


YAPAY ZEKÂ, SİBER GÜVENLİK VE AKILLI ÜRETİM TEKNOLOJİLERİ



EDİTÖR:
EYYÜP GÜLBANDILAR



BİDGE Yayınları

Yapay Zekâ, Siber Güvenlik ve Akıllı Üretim Teknolojileri

Editör: EYYÜP GÜLBANDILAR

ISBN: 978-625-8989-79-3

1. Baskı

Sayfa Düzeni: Gözde YÜCEL

Yayınlama Tarihi: 2026-06-25

BİDGE Yayınları

Bu eserin bütün hakları saklıdır. Kaynak gösterilerek tanıtım için yapılacak kısa alıntılar dışında yayıncının ve editörün yazılı izni olmaksızın hiçbir yolla çoğaltılamaz.

Sertifika No: 71374

Yayın hakları © BİDGE Yayınları

www.bidgeyayinlari.com.tr - bidgeyayinlari@gmail.com

Krc Bilişim Ticaret ve Organizasyon Ltd. Şti.

Güzeltepe Mahallesi Abidin Daver Sokak Sefer Apartmanı No: 7/9 Çankaya /
Ankara



İÇİNDEKİLER

THE USE OF AI AGENTS IN HEALTHCARE TECHNOLOGIES: AN AGENTIC AI APPROACH	1
<i>ABDULLAH SALAH LATEEF, MAHMUT DURGUN</i>	
YAPAY ZEKA VE SİBER GÜVENLİK: SAVUNMA MEKANİZMALARI VE UYGULAMALARI	19
<i>HAYDAR AĞGÖZ, ONUR SEVLİ</i>	
CNC TEZGAHLARI İÇİN DİJİTAL İKİZ, KESTİRİMCİ BAKIM VE SIFIR HATALI ÜRETİM YAKLAŞIMLARI	40
<i>ENES EMRE KOÇAK, SEREL ÖZMEN AKYOL</i>	
ÜRETKEN YAPAY ZEKÂNIN TOPLUMSAL, AKADEMİK VE TEKNOLOJİK ETKİLERİ	60
<i>SAMET ÇİFCİ, İLYAS KARTAL</i>	
DÖNGÜSÜZ YÖNLENDİRİLMİŞ KARMA ÇİZGELER (ACYCLIC DIRECTED MIXED GRAPHS – ADMGS)	107
<i>NURCİHAN FAKİOĞLU, SEREL ÖZMEN AKYOL</i>	
SÖZLÜK TABANLI MAKİNE TOPLULUK MODELLERİ İLE TÜRKÇE METİNLERİN DUYGU POLARİTESİ TESPİTİ ÜZERİNE PERFORMANS ANALİZİ	120
<i>MERVE PINAR, KÜBRA BUZLU, AYŞE BERNA ALTINEL GİRGİN, ESRA YILMAZ</i>	

BÖLÜM 0

The Use of AI Agents in Healthcare Technologies: An Agentic AI Approach

1.Abdullah Salah Lateef¹

2.Doç.Dr.Mahmut Durgun²

Introduction

The healthcare sector is experiencing an unprecedented digital transformation driven by the convergence of artificial intelligence, big data analytics, cloud computing, and connected medical devices. The increasing volume, velocity, and complexity of healthcare data have created significant opportunities for intelligent computational systems to support healthcare professionals in delivering more effective, accurate, and personalized care. Over the past decade, AI applications have become increasingly integrated into medical imaging, predictive analytics, electronic health record management,

¹ MSc Student, Tokat Gaziosmanpasa University, Graduate Education Institute, Department of Bioengineering Orcid:[0009-0004-7622-3267](https://orcid.org/0009-0004-7622-3267)

² Associate Professor., Tokat Gaziosmanpasa University, Graduate Education Institute, Department of Computer Engineering, Orcid: [0000-0002-5010-687X](https://orcid.org/0000-0002-5010-687X)

and clinical decision-support systems, fundamentally reshaping healthcare delivery processes(Jiang vd., 2017).

Despite these advances, most existing AI systems remain task-specific and dependent on predefined instructions. Traditional machine learning models are generally designed to perform narrow functions such as classification, prediction, or pattern recognition, while generative AI systems primarily focus on content generation and conversational interactions. Although these technologies provide substantial benefits, they often lack the ability to independently pursue complex goals, adapt to changing environments, and coordinate multi-step actions without continuous human supervision.

Recent advances in large language models, reinforcement learning, reasoning frameworks, and autonomous systems have led to the emergence of Agentic Artificial Intelligence. Agentic AI represents a significant shift in the evolution of intelligent systems because it introduces autonomous agents capable of goal formulation, strategic planning, adaptive reasoning, action execution, and continuous self-improvement. Rather than functioning solely as analytical tools, agentic systems operate as active participants within decision-making processes(Qiu vd., 2024).

Healthcare environments constitute one of the most promising domains for Agentic AI implementation. Clinical settings are characterized by uncertainty, rapidly changing conditions, large-scale data integration requirements, and high-stakes decisions that directly affect patient outcomes. Autonomous intelligent agents can address these challenges by continuously monitoring clinical information, identifying emerging risks, recommending evidence-based interventions, and supporting healthcare professionals in complex decision-making scenarios.

This chapter aims to provide a comprehensive examination of Agentic AI within healthcare technologies by reviewing its conceptual foundations, technological architecture, practical applications, ethical implications, and future opportunities.

Understanding these dimensions is essential for researchers, healthcare professionals, policymakers, and technology developers seeking to leverage the next generation of intelligent healthcare systems.

Literature Review

The evolution of artificial intelligence in healthcare has progressed through multiple developmental stages, beginning with rule-based expert systems, followed by machine learning algorithms, deep learning models, and more recently, large language models (LLMs). While these technologies have significantly enhanced diagnostic and analytical capabilities, they have generally operated within predefined functional boundaries. The emergence of Agentic AI represents a fundamental shift toward autonomous systems capable of reasoning, planning, and executing complex healthcare-related tasks with limited human intervention(Jiang vd., 2017).

Recent studies indicate that Agentic AI is rapidly emerging as one of the most influential paradigms in digital health. Qiu et al. (2024) argued that agentic systems extend the capabilities of large language models by incorporating planning, tool utilization, memory management, and autonomous decision-making processes. According to the authors, these characteristics enable AI systems to move beyond passive information generation toward active problem-solving and task execution in real-world environments(Qiu vd., 2024).

Liu et al. (2025) proposed a foundational architecture for healthcare AI agents consisting of perception, reasoning, planning, execution, and learning modules. Their framework demonstrated how autonomous agents can integrate heterogeneous clinical information from electronic health records, medical imaging systems, laboratory databases, and wearable devices to support healthcare decision-making(Liu vd., 2025).

Similarly, Srinivasu et al. (2025) investigated the operational principles of Agentic AI in healthcare and emphasized its potential

to improve diagnostic accuracy, optimize treatment pathways, and automate routine clinical workflows. Their findings suggested that agentic systems can substantially reduce administrative burdens while enhancing patient-centered care(Srinivasu vd., 2026).

A comprehensive review conducted by Njei et al. (2026) examined the growing body of research on AI agents in healthcare. The study identified substantial opportunities in clinical decision support, remote patient monitoring, personalized medicine, and healthcare administration. However, the review also highlighted concerns regarding data privacy, transparency, explainability, and regulatory governance(Njei vd., 2026).

The existing literature demonstrates a growing consensus that Agentic AI may become a critical component of future healthcare ecosystems. Nevertheless, researchers emphasize the importance of developing robust governance frameworks to ensure safety, reliability, and ethical compliance during implementation.

.

Evolution from Traditional AI to Agentic AI

Artificial intelligence technologies have evolved considerably over the past decades. Traditional AI systems primarily focused on prediction, classification, and pattern recognition tasks. These systems were designed to respond to predefined inputs and generally lacked the capacity for autonomous reasoning or long-term planning(Jiang vd., 2017).

The emergence of Generative AI introduced new capabilities in content generation, language understanding, and human-computer interaction. Large language models demonstrated unprecedented performance in text generation, summarization, translation, and conversational applications. However, generative systems remain largely reactive and dependent on user prompts.

Agentic AI represents the next evolutionary stage. Instead of merely generating responses, intelligent agents are capable of defining objectives, creating plans, selecting tools, executing

actions, monitoring outcomes, and adapting strategies based on environmental feedback(Qiu vd., 2024).

Table 1. Comparison of Traditional AI, Generative AI, and Agentic AI in Healthcare

Agentic AI	Generative AI	Traditional AI	Dimension
Autonomous Goal Achievement	Content Generation	Prediction and Classification	Primary Function
Autonomous	Prompt-Driven	Rule-Based	Decision-Making
Advanced	Partial	Limited	Planning Capability
High	Moderate	Low	Adaptability
High	Moderate	Limited	Environmental Awareness
End-to-End Clinical Support	Clinical Documentation	Diagnostics	Healthcare Applications
Lower	Moderate	High	Human Supervision

Source: Developed by the author based on Qiu et al. (2024), Liu et al. (2025), and Srinivasu et al. (2025).

Core Characteristics of Agentic AI

The effectiveness of Agentic AI in healthcare stems from several fundamental characteristics that distinguish it from previous generations of intelligent systems.

Autonomy

Agentic systems can independently perform tasks and make decisions without requiring constant human guidance.

Goal-Oriented Behavior

These systems are designed to pursue specific objectives and dynamically adjust their actions to achieve desired outcomes.

Adaptive Reasoning

Agentic AI can evaluate changing circumstances and modify decision-making strategies accordingly.

Continuous Learning

Through feedback loops and reinforcement mechanisms, intelligent agents continuously improve performance over time.


Tool Utilization

Modern AI agents can interact with external systems, databases, software platforms, and medical devices to accomplish complex tasks.

Architecture of Agentic AI in Healthcare

Figure 1 presents the conceptual architecture commonly adopted for healthcare agentic systems(Liu vd., 2025).

Figure 1. Conceptual Architecture of Agentic AI in Healthcare



Source: Developed by the authors based on Qiu et al. (2024), Liu et al. (2025), and Zhao et al. (2026).

Applications of Agentic AI in Healthcare Technologies

The practical value of Agentic AI becomes evident when examining its applications across different healthcare domains(Srinivasu vd., 2026). Unlike conventional AI systems that focus on isolated tasks, agentic systems are capable of coordinating multiple processes, integrating diverse data sources, and autonomously supporting

clinical and operational decision-making. These capabilities position Agentic AI as a transformative technology within modern healthcare ecosystems.

Clinical Decision Support Systems

Clinical decision-making represents one of the most critical processes in healthcare delivery. Physicians must evaluate large volumes of patient information, including medical history, laboratory results, diagnostic imaging, medications, and clinical guidelines. The complexity of these data often increases the risk of diagnostic delays and treatment-related errors.

Agentic AI can continuously analyze patient information, compare findings against clinical guidelines, identify potential risks, and generate evidence-based recommendations. Unlike traditional clinical decision-support tools, agentic systems can proactively monitor patients and recommend interventions before critical deterioration occurs(Liu vd., 2025).

For example, an intelligent healthcare agent monitoring intensive care unit patients may identify early signs of sepsis based on subtle physiological changes and immediately alert healthcare professionals. Early intervention in such cases can significantly reduce mortality rates and improve clinical outcomes.

Medical Diagnostics

Medical diagnosis remains one of the most challenging areas of healthcare because it often requires integrating information from multiple sources while considering numerous potential conditions. Diagnostic errors continue to represent a major cause of patient harm worldwide.

Agentic AI systems can synthesize information from medical images, laboratory findings, clinical notes, genetic data, and patient histories to generate comprehensive diagnostic assessments. These systems can autonomously search for relevant evidence, evaluate diagnostic hypotheses, and provide ranked recommendations to healthcare professionals(Choi & Yoo, 2026).

Research suggests that integrating multimodal healthcare data through intelligent agents may improve diagnostic accuracy for complex diseases, including cancer, cardiovascular disorders, and neurological conditions(Choi & Yoo, 2026).

Personalized Medicine

Personalized medicine seeks to tailor treatment strategies according to individual patient characteristics rather than relying solely on population-based guidelines. This approach requires the analysis of diverse datasets including genetics, lifestyle behaviors, environmental exposures, and clinical history.

Agentic AI provides a powerful framework for personalized medicine because it can continuously evaluate patient-specific information and dynamically adjust treatment recommendations. Intelligent agents may identify the most suitable therapies, optimize medication dosages, and predict individual treatment responses(Liu vd., 2025).

In oncology, for example, agentic systems may integrate genomic sequencing data with clinical records to support precision treatment planning and improve therapeutic outcomes.

Remote Patient Monitoring

The increasing adoption of wearable devices and Internet of Medical Things technologies has generated new opportunities for continuous patient monitoring. Healthcare providers can now collect real-time physiological data outside traditional clinical environments.

Agentic AI can analyze these continuous streams of information and identify early warning signs of clinical deterioration. When abnormalities are detected, intelligent agents may recommend medical interventions, notify healthcare professionals, or provide personalized guidance to patients.

This capability is particularly valuable for chronic disease management, where long-term monitoring plays a critical role in preventing complications and reducing hospital admissions(Njei vd., 2026).

Robotic Surgery and Intelligent Surgical Assistance

Robotic-assisted surgery has already transformed many surgical specialties by enhancing precision, dexterity, and visualization. The integration of Agentic AI introduces additional capabilities that may further improve surgical performance.

Agentic systems can assist surgeons through real-time analysis of intraoperative data, risk assessment, procedural guidance, and adaptive recommendations. Future developments may enable semi-autonomous surgical functions capable of responding to changing conditions during procedures.

Although fully autonomous surgery remains under development, intelligent agents are expected to play an increasingly important role in surgical planning, navigation, and post-operative management(Choi & Yoo, 2026).

Hospital Management and Operational Optimization

Healthcare institutions face significant operational challenges related to resource allocation, workforce management, patient scheduling, and financial sustainability. Inefficient management practices can negatively affect healthcare quality and increase operational costs.

Agentic AI systems can continuously monitor operational processes and optimize resource utilization. Applications include forecasting patient demand, managing hospital bed occupancy, scheduling healthcare personnel, and improving supply-chain logistics(Srinivasu vd., 2026).

By automating routine administrative activities and supporting evidence-based resource allocation, intelligent agents can contribute to more efficient and resilient healthcare systems.

Table 2. Major Applications of Agentic AI in Healthcare

Table 2. Major Applications of Agentic AI in Healthcare

Application Area	Primary Function	Expected Benefits
 Clinical Decision Support	Provides evidence-based recommendations, alerts, and risk assessments by analyzing patient data and clinical guidelines.	Improved clinical outcomes , reduced errors, and faster decision-making.
 Medical Diagnostics	Analyzes multimodal data (imaging, labs, EHRs, genomics) to detect diseases and generate diagnostic insights.	Higher diagnostic accuracy , early disease detection, and better patient triage.
 Personalized Medicine	Tailors treatment plans based on individual genomic, clinical, and lifestyle data and predicts treatment responses.	More effective treatments , fewer side effects, and improved patient satisfaction.
 Remote Patient Monitoring	Continuously monitors patient data from wearables and IoT devices to detect abnormal patterns and health risks in real time.	Early risk detection , timely interventions, and reduced hospital readmissions.
 Robotic Surgery & Surgical Assistance	Assists surgeons with real-time guidance, precision control, intraoperative analytics, and adaptive decision support.	Greater surgical precision , reduced complications, and faster recovery.
 Hospital Management & Operations	Optimizes resources, schedules, logistics, supply chains, and administrative workflows using intelligent automation.	Lower operational costs , higher efficiency, and improved patient experience.

Source: Developed by the authors based on recent literature.

Discussion

The reviewed evidence suggests that Agentic AI has the potential to become a foundational technology within future healthcare systems. Its ability to autonomously coordinate complex processes, integrate heterogeneous data, and support clinical decision-making distinguishes it from previous generations of AI technologies. However, successful implementation requires careful attention to ethical governance, regulatory compliance, transparency, and patient safety(Njei vd., 2026).

Ethical, Legal, and Regulatory Challenges

Despite the promising capabilities of Agentic AI in healthcare, its adoption raises significant ethical, legal, and regulatory concerns. Healthcare systems operate within highly sensitive environments where decisions directly affect human lives. Consequently, the implementation of autonomous intelligent agents requires careful consideration of issues related to privacy, transparency, accountability, fairness, and governance.

Data Privacy and Security

Healthcare data contain highly sensitive personal information, including medical histories, diagnostic reports, genetic profiles, and treatment records. The effectiveness of Agentic AI depends largely on access to extensive datasets, which increases concerns regarding data privacy and cybersecurity risks.

Unauthorized access, data breaches, and cyberattacks may compromise patient confidentiality and undermine public trust in healthcare institutions. Therefore, healthcare organizations must implement advanced encryption techniques, secure authentication mechanisms, and comprehensive governance policies to protect sensitive information.

Furthermore, compliance with international regulations such as the General Data Protection Regulation (GDPR) and national healthcare privacy laws remains essential for responsible AI deployment (WHO Guidance. World Health Organization, 2021).

Explainability and Transparency

One of the major concerns regarding advanced AI systems is the so-called “black-box” problem. Many machine learning models

generate outputs without providing clear explanations regarding the reasoning process behind their decisions.

In healthcare, explainability is particularly important because clinicians must understand and justify medical decisions affecting patient care. Agentic AI systems should therefore provide transparent reasoning pathways that enable healthcare professionals to evaluate and verify recommendations.

Explainable AI approaches can improve trust, facilitate regulatory approval, and support collaboration between intelligent agents and healthcare professionals(WHO Guidance. World Health Organization, 2021).

Algorithmic Bias and Fairness

Agentic AI systems learn from historical datasets that may contain demographic, socioeconomic, racial, or geographic biases.

If these biases are not adequately addressed, autonomous systems may unintentionally generate discriminatory outcomes.

For example, underrepresentation of specific patient populations within training datasets may reduce diagnostic accuracy for those groups. Such disparities can contribute to healthcare inequalities and negatively affect patient outcomes.

To mitigate these risks, healthcare organizations should employ diverse datasets, conduct fairness audits, and continuously monitor system performance across different patient populations(Njei vd., 2026), (WHO Guidance. World Health Organization, 2021).

Accountability and Governance

The increasing autonomy of Agentic AI raises fundamental questions regarding accountability. Determining responsibility when

an autonomous system contributes to a medical error remains a complex legal and ethical challenge.

Potential stakeholders include software developers, healthcare institutions, physicians, regulatory authorities, and technology providers. Clearly defining responsibilities is essential to ensure safe and accountable implementation.

Consequently, future regulatory frameworks should establish standards governing AI validation, performance monitoring, risk management, and clinical oversight(WHO Guidance. World Health Organization, 2021)

Future Directions of Agentic AI in Healthcare

The future development of healthcare technologies is expected to be increasingly influenced by autonomous intelligent agents capable of supporting both clinical and administrative functions(Zhao vd., 2026). Continuous advances in machine learning, large language models, multimodal data processing, and computational infrastructure will likely accelerate the adoption of Agentic AI.

