



TÜRKİYE VE DÜNYADA ENDÜSTRİ MÜHENDİSLİĞİ

Editör: Doç.Dr. Melik KOYUNCU

yaz
yayınları

Türkiye ve Dünyada Endüstri Mühendisliği

Editör

Doç.Dr. Melik KOYUNCU

yaz
yayınları

2025

**Türkiye ve Dünyada Endüstri
Mühendisliği**

Editör: Doç.Dr. Melik KOYUNCU

© YAZ Yayınları

Bu kitabın her türlü yayın hakkı Yaz Yayınları'na aittir, tüm hakları saklıdır. Kitabın tamamı ya da bir kısmı 5846 sayılı Kanun'un hükümlerine göre, kitabı yayınlayan firmanın önceden izni alınmaksızın elektronik, mekanik, fotokopi ya da herhangi bir kayıt sistemiyle çoğaltılamaz, yayınlanamaz, depolanamaz.

E_ISBN 978-625-8678-41-3

Aralık 2025 – Afyonkarahisar

Dizgi/Mizanpaj: YAZ Yayınları

Kapak Tasarım: YAZ Yayınları

YAZ Yayınları. Yayıncı Sertifika No: 73086

M.İhtisas OSB Mah. 4A Cad. No:3/3
İscehisar/AFYONKARAHİSAR

www.yazyayinlari.com

yazyayinlari@gmail.com

İÇİNDEKİLER

Decision Science in Smart Logistics: Data-Driven and AI-Based Approaches	1
<i>İrem KARAKAYA</i>	
Zaman Serileri ve Nedensel Makine Öğrenmesi Yaklaşımlarıyla Enerji Talep Tahmini	19
<i>Hüseyin Avni ES</i>	
Güneş Enerjisi Yatırımlarının İllere Göre Önceliklendirilmesinde Kümeleme Analizi Yaklaşımı ...	34
<i>Yasemin DÖNMEZ, Hüseyin Avni ES</i>	
Salgın Hastalıklarda Kaynak Planlamasında Kullanılan Modeller	53
<i>Melik KOYUNCU, Rızzan EROL</i>	
Bir Kimya Firmasında Endüstriyel Karıştırıcı Problemlerinin DEMATEL Yöntemiyle Analizi	64
<i>Yıldız ŞAHİN, Emre YÜKSEL</i>	
Evaluation of Critical Success Factors for Digital Twin Applicability in the Textile Industry: Swara and Bwm Approaches	84
<i>Özlem SÖKMEN</i>	

"Bu kitapta yer alan bölümlerde kullanılan kaynakların, görüşlerin, bulguların, sonuçların, tablo, şekil, resim ve her türlü içeriğin sorumluluğu yazar veya yazarlarına ait olup ulusal ve uluslararası telif haklarına konu olabilecek mali ve hukuki sorumluluk da yazarlara aittir."

DECISION SCIENCE IN SMART LOGISTICS: DATA-DRIVEN AND AI-BASED APPROACHES

İrem KARAKAYA¹

1. INTRODUCTION

As the global trend toward digitalization accelerates, logistics is no longer limited to transportation, storage, and distribution activities. Today, it has evolved into a complex system in which data, information, and decision-making processes are fully integrated. This transformation is referred to as smart logistics (Uckelmann 2008). Smart logistics represents a network-based, adaptive, and self-learning structure supported by technologies such as Information and Communication Technologies (ICT), the Internet of Things (IoT), Machine Learning (ML), Artificial Intelligence (AI), Deep Learning (DL), and optimization methods.

Although the concept of smart logistics has been defined from various perspectives in the literature, the common theme is the evolution of systems capable of autonomous decision-making, learning, and collaboration (Ding et al. 2021). In this context, five main subtypes are recognized: Autonomous Logistics (AL), Intelligent Transportation Systems (ITS), Physical Internet (PI), Smart Freight (SF), and Customer-Oriented Intelligent Logistics (COIL). The general structure of these subtypes and their relationship with decision science are illustrated in Figure 1.

¹ Dr., Department of Management and Organisation, Bartın University, 74100 Bartın, Türkiye, ORCID: 0000-0003-3176-1518.

SMART LOGISTICS



Figure 1. Five types of smart logistics

Each subtype of smart logistics focuses on distinct dimensions from a decision science perspective, including data-driven management, connected network structures, sensor-based monitoring, and customer-oriented service quality (Winkelhaus and Grosse 2020). This approach aims to enhance the agility, resilience, and sustainability of supply chains through both horizontal and vertical integration.

At the core of this new logistics paradigm lies decision science, which integrates data collection, modeling, simulation, and optimization processes to enable optimal decision-making under uncertainty. Beyond retrospective analysis, it also provides strategic direction to logistics processes through predictive and prescriptive models (Keeney and Raiffa 1993).

Within this framework, smart logistics systems have become one of the prominent application domains of decision

science. Models based on AI, ML, and DL enable logistics systems to adapt dynamically to changing conditions, generate predictive decisions, and optimize resource utilization through big data analytics (Oğuz and Yalçıntaş 2024; Woschank, Rauch, and Zsifkovits 2020). Decision science transforms these technologies into a systematic methodology, allowing for the design of continuously learning, human-machine-interactive decision mechanisms that operate within the data-model-decision-learning cycle (Yang, Zhang, and Yu 2025).

The literature reveals a growing body of research grounded in the decision science perspective within smart logistics. This chapter examines selected academic studies published between 2020 and 2025, identifying methodological and applied trends in the implementation of decision science principles. The reviewed studies cluster around themes such as data-driven decision support systems, hybrid AI models, optimization algorithms, driver behavior analysis, sustainability indicators, and real-time decision systems (see Tables 1–3).

Recent research has primarily focused on integrating AI, ML, big data analytics, and optimization techniques into logistics decision-making processes. However, most studies focus on a single decision level, with limited attention to holistic approaches that jointly consider strategic, tactical, and operational decision-making dimensions (Schmidt and Wilhelm 2000). Moreover, while data-driven and hybrid models are increasingly prevalent, comprehensive analyses evaluating their overall impact on smart logistics decision systems remain scarce.

Therefore, the objective of this chapter is to provide an integrated perspective on how decision-making processes in smart logistics are developed, which problem areas they target, and how emerging research directions are expected to evolve in the near future.

2. DECISION-MAKING IN SMART LOGISTICS

Smart logistics systems are integrated frameworks that embed data-driven decision-making processes across all levels of logistics operations. Within these systems, decision science plays a critical role at three distinct yet interconnected levels: strategic, tactical, and operational (Schmidt and Wilhelm 2000).

At the strategic level, long-term decisions such as network design, facility location selection, and sustainable supply chain policy development are emphasized. The tactical level involves medium-term decision processes, including inventory management, route optimization, and capacity planning. At the operational level, short-term and dynamic decisions are made regarding real-time monitoring, distribution scheduling, resource allocation, and driver behavior management.

When considered collectively, these three levels demonstrate that decision science in smart logistics is not merely an algorithmic tool, but a core component of a holistic management approach. The methodological perspectives and thematic contributions of studies published between 2020 and 2025 are summarized within this three-level decision framework (see Tables 1–3).

Table 1. Strategic-level decision frameworks

Reference	Area	Decision Problem	Method	Data Type	Objective	Result
(Alkhodair and Alkhudhayr 2025)	Supply chain / Smart manufacturing	IoT–Blockchain–AI integration	Literature review	Secondary data	Enhance sustainability	IoT + Blockchain + AI combination showed the highest impact
(Shee, Miah, and Vass 2025)	Smart supply chain	Modeling the impact of AI and digital technologies on supply chain performance	Structural Equation Modeling (SEM)	Survey data	Examine the effect of AI-based digital transformation on sustainable performance	Integration of AI and digital technologies significantly improves sustainability performance

At the strategic level (see Table 1), research in smart logistics emphasizes sustainability, digital transformation, and system integration objectives. The reviewed studies reveal that

the integration of Industry 4.0 technologies, such as IoT, blockchain, and AI, significantly enhances supply chain performance, while data sharing and transparency have a direct impact on sustainability indicators.

In particular, (Shee et al. 2025) empirically demonstrated that AI-driven digital transformation substantially improves firms' sustainable performance. These findings indicate that, at the strategic level, decision science functions not merely as a technical analytical tool but as a guiding framework for organizational digital transformation strategies within smart logistics systems.

Table 2. Tactic-level decision frameworks

Reference	Area	Decision Problem	Method	Data Type	Objective	Result
(Žunić, Đonko, and Buza 2020)	Vehicle Routing Problem (VRP)	Solving VRP with heterogeneous fleets and time windows	Heuristic + adaptive algorithm with GLM/SVM prediction	Benchmark + real data	Minimize total route cost	All routes feasible, financial savings achieved
(Dieter, Caron, and Schryen 2023)	Last-mile logistics	Time-windowed TSP with driver behavior-based routing	Hybrid ML + optimization (VNS)	Real data	Optimize deviation–cost balance	Reduced route costs while maintaining driver compliance
(Manafi and Sayan 2025)	Multimodal transport	Integrated network design	LSTM + robust optimization (HA-ε, GRASP-AVNS)	Real case + scenario data	Minimize cost, maximize service level	Cost reduced by 15%, response rate improved by 20% under disruptions
(Yazdani, Shahriari, and Haghani 2025)	Emergency logistics	Ambulance allocation and routing for patient transfer	GA + Bayesian ARIMA	Scenario data	Reduce risk, travel, and waiting times	Waiting time reduced to 2.34 units, achieving 22–34% time savings
(Issaoui et al. 2022)	Smart logistics / e-commerce	Delivery time prediction and routing problem	Deep learning (LSTM) + hybrid optimization (Dijkstra, PSO, ACO)	Real operational data	Improve delivery efficiency by reducing time and cost	Achieved high accuracy (MAPE $\approx$ 0.122) and fast convergence

At the tactical level (see Table 2), studies clearly reveal the hybrid nature of decision science, which integrates prediction and optimization within smart logistics systems. The proposed models combine Genetic Algorithms (GA), Variable

Neighborhood Search (VNS), and robust optimization techniques with predictive models such as Long Short-Term Memory (LSTM) networks, Support Vector Machines (SVM), and regression-based methods to address multi-criteria decision problems.

These hybrid approaches have shown significant improvements in cost reduction, operational speed, and flexibility, particularly in route planning, multimodal transport, emergency logistics, and e-commerce logistics. The findings highlight that AI-driven hybrid decision systems enhance adaptability and resilience under uncertainty, thereby reinforcing supply chain robustness and performance.

Table 3. Operational-level decision frameworks

Reference	Area	Decision Problem	Method	Data Type	Objective	Result
(Bu 2021)	Urban distribution	Time-windowed VRP optimization	ML (multi-label learning) + heuristic route operators	Synthetic / case data	Reduce delivery cost	ML-based approach improved cost and accuracy
(Zhou et al. 2021)	Warehouse / internal logistics	ULD handling sequence, station assignment, vehicle scheduling	Simulation + multi-objective optimization (MO-COMPASS)	Real facility data	Reduce operation time	Sorting time reduced by 20%, saving 3600 man-hours annually
(Diame et al. 2023)	Intelligent transport	Driver distraction detection and DSS warning system	Semi-supervised learning (SS-ELM, SVM)	Experimental data	Enhance driving safety and decision support	SS-ELM achieved 97.2% accuracy, best model performance
(Pegado-bardayo et al. 2023)	Last-mile logistics	Service failure prediction	ML (Extra Trees), clustering (Ward)	Real operational data	Improve service level	44.4% of failed services correctly predicted on planned routes
(Singgih and Singgih 2024)	Transport / route planning	GA objective prediction	Regression ML (Random Forest, GLM, RidgeCV)	Synthetic data	Reduce GA runtime	Random Forest achieved <1s runtime, ~1800x faster

Operasyonel At the operational level (see Table 3), studies focus on enhancing real-time decision-making and responsiveness in logistics systems. Machine learning, simulation, and data-driven modeling approaches dominate this level, addressing short-term decisions in urban distribution, in-

warehouse operations, driver behavior analysis, and last-mile delivery.

Findings highlight that model speed, data quality, and online learning capability are key determinants of operational performance. ML-based decision support systems have demonstrated meaningful improvements in cost efficiency, accuracy, and process time reduction. Consequently, this level represents a shift toward automation, speed, and efficiency-oriented transformation within smart logistics operations.

When examined together, the three decision levels reveal that decision science in smart logistics has evolved into a multi-layered and integrated framework. At the strategic level, research emphasizes sustainability, digital transformation, and data sharing. At the tactical level, hybrid approaches combining forecasting and optimization have become the key enabler of decision efficiency. At the operational level, advances in data quality, model speed, and online learning capacity have strengthened real-time decision support systems.

Across the 2020–2025 period, the literature demonstrates a clear trend: decision science in smart logistics has been redefined through data-driven approaches at all levels. Speed and accuracy dominate the operational layer; hybrid AI-optimization methods characterize the tactical layer; and sustainability with transparency defines the strategic layer. Together, these developments mark a shift from digitalization-centered systems to decision-centered ecosystems.

Overall, decision science has matured from being a purely computational tool into a systematic, scalable, and sustainable management paradigm. It now plays a strategic and transformative role in shaping the digitalization of smart logistics—laying the foundation for future agile, autonomous, and resilient logistics networks.

3. LITERATURE TRENDS

Between 2020 and 2025, research in smart logistics has demonstrated a clear paradigm shift in decision science, moving from descriptive data use toward predictive and prescriptive intelligence. The literature reveals not only an expansion in methodological diversity but also a deepening in analytical focus where data-driven reasoning, ML, and optimization-based decision systems converge to enhance both the autonomy and adaptability of logistics operations. This evolution reflects a transition from process automation to cognitive decision-making frameworks, positioning decision science as a central enabler of intelligent logistics management.

Moreover, cross-domain interactions among the major smart logistics types indicate a growing interdisciplinarity in research perspectives. While much of the scholarship still centers on transport optimization, routing efficiency, and customer service quality, the emergence of topics such as production–logistics integration, sustainable supply networks, and autonomous decision architectures signals a maturing field that integrates operational intelligence with strategic foresight.

Overall, the period marks a methodological convergence and conceptual broadening in which decision science evolves from being a technical component into a systemic paradigm that bridges analytics, autonomy, and sustainability in smart logistics.

3.1. Trends Across Smart Logistics Application

To understand the main orientations in recent smart logistics research, twelve studies published between 2020 and 2025 were analyzed according to their application domains (see Table 4 and Figure 2). The results show that most research concentrates on PI, SF, and COIL, which together account for nearly three-quarters of all reviewed works. This concentration suggests that the field still revolves largely around transportation-

and customer-centered subsystems, where efficiency and service quality remain the dominant objectives.

Studies focusing on the PI emphasize digital connectivity, data exchange, and sustainability as key enablers of integrated supply chain performance. The SF research primarily addresses route optimization, cost reduction, and operational validation through real-world logistics data. Meanwhile, the COIL focuses on e-commerce and last-mile delivery, prioritizing customer experience, service reliability, and timing accuracy.

In contrast, AL and ITS appear less frequently but introduce crucial forward-looking perspectives such as logistics automation, driver-behavior analytics, and safety intelligence. Although these subfields are still emerging, they reflect the growing importance of autonomy and predictive intelligence in logistics operations.

This distribution reveals a dual research trajectory. While most studies remain grounded in traditional, efficiency-oriented models of transportation logistics, an increasing number of works are shifting toward autonomous, adaptive, and decision-centric systems. This trend marks a transition from technology-driven innovation to a decision-science-oriented paradigm, where intelligence, connectivity, and sustainability converge to redefine the future of smart logistics.

Table 4. Classification of reviewed studies by smart logistics types

Reference	Smart Logistics Type	Focus Area
(Alkhodair and Alkhudhayr 2025)	PI	Manufacturing–logistics integration, IoT and blockchain-based network connectivity
(Bu 2021)	COIL	Urban distribution, customer service level, and cost optimization
(Diame et al. 2023)	ITS	Driver behavior analysis, safe driving, and decision support system development
(Singgih and Singgih 2024)	SF	Route prediction, transport efficiency, and rapid solution generation
(Manafi and Sayan 2025)	PI	Multimodal transport and global network design, resilience-oriented
(Zhou et al. 2021)	AL	Semi-automated warehouse management, IoT-based process control

(Pegado-bardayo et al. 2023)	COIL	Last-mile delivery performance and customer notification optimization
(Žunić et al. 2020)	SF	Real fleet routing and transportation cost reduction
(Shee et al. 2025)	PI	Supply chain sustainability through digital connectivity and AI integration
(Dieter et al. 2023)	SF	Driver-behavior-aware route planning, hybrid decision support system
(Yazdani et al. 2025)	ITS	Emergency transportation, real-time optimization
(Issaoui et al. 2022)	COIL	E-commerce delivery time prediction and route optimization




Figure 2. Distribution of reviewed articles across smart logistics domains

In sum, although the field retains a transportation-focused foundation, emerging trends underscore a rising emphasis on customer-oriented services and autonomous systems. This transition highlights the increasing relevance of human-machine collaboration, digital network integration, and sustainability considerations as essential components of decision-science-driven smart logistics.

3.2. Methodological Trends

This subsection analyzes the methodological distribution of smart logistics research, revealing which modeling approaches underpin contemporary decision-science applications. The

reviewed studies demonstrate a clear methodological diversity, which can be grouped into four major categories:

- (1) ML-based approaches,
- (2) Hybrid AI and optimization models,
- (3) Simulation and heuristic techniques,
- (4) Statistical or literature-based analyses.

This distribution indicates that decision science in smart logistics has evolved beyond simple algorithmic improvement, toward an integrated use of multiple AI layers across different decision contexts.

ML-based studies (Bu 2021; Diame et al. 2023; Issaoui et al. 2022; Pegado-bardayo et al. 2023; Singgih and Singgih 2024), employ supervised and semi-supervised learning, regression, and network-based models to address tasks such as route prediction, demand forecasting, and service completion analysis. These methods have proven effective in enhancing short-term decision accuracy and system adaptability, particularly when trained on real operational data.

Hybrid AI and optimization models (Dieter et al. 2023; Manafi and Sayan 2025; Yazdani et al. 2025; Žunić et al. 2020), combine machine-learning techniques with meta-heuristic algorithms such as GA, VNS, and Particle Swarm Optimization (PSO) to solve complex, multi-criteria logistics problems. These hybrid frameworks significantly improve decision quality under uncertainty, especially in domains like multimodal transport and emergency logistics.

Simulation and heuristic approaches (Zhou et al. 2021) focus on optimizing internal logistics and warehouse operations using process-level data, effectively reducing operational times and improving micro-level efficiency within logistics systems.

Finally, statistical and literature-based analyses (Alkhodair and Alkhudhayr 2025; Shee et al. 2025) examine sustainability, digital transformation, and industrial decision systems at a macro level. Such studies play a crucial role in defining the strategic dimension of decision science, linking analytical modeling to long-term policy and industrial transformation.

Figure 3 illustrates the distribution of reviewed studies by methodological category, revealing the clear predominance of machine-learning and hybrid AI–optimization models. Although statistical, literature-based, and simulation studies are fewer in number, they offer distinctive contributions at strategic and operational levels.




Figure 3. Distribution of reviewed articles by methodological category

The 2020–2025 smart logistics literature reflects a marked transition toward data-driven, adaptive, and multi-layered decision systems. This shift suggests that decision science is no longer merely an analytical tool but rather the core of an integrated, human–machine decision ecosystem that defines the next generation of smart logistics.

4. CONCLUSION

This chapter has examined twelve academic studies published between 2020 and 2025 to provide a comprehensive view of how the decision science perspective in smart logistics has evolved. The findings suggest that smart logistics represents not merely a technological transformation but the institutionalization of a data-driven decision-making culture, marking a new managerial paradigm in logistics.

The results confirm that decision science plays three complementary roles across the operational, tactical, and strategic levels. At the operational level, ML and data analytics techniques enhance real-time decision accuracy and process efficiency. At the tactical level, hybrid AI–optimization models strengthen uncertainty management and multi-criteria problem solving in tasks such as route planning and capacity allocation. At the strategic level, sustainability, digital transformation, and resilience policies, implemented through PI and autonomous systems, aim to build long-term supply chain robustness.

From an application standpoint, the reviewed studies indicate a strong focus on transportation, last-mile logistics, and multimodal network design, confirming that the field still gravitates around transportation-centric domains. However, an increasing emphasis on customer-oriented service quality, sustainability, and autonomous system integration reveals an ongoing shift in research priorities.

Methodologically, ML and hybrid AI–optimization approaches clearly dominate the literature, demonstrating that decision science is evolving from a supportive analytical tool into an active shaper of decision-making itself.

The findings point to the emergence of a data-driven, hybrid, and multi-level management approach in smart logistics. Future research should focus on explainable AI, digital twin–

based scenario simulations, and resilience-oriented multimodal network designs (for example, PI-enabled supply chains). Moreover, developing standardized frameworks for data sharing in sustainable supply chains will be essential to institutionalize decision science practices across industries.

In conclusion, decision science provides a learning, guiding, and transformative framework that connects planning, execution, and evaluation within smart logistics systems—forming the foundation for resilient and sustainable logistics in the future.

Simply put, the future of smart logistics will depend not only on intelligent technologies but also on intelligent decisions that adapt, learn, and align with long-term sustainability goals.

REFERENCES

- Alkhodair, Majid, and Hanadi Alkhudhayr. 2025. "Harnessing Industry 4.0 for SMEs: Advancing Smart Manufacturing and Logistics for Sustainable Supply Chains." *Sustainability* 17(3):813.
- Bu, Suhua. 2021. "Logistics Engineering Optimization Based on Machine Learning and Artificial Intelligence Technology." 40:2505–16. doi: 10.3233/JIFS-189244.
- Diame, Hussein Alaa, Waleed Hameed, Zainab R. Abdulsada, Noora Hani Sherif, and Noor H. Haroon. 2023. "Machine Learning Based Logistic Decision Support System for Intelligent Vehicles and Transportation Systems." 09(02):108–19.
- Dieter, Peter, Matthew Caron, and Guido Schryen. 2023. "Integrating Driver Behavior into Last-Mile Delivery Routing : Combining Machine Learning and Optimization in a Hybrid Decision Support Framework." 311:283–300. doi: 10.1016/j.ejor.2023.04.043.
- Ding, Yangke, Mingzhou Jin, Sen Li, and Dingzhong Feng. 2021. "Smart Logistics Based on the Internet of Things Technology: An Overview." *International Journal of Logistics Research and Applications* 24(4):323–45. doi: 10.1080/13675567.2020.1757053.
- Issaoui, Yassine, Azeddine Khiat, Karim Haricha, Ayoub Bahnasse, and Hassan Ouajji. 2022. "An Advanced System to Enhance and Optimize Delivery Operations in a Smart Logistics Environment." *IEEE Access* 10:6175–93. doi: 10.1109/ACCESS.2022.3141311.
- Keeney, Ralph L., and Howard Raiffa. 1993. *Decisions with Multiple Objectives: Preferences and Value Trade-Offs*. Cambridge university press.

- Manafi, Bahman, and Hakan Sayan. 2025. "Journal of Industrial Information Integration A Bi-Objective Robust Optimization and Heuristic Framework for Designing Resilient and Responsive Global Supply Chains with Multimodal Transportation." *Journal of Industrial Information Integration* 47(June):100895. doi: 10.1016/j.jii.2025.100895.
- Oğuz, Suzan, and Deniz Yalçıntaş. 2024. "A Review on The Use of Artificial Intelligence and Machine Learning Technologies in The Logistics Sector." *Trends in Business and Economics* 38(4):218–25.
- Pegado-bardayo, Ana, Antonio Lorenzo-espejo, Jesús Mu, and Pablo Aparicio-ruiz. 2023. "A Data-Driven Decision Support System for Service Completion Prediction in Last Mile Logistics." 176(February):1–18. doi: 10.1016/j.tra.2023.103817.
- Schmidt, G., and Wilbert E. Wilhelm. 2000. "Strategic, Tactical and Operational Decisions in Multi-National Logistics Networks: A Review and Discussion of Modelling Issues." *International Journal of Production Research* 38(7):1501–23. doi: 10.1080/002075400188690.
- Shee, Himanshu Kumar, Shah J. Miah, and Tharaka De Vass. 2025. "Impact of Smart Logistics on Smart City Sustainable Performance : An Empirical Investigation." 32(3):821–45. doi: 10.1108/IJLM-07-2020-0282.
- Singgih, Ivan Kristianto, and Moses Laksono Singgih. 2024. "Regression Machine Learning Models for the Short-Time Prediction of Genetic Algorithm Results in a Vehicle Routing Problem." *World Electric Vehicle Journal* 15(7):308.

