiştir. FUCOM yöntemi ile elde edilen kriter ağırlıklarının WEDBA yöntemine entegrasyonu ile 5 hazır beton tedarikçi firması sıralanmıştır. WEDBA yöntemi ile yapılan analizler sonrasında A5 alternatifi en iyi alternatif-en iyi tedarikçi firma olarak belirlenmiştir.

Çalışma FUCOM/WEDBA yaklaşımlarının tedarikçi seçiminde verimli bir şekilde kullanılabileceğini göstermiştir. Yöntemler kolay ve kısa sürede hesaplama imkânı nedeni ile etkin sonuçlar ortaya koymaktadır. Bu çalışmanın sınırı 5 büyük firmanın değerlendirilmiş olması geride onlarca firma değerlendirmeye dâhil edilmemiş olmasıdır. Gelecekte yapılacak çalışmalarda daha fazla firma ile değerlendirme yapılabilir. Aynı zamanda yöntemler tek başına, başka yöntemler ile entegre edilerek veya başka çok kriterli karar problemlerinin çözümünde kullanılabilir.

Kaynakça

- Al-Hawari, T., Naji, A., Alshraideh, H., & Bataineh, O. (2019). Extending the WEDBA to the fuzzy multi-criteria decision-making environment. *International Journal of Computer Applications in Technology*, 59(4), 330-346.
- Arman, K. ve Kundakcı, N. (2023). “Yeni Bütünleşik FUCOM-WEDBA Yaklaşımı ile Bir İşletme için Bulut Hizmet Sağlayıcısı Seçimi”, Pamukkale Sosyal Bilimler Enstitüsü Dergisi, Sayı 56, Denizli, ss.281-295.
- Atanassov, K. (2016). Intuitionistic fuzzy sets. *International journal bioautomation*, 20, 1.
- Ayçin, E., & Aşan, H. (2021). İş zekası uygulamaları seçimindeki kriterlerin önem ağırlıklarının FUCOM yöntemi ile belirlenmesi. *Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 23(2), 195-208.
- Aytekin, A., Okoth, B.O., Korucuk, S., Karamaşa, Ç. and Tirkolae, E.B. (2023), “A neutrosophic approach to evaluate the factors affecting performance and theory of sustainable supply chain management: application to textile industry”, *Management Decision*, Vol. 61 No. 2, pp. 506-529. <https://doi.org/10.1108/MD-05-2022-0588>
- Basar, M., & Tolga, A. C. (2020, July). Smart System Evaluation in Vertical Farming via Fuzzy WEDBA Method. In International Conference on Intelligent and Fuzzy Systems (pp. 534-542). Springer, Cham
- Bozkurt, A. A., & Şimşek, A. (2024). BİST Çimento Sektörü İşletmelerinin Finansal Performansının MEREK Tabanlı WEDBA ve CoCoSo Yöntemleriyle Analizi. *Turkish Studies-Economics, Finance, Politics*, 19(3).
- Cengiz, A. E., Aytekin, O., Ozdemir, I., Kusan, H., & Cabuk, A. (2017). A multi-criteria decision model for construction material supplier selection. *Procedia engineering*, 196, 294-301.
- Chen CH. 2020. A novel multi-criteria decision-making model for building material supplier selection based on entropy-AHP weighted TOPSIS. *Entropy*. 22(2):259. <https://doi.org/10.3390/e22020259>
- Durmić, E. (2019). Evaluation of criteria for sustainable supplier selection using FUCOM method. *Operational Research in Engineering Sciences: Theory and Applications*, 2(1), 91-107.
- Ecer, F. (2021). Sürdürülebilir Tedarikçi Seçimi: Fucom Sübjektif Ağırlıklılandırma Yöntemi Temelli Mairca Yaklaşımı. *Journal of Mehmet Akif Ersoy University Economics and Administrative Sciences Faculty*, 8(1), 26-48.
- Garg, R. (2017). Optimal selection of E-learning websites using multiattribute decision-making approaches. *Journal of Multi Criteria Decision Analysis*, 24(3-4), 187-196.