Several emerging trends are expected to shape future healthcare ecosystems(Collaco vd., 2026).

Digital Twins in Healthcare

Digital twins are virtual representations of individual patients that continuously update using real-time clinical data. Agentic AI may leverage these models to simulate treatment outcomes and optimize therapeutic strategies before implementation(Zhao vd., 2026).

Multi-Agent Healthcare Systems

Future healthcare infrastructures may consist of multiple specialized AI agents working collaboratively.

Different agents may manage diagnostics, treatment planning, patient monitoring, logistics, and administrative operations simultaneously(Collaco vd., 2026).

Intelligent Virtual Healthcare Assistants

Future virtual assistants are expected to move beyond conversational support and become proactive healthcare partners capable of monitoring health conditions, coordinating appointments, providing personalized guidance, and facilitating communication between patients and healthcare providers(Zhao vd., 2026).

Autonomous Hospital Ecosystems

The concept of smart hospitals may evolve toward highly integrated ecosystems where intelligent agents continuously optimize operational workflows, resource allocation, and patient management processes(Collaco vd., 2026).

Conclusion

Agentic Artificial Intelligence represents a significant advancement in the evolution of healthcare technologies. Unlike traditional AI systems that operate within predefined functional boundaries, Agentic AI introduces autonomous decision-making, adaptive reasoning, goal-oriented planning, and continuous learning capabilities. These characteristics enable intelligent agents to function as active participants within healthcare environments rather than passive analytical tools(Qiu vd., 2024).

The analysis presented in this chapter demonstrates that Agentic AI has substantial potential across multiple healthcare domains, including clinical decision support, medical diagnostics, personalized medicine, remote patient monitoring, robotic surgery, and hospital management. Through its ability to integrate heterogeneous data sources and coordinate complex workflows, Agentic AI can improve healthcare quality, operational efficiency, and patient outcomes(Liu vd., 2025).

Nevertheless, the successful adoption of Agentic AI requires addressing critical challenges related to privacy, transparency, fairness, accountability, and regulatory governance. Establishing robust ethical frameworks and effective oversight mechanisms will be essential for ensuring safe and trustworthy implementation.

Ultimately, Agentic AI is expected to become a central component of next-generation healthcare ecosystems, supporting the transition toward more intelligent, personalized, efficient, and patient-centered healthcare services(Zhao vd., 2026).

References

- Choi, J. Y., & Yoo, T. K. (2026). Transforming clinical medicine with multimodal artificial intelligence, agentic systems, and the model-context protocol: a perspective on future directions. *Discover Health Systems*, 5(1), 6. <https://doi.org/10.1007/s44250-026-00343-w>
- Collaco, B. G., Haider, S. A., Prabha, S., Gomez-Cabello, C. A., Genovese, A., Wood, N. G., Bagaria, S. P., Gopala, N., Tao, C., & Forte, A. J. (2026). The role of agentic artificial intelligence in healthcare: a scoping review. *npj Digital Medicine*, 9(1), 345. <https://doi.org/10.1038/s41746-026-02517-5>
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., Wang, Y., Dong, Q., Shen, H., & Wang, Y. (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and Vascular Neurology*, 2(4), 230–243. <https://doi.org/10.1136/svn-2017-000101>
- Liu, F., Niu, Y., Zhang, Q., Wang, K., Dong, Z., Wong, I. N., Cheng, L., Li, T., Duan, L., Li, K., Li, G., Hou, T. W., Fok, M., Luo, H., Chen, X., Zhang, K., & Yin, Y. (2025). A foundational architecture for AI agents in healthcare. *Cell Reports Medicine*, 6(10), 102374. <https://doi.org/10.1016/j.xcrm.2025.102374>
- Njei, B., Al-Ajlouni, Y. A., Sidney Kanmounye, U., Boateng, S., Loic Nguefang, G., Njei, N., Hamouri, S., & Al-Ajlouni, A. F. (2026). Artificial intelligence agents in healthcare research: A scoping review. *PLOS One*, 21(2), e0342182. <https://doi.org/10.1371/journal.pone.0342182>
- Qiu, J., Lam, K., Li, G., Acharya, A., Wong, T. Y., Darzi, A., Yuan, W., & Topol, E. J. (2024). LLM-based agentic systems in medicine and healthcare. *Nature Machine Intelligence*, 6(12), 1418–1420. <https://doi.org/10.1038/s42256-024-00944-1>
- Srinivasu, P. N., Aruna Kumari, G. L., Ahmed, S., & Alhumam, A.

- (2026). Exploring Agentic AI in Healthcare: A Study on Its Working Mechanism. *Frontiers in Medicine*, 12. <https://doi.org/10.3389/fmed.2025.1753443>
- WHO Guidance. World Health Organization. (2021). *Ethics and Governance of Artificial Intelligence for Health*.
- Zhao, L., Liu, S., Xin, T., Tan, J., Wang, X., Li, Y., Bian, Z., Chen, Y., Kong, F., Bian, J., Qian, C., & Zhang, Z. (2026). AI agent in healthcare: applications, evaluations, and future directions. *npj Artificial Intelligence*, 2(1), 31. <https://doi.org/10.1038/s44387-026-00076-4>

BÖLÜM 1

YAPAY ZEKÂ VE SİBER GÜVENLİK: SAVUNMA MEKANİZMALARI VE UYGULAMALARI

Haydar AĞGÖZ¹
Onur SEVLİ²

Giriş

Dijital dönüşüm, çağdaş toplumların ekonomik, kurumsal ve kamusal işleyişini köklü biçimde değiştirmiştir. Kamu hizmetlerinden sağlık sistemlerine, finansal işlemlerden endüstriyel kontrol altyapılarına, eğitim ortamlarından nesnelerin interneti ekosistemlerine kadar birçok süreç artık yoğun biçimde veri üretmekte, ağ bağlantısı üzerinden çalışmakta ve yazılım temelli karar mekanizmalarına dayanmaktadır. Bu dönüşüm, siber güvenliği yalnızca teknik bir bilgi işlem konusu olmaktan çıkarmış; kurumsal sürdürülebilirlik, ulusal güvenlik, veri mahremiyeti, ekonomik istikrar ve toplumsal güven açısından stratejik bir alan hâline getirmiştir. Dolayısıyla siber güvenlik, günümüzde yalnızca saldırıları engelleme pratiği değil, aynı zamanda dijital sistemlerin

¹ Burdur Mehmet Akif Ersoy Üniversitesi, Eğitim Bilimleri Enstitüsü, Bilgisayar ve Öğretim Teknolojileri Eğitimi, Orcid: 0009-0007-6820-2150


² Doç. Dr., Burdur Mehmet Akif Ersoy Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0000-0002-8933-8395

güvenilirliğini, erişilebilirliğini ve bütünlüğünü sürdürülebilir kılma çabası olarak ele alınmalıdır.

Siber tehdit ortamı, dijitalleşmenin hızına paralel olarak daha karmaşık, otomatik, hedef odaklı ve ölçeklenebilir bir karakter kazanmıştır. Geleneksel dönemde daha sınırlı kapsamda gözlenen kötü amaçlı yazılım bulaşmaları ve basit ağ saldırıları, günümüzde sıfırcı gün açıkları, gelişmiş kalıcı tehditler, polimorfik zararlı yazılımlar, botnet ağları, DDoS saldırıları, kurumsal kimlik avı kampanyaları ve tedarik zinciri saldırıları gibi çok boyutlu tehditlere dönüşmüştür. Bu dönüşüm, savunma mimarilerinin yalnızca bilinen saldırı imzalarına ve statik güvenlik kurallarına dayanarak etkili sonuç üretmesini zorlaştırmaktadır.

Geleneksel imza tabanlı güvenlik yaklaşımları, daha önce tanımlanmış zararlı yazılım imzalarını veya saldırı örüntülerini tespit etmede önemli katkılar sunmaktadır. Ancak bu yaklaşımlar, daha önce görülmemiş saldırı biçimlerinde, küçük değişikliklerle gizlenmiş zararlı yazılım varyantlarında veya normal kullanıcı davranışına benzetilen saldırı senaryolarında sınırlı kalabilmektedir. Bu nedenle çağdaş siber güvenlik yaklaşımı, yalnızca bilinen tehditleri yakalayan reaktif araçlardan ibaret olmamalı; ağ trafiği, sistem günlükleri, kullanıcı davranışları, uç nokta etkinlikleri ve bulut altyapısı hareketleri üzerinden yeni örüntüleri öğrenebilen, olağan dışı davranışları ayırt edebilen ve tehditleri erken aşamada önceliklendirebilen mekanizmaları içermelidir. Geleneksel savunma anlayışından yapay zekâ destekli proaktif savunmaya geçiş süreci Şekil 1’de özetlenmektedir.

Şekil 1. Geleneksel Savunmadan Yapay Zekâ Destekli Proaktif Savunmaya Geçiş



Yapay zekâ, makine öğrenmesi ve derin öğrenme teknikleri bu gereksinimin karşılanmasında önemli bir teknolojik zemin oluşturmaktadır. Yapay zekâ destekli siber güvenlik sistemleri; tehdit tespiti, anomali analizi, saldırı sınıflandırma, zararlı yazılım tespiti, ortalama saldırılarının belirlenmesi, DDoS saldırılarının saptanması, IoT güvenliği, güvenlik operasyon merkezlerinde alarm önceliklendirme ve otomatik olay müdahalesi gibi süreçlerde kullanılabilir. Oun et al. (2025), yapay zekânın saldırı tespit ve önleme sistemleri, zararlı yazılım tespiti, endüstriyel kontrol ve siber-fiziksel sistemler ile DDoS saldırılarının tespiti bağlamında öne çıktığını belirtmektedir. Benzer biçimde Ofusori et al. (2024), yapay zekânın anomali tespiti, tehdit belirleme, tahmine dayalı analiz ve otomatik olay müdahalesi süreçlerinde siber güvenlik kapasitesini artırdığını vurgulamaktadır.

Yapay Zekâ Tabanlı Savunma Mekanizmaları

Yapay zekâ destekli savunmanın temel üstünlüğü, yüksek hacimli ve çok boyutlu güvenlik verisi içinden insan analistin kısa sürede fark etmesi güç olan örüntüleri çıkarabilmesidir. Bir güvenlik operasyon merkezinde binlerce log kaydı, alarm, uç nokta bildirimi ve ağ trafiği olayı aynı anda değerlendirilmektedir. Bu yoğunluk, alarm yorgunluğu, yanlış pozitif kararlar ve kritik olayların gözden kaçması gibi operasyonel riskler üretmektedir. Yapay zekâ, alarm korelasyonu, risk puanlama, olay önceliklendirme ve analiste karar desteği sağlama işlevleriyle bu riskleri azaltma potansiyeline sahiptir. Bununla birlikte bu potansiyelin gerçek savunma değerine dönüşebilmesi için yapay zekâ modellerinin güvenilir veriyle eğitilmesi, sürekli güncellenmesi, açıklanabilir olması ve insan denetimiyle birlikte çalışması gerekmektedir.

Bu gereklilik, yapay zekâ destekli siber savunmanın yalnızca algoritma seçimiyle açıklanamayacağını göstermektedir. Etkili bir savunma mimarisi; veri toplama, veri temizleme, özellik çıkarımı, model eğitimi, model doğrulama, alarm üretimi, analist incelemesi ve geri bildirim süreçlerinin birlikte ele alındığı bütüncül bir yaşam döngüsüne dayanmalıdır. Bu yaşam döngüsünde verinin hangi kaynaktan geldiği, hangi güvenlik bağlamında üretildiği, hangi ön işleme adımlarından geçirildiği ve model tarafından nasıl kullanıldığı açık biçimde tanımlanmadığında, yüksek doğruluk oranına sahip görünen bir modelin gerçek ortamda beklenen performansı sağlayamaması mümkündür.

Siber güvenlik verilerinin doğası bu süreci daha da karmaşık hâle getirmektedir. Ağ trafiği kayıtları, uç nokta günlükleri, kimlik doğrulama hareketleri, DNS sorguları, e-posta başlıkları, uygulama logları ve bulut servis olayları farklı formatlarda, farklı hızlarda ve farklı güvenilirlik düzeylerinde üretilmektedir. Bu nedenle yapay zekâ destekli savunmada ilk adım, ham veriyi doğrudan modele

aktarmak değil, güvenlik bağlamını koruyacak biçimde anlamlı özelliklere dönüştürmektir.

Makine Öğrenmesi Tabanlı Savunma

Makine öğrenmesi, siber güvenlikte yapay zekâ tabanlı savunmanın en yaygın bileşenlerinden biridir. Alshuaibi et al. (2025), makine öğrenmesi yöntemlerinin farklı siber güvenlik problemlerinde saldırı türleriyle ilişkilendirilebildiğini ve güvenlik olaylarının tespitine katkı sunduğunu ortaya koymaktadır. Makine öğrenmesi modelleri, normal ve zararlı davranış örneklerinden öğrenerek yeni verileri sınıflandırabilir; bu sayede ağ trafiğinin normal mi yoksa saldırgan mı olduğu, bir e-postanın güvenli mi yoksa oltalama girişimi mi içerdiği veya bir dosyanın temiz mi yoksa zararlı mı olduğu değerlendirilebilir. Ancak model başarısı, kullanılan verinin niteliği, güncelliği, dengesi ve temsil gücüyle doğrudan ilişkilidir.

Derin Öğrenme Tabanlı Savunma

Derin öğrenme, özellikle büyük ve karmaşık veri kümelerinin analizinde güçlü temsil kapasitesi sunmaktadır. Ağ trafiği akışları, zaman serisi davranışları, zararlı yazılım özellikleri, API çağrıları, kullanıcı erişim örüntüleri ve IoT cihaz telemetrisi gibi çok boyutlu veriler derin öğrenme modelleriyle analiz edilebilir. Abdullahi et al. (2022), IoT güvenliği bağlamında makine öğrenmesi ve derin öğrenme yöntemlerinin saldırı tespitinde yaygın biçimde kullanıldığını; ancak büyük trafik verileri, dengesiz veri kümeleri, yüksek yanlış alarm oranları ve düşük tespit oranı gibi sorunların model başarısını etkileyebildiğini belirtmektedir. Bu durum, yapay zekâ tabanlı savunmada yalnızca algoritma seçiminin değil, veri mühendisliği ve değerlendirme süreçlerinin de kritik olduğunu göstermektedir. Makine öğrenmesi ve derin öğrenme yöntemlerinin siber güvenlik bağlamındaki kullanım alanları, avantajları ve sınırlılıkları Tablo 1’de karşılaştırmalı olarak sunulmuştur.

Tablo 1. Makine Öğrenmesi ve Derin Öğrenme Yöntemlerinin Kullanım Alanları, Avantajları ve Sınırlılıkları

Yöntem	Kullanım Alanları	Avantajları	Sınırlılıkları
Destek Vektör Makineleri (SVM)	Ağ trafiği sınıflandırma, spam/phishing tespiti	Küçük-orta ölçekli veri setlerinde yüksek performans; iyi genelleme yeteneği	Uygun çekirdek seçimi kritiktir; büyük veri setlerinde ölçeklenebilirlik sınırlıdır
Karar Ağaçları / Rastgele Orman	Saldırı sınıflandırma, anormali tespiti	Yorumlanabilir ve anlaşılabilir modeller sunar; gürültülü verilere karşı dayanıklıdır	Aşırı uyum (overfitting) riski; büyük ormanlarda model boyutu artar
Naive Bayes	E-posta filtreleme, phishing/spam tespiti	Hızlı, basit ve düşük hesaplama maliyetine sahiptir; yüksek boyutlu veride etkilidir	Özelliklerin birbirinden bağımsız olduğu varsayımına dayanır; bu varsayım gerçek veride sağlanmayabilir
K-En Yakın Komşu (KNN)	Benzer davranış örüntüleriyle saldırı tespiti	Uygulaması basittir; parametrik olmayan yapısı ile esneklik	Büyük veri setlerinde yüksek hesaplama maliyeti; bellek kullanımı artar
Lojistik Regresyon	İkili tehdit sınıflandırma (riskli / risksiz, zararlı / zararsız)	Modeli şeffaf ve yorumlanabilir; eğitim maliyeti düşüktür	Doğrusal karar sınırı varsayımı nedeniyle karmaşık ilişkileri yakalamada yetersiz kalabilir
Evrişimsel Sinir Ağları (CNN)	Zararlı yazılım analizi (ikili kod, API çağrıları), ağ trafiği örüntüleri analizi	Otomatik ve hiyerarşik özellik öğrenimi sağlar; yüksek başarı oranları elde eder	Büyük miktarda etiketli veri ve yüksek işlem gücü (GPU) ihtiyacı vardır
Tekrarlayan Sinir Ağları / LSTM	Zaman serisi analizi, DDoS tespiti, kullanıcı davranış analizi	Zamansal bağımlılıkları ve uzun vadeli ilişkileri etkili şekilde yakalar	Eğitim süreci karmaşık ve uzun sürebilir; hiperparametre seçimi hassastır
Autoencoder	Anormali tespiti (ağ trafiği, sistem çağrıları, kullanıcı davranışları)	Etiketsiz verilerle eğitilebilir; gürültüden robust özellik temsilcileri üretir	Anormali skoru için uygun eşik (threshold) belirlemek zor olabilir
Transformer Tabanlı Modeller	Olay günlüğü analizi, tehdit istibharatı analizi, metin tabanlı phishing analizi	Bağlamsal (contextual) öğrenme kabiliyeti yüksektir; uzun bağımlılıkları etkili şekilde modelleyebilir	Yüksek hesaplama ve bellek kaynağı gerektirir; açıklanabilirlik (explainability) sorunu devam etmektedir

Yapay Zekâ Sistemlerine Yönelik Siber Tehditler

Yapay zekâ siber güvenlik için yalnızca savunma kapasitesini artıran bir araç değildir; aynı zamanda saldırganlar tarafından da kullanılabilen çift yönlü bir teknolojidir. Nobles (2024), yapay zekânın siber güvenlikte silahlandırılması konusundaki sistematik incelemesinde, bu teknolojinin savunma süreçlerini güçlendirirken saldırganlara da otomasyon, ölçeklenebilirlik, hedefleme ve güvenlik sistemlerini atlatma açısından yeni imkânlar sunduğunu belirtmektedir. Üretken yapay zekâ destekli oltalama içerikleri, otomatik açık tarama, sosyal mühendislik mesajlarının kişiselleştirilmesi ve güvenlik sistemlerini yanıltmaya yönelik adversarial örnekler bu çift yönlü kullanımın güncel yansımalarıdır.

Bu çerçevede yapay zekâ sistemlerinin kendileri de siber güvenliğin nesnesi hâline gelmektedir. Sangwan et al. (2023), yapay

zekâ sistemlerinin veri, model, eğitim süreci, çıkarım aşaması ve dağıtım ortamı açısından farklı güvenlik tehditlerine açık olduğunu vurgulamaktadır. Veri zehirlenme, adversarial saldırılar, model tersine mühendisliği, model hırsızlığı ve gizlilik ihlalleri, yapay zekâ tabanlı güvenlik sistemlerinin güvenilirliğini zedeleyebilecek başlıca riskler arasında yer almaktadır. Bu nedenle yapay zekâ ile siber güvenlik ilişkisi yalnızca “yapay zekâ siber saldırıları nasıl tespit eder?” sorusuyla sınırlı değildir; aynı zamanda “yapay zekâ sistemleri nasıl güvenli hâle getirilir?” sorusunu da kapsamaktadır.