- Uckelmann, Dieter. 2008. "A Definition Approach to Smart Logistics BT - Next Generation Teletraffic and Wired/Wireless Advanced Networking." Pp. 273–84 in, edited by S. Balandin, D. Moltchanov, and Y. Koucheryavy. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Winkelhaus, Sven, and Eric H. Grosse. 2020. "Logistics 4.0: A Systematic Review towards a New Logistics System." *International Journal of Production Research* 58(1):18–43.
- Woschank, Manuel, Erwin Rauch, and Helmut Zsifkovits. 2020. "A Review of Further Directions for Artificial Intelligence, Machine Learning, and Deep Learning in Smart Logistics." *Sustainability* 12(9):3760.
- Yang, Fan, Xiaojuan Zhang, and Zhiwen Yu. 2025. "Human–Machine Collaborative Learning for Streaming Data-Driven Scenarios." *Sensors* 25(21):6505.
- Yazdani, Maziar, Siroos Shahriari, and Milad Haghani. 2025. "Progress in Disaster Science Real-Time Decision Support Model for Logistics of Emergency Patient Transfers from Hospitals via an Integrated Optimisation and Machine Learning Approach." *Progress in Disaster Science* 25(December 2024):100397. doi: 10.1016/j.pdisas.2024.100397.
- Zhou, Chenhao, Aloisius Stephen, Xinhua Cao, Shuhong Wang, and Aloisius Stephen. 2021. "A Data-Driven Business Intelligence System for Large-Scale Semi-Automated Logistics Facilities." 7543. doi: 10.1080/00207543.2020.1727048.
- Žunić, Emir, Dženana Đonko, and Emir Buza. 2020. "An Adaptive Data-Driven Approach to Solve Real-World

Vehicle Routing Problems in Logistics.” *Complexity*
2020(1):7386701.

ZAMAN SERİLERİ VE NEDENSEL MAKİNE ÖĞRENMESİ YAKLAŞIMLARIYLA ENERJİ TALEP TAHMİNİ

Hüseyin Avni ES¹

1. GİRİŞ

Enerji, günümüz toplumlarında ekonomik kalkınma, sanayileşme, teknolojik gelişme ve yaşam standartlarının sürdürülebilirliği açısından stratejik bir unsur haline gelmiştir. Dünya genelinde enerji talebi, nüfus artışı, ekonomik büyüme ve teknolojik ilerlemelerle birlikte hızla artmaktadır. 1970'lerden bu yana, birincil enerji tüketimi dünya çapında yıllık %2,5 oranında artış göstermiştir (IEA, 2023). Gelişmekte olan ülkelerdeki endüstriyel büyüme ve kentleşme, enerji talebindeki artışın temel nedenleri arasında yer almaktadır. Türkiye özelinde ise, enerji talebi 1970'lerde 18,85 milyon ton eşdeğer petrol (MTEP) iken, 2024 yılında 165,2 MTEP seviyesi ulaşmıştır. Enerji talebinin doğru ve güvenilir tahmini hem enerji politikalarının etkin biçimde planlanabilmesi hem de sürdürülebilir kalkınma hedeflerinin gerçekleştirilmesi açısından kritik önem taşımaktadır. Türkiye, özellikle petrol ve doğal gaz rezervleri bakımından kendi ihtiyacını karşılayamayan bir ülke olduğundan, toplam enerji talebinin güvenli biçimde karşılanması sanayileşme sürecinin sürdürülebilirliği ve ekonomik kalkınmanın devamlılığı açısından kritik bir unsur haline gelmiştir. Bu nedenle, Türkiye'nin toplam enerji talebine yönelik doğru ve güvenilir tahminlerin gerçekleştirilmesi, uzun vadeli, istikrarlı ve etkin

¹ Doç. Dr., Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, ORCID: 0000-0003-4987-0173.

enerji politikalarının oluşturulmasında oldukça önem arz etmektedir.

Enerji talebinin önemine binaen literatürde birçok tahmin çalışması gerçekleştirilmiştir. Bu çalışmalarla ilgili olarak derleme makaleleri incelenerek ayrıntılı bilgilere ulaşılabilir (Suganti ve Samuel, 2012; Salisu ve Ayinde, 2016). Çalışma kapsamında toplam (birincil) enerji talebi ile alakalı makaleler özelinde son dönemlerde daha sık kullanılmaya başlayan ve başarılı sonuçlar sunabilen makine öğrenmesi temelli yöntemlere odaklanılmıştır. Literatür özetini sistematik bir şekilde sunmak amacıyla Moher ve ark. (2009) önerdiği PRISMA yaklaşımı ile anahtar kelimeler kullanılarak SCOPUS veri tabanında aramalar yapılmıştır ve sonuçları Tablo 1’de sunulmuştur.

Tablo 1. Literatür sorgulama özeti

Sorgu No	Detaylı SCOPUS Sorgu İfadesi	Çalışma Sayısı
1	(TS=("energy consumption") OR TS=("energy demand")) AND TS=(forecast)	8116
2	(TS=("energy consumption") OR TS=("energy demand")) AND TS=(forecast) AND TS=(machine learning)	1475
3	TS=("total energy") AND TS=(forecast) OR TS=("primary energy") AND TS=(forecast)	955
4	((TS=("total energy") AND TS=(forecast)) OR (TS=("primary energy") AND TS=(forecast))) AND TS=("machine learning")	77
5	(TS=("energy consumption") OR TS=("energy demand")) AND TS=(forecast) AND TS=(machine learning) AND TS=(Turkey)	22
6	(TS=("energy consumption") OR TS=("energy demand")) AND TS=(forecast) AND TS=(machine learning) AND TS=(Turkey) AND (AK=(primary energy) OR AK=(energy demand))	3

Tablo 1’de yer alan ilk sorguda literatürde gerçekleştirilen 8116 adet enerji talebi ile alakalı çalışmanın yer aldığı, ikinci sorguda ise makine öğrenmesi yöntemleriyle gerçekleştirilen çalışma sayısının 1475 olduğu görülmektedir. Toplam enerji

talebi için gerçekleştirilen 955 çalışma varken bunların 77 tanesinin makine öğrenmesi yöntemleriyle yapıldığı görülmektedir. Türkiye özelinde gerçekleştirilen enerji talep tahmini çalışma sayısının 22 olduğu makine öğrenmesi yöntemiyle ise 3 olduğu görülmektedir. Türkiye özelinde gerçekleştirilen çalışmalardan Ağbulut (2022) çalışmasında; Türkiye’de ulaştırma sektörüne ilişkin CO₂ emisyonlarını ve enerji talebini tahmin etmek için Yapay Sinir Ağları (ANN), Destek Vektör Regresyonu (DVR), Rastgele Orman (RF) ve Gradient Boosting gibi makine öğrenmesi algoritmalarını karşılaştırmalı olarak incelemiştir. Bulgular, bu algoritmaların geleneksel yöntemlere kıyasla daha yüksek doğruluk sunarak enerji planlaması ve çevresel etki değerlendirmesi için güçlü ve güvenilir araçlar olduğunu göstermektedir. Çodur (2023) tarafından yapılan çalışmada Türkiye’nin toplam enerji talebini tahmin etmek amacıyla birden fazla makine öğrenmesi algoritmasını bir araya getiren topluluk (ensemble) modellerinin performansını incelemektedir. Sonuçlar, özellikle Random Forest, Gradient Boosting ve Bagging tabanlı yöntemlerin yüksek doğruluk sağlayarak enerji talep projeksiyonlarında etkili ve güvenilir modeller sunduğunu göstermektedir. Bolat ve Yıldız (2025) ise Türkiye’nin enerji talebini ve CO₂ emisyon değerlerini derin öğrenme ve makine öğrenmesi algoritmalarıyla modellemiş ve karşılaştırmalı analizler sonucunda derin öğrenme tabanlı yaklaşımların daha yüksek tahmin doğruluğu sağladığı göstermiştir. Türkiye özelinde yapılan bu çalışmalarda nedensel (sebeup-sonuç ilişkisine dayalı) yöntemler kullanıldığı görülmüştür. Geçmiş gözlem değerleri ile gerçekleştirilen zaman serisine dayalı yöntemler başarılı ve güvenilir sonuçlar sağlayabilmektedir. Bu bağlamda bu kitap bölümünde hem zaman serisi hem de nedensel makine öğrenmesi yöntemleri ile Türkiye toplam enerji talep tahmini çalışması gerçekleştirilmiştir.

2. TAHMİN YÖNTEMLERİ

Tahmin yöntemleri; sebep–sonuç ilişkilerine dayalı tahmin yöntemleri ve zaman serilerine dayalı tahmin yöntemleri olmak üzere genel olarak iki ana kategoriye ayrılabilir. Nedensel (sebep–sonuç ilişkisine dayalı) yöntemler arasında regresyon analizi, yapay sinir ağları, destek vektör makineleri, rassal orman ve karar ağaçları gibi çeşitli algoritmalar bulunmaktadır. Bu yöntemler, belirli değişkenler arasındaki nedensel ilişkileri modelleyerek gelecek tahmin değerlerini öngörmeyi amaçlar. Öte yandan, zaman serilerine dayalı tahmin yöntemleri arasında üstel düzeltme, ARIMA modelleri, uzun-kısa vadeli bellek ağları (LSTM) ve evrimsel sinir ağları (CNN) gibi yöntemler yer almaktadır. Bu yöntemler zamana bağlı verileri analiz ederek eğilimleri ve mevsimsellik gibi desenleri yakalamakta ve gelecekteki değeri bu verilere dayalı olarak tahmin etmektedir. Bu çalışmada, Türkiye’nin enerji talebini öngörmek üzere her iki yaklaşımın sunduğu yöntemler birlikte ele alınmış ve farklı makine öğrenmesi algoritmaları karşılaştırmalı olarak değerlendirilmiştir. Kullanılan yöntemler aşağıdaki bölümlerde kısaca açıklanmıştır.

2.1. Nedensel Makine Öğrenmesi Yöntemleri

Nedensel makine öğrenmesi yöntemleri olarak beş farklı yöntem ele alınmış olup kısa açıklamaları aşağıda sunulmuştur.

2.1.1. Karar Ağacı Regresyonu (KAR)

KAR, veri setini dallara ve yapraklara ayırarak sürekli hedef değişkenlerini tahmin eden açıklanabilir bir yöntemdir. Model, her düğümde hedef değişkenin varyansını en çok azaltan değişkeni seçerek parçalı bir karar yapısı oluşturur (Salem ve ark., 2025a).

2.1.2. Rassal Orman Regresyonu (ROR)

ROR, çok sayıda karar ağacının rastgele örneklerle eğitilmesi ve sonuçlarının birleştirilmesiyle daha kararlı ve yüksek doğruluk sağlayan güçlü bir topluluk yöntemidir. Aşırı öğrenme riskini azaltması ve karmaşık yapılarda yüksek doğruluk vermesi, yöntemi enerji talebi tahminlerinde etkili kılmaktadır (Salem ve ark., 2025b).

2.1.3. K-En Yakın Komşu Regresyonu (KNNR)

KNN regresyonu, tahmin yapılacak gözlemin en yakın komşularının hedef değerleri üzerinden tahmin üreten örnektemelli bir yaklaşımdır. Parametrik olmayan yapısı nedeniyle veri dağılımına dair varsayım gerektirmez (Hong ve ark., 2022).

2.1.4. Yapay Sinir Ağları (YSA)

Yapay sinir ağları, çok katmanlı yapısıyla karmaşık doğrusal olmayan ilişkileri modelleyebilen güçlü makine öğrenmesi yöntemleridir. Büyük veri yapılarında, giriş ve çıkış arasındaki yüksek karmaşıklık öğrenilmesi sayesinde tahmin problemlerinde yüksek doğruluk sağlamaktadır (Demircioğlu & Eşiyok, 2022).

2.1.5. Destek Vektör Regresyonu (DVR)

Destek vektör regresyonu, çekirdek fonksiyonları aracılığıyla girdileri yüksek boyutlu özellik uzayına dönüştürerek doğrusal olmayan ilişkilerin etkin şekilde modellenmesini sağlar (Rao ve ark., 2023).

2.2. Zaman serisine dayalı Makine Öğrenmesi Yöntemleri

Zaman serisine dayalı makine öğrenmesi yöntemleri olarak iki farklı yöntem ele alınmış olup kısa açıklamaları aşağıda sunulmuştur.

2.2.1. Uzun Kısa Süreli Bellek Ağları (LSTM)

LSTM modelleri, klasik tekrarlayan sinir ağlarında görülen gradyan sönümlenmesi sorununu çözmek üzere geliştirilmiş kapı mekanizmalarına sahip özel bir derin öğrenme mimarisidir. Bu kapılar, modelin geçmiş bilgiyi ne kadar saklayacağına ve ne kadar unutacağına karar vererek uzun dönemli bağımlılıkları öğrenmesine olanak sağlar (Chen ve Fu, 2023).

2.2.2. Konvolüsyonel Sinir Ağları (CNN)

CNN tabanlı modeller, zaman serilerindeki lokal örüntüleri yakalamak için konvolüsyon filtreleri kullanarak veri içinde kısa dönemli bağımlılıkların etkili şekilde çıkarılmasına imkân tanır. Bu yöntem, zamansal verinin eğilim ve dalgalanmalarını otomatik olarak öğrenir ve önemli özellikleri öne çıkarır (Chen ve Fu, 2023).

3. UYGULAMA

Bu çalışmada toplam enerji talebinin tahminine yönelik olarak iki farklı modelleme yaklaşımı uygulanmıştır. Bu iki yapısal yaklaşımın birlikte ele alınması, hem ekonomik ve yapısal göstergelerin enerji talebi üzerindeki etkilerinin anlaşılmasını hem de zaman serilerinin içsel dinamiklerinin güçlü biçimde modellenmesini mümkün kılmaktadır.

3.1. Veri Seti

Nedensel yaklaşımda, toplam enerji talebinin ekonomik ve sosyo-demografik göstergelerle olan ilişkisini modellemek amacıyla bağımlı değişken olarak toplam enerji tüketimi, bağımsız değişkenler olarak ise nüfus, gayrisafi milli hasıla (GSMH), ithalat ve ihracat değişkenleri kullanılmıştır.

Zaman serisine dayalı yöntemlerde ise bağımlı değişken dışsal faktörlerden ayrıştırılarak, yalnızca toplam enerji talebinin geçmiş değerlerine dayalı bir tahmin süreci yürütülmüştür. Kullanılan veri seti ile alakalı bilgiler Tablo 2’de özetlenmiştir.

Tablo 2. Bağımlı ve Bağımsız Değişkenler

Bağımlı Değişken	Birim	Kaynak
Toplam enerji	exajoule	BP Stat
Bağımsız Değişkenler		
Nüfus	kişi	Türkiye İstatistik Kurumu (TÜİK)
GSMH	zincirlenmiş	TÜİK
İthalat	dolar	TÜİK
İhracat	dolar	TÜİK

3.2. Yöntem Kıyaslama

Modellerin tahmin başarımını değerlendirmek amacıyla Ortalama Mutlak Yüzde Hata (OMYH) ölçütü kullanılmıştır. OMYH, gerçek değer ile tahmin edilen değer arasındaki mutlak farkın gerçek değere oranının ortalaması olarak hesaplanmakta olup, hata yüzdesi biçiminde modelin doğruluğunu değerlendirmektedir. Bu yönüyle farklı ölçeklerdeki modellerin karşılaştırılmasına imkân tanıyan güvenilir bir performans göstergesidir.

Nedensel yöntemlere ait veri seti 1999-2018 yılları için eğitilmiş ve 2019-2023 dönemi için test edilmiştir. Yöntemlere ait sonuçlar Tablo 3’de sunulmuştur.

Tablo 3. Nedensel yöntem kıyaslamaları (%)

Dönem	KAR	ROR	KNNR	DVR	YSA
Eğitim kümesi (1999–2018)	1.01	1.21	1.92	1.35	2.09
Test kümesi (2019–2023)	11.85	10.35	6.35	9.68	3.50

Nedensel yöntemlerde eğitim dönemi sonuçları incelendiğinde, en düşük hata değerinin KAR ve ROR tarafından elde edildiği görülmektedir. Bu durum, ağaç tabanlı yöntemlerin eğitim verisine oldukça iyi uyum sağladığını göstermektedir.

Diğer yöntemlerde de benzer şekilde düşük eğitim hataları gözlenmiştir.

Test dönemi sonuçları incelendiğinde, yöntemler arasında belirgin performans farklılıkları ortaya çıkmaktadır. En düşük hata oranı YSA ile elde edilmiştir. YSA'yı sırasıyla KNNR ve DVR takip etmektedir. Ağaç tabanlı yöntemlerin test döneminde hata değerlerinin yükselmesi, bu modellerin test verisine genelleme performansının sınırlı olduğunu göstermektedir. Bununla birlikte, nedensel yöntemler içinde en tutarlı performansı YSA'nın sağladığı sonucuna ulaşılmaktadır.

Zaman serisi tahmini için uzun dönemli veri ile çalışmak daha faydalı olacağı için veri seti daha geniş tutulmuştur. 1965-2018 yılları eğitim kümesi ve 2019-2023 yılları ise test kümesi olarak dikkate alınmıştır. Zaman Serisine Dayalı Yöntemlerin Sonuçları ise Tablo 4'te sunulmuştur.

Tablo 4. Zaman serisi yöntem kıyaslamaları (%)

Dönem	LSTM	CNN
Eğitim kümesi (1965–2018)	3.24	5.96
Test kümesi (2019–2023)	4.91	7.36

Elde edilen sonuçlar LSTM'nin zaman bağımlılıklarını CNN'e göre daha iyi öğrenebildiğini göstermektedir. Test dönemi karşılaştırmaları da bu sonucu desteklemektedir. LSTM test döneminde OMYH = 4,91 elde ederken, CNN modeli OMYH = 7,36 hata oranına sahiptir. Böylece LSTM modeli zaman serisi yapısındaki trend ve mevsimselliği daha başarılı temsil ederek daha yüksek tahmin doğruluğu sağlamıştır. Sonuç olarak, nedensel yöntemler arasında en başarılı performansı YSA, zaman serisine dayalı yöntemler arasında ise LSTM göstermiştir.

Bu çalışmada, nedensel makine öğrenmesi yöntemleri arasında test döneminde en düşük hata oranını üreten **YSA** modelinin daha üstün performans göstermesi nedeniyle, gelecek dönem enerji talebi tahminleri YSA modeli kullanılarak

gerçekleştirilmiştir. Gelecek tahminlerinin daha gerçekçi bir çerçevede değerlendirilebilmesi amacıyla düşük ve yüksek senaryo olmak üzere iki farklı ekonomik senaryo oluşturulmuştur.

Her iki senaryoda nüfus bağımsız değişkeni için TÜİK tarafından yayımlanan yıl ortası nüfus tahminleri kullanılmıştır. Diğer bağımsız değişkenler olan GSYH, ithalat ve ihracat için ise geçmiş yıllardaki artış ve azalış eğilimleri dikkate alınarak yıllık yüzde değişim oranları belirlenmiştir. Düşük senaryo, ekonomik büyümenin yavaşladığı ancak sınırlı ölçüde de olsa pozitif seyrin devam ettiği bir durumu ifade etmektedir. Yüksek senaryo ise geçmiş dönemin ortalama ve ortalamasının üzerindeki performansını esas alarak ekonomik göstergelerde daha güçlü ve istikrarlı bir büyümenin sürdüğü durumu temsil etmektedir. Her iki senaryoya ait yıllık yüzde değişim değerleri Tablo 5'te sunulmuş olup, enerji talebinin farklı ekonomik koşullara duyarlılığı bu iki senaryo üzerinden değerlendirilmiştir.

Tablo 5. Senaryolar

	GSYH	İthalat	İhracat
Düşük Senaryo	1.30%	1.90%	2.20%
Yüksek Senaryo	5.20%	12.20%	14.20%


3.3. Gelecek Tahmin

Bu çalışmada, test dönemi performansı en yüksek olan YSA modeli kullanılarak 2024–2030 dönemi için Türkiye'nin toplam birincil enerji talebine ilişkin gelecek tahminleri elde edilmiştir. Tahminler, ekonomik göstergelerdeki olası gelişme seviyelerine bağlı olarak düşük ve yüksek olmak üzere iki ayrı senaryo kapsamında değerlendirilmiştir. Düşük senaryo, ekonomik büyümenin geçmiş döneme göre daha yavaş seyrettiği, ancak pozitif yönde istikrarlı bir artışın devam ettiği bir durumu temsil ederken; yüksek senaryo, ekonomik faaliyetlerin ortalama ve ortalamasının üzerindeki performansını sürdürdüğü, daha güçlü

büyüme koşullarının geçerli olduğu bir yapıyı yansıtmaktadır. Tahmin sonuçları Tablo 6’da sunulmuş olup geçmiş tüketim ve gelecek tahminler Şekil 1’de çizdirilmiştir.

Tablo 6. Gelecek Tahminler

Yıl	Düşük Senaryo (exajoule)	Yüksek Senaryo (exajoule)
2024	7.69	7.85
2025	7.77	8.07
2026	7.85	8.28
2027	7.92	8.46
2028	7.99	8.61
2029	8.06	8.73
2030	8.13	8.80



Şekil 1. Toplam enerji tüketimi ve gelecek tahmin grafiği

Elde edilen sonuçlar her iki senaryoda da toplam enerji talebinin 2024 yılından itibaren artış eğilimini sürdürdüğünü

göstermektedir. Düşük senaryoda enerji talebi 2024 yılında 7,70 exajoule seviyesindeyken, bu değer 2030 yılında 8,13 exajoule düzeyine yükselmektedir. Yüksek senaryoda ise talep artışı daha belirgindir; 2024 yılında 7,85 exajoule olan toplam enerji talebi, 2030 yılında 8,80 exajoule seviyesine ulaşmaktadır. Bu sonuçlar, Türkiye'nin enerji talebinin ekonomik gelişmelere oldukça duyarlı olduğunu ve güçlü büyümenin olduğu dönemlerde enerji tüketiminin daha hızlı arttığını göstermektedir.

Grafiksel eğilim incelendiğinde, her iki senaryonun da mevcut tarihsel trendle uyumlu şekilde pozitif yönlü bir seyir izlediği görülmektedir. Bununla birlikte yüksek senaryoda eğimin daha dik olması, enerji arz-talep planlaması açısından dikkat edilmesi gereken bir durumdur. Bu bağlamda, politika yapıcılar açısından enerji arz güvenliği, yenilenebilir enerji yatırımları ve talep yönetimi stratejilerinin farklı ekonomik koşullara göre yeniden değerlendirilmesi faydalı olacaktır.

4. SONUÇLAR

Bu çalışmada Türkiye'nin toplam enerji talebi, hem nedensel makine öğrenmesi yöntemleri hem de zaman serisine dayalı öğrenme modelleri kullanılarak kapsamlı biçimde analiz edilmiştir. Farklı modelleme yaklaşımlarının performans karşılaştırması, enerji talebinin hem ekonomik göstergelerle olan ilişkisini hem de zaman içerisindeki içsel dinamiklerini ortaya koymak açısından önemli bir çerçeve sunmuştur. Elde edilen bulgular, nedensel makine öğrenmesi yöntemleri içinde en başarılı performansın YSA tarafından üretildiğini göstermiştir. Test kümesinde en düşük OMYH değerini elde eden YSA modeli, enerji talebinin ekonomik değişkenlerle olan karmaşık ilişkisini en iyi temsil eden yöntem olmuştur. Bu nedenle gelecek dönem enerji talebi tahminleri YSA modeli kullanılarak gerçekleştirilmiştir.