- George, J., & Balaguru, S. (2024). Sustainable Supplier Selection in the Manufacturing Sector Using Integrated MCDM Techniques. In *MATEC Web of Conferences* (Vol. 393, p. 01013). EDP Sciences.
- Ghafoori, M., & Abdallah, M. (2024). Multi-criteria decision support model for material and supplier selection in the construction industry. *International Journal of Construction Management*, 25(4), 409–418. <https://doi.org/10.1080/15623599.2024.2327251>
- He X, Zhang J. 2018. Supplier selection study under the respective of Low-Carbon supply chain: a hybrid evaluation model based on FA-DEA-AHP. Sustainability (Switzerland). 10(3):564. <https://doi.org/10.3390/su10020564>
- Hoseini, S. A., Fallahpour, A., Wong, K. Y., Mahdiyar, A., Saberi, M., & Durduev, S. (2021). Sustainable supplier selection in construction industry through hybrid fuzzy-based approaches. *Sustainability*, 13(3), 1413.
- Işık, Ö. (2021). AHP, CRITIC ve WEDBA yöntemlerini içeren entegre bir ÇKKV modeli ile AXA Sigorta şirketinin finansal performansının analizi. *Uluslararası İşletme, Ekonomi ve Yönetim Perspektifleri Dergisi*, 5(2), 892-908.
- Kara, K., Yalçın, G. C., Kaygısız, E. G., & Edinsel, S. (2024). Assessing the academic performance of Turkish Universities in 2023: a MEREC-WEDBA hybrid methodology approach. *Journal of Operations Intelligence*, 2(1), 252-272.
- Karamaşa, Ç., Korucuk, S., & Ergün, M. (2021). Determining the green supplier selection criteria in textile enterprises and selecting the most ideal distribution model: A case study of Giresun. *Alphanumeric Journal*, 9(2), 311-324.
- Koç, E. (2020). Alternatif Tedarikçilerin Bulanık Topsıs Yöntemi İle Karşılaştırılması: Hazır Beton Sektöründe Bir Uygulama. *Malatya Turgut Özal Üniversitesi İşletme Ve Yönetim Bilimleri Dergisi*, 1(2), 128-146.
- Mahmood, T., Ullah, K., Khan, Q., & Jan, N. (2019). An approach toward decision-making and medical diagnosis problems using the concept of spherical fuzzy sets. *Neural Computing and Applications*, 31, 7041-7053.
- Matić, B., Jovanović, S., Das, D. K., Zavadskas, E. K., Stević, Ž., Sremac, S., & Marinković, M. (2019). A new hybrid MCDM model: Sustainable supplier selection in a construction company. *Symmetry*, 11(3), 353.
- Negoita, C. V. (2003). Book review of "Fuzzy sets" by H.-J. Zimmermann. *Fuzzy Sets and Systems*, 133(2), 275-275.
- Noureddine, M. & Ristic, M. (2019). Route Planning for Hazardous Materials Transportation: Multi criteria Decision Making Approach. *Decision Making: Applications in Management and Engineering*, 2(1), 66- 85

- Nguyen PT. 2019. 'The application of fuzzy analytic hierarchy process (F-AHP) in engineering project management', in 2018 IEEE 5th International Conference on Engineering Technologies and Applied Sciences, ICE-TAS 2018. <https://doi.org/10.1109/ICETAS.2018.8629217>
- Ömürbek, N. , Karaatlı, M. , Cömert, H. G. (2016). AHP-SAW ve AHP-ELECTRE Yöntemleri ile Yapı Denetim Firmalarının Değerlendirilmesi. *Yönetim Bilimleri Dergisi*, 14(27), s.171-199.
- Özdağoğlu, A., Keleş, M. K. ve Genç, V. (2021). FUCOM ve PROMETHEE yöntemleri ile ticari araç seçimi: peyzaj firmasında bir uygulama. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 25(Özel Sayı), 231- 253.
- Pamučar, D., Stević, Ž., & Sremac, S. (2018). A new model for determining weight coefficients of criteria in mcdm models: Full consistency method (fucom). *symmetry*, 10(9), 393.
- Pamucar, D., & Ecer, F. (2020). Prioritizing the weights of the evaluation criteria under fuzziness: The fuzzy full consistency method–FUCOM-F. *Facta Universitatis, Series: Mechanical Engineering*, 18(3), 419-437.
- Pamucar, D., Ecer, F., & Deveci, M. (2021). Assessment of alternative fuel vehicles for sustainable road transportation of United States using integrated fuzzy FUCOM and neutrosophic fuzzy MARCOS methodology. *Science of the Total Environment*, 788, 147763.
- Rao, R. V. ve Singh, D. (2012). "Weighted Euclidean Distance Based Approach as a Multiple Attribute Decision Making Method for Plant or Facility Layout Design Selection". *International Journal of Industrial Engineering Computations*, 3(3), 365–382.
- Stević, Ž., Durmić, E., Gajić, M., Pamučar, D., & Puška, A. (2019). A novel multi-criteria decision-making model: interval rough SAW method for sustainable supplier selection. *Information*, 10(10), 292.
- Supçiller, A. A. ve Çapraz, O. (2011). AHP-TOPSIS yöntemine dayalı tedarikçi seçimi uygulaması ekonometri ve istatistik, İstanbul Üniversitesi İktisat Fakültesi Ekonometri ve İstatistik Dergisi, 13(12. Uluslararası Ekonometri, Yöneylem Araştırması, İstatistik Sempozyumu Özel Sayısı) 1–22.
- Taşkent, M. C., & Delice, E. K. (2021). Bulanık FUCOM metodu ile tedarikçi değerlendirme kriterlerinin ağırlıklarının belirlenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 863-868.
- Torra, V. (2010). Hesitant fuzzy sets. *International journal of intelligent systems*, 25(6), 529-539.
- Ulutaş, A. (2020). Stacker Selection with PSI and WEDBA Methods. *International Journal of Contemporary Economics and Administrative Sciences*, 10(2), 493-504.