Yapay zekâ sistemlerinin güvenliği, modelin eğitildiği veri setinden başlayarak üretim ortamındaki kullanımına kadar uzanan çok aşamalı bir konu olarak değerlendirilmelidir. Eğitim verisine kasıtlı olarak hatalı örneklerin yerleştirilmesi, modelin belirli saldırı türlerini normal davranış gibi öğrenmesine neden olabilir. Benzer biçimde çıkarım aşamasında üretilen özel girdiler, modelin yanlış sınıflandırma yapmasına yol açabilir. Bu durum, yapay zekâ tabanlı bir savunma sisteminin yalnızca saldırıları tespit eden bir araç olmadığını, aynı zamanda saldırganın hedef alabileceği yeni bir yüzey oluşturduğunu göstermektedir.

Bu nedenle model geliştirme sürecinde güvenlik testleri, klasik yazılım testlerinden daha geniş bir kapsamda ele alınmalıdır. Modelin farklı veri dağılımlarında nasıl davrandığı, yeni saldırı örüntülerine karşı genellenebilirliği, gürültülü veya eksik verilerde alarm üretme eğilimi, adversarial örnekler karşısındaki dayanıklılığı ve zaman içinde performans kaybı yaşayıp yaşamadığı düzenli olarak izlenmelidir. Siber güvenlik ortamları durağan olmadığı için, modelin eğitim zamanındaki başarı düzeyi kalıcı bir güvence olarak görülmemelidir.

Açıklanabilir Yapay Zekâ ve Güvenilir Siber Savunma

Yapay zekâ tabanlı savunma sistemlerinin güvenilirliğinde açıklanabilirlik özel bir yere sahiptir. Derin öğrenme modelleri

yüksek doğruluk sağlayabilse de çoğu zaman karar süreçlerini açık biçimde göstermeyen kara kutu yapılar olarak çalışmaktadır. Siber güvenlik gibi yüksek riskli alanlarda, bir alarmin neden üretildiği, hangi IP davranışının, hangi paket özelliğinin, hangi kullanıcı hareketinin veya hangi dosya davranışının karar üzerinde etkili olduğu bilinmelidir. Charmet et al. (2022), Rjoub et al. (2023), Neupane et al. (2022) ve Mohale and Obagbuwa (2025), açıklanabilir yapay zekânın özellikle saldırı tespit sistemlerinde şeffaflık, yorumlanabilirlik, güven ve hesap verebilirlik bakımından önemli olduğunu göstermektedir. Bu nedenle Açıklanabilir Yapay Zekâ (Explainable AI, XAI), siber savunmada yalnızca teknik bir iyileştirme değil, operasyonel karar kalitesini artıran bir gereklilik olarak değerlendirilmelidir.


Bu çalışmanın amacı, yapay zekânın siber güvenlik alanındaki savunma mekanizmalarını, uygulama alanlarını, fırsatlarını, risklerini ve sınırlılıklarını akademik literatür temelinde incelemektir. Çalışmada öncelikle yapay zekânın siber güvenlikteki rolü ele alınacak, ardından makine öğrenmesi ve derin öğrenme tabanlı savunma mekanizmaları, IDS ve IPS sistemleri, zararlı yazılım ve oltalama tespiti, açıklanabilir yapay zekâ, yapay zekâ sistemlerine yönelik tehditler ve insan denetimli güvenlik mimarileri tartışılacaktır. Böylece bölüm, yapay zekânın geleneksel savunmanın yerine geçen tekil bir çözüm değil, doğru veri, açıklanabilirlik, model dayanıklılığı ve insan uzmanlığıyla birlikte çalıştığında siber savunmayı güçlendiren stratejik bir teknoloji olduğu görüşünü temellendirmeyi amaçlamaktadır.

Siber Güvenlikte Yapay Zekânın Rolü

Yapay zekâ, siber güvenlikte yalnızca yardımcı bir analiz aracı değil, modern savunma mimarilerinin stratejik bileşenlerinden biri olarak konumlanmaktadır. Siber tehditlerin hacim, hız ve karmaşıklık bakımından artması; manuel inceleme, statik imza

denetimi ve klasik kural tabanlı yaklaşımların sınırlarını görünür hâle getirmiştir. Yapay zekâ bu noktada, büyük veri kümeleri içinden anlamlı örüntüler çıkarma, normal ve anormal davranışları ayırt etme, saldırı olasılığını puanlama ve güvenlik olaylarını önceliklendirme kapasitesiyle öne çıkmaktadır. Bu rol, siber savunmayı yalnızca olay gerçekleştikten sonra tepki veren reaktif bir yapıdan, olası tehditleri önceden işaret eden proaktif bir yapıya taşımaktadır. Yapay zekânın siber güvenlikte veri kaynaklarından modelleme sürecine, analitik çıktılarından SOC/IDS/IPS karar mekanizmalarına uzanan bütüncül rolü Şekil 2’de gösterilmektedir.

Şekil 2. Yapay Zekânın Siber Güvenlikteki Rolü



Yapay zekânın siber güvenlikteki ilk temel işlevi, tehdit tespitinin ölçeklenebilir hâle getirilmesidir. Kurumsal ağlarda, bulut altyapılarında, uç nokta cihazlarında, kimlik yönetimi sistemlerinde ve IoT ortamlarında saniyeler içinde çok sayıda veri üretilmektedir. Bu verilerin tamamının insan analistler tarafından manuel olarak değerlendirilmesi mümkün değildir. Yapay zekâ, log kayıtları, ağ

paketleri, kullanıcı oturumları, dosya davranışları ve sistem çağrıları gibi veri kaynaklarını analiz ederek şüpheli örüntüleri daha kısa sürede belirleyebilir. Oun et al. (2025) tarafından yapılan sınıflandırmada, yapay zekâ tabanlı çalışmaların IDS/IPS, zararlı yazılım tespiti, endüstriyel kontrol sistemleri, siber-fiziksel sistemler ve DDoS saldırılarının tespiti gibi alanlarda yoğunlaştığı görülmektedir.

İkinci temel rol, anomali tespitidir. Geleneksel sistemler çoğunlukla “bilinen saldırı” bilgisini temel alırken, yapay zekâ destekli sistemler normal davranış örüntülerini öğrenerek bu örüntülerden sapmaları tehdit göstergesi olarak değerlendirebilir. Örneğin bir kullanıcının olağan dışı saatlerde farklı coğrafi konumlardan oturum açması, bir IoT cihazının beklenmeyen ağ bağlantıları kurması, bir sunucunun normalden çok daha fazla dış bağlantı başlatması veya bir e-posta ekinin olağan dışı dosya davranışı göstermesi anomali olarak işaretlenebilir. Bu yaklaşım, özellikle imzası henüz tanımlanmamış sıfırıncı gün saldırılarında veya saldırganın normal kullanıcı davranışını taklit etmeye çalıştığı durumlarda önem kazanmaktadır.

Üçüncü rol, saldırı sınıflandırma ve karar desteğidir. Güvenlik operasyon merkezlerinde yalnızca alarm üretmek yeterli değildir; alarmin önem düzeyi, olası saldırı türü, etkilenen varlık, saldırının yayılma potansiyeli ve önerilen müdahale biçimi de belirlenmelidir. Yapay zekâ tabanlı modeller, anomaliyi yalnızca “normal dışı” olarak işaretlemekle kalmayıp DDoS, botnet, brute force, zararlı yazılım, veri sızdırma, ortalama veya yetkisiz erişim gibi kategorilere ayırabilir. Ofusori et al. (2024), yapay zekânın tehdit belirleme, tahmine dayalı analiz ve otomatik olay müdahalesi süreçlerinde karar destek kapasitesi sunduğunu vurgulamaktadır. Bu kapasite, güvenlik analistlerinin sınırlı zamanını en yüksek riskli olaylara yönlendirmesine yardımcı olabilir.

IDS ve IPS Sistemlerinde Yapay Zekâ


Dördüncü rol, otomasyon ve olay müdahalesidir. Yapay zekâ destekli sistemler, belirli eşik değerlerine, risk puanlarına ve davranış modellerine göre olayları önceliklendirebilir; güvenlik orkestrasyonu ve otomatik müdahale araçlarıyla birlikte çalışarak şüpheli uç noktanın izole edilmesi, zararlı alan adının engellenmesi, riskli oturumun sonlandırılması veya ilgili analiste vaka açılması gibi işlemleri tetikleyebilir. Bununla birlikte otomasyon, siber güvenlikte insan denetiminin ortadan kalkması anlamına gelmemelidir. Kritik altyapı, sağlık, finans ve kamu hizmetleri gibi yüksek riskli alanlarda tamamen otomatik kararlar yanlış pozitif durumunda hizmet kesintilerine veya meşru kullanıcıların engellenmesine yol açabilir. Bu nedenle yapay zekâ destekli otomasyon, insan denetimli karar mekanizmalarıyla birlikte tasarlanmalıdır. Anomali tabanlı IDS/IPS süreçlerinde veri toplama, risk skorlama, analist doğrulaması, yanlış pozitif yönetimi ve model geri bildirimi Şekil 3'te şematize edilmiştir.

Otomasyonun etkili kullanılabilmesi için müdahale düzeyleri açık biçimde ayrıştırılmalıdır. Düşük etkili ve geri alınabilir eylemler, örneğin bir alarmın önceliğinin yükseltilmesi, ek log toplanması veya bir vakaya otomatik etiket atanması daha yüksek otomasyon düzeyiyle yürütülebilir. Buna karşılık kullanıcı hesabının kilitlenmesi, kritik bir sunucunun ağdan ayrılması, finansal işlem akışının durdurulması veya üretim hattını etkileyebilecek güvenlik müdahaleleri daha dikkatli ele alınmalıdır. Bu tür durumlarda yapay zekâ sistemi yalnızca risk gerekçesini sunmalı, nihai karar ise tanımlı yetki düzeyine sahip güvenlik analisti veya olay müdahale ekibi tarafından verilmelidir.

Yanlış pozitif yönetimi, IDS ve IPS sistemlerinin operasyonel başarısında belirleyici bir unsurdur. Çok sayıda yanlış alarm üreten bir sistem, başlangıçta güvenliği artırıyor gibi görünse de zaman içinde analistlerin alarmlara duyarlılığını azaltabilir.

Alarm yorgunluğu, kritik bir olayın sıradan bir bildirim gibi değerlendirilmesine ve gerçek saldırıların geç fark edilmesine neden olabilir. Bu nedenle yapay zekâ tabanlı IDS/IPS tasarımında yalnızca tespit oranı değil, alarmın bağlamı, açıklaması, önceliği ve analistin iş akışına etkisi de dikkate alınmalıdır.

Şekil 3. Anomali Tabanlı IDS/IPS İş Akışı ve Yanlış Pozitif Yönetimi



Zararlı Yazılım ve Phishing Tespiti

Beşinci rol, zararlı yazılım ve ortalama tespitinde davranışsal analiz sağlamasıdır. Geleneksel antivirüs sistemleri büyük ölçüde bilinen zararlı yazılım imzalarına dayanırken, yapay zekâ tabanlı yaklaşımlar dosya yapısı, API çağrıları, sistem üzerindeki davranış, ağ bağlantıları, bellek kullanımı ve çalışma zamanı etkinlikleri gibi özellikleri analiz edebilir. Ortalama saldırılarında ise e-posta metni, bağlantı yapısı, alan adı benzerliği, dilsel özellikler, gönderici davranışı ve kullanıcı etkileşim örüntüleri değerlendirilebilir. Üretken yapay zekânın daha inandırıcı ve kişiselleştirilmiş ortalama

içerikleri üretme kapasitesi arttıkça, savunma tarafında da bağlamsal ve davranışsal analiz yapabilen modellerin önemi artmaktadır.

Zararlı yazılım tespitinde yapay zekâ kullanımının değeri, yalnızca dosya imzası karşılaştırmasından daha geniş bir davranışsal değerlendirme yapabilmesinden kaynaklanmaktadır. Bir dosyanın çalıştırıldığında hangi süreçleri başlattığı, hangi sistem dizinlerine eriştiği, hangi API çağrılarını yaptığı, dış ağ bağlantısı kurup kurmadığı ve bellekte nasıl davrandığı, zararlı yazılım analizi için önemli göstergelerdir. Statik analiz dosya çalıştırılmadan özellik çıkarımı sağlarken, dinamik analiz dosyanın gerçek veya izole edilmiş ortamda sergilediği davranışı gözlemlemeye odaklanır.

Ortalama tespitinde ise teknik göstergeler ile dilsel göstergelerin birlikte değerlendirilmesi önem taşır. Şüpheli alan adı benzerlikleri, bağlantı yönlendirmeleri, gönderici adresindeki tutarsızlıklar, aciliyet vurgusu, kullanıcıyı kimlik bilgisi girmeye zorlayan ifadeler ve kurumsal dilin taklit edilmesi gibi özellikler model açısından anlamlı sinyaller oluşturabilir. Bununla birlikte ortalama saldırıları yalnızca teknik bir problem değildir; insan psikolojisi, kurumsal alışkanlıklar ve kullanıcı farkındalığı ile doğrudan ilişkilidir.

Altıncı rol, IoT ve siber-fiziksel sistemler gibi yüksek çeşitlilik içeren ortamlarda güvenliği desteklemesidir. IoT ekosistemleri sınırlı işlem gücüne sahip cihazlar, heterojen protokoller, yüksek veri hacmi ve farklı güvenlik olgunluk düzeyleri nedeniyle klasik savunma yöntemleri açısından zorluk üretmektedir. Abdullahi et al. (2022), IoT güvenliğinde yapay zekâ yöntemlerinin saldırı tespiti için yaygın biçimde kullanıldığını, ancak büyük trafik verileri ve dengesiz veri kümelerinin yanlış alarm oranlarını etkileyebildiğini belirtmektedir. Bu bulgu, yapay zekânın IoT güvenliği için güçlü bir araç olduğunu; fakat veri dengesi, model genellenebilirliği ve gerçek zamanlı çalışma kapasitesi gibi konuların dikkatle ele alınması gerektiğini göstermektedir.

IoT ve siber-fiziksel sistemlerde yapay zekâ kullanımının önemli bir boyutu, güvenlik kararlarının fiziksel sonuçlar doğurabilmesidir. Geleneksel bilişim sistemlerinde bir alarm çoğu zaman veri gizliliği, sistem erişilebilirliği veya hesap güvenliğiyle ilişkilendirilirken; endüstriyel kontrol sistemleri, akıllı şehir altyapıları, sağlık cihazları ve enerji ağlarında yanlış veya gecikmiş kararlar fiziksel süreçleri de etkileyebilir. Bu nedenle bu tür ortamlarda yapay zekâ destekli savunma sistemlerinin yalnızca siber olayları değil, operasyonel güvenliği ve hizmet sürekliliğini de dikkate alması gerekir.


Yedinci rol, güvenlik operasyon merkezlerinde analist yükünü azaltmasıdır. Modern SOC ortamları, çok sayıda güvenlik aracından gelen alarm, log ve tehdit istihbaratı bildirimiyle karşı karşıyadır. Bu yoğunluk, analistlerin her olayı aynı derinlikte incelemesini zorlaştırmakta ve alarm yorgunluğuna neden olabilmektedir. Yapay zekâ destekli sistemler alarmları benzer olaylarla ilişkilendirebilir, tekrarlayan düşük riskli bildirimleri gruplayabilir, anomaliyi daha geniş saldırı zinciri içinde konumlandırabilir ve analiste açıklamalı risk puanı sunabilir. Ancak bu işlevin etkili olabilmesi için modelin neden belirli bir alarmı önceliklendirdiğini gösterebilmesi gerekir.

Kara Kutu Problemi

Bu noktada açıklanabilir yapay zekâ, siber güvenlikte yapay zekânın rolünü tamamlayan temel bir ilkedir. Bir IDS sistemi “bu trafik zararlıdır” sonucunu verdiğinde, güvenlik analisti bu kararın hangi özelliğe dayandığını bilmek ister. Neupane et al. (2022), açıklanabilir saldırı tespit sistemlerinin mevcut yöntemler, zorluklar ve fırsatlar bakımından önemli bir araştırma alanı olduğunu göstermektedir. Charmet et al. (2022) ve Rjoub et al. (2023) ise XAI yaklaşımlarının siber güvenlikte güven, yorumlanabilirlik ve denetlenebilirlik açısından kritik olduğunu vurgulamaktadır. Mohale

and Obagbuwa (2025), XAI entegrasyonunun IDS sistemlerinde şeffaflığı ve yorumlanabilirliği artırma potansiyeline dikkat çekmektedir. SHAP ve LIME gibi açıklanabilir yapay zekâ tekniklerinin bir güvenlik alarmını analist açısından nasıl yorumlanabilir hâle getirdiği Şekil 4’te gösterilmektedir.

Şekil 4. SHAP/LIME ile Alarm Açıklama Süreci



Açıklanabilir Yapay Zekâ Teknikleri

Şekil 4’te gösterilen açıklama süreci, yapay zekâ tabanlı bir alarmın analist tarafından daha anlamlı biçimde değerlendirilmesine katkı sağlar. Bir alarm yalnızca yüksek risk puanı sunduğunda, analist çoğu zaman bu puanın hangi davranışlara dayandığını anlamak için ek inceleme yapmak zorunda kalır. Oysa katkı değerleri, hangi özelliğin alarmı artırdığını, hangi özelliğin riski azalttığını ve model kararında hangi göstergelerin baskın olduğunu görünür hâle getirir. Böylece analist, alarmı kör bir model çıktısı

olarak değil, gerekçeleriyle birlikte değerlendirilebilen bir karar önerisi olarak ele alabilir.

Açıklanabilirlik yalnızca analist düzeyinde değil, kurumsal yönetim açısından da önemlidir. Güvenlik ekipleri, hangi alarm tiplerinin sık tekrarlandığını, hangi özelliklerin sürekli yanlış pozitif ürettiğini ve hangi müdahale kurallarının gereksiz iş yükü oluşturduğunu açıklama kayıtları üzerinden izleyebilir. Bu kayıtlar, model güncelleme süreçlerinde kullanılabileceği gibi kurum içi denetim, olay sonrası değerlendirme ve politika iyileştirme çalışmalarına da veri sağlayabilir.