Gelecek tahminlerinde, enerji talebinin farklı ekonomik koşullara duyarlılığını değerlendirebilmek amacıyla düşük ve yüksek olmak üzere iki senaryo oluşturulmuştur. Düşük senaryo, ekonomik büyümenin sınırlı hızda devam ettiği ve pozitif fakat zayıf bir iyileşme sürecinin sürdüğü bir yapıyı temsil etmektedir. Buna karşılık yüksek senaryo, geçmiş ortalama değerlerin üzerinde gerçekleşen, daha güçlü ve istikrarlı bir ekonomik performansa dayalı büyüme sürecini ifade etmektedir. Senaryolara ait değişken artış oranları geçmiş eğilimler dikkate alınarak belirlenmiş, toplam enerji talebi tahminleri bu oranlar doğrultusunda YSA modeli aracılığıyla hesaplanmıştır.

Elde edilen sonuçlara göre Türkiye'nin toplam enerji talebinin 2024 yılından itibaren her iki senaryoda da artmaya devam edeceği görülmektedir. Düşük senaryoda enerji talebi 2024 yılında 7,69 exajoule seviyesinde iken 2030 yılında 8,13 exajoule düzeyine ulaşmaktadır. Yüksek senaryoda ise aynı dönemde talep 7,85 exajoule seviyesinden başlayarak 2030 yılında 8,80 exajoule seviyesine yükselmektedir. Bu durum, ekonomik büyümenin daha güçlü gerçekleşmesi hâlinde enerji talebindeki artış hızının da belirgin şekilde yükseldiğini göstermektedir. Ayrıca grafiksel sonuçlar, geçmiş yıllardaki artış trendi ile tahmin edilen değerler arasında yapısal bir uyum olduğunu ortaya koymakta; modelin hem kısa vadeli hem de orta vadeli enerji politikaları açısından güvenilir bir öngörü sunduğunu doğrulamaktadır.

Genel olarak bulgular, Türkiye'nin enerji talebinin önümüzdeki yıllarda artmaya devam edeceğini ve bu artış hızının ekonomik büyümenin niteliğine duyarlı olduğunu göstermektedir. Bu nedenle enerji arz güvenliğinin sağlanması, yenilenebilir enerji yatırımlarının artırılması, dışa bağımlılığın azaltılması ve enerji verimliliği politikalarının güçlendirilmesi kritik önem taşımaktadır. Çalışma bulguları, karar vericilere enerji planlamasında hem ihtiyatlı hem de büyüme odaklı

senaryoları dikkate alarak uzun vadeli stratejiler geliştirme konusunda önemli bir analitik temel sağlamaktadır.

KAYNAKÇA

- Ağbulut, Ü. (2022). Forecasting of transportation-related energy demand and CO₂ emissions in Turkey with different machine learning algorithms. *Sustainable Production and Consumption*, 29, 141–157.
- Chen, Y., & Fu, Z. (2023). Multi-step ahead forecasting of the energy consumed by the residential and commercial sectors in the United States based on a hybrid CNN-BiLSTM model. *Sustainability*, 15(3), 1–21.
- Demircioğlu, M., & Eşiyok, S. (2022). Energy consumption forecast of Turkey using artificial neural networks. *International Journal of Sustainable Energy*, 41(8), 1127–1141.
- Hong, G., Choi, G.-S., Eum, J.-Y., Lee, H. S., & Kim, D. D. (2022). The hourly energy consumption prediction by KNN for buildings. *Buildings*, 12, 1636.
- IEA, 2023. World Energy Outlook 2023. <https://www.iea.org/reports/world-energy-outlook-2023>
- Kayacı Çodur, M. (2023). Ensemble machine learning approaches for prediction of Türkiye's energy demand. *Energies*, 17(1), 74.
- Moher, D., Liberati, A., Tetzlaff, J., & Altman, D. G. (2009). Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *Bmj*, 339.
- Rao, C., Zhang, Y., Wen, J., Xiao, X., & Goh, M. (2023). Energy demand forecasting in China: A support vector regression–compositional data second exponential smoothing model. *Energy*, 263, 125955.
- Salem, K. M., Rey-Hernández, J. M., Elgharib, A. O., & Rey-Martínez, F. J. (2025b). Optimizing energy forecasting

using ANN and RF models for HVAC and heating predictions. *Applied Sciences*, 15, 6806.

Salem, K. M., Rey-Martínez, F. J., Elgharib, A. O., & Rey-Hernández, J. M. (2025a). Energy demand forecasting scenarios for buildings using six AI models. *Applied Sciences*, 15(15), 8238.

Salisu, A. A., ve Ayinde, T. O., 2016. Modeling Energy Demand: Some Emerging Issues. *Renewable and Sustainable Energy Reviews*, 54, 1470-1480.

Suganthi, L., ve Samuel, A. A., 2012. Energy Models for Demand Forecasting—a Review. *Renewable and sustainable energy reviews*, 16(2), 1223- 1240.

GÜNEŞ ENERJİSİ YATIRIMLARININ İLLERE GÖRE ÖNCELİKLENDİRİLMESİNDE KÜMELEME ANALİZİ YAKLAŞIMI

Yasemin DÖNMEZ¹

Hüseyin Avni ES²

1. GİRİŞ

Günümüzde enerji, ekonomik kalkınmanın en temel itici güçlerinden biri olarak küresel ölçekte stratejik bir öneme sahiptir. Sanayi, hizmet ve konut sektörlerindeki hızlı büyüme; ulaşım, iletişim ve dijitalleşme odaklı yeni uygulamalar; hatta tarım ve su yönetimi gibi alanlar, artan enerji talebini doğurmuştur. Bu talebin büyük oranda fosil kaynaklara dayalı karşılanması ise hem tedarik güvenliği hem de çevresel sürdürülebilirlik bakımından kritik riskler barındırmaktadır. Uzun vadede rezervlerin tükenme olasılığı, fiyat dalgalanmaları ve iklim değişikliği etkileri, enerji arzında çeşitliliği ve yerli/yenilenebilir kaynakların payını artırmayı zorunlu kılmaktadır (Uzmen & Arar, 2025).

Karbon emisyonlarının azaltılması, dışa bağımlılığın düşürülmesi ve yenilenebilir kaynakların yaygınlaştırılması, birçok ülkenin enerji politikalarının merkezine yerleşmiştir. Rüzgâr, jeotermal, biyokütle ve hidroelektrik gibi kaynakların yanı sıra özellikle güneş enerjisi; düşük işletme maliyetleri, ölçeklenebilirlik ve hızla ilerleyen teknoloji sayesinde, geleceğin

¹ Yüksek Lisans Öğrencisi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, ORCID: 0000-0002-3249-6122.

² Doç. Dr., Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, ORCID: 0000-0003-4987-0173.

enerji sistemlerinde artan bir pay sunmaktadır. Yenilenebilir enerjinin enerji üretim portföyündeki yükselen oranı, teknolojik gelişmelerle paralel seyreden maliyet düşüşleri ve devlet teşvikleriyle pekişmektedir (Uzmen & Arar, 2025).

Güneş enerjisi, erişilebilirliği ve geniş coğrafi yayılımı sayesinde hem merkezi hem de dağıtık üretim modellerine uygundur. Fotovoltaik panellerin hızlı kurulum süreleri, düşük işletme-gider profili ve modüler büyüme imkânı; endüstriyel ölçekten çatı üstü sistemlere kadar farklı yatırımcı profillerine esneklik sunar. Dünya genelinde güneşten elde edilen elektrik üretimi, son on yılda yıllık ortalama %25–30 arasında büyüme kaydetmiş olup, bu eğilim teknolojik verimlilik artışları ve finansman modellerinin çeşitlenmesiyle ivme kazanmaktadır (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2025).

Türkiye’deki ekonomik ve sosyal gelişim, özellikle sanayi ve hizmet sektörlerindeki büyüme, elektrik enerjisine olan talebi önemli ölçüde artırmıştır. 2024 yılı itibarıyla elektrik üretimimizin %54,1’i fosil yakıt kaynaklarından sağlanmakta; bunun %35,2’si kömür, %18,9’u ise doğal gaz üzerinden karşılanmaktadır. Söz konusu fosil yakıtların büyük bölümü yurt dışından ithal edilmekte, bu da hem dış ticaret açığını derinleştirmekte hem de çevresel zararları artırmaktadır.

Bu çerçevede, Türkiye Cumhuriyeti Enerji ve Tabii Kaynaklar Bakanlığı’nın 2025 verilerine göre, elektrik üretim portföyümüzde alternatif enerji kaynaklarının payı %24,4’e (rüzgâr %10,5, güneş %7,5, jeotermal %3,2 ve diğer %3,2) ulaşmıştır (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2025).

Artan enerji talebi, iklim değişikliği yakıcı endişeleri ve fosil yakıt rezervlerinin sınırlılığı, dünya genelinde olduğu gibi Türkiye’de de yenilenebilir enerji yatırımlarının stratejik önceliğini pekiştirmiştir. Özellikle coğrafi konumu ve yüksek güneşlenme potansiyeli göz önünde bulundurulduğunda, güneş

enerjisi santrallerinin ulusal elektrik üretimindeki rolünü yükseltmek büyük önem taşımaktadır (Sağiroğlu, 2016). Ancak, bu potansiyelin etkin şekilde değerlendirilmesi, iller bazında farklı coğrafi, demografik ve ekonomik göstergeler dikkate alınarak “hangi bölgede, hangi ölçekte” yatırım yapılması gerektiğinin açıkça belirlenmesini gerektirmektedir.

2. LİTERATÜR ARAŞTIRMASI

Genel olarak literatür incelendiğinde güneş enerjisi yatırımları üzerine yapılan çalışmalar; ekonomik fizibilite, yer seçimi analizleri, potansiyel değerlendirmeleri ve makine öğrenmesi temelli modellemeler olmak üzere çeşitli başlıklarda yoğunlaşmaktadır.

2.1. Ekonomik Değerlendirme ve Yatırım Analizleri

Güneş enerjisi sistemlerinin ekonomik açıdan uygulanabilirliğine dair birçok çalışma, farklı ölçeklerdeki kullanıcı profillerini dikkate alarak yatırım kararlarını analiz etmektedir. Örneğin, Avşar (2024), Türkiye genelinde 3000’den fazla mağazaya sahip büyük bir perakende firmasının güneş enerjisi yatırımlarını CBA yöntemiyle değerlendirirken; Elmas (2024) konut tipi sistemlerde çeşitli finansal modellerle yapılan analizleri saha çalışmasıyla desteklemiştir. Jiryawée (2023) ve Almassak (2023) ise Homer ve PVsyst gibi yazılımlarla ev tipi sistemlerin teknik/ekonomik optimizasyonuna odaklanmıştır.

2.2. Yer Seçimi ve Uygunluk Analizleri

Güneş enerjisi santrallerinin verimli bir şekilde kurulabilmesi için yer seçimi oldukça kritik bir konudur. Bu bağlamda, Coğrafi Bilgi Sistemleri (CBS) ile desteklenen Çok Kriterli Karar Verme (ÇKKV) yöntemleri yaygın olarak kullanılmıştır. Kocabaldır (2021) ve Sarsıcı (2020), sırasıyla Çanakkale ve Karabük illeri özelinde AHP (Analitik Hiyerarşi

Prosesi) yöntemi ile uygun alanları belirlemiştir. Yılmaz (2024), Antalya-Burdur-Isparta bölgesinde Bulanık AHP ile hem potansiyel bölgeleri hem de mevcut GES'lerin çevresel uygunluğunu değerlendirmiştir. Yüce (2023) ise yer seçimi kararlarını makine öğrenmesi algoritmalarıyla bütünleştirerek yenilikçi bir yaklaşım sunmuştur.

2.3. Güneş Enerjisi Potansiyeli ve Bölgesel Analizler

Ülke genelinde veya bölgesel düzeyde güneş enerjisi potansiyelinin belirlenmesine yönelik çalışmalar da literatürde önemli bir yer tutmaktadır. Aykar (2016) Ege Bölgesi için RETScreen ile il bazlı 1 MW santral tasarımı yaparken, Ceylan (2016) ve Çiftçi (2015) Türkiye genelindeki potansiyeli örnek projelerle açıklamıştır. Arslan (2015) ise güneş kolektörlerinin performansına odaklanmıştır.

2.4. Politika, Sürdürülebilirlik ve Stratejik Değerlendirmeler

Güneş enerjisine dayalı stratejik planlamalar ve sürdürülebilirlik analizleri kapsamında yapılan çalışmalarda, SWOT(Güçlü Yönler – Strengths, Zayıf Yönler – Weaknesses, Fırsatlar – Opportunities, Tehditler – Threats) ve AHP temelli yöntemlerle sektöre dair yol haritaları oluşturulmuştur. Kısa (2020) ve Kömürcü (2019), Türkiye'deki güneş enerjisi potansiyelini SWOT ile değerlendirirken, Doğan (2019) bu analizleri bulanık AHP ile harmanlayarak strateji önceliklendirmesi yapmıştır. Sağıroğlu (2016) ise illerin enerji tüketim profiline dayalı olarak planlama kararları için önerilerde bulunmuştur.

2.5. Güneş Enerjisi ve Makine Öğrenmesi Uygulamaları

Son yıllarda yapay zekâ ve veri bilimi tekniklerinin enerji alanına entegrasyonu hız kazanmıştır. Sezikli (2023),

meteorolojik veriler ve güneş enerjisi üretimi arasındaki ilişkiyi farklı regresyon ve sınıflandırma algoritmaları ile analiz ederken, Yüce (2023) bu yaklaşımı yer seçimi kararlarına da taşımıştır. Bu tür çalışmalar, veri temelli politika üretiminde makine öğrenmesinin katkısını gözler önüne sermektedir.

3. METOT

Literatürde, güneş enerjisi yatırımlarının ekonomik analizleri (Avşar, 2024; Elmas, 2024; Canpolat, 2025), teknik ve ekonomik optimizasyon çalışmaları (Almassak, 2023; Jiryawee, 2023), CBS ve çok kriterli karar verme yöntemleri (Kocabaldır, 2021; Sarsıcı, 2020), stratejik değerlendirmeler ve SWOT temelli yaklaşımlar (Kısa, 2020; Kömürcü, 2019; Doğan, 2019) ile makine öğrenmesi tabanlı üretim tahmin süreçleri (Sezikli, 2023) geniş bir yelpazede ele alınmıştır. Bununla birlikte, Türkiye'nin tüm illerini kapsayan, çok boyutlu veri madenciliği teknikleriyle sistematik bir önceliklendirme çalışması henüz yeterince derinlemesine yürütülmemiştir.

Bu eksikliği gidermek üzere, çalışmamız Türkiye'nin 81 ilini sekiz temel göstergesi" güneşlenme süresi, mevcut GES kurulu gücü, elektrik tüketimi, nüfus yoğunluğu, tarım dışı arazi varlığı, hane halkı sayısı, sosyo-ekonomik gelişmişlik endeksi ve yatırım teşvik düzeyi" temelinde değerlendirmektedir. Weka platformunda K-Means algoritması kullanılarak; hem tekil hem de bileşik kriter setleriyle illerin kümeleme analizi yapılmış, veri temelli çok katmanlı bir yatırım önceliklendirme modeli ortaya konmuştur. Sonuç olarak, bu çalışma yalnızca yatırım karar süreçlerine niceliksel bir altyapı sağlamakla kalmayıp, aynı zamanda yerel ve ulusal düzeyde sürdürülebilir enerji planlamasına rehberlik edecek pratik bir harita sunmayı amaçlamaktadır.

3.1. Çalışma Grubu

Bu araştırmanın çalışma grubu, Türkiye'nin 81 ilidir. Her bir il, seçilen sekiz temel göstergeye (ortalama yıllık güneşlenme süresi, mevcut GES kurulu gücü, elektrik tüketimi, nüfus yoğunluğu, tarım dışı arazi varlığı, hane halkı sayısı, sosyo ekonomik gelişmişlik endeksi ve yatırım teşvik düzeyi) göre tanımlanmış ve veri setine dâhil edilmiştir. İl düzeyindeki tüm veriler güncel resmi kaynaklardan ve ilgili bakanlık/kurum veri tabanlarından temin edilmiştir. Çalışma grubuna dâhil edilen tüm iller, analiz açısından homojenlik ve karşılaştırılabilirlik ilkelerine uygun olarak seçilmiş olup, veri eksikliği bulunan hiçbir il çalışmaya dâhil edilmemiştir.

3.2. Veri Toplama Aracı ve İşleme Süreci

Veri toplama aşamasında, sekiz göstergeye ilişkin sayısal veriler ilgili kamu kurumlarının çevrimiçi raporları, TÜİK veri portalı ve Enerji ve Tabii Kaynaklar Bakanlığı istatistiklerinden derlenmiştir. Toplanan ham veriler, öncelikle Excel ortamında birleştirilmiş; eksik değer analizi yapılarak uygun hale getirilmiştir. Ardından, değerlerin ölçekler arası uyumunu sağlamak üzere min-max normalizasyon işlemleri yapılmıştır.

4. UYGULAMA

Bu çalışmada, Türkiye'deki 81 ilin güneş enerjisi yatırımı açısından değerlendirilmesi amacıyla veri madenciliği teknikleri kullanılarak bir kümeleme analizi gerçekleştirilmiştir. Analizde, illerin güneş enerjisi potansiyelini ve yatırım yapılabilirliğini etkileyen 8 adet nitelik belirlenmiş ve bu nitelikler üzerinden K-Means algoritması ile kümeler oluşturulmuştur.

Bu çalışmada kullanılan nitelikler, Türkiye'deki illerin güneş enerjisi yatırımı açısından taşıdığı potansiyeli çok boyutlu bir bakış açısıyla değerlendirmek üzere seçilmiştir. Yıllık

ortalama güneşlenme süresi, bir ilin güneş enerjisinden yararlanma kapasitesini doğrudan etkileyen temel çevresel göstergedir. GES kurulu gücü, mevcut güneş enerjisi altyapısının gelişmişlik düzeyini ortaya koyarken; elektrik tüketimi, enerji talebinin büyüklüğünü ve yerel ihtiyaçları temsil etmektedir. Kentsel nüfus ve hane halkı sayısı, nüfus yoğunluğu ve enerji tüketim alışkanlıkları açısından önemli sosyal-demografik göstergelerdir. Tarım dışı arazi miktarı, güneş enerjisi santrallerinin kurulabileceği potansiyel alanları işaret ederken; SEGE skoru (Sosyo-Ekonomik Gelişmişlik Endeksi), illerin ekonomik gelişmişlik düzeyini yansıtarak yatırımın geri dönüş potansiyeline ışık tutmaktadır.

Son olarak, yatırım teşvik düzeyi, devlet desteklerinin yoğunluğunu göstererek, yatırım yapılabilirliğe doğrudan etki eden önemli bir politika değişkenidir. Normalize olan veri seti Tablo 1’de yer alırken normalize olmayan veri seti Tablo 2’de yer almaktadır.

Tablo 1. Analizde kullanılan normalize edilmemiş verisetinin bir kısmı

İl	Güneşlenme Süresi (saat/yıl)	GES Kurulu Gücü (MW)	Elektrik Tüketimi (kWh)	Kentsel Nüfus (%)	Tarım Dışı Arazi (%)	Hane Halkı Sayısı	SEGE Skoru	Yatırım Teşvik Düzeyi
Adana-1	7,6	293	7887139	87,30595671	0,637391858	632875	3	4
Adıyaman-2	7,7	157	1134773	70,04203037	0,687073736	155300	6	1
Afyonkarahisar-3	6,8	305	2092766	61,84120232	0,608991296	218348	4	3
Ağrı-4	6,2	173	524471	59,83635773	0,690076944	109974	6	1
Aksaray-68	7,4	300	1368319	63,04072231	0,450488314	123019	4	3
Amasya-5	5,8	53	709302	69,86285981	0,556197406	109469	4	3
Antakya-6	6,7	2608	17246705	95,88351138	0,562738837	1874093	1	6
Antalya-7	8,1	1362	10072347	86,90243765	0,837912217	858107	1	6
Ardahan-75	5,5	154	138595	31,60973605	0,823266315	28669	6	1
Artvin-8	4,9	0,02	387566	58,1365147	0,959144867	58847	4	3
Aydın-9	6,6	169	3690776	80,15817237	0,550912935	391460	2	5
Balekçevre-10	6,6	191	4437397	73,85053952	0,715415086	456193	2	5
Bartın-74	5,9	15	635449	45,75979464	0,866977253	67709	4	3
Batman-72	7,5	67	1098476	81,69745513	0,786085772	124388	6	1
Bayburt-69	0	176	107383	57,88392825	0,694410304	24347	5	2
Bilecik-11	6,3	203	2251145	82,24582701	0,789784637	72972	2	5
Bingöl-12	6,2	165	331025	64,40351647	0,828647382	79458	6	1
Bitlis-13	0	211	433990	63,84820954	0,833384857	79417	6	1
Bolu-14	5,3	38	1463024	65,61759719	0,865426681	104358	2	5
Burdur-15	7,5	285	958082	62,64047714	0,775510199	96220	3	4
Bursa-16	6,2	186	13735283	92,64207818	0,72161042	966765	1	6

Tablo 2. Analizde kullanılan normalize edilmiş verisetinin bir kısmı

İ	Güneşlenme Süresi [saat/gün]	GES Kurulu Gücü [MW]	Elektrik Tüketimi [kWh]	Karstık Nüfus [ki]	Tarım Dep. Alanı [ha]	Hane Hedef Sayısı	SEGE Skoru	Yatırım Teyak Düzeyi
Adana-1	0,938221605	0,112139819	0,180661943	0,825403711	0,519396488	0,128612757	0,0	0,4
Adıyaman-2	0,950617284	0,0600192179	0,02385811	0,5895608	0,593606468	0,027681299	0	1
Afyonkarahisar-3	0,839506173	0,116941081	0,046104679	0,44802258	0,476974473	0,041008604	0,4	0,6
Ağrı-4	0,765432099	0,066127196	0,00985642	0,418111297	0,598092369	0,018100132	0	1
Alkay-68	0,913580247	0,115013888	0,025281528	0,465799158	0,240218055	0,020857679	0,4	0,6
Amasya-5	0,716049383	0,020314573	0,013977798	0,566901487	0,398116068	0,017993383	0,4	0,6
Ankara-6	0,827160494	1	0,398010325	0,952520899	0,407884037	0,391005718	1	0
Antalya-7	1	0,5222356	0,231406969	0,819423662	0,818914397	0,176243077	1	0
Artahlan-75	0,679022346	0,059041864	0,000724807	0	0,797037766	0,000913599	0	1
Artvin-8	0,604938272	0	0,000506426	0,393120059	1	0,00729273	0,4	0,6
Aydın-9	0,814814815	0,064793442	0,083213759	0,71947538	0,390252511	0,077601618	0,8	0,2
Balıkesir-10	0,814814815	0,073229089	0,100551835	0,625997878	0,665820074	0,091285104	0,8	0,2
Bartın-14	0,728350662	0,005743909	0,012262778	0,299700241	0,862328938	0,09916601	0,4	0,6
Batman-72	0,925925956	0,025482712	0,023015219	0,742287156	0,741501067	0,021147013	0	1
Bayburt-69	0	0,067477511	0	0,389376793	0,604565124	0	0,2	0,8
Bilecik-11	0,777777778	0,077830351	0,049782565	0,750413886	0,747026075	0,010278521	0,8	0,2
Bitöl-12	0,765432099	0,061259688	0,005193427	0,489995418	0,805075483	0,011015404	0	1
Bitlis-13	0	0,08089796	0,007584487	0,477765912	0,817151864	0,011640887	0	1
Bolu-14	0,654320988	0,014562995	0,031480774	0,503987783	0,860012842	0,016913002	0,8	0,2
Burdur-15	0,925925926	0,10927231	0,019754981	0,459867628	0,7257043	0,015192764	0,6	0,4
Bursa-16	0,765432099	0,071111897	0,31646788	0,90483664	0,645194024	0,199211582	1	0

Veri madenciliği sürecinde, Weka 3.9 yazılımı kullanılarak K-Means kümeleme algoritması uygulanmıştır. Uygulama öncesinde, veri seti arff formatına dönüştürülmüş ve yazılım ara yüzüne aktarılmıştır. K-Means algoritması, hem normalize edilmiş verilerle hem de normalize edilmemiş ham verilerle çalıştırılmıştır. Normalize işlemi, Weka'daki "Normalize" filtresi aracılığıyla Min-Max yöntemi kullanılarak gerçekleştirilebileceği gibi Excel dosyasında gerekli formülasyonlarla da gerçekleştirilebilir. Normalizasyon işlemi Excel dosyasında gerçekleştirilip arff formatına dönüştürülüp yazılım ara yüzüne aktarılmıştır. Küme sayısının belirlenmesinde deneme-yanılma yöntemiyle farklı değerler test edilmiş, en anlamlı dağılımın 5 küme ile elde edildiği gözlemlenmiştir. Algoritma çalıştırılırken varsayılan olarak 100 iterasyon ve Euclidean (Öklidyen) mesafe ölçütü kullanılmıştır. Weka programında elde edilen çıktıların bir kısmı normalize olan ve olmayan olmak üzere Tablo 3 ve Tablo 4' te gösterilmektedir.