- Wei, Q., & Zhou, C. (2022). A multi-criteria decision-making framework for electric vehicle supplier selection of government agencies and public bodies in China. *Environmental Science and Pollution Research*, 1- 20.
- Yager, R. R. (2013). Pythagorean membership grades in multicriteria decision making. *IEEE Transactions on fuzzy systems*, 22(4), 958-965.
- Yazdani, M., Chatterjee, P., Pamucar, D., & Chakraborty, S. (2020). Development of an integrated decision making model for location selection of logistics centers in the Spanish autonomous communities. *Expert Systems with Applications*, 148, 113208.
- Zhang C. 2018. ‘Research of the selection of green material suppliers based on entropy- TOPSIS Model’, in IOP Conference Series: Materials Science and Engineering. <https://doi.org/10.1088/1757-899X/394/5/052063>

Predicting and Interpreting Employee Attrition with Machine Learning Models: An Application on the HR Analytics Dataset

Cansu Ergenç Özdaş¹

Abstract

Employee retention is a critical challenge in modern organizations, as high rates of turnover can negatively impact organizational productivity and increase operational costs. The rise of data-driven decision-making in human resources management has enabled organizations to leverage advanced analytics and machine learning techniques to better understand the factors influencing employee attrition and to predict which employees are at risk of leaving. This chapter presents an application of various machine learning algorithms—including logistic regression, decision trees, random forests, and gradient boosting—on the open-source IBM HR Analytics Employee Attrition & Performance dataset. The analysis aims not only to achieve accurate predictions of employee turnover but also to provide actionable insights into the underlying determinants of attrition using model interpretability techniques such as SHAP (Shapley Additive Explanations). Key variables including job satisfaction, monthly income, years at company, and work-life balance are explored in detail to identify their relative importance in predicting employee departure. The findings are intended to assist human resource managers in developing proactive strategies to enhance employee engagement and retention. This chapter demonstrates the practical value of machine learning models in human resources analytics, offering both predictive power and interpretability to support evidence-based management decisions.

1 Management Department, Business School, Ankara Yildirim Beyazıt University, Ankara, Turkey

1. Introduction

Employee turnover remains a persistent and multifaceted challenge for organizations across various industries, as the departure of skilled personnel can significantly disrupt business operations, erode valuable organizational knowledge, and lead to substantial financial burdens in terms of recruitment, onboarding, and lost productivity (Avrahami et al., 2022). High attrition rates are associated not only with declines in organizational performance and efficiency but also with increased operational costs, weakened competitive positioning, and the risk of losing critical institutional memory. Moreover, frequent turnover can undermine employee morale, erode trust in leadership, reduce team cohesion, and hinder the achievement of long-term strategic objectives, making it increasingly difficult for organizations to build and maintain a committed, motivated, and high-performing workforce. In dynamic and knowledge-intensive sectors, the loss of experienced employees may even jeopardize innovation capacity and disrupt key client relationships. For these reasons, understanding the underlying drivers, patterns, and mechanisms of employee attrition has become a strategic imperative for human resources (HR) professionals, managers, and organizational leaders who seek to foster a stable, productive, and engaged workforce (Kim et al., 2023).

Historically, the analysis and prediction of employee turnover have relied heavily on traditional methods such as retrospective surveys, descriptive statistics, correlation analyses, and regression-based approaches (Somers, 1999). While these techniques have provided valuable initial insights into the factors influencing turnover—including demographic characteristics, job satisfaction, compensation, work environment, leadership quality, and opportunities for career advancement—they are often constrained by their inability to capture the complex, nonlinear, and interactive effects that can exist among a multitude of variables. Traditional models typically assume linearity and independence among predictors, which may not reflect the reality of modern organizational dynamics, where multiple internal and external forces simultaneously shape employee attitudes and behaviors. Furthermore, such approaches may struggle to incorporate and interpret unstructured or high-dimensional data—such as text from exit interviews, feedback surveys, emails, or large volumes of digital HR records—thereby limiting their explanatory and predictive power in today’s data-rich environments.

As organizations increasingly collect vast and diverse datasets through digital HR management systems, wearable technologies, and online

platforms, the limitations of conventional analytic frameworks have become even more pronounced. For example, sentiment analysis of open-ended survey responses or social network analysis of workplace communications can provide rich contextual understanding of employee engagement and intentions—data types that are not easily integrated into classical statistical models. Moreover, modern organizations operate in environments characterized by rapid change, remote and hybrid work arrangements, cross-functional teams, and shifting employee expectations. These complexities introduce new and evolving variables that can interact in unexpected ways, making turnover prediction a moving target for HR professionals.

Consequently, there is a growing consensus among researchers and practitioners that more advanced analytical approaches are necessary to fully leverage the potential of contemporary workforce data. This includes not only capturing complex nonlinear relationships but also integrating structured and unstructured data sources, accounting for time-varying effects, and enabling real-time predictive insights. The transition from traditional statistical methods to more sophisticated computational techniques, such as machine learning and artificial intelligence, represents a critical step toward developing a deeper, more nuanced understanding of employee attrition and enabling organizations to respond proactively to emerging workforce challenges.

The limitations of conventional statistical models become particularly pronounced in contemporary organizational settings, where rapid digitalization, shifting labor market dynamics, and evolving employee expectations continuously introduce new variables into the equation. In response to these challenges, organizations are increasingly seeking innovative solutions that go beyond traditional analytic frameworks. The rapid expansion of digital HR systems, the integration of workforce analytics platforms, and the increasing availability of large-scale, granular employee datasets have presented both scholars and practitioners with unprecedented opportunities to understand and manage turnover more effectively. This digital transformation enables the continuous collection and real-time analysis of diverse employee data points, ranging from performance metrics and engagement survey results to social network interactions and even biometric data.