Yapay zekânın siber güvenlikteki rolü değerlendirilirken, model performansının yalnızca doğruluk oranıyla ölçülmemesi gerekir. Bir modelin gerçek savunma değerini belirleyen unsurlar arasında yanlış pozitif ve yanlış negatif oranları, farklı saldırı türlerine genellenebilirliği, veri seti önyargılarına duyarlılığı, açıklanabilirliği, operasyonel ortama uyarlanabilirliği ve adversarial saldırılara dayanıklılığı yer almaktadır. Özellikle güvenlik alanında yanlış negatifler gerçek saldırıların gözden kaçmasına, yanlış pozitifler ise gereksiz müdahalelere ve güvenlik ekiplerinde alarm yorgunluğuna neden olabilir. Bu nedenle yapay zekâ destekli güvenlik sistemleri, laboratuvar koşullarındaki başarıdan çok gerçek ağ ortamlarındaki sürdürülebilir performanslarıyla değerlendirilmelidir.

Gerçek ortam performansının değerlendirilmesinde zaman faktörü özel bir önem taşır. Siber tehditler, modelin eğitildiği dönemdeki örüntülerle sınırlı kalmaz; saldırı araçları, kullanıcı davranışları, kurumun ağ mimarisi ve yazılım envanteri sürekli değişir. Bu değişim modelin zamanla güncelliğini yitirmesine neden olabilir. Bu nedenle yapay zekâ destekli güvenlik sistemlerinde düzenli yeniden eğitim, performans izleme, alarm istatistiklerinin değerlendirilmesi ve model sürümleri arasında karşılaştırma yapılması gerekir.

Değerlendirme sürecinde doğru metriklerin seçilmesi de önemlidir. Güvenlik alanında yalnızca genel doğruluk oranı yanıltıcı olabilir; çünkü veri kümelerinde normal olaylar saldırı olaylarına göre çok daha fazla olabilir. Bu durumda model çok sayıda olayı normal sınıfına atayarak yüksek doğruluk elde ediyor gibi görünebilir; ancak kritik saldırıları kaçırabilir. Bu nedenle tespit oranı, yanlış pozitif oranı, yanlış negatif oranı, kesinlik, duyarlılık, F1 değeri, alarm başına inceleme süresi ve müdahale başarısı gibi göstergeler birlikte değerlendirilmelidir.

Yapay zekâ, savunma tarafını güçlendirirken saldırganların araç setini de genişletebilir. Nobles (2024), yapay zekânın siber güvenlikte silahlandırılmasının tehdit ekosisteminde yeni riskler doğurduğunu belirtmektedir. Saldırganlar, yapay zekâyı açık tarama süreçlerini hızlandırmak, ortalama mesajlarını kişiselleştirmek, güvenlik sistemlerini yanıltacak adversarial örnekler üretmek veya sosyal mühendislik saldırılarını ölçeklendirmek için kullanabilir. Sangwan et al. (2023) ise yapay zekâ sistemlerinin veri, model ve dağıtım aşamalarında korunması gerektiğini göstermektedir. Bu bağlamda yapay zekânın siber güvenlikteki rolü, hem savunmada kullanılan yapay zekâ araçlarının etkinliğini hem de bu araçların kendilerinin güvenliğini kapsayan bütüncül bir yaklaşım gerektirir.

İnsan Denetimli Siber Savunma

Bu bütüncül yaklaşımın uygulanabilmesi için teknik, örgütsel ve etik boyutlar birlikte planlanmalıdır. Teknik boyut; veri kaynaklarının belirlenmesi, model mimarisinin seçilmesi, güvenli entegrasyonun sağlanması ve alarm akışlarının tanımlanmasını içerir. Örgütsel boyut; güvenlik analistlerinin rol paylaşımını, olay müdahale prosedürlerini, karar yetkilerini ve geri bildirim mekanizmalarını kapsar. Etik ve hukuki boyut ise kişisel verilerin korunması, asgari veri işleme ilkesi, açıklanabilir karar üretimi ve denetlenebilir kayıt yapılarıyla ilişkilidir.

Yapay zekâ destekli siber güvenlik uygulamalarında aşamalı geiş yaklaşımı daha saėlıklı sonuçlar üretebilir. İlk aşamada model, yalnızca izleme ve alarm önceliklendirme amacıyla kullanılabilir. İkinci aşamada analiste öneri sunan ve vaka ilişkilendiren karar destek işlevleri devreye alınabilir. Üçüncü aşamada ise düşük riskli ve geri alınabilir işlemler için sınırlı otomasyon uygulanabilir. Tam otomatik müdahale ise ancak modelin performansı, açıklanabilirliği, geri alma mekanizmaları ve insan denetimi olgunlaştığında değerlendirilmelidir.

Yapay zekâ destekli siber güvenlik uygulamalarında ortaya çıkan fırsatlar, riskler, sınırlılıklar ve bunlara yönelik azaltım stratejileri Tablo 2’de özetlenmiştir.

Tablo 2. Yapay Zekâ Destekli Siber Güvenlikte Fırsatlar, Riskler, Sınırlılıklar ve Azaltım Stratejileri

Sınıf	Başlık	Olası Etki	Azaltım Stratejileri
Fırsat	Hızlı tehdit tespiti ve otomasyon	Alarm analizi ve olay müdahalesinde süre kısılır	İnsan denetimi ile kademeli otomasyon
Fırsat	Ölçeklenebilirlik ve büyük veri analizi	Yüksek hacimli log ve trafik verisi etkin işlenir	Bulut/kenar mimarileri ve performans izleme
Fırsat	Proaktif savunma ve anormal tespiti	Bilinmeyen tehditler daha erken fark edilir	Sürekli model güncelleme ve geri bildirim
Risk	Adversarial saldırılar	Model yanıltılabilir, tespit başarısı düşebilir	Saėlıklı testleri, adversarial eğitim, savunmalı modelleme
Risk	Saldırganların yapay zekâyı kullanması	Phishing, kötü amaçlı içerik ve otomatik saldırılar gelişebilir	Çok katmanlı savunma, tehdit istihbaratı ve farkındalık eğitimi
Sınırlılık	Yanlış pozitif / yanlış negatif	Analist yükü artar veya kritik tehditler kaçabilir	Eşik ayarı, insan doğrulaması, veri kalitesi iyileştirme
Sınırlılık	Veri kalitesi ve önyargı	Hatalı veya dengesiz veri güvenilirliği azaltır	Veri temizleme, dengeleme, veri yönetişi
Sınırlılık	Kara kutu ve açıklanabilirlik sorunu	Kararların anlaşılması ve güven zorlaşır	XAI teknikleri, SHAP/LIME, denetim izi
Sınırlılık	Mahremiyet ve uyum	Kişisel verilerin işlenmesinde hukuki ve etik sorunlar doğabilir	Asgari veri ilkesi, anonimleştirme, mevzuata uyum

Sonu olarak yapay zekâ, siber gvenlikte geleneksel savunma yaklaşımlarının yerine tamamen geen bağımsız bir zm olarak değıl, bu yaklaşımları glendiren, hızlandıran ve leklendiren stratejik bir tamamlayıcı olarak grlmelidir. Etkili bir yapay zekâ destekli savunma mimarisi; kaliteli ve gncel veri, aıklanabilir model yapısı, insan denetimi, model dayanıklılığı, etik-hukuki uyum ve srekli geri bildirim mekanizması zerine kurulmalıdır. Bu yaklaşımlar benimsendiğinde yapay zekâ, siber gvenlikte yalnızca daha hızlı alarm reten bir teknoloji değıl, doğıru alarmı doğıru bağlamda sunan ve analistin karar kapasitesini artıran gvenilir bir savunma ortağı hâline gelebilir.

Kaynakça

Abdullahi, M., Baasha, Y., Alhussian, H., Alwadain, A., Aziz, N., Capretz, L. F., & Abdulkadir, S. J. (2022). Detecting cybersecurity attacks in Internet of Things using artificial intelligence methods: A systematic literature review. *Multidisciplinary Digital Publishing Institute (MDPI)*, 198. doi:<https://doi.org/10.3390/electronics11020198>

Alshuaibi, A., Almaayah, M., & Ali, A. (2025). Machine Learning for Cybersecurity Issues : A systematic Review. *Journal of Cyber Security and Risk Auditing*, 36-46. doi:<https://doi.org/10.63180/jcsra.thestap.2025.1.4>

Charmet, F., Tanuwidjaja, H. C., Ayoubi, S., Gimenez, P. F., Han, Y., Jmila, H., . . . Zhang, Z. (2022). Explainable artificial intelligence for cybersecurity: A literature survey. *Annals of Telecommunications*, 789-812. doi:<https://doi.org/10.1007/s12243-022-00926-7>

Mohale, V. Z., & Obagbuwa, I. C. (2025). A systematic review on the integration of explainable artificial intelligence in intrusion detection systems to enhancing transparency and interpretability in cybersecurity. *Frontiers in Artificial Intelligence*. doi:<https://doi.org/10.3389/frai.2025.1526221>

Neupane, S., Ables, J., Anderson, W., Mittal, S., Rahimi, S., Banicescu, I., & Seale, M. (2022). Explainable Intrusion Detection Systems (X-IDS): A Survey of Current Methods, Challenges, and Opportunities. *IEEE Access*. doi:<https://doi.org/10.48550/arXiv.2207.06236>

Nobles, C. (2024). The Weaponization of Artificial Intelligence in Cybersecurity: A Systematic Review. *Procedia Computer Science*, 547-555. doi:<https://doi.org/10.1016/j.procs.2024.06.206>

Ofusori, L., Bokaba, T., & Mhlongo, S. (2024). Artificial Intelligence in Cybersecurity: A Comprehensive Review and Future Direction. *Applied Artificial Intelligence*. doi:<https://doi.org/10.1080/08839514.2024.2439609>

Oun, A., Wince, K., & Cheng, X. (2025). The Role of Artificial Intelligence in Boosting Cybersecurity and Trusted Embedded Systems Performance: A Systematic Review on Current and Future Trends. *IEEE Access*. doi:<https://doi.org/10.1109/ACCESS.2025.3554739>

Rjoub, G., Bentahar, J., Wahab, O. A., Mizouni, R., Song, A., Cohen, R., . . . Mourad, A. (2023). A Survey on Explainable Artificial Intelligence for Cybersecurity. *IEEE Transactions on Network and Service Management*. doi:<https://doi.org/10.48550/arXiv.2303.12942>

Sangwan, R. S., Badr, Y., & Srinivasan, S. M. (2023). Cybersecurity for AI Systems: A Survey. *Journal of Cybersecurity and Privacy*, 166-190. doi:<https://doi.org/10.3390/jcp3020010>

BÖLÜM 2

CNC TEZGAHLARI İÇİN DİJİTAL İKİZ, KESTİRİMCİ BAKIM VE SIFIR HATALI ÜRETİM YAKLAŞIMLARI

ENES EMRE KOÇAK¹
SEREL ÖZMEN AKYOL²

Giriş

Endüstri 5.0 paradigmasıyla birlikte CNC tezgahları, salt otomasyon odaklı yaklaşımlardan uzaklaşarak insan-makine iş birliğini merkeze alan yeni bir dönüşüm eksenine girmiştir (Ahmed Murtaza vd., 2024; Ramzan & Reforgiato Recupero, 2025). Bu dönüşümde Dijital İkiz (DT), Kestirimci Bakım (PdM) ve Sıfır Hatalı Üretim (ZDM) kavramları; operatörün karar döngüsüne aktif olarak katıldığı şeffaf ve güvenilir bir çerçeve içinde bütünleşmektedir (Mateo-Casalí vd., 2025; Mourtzis vd., 2021). Bu üç kavramın yeni ortak paydası; tezgahın ürettiği verileri kullanarak arızayı ve hatalı ürünü önceden tahmin etmenin ötesinde, elde edilen öngörülerini operatöre açıklanabilir yapay zeka (XAI) prensipleriyle sunarak insan uzmanlığını desteklemektir (Ahmed Murtaza vd., 2024; Mikołajewska vd., 2025). Bu inceleme, söz konusu insan


¹Yükseklisans Öğrencisi, Eskişehir Osmangazi Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0009-0000-0382-5735

²Dr. Öğr. Üyesi, Eskişehir Osmangazi Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0000-0002-5344-4065

odaklı ve bütünsel yapıya odaklanmakta; özellikle görüntü işleme dışında kalan sensör ve parametre verilerine dayalı, açıklanabilirlik ve operatör etkileşimi kapasitesi yüksek makine öğrenimi yaklaşımlarını ele almaktadır (S. Chen vd., 2025; Papageorgiou vd., 2022).

Son yıllarda bu kavramlara yönelik akademik ve endüstriyel ilgi belirgin biçimde artmıştır (C. Chen vd., 2023). Grafik 1'de sunulan arama trendleri incelendiğinde, özellikle Dijital İkiz ve Kestirimci Bakım alanlarındaki ilginin son dönemde eşzamanlı bir ivme kazandığı açıkça görülmektedir (Ismail vd., 2025). Bu artış, endüstriyel bakım stratejilerinde yaşanan zorunlu evrimsel dönüşümün bir yansımasıdır.


Grafik 1 Dijital İkiz ve Kestirimci Bakım kavramlarının yıllara göre arama trendleri analizi



Literatürde bakım yaklaşımları genellikle verimlilik ve maliyet ekseninde Şekil 1'de gösterildiği gibi dört ana stratejiye (arıza sonrası, önleyici, durum tabanlı ve kestirimci) ayrılmaktadır (Garcia vd., 2025; Ismail vd., 2025). Bu stratejiler arasındaki tarihsel ve teknolojik geçiş ise Şekil 2'de özetlenmiş olup; sistemler reaktif (arıza sonrası) bakımdan, yapay zeka destekli kestirimci ve çözüm öneren perspektif (kuralcı) bakıma doğru belirgin bir dönüşüm

geçirmektedir (Ahmed Murtaza vd., 2024; S. Chen vd., 2025; Ramzan & Reforgiato Recupero, 2025).

Şekil 1 Verimlilik ve maliyet ekseninde temel endüstriyel bakım stratejileri



Kaynak: (How Digital Twins Enhance Predictive Maintenance in Manufacturing |INSIA)

Şekil 2 Geleneksel reaktif bakımdan yapay zeka odaklı perspektif bakıma geçiş süreci




Dijital İkiz

Dijital İkiz (Digital Twins-DT), fiziksel bir sistemin gerçek zamanlı olarak beslenen ve davranışını simüle eden sanal kopyası olarak tanımlanmaktadır. Chen vd. (2023), DT'nin kestirimci bakımdaki (PdM) rolünü kapsamlı biçimde incelemiş ve makine öğreniminin bu mimarideki işlevini durum tanıma, arıza tahmini ve bakım kararı optimizasyonu olmak üzere üç katmana ayırmıştır (C.

Chen vd., 2023). Alandaki 42 temel çalışmayı kapsayan sistematik incelemede DT tabanlı PdM sistemlerinin tasarımıdaki temel zorlukların hesaplama yükü, veri çeşitliliği ve model karmaşıklığı olduğu ortaya koyulmuştur (van Dinter vd., 2022). Mimari düzeydeki bu tartışmalara ek olarak güncel bir çalışmada, CNC tezgahları özelinde Bulut, Kenar (Edge) ve DT mimarilerini karşılaştıran sistematik bir derleme sunularak, gerçek zamanlı izleme için kenar mimarisinin, tarihsel analiz ve simülasyon için ise bulut mimarisinin ön plana çıktığı gösterilmiştir (Hamza, 2026). Literatürdeki bu tartışmayı somutlaştıran Cao vd. (2026) ise yüksek hızlı CNC frezeleme tezgahları için titreşim, iş mili akımı ve sıcaklık sinyallerini Kalman filtrelemesiyle birleştiren, kenar kısıtları altında (100 ms gecikme) çalışabilen ve LSTM ile kompakt Transformer karşılaştırması yapan bir araç-sağlığı DT çerçevesi geliştirmiştir (Cao vd., 2026). Söz konusu çalışma, sensör füzyonu, belirsizlik ölçümü (Monte Carlo Dropout) ve yorumlanabilirlik (SHAP) bileşenlerini tek bir sistem bünyesinde bütünleşik biçimde ele alması açısından literatürde özgün bir konuma sahiptir. Doğrudan endüstriyel uygulamalara bakıldığında, Profinet iletişim ağından toplanan veriler üzerinde otokodlayıcı tabanlı bir DT mimarisi geliştirilerek, söz konusu sistemin dokuma atölyesindeki kalite yönetimini iyileştirdiği görülmektedir (Kerkeni vd., 2024). Benzer bir yaklaşımla Liu vd. (2024), bu sistemi takım durum izlemesine uyarlamış ve gerçek zamanlı dijital ikiz tabanlı anomali tespiti için frezeleme işlemlerinde takım koşulunu anlık olarak etkin biçimde izleyebildiğini ortaya koymuştur (Liu vd., 2024).

Dijital ikiz teknolojinin bu süreçteki rolü ve sisteme entegrasyonu, kestirimci bakımın başarısı açısından belirleyici öneme sahiptir. Şekil 3’de dijital ikiz mimarisinin kestirimci bakıma sağladığı artırılmış verimlilik, erken sorun tespiti ve azaltılmış kesinti süresi gibi temel operasyonel avantajları özetlemektedir.


Şekil 3 Kestirimci bakım süreçlerinde Dijital İkiz mimarisinin sağladığı temel avantajlar



Kaynak: (How Digital Twins Enhance Predictive Maintenance in Manufacturing | INSIA)

Söz konusu mimarinin üretim sahasına entegrasyonu ise çok aşamalı bir süreç gerektirmektedir. Şekil 4'de sunulduğu üzere; dijital ikiz mimarisinin uygulanması veri toplama ile başlayıp model kalibrasyonu, öngörücü model geliştirme, mevcut sistemlerle (CMMS/ERP) entegrasyon ve sürekli iyileştirme adımlarından oluşan sistematik bir boru hattını (pipeline) kapsamaktadır.


Şekil 4 Endüstriyel bakım için Dijital İkiz sistemlerinin uygulama ve entegrasyon adımları



Sensör Verileri

Teorik modellerin sahadaki karşılığı, doğrudan tezgaha entegre edilen sensörler ve haberleşme donanımları aracılığıyla sağlanmaktadır. Resim 1'de, bir CNC freze tezgahı üzerinde üç eksenli ivmeölçer, iş mili (spindle) akım sensörü ve sıcaklık sensörünün fiziksel konumlandırması ile toplanan telemetri verilerinin endüstriyel kontrolcüler ve kenar-uç (edge) cihazlar üzerinden nasıl aktarıldığı ayrıntılı bir mimari ile gösterilmektedir.