Tablo 1. Analizde kullanılan normalize edilmemiş verisetinin bir kısmının çıktısı

ÇinHidroelektrikSanayiGüçÜretimKapasitesi(MW),ÇinHidroelektrikTürbini(KWh),KentsalNüfus(1000),YatırımDüzeni(100),YatırımHesapSırası,SEGEKısmı,YatırımYatırımcıDüzeni	KÜME	İL
7.4,293,2882139,87,302987,0.637302,6.62875,3,cluster1	1	Adana-1
7.7,157,1134773,20,042304,0.682074,55300,5,1,cluster2	2	Adıyaman-2
6.8,305,2022766,61,891202,0.628991,218346,4,cluster2	2	Afyonkarahisar-3
6.2,173,524471,59,836358,0.690077,109974,6,1,cluster3	3	Ağrı-4
7.4,300,1368319,63,040722,0.450488,123019,4,3,cluster2	2	Akarsay-68
5.8,53,109302,68,96286,0.596157,150469,4,1,cluster2	2	Amasya-5
6.7,2004,17240705,95,885533,0.563737,1874903,1,2,cluster5	5	Ankara-6
8.1,362,10072347,86,902438,0.837912,858107,1,1,cluster5	5	Antalya-7
5.5,154,138595,31,609736,0.823266,28669,6,1,cluster3	3	Ardeşan-75
4.9,0.02,387566,56,130515,0.559145,56847,4,3,cluster3	3	Artvin-8
6.6,169,1690776,80,138172,0.555913,191490,4,3,cluster4	4	Aydin-9
6.4,151,4437397,71,80564,0.716416,854913,2,3,cluster4	4	Balıkesir-10
5.9,15,134449,45,752995,0.866077,67705,4,3,cluster3	3	Bartın-24
7.5,67,1098475,81,697455,0.788086,124388,6,1,cluster3	3	Batman-72
0.176,107381,57,887928,0.69441,24347,5,2,cluster7	3	Bayburt-69
6.3,203,225145,82,284827,0.789785,72727,2,5,cluster4	4	Bilecik-11
6.7,165,131025,66,420156,0.829647,26458,6,1,cluster3	1	Bingöl-12
0.211,433995,63,848212,0.823385,79417,1,3,cluster3	3	Birleşik-13
5.3,38,1463024,65,617597,0.865427,104358,2,5,cluster6	5	Bolu-14
7.5,785,950802,62,640477,0.77551,90270,3,4,cluster1	1	Burdur-15
6.2,186,13735283,92,642076,0.72161,966765,1,6,cluster4	6	Bursa-16
7.2,29,3912527,70,943535,0.697345,204793,2,5,cluster4	4	Canakkale-17
6.4,228,618456,54,534063,0.705088,68624,5,2,cluster3	3	Çankırı-18
6.1,286,962382,69,535283,0.567996,173928,7,4,cluster2	2	Çorum-19
7.3,781,3991306,74,451927,0.695607,351281,2,3,cluster4	4	Denizli-20
7.8,406,3271763,73,742243,0.623342,394867,6,1,cluster2	2	Diğerbaki-21
5.1,27,1380018,80,126394,0.697961,197000,3,4,cluster2	4	Düzce-81

Tablo 2. Analizde kullanılan normalize edilmiş verisetinin bir kısmının çıktısı

NormalizasyonSonuçları,SEGEKısmı,ÇinHidroelektrikTürbini(1000),KentsalNüfus(1000),YatırımDüzeni(100),YatırımHesapSırası,SEGEKısmı,YatırımYatırımcıDüzeni	KÜME	İL
0.582777,0.11234,0.18063,0.825404,0.519196,0.188333,0.6,0,cluster1	3	Adana-1
0.950617,0.060592,0.023805,0.569661,0.563606,0.027485,0.3,cluster2	2	Adıyaman-2
0.889506,0.116991,0.046103,0.418023,0.476974,0.041009,0.4,0,cluster2	2	Afyonkarahisar-3
0.765432,0.086327,0.020988,0.438111,0.588991,0.01811,1,1,cluster3	3	Ağrı-4
0.911358,0.115024,0.029282,0.485790,0.240218,0.020858,0.4,0,cluster2	2	Akarsay-68
0.716649,0.020315,0.017828,0.546003,0.398116,0.017993,0.4,0,cluster2	2	Amasya-5
0.82716,1.0,1.0902,0.95251,0.40788,0.395006,1,0,cluster5	5	Ankara-6
1.0,0.52316,0.71,4477,0.819424,0.818914,0.716243,1,0,cluster5	5	Antalya-7
0.679612,0.00942,0.000723,0.0,797938,0.000914,0,0,cluster3	3	Ardeşan-75
0.604938,0.0,00006,0.99312,1.0,0.007291,0.4,0,cluster3	3	Artvin-8
0.814915,0.064793,0.08314,0.719475,0.390253,0.07702,0.0,0,cluster4	4	Aydin-9
0.814915,0.073229,0.100512,0.629798,0.466482,0.011285,0.0,0,cluster4	4	Balıkesir-10
0.728395,0.005744,0.01224,1.0,2.997,0.867179,0.009106,0.4,0,cluster3	3	Bartın-24
0.925928,0.025883,0.023035,0.742287,0.741501,0.021147,0.3,cluster3	3	Batman-72
0.0047476,0.0,0.001773,0.464965,0.0,0,0,cluster3	3	Bayburt-69
0.777718,0.07783,0.049781,0.750414,0.747026,0.032799,0.0,0,cluster4	4	Bilecik-11
0.765432,0.06326,0.005113,0.485995,0.806793,0.011015,0.1,cluster3	3	Bingöl-12
0.0048098,0.007584,0.477766,0.812552,0.015641,0.1,cluster3	3	Bolu-14
0.854123,0.019464,0.031481,0.539886,0.360311,0.019191,0.0,0,cluster4	4	Burdur-15
0.925928,0.109272,0.019755,0.598884,0.725708,0.021593,0.0,0,cluster3	3	Bursa-16
0.765432,0.073122,0.316468,0.904884,0.645194,0.199212,1,0,cluster4	4	Canakkale-17
0.888889,0.011123,0.08031,0.562887,0.688949,0.03813,0.0,0,cluster4	4	Çankırı-18
0.767123,0.087440,0.01668,0.379436,0.620511,0.009796,0.2,0,cluster3	2	Çorum-19
0.753086,0.109066,0.03888,0.562343,0.451543,0.012749,0.4,0,cluster2	4	Denizli-20
0.901235,0.107739,0.090395,0.634318,0.606487,0.069531,0.0,0,cluster4	4	Diğerbaki-21
0.967963,0.170178,0.073483,0.624393,0.49841,0.078122,0.1,cluster2	2	Düzce-81

Ham veriler (normalize olmayan) ile olan veri seti ve min-max normalizasyonu ile elde edilmiş veri seti ayrı ayrı k-means algoritması ile kümelendirilmiş ve kümeleme sonucunda, benzer özellikler taşıyan iller beş farklı grupta toplanmıştır. Her iki durumda da oluşan kümelerde bir farklılık gözlemlenmemiştir. Aşağıda, her bir kümede yer alan iller sıralanmakta ve kümelerin içeriği detaylandırılmaktadır. Bu dağılım, yatırım stratejilerinin bölgesel düzeyde farklılaştırılmasına olanak sağlamaktadır.

Küme 1; Adana, Burdur, Elazığ, Gaziantep, Hatay, Karaman, Kilis, Malatya, Mersin, Sinop, Uşak

Küme 2; Adıyaman, Afyonkarahisar, Aksaray, Amasya, Çorum, Diyarbakır, Kırklareli, Mardin, Muş, Nevşehir, Niğde, Ordu, Osmaniye, Şanlıurfa, Şırnak, Tokat, Yozgat

Küme 3; Ağrı, Ardahan, Artvin, Bartın, Batman, Bayburt, Bingöl, Bitlis, Çankırı, Erzincan, Erzurum, Giresun, Gümüşhane, Hakkari, Iğdır

Küme 4; Aydın, Balıkesir, Bilecik, Bolu, Bursa, Çanakkale, Denizli, Düzce, Edirne, Eskişehir, Isparta, Karabük, Kayseri, Kırıkkale, Kocaeli, Kütahya, Manisa, Muğla, Rize, Sakarya, Samsun, Tekirdağ, Trabzon, Yalova, Zonguldak

Küme 5; Ankara, Antalya, İstanbul, İzmir, Konya

Bu bulgudan yola çıkarak, değişkenlerin orijinal ölçekteki dağılımının küme yapısını önemli ölçüde etkilemediği, dolayısıyla veriler arasında belirgin doğal ayrımlar olduğu sonucuna ulaşılmıştır. İkinci aşamada, Entropi yöntemi kullanılarak her değişkenin bilgi katkısı oranında ağırlığı hesaplanmış ve bu ağırlıklar veri setine uygulanarak ağırlıklı bir kümeleme süreci yürütülmüştür. Entropi yöntemiyle elde edilen kriter ağırlıkları sırasıyla; 0.020203602, 0.259605764, 0.310623465, 0.007340602, 0.00978054, 0.291553037, 0.045009743, 0.055883248'dir. Ağırlık katsayıları ile düzenlenmiş veri seti ile kümeleme çıktısı Tablo 5' te yer almaktadır. Bu analiz sonucunda da, entropi ile ağırlıklandırılmış veri setinden elde edilen kümelerin, önceki kümeleme sonuçlarıyla tamamen aynı olduğu tespit edilmiştir.

Tablo 3. Entropi yöntemi ile elde edilen ağırlıklı veri setinin bir kısmı

Güvenlenme Süresi (saat/yıl), 'GES Kurulu Gücü (MW)', 'Elektrik Tüketimi (kWh)', 'Kentsel Nüfus (Y)', 'Tarım Dışı Arazi (Y)', 'Hane Halkı Sayısı', 'SEGE Skoru', 'Yatırım Tesvik Düzeyi', cluster	KÜME	İL
0.018956,0.029164,0.056118,0.006059,0.00508,0.037503,0.027008,0.022353,cluster1	1	Adana-1
0.019206,0.015626,0.007411,0.004181,0.005806,0.008071,0.0.055883,cluster2	2	Adıyaman-2
0.016961,0.030359,0.014321,0.003289,0.004665,0.011956,0.018004,0.03353,cluster2	2	Afyonkarahisar-3
0.015464,0.017219,0.003009,0.003071,0.00585,0.005277,0.0.055883,cluster3	3	Ağrı-4
0.018458,0.029861,0.009096,0.003419,0.002349,0.006081,0.018004,0.03353,cluster2	2	Aksaray-68
0.014467,0.005274,0.004342,0.004161,0.003894,0.005246,0.018004,0.03353,cluster2	2	Amasya-5
0.016712,0.259606,0.123631,0.006992,0.003989,0.113999,0.04501,cluster5	5	Ankara-6
0.020204,0.135575,0.07188,0.006015,0.008009,0.051384,0.04501,cluster5	5	Antalya-7
0.013718,0.015328,0.000225,0.0.007795,0.000266,0.0.055883,cluster3	3	Ardahan-75
0.01222,0.0.002021,0.002886,0.009781,0.002126,0.018004,0.03353,cluster3	3	Artvin-8
0.016462,0.016821,0.025848,0.005281,0.003817,0.022625,0.036008,0.011177,cluster4	4	Aydın-9
0.016462,0.019011,0.031234,0.004595,0.006512,0.026614,0.036008,0.011177,cluster4	4	Balıkesir-10
0.014716,0.001491,0.003809,0.001539,0.008434,0.002672,0.018004,0.03353,cluster3	3	Bartın-74
0.018707,0.006667,0.007149,0.005449,0.007252,0.006165,0.0.055883,cluster3	3	Batman-72
0.017518,0.0.002858,0.005913,0.0.009002,0.047707,cluster3	3	Bayburt-69
0.015714,0.020205,0.015464,0.005508,0.007306,0.002997,0.036008,0.011177,cluster4	4	Bilecik-11
0.015464,0.016423,0.001613,0.003567,0.007874,0.003212,0.0.055883,cluster3	3	Bingöl-12
0.021002,0.002356,0.003507,0.007943,0.003394,0.0.055883,cluster3	3	Bitlis-13
0.01322,0.007781,0.009779,0.0037,0.008411,0.004931,0.036008,0.011177,cluster4	4	Bolu-14
0.018707,0.028368,0.006136,0.003376,0.007098,0.004429,0.027006,0.022353,cluster1	1	Burdur-15
0.015464,0.018513,0.098302,0.006639,0.00631,0.058081,0.04501,cluster4	4	Bursa-16
0.017959,0.002885,0.027448,0.004279,0.005956,0.011121,0.036008,0.011177,cluster4	4	Çanakkale-17
0.015963,0.022694,0.003687,0.002492,0.006069,0.002729,0.009002,0.047707,cluster3	3	Çankırı-18
0.015215,0.028667,0.005864,0.004128,0.00406,0.009554,0.018004,0.03353,cluster2	2	Çorum-19
0.018208,0.02797,0.028017,0.004656,0.005912,0.020722,0.036008,0.011177,cluster4	4	Denizli-20
0.019455,0.049371,0.022826,0.004583,0.004875,0.022835,0.0.055883,cluster2	2	Diyarbakır-21
0.012721,0.002686,0.009223,0.0053,0.005965,0.005877,0.027006,0.022353,cluster4	4	Düzce-81
0.014966,0.025879,0.008761,0.004285,0.002956,0.007383,0.036008,0.011177,cluster4	4	Edirne-22

Entropi yöntemiyle elde edilmiş analiz sonucunda 5 adet kümede yer alan iller aşağıda kümelerine göre sıralanmıştır.

Küme 1; Adana, Burdur, Elazığ, Gaziantep, Hatay, Karaman, Kilis, Malatya, Mersin, Sinop, Uşak

Küme 2; Adıyaman, Afyonkarahisar, Aksaray, Amasya, Çorum, Diyarbakır, Kırklareli, Mardin, Muş, Nevşehir, Niğde, Ordu, Osmaniye, Şanlıurfa, Şırnak, Tokat, Yozgat

Küme 3; Ağrı, Ardahan, Artvin, Bartın, Batman, Bayburt, Bingöl, Bitlis, Çankırı, Erzincan, Erzurum, Giresun, Gümüşhane, Hakkari, Iğdır

Küme 4; Aydın, Balıkesir, Bilecik, Bolu, Bursa, Çanakkale, Denizli, Düzce, Edirne, Eskişehir, Isparta, Karabük, Kayseri, Kırıkkale, Kocaeli, Kütahya, Manisa, Muğla, Rize, Sakarya, Samsun, Tekirdağ, Trabzon, Yalova, Zonguldak

Küme 5; Ankara, Antalya, İstanbul, İzmir, Konya

Analiz sonucunda gruplandırılan 5 kümede yer alan iller, çalışmada belirlenen 8 kritere göre aşağıdaki gibi değerlendirilmiştir:

Küme 1 – Güneş Potansiyeli Yüksek, Gelişmekte Olan Bölgeler

Bu kümeye dahil iller, yüksek güneşlenme süresine sahip olmakla birlikte, sosyo-ekonomik gelişmişlik düzeyleri orta seviyededir. Elektrik tüketimi ve mevcut GES kapasitesi sınırlı olsa da, tarım dışı arazi oranı yüksek ve yatırım teşvik düzeyleri de görece yüksektir. Bu nedenle devlet destekli yatırımlar açısından fırsat barındıran bölgeler olarak değerlendirilebilir.

Küme 2 – Orta Düzey Potansiyele Sahip Kalkınma Bölgeleri

Bu grup, orta düzey güneşlenme süresi ve düşük-orta düzey elektrik tüketimi ile öne çıkmaktadır. Mevcut GES kurulu gücü düşüktür. Ancak teşvik düzeyleri yüksektir ve kalkınma öncelikli iller arasında yer almaktadır. Uzun vadede küçük-orta ölçekli GES yatırımları için uygun bölgeler olarak değerlendirilebilir.

Küme 3 – Yatırım Önceliği Düşük, Sosyal Amaçlı Gelişme Bölgeleri

Bu küme, düşük güneşlenme süresi, düşük sosyo-ekonomik gelişmişlik, düşük nüfus yoğunluğu ve az yatırım çekmiş bölgelerden oluşmaktadır. Bu iller için doğrudan ticari yatırım cazibesi düşüktür; ancak bölgesel kalkınma ve sosyal enerji projeleri kapsamında değerlendirilmesi mümkündür. Bu alanlarda kamu destekli kırsal enerji çözümleri önerilebilir.

Küme 4 – Dengeli ve Gelişmiş Sanayi Bölgeleri

Bu küme, orta-yüksek düzeyde güneş potansiyeline, gelişmiş sanayi altyapısına ve yüksek nüfus yoğunluğuna sahip illerden oluşmaktadır. GES yatırımları açısından denge bölgesi olarak değerlendirilen bu grup, enerji talebi yüksek ancak yatırım yoğunluğu bakımından ilk sırada olmayan illeri barındırmaktadır.

Orta vadeli planlamalar kapsamında bu bölgelerde yeni GES yatırımları desteklenebilir.

Küme 5 – Yüksek Öncelikli Yatırım Bölgeleri

Bu grup, Türkiye'nin en gelişmiş ve yüksek enerji tüketimine sahip metropollerinden oluşmaktadır. Elektrik talebinin yüksekliği, nüfus yoğunluğunun fazlalığı ve sosyo-ekonomik gelişmişlik düzeyi bu kümeyi ön plana çıkarmaktadır. Ayrıca Konya ve Antalya gibi iller güneşlenme süresi açısından da Türkiye ortalamasının üzerindedir. Bu nedenle bu kümeye dahil iller, yüksek ölçekli ve stratejik GES yatırımları açısından birincil önceliğe sahiptir.

Yapılan tüm kümeleme analizleri sonucunda 81 ile ait renklendirilmiş harita Şekil 1'de yer almaktadır.



Şekil 1. Güneş enerjisi potansiyeline göre kümeleme çıktılarını gösteren renklendirilmiş harita

5. SONUÇ

Bu çalışma, Türkiye'nin 81 ili özelinde güneş enerjisi potansiyeli ve yatırım kararlarını etkileyebilecek sekiz temel göstergeye dayanarak (ortalama yıllık güneşlenme süresi, mevcut

GES kurulu gücü, elektrik tüketimi, nüfus yoğunluğu, tarım dışı arazi varlığı, hane halkı sayısı, sosyo ekonomik gelişmişlik endeksi ve yatırım teşvik düzeyi) veri madenciliği teknikleriyle analiz ederek illerin benzer özelliklere göre gruplandırılmasını sağlamıştır. İlk aşamada, ham veriler kullanılarak K-Means algoritması uygulanmış ve elde edilen kümeler kaydedilmiştir. Ardından, aynı veri seti Min-Max normalizasyon yöntemiyle ölçeklendirilmiş ve tekrar aynı algoritma ile kümeleme yapılmıştır. Elde edilen sonuçlar karşılaştırıldığında, normalize edilmiş ve edilmemiş veri setleriyle yapılan kümelemelerin birebir aynı kümeleri oluşturduğu gözlemlenmiştir. Bu bulgudan yola çıkarak, değişkenlerin orijinal ölçekteki dağılımının küme yapısını önemli ölçüde etkilemediği, dolayısıyla veriler arasında belirgin doğal ayrımlar olduğu sonucuna ulaşılmıştır.

İkinci aşamada, Entropi yöntemi kullanılarak her değişkenin bilgi katkısı oranında ağırlığı hesaplanmış ve bu ağırlıklar veri setine uygulanarak ağırlıklı bir kümeleme süreci yürütülmüştür. Bu analiz sonucunda da, entropi ile ağırlıklandırılmış veri setinden elde edilen kümelerin, önceki kümeleme sonuçlarıyla tamamen aynı olduğu tespit edilmiştir. Hem normalizasyon hem de ağırlıklandırma gibi ön işleme adımlarının kümeleme üzerindeki etkisinin karşılaştırılmasıyla, verinin doğasındaki baskın değişkenlerin belirleyici rolü açık bir şekilde ortaya konmuştur. Literatürde genellikle tek boyutlu verilerle yapılan benzer analizlerin aksine, bu çalışma çok değişkenli ve bölgesel düzeyde yapılmasıyla özgünlük taşımaktadır.

Çalışma sonucunda elde edile bulgular, karar vericilerin enerji yatırımlarını bölgesel düzeyde farklılaştırarak daha etkili planlamalar yapabilmesine olanak sağlamaktadır. Özellikle kamu yatırımları, teşvik politikaları ve uzun vadeli enerji planlamaları açısından kümelerin sunduğu profil önemli bir yol gösterici niteliğe sahiptir. Elde edilen sonuçlar, güneş enerjisi

yatırımlarının yalnızca çevresel potansiyele değil, aynı zamanda sosyo-ekonomik, demografik ve mekânsal değişkenlere bağlı olarak şekillendiğini göstermekte; bu nedenle enerji politikalarının çok boyutlu veri analizlerine dayanması gerektiğini vurgulamaktadır.

Sonuç olarak, bu çalışma Türkiye’de illerin güneş enerjisi potansiyellerine göre bütüncül bir şekilde gruplandırılmasını sağlamış; farklı veri işleme yöntemleri kullanılarak güçlü bir kümeleme yapısı ortaya çıkarmıştır. Bu yaklaşım gelecekte yapılacak akademik araştırmalar, bölgesel planlamalar, yatırım stratejileri ve sürdürülebilir enerji politikaları için temel bir referans niteliği taşımaktadır. Ayrıca, politika yapıcıların kaynak tahsisini daha etkin bir şekilde yönlendirebilmesine, yerel yönetimlerin yatırım planlarını enerji potansiyellerine göre şekillendirebilmesine ve özel sektör yatırımcılarının karar destek süreçlerini güçlendirmesine katkı sağlaması beklenmektedir.

KAYNAKLAR

- Akbulut, S. (2006). Veri madenciliği teknikleri ile bir kozmetik markanın ayrılan müşteri analizi ve müşteri segmentasyonu (Yüksek lisans tezi). Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Akpınar, H. (2000). Veri tabanlarında bilgi keşfi ve veri madenciliği. İstanbul Üniversitesi İşletme Fakültesi Dergisi, 1–22.
- Almassak, S. H. (2023). Energy management and economic analysis of solar energy: A case study.
- Arslan, E. (2015). Güneş enerjisi potansiyelinin bölgesel analizi ve enerji üretim sistemlerine uyarlanması.
- Atbaş, G., & Yazar, A. C. (2008). Kümeleme analizinde küme sayısının belirlenmesi üzerine bir çalışma. Ankara Üniversitesi Fen Bilimleri, İstatistik ABD.
- Avşar, S. (2024). Solar power plant investment strategy assessment with cost-benefit analysis: A case of a retail company in Turkey.
- Aykar, C. (2016). Türkiye Ege bölgesi güneş enerjisi potansiyeli tekno-ekonomik analizi.
- Berson, A., & Thearling, K. (1999). Building data mining applications for CRM.
- Canpolat, H. (2025). Endüstriyel tesislerde güneş enerjisi santrallerinin optimum planlaması ve etkinlik analizi: Teknik, ekonomik ve çevresel yaklaşımlar.
- Ceylan, Y. (2016). Türkiye'nin güneşlenme potansiyelinin analizi ve güneş enerjisinin enerji politikasındaki yeri.
- Ching, W.-K., & Ng, M. K.-P. (2003). Advances in data mining and modeling. Hong Kong.