Against this backdrop, advanced computational and analytical techniques—most notably, machine learning methods—have emerged as powerful tools for modeling, understanding, and predicting employee attrition with greater sophistication and accuracy (Novia & Yuadi, 2023).

Unlike traditional statistical approaches, machine learning algorithms possess the capacity to model complex interactions, capture nonlinear relationships, and automatically detect subtle patterns in large, multidimensional datasets. Methods such as decision trees, random forests, gradient boosting, and deep learning can accommodate a wide array of predictor variables, including both structured and unstructured data, while handling multicollinearity and interaction effects with minimal manual intervention. These techniques enable researchers and practitioners to uncover hidden risk factors, latent dependencies, and previously overlooked determinants of turnover, offering insights that are both more granular and more predictive than those provided by classical approaches.

Moreover, the adoption of machine learning in the context of employee turnover is not limited to predictive modeling. The growing emphasis on interpretability and transparency in artificial intelligence has led to the integration of explainable machine learning tools—such as SHAP values and LIME—that help HR leaders and stakeholders understand the reasoning behind predictions, identify the most influential variables, and translate analytic findings into actionable strategies. This confluence of big data, advanced analytics, and interpretability is redefining the possibilities of evidence-based human resource management, enabling organizations to move from reactive responses to proactive, data-driven talent retention interventions.

The evolving landscape of employee turnover research reflects a broader shift in organizational analytics, where the integration of digital technologies and sophisticated computational methods offers a transformative potential to enhance workforce stability, optimize HR policies, and ultimately drive organizational success.

In light of these evolving challenges and opportunities, the present study systematically applies several machine learning algorithms—including logistic regression, decision trees, random forests, and gradient boosting—to the widely recognized IBM HR Analytics Employee Attrition & Performance dataset. The primary aim of this research is twofold: first, to improve the accuracy and reliability of employee attrition predictions by harnessing the power of advanced machine learning models; and second, to identify and interpret the key factors that drive turnover, using sophisticated interpretability tools such as SHAP (Shapley Additive Explanations) values.

By employing these models and interpretability techniques, the study not only seeks to address the inherent complexities of employee turnover, but also strives to make the analytical process more transparent and actionable

for human resource practitioners. Unlike “black box” models that yield predictions without explanatory context, the integration of interpretability tools enables decision-makers to understand which variables—such as job satisfaction, tenure, compensation, work-life balance, and overtime status—most significantly contribute to the risk of attrition. These insights are intended to provide a robust, data-driven foundation for developing targeted employee retention strategies, designing proactive HR interventions, and supporting more effective, evidence-based management decisions. The findings of this research are expected to reinforce the practical value of machine learning in human resources analytics, highlighting not only the predictive power but also the interpretability and strategic applicability of advanced analytical models in contemporary workforce management.

2. Literature Review

Employee turnover has long constituted a central topic of concern in organizational research, with scholars dedicating extensive attention to understanding both its antecedents and its far-reaching consequences (Oh & Chhinzer, 2021; Kim & Park, 2017). Over the decades, traditional research in this domain has typically concentrated on a core set of factors—including job satisfaction, organizational commitment, compensation, work environment, and career advancement opportunities—as primary drivers influencing an employee’s decision to stay or leave an organization (Peters et al., 1981; Lee et al., 2023). These variables have been examined through a variety of statistical approaches, most notably regression analysis and structural equation modeling, which have enabled researchers to explore both the direct and indirect effects on turnover intentions and actual employee departure (Margaretha et al., 2023; Shin & Jeung, 2019). The accumulated findings from this stream of research have not only contributed to the theoretical understanding of turnover processes but have also informed practical HR interventions aimed at enhancing employee retention and organizational performance.

In recent years, the landscape of turnover research has undergone a significant transformation, spurred by remarkable advancements in data availability, digitalization, and computational power. As organizations increasingly implement digital HR systems and amass granular, large-scale workforce data, scholars and practitioners alike are now equipped to move beyond the confines of conventional methodologies. The rise of machine learning techniques, in particular, has opened up new avenues for the analysis and prediction of employee attrition. Unlike traditional models, machine learning algorithms—such as decision trees, random forests, support

vector machines, and gradient boosting—are uniquely capable of capturing complex, nonlinear interactions among a vast array of predictor variables (Nawafleh et al., 2021; Wu et al., 2024). Numerous studies leveraging these algorithms have demonstrated their superior predictive performance over classical models, achieving higher accuracy in identifying employees at risk of leaving and uncovering intricate patterns previously masked in the data (Swider et al., 2011; Wu et al., 2024).

However, as machine learning models become more prominent in employee turnover research, a parallel emphasis has emerged on the importance of interpretability. While predictive accuracy is critical, organizations also require clear, actionable explanations for model outputs to ensure trust and facilitate informed decision-making. To address this need, advanced interpretability techniques such as SHAP (Shapley Additive Explanations) and LIME (Local Interpretable Model-Agnostic Explanations) have gained widespread adoption (Çolak, 2023; Sturman & Trevor, 2001). These tools offer the ability to decompose model predictions and highlight the relative influence of specific variables—such as overtime, job satisfaction, or work-life balance—on attrition outcomes. This, in turn, enhances the practical applicability of machine learning models in HR contexts, empowering managers to design targeted retention initiatives based on transparent, evidence-based insights (Chen et al., 2015; Han, 2020).