Resim 1 CNC tezgah ve kenar (edge) bilişim mimarisi



Kaynak: (Cao vd., 2026)


CNC tezgahlarında kestirimci bakım ve kalite kontrolü amacıyla kullanılan başlıca sensör sinyalleri, taşıdıkları bilgi içeriği bakımından birbirinden farklılaşmaktadır. En bilgi yoğun sinyal olan titreşim, tırlama (chatter), dengesizlik, rulman hasarı ve takım aşınması gibi konularda kendine özgü örüntüler barındırmaktadır. Apostolou vd. (2024), CNC frezeleme süreçlerinde iş mili titreşiminin iş parçası yüzey kalitesini doğrudan etkilediğini; titreşim izleme ile kalite kontrolünün bütünleştirilmesinin hurda oranını, yeniden işleme sürelerini ve maliyetleri önemli ölçüde azalttığını göstermiştir (Apostolou vd., 2024). Kesme kuvvetinin dolaylı bir

göstergesi olan mil (spindle) akımı ise endüstriyel uygulanabilirliği yüksek bir sinyal türüdür. Li vd. (2020) mevcut tezgahlardaki PLC'den ek sensör gerektirmeksizin alınan akım sinyalleri üzerinde derin anomali tespiti uygulayarak takım kırılmalarını ve aşırı aşınmayı tespit etmiştir (G. Li vd., 2020). Doğru ölçümü güç ancak bilgi değeri yüksek olan kesme kuvveti üzerine çalışan Zhang vd. (2023), bu sinyallerden derin öğrenme yöntemiyle takım aşınma koşulunu izlerken; 5 eksenli frezeleme süreçlerinde kuvvet korelasyonunu doğrudan ZDM hedefiyle ilişkilendirerek sıfır hatalı üretim yönünde önemli bir yaklaşım da ortaya koyulmuştur (Cascón-Morán vd., 2024; Y. Zhang vd., 2023). Hassas işleme sistemlerinde ses ve akustik bilgilerinden de faydalanılmaktadır. Emisyon sinyallerini titreşimle birlikte kullanarak tamamlayıcı bir tezgah durum sınıflandırması gerçekleştirmiş ve frezeleme sırasında oluşan taşlama yanığını kısmen akustik verilere dayanarak tespit edilmiştir (Han vd., 2021; Sauter vd., 2021). Literatürdeki hâkim eğilim, tek sensör kullanımı yerine çoklu sensör füzyonu yaklaşımını benimsemek yönündedir; Ströbel vd. (2025)'nin Siemens SINUMERIK 840D kontrolöründen 500 Hz sinyal verileriyle 10 kHz ivmeölçer verilerini senkronize ederek yayımladığı sekiz anomali tipini kapsayan veri kümesi, alan için önemli bir referans kaynağı hâline gelmiştir (Ströbel vd., 2025).

Temel Yapay Zeka ve Makine Öğrenmesi Mimarileri

Kestirimci bakım mimarileri, sensörlerden gelen ham verinin karar destek mekanizmalarına dönüştürüldüğü veri güdümlü süreçlere dayanmaktadır. Şekil 5'te gösterildiği üzere bu süreç; çoklu kaynaklardan gerçek zamanlı veri toplanması, verilerin merkezi platformlara entegrasyonu, anomali tespiti, makine öğrenimi tabanlı analiz, kestirimci modellerin tetiklenmesi ve nihayetinde proaktif bakım müdahalesi olmak üzere birbirini besleyen ardışık adımlardan oluşmaktadır. Bu adımları gerçekleştirmek için literatürde çeşitli yapay zeka mimarileri ön plana çıkmaktadır.

Şekil 5 Makine öğrenimi destekli kestirimci bakım süreci



Kaynak: (How Digital Twins Enhance Predictive Maintenance in Manufacturing | INSIA)

Bu mimarilerden biri olan Otokodlayıcı (Autoencoder, AE) tabanlı yaklaşım, bu çalışmanın odak noktasını oluşturan mimaridir. Model yalnızca normal üretim verisiyle eğitilerek "normalin nasıl görüldüğünü" öğrenmektedir; yeni bir veri örneği geldiğinde ise yeniden yapılandırma hatası belirli bir eşiği aşıyorsa bu örnek anormal olarak işaretlenmektedir. Zaman serisi verilerinde en yaygın kullanılan kombinasyon LSTM-AE'dir. PHM2010 veri kümesi üzerinde gerçekleştirilen çalışmada entropi ve çeyrekler arası aralık gibi ek özneliliklerle %98 takım aşınması tahmin doğruluğuna ulaşılmış ve arıza öncesi erken müdahaleyi sağlamak amacıyla RUL değeri manipüle edilmiştir (Elminir vd., 2024). Daha gürültülü üretim koşullarında ise, geliştirilen hibrit konvolüsyonel-LSTM AE ile geleneksel yöntemlerin zayıflıklarını aşılmıştır (Elminir vd., 2024). Üretim koşulları (takım değişimi, malzeme farklılığı vb.) değiştikçe sabit eşiklerin yanlış alarm üretmesi sorunu ise çok değişkenli zaman serileri için dikkat mekanizmalı ConvLSTM-AE ve dinamik eşikleme yöntemiyle ele alınmıştır (Elminir vd., 2024). Soğuk başlangıç sorununu gidermek adına, transfer öğrenmesi ile AE uygulanarak yeni bir tezgahta yeterli veri birikene dek geçmiş

bilgileri izlenmesi amacıyla kullanmıştır (Elminir vd., 2024). Ayrıca düşük bütçeli sistemler için Arduino ve MPU6050 sensörüyle denetimsiz otokodlayıcı kurularak üç eksen titreşim verisine istatistiksel eşik uygulayıp KOBİ'ler için işlevsel bir çözüm sunulmuştur (Elminir vd., 2024). Sensörler arası uzamsal bağımlılıkları modellemek amacıyla da titreşim ve akım verilerine GCN-VAE uygulanarak eksen-çapraz ilişkileri yakalanmıştır (Choi vd., 2024). Sıralı verilerde ise BiLSTM ve GRU tabanlı AE modellerini karşılaştırmalı olarak değerlendirmiş ve her iki yaklaşımın da kullanım senaryosuna göre üstünlük sağladığı alanları ortaya koyulmuştur (Patra vd., 2022).

Kalan Kullanım Ömrü (RUL - Remaining Useful Life) Tahmininde Hibrit Sıralı Modeller ve Klasik Yöntemler

Kalan Kullanım Ömrü (RUL) tahmini görevinde literatür son zamanlarda hibrit mimarilere yönelmektedir. Kesme kuvveti, titreşim ve akım sinyallerini işleyerek RUL tahmini için geliştirilen CNN-LSTM-Attention-PSA modeliyle $R^2 = 0,9942$ değerine ulaşılmış ve tekil modellerin hata payları kayda değer ölçüde düşürülmüştür (Zhu vd., 2024). Benzer şekilde Yang vd. (2022), ham sinyali wavelet scalogram'a dönüştürerek CNN ve LSTM'i birleştirmiş ve modelin genelleme kapasitesini iyileştirmiştir (Yang vd., 2022). GRU tabanlı DT mekanizmasıyla yük pertürbasyonlarını tahmin ederek göreceli tahmin hatasını %4'ün altında tutulurken, PSD haritaları CNN ve Vision Transformer (PSD-CVT) ile işlenerek takım aşınması tahmininde yüksek doğruluk sağlanmıştır (Si vd., 2024; X. Zhang & Xie, 2025).

Endüstri 5.0 hedefleri doğrultusunda LSTM ve RNN'i alarm sinyalleriyle birleştirilerek operatörleri gerçek zamanlı uyarın insan-merkezli bir mimari geliştirilmiştir (Mateo-Casalı vd., 2025). Derin öğrenme yaklaşımlarının yanı sıra klasik makine öğrenimi uygulamaları da endüstriyel değerliliğini korumaktadır (Ganeshkumar vd., 2023; Singh vd., 2025; Unal vd., 2023).

Üretici Ağlar ile Veri Artırma

CNC arıza teşhisindeki en kritik sorunlardan biri, etiketli arıza verisinin yetersizliğidir; bu açığı gidermek amacıyla GAN (Çekişmeli Üretici Ağlar) mimarilerine başvurulmaktadır. Shah vd. (2022) SGAN ile LSTM'yi, Jalayer vd. (2022) ise WGAN-GP ile CLSTM hibrit çerçevesini birleştirerek nadir arıza sınıflarını sentetik verilerle zenginleştirmiş ve genelleme performanslarını artırmışlardır (Jalayer vd., 2022; Shah vd., 2022). Başka bir çalışmada ise WGAN ve CNN kodlayıcı kombinasyonunu kullanarak etiket gerektirmeksizin normal ve anormal örnekleri ayırt edebilen veri merkezli bir anomali tespit sistemi oluşturulmuştur (Zeiser vd., 2023). Güncel bir çalışmada ise üretici yapay zekanın (GenAI) çok kipli sensör verileri birleştirilerek nadir arıza senaryolarını nasıl simüle edebileceği XAI ile destekleyerek Endüstri 4.0/5.0 vizyonu çerçevesinde kapsamlı biçimde incelenmiştir (Mikołajewska vd., 2025). Bu süreçte kullanılacak sensör verilerinin işlenmesi ve seçimi model başarısını etkilemektedir. Ham sensör verisi, doğrudan zaman serisi biçiminde modele beslenip iki aşamalı denetimsiz öznitelik çıkarımıyla kullanılabildiği gibi (Tnani vd., 2022); Gauss süreci modeliyle %91,45 doğruluk elde ettiği çalışmasında olduğu üzere frekans alanına (FFT vb.) dönüştürülerek de işlenebilmektedir (Y. Li vd., 2025). Çift domainli (zaman ve frekans) mimariler ise literatürdeki bilgi içeriği en zengin örnekler arasında yer almaktadır (Si vd., 2024).

Titreşim ve akım tabanlı yöntemlerin sanayide en çok faydalanan uygulamalar olduğunun belirtildiği RUL ve takım durum izleme alanındaki öne çıkan çalışmalar, Tablo 1'de özetlenmiştir (Leon vd., 2023).

Tablo 1 Kalan Kullanım Ömrü (RUL) ve Takım Durum İzleme Çalışmaları

Çalışma	Sensör(ler)	Model	Başarım
(Zhu vd., 2024)	Titreşim, akım, kuvvet	CNN-LSTM-Attention-PSA	$R^2 = 0,994$, MAPE ↓
(Elminir vd., 2024)	Titreşim, akım (PHM2010)	LSTM-AE	Doğruluk $\approx$ %98, MAE = $2,6 \times 10^{-3}$
(Yang vd., 2022)	Titreşim (wavelet)	CNN + LSTM	Çok koşulda genelleme ↑
(Si vd., 2024)	Titreşim, akım (PHM2010)	PSD-CNN-ViT	RMSE en düşük grupta
(Cao vd., 2026)	Titreşim, akım, sıcaklık	LSTM + Transformer (füzyon)	F1: 0,892 -> 0,903, RMSE: 8,1 döngü
(Hassan vd., 2023)	Akım, titreşim	Derin öğrenme (gerçek zamanlı)	Ani takım kırılmalarında erken uyarı
(Unal vd., 2023)	Çok sensörlü	YSA sınıflandırma + regresyon	CNC takım RUL tahmini, endüstri odaklı
(Y. Zhang vd., 2023)	Kesme kuvveti	Derin öğrenme	Aşınma koşulu izleme
(Y. Li vd., 2025)	Kesme kuvveti	Gauss Süreci + istatistiksel eşik	Anomali doğruluğu %91,45

Anomali Tespiti ve Sıfır Hatalı Üretim (Zero Defect Manufacturing – ZDM)

Normal ve hatalı üretimi karşılaştıran yaklaşımlar (denetimsiz anomali tespiti vb.) üzerine, etiket gerektirmeyen yöntemlerin IoT cihazları için en ümit vadeden yaklaşım olduğunu göstermektedir. Literatürde uygulanan farklı anomali tespit çerçeveleri Tablo 2'de verilmiştir. Bu tespit sürecini yalnızca hatayı bulmaktan öteye taşıyarak hatanın oluşmasını önlemeyi amaçlayan Sıfır Hatalı Üretim (ZDM) stratejisi ise proaktif bir analiz yapısını zorunlu kılmaktadır. ZDM doğrultusunda Kök Neden Analizi (KNA) için derin öğrenmenin önemli bir potansiyel taşıdığını; ancak "görüntü olmaksızın, yalnızca tezgah telemetrisiyle çalışan sensör tabanlı KNA"nın literatürdeki temel eksiklik olduğunu vurgulanmaktadır (Papageorgiou vd., 2022). Farklı çalışmalarda ZDM için DT tabanlı tasarım optimizasyonu önerilmiş (Mourtzis vd., 2021) ve 5 eksenli frezeleme sürecinde yapay zeka ile kuvvet korelasyonunu ZDM hedefiyle eşleştirerek hatalı ürün tahminini

gerçekleştirilmiştir (Cascón-Morán vd., 2024). Bununla birlikte Garcia vd. (2025)'nin de belirttiği üzere, gerçek zamanlı kök neden belirleme pratiği sanayide hala oldukça sınırlı kalmaktadır (Garcia vd., 2025).

Tablo 2 Anomali Tespiti Yaklaşım, Veri Tipi ve Eşik Yöntemi Karşılaştırması

Çalışma	Yaklaşım	Veri Tipi	Eşik Yöntemi	Öne Çıkan Yönü
<i>(Wankhede & Handi, 2026)</i>	Denetimsiz AE	X-Y-Z titreşim	İstatistiksel eşik	Düşük maliyetli, KOBİ uygulamaları
<i>(Yan vd., 2023)</i>	Hibrit konv.-LSTM AE	Ham titreşim	Adaptif eşik	Gürültüye dayanıklı
<i>(Tayeh vd., 2022)</i>	ConvLST M-AE	Çok değişkenli zaman serisi	Dinamik eşik	Kayma (drift) yönetimi
<i>(Demetgul vd., 2023)</i>	Transfer öğrenme AE	Titreşim	Sabit / transfer	Soğuk başlangıç çözümü
<i>(Choi vd., 2024)</i>	GCN-VAE	Titreşim + akım	Olasılık skoru	Sensörler arası bağımlılık
<i>(Patra vd., 2022)</i>	BiLSTM/GRU-AE	Titreşim	Yeniden yapılandırma hatası	Model karşılaştırması
<i>(Fathi vd., 2021)</i>	AE tabanlı PdM	Robot eklemi	Eşik	3 DoF robot, genel çerçeve
<i>(Zeiser vd., 2023)</i>	WGAN + CNN AE	Üretim süreci	Kümeleme skoru	Etiketsiz ZDM uygulaması
<i>(Kerkeni vd., 2024)</i>	DT + AE	Profinet ağı	Derin öğrenme	Gerçek endüstri uygulaması
<i>(Liu vd., 2024)</i>	DT + anomali tespiti	Takım sinyali	Gerçek zamanlı eşik	Anlık izleme

Endüstri 4.0 tam otomasyona odaklanırken, Endüstri 5.0 insanı karar döngüsünün merkezine yeniden konumlandırarak operatöre anlayabileceği düzeyde açıklamalar sunmayı hedeflemektedir. Bu geçişin temel taşıını oluşturan açıklanabilir yapay zeka (XAI) güven tesis edilmesi için zorunludur (Mikołajewska vd., 2025).

İlgili literatür incelendiğinde etiketli arıza verisi yetersizliğine karşı GAN ve otokodlayıcı çözümlerine odaklanmak; üretim koşulları değiştikçe yanlış alarm üreten sabit eşiklere alternatif olarak referanslı dinamik ve adaptif eşikleme mekanizmaları geliştirmek (Cao vd., 2026; Tayeh vd., 2022), transfer öğrenme kapasitesini genişletmek ve yüksek hesaplama yüküne karşı kenar dağıtımlı TinyML stratejilerine yönelmek (Demetgul vd., 2023) özellikle alanda ihtiyaç duyulan konulardır. Ströbel vd. (2025)'nin yayımladığı veri kümesinde örneklendiği üzere çoklu sensör füzyonunda standardizasyon sağlanırken (Ströbel vd., 2025), "görüntü olmaksızın, yalnızca tezgah telemetrisine dayalı sensör tabanlı kök neden analizi" yaklaşımı hâlâ sınırlı düzeyde araştırılmış olup literatürde özgün katkı sunabileceği düşünülen en kritik alanlardan birini oluşturmaktadır (Papageorgiou vd., 2022).

Kaynakça

Ahmed Murtaza, A., Saher, A., Hamza Zafar, M., Kumayl Raza Moosavi, S., Faisal Aftab, M., & Sanfilippo, F. (2024). Paradigm shift for predictive maintenance and condition monitoring from Industry 4.0 to Industry 5.0: A systematic review, challenges and case study. *Results in Engineering*, 24, 102935. <https://doi.org/10.1016/j.rineng.2024.102935>

Apostolou, G., Ntemi, M., Paraschos, S., Gialampoukidis, I., Rizzi, A., Vrochidis, S., & Kompatsiaris, I. (2024). Novel Framework for Quality Control in Vibration Monitoring of CNC Machining. *Sensors*, 24(1), 307. <https://doi.org/10.3390/s24010307>

Cao, Z., Chen, L., Li, C., Zhu, L., & Deng, Z. (2026). Tool-Health Digital Twin for CNC Predictive Maintenance via Innovation-Adaptive Sensor Fusion and Uncertainty-Aware Prognostics. *Machines*, 14(3), 335. <https://doi.org/10.3390/machines14030335>

Cascón-Morán, I., Gómez, M., Fernández, D., Val, A. G. D., Alberdi, N., & González, H. (2024). Towards Zero-Defect Manufacturing Based on Artificial Intelligence through the Correlation of Forces in 5-Axis Milling Process. *Machines*, 12(4), 226.

<https://doi.org/10.3390/machines12040226>

Chen, C., Fu, H., Zheng, Y., Tao, F., & Liu, Y. (2023). The advance of digital twin for predictive maintenance: The role and function of machine learning. *Journal of Manufacturing Systems*, 71, 581-594.

<https://doi.org/10.1016/j.jmsy.2023.10.010>

Chen, S., Turanoglu Bekar, E., Bokrantz, J., & Skoogh, A. (2025). AI-enhanced digital twins in maintenance: Systematic review, industrial challenges, and bridging research–practice gaps. *Journal of Manufacturing Systems*, 82, 678-699. <https://doi.org/10.1016/j.jmsy.2025.07.006>

Chevtchenko, S. F., Rocha, E. D. S., Santos, M. C. M. D., Mota, R. L., Vieira, D. M., Andrade, E. C. D., & Araújo, D. R. B. D.

(2023). Anomaly Detection in Industrial Machinery Using IoT Devices and Machine Learning: A Systematic Mapping. *IEEE Access*, 11, 128288-128305.

<https://doi.org/10.1109/access.2023.3333242>

Choi, S.-H., An, D., Lee, I., & Lee, S. (2024). Anomaly Detection Based on Graph Convolutional Network–Variational Autoencoder Model Using Time-Series Vibration and Current Data. *Mathematics*, 12(23), 3750. <https://doi.org/10.3390/math12233750>

Demetgul, M., Zheng, Q., Tansel, I. N., & Fleischer, J. (2023). Monitoring the misalignment of machine tools with autoencoders after they are trained with transfer learning data. *The International Journal of Advanced Manufacturing Technology*, 128(7-8), 3357-3373.