- Çakmak, Z., Uzgören, N., & Keçek, G. (2015). Kümeleme analizi teknikleri ile illerin kültürel yapılarına göre sınıflandırılması ve değişimlerinin incelenmesi. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*.
- Çamurcu, A. Y., & Işık, M. (2010). K-means ve aşırı küresel c-means algoritmaları ile belge madenciliği. *Marmara Fen Bilimleri Dergisi*.
- Çiftçi, M. (2015). Türkiye'de yenilenebilir enerji kaynaklarından güneş enerjisi potansiyeli ve yerel yönetimlerde kullanımının SWOT analizi: Bursa Gürsu Belediyesi.
- Çil, F. (2010). Banka yatırım fonu müşteri hareketlerinin belirlenmesine yönelik bir veri madenciliği uygulaması (Yüksek lisans tezi).
- Doğan, M. (2019). Güneş enerjisi santrallerinin incelenmesi ve verimlilik analizi.
- Elmas, İ. E. (2024). An analysis of the financial viability of renewable energy investments: A case study on residential solar and battery solutions.
- Hastie, T., & Trevor, R. (2009). The elements of statistical learning: Data mining, inference, and prediction. New York: Springer.
- Jiryawee, H. A. (2023). Solar energy analysis by using different package programs.
- Kısa, G. (2020). Türkiye’de güneş enerjisinden elektrik üretimi potansiyelinin sürdürülebilirlik çerçevesinde SWOT Analizi yöntemiyle incelenmesi.
- Kocabaldır, C. (2021). Coğrafi bilgi sistemi tabanlı çok kriterli karar analizi ile fotovoltaik güneş enerjisi santralleri için yer seçimi: Çanakkale ili örneği.

- Kömürcü, S. (2019). Güneş enerjisi santralleri yatırım analizi ve yatırımcıların karşılaştığı sorunlar.
- Kumar, V., Tan, P., & Steinbach, M. (2006). Introduction to data mining.
- Larose, D. T. (2005). An introduction to data mining.
- MacQueen, J. (tarih yok). Some methods for classification and analysis of multivariate observations. University of California.
- Özdamar, K. (2002). Paket programlar ile istatistiksel veri analizi II. Eskişehir: Kaan Kitabevi.
- Reşat Uzmen, A. A. (2025). 21.yüzyılda enerji kullanımı ve iklim değişikliği. T.C. Dışişleri Bakanlığı.
- Sağiroğlu, Ç. (2016). Türkiye'nin iller bazında enerji ihtiyacının veri madenciliği ile analizi ve lisanssız yenilenebilir enerji yatırımları için karar destek önermesi (Doktora tezi). Çukurova Üniversitesi.
- Sarsıcı, N. (2020). Karabük ilinde güneş enerjisi santrali (GES) kurulabilecek alanların çok ölçütlü karar analizi ile tespiti.
- Sezikli, N. M. (2023). Makine öğrenmesi yöntemiyle yenilenebilir güneş enerjisi üretiminin meteorolojik veriler kullanılarak tahmin analizi.
- Suner, A., & Çelikoğlu, C. C. (2010). Toplum tabanlı bir çalışmada çoklu uygunluk analizi ve kümeleme analizi ile sağlık kurumu seçimi. Dokuz Eylül Üniversitesi İİBF Dergisi, 43–55.
- T.C. Enerji ve Tabii Kaynaklar Bakanlığı. (2025, April 16). T.C. Enerji ve Tabii Kaynaklar Bakanlığı. <https://enerji.gov.tr/>

- Tekkale, G. (2018). Türkiye'nin çeşitli illerinde yapılacak arazi tipi lisanssız güneş enerjisi santrali yatırımlarının teknik ve finansal analizi.
- Uçar, M. T. (2017). Yenilenebilir enerji kaynaklarından rüzgar ve güneş enerjisinin incelenmesi ve Güneydoğu Anadolu bölgesinde uygulanabilirliğinin analizi.
- Yılmaz, İ. (2024). Bulanık analitik hiyerarşi prosesi ve makine öğrenmesi yöntemleri ile güneş enerjisi santralleri için yer seçimi: Batı Akdeniz örneği (Yüksek lisans tezi). Akdeniz Üniversitesi.
- Yüce, M. (2023). Makine öğrenmesi yöntemleriyle Burdur ilinde arazilerin güneş enerjisi santrallerine yönelik uygunluğunun değerlendirilmesi (Yüksek lisans tezi). Burdur Mehmet Akif Ersoy Üniversitesi.

SALGIN HASTALIKLARDA KAYNAK PLANLAMASINDA KULLANILAN MODELLER¹

Melik KOYUNCU²

Rızvan EROL³

1. GİRİŞ

Tarih boyunca salgın hastalıklar, insanlık için ciddi sorunlar teşkil etmiştir. Her ne kadar insanlık tarihinin tüm dönemlerinde salgın hastalıklara rastlansa da, bazı zaman dilimlerinde bu hastalıkların etkileri son derece yıkıcı olmuştur. Örneğin, 14. yüzyılda meydana gelen veba salgını sırasında Avrupa nüfusunun yaklaşık 100 milyon olduğu, bu nüfusun yaklaşık 25 milyonunun salgın nedeniyle yaşamını yitirdiği tahmin edilmektedir. Bilim insanları, salgın hastalıklarla etkili bir şekilde mücadele edebilmek amacıyla sürekli olarak yeni yöntemler geliştirmeye çalışmışlardır. Antibiyotikler, aşılar ve diğer mücadele stratejileri sayesinde zaman zaman önemli başarılar elde edilse de, salgın hastalıkların tamamen ortadan kaldırılması mümkün olmamıştır. Nitekim tüberküloz ve vebaya yol açan bakteriler, zaman içerisinde antibiyotiklere karşı direnç geliştirerek yeniden ortaya çıkmıştır. Bunun yanı sıra Lyme hastalığı (1975), lejyoner hastalığı (1976), toksik şok sendromu (1978), AIDS (1981), hepatit C (1989) ve hepatit E (1990) gibi

¹ Bu bölüm büyük ölçüde “Salgın Hastalıkların Önlenmesinde Kaynak Atama Probleminin İncelenmesi” adlı doktora tezinden üretilmiştir.

² Doç. Dr., Çukurova Üniversitesi Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, ORCID: 0000-0003-0513-6276

³ Prof. Dr., Çukurova Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü, ORCID: 0000-0001-6914-5062.

pek çok salgın hastalık da yakın dönemde ortaya çıkan önemli sağlık sorunları arasında yer almaktadır. Salgın hastalıklar insanlık tarihinin çeşitli dönemlerinde ortaya çıkarak çok ciddi zarar vermişlerdir. En son 2019 yılında ortaya çıkan Covid 19 virüsü çok hızlı bir şekilde yayılarak dünya çapında milyonlarca kişinin ölümüne neden olmuştur.

T.C. Sağlık Bakanlığının 2005 yılında hazırladığı Pandemi İnfluenza Ulusal Eylem Planına göre salgına hazırlık süreci kısaca aşağıdaki maddeler gibi sıralanabilir.

a. İzleme ve Gözlem Aşaması

- i. Salgından etkilenecek kişi sayısının tahmin edilmesi
- ii. Sağlık kurumlarına müracaat sayılarında olağan dışı hareketlilerin analiz edilmesi
- iii. Salgın hastalığın yayılımının gözlenmesi ve etkilerinin değerlendirilmesi
- iv. Olağan dışı vaka sayılarına yönelik erken uyarı sistemlerinin oluşturulması

b. Koruyucu ve Önleyici Yöntemlerin Değerlendirilmesi

- i. Sağlık otoritelerince hazırlanan koruma programlarının oluşturulması
- ii. Koruma programlarının tüm kamuoyuna hızlı biçimde duyurulması
- iii. Yetkili kurullarca, koruma programının etkinliğinin ve güvenilirliğinin analiz edilmesi

c. Tedavi Yöntemlerinin Belirlenmesi

Salgın hastalık esnasında tedavi yöntemlerine ait strateji belirlenmesi

- i. İlaçları ve kaynakları hızlı ve etkili bir biçimde dağıtmak için tedarik zincirinin oluşturulması

d. Sağlık Servislerinin Planlanması

- i. Sağlık kaynaklarının olağanüstü durumlar için hazırlanması ve planlanması
- ii. Sağlık sistemlerinin olası etkilere kapasitelerinin değerlendirilmesi

e. Halk Sağlığı Ölçütleri

- i. Kapanma koşullarının belirlenmesi
- ii. Salgına maruz kalan tüm ülkelerle işbirliği yapılması

Salgınla mücadele için hazırlık aşamasından sonra müdahale aşaması gelir. Müdahale aşamasının bileşenleri aşağıda verilmiştir.

- i. Kaynakların sağlık birimlerine, amaçları sağlayacak biçimde dağıtılması
- ii. Hazırlık aşamasında planlanan önlemlerin uygulamaya geçirilmesi,
- iii. Hastalığın değişik yayılım senaryolarına göre alternatif kaynakların sağlanması

Salgına neden olabilecek bulaşıcı hastalık ortaya çıktıktan sonra sağlık ekiplerinin birbirleriyle koordineli bir biçimde hastalığa hızlı müdahale etmesi salgının daha fazla yayılmasını engellemek açısından son derece önemlidir. Aynı zamanda salgın hastalıkların toplum üzerinde oluşturacağı olumsuz etkilerin en aza indirilmesi için sağlık kaynaklarının ihtiyaç duyulan bölgelere en uygun şekilde dağıtılması da oldukça önemlidir. Problemin karmaşıklığı, kaynak paylaşımı kararının rasgele yapılmasından veya kişisel kararlara dayanmasından ziyade belirli bir sisteme ve analitik düşünceye dayandırılmasını zorunlu kılmıştır. Bu durum, araştırmacıları, kaynak tahsisi problemi ve salgın hastalıkların modellenmesinde yöneylem tekniklerinin kullanılması konusunda teşvik edici olmuştur.

2. SALGIN YAYILIM MODELLERİ

Bu bölümde, salgın hastalıkların olumsuz etkilerini en aza indirmek için, vaka sayısının tahmininde kullanılan sayısal yöntemlerden bahsedilecektir.

2.1. Vaka Sayılarının Tahmini

Salgınla mücadele edebilmek için, ilgili salgında zamana bağlı olarak oluşacak vaka sayısının tahmin edilmesi kritik öneme sahiptir. En çok kullanılan iki yöntem; klinik atak oranını kullanarak tahmin ve temel çoğalma katsayısını (R_0) kullanarak tahmindir.

2.1.1. Klinik atak oranı ile Vaka Sayılarının Tahmini


Klinik atak oranı, bir popülasyondaki nüfusun, ilgili salgında hangi oranda bu salgına maruz kalacağını ölçtünü ifade eder. Nüfusu 100 milyon olan bir popülasyonda klinik atak oranının 0.25 olması, 25 milyon kişinin bu salgında enfekte olacağını tahmin eder. Farklı atak oranları kullanılarak, değişik senaryoların analiz edilmesi mümkündür. Bu yöntemde, salgın periyodunda zamana bağlı olarak vaka sayıları hesaplanamaz ancak belirli varsayımlarla günlük artışlar dikkate alınarak tahminde bulunulabilir. Örneğin, salgının periyodu 90 gün ise , atak oranının 0.25 olduğu bir senaryoda, 25 milyon kişinin bu salgına maruz kalacağı varsayılır. Başlangıç gününden, salgının periyodunun bitiş gününe kadar belli oranda artışın toplam maruz kalan kişi sayısına eşit olacak biçimde, günlük bazda vaka sayıları tahmin edilir. Bu işlemler her senaryoda farklı atak oranları için tekrarlanır. Zhang ve arkadaşlarının (2006) pandemik influenza için vaka sayısını tahmin etmek için geliştirdikleri FLUSURGE 2.0 bu yaklaşımı kullanmaktadır.

2.1.2. Temel Çoğalma Sayısını (R0) Kullanarak Vaka sayılarının Tahmini

Özellikle Covid 19 salgınından itibaren bir çok kişi Ro sayısını sıklıkla duymaya başlamıştır. Literatürde temel çoğalma sayısı olarak bilinen Ro, genel olarak bir kişinin hastalığı ortalama kaç kişiye bulaştıracığının ölçüsü olarak bilinir. Temel yeniden çoğalma sayısının doğru tahmin edilmesi zamana bağlı olarak beklenen vaka sayılarının doğru tahmin edilmesine olanak sağlar. Temel yeniden çoğalma sayısı salgının türüne göre farklı hesaplama metodolojileri içerir.

2.1.3. Şüpheli ve Enfekte (SI) Modeli

Temel yeniden çoğalma sayısı ile vaka sayısının zamana bağlı olarak tahmin eden en basit model SI modelidir. Bu modelde popülasyondaki bireyler şüpheli (S:enfekte olmuş veya olmamış) ve enfekte olmuş (I) bireyler olarak iki kategoriye ayrılır. Bu modelde popülasyon büyüklüğünün sabit kaldığı varsayılır. Bir kez enfekte olan kişinin, iyileşmesinin mümkün olmadığı kabul edilir. Enfekte olan kişinin, bulaştırmaya hemen başladığı, kuluçka döneminin olmadığı kabul edilir. Kişi bir kez enfekte olduğunda hastalığı hemen bulaştırmaya başlar. SI modeli şematik olarak Şekil 1.'deki gibi gösterilebilir.



Şekil 1. SI yayılım modeli

Salgın hastalıkların yayılımı diferansiyel denklemler ile modellenebilir.

$$X'_i(t) = f(x_1(t), x_2(t), \dots, x_m(t)) \quad (1)$$

(1) no'lu denklemin diferansiyel denklem tekniklerini kullanarak çözümü basit popülasyonlar için aşağıdaki gibi çözülebilir.

Notasyon

t : t anındaki zaman $t > 0$

$x_1(t)$: t anında popülasyondaki şüpheli kişilerin sayısı

$x_2(t)$: t anında popülasyonda enfekte olan kişilerin sayısı

λ : temas oranı , $\lambda \in (0,1)$

δ : şüpheli kişilerin enfekte olma oranı, $\delta \in (0,1)$

N : popülasyondaki birey sayısı

Denklem(1)'de gösterilen modelde, popülasyondaki birey sayısı (N) sabit varsayıldığından, epidemik model denklemi (2-4) ile gösterilebilir.

$$x_1'(t) = \delta - \lambda x_1(t)x_2(t) \quad (2)$$

$$x_2'(t) = \lambda x_1(t)x_2(t) - \delta x_2(t) \quad (3)$$

$$x_1(t) + x_2(t) = 1 \quad (4)$$

Popülasyonda bulunan toplam kişi sayısı N ise ; t anında şüpheli ve enfekte olmuş kişilerin sayısı $Nx_1(t) + Nx_2(t)$ olacaktır ve denklemin kapalı çözümü denklem (5)'deki gibi hesaplanır.

$$x_2(t) = \left\{ \begin{array}{ll} \frac{x_2(0) (\lambda - \delta) e^{(\lambda - \delta)t}}{\lambda x_2(0) e^{(\lambda - \delta)t} - 1 + (\lambda - \delta)} & \lambda \neq \delta \\ \frac{1}{\lambda t + \frac{1}{x_2(0)}} & \lambda = \delta \end{array} \right\} \quad (5)$$

2.1.4. Çoklu Popülasyonda Bulaşıcı Hastalık Yayılım Modeli

Tekli popülasyon modelinde, $t=0$ anından T anına kadar olan zaman periyodunda oluşacak hasta sayısı ;


$$H(\lambda) \equiv \int_{t=0}^T \lambda I(t, \lambda) S(t, \lambda) dt = \int_{t=0}^T \frac{\partial I(t, \lambda)}{\partial t} dt + \delta \int_{t=0}^T I(t, \lambda) dt \quad (6)$$

ile hesaplanır.

Benzer durumda, m farklı popülasyonun olması durumunda, $t=0$ anından T anına kadar popülasyonlarda enfekte olan kişi sayısı ;

$$H_i(\lambda_i) \equiv \int_{t=0}^T \lambda_i I_i(t, \lambda_i) S_i(t, \lambda_i) dt = \int_{t=0}^T \frac{dI(t, \lambda_i)}{dt} dt + \delta_i \int_{t=0}^T I_i(t, \lambda_i) dt \quad (7)$$

formülü ile hesaplanacaktır.



Şekil 2. Çoklu Popülasyonda Bulaşıcı Hastalık Yayılım Modeli

2.1.5. SEIR Modeli

Vaka sayılarını zamana bağlı olarak tahmin etmek için sıklıkla kullanılan modellerden birisidir. Modelin açılımı Şüpheli (Suspected), enfeksiyon öncesi (Pre Infected), enfekte olmuş (Infected) ve iyileşmiş (Recovered) biçimindedir. Modelin matematiksel açıklaması aşağıda detaylı olarak yapılmıştır.

Notasyon

β : bir kişinin ortalama temas oranı

f : t ve $t+1$ arasında enfekte olan kişilerden hastalığı bulaştıranların oranı

r : enfekte olmuş kişilerin iyileşme oranı

λ_t : t ve $t+1$ zamanları arasında bir bireyin enfekte olma riski

E_t : t anında enfekte olan ama henüz bulaştırmaya başlamayan bireylerin sayısı

E_{t+1} : $t+1$ anında enfekte olan ama henüz bulaştırmaya başlamayan bireylerin sayısı

S_t : t anında şüpheli bireylerin sayısı

$S_{t=0}$: $t=0$ anında toplam şüpheli kişilerin sayısı

S_{t+1} : $t+1$ anında şüpheli kişilerin sayısı

I_t : t anında enfekte olan kişi sayısı

I_{t+1} : $t+1$ anında enfekte olan kişi sayısı

$R_{t=0}$: $t=0$ anında bağışıklığı olan kişi sayısı

R_t : t anında bağışıklığı olan kişi sayısı

R_{t+1} : $t+1$ anında bağışıklığı olan kişi sayısı

$I_{yeni(t+1)}$: t ile $t+1$ arasında yeni enfekte bireylerin sayısı

NC_{t+1} : t ile $t+1$ zamanları arasında bildirilen vaka sayısı

CI: Enfekte olan kişilerin hastalığa yakalanma oranı

SEIR modeli için temel yeniden çoğalma sayısı Denklem (8-19)
'da verilen eşitlikler çözülerek hesaplanır.

$$\beta = \frac{R_0}{N.D} \quad (8)$$

$$f = 1/t_e \quad (9)$$

$$r = 1/D \quad (10)$$

$$S_{t+1} = S_t - \lambda_t . S_t \quad (11)$$

$$\lambda_t = \beta . I_t \quad (12)$$

$$E_{t+1} = E_t + \lambda_t . S_t - f . E_t \quad (13)$$

$$I_{t+1} = I_t + f . E_t - r . I_t \quad (14)$$

$$R_{t+1} = R_t + r . I_t \quad (15)$$

$$S_{t=0} = N - I_0 - R_{t=0} \quad (16)$$

$$R_{t=0} = N . I_{m(0)} \quad (17)$$

$$I_{yeni(t+1)} = E_t . f \quad (18)$$

$$NC_{t+1} = E_t . f . CI \quad (19)$$

3. VAKA SAYISINI TAHMİN EDEN YAZILIMLAR

Matematiksel modellerinden bahsedilen vaka sayısı tahmin yöntemleri için çeşitli yazılımlar geliştirilmiştir. Zhang ve arkadaşları (2006) tarafından geliştirilen ve vaka sayısını klinik atak oranına göre tahmin eden FLUSURGE 2.0 yazılımı Amerika Birleşik Devletleri Enfeksiyonla Mücadele ve Engelleme Merkezi (CDC) 'nin internet sitesinden indirilebilir. Temel yeniden çoğalma sayısı ise R yazılımının deSolve kütüphanesi kullanılarak hesaplanabilir. Salgın hastalıkların yayılması ve

modellenmesi hakkında Vynnycky, E., & White, R. (2010) tarafından yazılan kitabın internet sitesindende Ro'ı hesaplayan excel tabanlı yazılımlara ulaşmak mümkündür.

KAYNAKÇA

1. Koyuncu, Melik. Salgın Hastalıkların Önlenmesinde Kaynak Atama Probleminin İncelenmesi, Doktora Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, 2008.
2. T.C. Sağlık Bakanlığı Temel Sağlık Hizmetleri Genel Müdürlüğü. Pandemik İnfluenza Ulusal Faaliyet Planı, Ankara, 2005.
3. Centers for Disease Control and Prevention. (2016, 22 Ağustos). *FluSurge 2.0*. U.S. Department of Health and Human Services. https://archive.cdc.gov/www_cdc_gov/flu/pandemic-resources/tools/flusurge.htm
4. Zhang X, Meltzer MI, Wortley PM. FluSurge—A Tool to Estimate Demand for Hospital Services during the Next Pandemic Influenza. *Medical Decision Making*. 2006;26(6):617-623. doi:10.1177/0272989X06295359
5. Vynnycky, E., & White, R. (2010). *An introduction to infectious disease modelling*. Oxford University Press.

BİR KİMYA FİRMASINDA ENDÜSTRİYEL KARIŞTIRICI PROBLEMLERİNİN DEMATEL YÖNTEMİYLE ANALİZİ

Yıldız ŞAHİN¹

Emre YÜKSEL²

1. GİRİŞ

Günümüzde sanayi ve üretim sektörlerinde süreç verimliliği, kalite yönetimi ve sürdürülebilirlik ilkeleri işletme stratejilerinin merkezinde yer almaktadır. Bu çerçevede, özellikle kimya gibi hassas ve sürekli kontrol gerektiren proseslere sahip endüstrilerde, üretim ekipmanlarının performansı rekabet avantajı açısından belirleyici bir unsur hâline gelmiştir. Kimya sanayisinde sıklıkla kullanılan ekipmanlardan biri olan endüstriyel karıştırıcılar, üretim sisteminin temel yapı taşlarından biridir; hem ürün kalitesini doğrudan etkileyen hem de prosesin sürekliliğini sağlayan bir işlev üstlenmektedir. Bu karıştırıcılar, farklı fazlardaki maddeleri belirli bir düzen içerisinde homojen hâle getirmek amacıyla geliştirilen mekanik sistemlerdir. Ancak bu sistemlerde meydana gelen herhangi bir verim düşüklüğü ya da teknik problem, üretim sürecinde aksamalar, kalite kayıpları ve enerji israfı gibi sonuçlar doğurabilmektedir. Bu tür teknik problemlerin kaynağını belirlemek ve çözüme yönelik sistematik adımlar atmak adına, bilimsel karar destek mekanizmalarının kullanımı kaçınılmaz hâle gelmiştir. İşletmelerde yaşanan

¹ Doç. Dr., Kocaeli Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, ORCID: 0000-0002-6283-5340.

² Lisansüstü Öğrencisi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Mühendislik Yönetimi A.B.D., ORCID: 0009-0009-0268-8877.

karmaşık sorunların analizinde, karar vericilerin problemler arasındaki ilişkileri anlaması, kaynakların etkili ve öncelikli kullanımı için kritik öneme sahiptir. Bu sebeple, özellikle üretim gibi çok değişkenli süreçlerde, çok kriterli karar verme (ÇKKV) yaklaşımları öne çıkmaktadır. ÇKKV yöntemleri, birden fazla faktörün aynı anda değerlendirilmesine ve aralarındaki ilişkilerin sistematik olarak incelenmesine olanak sağlar. Bu yöntemler arasında yer alan DEMATEL (Decision Making Trial and Evaluation Laboratory) tekniği ise karar alıcılara, kriterler arasındaki etkileşimleri hem sayısal hem de görsel biçimde değerlendirme olanağı sunarak, sorunların neden-sonuç yapısını ortaya koymada etkili bir araç olarak öne çıkmaktadır.