The convergence of employee turnover research and machine learning thus represents a powerful intersection for organizations striving to proactively manage workforce stability and optimize their HR interventions. Nevertheless, recent scholarship continues to underscore the necessity for transparent, interpretable, and trustworthy analytical models (Kang et al., 2024; Chovwen, 2012). Without sufficient clarity and understanding of how model predictions are generated, the utility of even the most accurate algorithms may be limited. As such, ongoing research increasingly highlights the dual imperative of achieving both predictive excellence and interpretability, ensuring that data-driven recommendations are not only reliable but also actionable for practitioners seeking to enhance organizational outcomes through strategic HR management.

3. Methods

In this study, a diverse set of machine learning algorithms—including logistic regression, decision trees, random forests, and gradient boosting—were implemented to address the dual goals of accurately predicting employee attrition and uncovering the primary determinants contributing

to turnover. The rationale for selecting these models stems from their proven ability to handle the intricate, nonlinear relationships commonly observed in workforce data, as well as their capacity to yield interpretable results that support data-driven managerial decision-making. By leveraging these techniques, the research aims to significantly enhance both the predictive accuracy and the interpretability of attrition analyses, thereby supporting proactive and evidence-based human resource management strategies.

3.1. Data Source

The analysis was conducted using the IBM HR Analytics Employee Attrition & Performance dataset, a widely recognized benchmark in human resource analytics research. This dataset encompasses detailed information on 1,470 employees from a fictional organization, designed to simulate real-world HR scenarios. It comprises 35 diverse features, capturing a broad range of demographic variables (including age, gender, marital status), job-related characteristics (such as department, job role, years at company, years in current role), compensation details (monthly income, stock option level, percent salary hike), and organizational factors (job satisfaction, work-life balance, overtime status). The dependent variable, Attrition, is binary and indicates whether an employee has left the company (“Yes”) or remains employed (“No”), providing a clear and actionable target for predictive modeling.

3.2. Data Preprocessing

Comprehensive data preprocessing steps were undertaken to ensure the robustness and reliability of subsequent modeling efforts. Initial exploratory data analysis was performed to detect any missing values, outliers, or inconsistencies within the dataset. Notably, the dataset was found to be complete, with no missing entries, eliminating the need for imputation strategies. Categorical variables—including gender, marital status, business travel, department, education field, job role, and overtime—were transformed using one-hot encoding to facilitate compatibility with the chosen machine learning algorithms. Numerical variables, such as age, years at company, monthly income, and distance from home, were standardized (z-score normalization) to ensure uniformity across features and promote model convergence. The outcome variable, Attrition, was converted to a binary format (1 = Yes, 0 = No) to align with the requirements of classification algorithms. Additional steps, such as outlier detection and treatment, were considered to minimize the influence of extreme values and ensure data quality.

3.3. Model Development

A suite of machine learning algorithms—logistic regression, decision tree, random forest, and gradient boosting machines (GBM)—was systematically deployed to model employee attrition. The dataset was randomly partitioned into training and testing sets using an 80:20 split, ensuring that the class distribution was preserved via stratified sampling. This approach was critical in addressing the class imbalance typically present in attrition datasets, where the number of employees who leave the company is often much lower than those who stay. To further mitigate the effects of imbalance, class weights were incorporated into model training when applicable. Hyperparameters for each model were fine-tuned using grid search combined with five-fold cross-validation, optimizing model performance while reducing the risk of overfitting.

3.4. Model Evaluation

The predictive performance of each model was rigorously evaluated using a comprehensive suite of classification metrics, including accuracy, precision, recall, F1-score, and the area under the receiver operating characteristic curve (AUC-ROC). These metrics provide a multifaceted assessment of model effectiveness, capturing both the ability to correctly identify employees at risk of leaving (recall) and the accuracy of these predictions (precision). Additionally, confusion matrices were generated to offer a more granular view of model predictions, allowing for the assessment of true positives, true negatives, false positives, and false negatives. This approach facilitated the identification of potential biases and limitations in the models' predictive capabilities, particularly in correctly identifying the minority class (employees who leave).

3.5. Model Interpretability

Recognizing the importance of actionable insights for human resources management, advanced model interpretability techniques were integrated into the analysis. SHAP (Shapley Additive Explanations) values were calculated to quantify the contribution of each feature to the overall model predictions. This interpretability analysis enabled the identification of the most influential factors affecting employee attrition—such as overtime status, job satisfaction, monthly income, years at company, and distance from home—thereby translating complex model outputs into understandable and practical recommendations for HR decision-makers. The use of SHAP values also allowed for the exploration of feature interactions and individualized

risk profiles, supporting the development of targeted retention strategies tailored to the specific needs and risk factors of different employee segments.

4. Results

4.1. Model Performance

Four machine learning algorithms were systematically evaluated in this study—logistic regression, decision tree, random forest, and gradient boosting machine (GBM)—to determine their effectiveness in predicting employee attrition using the IBM HR Analytics Employee Attrition & Performance dataset. The comparative performance metrics for these models are presented in Table 1, which summarizes accuracy, precision, recall, F1-score, and the area under the receiver operating characteristic curve (AUC-ROC).