<https://doi.org/10.1007/s00170-023-12060-2>

Elminir, H. K., El-Brawany, M. A., Ibrahim, D. A., Elattar, H. M., & Ramadan, E. A. (2024). *An efficient deep learning prognostic model for remaining useful life estimation of high speed CNC milling machine cutters*. <https://doi.org/10.1016/j.rineng.2024.103420>

Fathi, K., Venn, H. W. van de, & Honegger, M. (2021). Predictive Maintenance: An Autoencoder Anomaly-Based Approach for a 3 DoF Delta Robot. *Sensors*, 21(21), 6979. <https://doi.org/10.3390/s21216979>

Ganeshkumar, S., Singh, B. K., Kumar, R. S., & Haldorai, A. (2023). Digital Twin Framework for Lathe Tool Condition Monitoring in Machining of Aluminium 5052. *Defence Science Journal*, 73(3), 341-350. <https://doi.org/10.14429/dsj.73.18650>

Garcia, J., Rios-Colque, L., Peña, A., & Rojas, L. (2025). Condition Monitoring and Predictive Maintenance in Industrial Equipment: An NLP-Assisted Review of Signal Processing, Hybrid Models, and Implementation Challenges. *Applied Sciences*, 15(10), 5465.

<https://doi.org/10.3390/app15105465>

Hamza, M. F. (2026). Cloud, Edge, and Digital Twin Architectures for Condition Monitoring of Computer Numerical Control Machine Tools: A Systematic Review. *Information*, 17(2), 153. <https://doi.org/10.3390/info17020153>

Han, S., Mannan, N., Stein, D. C., Pattipati, K. R., & Bollas, G. M. (2021). Classification and regression models of audio and vibration signals for machine state monitoring in precision machining systems. *Journal of Manufacturing Systems*, 61, 45-53.

<https://doi.org/10.1016/j.jmsy.2021.08.004>

Hassan, M., Sadek, A., & Attia, H. (2023). A Real-Time Deep Machine Learning Approach for Sudden Tool Failure Prediction and Prevention in Machining Processes. *Sensors*, 23(8), 3894.

<https://doi.org/10.3390/s23083894>

How Digital Twins Enhance Predictive Maintenance in Manufacturing | INSIA. (t.y.). Geliş tarihi 21 Mayıs 2026, gönderen <https://www.insia.ai/blog-posts/digital-twins-enhance-predictive-maintenance-manufacturing>

Ismail, L., Abdelmoti, A., Basu, A., Berini, A. D. E., & Naouss, M. (2025, Eylül). *A Systematic Review of Digital Twin-Driven Predictive Maintenance in Industrial Engineering: Taxonomy, Architectural Elements, and Future Research Directions*. arXiv. <https://doi.org/10.48550/arXiv.2509.24443>

Jalayer, M., Kaboli, A., Orsenigo, C., & Vercellis, C. (2022). Fault Detection and Diagnosis with Imbalanced and Noisy Data: A Hybrid Framework for Rotating Machinery. *Machines*, 10(4), 237.

<https://doi.org/10.3390/machines10040237>

Kerkeni, R., Khelif, S., Mhalla, A., & Bouzrara, K. (2024). Digital Twin Applied to Predictive Maintenance for Industry 4.0. *Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems*, 7(041008). <https://doi.org/10.1115/1.4065875>

Leon, M. A. L. de, Kolarik, J., Byrtus, R., Koziorek, J., Zmij, P., & Martinek, R. (2023). Tool Condition Monitoring Methods Applicable in the Metalworking Process. *Archives of Computational Methods in Engineering*, 31(1), 221-242.

<https://doi.org/10.1007/s11831-023-09979-w>

Li, G., Fu, Y., Chen, D., Shi, L., & Zhou, J. (2020). Deep Anomaly Detection for CNC Machine Cutting Tool Using Spindle Current Signals. *Sensors*, 20(17), 4896. <https://doi.org/10.3390/s20174896>

Li, Y., Zhao, Z., Peng, Z., Zhang, L., Ding, W., & Fu, Y. (2025). An innovative strategy for real-time tool anomaly detection in CNC milling processes using time series monitoring. *Frontiers of Mechanical Engineering*, 20(3), 21. <https://doi.org/10.1007/s11465-025-0837-3>

Liu, Z., Lang, Z.-Q., Gui, Y., Zhu, Y.-P., & Laalej, H. (2024). Digital twin-based anomaly detection for real-time tool condition monitoring in machining. *Journal of Manufacturing Systems*, 75, 163-173. <https://doi.org/10.1016/j.jmsy.2024.06.004>

Mateo-Casalí, M. A., Mateos, J., Alarcón, F., & Fraile, F. (2025). Predictive Maintenance for CNC Machines: Empowering Operators with Real-Time Insights. İçinde A. A. Juan, J. Faulin, & D. Lopez-Lopez (Ed.), *Decision Sciences* (ss. 330-341). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-78238-1_30

Mikołajewska, E., Mikołajewski, D., Mikołajczyk, T., & Paczkowski, T. (2025). Generative AI in AI-Based Digital Twins for Fault Diagnosis for Predictive Maintenance in Industry 4.0/5.0. *Applied Sciences*, 15(6), 3166. <https://doi.org/10.3390/app15063166>

Mourtzis, D., Angelopoulos, J., & Panopoulos, N. (2021). Equipment Design Optimization Based on Digital Twin Under the Framework of Zero-Defect Manufacturing. *Procedia Computer Science, Proceedings of the 2nd International Conference on Industry 4.0 and Smart Manufacturing (ISM 2020)*, 180, 525-533. <https://doi.org/10.1016/j.procs.2021.01.271>

Papageorgiou, K., Theodosiou, T., Rapti, A., Papageorgiou, E. I., Dimitriou, N., Tzovaras, D., & Margetis, G. (2022). A systematic review on machine learning methods for root cause analysis towards zero-defect manufacturing. *Frontiers in Manufacturing Technology*, 2. <https://doi.org/10.3389/fmtec.2022.972712>

Patra, K., Sethi, R., & Behera, D. (2022). Anomaly detection in rotating machinery using autoencoders based on bidirectional LSTM and GRU neural networks. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30(4), 1637-1653. <https://doi.org/10.55730/1300-0632.3870>

Ramzan, F., & Reforgiato Recupero, D. (2025). A Literature Review on Enhancing Predictive Maintenance in Smart Manufacturing Industries: Fostering Human-Technology Collaboration and Overcoming Data Scarcity Limitations with Advanced AI Models. *Operations Research Forum*, 6(4), 181. <https://doi.org/10.1007/s43069-025-00584-0>

Sauter, E., Sarikaya, E., Winter, M., & Wegener, K. (2021). In-process detection of grinding burn using machine learning. *The International Journal of Advanced Manufacturing Technology*, 115(7-8), 2281-2297. <https://doi.org/10.1007/s00170-021-06896-9>

Shah, M., Vakharia, V., Chaudhari, R., Vora, J., Pimenov, D. Y., & Giasin, K. (2022). Tool wear prediction in face milling of stainless steel using singular generative adversarial network and LSTM deep learning models. *The International Journal of Advanced Manufacturing Technology*, 121(1-2), 723-736. <https://doi.org/10.1007/s00170-022-09356-0>

Si, S., Mu, D., & Si, Z. (2024). Intelligent tool wear prediction based on deep learning PSD-CVT model. *Scientific Reports*, 14(1), 20754. <https://doi.org/10.1038/s41598-024-71795-4>

Singh, S., Sethi, S., Sharma, R., Vaibhavi, D., & Tiwari, A. (2025). AI-Powered CNC Digital Twin for Predictive Maintenance. *2025 Fourth International Conference on Power, Control and Computing Technologies (ICPC2T)*, 1-6.

<https://doi.org/10.1109/ICPC2T63847.2025.10958573>

Ströbel, R., Kuck, M., Oexle, F., Kader, H., Puchta, A., Noack, B., & Fleischer, J. (2025). A multimodal dataset for process monitoring and anomaly detection in industrial CNC milling. *Data in Brief*, 63, 112207. <https://doi.org/10.1016/j.dib.2025.112207>

Tayeh, T., Aburakhia, S., Myers, R., & Shami, A. (2022). An Attention-Based ConvLSTM Autoencoder with Dynamic Thresholding for Unsupervised Anomaly Detection in Multivariate Time Series. *Machine Learning and Knowledge Extraction*, 4(2), 350-370.

<https://doi.org/10.3390/make4020015>

Tnani, M.-A., Subarnaduti, P., & Diepold, K. (2022). Efficient Feature Learning Approach for Raw Industrial Vibration Data Using Two-Stage Learning Framework. *Sensors*, 22(13), 4813. <https://doi.org/10.3390/s22134813>

Unal, P., Temel, S., Ummak, E., & Özbayoğlu, A. M. (2023). Condition Monitoring and Remaining Useful Life Prediction for Tool Wear in CNC Machines. *2023 10th International Conference on Future Internet of Things and Cloud (FiCloud)*, 264-269.

<https://doi.org/10.1109/FiCloud58648.2023.00046>

van Dinter, R., Tekinerdogan, B., & Catal, C. (2022). Predictive maintenance using digital twins: A systematic literature review. *Information and Software Technology*, 151, 107008.

<https://doi.org/10.1016/j.infsof.2022.107008>

Wankhede, S., & Handi, P. (2026). AI-Based predictive maintenance for CNC machines using vibration data from MPU6050 sensor. *International Journal on Interactive Design and Manufacturing (IJIDeM)*, 20(1), 425-435. <https://doi.org/10.1007/s12008-025-02407-2>

Yan, S., Shao, H., Xiao, Y., Liu, B., & Wan, J. (2023). Hybrid robust convolutional autoencoder for unsupervised anomaly detection of machine tools under noises. *Robotics and Computer-*

Integrated Manufacturing, 79, 102441.
<https://doi.org/10.1016/j.rcim.2022.102441>

Yang, C., Zhou, J., Li, E., Wang, M., & Jin, T. (2022). Local-feature and global-dependency based tool wear prediction using deep learning. *Scientific Reports*, 12(1), 14574.
<https://doi.org/10.1038/s41598-022-18235-3>

Zeiser, A., Özcan, B., van Stein, B., & Bäck, T. (2023). Evaluation of deep unsupervised anomaly detection methods with a data-centric approach for on-line inspection. *Computers in Industry*, 146, 103852. <https://doi.org/10.1016/j.compind.2023.103852>

Zhang, X., & Xie, X. (2025). A data model-driven prediction and compensation strategy for load disturbances in CNC machine tool feeding systems via digital twin technology. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 09544062241309251.
<https://doi.org/10.1177/09544062241309251>

Zhang, Y., Qi, X., Wang, T., & He, Y. (2023). Tool Wear Condition Monitoring Method Based on Deep Learning with Force Signals. *Sensors*, 23(10), 4595. <https://doi.org/10.3390/s23104595>

Zhu, M., Zhang, J., Bu, L., Nie, S., Bai, Y., Zhao, Y., & Mei, N. (2024). Methodology and Experimental Verification for Predicting the Remaining Useful Life of Milling Cutters Based on Hybrid CNN-LSTM-Attention-PSA. *Machines*, 12(11), 752.

<https://doi.org/10.3390/machines12110752>

BÖLÜM 3

Üretken Yapay Zekânın Toplumsal, Akademik ve Teknolojik Etkileri

Samet ÇİFCİ¹
İlyas KARTAL²

Giriş

Yapay zekâ (AI), bilgisayarların tarihsel olarak insan bilişini ve diğer entelektüel yetenekleri gerektiren görevleri yerine getirme yeteneğini ifade eder; bu yetenekler arasında algılama, soyutlama, çıkarım yapma, öğrenme ve karar verme yer alır. Yapay zekâ, giderek insan biliminin ve mühendisliğinin zirvesi olarak kabul ediliyor (Russell & Norvig, 2016). Tarihsel olarak, bu terim resmi olarak 1956'daki Dartmouth Konferansı'nda ortaya atılmış ve John McCarthy yapay zekâyı akıllı makineler yapma bilimi ve mühendisliği" olarak tanımlamıştır (McCarthy vd., 1956). Bu tanım, alanın hem bilimsel hem de mühendislik yönlerini vurgulayarak temel niteliğini korumaktadır.

¹ Marmara Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği , Orcid: 0009-0006-8911-9404

² Doç. Dr., Marmara Üniversitesi Teknoloji Fakültesi Metalurji ve Malzeme Mühendisliği, Orcid: 0000-0001-9677-477X

Üretken Yapay Zeka (GenAI) ise son yıllarda yirmi birinci yüzyılın en dönüştürücü teknolojik gelişmelerinden biri olarak ortaya çıkmıştır. GenAI sistemlerinin yaygınlaşması, eğitimden iş dünyasına, bilimsel araştırmalardan medya sektörüne kadar çok geniş bir alanda dönüşüm yaratmıştır. ChatGPT, Gemini ve Claude gibi sistemlerin çok çeşitli alanlarda insan benzeri, bağlamsal ve tutarlı çıktılar üretebilmesi; büyük dil modelleri (Large Language Models - LLMs) alanındaki son gelişmeler, özellikle de transformer tabanlı mimariler sayesinde mümkün hale gelmiştir. Araştırmacılar, verilerin tamamını önceden sınıflandırmaya gerek kalmadan, makine öğrenme araçları olan Transformer'ları kullanarak giderek daha büyük modeller eğitebilirler. Bu sayede yeni modeller, çok sayıda metin üzerinde eğitilerek daha eksiksiz yanıtlar üretebilmektedir.

GenAI modelleri, büyük miktarda veriye dayanarak yeni içerik üretmek için gelişmiş mimari bileşenler, derin sinir ağları ve katmanlar kullanan sofistike sistemlerdir. Bu alandaki farklı mimarilerden Generative Adversarial Networks (GAN), bir üreticiyi bir ayıracıyla karşılaştırarak pratikle daha gerçekçi çıktılara yol açarken; Transformer modelleri metinsel veriler içindeki uzun menzilli dokuların ince taneli bağlamsal kavranmasını kolaylaştırarak doğal dil işlemeyi (NLP) bir adım ileriye taşımıştır. Görüntü oluşturmada ise yüksek kaliteli ve gerçekçi görsel içeriklerin üretilmesine olanak tanıyan difüzyon modelleri, günümüzün en gelişmiş teknolojisi olarak kanıtlanmıştır (Aggarwal vd. 2021; Aldausari vd. 2023; Bandi vd. 2023).

GenAI'nin gelişimi, öncelikle otomasyon ve analitik karar desteğini mümkün kılan tahmine dayalı yapay zekanın yeteneklerinin ötesinde önemli bir sıçramayı işaret etmektedir. İlk bulgular, bu modellerin performansının yaratıcı düşünme, duygusal zeka ve empatik iletişim gibi yönlerde insan seviyesine ulaştığını,

hatta bazı durumlarda onu aştığını göstermektedir (Krakowski, 2025). Derin öğrenme algoritmalarına dayanan ve isteğe bağlı olarak metin, grafik, program kodu, konuşma ve müzik gibi yapılandırılmamış bilgileri filtreleyerek yeni içerikler üretebilen bu araçlar, insanların karar verme ve zorluklara çözüm bulma süreçlerini simüle ederek yenilikçi sonuçlar sağlar. Bu teknolojik ilerlemeler; ChatGPT, Dall-E, MidJourney, Gemini ve CoPilot AI gibi araçların artan popülaritesiyle birlikte yapay zekanın günlük kullanımdaki rolüne dair büyük bir ilgi ve spekülasyona yol açmıştır.

Temelde LLM'ler, yapay zeka sistemlerinin insan bağlamlarını ilişkilendirilebilir ve makul şekillerde değerlendirmesini ve bunlarla ilişki kurmasını mümkün kılarak daha önce başaramadıkları bilgi merkezli görevleri gerçekleştirmelerine olanak tanır (Bender vd., 2021). Bu tür yetenekler, sonsuz sayıda yeni iş kullanım durumunu destekleme potansiyeli taşımaktadır. GenAI araçlarına ilişkin incelemeler ve analizler, iş yapmanın yeni ve verimli yollarını sunan "bir eşiği aşmaktan", büyük ölçekli intihal ve yanlış bilgilendirmeye uzanan geniş bir yelpazeyi kapsamaktadır (Savage, 2023; Susarla vd., 2023). GenAI'nin içerik üretme yeteneği, geleneksel makine öğrenme algoritmalarının yalnızca veri yorumlamaya dayalı yöntemlerinin aksine, onu çeşitli sektörlerde önemli bir motivasyon kaynağı haline getirmektedir (Mohawesh vd., 2025). Yakın zamanda yayınlanan bir araştırmaya göre, 2023'ten 2028'e kadar %35,6'lık Bileşik Yıllık Büyüme Oranı (CAGR) ile küresel pazarın 2028 yılına kadar 51,8 milyar ABD dolarına ulaşma potansiyeli bulunmaktadır. İstatistiksel veriler, rota planlaması yapmak isteyen işletmeler için oyun değiştirici nitelikte olan bu teknolojinin katlanarak büyüme ve artan verimliliğe yol açacağını ortaya koymaktadır (Birlasoft, 2023). GenAI'nin ortaya çıkışı, toplumun genel olarak bu yeni teknolojiye nasıl yanıt verebileceği, roller ve etkilerle ilgili birçok soruyu da beraberinde getirmiştir.

GenAI'nin deęer ve risklerinin anlařılmasına katkıda bulunmak adına, bu alıřma řu ana arařtırma sorusuna odaklanmaktadır: Bilgi sistemleri ve sosyo-teknik sistem yaklařımları, GenAI teknolojisinin bireyler, kuruluřlar ve geniř toplumsal katmanlar üzerindeki dnřtrc etkilerine iliřkin nasıl btncl ve deęerli bir bakıř aısı saęlayabilir? Bilgi sistemleri arařtırmaları, geleneksel olarak teknolojinin teknik boyutu ile sosyal dinamiklerin birbirine baęlılıęını (teknolojinin sosyo-teknik doęasını) incelemede kkl bir gemiře sahiptir. GenAI aralarının adaptasyon sreleri, yalnızca bireysel kullanıcı kabul (Teknoloji Kabul Modeli - TAM veya Birleřtirilmiř Teknoloji Kabul ve Kullanım Teorisi - UTAUT gibi erevesler) zerinden deęil, aynı zamanda bu araların toplumsal normlar, akademik drstlk ve kurumsal iř sreleriyle olan dinamik etkileřimi zerinden okunmalıdır. Bu doęrultuda alıřma; GenAI'nin teknik altyapısını kurumsal, akademik ve toplumsal yapılarla iliřkilendirerek ok boyutlu bir sosyo-teknik analiz sunmayı amalamaktadır.

2. retken Yapay Zek Kavramı ve Temelleri

Yapay zek, evreden bilgi toplayarak belirli hedeflere ulařmak iin karar verebilen sistemlerin geliřtirilmesini amalayan geniř bir arařtırma alanıdır. Makine ęrenmesi yapay zeknın alt alanlarından biri olup sistemlerin verilerden ęrenmesini saęlarken, derin ęrenme ise ok katmanlı yapay sinir aęları kullanarak karmařık rntlerin keřfedilmesine odaklanmaktadır (Russell & Norvig, 2021).