Bu bağlamda, çalışma kapsamında Türkiye’de kimya sektöründe faaliyet gösteren Ege Kimya firmasında, üretim hattında kullanılan endüstriyel karıştırıcı sistemlerde yaşanan performans problemleri değerlendirilmiştir. Son dönemde firmada sıkça raporlanan problemler arasında; karışım homojenliğinin sağlanamaması, motor arızalarının artması, enerji tüketiminin yüksek olması, bakım uygulamalarındaki eksiklikler, proses koşullarına uygun olmayan ekipman kullanımı ve vibrasyon kaynaklı yapısal sorunlar yer almaktadır. Bu sorunların yalnızca teknik düzeyde bireysel problemler değil, aynı zamanda birbirini etkileyen ve tetikleyen sistematik unsurlar olduğu düşünülmektedir. Bu nedenle, klasik hata analizi yöntemlerinin ötesine geçilerek, neden-sonuç ilişkilerini açık biçimde ortaya koyabilecek ve etki derecelerini ölçebilecek bir yaklaşıma ihtiyaç duyulmuştur.

Bu çalışmanın temel amacı; endüstriyel karıştırıcı sistemlerinde karşılaşılan bu problemlerin neden ve sonuçlarını DEMATEL yöntemiyle analiz etmek, kriterler arasındaki etkileşim ağını ortaya koymak ve işletme yönetimi için stratejik iyileştirme önerileri sunmaktır. Bu doğrultuda; firmanın proses mühendisi, bakım sorumlusu, üretim yöneticisi ve saha

operatörlerinden oluşan uzman ekip ile yapılan değerlendirmeler doğrultusunda, DEMATEL yöntemi sistematik olarak uygulanmıştır. Süreç boyunca önce doğrudan ilişki matrisi oluşturulmuş, ardından veriler normalize edilerek toplam etki matrisi elde edilmiş ve bu verilerle nedensellik diyagramı oluşturulmuştur. Nihayetinde, hangi sorunların daha fazla etkileyici olduğu ve hangilerinin daha çok dış etkilere kaynaklandığı analiz edilerek, problemler neden ve sonuç kümeleri şeklinde sınıflandırılmıştır. Yalnızca teknik bir analiz değil; aynı zamanda karar alma süreçlerine yön verecek stratejik bir karar destek modeli olarak değerlendirilmiştir. Bu çalışmanın, benzer yapıda üretim sistemlerine sahip olan diğer kimya sektörü firmaları için örnek teşkil etmesi ve benzer karmaşık problemlerin sistematik şekilde çözümlenmesine katkı sağlaması beklenmektedir.

2. LİTERATÜR İNCELEMESİ

Endüstriyel karıştırıcı sistemler, kimya, gıda, ilaç ve kozmetik gibi birçok üretim sektöründe kritik öneme sahip proses ekipmanlarıdır. Bu sistemler; sıvı, katı ya da gaz fazlardaki maddeleri belirli bir homojenlik derecesine ulaştırmak amacıyla geliştirilmiş mekanik yapılar olup, ürün kalitesini ve proses sürekliliğini doğrudan etkileyen unsurlar arasında yer almaktadır. Literatürde karıştırıcıların tasarımı ve performans değerlendirmesinde dikkate alınan temel faktörler arasında akışkanın viskozitesi, yoğunluğu, tankın hacmi ve geometrisi, kullanılan pervane tipi ve dönüş hızı gibi fiziksel ve operasyonel parametreler öne çıkmaktadır. Paul vd. (2004), gerçekleştirdikleri çalışmada, farklı tipte karıştırıcıların performanslarını özellikle viskoz ve yüksek yoğunluklu sistemlerde detaylı biçimde karşılaştırmıştır. Benzer şekilde, Armenante ve Nagamine (1998), enerji verimliliği ile karışım kalitesi arasındaki ilişkiyi deneysel

düzlemde inceleyerek, daha düşük enerjiyle homojen karışım sağlanmasına yönelik yöntemler önermiştir. Bu bağlamda, Hesaplamalı Akışkanlar Dinamiği (CFD) gibi sayısal analiz teknikleri, karıştırma sistemlerinin prototipleme aşamasında simülasyon temelli optimizasyonuna olanak tanımaktadır (Jaworski vd., 2019). Weheliye vd. (2020) tarafından yapılan araştırmada ise farklı pervane geometrilerinin CFD analizleri yardımıyla test edilerek optimum karışım koşulları belirlenmiştir. Ochieng & Lewis (2006) çok fazlı sistemlerde karıştırıcıların deneysel analizini gerçekleştirirken; Rahimi vd. (2018) ve Ibrahim vd. (2021) ise karıştırıcı kanat yapısının türbülans davranışı ve enerji tüketimi üzerindeki etkilerini değerlendirmiştir.

Endüstriyel karıştırıcılar üzerine yapılan diğer araştırmalarda ise sistem performansının artırılması ve bakım süreçlerinin iyileştirilmesi ana temalar olarak öne çıkmaktadır. Tatterson (1991), endüstriyel karıştırıcıların farklı reaktör tipleriyle olan etkileşimini analiz ettiği çalışmada, bu sistemlerin temel tasarım ilkelerini tanımlamıştır. Doran (2013) ise biyoteknolojik uygulamalarda kullanılan karıştırıcı sistemlerin dinamik tepkilerini incelemiş ve özellikle mikrobiyal üretimlerde karışım kalitesinin ürün verimliliğiyle güçlü bir ilişki içinde olduğunu göstermiştir. Çok fazlı karışımlarda parçacık süspansiyonlarının etkisini inceleyen Gao ve Bai (2020), bu tür sistemlerde karıştırma davranışının faz dağılımına olan etkilerini ortaya koymuştur. Müller vd. (2022) ise saha verilerine dayalı olarak gerçekleştirdikleri çalışmada, karıştırıcılarda en sık karşılaşılan arıza tiplerini ve bu arızaların temel nedenlerini analiz etmiş ve kestirimci bakım sistemlerinin gerekliliğini vurgulamıştır.

Karıştırıcı teknolojilerinde dijitalleşme ve veri temelli izleme sistemleri üzerine yapılan çalışmalar da dikkat çekmektedir. Son yıllarda karıştırıcılarda karşılaşılan vibrasyon,

gürültü, aşırı enerji tüketimi ve bakım aralığı problemleri gibi konular, özellikle IoT (Nesnelerin İnterneti) destekli bakım sistemlerinin geliştirilmesine öncülük etmiştir. Wang vd. (2022), sensör tabanlı sistemlerin karıştırıcılarda arıza tespitinde önemli avantajlar sunduğunu belirtmektedir. Buna ek olarak, dijital ikiz uygulamalarının karıştırıcı sistemlerine entegre edilmesiyle, gerçek zamanlı performans izlemesi ve arıza tahminine dayalı bakım planlaması yapılabilmektedir. Bu gelişmeler, Endüstri 4.0 kapsamında karıştırma sistemlerinin akıllı üretim teknolojilerine entegrasyonunu hızlandırmaktadır.

Ürün kalitesinin güvence altına alınması açısından karışım homojenliğinin üretim sırasında izlenebilirliği büyük önem taşımaktadır. Literatürde, inline sensörler, optik tabanlı analiz sistemleri ve renk ölçüm cihazları gibi teknolojilerle karışım kalitesinin anlık olarak değerlendirilebildiği çalışmalara sıklıkla rastlanmaktadır (Kim vd., 2021). Bu sistemler, üretim hattında kalite sapmalarının erken tespitine ve anlık müdahalelere imkân tanımakta; böylece hatalı ürün oranlarının düşürülmesini sağlamaktadır.

Endüstriyel sistemlerdeki teknik problemleri sistematik olarak analiz edebilmek amacıyla çok kriterli karar verme (ÇKKV) yöntemleri sıklıkla kullanılmaktadır. Bu yöntemlerden biri olan DEMATEL, sistemde yer alan faktörlerin karşılıklı ilişkilerini hem sayısal hem grafiksel olarak analiz etme yeteneğine sahiptir. Battelle Memorial Institute tarafından 1970’li yıllarda geliştirilen bu yöntem, özellikle sosyal, yönetsel ve mühendislik sistemlerindeki karmaşıklığın modellenmesi ve neden-sonuç yapılarının ortaya konması açısından etkili bir analiz yaklaşımı olarak öne çıkmaktadır. DEMATEL’in temel avantajı yalnızca kriterlerin önem derecelerini hesaplamakla kalmayıp, bu kriterler arasındaki nedensel bağları da belirleyebilmesidir.

DEMATEL yöntemi literatürde farklı sektörlerde yaygın biçimde uygulanmaktadır. Yılmaz vd. (2023), Fas'taki bir kimya işletmesinde bakım performans kriterlerini analiz ederken; Wu ve Chang (2015), yeşil tedarik zinciri uygulamalarında çevresel faktörlerin ilişkilerini incelemiştir. Zhang vd. (2019), Sponge City projelerinde proje risklerini analiz etmek için DEMATEL'i kullanmış; Cheshmberah vd. (2020) ise FMEA yöntemiyle entegre ederek arıza nedenlerini daha derinlemesine sınıflandırmıştır. Lin vd. (2011), Tayvan'daki IC firmalarında çekirdek yetkinliklerin belirlenmesinde DEMATEL'i tercih etmiş; Lee vd. (2012) kalite kontrol kriterlerinin süreç üzerindeki etkilerini ortaya koymuştur. Mohagheghi vd. (2020) enerji verimliliği alanında, Büyüközkan & Çifçi (2012) ise sürdürülebilir tedarikçi seçiminde DEMATEL yöntemini hibrit modellerle birlikte kullanmıştır. Tzeng vd. (2007), yöntemi ANP ile birleştirerek çok kriterli karar destek yapıları geliştirmiştir. Diğer örneklerde ise enerji (Zolfani & Saparaukas, 2013), lojistik (Keshavarz Ghorabae vd., 2017), dijital dönüşüm (Vujanovic vd., 2022) gibi alanlarda DEMATEL'in etkinliği gösterilmiştir.

Tüm bu uygulamalar göstermektedir ki DEMATEL yöntemi, teknik sistemlerdeki karmaşık ilişkileri açıklamada güçlü bir karar destek aracıdır. Karıştırıcı sistemlerinde ortaya çıkan arızalar, bakım gereksinimleri, ekipman uyumsuzlukları ve sistematik hatalar gibi çok boyutlu sorunların analizi için DEMATEL hem neden hem de sonuç yapısını belirginleştiren analitik ve görsel çıktılar sağlamaktadır. Bu bağlamda, endüstriyel karıştırıcı problemlerine yönelik uygulamalarda DEMATEL yönteminin daha fazla kullanılması, literatürde eksik kalan bir boşluğu doldurmakta ve uygulayıcılara yeni bir analiz perspektifi sunmaktadır.

Bu çalışma, endüstriyel karıştırıcı sistemlerdeki mühendislik temelli problemleri, neden-sonuç ekseninde ele

olarak çözüm yolları geliştiren özgün bir yaklaşım sunmaktadır. Literatürde DEMATEL'in doğrudan bu sistemlere uygulanmasına dair sınırlı sayıda araştırma bulunmakta olup, bu bağlamda mevcut çalışma hem yöntemsel hem de uygulamalı olarak sektöre katkı sağlamayı hedeflemektedir.

3. DEMATEL YÖNTEMİ METODOLOJİSİ

DEMATEL, çok kriterli karar verme (ÇKKV) problemlerinde, sistemde yer alan faktörlerin birbirleriyle olan nedensel bağlarını ortaya koymak amacıyla geliştirilen etkili bir analiz metodudur. Özellikle karmaşık yapıli sistemlerde doğrudan ve dolayli etkilerin birbirinden ayırtılarak modellenmesini sağlamakta ve bu sayede karar vericilere sistemin bütüncül etkileşim yapısını daha net biçimde sunmaktadır

Yöntem ilk olarak 1970'li yıllarda Cenevre merkezli Battelle Memorial Institute tarafından geliştirilmiş olup, başlangıçta sosyal sistem analizlerine yönelik olarak kullanılmıştır. Ancak zamanla mühendislik, yönetim, sağlık, eğitim ve enerji gibi birçok alanda yaygın biçimde uygulanmaya başlamıştır. DEMATEL'in temel işlevi, karar sürecinde yer alan çok sayıda faktör arasındaki karşılıklı etkileri görselleştirerek, sistemde hangi unsurların neden, hangilerinin sonuç rolünde olduğunu ortaya koymaktır. Yöntemin en önemli özelliklerinden biri, ilişkileri yalnızca tek yönlü değerlendirmekle yetinmeyip çift yönlü analiz gerçekleştirebilmesidir. Böylece, yalnızca "hangi unsur diğerlerini etkiler?" sorusuna değil, aynı zamanda "hangi unsur diğerlerinden etkilenir?" sorusuna da yanıt verilebilir. Bu yaklaşım, özellikle üretim, bakım ve enerji yönetimi gibi etkileşimli yapıya sahip endüstriyel sistemlerde, karar vericilere çok boyutlu ve sistematik bir değerlendirme olanağı sunmaktadır.

Bu bölümde, uzman görüşlerinden elde edilen değerlendirmelere dayanarak oluşturulan doğrudan ilişki matrisi temel alınmış ve DEMATEL yönteminin tüm adımları ayrıntılı biçimde uygulanmıştır. DEMATEL yöntemi 5 adımdan oluşmaktadır (Wu ve Lee, 2007; Tsai ve Chou, 2009):

Adım 1: Direkt ilişki matrisinin oluşturulması.

Yöntemin bu aşamasında kriterler arası ilişkiler, uzman grup tarafından ikili karşılaştırma ölçeği kullanılarak ortaya konulmaktadır. Uzmanlarca gerçekleştirilen karşılaştırmalar yoluyla direkt ilişki matrisi elde edilmektedir. Tablo 1’de ikili karşılaştırmada kullanılan değerlendirme ölçeği görülmektedir.

Tablo 1. Etki ve Sayısal Değer Karşılığı

Sayısal Değer	Tanım
0	Etkisiz
1	Çok Düşük Etki
2	Normal Etki
3	Yüksek Etki
4	Çok Yüksek Etki

Adım 2: Normalleştirilmiş direkt ilişki matrisinin belirlenmesi.

Normalleştirilmiş direkt ilişki matrisi (M), Adım 1 ile ortaya konulan Direkt ilişki matrisine (A) bağlı olarak 1 ve 2 numaralı eşitlikler yardımıyla oluşturulur.

$$M=k \times A \quad (1)$$

$$k = \min \left(\frac{1}{\max \sum_{j=1}^n |a_{ij}|}, \frac{1}{\max \sum_{i=1}^n |a_{ij}|} \right) i, j \in \{1, 2, 3, \dots, n\} \quad (2)$$

Adım 3: Toplam ilişki matrisinin elde edilmesi (S).

Toplam ilişki matrisi (S), 3 numaralı eşitlik yardımıyla normalleştirilmiş direkt ilişki matrisi kullanılarak hesaplanmaktadır. Bu eşitlikte (I) birim matrisi ifade etmektedir.

$$S = M + M^2 + M^3 + \dots = \sum_{i=1}^{\infty} M^i = M(I - M)^{-1} \quad (3)$$

Adım 4: Gönderici ve alıcı grupların hesaplanması

Gönderici ve alıcı gruplar 4, 5 ve 6 numaralı eşitlikler yardımıyla hesaplanmaktadır. (R), Toplam ilişki matrisi (S)'de sütunlar toplamını, (D) is satırlar toplamını göstermektedir. D ve R değerleri hesaplandıktan sonra (D-R) ve (D+R) değerleri elde edilmektedir. Bu değerler her bir kriterin diğerleri üzerindeki etkisini ve diğerleri ile olan ilişki düzeyini ifade etmektedir. (D-R)'de pozitif değerlere sahip olan kriterlerin, diğerleri üzerinde daha yüksek bir etkiye sahip olduğunu kabul edilmektedir. Bu tip kriterler gönderici olarak adlandırılmaktadır. (D-R) değeri açısından negatif değere sahip olan kriterler ise diğerlerinden daha fazla etkilenirler. Bu kriterler ise alıcı olarak adlandırılmaktadırlar. Diğer yandan (D+R) değerleri, kriterlerden birinin diğerleri ile arasındaki ilişkiyi göstermektedir.

$$S = [S_{i,j}]_{m \times n}, \quad i, j \in \{1, 2, 3, \dots, n\} \quad (4)$$

$$D_i = \sum_{j=1}^n S_{ij} \quad (i = 1, 2, 3, \dots, n) \quad (5)$$

$$R_j = \sum_{i=1}^n S_{ij} \quad (j = 1, 2, 3, \dots, n) \quad (6)$$

Adım 5: Etki-yönlü graf diyagramının elde edilmesi

Karar vericilerin etki seviyesi için bir eşik değeri belirlemesinin ardından etki-yönlü graf elde edilebilmektedir. Toplam ilişki matrisinde, belirlenmiş olan eşik değerinden daha büyük değerlere sahip elemanlar seçilerek etki yönlü graf diyagramına dönüştürülür. Eşik değeri karar verici ya da uzmanlar tarafından belirlenir (Tsai ve Chou, 2009; Tzeng, vd, 2007).

4. DEMATEL İLE ENDÜSTRİYEL KARIŞTIRICI PROBLEMLERİNİN DEĞERLENDİRİLMESİ

Gerçekleştirilen bu çalışma ile bir kimya firmasında incelenen endüstriyel karıştırıcı problemleri DEMATEL yöntemi

ile analiz edilmiştir. Bölüm kapsamında yöntemin uygulama adımları dikkate alınarak sırasıyla her bir adımda yapılan işlemler ve hesaplama sonucunda elde edilen sonuçlar açıklanmıştır. Karar probleminin çözülmesi sürecine öncelikle değerlendirme kriterlerinin belirlenmesi ile başlanmıştır. Kriterler belirlendikten sonra uzman görüşlerine başvurulmuş, tüm değerlendirmelerin ortalaması alınarak Direkt İlişki Matrisinin oluşturulması sağlanmıştır. Aşağıda DEMATEL yönteminin karar problemine uygulanmasına ait tüm aşamalar detaylandırılmıştır.

4.1. Kriterlerin Belirlenmesi ve Tanımlanması

Bu adım, çözülmek istenen problemin kapsamını netleştirmek adına oldukça kritiktir. Kriterlerin doğru şekilde tanımlanması, elde edilecek sonucun geçerliliğini ve güvenilirliğini doğrudan etkiler. Bu nedenle kriterler, literatür taraması, saha gözlemleri ve uzman görüşleri doğrultusunda belirlenmelidir. Belirlenen kriterler, sistemin yapısını temsil eden etkili unsurları simgeler. DEMATEL yöntemiyle analiz edilen kriterler, endüstriyel karıştırıcı sistemlerinde gözlenen operasyonel sorunları temsil etmektedir. Bu kapsamda kullanılan kriterler ve açıklamaları Tablo 2’de belirtildiği gibidir.

Tablo 2. Kriter Gösterimleri ve Açıklamaları

Kriter	Açıklama
P1	Karışımın homojen olmaması
P2	Yüksek enerji tüketimi
P3	Motor arızalarının sıklığı
P4	Vibrasyon kaynaklı yapısal sorunlar
P5	Ekipmanın proses koşullarına uygun olmaması
P6	Bakım süreçlerindeki yetersizlik

Bu problemler birbirini tetikleyebilmektedir. Örneğin hatalı ekipman seçimi, vibrasyon ve motor arızalarına neden olmakta, bu da bakım ihtiyacını artırmakta ve üretim gecikmelerine yol açmaktadır.

4.2. Uzman Görüşlerinin Alınması

DEMATEL yönteminde sayısal veri eksikliği olan durumlarda uzman görüşü önemli bir bilgi kaynağıdır. Bu adımda, her kriterin diğer kriter üzerindeki etkisi 0 (etkisiz) ile 4 (çok güçlü etki) arasında puanlanır. Bu süreçte uzmanların farklı bakış açıları, etkileşimlerin çok boyutlu doğasını yansıtır. Birden fazla uzmandan alınan görüşlerin ortalaması alınarak daha nesnel bir değerlendirme yapılması sağlanır. Bu çalışmada, firmanın proses mühendisi, bakım şefi, üretim müdürü ve operatörlerinden oluşan 5 kişilik uzman bir ekipten görüş alınmıştır. Farklı değerlendirmeler olsa dahi aritmetik ortalama uygulanarak tabloya bu veriler işlenmiştir. Aynı kriterlerin kesişimleri tabloda 0 olarak kabul edilmiştir

4.3. DEMATEL Yöntem Adımlarının Uygulanması

Adım 1: Ortalama Direkt İlişki Matrisinin Oluşturulması (A)

Bu tablo, uzman görüşleriyle her bir problemin diğerleri üzerindeki etkisini göstermektedir. Değerler 0 (hiç etkisi yok) ile 4 (çok güçlü etki) arasında puanlanmıştır. Beş uzman tarafından gerçekleştirilen değerlendirmelerin ortalaması alınarak Tablo 3'teki sonuçlar elde edilmiştir.

Tablo 3. Ortalama Direkt İlişki Matrisi (A)

Kriterler	P1	P2	P3	P4	P5	P6
P1	0.000	1.200	2.000	1.400	0.600	2.200
P2	2.400	0.000	2.600	3.200	1.000	3.000
P3	1.200	1.800	0.000	2.400	0.400	2.200
P4	1.800	2.800	2.200	0.000	0.800	2.000
P5	0.800	1.600	0.800	1.200	0.000	1.400
P6	3.000	3.200	3.000	2.200	1.000	0.000

Adım 2: Normalleştirilmiş İlişki Matrisi (M)

Satır ve sütun toplamalarının en büyük değeri S olarak adlandırılır. Matrisin her bir elemanı S değerine bölünür ve

Normalize direkt ilişki matrisi oluşturulur. Tablo 4 Normalleştirilmiş İlişki Matrisini göstermektedir.

Tablo 4. Normalleştirilmiş İlişki Matrisi (M)

Kriterler	P1	P2	P3	P4	P5	P6
P1	0.000	0.097	0.161	0.113	0.048	0.177
P2	0.194	0.000	0.210	0.258	0.081	0.242
P3	0.097	0.145	0.000	0.194	0.032	0.177
P4	0.145	0.226	0.177	0.000	0.065	0.161
P5	0.065	0.129	0.065	0.097	0.000	0.113
P6	0.242	0.258	0.242	0.177	0.081	0.000

Adım 3: Toplam ilişki matrisinin elde edilmesi (S)

Adım 2’de yer alan Normalleştirilmiş ilişki matrisi kullanılarak Tablo 5’te verilen Toplam ilişki matrisi elde edilmiştir.

Tablo 5. Toplam İlişki Matrisi (S)

Kriterler	P1	P2	P3	P4	P5	P6
P1	0.144	0.201	0.237	0.211	0.106	0.312
P2	0.341	0.272	0.369	0.428	0.177	0.467
P3	0.203	0.245	0.182	0.291	0.083	0.293
P4	0.258	0.347	0.299	0.246	0.126	0.327
P5	0.147	0.207	0.142	0.181	0.054	0.218
P6	0.421	0.463	0.418	0.364	0.175	0.328

Eşik Değer Tablo 5’teki tüm değerlerin ortalaması alınarak elde edilmiştir. Eşik Değer yaklaşık 0,258 olarak kabul edilmiştir.

Adım 4: Gönderici grubu ve alıcı grubu hesaplanması

Toplam ilişki matrisinin oluşturulmasından sonra 5 ve 6 nolu eşitsizlikler yardımıyla kullanılarak D ve R değerleri elde edilmiştir. Ardından kriterler arası ilişkileri gösteren D+R ile kriterlerin daha çok etkileyen mi yoksa etkilenen kriter mi olduğunu açıklayan D-R değerleri hesaplanmıştır. Tablo 6’da yapılan hesaplamalar D+R sütunu incelendiğinde sırasıyla P6, P2 ve P4 kriterlerinin diğer kriterler ile daha çok ilişkide olduğu belirlenmiştir.