Table 1. The comparative performance metrics for machine learning algorithms

Model	Accuracy	Precision	Recall	F1-score	AUC-ROC
Logistic Regression	0.70	0.30	0.64	0.41	0.75
Decision Tree	0.77	0.27	0.26	0.26	0.56
Random Forest	0.84	0.44	0.09	0.14	0.75
Gradient Boosting	0.85	0.59	0.21	0.31	0.79

According to the results, the gradient boosting algorithm emerged as the top performer, achieving the highest overall accuracy (0.85), as well as the best balance between precision and recall, reflected by its F1-score (0.31) and AUC-ROC (0.79). These findings indicate that gradient boosting not only makes correct predictions most often but also effectively identifies employees who are likely to leave, without generating an excessive number of false positives or negatives. This superior performance is consistent with existing literature, which emphasizes the strength of ensemble learning techniques in handling complex, nonlinear relationships in classification problems.

Logistic regression, on the other hand, achieved the highest recall (0.64), meaning it was most effective at correctly identifying employees who actually left the organization. However, its relatively lower precision (0.30) and F1-score (0.41) indicate that it also misclassified a substantial number of employees as potential leavers who ultimately stayed, resulting in a higher false positive rate. This trade-off between recall and precision is typical in models that are tuned for sensitivity, especially in contexts with class imbalance.

The random forest model showed high accuracy (0.84) and moderate precision (0.44), but it struggled with recall (0.09) and F1-score (0.14), suggesting that while it was generally reliable in its predictions, it failed to accurately capture many of the employees who left. This highlights a potential weakness of the model in recognizing the minority class, a known challenge in attrition prediction tasks.

Finally, the decision tree algorithm performed the weakest across most metrics, with accuracy (0.77), precision (0.27), recall (0.26), F1-score (0.26), and AUC-ROC (0.56) all lagging behind the other models. Its relatively poor performance may be attributed to its tendency to overfit the training data and its limited ability to generalize complex patterns without the benefit of ensemble methods.

These comparative results underscore the critical importance of selecting appropriate machine learning algorithms and performance metrics based on the specific goals of the analysis—whether prioritizing overall accuracy, sensitivity to identifying at-risk employees, or the interpretability of results. The demonstrated superiority of ensemble models like gradient boosting in this context suggests that such approaches should be considered best practice for similar workforce analytics challenges.

4.2. SHAP Feature Importance Analysis

The SHAP summary plot (see Figure 1) provides a comprehensive overview of the relative contributions and importance of each variable in the model's prediction of employee attrition. Among the numerous features included in the analysis, several emerged as particularly influential in determining an employee's likelihood of leaving the organization. Notably, OverTime (Yes) stands out as the most impactful predictor, with employees who consistently worked overtime demonstrating a substantially higher probability of attrition, as indicated by the predominantly high positive SHAP values associated with this feature. This finding underscores the critical role that work-life balance and excessive job demands play in employee turnover risk.

Additionally, variables such as StockOptionLevel, NumCompaniesWorked, Age, and MonthlyIncome were found to significantly influence attrition predictions. The SHAP analysis reveals that both the presence of stock options and higher monthly income can shift attrition risk, although the direction of this effect may vary based on individual employee profiles. A greater number of previous companies worked for (NumCompaniesWorked) and specific age brackets were also associated with distinct attrition patterns,

suggesting that career mobility and employee lifecycle factors are important considerations in understanding turnover dynamics.

Environmental factors also proved to be salient. `EnvironmentSatisfaction` and `DistanceFromHome` demonstrated that lower levels of satisfaction with the workplace environment and greater distances between home and work are linked to an elevated risk of leaving the company. These insights emphasize the importance of fostering a positive organizational climate and minimizing commute-related stressors as part of retention strategies.

The SHAP plot not only highlights the overall ranking of feature importance but also elucidates the direction and magnitude of each variable's impact on individual model predictions. Features with higher values (shown in red) and those with lower values (blue) can either increase or decrease the predicted probability of attrition, with points plotted further to the right indicating a stronger effect towards employee departure. This level of interpretability enables human resource practitioners to move beyond "black box" outputs and develop more nuanced, targeted interventions by understanding not just which variables matter, but how they influence the likelihood of turnover across different employee segments.




Figure 1. SHAP summary plot

5. Discussion

The present study demonstrates the significant utility of machine learning algorithms for predicting employee attrition and elucidating the key determinants of turnover by leveraging the IBM HR Analytics dataset. Through the comparative evaluation of several models—including logistic regression, decision trees, random forests, and gradient boosting—it was observed that gradient boosting algorithms achieved the highest overall predictive performance. This outcome aligns with a growing body of literature emphasizing the robustness, flexibility, and predictive power of ensemble methods, which effectively capture complex, nonlinear patterns and interactions within workforce data (Wu et al., 2024; Alqahtani et al., 2024). The superior performance of gradient boosting models supports their growing adoption in organizational analytics, particularly in domains

characterized by intricate variable relationships and a need for high predictive accuracy.