GenAI, ncelikle retken modellemeye dayanır; bu da, veri odaklı karar destek sistemlerinde sıklıkla kullanılan ayrımcı modellemeden belirgin matematiksel farklılıklara sahiptir (Ng, A. & Jordan, 2001). retken yapay zek modeli, makine ęrenimi mimarisi (rneęin, derin sinir aęı) ile somutlařtırılan ve bu nedenle

öğrenilen kalıplara dayalı olarak yeni veri örnekleri oluşturabilen matematiksel yaklaşımları ifade eder. Ayrıca, bütünsel bir GenAI sistemi; model, veri işleme ve kullanıcı arayüzü bileşenleri de dahil olmak üzere tüm altyapıyı kapsar. Model, daha geniş bir bağlamda etkileşimi ve uygulamayı kolaylaştıran sistemin temel bileşeni olarak hizmet eder.

GenAI uygulamaları; arama motoru optimizasyonu (SEO) içerik üretimi veya kod üretimi gibi gerçek dünya sorunlarını çözen ve çeşitli alanlarda yeniliği yönlendiren bu sistemlerin pratik kullanım durumlarını ve uygulamalarını tanımlar. Son dönemde büyük çokuluslu şirketlerden ciddi düzeyde ilgi ve fon çeken bu teknoloji, küresel ölçekte yeni girişimlerin kurulmasına öncülük etmiştir. GenAI modelleri; kullanıcı sorgularına yanıt olarak metin, resim, ses, video ve 3 boyutlu modeller gibi çok çeşitli medya türleri üretebilmektedir. Veri sınıflandırma ve tahmin gibi görevleri yerine getirmeyi amaçlayan geleneksel yapay zeka sistemlerinin aksine GenAI; eğitildiği girdi veri kümesinin karakteristik özelliklerini ve karmaşık örüntülerini yakalayarak bunlara benzer, özgün ve ayırt edici çıktılar üretmek üzere tasarlanmıştır.

Bu alandaki hızlı popülerite artışının arkasında ChatGPT, Dall-E, Midjourney ve Bard gibi kullanıcı dostu ve dikkat çekici platformların yaygınlaşması yer almaktadır. Bu sistemlerden OpenAI tarafından geliştirilen ChatGPT, NLP yeteneğiyle geniş çapta tanınmakta ve kullanıcıları mantıklı, bağlama uygun konuşmalara dahil edebilmektedir.


Derin öğrenme ve sinir ağı mimarilerindeki paradigma dönüşümü, GenAI alanındaki yöntemsel ilerlemelerin ana motoru olmuştur. Literatürde bu doğrultuda farklı üretken yaklaşımlar kullanılmaktadır; bunların başında gelen GAN, birbirleriyle rekabet eden üretici (generator) ve ayırıştırıcı (discriminator) ağların bir

kombinasyonu aracılığıyla çalışır. Üretici yeni veri örnekleri oluştururken, ayırıcı ise bu örnekleri gerçek verilerden ayırt etmeye çalışır. Öte yandan Varyasyonel Otokodlayıcılar (VAE), öncelikle girdi verilerini gizli bir alana (latent space) sıkıştırarak ve ardından yeni örnekler üretmek üzere veriyi yeniden kurgulayarak işler. Son olarak otoregresif modeller ise veriyi sıralı olarak üretir ve her yeni nesil adımında, seride kendisinden önce gelen bileşenleri bütünleştirerek ilerler (Sai vd., 2024; Carlini, 2024; Corvello, 2025).

2.1 Üretken Yapay Zekâ Modellerinin Türleri

Üretken yapay zekâ modelleri Şekil 1 de görüldüğü gibi; Transformer tabanlı mimariler, LLM’ler ve çok modlu (multimodal) sistemler gibi farklı model ailelerinden oluşmakta olup, bu yapılar ölçeklendirilmiş derin öğrenme yaklaşımları ile metin, görüntü ve diğer veri türlerini üretme kapasitesine sahiptir (Vaswani vd., 2017; Bommasani vd., 2021).

Şekil 1. Üretken Yapay Zekâ (GenAI), temel modeller, büyük dil modelleri (LLM) ve Transformer mimarisi arasındaki hiyerarşik ilişki.



2.1.1 Transformer Modeli

Transformer, LLM'ler ve birçok görüntü oluşturma sistemi de dahil olmak üzere çoğu modern üretken modelin arkasındaki mimari omurgadır. Transformer'lar, mesafeden bağımsız olarak, bir girdinin her bir parçasının diğer her bir parçasıyla ne kadar alakalı olduğunu değerlendirmek için öz-dikkat adı verilen bir mekanizma kullanır. Transformer'lardan önce, Özyinelemeli Yapay Sinir Ağları (Recurrent Neural Networks - RNN) gibi sıralı modeller uzun menzilli bağımlılıklarla mücadele ediyordu. Son kelimenin ilk kelimeye geri bağlanması gereken bir cümle, bir RNN'yi karıştırdı. Transformer'lar bunu doğal olarak ele alır, bu nedenle uzun belgeler ve karmaşık akıl yürütme görevlerine çok iyi uyum sağlarlar. Son üç yılda piyasaya sürülen GPT'den Gemini'ye ve Claude'a kadar her büyük üretken yapay zeka modeli temelde bir transformatördür. Modern üretken yapay zekâ sistemlerinin temelini oluşturan transformer mimarisi, dikkat mekanizması sayesinde uzun bağımlılıkları daha etkin şekilde modelleyebilmekte ve geleneksel RNN tabanlı yaklaşımlara göre daha yüksek performans sağlayabilmektedir (Vaswani vd., 2017).

2.1.2 Large Language Modeli (LLM)

Son birkaç yıldır, akıllı makineler inşa etme konusundaki onlarca yıllık arayış LLM'leri ortaya çıkararak devasa bir sıçrama yapmıştır. İnsan beynini modellemeye çalışan araştırmalara dayanan bu teknoloji, insan yeteneğini taklit eden bir düzeyde inandırıcı ve karmaşık metin, görüntü ve bilgisayar kodu üretebilen yazılımlar olan üretken yapay zeka olarak bilinen yeni bir alana yol açmıştır. Dünya çapındaki işletmeler, medya, finans, hukuk ve profesyonel hizmetlerin yanı sıra eğitim gibi kamu hizmetlerini de dönüştürebileceğine inanarak bu yeni teknolojiyle denemeler yapmaya başlamıştır. LLM, Google araştırmacıları tarafından 2017

yılında geliştirilen transformatör modeli olarak bilinen bilimsel bir gelişmeye dayanmaktadır. Google'da yapay zeka modelleri (LLM'ler dahil) geliştiren kıdemli araştırmacı Slav Petrov, "Dönüştürücü çalışmalarımızın çığır açıcı niteliğini her zaman anlamış olsak da, aradan birkaç yıl geçtikten sonra, sağlık hizmetlerinden robotik ve güvenliğe, insan yaratıcılığını geliştirmeye ve daha fazlasına kadar yeni alanlarda kalıcı potansiyelinden dolayı heyecan duyuyoruz" diyor. LLM'lerin metin yazarak ve analiz ederek verimliliği artırma yeteneği, aynı zamanda insanlara karşı bir tehdit oluşturmasının da nedenidir. Goldman Sachs'a göre, büyük ekonomilerde 300 milyon tam zamanlı çalışana eşdeğer bir iş gücünü otomasyona maruz bırakarak yaygın işsizliğe yol açabilir. Teknoloji hızla hayatımızın bir parçası haline gelirken, LLM'lerin metni nasıl ürettiğini anlamak, bu modellerin neden bu kadar çok yönlü bilişsel motorlar olduğunu ve başka nelerin yaratılmasına yardımcı olabileceğini anlamak anlamına gelir.

2.1.3 Generative Adversarial Networks (GANs)

GAN'lar iki sinir ağını birbirine karşı kullanır. Üretici, gerçek gibi görünen sahte veriler üretmeye çalışır. Ayırıcı ise sahteyi gerçekten ayırt etmeye çalışır. Her iki ağ da eş zamanlı olarak eğitilir ve her biri işinde daha iyi hale geldikçe çıktılarının kalitesi de sürekli olarak iyileşir. GAN'lar, difüzyon modelleri ortaya çıkmadan önce görüntü üretimi için baskın mimariydi. Hala video sentezi, yüz üretimi ve nadir bir şeyin gerçekçi görünen örneklerine ihtiyaç duyulan veri artırma görevlerinde yaygın olarak kullanılmaktadırlar. GAN'ların en büyük pratik problemi, eğitimdeki istikrarsızlıklarıdır. İki ağın da birinin çökmeden senkronize bir şekilde gelişmesini sağlamak gerçekten zordur. GAN, biri veri üretmeye çalışan üretici ağ (generator), diğeri ise üretilen verinin gerçek olup olmadığını ayırt etmeye çalışan ayırt edici ağdan (discriminator) oluşan iki bileşenli bir mimariye dayanmaktadır. Bu iki ağ arasındaki rekabetçi

öğrenme süreci sayesinde sistem gerçek verilere oldukça benzer yeni içerikler üretebilmektedir (Goodfellow vd., 2014).

2.1.4 Diffusion Modeli

Difüzyon modelleri, gürültü oluşturma sürecini tersine çevirmeyi öğrenerek çalışır. Eğitim sırasında model, temiz verileri görür ve bunların giderek daha gürültülü hale geldiğini izler. Bu gürültüyü ortadan kaldırmayı öğrenir. Üretim zamanında, saf gürültüden başlar ve kademeli olarak gürültüyü gidererek temiz bir görüntü, ses klibi veya video oluşturur. Stable Diffusion, DALL-E 3 ve Midjourney'nin tümü difüzyon tabanlı yaklaşımlar kullanır. Görüntüler için kalite tavanı şu anda GAN'lardan daha yüksek difüzyon modellerinde mevcuttur; bu nedenle alan, görsel üretim için büyük ölçüde bunlara yönelmiştir. Diffusion modelleri, veriye kademeli olarak gürültü ekleyip ardından bu gürültüyü tersine çevirerek yeni örnekler üreten üretken modellerdir (Ho vd., 2020).

2.1.5 Üretken Yapay Zekâ Modellerinin Yapısal ve İşlevsel Analizi

Yapay zekâ ve doğal dil işleme mimarilerinin tarihsel ve yapısal evrimini, teknik kapasiteler ile yöntemsel sınırlılıklar arasındaki denge üzerinden ele alan akademik bir özet mahiyetindeki Tablo 1, literatürdeki paradigmasal dönüşümü net bir şekilde ortaya koymaktadır. Bu bağlamda, geleneksel RNN ve LSTM gibi sekans modelleri, veriyi ardışık olarak işlemelerinden ötürü basit bir yapı sunmalarına rağmen, uzun vadeli bağımlılıkları yönetmekte zayıf kalmış ve yalnızca sınırlı metin görevlerinde kendilerine yer bulabilmiştir. Bu kronik sorunun aşılması amacıyla geliştirilen Transformer mimarisi ise öz-dikkat mekanizması vasıtasıyla verinin paralel işlenmesine olanak tanımış, ancak bu teorik sıçrama doğrusal bir artışla çok daha yüksek hesaplama maliyetlerini beraberinde getirmiştir. Transformer altyapısının milyarlarca parametreyle

ölçeklenmesi sonucu ortaya çıkan LLM, sistemleri belirli bir görev alanından çıkarıp genel amaçlı bilişsel araçlara dönüştürmüş; fakat bu durum, modellerin olasılıksal doğasından kaynaklanan ve epistemik güvenilirliği zedeleyen halüsinasyon riskini en belirgin zayıflık olarak literatüre yerleştirmiştir. Gelişimin ulaştığı son aşamayı temsil eden Çok Modlu Üretken Yapay Zekâ (Multimodal GenAI) ise metin tabanlı sınırları aşarak görsel, işitsel ve metinsel veri tiplerini ortak bir semantik uzayda birleştirmiş; farklı modalitelerin hizalanmasından doğan karmaşık eğitim süreçlerine rağmen, yapay zekânın otonom sistemler gibi dinamik ve gerçek dünya şartlarına uyumlu alanlarda köklü bir dönüştürücü güç olmasını sağlamıştır.

Tablo 1. Üretken Yapay Zekâ Modellerinin Mimari ve Fonksiyonel Karşılaştırması

Model Türü	Temel Mimari	Güçlü Yön	Zayıf Yön	Kullanım Alanı
<i>RNN / LSTM</i>	Sekans modeli	Basit yapı	Uzun bağımlılıkları modelleme	Metin sınırlı görevler
<i>Transformer</i>	Öz-dikkat mekanizması	Paralel işlem	Yüksek hesaplama maliyeti	NLP, çeviri
<i>LLM (GPT vb.)</i>	Büyük Transformer	Genel amaçlı	Halüsinasyon riski	Chatbot, kod üretimi
<i>Multimodal GenAI</i>	Çoklu veri tipi	Görsel + metin + ses	Karmaşık eğitim	Otonom sistemler

3. Toplumsal Etkiler

Yapay zeka terimi ile toplum arasındaki bağlantı açıkça görülebilir. Bugün itibariyle yapay zeka, hem endüstrilerde hem de

işletmelerde sosyal açıdan son derece önemli bir kelimedir. Yapay zekâ teknolojisi, günümüzde her şeyi ele geçiren dijitalleşme veya dijital dönüşümle ilgili çok önemli bir temel taşıdır. Bazı şirketler, toplanan ve üretilen sürekli artan veri miktarlarından faydalanabilecek şekilde kendilerini konumlandırıyorlar (Nadikattu, 2016). Bazı insanlar akıllı makinelerin bir gün insanları tamamen değiştirebileceğine inanıyor olsa da, iş yerinde akıllı robotların bulunması, insanları tamamen değiştirmek yerine tamamlayan daha güvenli ve verimli çalışma ortamları yaratacaktır. İşlerin tamamen robotlar tarafından yapılması olasılığı konusunda bazı endişeler var; robotlar insanların işlerini ellerinden alacak şekilde düşünülüyor. Öte yandan, robotlar tarafından iş yapılmasına güvenmek, görevlerin türüne göre robotlar veya insan çalışanlar tarafından görevlerin yerine getirilmesinde entegre bir çalışma biçimi sağlamayı ifade eder. Şu anda insanlar, ihtiyaç sahiplerine yardımcı olmak için akıllı makineler yapmak amacıyla yapay zekâ kullanıyorlar (Holt, 2018).

3.1 Yapay Zekanın Toplumdaki Kullanım Alanları

3.1.1 Ekonomi ve İşgücü Piyasası

Yapay zekâ, otomasyon süreçlerini iyileştirerek yeni uzmanlaşmış yetkinlikler yaratıp verimliliği artırabildiği için ekonomik kalkınmada önemlidir. 2024 yılı PwC raporlarında “Yapay zekânın 2030 yılında küresel ekonomiye 15,7 trilyon dolara kadar katkıda bulunabileceğini, bunun da Çin ve Hindistan'ın mevcut toplam üretiminden daha fazla olduğunu” tahmin etmektedir (PricewaterhouseCoopers, 2024). Bu durum, işletmelerin süreçleri otomatikleştirmesi ve mevcut iş gücünü yapay zekâ teknolojileriyle desteklemesi yoluyla elde edilen verimlilik kazanımlarından kaynaklanmaktadır (Smith & Neupane, 2018). Yapay zekâ araçlarının düşük üretim maliyeti, yapay zekâ üretiminin zaman içinde hızla artmasının temel nedenlerinden biridir. Bilgisayar

maliyetlerindeki olağanüstü düşüş, kurulu bilgi işlem gücünde ve depolama kapasitesinde bir patlamaya yol açmıştır. Günümüzdeki basit akıllı telefonlar, ilk insanı aya götüren bilgisayardan önemli ölçüde daha güçlüdür. Örneğin, bir iPhone marka cep telefonunun bir modelinin üretim maliyeti şu anda yaklaşık 220 ABD dolarıdır; 1980'lerde ise yaklaşık 1,2 milyon ABD dolarıydı (Naidu, 2019). Ayrıca, yapay zekanın istihdam üzerindeki etkisini şekillendirmede siyasi, ekonomik ve kültürel unsurların yanı sıra yapay zeka teknolojilerinin yetenekleri ve teknik özellikleri de dahil olmak üzere bir dizi faktör rol oynamaktadır. Disiplinler arası en iyi mevcut araştırma kanıtlarını kullanmak, bu teknoloji destekli değişikliklerin faydalarını toplum genelinde paylaşan politikalar geliştirmeye yardımcı olabilir (G7 Bilim Akademileri, 2019). Bu nedenle, yapay zeka araçlarının üreticileri arasında işgücü piyasalarında kâr oranlarını artırmak için yüksek bir rekabet vardır. Bununla birlikte, ortaya çıkan eşitsizlik ırk, sınıf ve cinsiyet çizgileri boyunca orantısız bir şekilde düşebilir; bu tür eşitsizliğin ekonomik ve toplumsal etkisini öngören araştırmalar faydalı olabilir (Russell, Dewey & Tegmark, 2015).

3.1.2 Sanayi ve Tarım

Yapay zekâ programları, üretim sürecinde ve birçok endüstride önemli bir role sahiptir,

çünkü birçok görevi verimli ve hızlı bir şekilde gerçekleştirmek üzere etkili bir şekilde programlanmışlardır.

Bu nedenle, yapay zekâ programları, yüksek verimlilikle zaman ve emekten tasarruf sağlar, bu da üretim maliyetini düşürerek finansal kâr artırır. Sektörün, politika yapıcılarının doğru mevzuatları geliştirmelerini sağlamak için bu yönergeler üzerinde bir fikir birliğine varması gerekir. Bu nedenle, özellikle kullanıcı gizliliğiyle ilgili olan ve ihlal edenleri cezalandıran yapay zekâ araçlarının

kullanımıyla ilgili net yönergeler ve mevzuatların belirlenmesi gereklidir.

Gelecekte yapay zekâ kullanımında artış olacağından, yapay zekâ için uygun yasa ve kontrol mekanizmalarına ihtiyaç vardır. Küresel Güney'deki birçok ülkede, tarım ekonominin önemli bir bileşenidir ve nüfusun büyük bir kısmı gıda kaynağı olarak tarıma bağımlıdır. Ancak, sağlıklı ürünler ve başarılı hasatlar hastalıklara, böceklerle ve kuraklığa kurban gidebilir. Dahası, Küresel Güney ülkeleri, tarım yöntemlerindeki gelişmelere rağmen, hala büyük ölçüde geleneksel tarıma bağımlıdır; çiftçiler modern tarım yöntemleri yerine manuel iş gücüne güvenmektedir (Smith & Neupane, 2018). Görüntü tanıma gibi bilişsel hesaplama teknolojilerinin doğruluğunun artması tarımı değiştiriyor. Geleneksel olarak, tarım, doğru ürünleri belirlemek için deneyimli çiftçilerin gözlerine ve ellerine dayanıyordu. Bu nedenle, yapay zekanın tarıma girişi, tarım ürünlerinin verimliliğini artırarak büyük bir sıçrama sağladı; çünkü yapay zeka, robotların girişiyle çiftçilerin işini kolaylaştırıyor. Yapay zeka teknolojileri ve kameralardan ve sensörlerden gelen verilerle donatılmış "hasat" robotları artık bu kararı gerçek zamanlı olarak verebiliyor. Bu tür robotlar, daha önce insan emeği ve bilgisi gerektiren görevleri giderek daha fazla yerine getirebiliyor (OECD, 2019).