Diğer yandan D-R sütunu incelendiğinde hem pozitif hem de negatif değerlerle karşılaşıldığı görülmektedir. Tablo 6’da D-R sütununda negatif değerlere sahip olan P3, P1 ve P4 kriterleri diğer kriterler tarafından etkilenen ya da alıcı kriter olarak isimlendirilmektedir. Bunlar daha düşük önceliğe sahip ve diğer kriterlerden daha çok etkilenen kriterlerdir. Gönderici ya da etkileyici olarak adlandırılan, daha yüksek etkiye ve daha yüksek önceliğe sahip olan pozitif D-R değerlerinde sırasıyla P2, P5 ve P6 kriterlerinin diğer kriterleri etkileyen özellik gösterdiği tespit edilmiştir.

Tablo 6. D+R ve D-R Değerleri

Kriterler	D	R	D + R (Önem)	D – R (Net Etki)	Durum
P1	1,211	1,514	2,725	-0,303	Sonuç
P2	2,054	1,735	3,789	0,319	Neden
P3	1,297	1,649	2,946	-0,352	Sonuç
P4	1,603	1,721	3,324	-0,118	Sonuç
P5	0,949	0,721	1,67	0,228	Neden
P6	2,169	1,945	4,114	0,224	Neden

Adım 5: Etki Yönlü Graf Diyagramının Elde Edilmesi

Aşağıdaki diyagramda X ekseninde D+R Toplam Sistem Etki Gücünü, Y ekseninde D-R ise Nedensellik Yönünü açıklamaktadır. Diyagramın sağ üst bölgesi, sistemde en etkili neden kriterlerini, sol alt bölgesi ise en çok etkilenen sonuç kriterlerini göstermektedir.



Şekil 1. DEMATEL Yöntemi Etki Yönlü Graf Diyagramı

Diyagramın sağ üst bölgesinde yer alan faktörler, sistemde baskın neden rolünü üstlenen ve birçok diğer problemi tetikleyebilecek potansiyele sahip olan unsurlardır. Bu kapsamda Bakım Süreçlerindeki Yetersizlik (P6), yalnızca en yüksek R değeriyle değil, aynı zamanda oldukça güçlü bir D-R pozitifliğiyle öne çıkmaktadır. Bu durum, söz konusu faktörün sistemdeki diğer problemlerin temelinde yer aldığını ve iyileştirme çalışmalarının odak noktasında olması gerektiğini ortaya koymaktadır.

Benzer biçimde, Yüksek Enerji Tüketimi (P2) faktörü de pozitif D-R değeri ve yüksek D+R toplamıyla dikkate değerdir. Bu kriterin etkileyciliği, sadece enerji maliyetlerini artırmakla sınırlı kalmayıp, ekipman ömrü, proses dengesi ve dolaylı olarak bakım gereksinimlerine de katkı sunduğunu göstermektedir.

Ekipmanın Proses Koşullarına Uygun Olmaması (P5), mutlak etki gücü açısından ilk iki faktöre göre daha düşük görünse de, pozitif yönlü D-R değeri onu önemli bir yapısal neden olarak konumlandırmaktadır. Özellikle vibrasyon, motor

zorlanması ve karışım dengesizliği gibi ikincil sorunları tetikleyici rolü dikkat çekicidir.

Nedensellik ekseninde negatif değerlere sahip faktörler, sistemde daha çok dışsal etkilerin sonucu olarak ortaya çıkan ve semptomatik rol oynayan sorunları temsil etmektedir. Bu çerçevede, Motor Arızalarının Sıklığı (P3), Karışımın Homojen Olmaması (P1) ve Vibrasyon Kaynaklı Yapısal Sorunlar (P4), öncelikli nedenlerin sonucu olarak değerlendirilebilir. Bu problemler doğrudan değil, bakım eksiklikleri, uygun olmayan ekipman seçimi veya enerji dengesizlikleri gibi kök nedenlere bağlı olarak gelişmektedir.

5. SONUÇ VE ÖNERİLER

Bu çalışmada, endüstriyel karıştırıcı sistemlerinde gözlemlenen operasyonel sorunların neden-sonuç ilişkileri DEMATEL yöntemi aracılığıyla sistematik biçimde analiz edilmiştir. Analiz süreci boyunca, her bir kriterin hem sistem üzerinde etkileyici gücü (D) hem de dışsal etkilenme düzeyi (R) hesaplanmış ve bu parametreler doğrultusunda öncelikli müdahale gerektiren alanlar belirlenmiştir.

Analiz sonuçlarına göre, Bakım Süreçlerindeki Yetersizlik (P6) kriteri, sistem üzerindeki en belirgin neden faktörü olarak öne çıkmaktadır. Bu kriterin hem yüksek etkileme ($D = 2,169$) hem de yüksek etkilenme ($R = 1,945$) değerlerine sahip olması, sistemdeki çok sayıda problemi tetiklediğini ve aynı zamanda çeşitli dışsal faktörlerden de etkilendiğini göstermektedir. Benzer biçimde, “Yüksek Enerji Tüketimi (P2)” kriteri de yüksek bir toplam sistemsal etkiye ($D+R = 3,789$) sahiptir ve pozitif D-R değeri ($0,319$) sayesinde doğrudan müdahale edilmesi gereken neden konumundaki kriterler arasında yer almaktadır.

Diğer yandan, Motor Arızalarının Sıklığı (P3), Karışımın Homojen Olmaması (P1) ve Vibrasyon Kaynaklı Yapısal Sorunlar (P4) kriterleri negatif D-R değerleri ile sistemin sonuç faktörleri arasında konumlanmaktadır. Bu durum, söz konusu problemlerinin doğrudan neden olmaktan ziyade, sistemdeki diğer eksikliklerden kaynaklandığını ortaya koymaktadır. Örneğin, motor arızaları büyük ölçüde bakım eksiklikleri, dengesiz enerji kullanımı ve vibrasyon gibi nedenlerle ilişkilendirilirken; karışımın homojen olmaması, ekipman uyumsuzluğu ve motor performansı ile doğrudan bağlantılıdır. Ayrıca Ekipmanın Proses Koşullarına Uygun Olmaması (P5) kriteri, düşük R değerine karşın ikinci en yüksek D-R farkına sahip kriter olarak, sistemin güçlü ve bağımsız bir neden faktörü olduğunu göstermektedir. Bu da uygun olmayan ekipman seçiminin sistem genelindeki verimsizlikleri tetikleyici bir unsur olduğunu ortaya koymaktadır.

5.1. Önerilen İyileştirme Adımları

Yukarıda detaylandırılan sonuçlar ışığında önerilen iyileştirme adımları aşağıdaki 5 madde ile özetlenebilmektedir.

1. Bakım sistemleri yeniden yapılandırılmalı; arıza sonrası müdahale yerine kestirimci bakım ve sensör destekli izleme yaklaşımları hayata geçirilmelidir.

2. Enerji yönetimi stratejik düzeye taşınmalı; inverterli motorlar, dijital enerji analizörleri ve gerçek zamanlı izleme çözümleri entegre edilmelidir.

3. Ekipman seçimi proses ihtiyaçlarına uygun yapılmalı; mevcut ekipmanlar teknik açıdan değerlendirilerek gerekli revizyonlar gerçekleştirilmelidir.

4. Vibrasyon kaynaklı yapısal sorunlara karşı statik ve dinamik analizlerle sönümleme sistemleri veya destekleyici çözümler uygulanmalıdır.

5. Motor performansı periyodik olarak izlenmeli; arıza tahmini yapan yazılım sistemleri ile önleyici mühendislik müdahaleleri planlanmalıdır.

DEMATEL yöntemi ile yapılan analiz, karıştırıcı sistemlerinde bulunan teknik problemlerin birbirleriyle olan ilişkilerini görsel ve sayısal olarak ortaya koymuş; bu yapı sayesinde karar vericilerin sistemde öncelikli müdahale etmesi gereken alanları belirlemesini kolaylaştırmıştır. Bu kapsamda önerilen stratejik aksiyonların hayata geçirilmesi, karıştırıcı sistemlerinin genel verimliliğini artıracak, enerji tüketimini azaltacak ve operasyonel performansı sürdürülebilir şekilde iyileştirecektir.

KAYNAKÇA

- Armenante, P. M., & Nagamine, E. U. (1998). Power consumption and liquid velocity distributions in stirred tanks. *Industrial & Engineering Chemistry Research*.
- Büyüközkan, G., & Çifçi, G. (2012). A novel hybrid MCDM approach based on fuzzy DEMATEL, fuzzy ANP and fuzzy TOPSIS to evaluate green suppliers. *Expert Systems with Applications*, 39(3), 3000-3011.
- Cheshmberah, M., Naderizadeh, A., Shafaghat, A., & Nokabadi, M. K. (2020). An integrated process model for root cause failure analysis based on reality charting, FMEA and DEMATEL. *Int. J. Data Netw. Sci*, 4(2), 225-236.
- Doran, P. M. (2013). *Bioprocess engineering principles*. Academic press.
- Gao, S., Li, J., & Bai, Y. (2020). Influence of solid particle size and distribution on suspension characteristics in a stirred tank. *Chemical Engineering Research and Design*.
- Ibrahim, A., Gimbut, J., & Ahmad, M. (2021). CFD simulation of industrial mixing tanks. *Journal of Applied Fluid Mechanics*.
- Jaworski, Z., Nienow, A. W., & Brucato, A. (2019). Computational modelling of mixing. *Chemical Engineering Science*.
- Keshavarz Ghorabae, M., Amiri, M., Zavadskas, E. K., & Antucheviciene, J. (2017). Supplier evaluation and selection in fuzzy environments: a review of MADM approaches. *Economic research-Ekonomska istraživanja*, 30(1), 1073-1118.

- Kim, H. K., Park, J. Y., & Lee, C. Y. (2021). Optical monitoring of mixing uniformity using machine vision. *Sensors and Actuators B: Chemical*.
- Lin, Y.-T., Yang, C.-H., & Pai, F.-Y. (2011). IC design services evaluation using DEMATEL. *Expert Systems with Applications*.
- Mohagheghi, V., Bakhsha, A., & Noorpoor, A. (2020). Energy management using DEMATEL and AHP. *Renewable Energy*.
- Müller, R., Schmitt, R., & Weiss, S. (2022). Maintenance strategies and reliability analysis of industrial agitators. *Journal of Manufacturing Science and Engineering*.
- Ochieng, A., & Lewis, M. J. (2006). Mixing of viscous fluids. *Chemical Engineering Science*.
- Paul, E. L., Atiemo-Obeng, V. A., & Kresta, S. M. (2004). Handbook of industrial mixing: science and practice. Wiley-Interscience.
- Rahimi, M., Ghaffari, M., & Ghaemi, M. (2018). Experimental study on impeller performance in viscous fluids. *Journal of Fluids Engineering*.
- Tatterson, G. B. (1991). Fluid mixing and gas dispersion in agitated tanks. McGraw-Hill.
- Tsai, W.H. & Chou, W.C. (2009). Selecting Management Systems For Sustainable Development in SMEs: A Novel Hybrid Model Based On DEMATEL, ANP, and ZOGP. *Expert Systems with Applications*, 36(2): 1444-1458.
- 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.

- Wang, L., Zhang, Y., & Liu, H. (2022). IoT-based predictive maintenance for mixing equipment. *IEEE Transactions on Industrial Informatics*.
- Weheliye, W. H., Kamal, R., & Nienow, A. W. (2020). Optimizing impeller design using CFD. *Chemical Engineering Journal*.
- Wu, H.-H., & Chang, S.-Y. (2015). Green supply chain management using DEMATEL. *Applied Mathematics and Computation*.
- Wu, W.W. ve Lee, Y.T. (2007). Developing Global Managers' Competencies Using The Fuzzy DEMATEL Method, *Expert Systems with Applications*, 32(2): 499507.
- Vujanović, N., Radošević, S., Stojčić, N., Hisarciklilar, M., & Hashi, I. (2022). FDI spillover effects on innovation activities of knowledge using and knowledge creating firms: Evidence from an emerging economy. *Technovation*, 118, 102512.
- Yılmaz, I., Demirtaş, B., & Çakar, S. (2023). A fuzzy DEMATEL framework for maintenance performance improvement. *Journal of Engineering Research*.

EVALUATION OF CRITICAL SUCCESS FACTORS FOR DIGITAL TWIN APPLICABILITY IN THE TEXTILE INDUSTRY: SWARA AND BWM APPROACHES

Özlem SÖKMEN¹

1. INTRODUCTION

In recent years, production logic and competitive conditions have changed in many manufacturing sectors, especially the textile industry. Shorter order cycles, increasing cost pressures, and the demand for error-free products in a faster time frame make it difficult for businesses to proceed solely with experience-based decisions. In this context, the digital twin concept, which has attracted attention in recent years, offers the possibility of preventing problems before they occur by creating a copy of physical processes in a computer environment. A digital twin is more than just a simple screen image or data archive; it's a system that updates itself with real-time information flow and monitors numerous parameters, from machine speed to energy consumption. The ability to instantly monitor real machine behavior in a computer environment makes it easier for businesses to detect errors and prevent them before they occur. Therefore, the applicability of digital twin technology, which offers businesses prediction, simulation, and optimization capabilities, is quite significant in the textile sector, where product variety, production speed, and quality expectations are high. However, many factors play a role in integrating a digital

¹ Asst. Prof. Dr., Erzurum Technical University, Faculty of Engineering and Architecture, Department of Industrial Engineering, ORCID: 0000-0001-8765-0038.

twin into the system, such as the support of top management, the maturity of the infrastructure, and the organization's openness to change. Therefore, this study examines various criteria to measure the applicability of digital twin technology in textile businesses. To determine which of these factors is more dominant and to provide decision support to firms, two different Multi Criteria Decision Making (MCDM) approaches, BWM and SWARA, were evaluated together, and the criterion weights were systematically calculated. The results are expected to provide a roadmap for businesses planning digital transformation in the textile sector.

2. DIGITAL TWIN

Digital twin is a strategic technology shaped by the advanced technologies offered by digital transformation; it has the potential to increase operational efficiency, agility, and sustainability in manufacturing (Özgüner & Ovalı, 2023). Essentially, a digital twin is a live digital linking of the state of physical entities or processes to a virtual representation that delivers functional output (Catapult, 2021). This technology refers to the creation of smart manufacturing systems that enable the sustainable production of high-quality, personalized products by leveraging real-time data collected throughout the product's lifecycle (Özgüner & Ovalı, 2023). Digital twins are among the central technologies of Industry 4.0 and are considered one of the most critical steps enabling the applicability of cyber-physical systems (Zhuang et al., 2018).

The concept of a digital twin, derived from NASA's mirroring-focused technological applications, was first clearly defined in the literature by Grieves in his 2003 work within the framework of Product Lifecycle Management (PLM) (Grieves, 2014). In general, a digital twin is a virtual copy of a product that

exhibits its behavior in the real physical world (Tao & Zhang, 2017). It also provides an interface that enables predictions about the future with data representing the structure, context, and behavior of the physical system, and acts as a bridge between the physical and digital worlds (Khajavi et al., 2019).

A general digital twin model for a product consists of three main components: physical entities in the physical realm, virtual models in the virtual realm, and connected data linking these two worlds (Tao & Qi 2019; Koçak & Yıldız, 2022). Data forms the basis of the digital twin; this data is collected and transmitted in near real-time using tools such as sensors, displays, RFID tags, readers, cameras, and scanners (Liu et al., 2021; AbdelAziz et al., 2025). Digital twins, a critical technology in the transition to Industry 5.0, help industrial manufacturing reduce costs and become more efficient by providing improvements in equipment intelligence, real-time process analysis, and automated fault detection (Lv, 2023). Key benefits of digital twins include reducing costs and risks, increasing productivity, and ensuring safety (Pan & Zhang, 2021).

Current studies on digital twins offer comprehensive solutions on how the technology is used in production, logistics, and organizational transformation processes. In a study conducted by Um et al. (2017), a digital twin-based universal data model was developed to support the plug-and-play approach in modular and multi-vendor assembly lines. Zhuang et al. (2018) presented a digital twin-based intelligent control and management method for more efficient management of complex product assembly processes. Mukherjee and DebRoy (2019) developed a digital twin model for three-dimensional printing machines and conducted a study on monitoring and analyzing the system in a virtual environment. In their study, Ku et al. (2020) aimed to minimize queue-dependent setup times and eliminate information silos between different information systems in textile dyeing

operations using digital twin-based decision support systems. Yi et al. (2021) presented a digital twin-based reference model for the design of intelligent assembly processes and proposed a three-layer digital twin-based intelligent assembly architecture. Digital twin research has focused particularly on developing real-time production scheduling models in mass manufacturing systems, taking into account parameters such as raw material stocks, downtimes, and shift changes (Bal et al., 2022). These models have provided significant improvements in production time and machine utilization rates compared to manual methods. In the study conducted by Koçak and Yıldız (2022), a digital twin infrastructure was created in the ready-to-wear sector by collecting data through process mapping and sensors/interfaces, and product completion time was successfully predicted using algorithms such as random forest regression. In the study conducted by Cesur et al. (2023), machine learning methods such as artificial neural networks (ANNs) were used to estimate the completion times of G-Code instructions on CNC machines in order to optimize precise instruction times in production. Digital twins, on the other hand, have frequently been used in studies for maintenance, risk estimation, and organizational strategies. In this context, one of the most prioritized Industry 4.0 applications for the textile sector is early detection of failures using digital twins (Nebati, 2024). In the fields of predictive maintenance and failure analysis (Calayır & Kabak, 2021; Kulluk et al., 2024), studies have been conducted to predict remaining useful life and failure times using machine learning algorithms such as Hybrid ARIMA-ANN (Kaynak, 2022) and XGBoost/Decision Tree (Pirge & Baştürk, 2025). Priyanka et al. (2022) aimed to develop a digital twin framework based on machine learning and prognostic algorithms for the analysis and estimation of risk ratios in oil pipelines. Studies on organizational success have identified "support from top management" and "sufficient financial resources" as the most important critical success factors in the

effective use of digital twin technology (Özgüner & Ovalı, 2023). On the other hand, the biggest obstacle to digital twin applications has been determined to be "lack of systemic and technological integration" (Aka, 2025). In the supply chain, digital twins create virtual models of physical assets, offering scenario planning, real-time simulation, and optimization capabilities (Nabeeh et al., 2022), thereby aiming to reduce supply risks and increase traceability (Hezam et al., 2024). To ensure reliable and valid results from digital twins, integration models that enable bidirectional, real-time data exchange between physical and digital systems are being developed, referencing standards such as ISO 23247, as seen in robotic arm applications (Engin et al., 2025). By merging the virtual and physical environments, the digital twin provides significant support to decision-makers in making strategic and operational decisions.

A review of the relevant literature reveals that digital twin applications have been addressed in various sectors, focusing on areas such as supply chain integration, maintenance and risk management, and production scheduling. These studies emphasize that digital twins enhance efficiency, process visibility, and decision support capabilities. However, especially in the textile sector, where high speed, low cost, and impeccable quality are paramount, the successful implementation of digital twin technology depends on accurately assessing businesses' existing technical infrastructure, data maturity, and organizational readiness. Therefore, it is critical for businesses to conduct a feasibility analysis tailored to their specific conditions before transitioning to digital twin technology. This study utilized two different multi-criteria decision-making (MCDM) methods, SWARA and BWM, to determine the importance levels of key criteria that textile companies should consider before implementing digital twin applications. The criteria, identified through literature review and expert opinions, were evaluated by

consulting textile and industrial engineers working at a corporate textile firm and by having them complete prepared forms. The evaluation model developed within the scope of this study provides a systematic framework for assessing the maturity of digital twin applications in the textile sector and offers a holistic roadmap for businesses to prioritize in the technology transition process.

3. METHOD

Multi Criteria Decision Making (MCDM) methods are popular tools used to effectively and quickly resolve complex and poorly structured evaluation problems involving multiple conflicting goals or criteria in decision-making processes (Nila & Roy, 2023). These methods are a collection of techniques used to determine qualitative and quantitative criteria, evaluate, rank, and classify options (Özbek, 2019; Yenilmezel & Ertuğrul, 2022). In MCDM, criterion weights can be determined using subjective methods based on the judgments of decision-makers (Ecer, 2020). In this study, SWARA and BWM MCDM methods were used together to determine the relative importance of the criteria affecting the applicability of digital twin technology in the textile sector. While the SWARA method gathers the prioritization of expert opinions in a more flexible and intuitive framework, the BWM approach transforms these priorities into mathematically more consistent weights. The combined use of these two methods ensures that criterion weights are obtained in a way that is both based on expert evaluations and has high numerical consistency. This allows for a more accurate modeling of uncertainties frequently encountered in the textile industry, as well as differences in expert assessments.

3.1. SWARA Method

SWARA (Step-wise Weight Assessment Ratio Analysis) was introduced to the literature in 2010 by Keršulienė et al. and is a subjective MCDM method used to determine criterion weights (Keršulienė et al., 2010). SWARA is an expert-oriented method and helps decision-makers determine their priorities (Zolfani et al., 2015; Shukla et al., 2016; Sivaslıoğlu, 2024). The steps of the method can be listed as follows (Radović & Stević, 2018):

Step 1: Experts rank the criteria to be used in the study from most important to least important according to their relative importance. This ranking forms the basis for subsequent calculations.

Step 2: Starting with the second criterion, the extent to which each criterion is more important than the next criterion is determined. As a result of this comparison, the comparative importance value (s_j) for the relevant criterion is obtained.

Step 3: The coefficient (k_j) is calculated taking into account the comparative importance. For the first criterion, the coefficient is fixed at 1; for the other criteria, the coefficient is determined according to the comparative importance value using Equation (1):

$$k_j = \begin{cases} 1, & j = 1 \\ s_j + 1, & j > 1 \end{cases} \quad (1)$$

Step 4: Calculate the rescaled weight value (q_j) for each criterion. The value for the first criterion is 1. For the other criteria, the ratio given by Equation (2) is used, taking into account the coefficient of the previous criterion:

$$q_j = \begin{cases} 1, & j = 1 \\ \frac{k_{j-1}}{k_j}, & j > 1 \end{cases} \quad (2)$$

Step 5: Finally, all the obtained (q_j) values are normalized to determine the final weights of the criteria. Normalization is done using Equation (3):

$$w_j = \frac{q_j}{\sum_{k=1}^m q_j} \quad (3)$$

3.2. BWM Method

The Best Worst Method (BWM) is a MCDM method proposed by Rezaei in 2015 that relies on pairwise comparisons to determine criterion weights (Rezaei, 2015). BWM is a vector-based method (Mou et al., 2016). BWM reduces the number of pairwise comparisons required to determine criterion weights, which helps reduce the burden on decision-makers. The application steps required to assign weights to criteria using this method can be listed as follows: (Rezaei, 2015):

Step 1: The set of criteria to be used in the decision problem is determined.

Step 2: The best (B) (most important, most preferred, etc.) and worst (W) (least important, least preferred, etc.) criteria are determined by the decision-makers.

Step 3: The preference levels of the best criterion compared to all other criteria are determined using a scale from 1 to 9 (Table 1). The resulting Best-Others (BO) vector, which includes the importance of the best criterion compared to others, should be as in Equation (4):

$$A_B = (a_{B1}, a_{B2}, \dots, a_{Bn}) \quad (4)$$

Here, a_{Bj} shows how important the most important criterion b is compared to the j . criterion, and $a_{BB} = 1$.

Step 4: In this step, the importance of all the criteria compared to the criterion determined as having the least importance is determined using the scale presented in Table 1. As

a result, the Other-to-Worst (OW) vector, which includes the dominance of the other criteria over the worst criterion, should be like Equation (5):

$$A_W = (a_{1W}, a_{2W}, \dots, a_{nW}) \quad (5)$$

Here, a_{jW} represents the degree to which criterion j is preferred over w , which is the least important criterion, and $a_{WW} = 1$.