However, the analysis also brought to light several challenges that persist in practical applications of machine learning to employee attrition prediction. Most notably, the presence of class imbalance in the dataset—where the proportion of employees who actually leave is significantly smaller than those who remain—adversely affected the recall values of all tested models. This phenomenon is consistent with prior research findings, which emphasize that traditional classifiers often struggle to accurately identify minority class events, such as actual attrition, when faced with imbalanced data (Kim & Park, 2017; Swider et al., 2011). This limitation highlights the ongoing need for the integration of additional data resampling techniques—such as Synthetic Minority Over-sampling Technique (SMOTE)—or the adoption of cost-sensitive learning algorithms that assign higher penalties to misclassification of the minority class. Such methodological enhancements are crucial for improving the sensitivity of predictive models, especially in identifying employees at high risk of departure.

The feature importance analysis using SHAP values emerged as a central contribution of this study, offering actionable and interpretable insights into the factors that most strongly influence attrition risk. Variables such as OverTime (Yes), StockOptionLevel, NumCompaniesWorked, Age, and MonthlyIncome were consistently identified as the most influential predictors across models. The finding that overtime work significantly increases attrition risk is particularly noteworthy, as it reinforces existing evidence linking excessive job demands and compromised work-life balance with increased turnover intentions (Han, 2020; Kim et al., 2023). Similarly, lower levels of job and environmental satisfaction, greater commuting distances, and higher job mobility (i.e., more previous employers) were found to elevate attrition risk, echoing long-standing theoretical and empirical models of employee turnover (Peters et al., 1981; Margaretha et al., 2023). The importance of compensation and benefits, as reflected in monthly income and stock option levels, further substantiates established frameworks emphasizing economic incentives and career advancement as core drivers of retention and turnover (Griffeth et al., 2000; Chen et al., 2015).

One of the most significant practical advantages of the machine learning approach adopted in this study is the enhanced interpretability provided by SHAP values. Unlike traditional “black box” models, the ability to quantify and visualize the contribution of each feature to model predictions empowers HR practitioners to develop evidence-based, targeted interventions. For

example, organizations can use these insights to refine overtime management policies, tailor retention programs to address specific satisfaction gaps, and proactively identify employees at heightened risk of departure based on their unique risk profiles. This transition from generic to personalized HR strategies represents a substantial advancement in the application of analytics to workforce management, fostering both strategic decision-making and operational effectiveness (Pepple et al., 2021; Garg et al., 2023).

Despite the strengths and novel contributions of this research, several limitations must be acknowledged. The moderate recall values—primarily attributable to class imbalance—limit the models' ability to detect all potential leavers, indicating that further improvements in data preprocessing and model selection are warranted. Future research should systematically explore the integration of oversampling methods such as SMOTE, as well as advanced cost-sensitive and ensemble algorithms specifically tailored for imbalanced classification problems (Nawafleh et al., 2021). Another limitation pertains to the nature of the dataset itself: although the IBM HR Analytics dataset provides a rich and diverse set of features, it is based on simulated data from a fictional organization. Consequently, the generalizability of findings to real-world organizational settings or different industries may be constrained. Additional studies leveraging empirical data from various sectors and organizational contexts are necessary to validate and extend the applicability of these findings.

This research underscores the substantial potential of machine learning—and especially interpretable ensemble models—in supporting the understanding and management of employee turnover. The integration of advanced analytical techniques and transparent model interpretation offers both high predictive accuracy and practical, actionable insights, ultimately enhancing the effectiveness of human resource management. As organizations continue to embrace data-driven approaches to workforce stability, ongoing methodological innovations and real-world validation will be critical in further advancing the field of HR analytics and employee retention strategy.

6. Conclusion

This study provides compelling evidence for the efficacy of machine learning approaches in predicting employee attrition and delivering actionable insights for strategic human resource management. By applying a comprehensive set of algorithms—including logistic regression, decision trees, random forests, and gradient boosting—to the IBM HR Analytics Employee Attrition & Performance dataset, the research not only achieved

robust predictive accuracy but also showcased the value of interpretable models in organizational decision-making. The integration of SHAP analysis was particularly instrumental in unraveling the underlying factors most strongly associated with turnover, identifying overtime status, stock option level, job mobility, age, and monthly income as key predictors.

The findings of this study reinforce the growing importance of data-driven decision-making in contemporary HR practices. They emphasize the necessity for organizations to systematically monitor and manage critical drivers such as overtime, job satisfaction, compensation, and employee mobility. By proactively addressing these areas, organizations can mitigate the risk of turnover, improve employee engagement, and foster a more stable and productive workforce. Moreover, the interpretability of the machine learning models employed ensures that HR professionals and managers are not left with opaque “black box” predictions but can instead develop targeted, evidence-based retention strategies tailored to the specific needs and risk factors of their employees.

Despite these strengths, the study also recognizes important limitations. Chief among these is the challenge posed by class imbalance, which constrained the models’ ability to accurately detect all at-risk employees. This limitation echoes ongoing challenges in the field and points to the need for future research to explore advanced resampling strategies, cost-sensitive learning methods, and the use of real-world, longitudinal datasets to further enhance prediction sensitivity and generalizability.

In conclusion, this research underscores the transformative potential of integrating advanced analytics and transparent modeling into workforce management practices. By harnessing the power of machine learning, organizations are better equipped to anticipate and address attrition risks, ultimately supporting the development of more effective and sustainable HR strategies. Ongoing methodological refinement, coupled with the continuous evolution of explainable artificial intelligence tools, promises to further expand the role of machine learning in shaping the future of evidence-based HR management and organizational success.