Table 1. 1–9 Saaty Scale of Importance Intensities (Demir & Bircan, 2020; Nebati, 2024;)

Importance	Intensity Definition
1	Equally important
2	Moderately important
3	Moderately more important
4	Moderately much more important
5	Strongly important
6	Strongly very important
7	Very strongly important
8	Very strongly important
9	Very strongly more important

Step 5: In this step, the aim is to minimize the maximum of the absolute deviations of the comparisons calculated for all criteria ($Min - Max$). Accordingly, an optimization problem is defined that minimizes the maximum value of the expressions $|w_B - a_{Bj} w_j|$ obtained from the comparisons with the best criterion (B) and $|w_j - a_{jW} w_W|$ obtained from the comparisons with the worst criterion (W) for each criterion (Equations (6–8)).

$$\min \max_j \{|w_B - a_{Bj} w_j| \text{ and } |w_j - a_{jW} w_W|\} \quad (6)$$

$$\sum_j w_j = 1 \quad (7)$$

$$w_j \geq 0 \quad (j = 1, 2, \dots, n) \quad (8)$$

As given in Equation (9–13), this min-max structure problem is transformed into a linear programming model in order

to obtain the solution, and the optimal weights of the criteria are calculated in line with the results obtained from the model. The ε^* obtained from the solution of this model represents the consistency in the evaluations of the decision-makers and is used as the basic input in the calculation of the Consistency Ratio (*CR*).

$$\min \varepsilon \quad (9)$$

$$|w_B - a_{Bj}w_j| \leq \varepsilon \quad (j=1,2,\dots,n) \quad (10)$$

$$|w_j - a_{jw}w_w| \leq \varepsilon \quad (j=1,2,\dots,n) \quad (11)$$

$$\sum_j w_j = 1 \quad (12)$$

$$w_j \geq 0 \quad (j = 1,2,\dots,n) \quad (13)$$

Solving this model yields the optimal weights and the ε^* value.

Step 6: Finally, the consistency ratio of the obtained weights is calculated. For the comparison to be consistent, the equality $a_{Bj} * a_{jw} = a_{BW}$ must be satisfied for all criteria. a_{Bj} , a_{jw} , and a_{BW} respectively represent the superiority of the best criterion over criterion j , the superiority of criterion j over the worst criterion, and the superiority of the best criterion over the worst criterion. The consistency ratio is calculated using Equation (14):

$$CR = \frac{\varepsilon^*}{CI} \quad (14)$$

Here, *CR* is in the range of [0,1], and a lower ratio indicates that the comparisons are consistent. Consistency index (*CI*) values are given in Table 2.

Table 2. Consistency index values

a_{BW}	1	2	3	4	5	6	7	8	9
<i>CI</i>	0.00	0.44	1.00	1.63	2.30	3.00	3.73	4.47	5.23

4. APPLICATION

This study aims to determine the importance levels of factors affecting the applicability of digital twin technology in textile companies and to provide a guiding evaluation framework for companies in their decision-making process. Accordingly, the technical, organizational, and managerial criteria playing a role in the integration of digital twins into production systems were examined, and the relative weights of these criteria were calculated using MCDM methods.

4.1. Creating the Criteria Set

The criteria for this study were determined by considering the relevant literature in the field of digital twins and Industry 4.0, as well as the opinions of experts with experience in the textile sector. Furthermore, Industry 4.0 maturity models, digital twin application requirements, and cyber-physical system infrastructures were examined; and a pool of criteria was created by combining these with the specific requirements of the textile sector. This pool of criteria was simplified based on expert opinions, and key criteria directly affecting the applicability of the digital twin were selected. The 10 criteria used in the study and their short names are given in Table 3; the criterion descriptions are given in Table 4.

Table 3. Criteria used in the study

Criterion Code	Criterion Name	Criterion Short Name
K1	Strategic alignment and top management support	Strategic alignment
K2	Internal policy, process and information sharing	Internal structure and processes
K3	Technological competence of the workforce	Technical competence
K4	Technological infrastructure and integration	Technology infrastructure
K5	Cloud and computing capacity	Cloud capacity
K6	Data management, security and privacy	Data security
K7	Artificial intelligence and analytical maturity	Analytical maturity
K8	Sufficiency of financial resources	Financial resources
K9	Operator competence and ergonomic adaptation	Operator maturity
K10	Level of digitalization in supply chain and logistics	Supply digitalization

Table 4. Criterion descriptions

Criterion Code	Explanation
K1	The vision of senior management, their level of ownership of the project, and their willingness to allocate resources.
K2	Standardization of business processes, interdepartmental coordination, and a culture of information sharing.
K3	The staff's level of technical knowledge, digital literacy, and data-driven work skills..
K4	Integration capability for real-time data transfer between sensors, machines, and IT systems.
K5	Sufficient technical equipment to perform simulations and analyses requiring high processing power.
K6	Continuity and accuracy of data flow, cybersecurity measures, and privacy protocols.
K7	Transforming data into decision support mechanisms through machine learning and predictive analytics.
K8	The capacity to cover technology, software, and training costs, and to sustain the project in the long term.
K9	Operator adaptation to the system and user-friendly design of human-machine interaction.
K10	Digital integration of material flow and logistics processes ensures end-to-end traceability.

After the criteria were determined, forms were created to match the methods, and face-to-face interviews were conducted with an industrial engineer and two textile engineers working at a corporate textile company to increase the reliability of the decision-making process and reflect different perspectives. Based on their experience in production processes and quality management, the experts evaluated the criteria and ranked them in order of importance. Literature shows that using multiple MCDM methods together in solving similar problems strengthens the consistency of decisions. Accordingly, this study did not rely on a single method; data obtained from expert opinions were analyzed using different methods to determine criterion weights on a more solid foundation. Thus, the evaluation process gained a systematic structure, and the decisions became more explainable and consistent.

4.2. Determination of Criteria Importance Weights Using the SWARA Method

In this study, the SWARA method was applied to evaluate the applicability of digital twin technology, based on the scores given by decision-makers consulted regarding the specified criteria. In the first stage, the selected criteria were evaluated for one decision-maker (DM1) using the SWARA method, and the s_j , k_j , q_j , and w_j values were calculated respectively within the scope of the analysis process. The results of this stage are presented in Table 5 to illustrate the method's operation. Then, the SWARA method was applied separately for each decision-maker, and the criterion weights were calculated. To reflect the decision-makers' evaluations holistically, the arithmetic mean of the obtained weights was taken to determine the final criterion weights, which are presented in Table 6. During the analysis process, decision-makers were coded as DM1, DM2, and DM3.

Table 5. Weights of decision criteria for DM1

Crit. Short Name	Priority	Ranked Crit.	Rank	s_j	k_j	q_j	w_j
Strategic alignment (K1)	1	K1	1		1	1	0.247
Internal structure and processes (K2)	6	K4	2	0.25	1.25	0.8	0.198
Technical competence (K3)	5	K6	3	0.2	1.2	0.667	0.165
Technology infrastructure (K4)	2	K7	4	0.3	1.3	0.512	0.127
Cloud capacity (K5)	7	K3	5	0.4	1.4	0.366	0.091
Data security (K6)	3	K2	6	0.35	1.35	0.271	0.067
Analytical maturity (K7)	4	K5	7	0.5	1.5	0.181	0.045
Financial resources (K8)	10	K10	8	0.45	1.45	0.125	0.031
Operator maturity (K9)	9	K9	9	0.6	1.6	0.078	0.019
Supply digitalization (K10)	8	K8	10	0.7	1.7	0.046	0.011

Table 6. Final criterion weights according to multiple decision-maker evaluations

No	Crit. Code	Crit. Short Name	DM1 Weight	DM2 Weight	DM3 Weight	Final Weight
1	K4	Technology infrastructure	0.198	0.246	0.133	0.192
2	K6	Data security	0.165	0.214	0.153	0.177
3	K1	Strategic alignment	0.247	0.117	0.161	0.175
4	K7	Analytical maturity	0.127	0.164	0.121	0.137
5	K3	Technical competence	0.091	0.067	0.101	0.086
6	K2	Internal structure and processes	0.067	0.090	0.096	0.084
7	K5	Cloud capacity	0.045	0.029	0.074	0.049
8	K10	Supply digitalization	0.031	0.045	0.054	0.043
9	K8	Financial resources	0.011	0.011	0.067	0.030
10	K9	Operator maturity	0.019	0.018	0.040	0.026

Table 6 presents the final criterion weights calculated using the SWARA method based on the decision-makers' evaluations. Examination of the findings reveals that the Technological infrastructure and integration (K4) criterion has the highest weight. This indicates that a robust hardware, software, and system integration infrastructure is a fundamental requirement for the effective implementation of digital twin technology. The high weighting of Data management, security, and privacy (K6) and Strategic alignment and top management support (K1) criteria reveals that digital twin applications represent not only a technical but also a strategic and managerial transformation process. When other criteria are examined, AI and analytical maturity (K7) and Technological competence of the workforce (K3) are of moderate importance, while Sufficiency of

financial resources (K8) and Operator competence and ergonomic adaptation (K9) have relatively lower weights. These results indicate that in twin applications, priority is given to fundamental readiness elements such as infrastructure, data, and strategic alignment, rather than directly to financial factors. The criterion weights obtained using the SWARA method are graphically shown in Figure 1 to more clearly illustrate the relative importance levels between the criteria.




Figure 1. Distribution of final criterion weights obtained using the SWARA method.

4.3. Determination of Criteria Importance Weights Using the BWM Method

At this stage, the BWM method was applied to evaluate the applicability of digital twin technology in textile businesses. First, each decision-maker was asked to select the best (most important) and worst (least important) criteria from among the defined criteria. The best and worst criterion selections for each decision-maker are presented in Table 7.

Table 7. Best and worst criteria

	DM1	DM2	DM3
Best Criterion	K1	K4	K1
Worst Criterion	K8	K8	K9

After determining the best and worst criteria, decision-makers were asked to make comparisons expressing the relative importance levels of the best criterion compared to the other criteria, and of the other criteria compared to the worst criterion. The scale commonly used in the literature and given in Table 1 was used to score the pairwise comparisons. The resulting comparisons formed the basic inputs of the BWM method. To determine the optimal weights of the criteria, a linear programming model was created that minimizes the maximum of the differences $|w_B - a_{Bj} w_j|$ and $|w_j - a_{jw} w_w|$. To determine the weights of the factors, 10 criteria were used and 17 comparisons were made from $(2n - 3)$, each of which was included in the model as a linear programming constraint. This model was solved using the Python programming language; the consistency of the obtained results was analyzed through the ε^* values. To illustrate the operation of the method in detail, calculations were first performed for a decision maker (DM1), and the findings for this stage are presented in Table 8.

Table 8. Findings of the BWM method for DM1

Crit. Code	Best-to-Others (K1)	Others-to-Worst (K8)	Weight
K1	1	9	0.365
K4	4	8	0.120
K6	5	7	0.096
K7	6	7	0.080
K3	7	6	0.069
K2	7	5	0.069
K5	8	4	0.060
K10	8	3	0.060
K9	9	2	0.053
K8	9	1	0.028

The same analysis process was then repeated for the other decision-makers (DM2 and DM3) to obtain individual weight values for each expert. After calculating the weights for all decision-makers, a consistency analysis was performed to confirm the reliability of these evaluations. The error margins ε^* and the associated consistency ratios (CR) obtained from the analysis are presented in Table 9.

Table 9. Consistency Ratios

Parameters	DM1	DM2	DM3
Margin of Error ε^*	0.115	0.076	0.082
Consistency Index (CI)	5.23	5.23	5.23
Consistency Ratio (CR)	0.022	0.015	0.016

Table 9 shows that the consistency ratios of all decision-makers are below the reference value of 0.10. This confirms that the expert evaluations are consistent and that the weights obtained are reliable.

In the next stage, in order to holistically reflect the decision-makers' evaluations, the final BWM criterion weights were determined by taking the arithmetic mean of the weights obtained for each criterion. The final results for multiple decision-makers are presented in Table 10.

Table 10. Final criterion weights

No	Crit. Code	Crit. Short Name	DM1 Weight	DM2 Weight	DM3 Weight	Final Weight
1	K1	Strategic alignment	0.365	0.089	0.279	0.245
2	K4	Technology infrastructure	0.120	0.280	0.090	0.163
3	K6	Data security	0.096	0.178	0.181	0.152
4	K7	Analytical maturity	0.080	0.119	0.072	0.090
5	K8	Financial resources	0.028	0.023	0.120	0.057
6	K3	Technical competence	0.069	0.059	0.072	0.067
7	K10	Supply digitalization	0.060	0.071	0.052	0.061
8	K2	Internal structure and processes	0.069	0.071	0.060	0.067
9	K5	Cloud capacity	0.060	0.059	0.052	0.057
10	K9	Operator maturity	0.053	0.051	0.022	0.042

Examining the final weighting values presented in Table 10, it was determined that, according to the decision-makers' evaluations using the BWM method, the most important criterion for the applicability of digital twin technology in textile businesses is Strategic alignment and top management support (K1) with a weighting score of 0.245. This is followed by Technological infrastructure and integration (K4) and Data management, security and privacy (K6) criteria, respectively. The results show that businesses should primarily focus on strategic alignment in their digital twin transformation. On the other hand, Operator competence and ergonomic adaptation (K9) criterion was determined as the criterion with the lowest weight. In order to more clearly show the relative importance levels between the criteria according to the results obtained from the BWM method, it is shown graphically in Figure 2.




Figure 2. Distribution of final criterion weights obtained using the BWM method

5. CONCLUSION AND RECOMMENDATIONS

This study evaluates the factors affecting the applicability of digital twin technology in the textile industry using SWARA and BWM methods, based on expert opinions. The aim is to identify which criteria are more decisive for businesses considering digital twin investments. Examining the results obtained using the SWARA method reveals that technological infrastructure and integration, data management, security and confidentiality, strategic alignment, and top management support are more prominent criteria compared to others. This situation shows that the successful implementation of a digital twin requires not only technological tools but also a management approach that embraces this transformation. The high ranking of criteria such as data management, security, and privacy, as well as artificial intelligence and analytical maturity, reveals that the digital twin is being considered not just as a monitoring system, but as a system that provides decision support and prediction. The BWM method results present a similar picture. Although decision-makers may have some differences in their preferences for best and worst criteria, a final weighting reveals that strategic alignment and top management support, technological infrastructure and integration, and data management, security, and privacy still stand out. This indicates that despite differences in opinion among decision-makers, a common perspective has emerged regarding the fundamental elements that determine the feasibility of a digital twin. When both methods are considered together, it can be said that success in digital twin applications is largely related to strategic preparation, a strong technological infrastructure, and data-driven decision-making capabilities. Although the rankings shift depending on the method, the results of both methods show that these three criteria have the highest weights. While the SWARA method reflects the intuitive assessments of experts, the BWM method has transformed these

assessments into a more consistent and mathematical structure. Furthermore, the consistency rates of decision-makers in the BWM method were calculated, and the comparison was found to be consistent. The observed similarity between the methods increases the reliability of the findings.

Based on the results obtained, some recommendations can be offered to businesses planning to implement digital twin applications in the textile sector. First, digital twin projects should not be viewed solely as a technical investment; they should be treated as a long-term transformation process embraced by senior management. Furthermore, it will be difficult to reap the expected benefits from the digital twin without strengthening data infrastructure, cybersecurity, and analytical capacity. Finally, improving employees' technical skills and aligning organizational processes with digital transformation will directly impact the success of such investments. This study, focusing on the textile sector, examines the applicability of digital twins using MCDM approaches and provides a guiding assessment for businesses. In future studies, similar analyses can be conducted for different sectors, or more comprehensive results can be obtained by increasing the number of decision-makers. Furthermore, the obtained criterion weights can be used within the framework of integrating different MCDM methods (e.g., FUCOM-TOPSIS, BWM-VIKOR) or by applying fuzzy logic-based extensions of these methods, to conduct studies evaluating the performance of alternative digital twin projects or companies in different sectors.

REFERENCES

- AbdelAziz, N. M., & Soliman, H. (2025). A multi-criteria decision-making framework for evaluating emerging digital technologies in supply chain optimization. *Neutrosophic Sets and Systems*, 87, 379-433.
- Aka, S. (2025). Üretim sistemlerinde dijital ikiz kullanımına yönelik bariyer analizi. *Uluslararası Ekonomi İşletme ve Politika Dergisi*, 9(1), 247-261.
- Bal, A., Gevrek, H., & Demir, S. (2022). Kitlemel imalat sistemlerinde dijital ikiz kullanılarak gerek zamanlı üretim izelgeleme ve tekstil sektrnde bir uygulama. *International Journal of Advances in Engineering and Pure Sciences*, 34(2), 328-336.
- Calayır, G. N., & Kabak, M. (2021). Bakım iin makine ğrenme tekniklerinin analizi ve bir uygulama. *Journal of Turkish Operations Management*, 5(1), 662-675.
- Catapult, H. V. (2021). Untangling the requirements of a digital twin. *University of Sheffield Advanced Manufacturing Research Centre (AMRC)*, 7.
- Cesur, E., Cesur, R., & Aydoğın, B. N. (2023). Cnc tezgahlarının dijital ikiz modeli ile komut tamamlanma srelerinin tahmin edilmesi. *International Journal of 3D Printing Technologies and Digital Industry*, 7(2), 303-321.
- Demir, G., & Bircan, H. (2020). Kriter ağırlıklandırma yöntemlerinden BWM ve FUCOM yöntemlerinin karşılaştırılması ve bir uygulama. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 21(2), 170-185.
- Ecer, F. (2020). *ok kriterli karar verme gemişten günümüze kapsamlı bir yaklaşım* (1st ed.). Ankara, Turkey: Seçkin Yayıncılık.

- Engin, O., Yaşa, E., & Çakırköy, F. (2025). Üretimde dijital ikizlerin kullanımı: ISO 23247 standardı. *Bartın University International Journal of Natural and Applied Sciences*, 8(1), 157-177.
- Grieves, M. (2014). Digital twin: manufacturing excellence through virtual factory replication. *White paper*, 1, 1-7.
- Hezam, I. M., Ali, A. M., Sallam, K., Hameed, I. A., & Abdel-Basset, M. (2024). Digital twin and fuzzy framework for supply chain sustainability risk assessment and management in supplier selection. *Scientific Reports*, 14(1), 17718.
- Kaynak, G. (2022). *Kestirimci bakım planlamasi için zaman serisi modellerine dayali ariza zamani tahmini* (Master's thesis). Necmettin Erbakan University, Konya, Turkey.
- Keršulienė, V., Zavadskas, E. K., & 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.
- Khajavi, S. H., Motlagh, N. H., Jaribion, A., Werner, L. C., & Holmström, J. (2019). Digital twin: vision, benefits, boundaries, and creation for buildings. *IEEE Access*, 7, 147406-147419.
- Koçak, A., & Yıldız, A. (2022). Üretim planlama ve kontrol süreçlerinde dijital ikiz teknolojisinin kullanılması: Tekstil sektöründe bir uygulama. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 10(4), 711-732.
- Ku, C. C., Chien, C. F., & Ma, K. T. (2020). Digital transformation to empower smart production for Industry

- 3.5 and an empirical study for textile dyeing. *Computers & Industrial Engineering*, 142, 106297.
- Kulluk, S., Torun, H., Ay, M. M., & Akargöl, İ. (2024). *Kestirimci bakımda makine öğrenmesi: Sayısal bir vaka çalışması*. Sivas II. International Conference on Scientific and Innovation Research.
- Liu, Z., Chen, W., Zhang, C., Yang, C., & Cheng, Q. (2021). Intelligent scheduling of a feature-process machine tool supernetwork based on digital twin workshop. *Journal of Manufacturing Systems*, 58, 157-167.
- Lv, Z. (2023). Digital twins in Industry 5.0. *Research*, 6, 0071.
- Mou, Q., Xu, Z., & Liao, H. (2016). An intuitionistic fuzzy multiplicative best-worst method for multi-criteria group decision making. *Information Sciences*, 374, 224–239.
- Mukherjee, T., & DebRoy, T. (2019). A digital twin for rapid qualification of 3D printed metallic components. *Applied Materials Today*, 14, 59-65.
- Nabeeh, N. A., Abdel-Basset, M., Gamal, A., & Chang, V. (2022). Evaluation of production of digital twins based on blockchain technology. *Electronics*, 11(8), 1268.
- Nebati, E. E. (2024). Tekstil sektöründe Endüstri 4.0 perspektifinde dijital teknoloji uygulamalarının değerlendirilmesi. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 25(3), 417-429.
- Nila, B., & Roy, J. (2023). A new hybrid MCDM framework for third-party logistics provider selection under sustainability perspectives. *Expert Systems with Applications*, 234, 121009.

- Özbek, A. (2019). *Çok kriterli karar verme yöntemleri ve Excel ile problem çözümü* (2. baskı). Ankara, Turkey: Seçkin Yayıncılık.
- Özgüner, M., & Ovalı, E. (2023). Dijital ikiz teknolojisinin imalat sektöründe kullanımı noktasında kritik öneme sahip başarı faktörlerinin SWARA yöntemiyle değerlendirilmesi. *Doğuş Üniversitesi Dergisi*, 24(1), 449-462.
- Pan, Y., & Zhang, L. (2021). A BIM-Data mining integrated digital twin framework for advanced project management. *Automation in Construction*, 124, 103564.
- Pirge, İ. G., & Baştürk, İ. (2025). Endüstriyel tesislerde makine öğrenmesi ile kestirimci bakım ve arıza analizleri. *Karaelmas Fen ve Mühendislik Dergisi*, 15(1), 119-133.
- Priyanka, E. B., Thangavel, S., Gao, X. Z., & Sivakumar, N. S. (2022). Digital twin for oil pipeline risk estimation using prognostic and machine learning techniques. *Journal of Industrial Information Integration*, 26, 100272.
- Radovic, D., & Stevic, Z. (2018). Evaluation and selection of KPI in transport using SWARA method. *Transport & Logistics: The International Journal*, 18(44), 60-68.
- Rezaei, J. (2015). Best-worst multi-criteria decision-making method. *Omega*, 53, 49-57.
- Shukla, S., Mishra, P. K., Jain, R., & Yadav, H. C. (2016). An integrated decision making approach for ERP system selection using SWARA and PROMETHEE method. *International Journal of Intelligent Enterprise*, 3(2), 120-147.
- Sivaslıoğlu, F. (2024). Kuruluş yeri seçiminde kriterlerin önem ağırlıklarının SWARA yöntemi ile belirlenmesi. *Scientific Journal of Space Management and Space Economy*, 4(2), 16-32.

- Tao, F., & Zhang, M. (2017). Digital twin shop-floor: a new shop floor paradigm towards smart manufacturing. *IEEE Access*, 5, 20418–20427.
- Tao, F., & Qi, Q. (2019). Make more digital twins. *Nature*, 573, 490-491
- Um, J., Weyer, S., & Quint, F. (2017). Plug-and-simulate within modular assembly line enabled by digital twins and the use of AutomationML. *IFAC-PapersOnLine*, 50(1), 15904-15909.
- Yenilmezel, S., & Ertuğrul, İ. (2022). Çok kriterli karar verme yöntemleri ile bir mermer fabrikası için kesintisiz güç kaynağı seçimi. *Aksaray Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(3), 251-266.
- Yi, Y., Yan, Y., Liu, X., Ni, Z., Feng, J., & Liu, J. (2021). Digital twin-based smart assembly process design and application framework for complex products and its case study. *Journal of Manufacturing Systems*, 58, 94-107.
- Zhuang, C., Liu, J., & Xiong, H. (2018). Digital twin-based smart production management and control framework for the complex product assembly shop-floor. *International Journal of Advanced Manufacturing Technology*, 96(4), 1149–1163.
- Zolfani, S. H., Salimi, J., Maknoon, R., & Simona, K. (2015). Technology foresight about R&D projects selection; Application of SWARA method at the policy making level. *Inzinerine Ekonomika-Engineering Economics*, 26(5), 571-580.

**TÜRKİYE VE DÜNYADA
ENDÜSTRİ MÜHENDİSLİĞİ**

yaz
yayınları

YAZ Yayınları
M.İhtisas OSB Mah. 4A Cad. No:3/3
İscehisar / AFYONKARAHİSAR
Tel : (0 531) 880 92 99
yazyayinlari@gmail.com • www.yazyayinlari.com