Reference

- Alqahtani, H., Almagrabi, H., & Alharbi, A. (2024). Employee attrition prediction using machine learning models: a review paper. *International Journal of Artificial Intelligence & Applications*, 15(2), 23-49.
- Avrahami, D., Pessach, D., Singer, G., & Ben-Gal, H. (2022). A human resources analytics and machine-learning examination of turnover: implications for theory and practice. *International Journal of Manpower*, 43(6), 1405-1424.
- Chen, J., Hou, Z., Li, X., Lovelace, K., Yiling, L., & Wang, Z. (2015). The role of career growth in chinese new employee's turnover process. *Journal of Career Development*, 43(1), 11-25.
- Chowwen, C. (2012). Organisational practices influencing turnover intention restructured bank environment in nigeria. *Ibadan Journal of the Social Sciences*, 10(2).
- Çolak, O. (2023). The impact of artificial intelligence on the employment structure of the tourism industry: an interview with chatgpt. *İktisadi İdari Ve Siyasal Araştırmalar Dergisi*, 8(22), 919-939.
- Garg, N., Mahipalan, M., & Sharma, N. (2023). Does workplace toxicity influence turnover intentions among indian healthcare employees? investigating the moderating role of gratitude. *Journal of Health Organization and Management*, 37(2), 250-272.
- Han, J. (2020). A review of antecedents of employee turnover in the hospitality industry on individual, team and organizational levels. *International Hospitality Review*, 36(1), 156-173.
- Kang, J., Shin, H., & Kang, C. (2024). Hospitality labor leakage and dynamic turnover behaviors in the age of artificial intelligence and robotics. *Journal of Hospitality and Tourism Technology*, 15(5), 916-933.
- Khoirunnisa, A. and Usman, U. (2024). Effect positive of learning agility on salespeople turnover intention in the automotive sector. *Neo Journal of Economy and Social Humanities*, 3(1), 1-11.
- Kim, H. and Park, J. (2017). The effects of longer commutes, unsolicited job offers, and working in the seoul metropolitan area on the turnover intentions of korean employees. *International Journal of Manpower*, 38(4), 594-613.
- Kim, S., Kim, E., Kim, H., Song, S., Park, B., & Jo, K. (2023). Development of a nurse turnover prediction model in korea using machine learning. *Healthcare*, 11(11), 1583.
- Lee, Y., Yang, J., & Lee, J. (2023). Identifying determinants in the first turnover of new graduate employees in korea: applying a discrete-time survival analysis. *Evidence-Based HRM a Global Forum for Empirical Scholarship*, 11(4), 641-658.

- Margaretha, M., Zaniarti, S., & Indrawan, D. (2023). Mediating role of employee engagement on person-organization fit and turnover intention in indonesia. *International Journal of Professional Business Review*, 8(7), e01320.
- Nawafleh, S., Alkhalayleh, W., & Qerba, M. (2021). Impact of work alienation feelings on turnover intention in the aqaba special economic zone authority located in jordan. *Journal of Social Sciences (Coes&trj-Jss)*, 10(2), 179.
- Novia, A. and Yuadi, I. (2023). Forecasting employee potential through probationary assessment. *JBMP (Jurnal Bisnis Manajemen Dan Perbankan)*, 9(2), 131-149.
- Oh, J. and Chhinzer, N. (2021). Is turnover contagious? the impact of transformational leadership and collective turnover on employee turnover decisions. *Leadership & Organization Development Journal*, 42(7), 1089-1103.
- Pepple, D., Akinsowon, P., & Oyelere, M. (2021). Employee commitment and turnover intention: perspectives from the nigerian public sector. *Public Organization Review*, 23(2), 739-757.
- Peters, L., Bhagat, R., & O'Connor, E. (1981). An examination of the independent and joint contributions of organizational commitment and job satisfaction on employee intentions to quit. *Group & Organization Studies*, 6(1), 73-82.
- Shin, I. and Jeung, C. (2019). Uncovering the turnover intention of proactive employees: the mediating role of work engagement and the moderated mediating role of job autonomy. *International Journal of Environmental Research and Public Health*, 16(5), 843.
- Somers, M. (1999). Application of two neural network paradigms to the study of voluntary employee turnover.. *Journal of Applied Psychology*, 84(2), 177-185.
- Sturman, M. and Trevor, C. (2001). The implications of linking the dynamic performance and turnover literatures.. *Journal of Applied Psychology*, 86(4), 684-696.
- Swider, B., Boswell, W., & Zimmerman, R. (2011). Examining the job search–turnover relationship: the role of embeddedness, job satisfaction, and available alternatives.. *Journal of Applied Psychology*, 96(2), 432-441.
- Wu, R., Zhao, X., Li, Z., & Xie, Y. (2024). The role of employee personality in employee satisfaction and turnover: insights from online employee reviews. *Personnel Review*, 53(7), 1581-1611.

Nicel Karar Verme: Çok Kriterli Yaklaşımlar ve Makine Öğrenmesi Uygulamaları

Editör:

Dr. Öğr. Üyesi Şule Bayazıt Bedirhanoglu