3.1.3 Eğitim ve İnovasyon

Yapay zekâ sistemlerinin rolü, uzaktan eğitim yoluyla eğitim sürecinde ortaya çıkmaktadır; bu nedenle yapay zekâ destekli müfredat planları, sistematik ve yapılandırılmış bir eğitim biçimi sağlayan yapay zekâ sistemlerinin temelleri üzerine inşa edilmiştir.

Genellikle "müfredat listeleri" olarak adlandırılan yapay zekâ destekli müfredat planları ve akıllı öğretim sistemleri, gençlere kişiselleştirilmiş öğrenme deneyimleri sunarak, öğretimi ve geri

bildirimi öğrencilerin yeteneklerine ve ihtiyaçlarına göre uyarlamaktadır. Sistem, her öğrenci için günlük bireyselleştirilmiş öğrenme etkinliklerini müfredata dayalı olarak düzenlerken, ikincisi insan öğretimini taklit etmeyi amaçlayan bire bir özel ders yoluyla sunulmaktadır (Hasse vd., 2019). Lise mezuniyeti, nispeten daha yüksek genel yaşam boyu kazanç ve yaşam beklentisi ile daha düşük işsizlik ve hapis oranlarıyla ilişkilidir. Ancak, bazı üniversite mezunlarının iş piyasasında fırsat bulamayabileceği durumlar vardır; bu nedenle, bu sorun, yapay zeka sistemlerinin öğrencilerden veri toplayarak ve onlara iş piyasasında iş fırsatı olan belirli üniversite bölümlerini okumaları konusunda tavsiyelerde bulunarak bir denge oluşturmasını gerektirir. Bu sistemler, farklı akademik disiplinler arasında denge kurmanın yanı sıra, eğitim girdilerini ve çıktılarını iş piyasasının gereksinimlerini karşılayacak şekilde birbirine bağlayabilme yeteneğine de sahiptir. Müdahaleler, eğitim hedeflerinde geride kalanlara yardımcı olabilir, ancak sınırlı kaynaklar göz önüne alındığında, bu tür programlar doğru zamanda doğru öğrencilere ve doğru mesajla odaklanmalıdır. Son birkaç yıldır, ABD genelindeki birçok okul bölgesi, lise eğitimini zamanında bitirme olasılığı düşük olan risk altındaki öğrencileri belirlemelerine yardımcı olmak için yapay zeka tabanlı sistemler geliştirmek üzere üniversitelerle işbirliği yapmaktadır (Hager vd., 2017). Bazı yapay zeka programları, performans hızı açısından yüksek verimliliğe sahiptir ve bu da onları insan performansından daha iyi performans göstermeye itmektedir. İnsan iş gücünün aynı görevleri yapabilme yeteneğine rağmen, bazen insanlar aynı hıza sahip olmayabilir veya çalışanlar görevleri aynı sürede tamamlasalar bile, büyük fabrikalardaki akıllı makinelerle aynı kalitede iş yapmamış olabilirler. Ayrıca, yapay zekâ teknolojisi (robotlar), bir insanın gerçekleştiremeyeceği büyük miktarda veriyi işleyen akıllı makineleri içerir.

3.1.4 Sağlık ve Çevre

Yapay zekâ, sağlık ve bakımda karar verme süreçlerini destekleyen sistemlerde önemli potansiyel faydalar sunmaktadır. Bu alandaki yapısal sorunlar, tanı hatalarına, uzmanlığın olası başarısızlığına ve araştırmacılar, mühendislik ve klinik dünyalar arasında bilgi iletişiminin verimsizliğine yol açabilir. Birçok yapay zekâ tıbbi cihazı, hastalığı teşhis etmek için hastanın semptomlarını sormaya dayanan geleneksel tıbbi muayenelerden daha doğru bir şekilde hastalıkları tespit edebilir ve teşhis edebilir; modern yapay zekâ cihazları ise hastanın durumunu doğru bir şekilde teşhis etmenin yanı sıra birçok yeni ortaya çıkan hastalığı da tespit edebilir. Yapay zekâ, çok sayıda araştırma yayınını değerlendirmeye, büyük veri kümelerinde olası olmayan, zayıf korelasyonları tespit etmeye, sağlık sistemleri tarafından üretilen görüntüleri ve diğer verileri analiz etmeye ve yeni teknolojiler geliştirmeye yardımcı olabilir (G7 Bilim Akademileri, 2019). Sağlık ve ilaç sektöründeki yapay zekâ uygulamaları, sağlık durumlarını erken teşhis etmeye, önleyici hizmetler sunmaya, klinik karar verme süreçlerini optimize etmeye ve yeni tedaviler ve ilaçlar keşfetmeye yardımcı olabilir. Yapay zekâ uygulamaları yalnızca hastalık vakaları için doğru teşhis sağlamakla kalmaz, aynı zamanda uygun reçeteleri de sağlar. Kişiselleştirilmiş sağlık hizmetlerini ve hassas tıbbi kolaylaştırabilir, aynı zamanda kendi kendini izleme araçlarına, uygulamalarına ve takip cihazlarına güç sağlayabilir. Sağlık hizmetlerinde yapay zeka, bakım kalitesi ve maliyeti açısından potansiyel faydalar sunmaktadır (OECD, 2019).

Yapay zekanın çevre alanına girişi, kasırgalar ve orman yangınları gibi çevresel felaketler sırasında alınacak önleyici ve koruyucu önlemlerin yanı sıra bu tür durumlarda nasıl davranılacağına dair bilgi sağlamaya yardımcı olmuştur. Yapay zeka, örneğin, uzman sistemlerin acil müdahale ekiplerine endüstriyel kazalarla nasıl başa çıkılacağı konusunda tavsiyelerde bulunması,

tehlikeli atık sahası izinlerinin verilmesinde uzman sistemlerin kullanılması, su kalitesi modellemesi, balık stoğu tahmini ve diğer birçok çevre mühendisliği uygulamasında olduğu gibi çevre yönetimi sorunlarına uygulanmıştır.

3.2 Yapay Zekanın Toplumun Çeşitli Sektörlerindeki Avantajları

Prensip olarak, algoritmalar ve alana özgü yapay zekâlar birçok avantaj sağlar. Algoritmalar, yapay zekâ sistemlerinin geliştirilmesinde önemlidir ve avantajları, her yeni yapay zekâ sistemi güncellemesiyle önceki sürümlerin daha iyi versiyonlarını oluşturarak sistemlerin sürekli gelişmesiyle artmaktadır. Yaşamlarımızı daha iyi yönde etkilediler ve gerekli önlemler alındığı takdirde gelecekte de giderek artan bir oranda etkilemeye devam etmeleri bekleniyor (Mannino vd., 2015). Yapay zekâ, iş yerinin verimliliğini önemli ölçüde artıracak ve belki de insanlar tarafından yapılan işi destekleyecektir. Yapay zekânın iş alanına girmesinin avantajlarından biri, insan çalışanlar ve yapay zekâ sistemleri arasında iş ortamında rekabet olmasıydı; bu rekabet, yapay zekâ sistemlerinin performansına kıyasla insan çalışanların performans verimliliğini göstererek işletmeler için verimlilik oranlarının artmasına yol açtı. Yapay zekâ tehlikeli ve tekrarlayan görevleri devraldıkça, manuel iş gücünü serbest bırakarak insanların empati ve yaratıcılık gibi kendileri için daha uygun olan diğer işlere aynı titizliği uygulayabilmelerini sağlar. İnsanlar daha ilgi çekici pozisyonlarda çalışmalıdır; bu da iş memnuniyetini ve mutluluğu artıracaktır (Nadikattu, 2016).

3.3 Yapay Zekanın Toplumun Çeşitli Sektörlerindeki Dezavantajları

Yapay zekânın insan deneklerin yerini almasıyla ortaya çıkan genel sorun, insanların işsiz kalmasıdır. Yapay zekâ kullanan

şirketler, birlikte çalıştıkları insan denek sayısını azaltmaya güvenmektedir. Çalışanların yapay zekâ sistemleriyle değiştirilmesi fikri, birçok durumda olası bir durumdur, çünkü bazı çalışanların işini kaybetmesine neden olan bir sorun olarak kabul edilmektedir. Bir yandan, çalışanlar işten çıkarıldıktan sonra alternatif bir çözümün olmaması söz konusudur. Öte yandan, şirketlerin aynı işleri yapma fırsatları da mevcuttur ve bu işten çıkarılan çalışanlar yerine yapay zekâ sistemlerini kullanmaktadırlar. Bu nedenle, durum, bu tür şirketler tarafından sunulabilecek farklı istihdam fırsatlarından yararlanma şansına sahip insan sayısını azalttığı gerçeği göz önüne alındığında, bazı büyük sorunları beraberinde getirmektedir (Nadimpalli, 2017). İnsan topluluğunda yaşam biçimini alt üst eden büyük bir sosyal değişim meydana gelecektir. İnsanlığın geçimini sağlamak için çalışkan olması gerekiyor, ancak yapay zekanın hizmetiyle, bir alet bile kaldırmadan makineyi bizim için bir şey yapması için programlayabiliyoruz İnsan yakınlığı giderek azalacak, çünkü yapay zeka, fikir alışverişi için insanların yüz yüze görüşme ihtiyacını ortadan kaldıracak. Yapay zeka insanlar arasında yer alacak, çünkü kişisel buluşma artık iletişim için gerekli olmayacak.

Yapay zeka sistemlerinin toplumda yarattığı dezavantajlardan biri, gerçekçi yüz yüze sosyal etkileşimin yokluğuyla ilişkili sosyal medya sessizliği olgusudur. Dahası, bu olgu birçok kamusal alanda sık sık gözlemleniyor; burada birkaç kişi bir arada oturuyor ancak akıllı telefonlarıyla meşguller ve birbirleriyle konuşuyorlar. Sosyal medya veya diğer insanlarla sanal olarak sohbet etmek. Bu sadece kafeler gibi halka açık yerlerde değil, aynı zamanda aile üyelerinin aynı odada birlikte oturduğu evlerde de mevcuttur; ancak birbirleriyle konuşmazlar, ama sosyal medya aracılığıyla diğer insanlarla konuşurlar. Dolayısıyla, sosyal medya dünyayı küçük bir köye dönüştürürken, diğer yandan aynı evi veya hatta aynı odayı paylaşan, aslında birbirine yakın olan insanlar

arasında bir mesafe yaratmaktadır. Bazı makaleler sosyal ve teknik arasındaki ilişkiyi ele almış olsa da, her alandaki sorunları belirlemenin ötesine nadiren geçmişlerdir. Bu nedenle, çabalar bütüncül ve kapsamlı bir çözüme ulaşamamıştır. Bazı araştırmacılar bunu teknik bir olgu olarak görmekte ve teknolojide çözümler aramaktadır (Dolata, Feuerriegel & Schwabe, 2021).

3.4 Yapay Zekanın Toplumda Karşılaştığı Zorluklar

Yapay zekâ, çeşitli nitelikteki farklı toplanmış bilgileri analiz edebilir. Bu durum, veri koruma, siber güvenlik ve veri gizliliği konusunda büyük endişelere yol açmıştır (Majumdar & Chattopadhyay, 2020). Yapay zekânın karşılaştığı zorluklardan biri, gizlilik ihlali ve müşterilerin kişisel verilerinin gizliliği ve korunması konusundaki endişeleridir. Yapay zekânın sektörler, toplumlar ve ekonomiler genelinde büyümesi, karmaşık ve birbirine bağlı zorlukları beraberinde getirir ve bu zorluklar, Asya-Pasifik politika yapımcılarının yapay zekâyâ yönelik ulusal yaklaşımlarını tanımlarken ve çerçeveselendirirken ön planda tuttukları dört yapay zekâ "konusu" altında toplanabilir: Altyapı, Verilere erişim, Beceriler ve insan sermayesi, Güven ve ortaklıklar ve Ekosistem ve girişimcilik (International Institute of Communications, 2020). Stanford çalışmasının gösterdiği yapay zekâ yetenekleri, yapay zekânın gizliliği nasıl tehdit edebileceğine dair bir fikir vermektedir: hem yaygın veri toplama hem de özneleri anonimlikten çıkarma kapasitesi yoluyla. Sonuç olarak, bu endişeler yakın zamanda insan hakları örgütleri Article 19 ve Privacy International tarafından hazırlanan bir raporda belgelenmiştir ve raporda şu ifade yer almaktadır: “Yapay zekâ destekli tüketici ürünleri... sıklıkla, yakınındakilerin bilgisi veya rızası olmadan büyük miktarda veri üreten ve toplayan sensörlerle donatılmıştır.

Yapay zekâ sistemlerini karakterize eden yüksek verimlilik ve performans kalitesine ek olarak, örneğin insanlardan farklı olarak, bilgisayarlar hafızalarının tüm içeriğini saniyeler içinde diğer bilgisayarlarla paylaşabilmektedir. Böylece yapay zekâ ile öğrenme dağıtılabilir (Ertel, 2019). Yapay zekâ odaklı teknolojiler, sosyal bölünmeleri derinleştirme ve özellikle tarihsel olarak marjinalleştirilmiş gruplar arasında sosyal eşitsizliği artırma eğilimindedir (Hagerty & Rubinov, 2019). Bu marjinalleşme, gelişmiş ülkeler ile yapay zekâ araçları üretme veya hatta satın alma yeteneğinden yoksun gelişmekte olan ülkeler arasında açıkça görülmektedir. Yapay zekâ teknolojisinin eğitim ve öğrenme için kullandığı veriler, insan davranışının tüm yönlerini kapsamamaktadır. Zekâ, ister insan ister makine olun, öğrenmeden gelir. Sistemler genellikle doğru kalıpları tespit etmeyi ve girdilerine göre hareket etmeyi "öğrendikleri" bir eğitim aşamasına sahiptir (Hussein vd, 2020).

Yapay zekâ sistemlerinin karşılaştığı bir zorluk, statik çözümlerle belirli bir sisteme göre programlanmaları nedeniyle insanların sosyal davranışlarını tahmin edememeleridir. Birçok durumda bireylerin veya müşterilerin davranışları dinamik bir çözüm veya davranış gerektirirken, robotlar beklenmedik tepkilerine rağmen insanlarla aynı şekilde ilgilenir. Bir yapay zeka projesinin tasarım ve uygulama aşamaları arasında genellikle bir kopukluk vardır. Bu, özellikle sistemin insani yardım bağlamlarında uygulanması gerekiyorsa kritik öneme sahiptir. Araçlar yeterli bağlamsal bilgi olmadan tasarlanabilir; genellikle gelişmekte olan dünyada insani yardım için değil, iş ve pazarlama karar verme süreçleri için uygun olacaktır.

4. Akademik Etkiler

Yükseköğretimde, ChatGPT gibi Büyük Dil Modelleri de dahil olmak üzere Üretken Yapay Zeka (GenAI) teknolojilerinin yaygınlaşması, benzersiz fırsatlar ve zorlu zorluklar sunmaktadır. GenAI kişiselleştirilmiş eğitim deneyimleri yoluyla öğrenmeyi önemli ölçüde geliştirirken, bu teknolojiler özgünlük ve etik öğrenci davranışı gibi akademik dürüstlüğün temel ilkelerine önemli riskler oluşturmaktadır.


4.1 Yükseköğretimde GenAI'ye İlişkin Görüşler

Yükseköğretimde, özellikle de Öğretim ve Öğrenme alanında, paydaşların GenAI'ye ilişkin algıları oldukça karışıktır. Eğitim süreçlerini geliştirme potansiyeli yaygın olarak kabul edilse de, paydaşlar GenAI'nin benimsenmesi konusunda temkinli ve zaman zaman şüphecidirler. Literatür, öğrencilerin, eğitmenlerin ve kurumların GenAI'nin etkinliği ve eğitim ortamlarına entegrasyonunun karmaşıklığı konusunda farklı bakış açılarına sahip olduğunu ortaya koymaktadır. Bu bölüm, eğitmenlerden başlayarak bu bakış açılarını ele almaktadır.

4.1.1 Öğretmenlerin Görüşleri

Eğitmenlerin görüşü Şekil 2'de görüldüğü gibi genel olarak olumlu/destekleyici ve olumsuz/eleştirel olmak üzere iki kategoriye ayrılır.

Şekil 2. Eğitimde Üretken Yapay Zekâ Algı Modeli.



Olumsuz algılar çoğunlukla akademik dürüstlük ve yapay zekanın eğitim bağlamlarındaki istenmeyen sonuçlarına ilişkin endişelerden kaynaklanmaktadır. Öğitmenler ayrıca, güvenilirlik, inanılabilirlik ve bağımsız düşünme ve yaratıcılığı aşındırma potansiyeli gibi sınırlamaları gerekçe göstererek, yapay zekanın etik, pedagojik ve epistemolojik etkileri konusunda da endişelerini dile getirmektedir (Barrett & Pack, 2023; Chan, 2023). Özellikle yapay zeka tarafından üretilen içerikte intihal, yanlış bilgilendirme ve önyargı gibi etik dışı kullanımlardan çekinmektedirler (Barrett & Pack, 2023; Singh, 2023). Öğrencilerin haksız akademik avantaj elde etmek için yapay zekayı istismar edebileceği ve bunun da eleştirel düşünme ve bağımsız öğrenmenin gelişimini baltalayabileceği konusunda artan bir endişe vardır (Chan & Lee, 2023). Dahası, kurumsal politikaların, resmi eğitimin ve pedagojik rehberliğin olmaması gibi uygulama zorlukları, öğretmenlerin çekincelerini daha da artırmaktadır. Bu endişelere rağmen, literatürdeki fikir birliği ihtiyatlı bir iyimser duruşu yansıtmaktadır. Öğitmenler, GenAI'nin öğretim verimliliğini artırma, tamamlayıcı

bir kaynak olarak işlev görme, kapsayıcı ve etkileşimli öğrenmeyi teşvik etme ve değerlendirme ve geri bildirim süreçlerinde nesnellik sunma potansiyelini takdir etmektedir (Cox vd., 2024; Eager & Brunton, 2023). GenAI'nin eğitim içeriği oluşturmayı kolaylaştırma ve ders planlamasını destekleme yeteneği özellikle değerlidir ve eğitimcilerin odaklarını daha etkileşimli, yüksek etkili pedagojik faaliyetlere kaydırmalarını sağlar (Van den Berg & du Plessis, 2023; Shimizu vd., 2023). Yaygın olarak belirtilen bir avantaj, GenAI'nin ders etkinliklerinin ve değerlendirme görevlerinin tasarımını destekleme hızı, tutarlılığı ve nesnelligidir (Almasre, 2024; Jackaria vd., 2024).

Eğitimciler, GenAI'nin idari görevler ve kaynak oluşturma gibi tekrarlayan ve zaman alan sorumlulukların yükünü hafifletebileceğini ve böylece öğretmenlerin zamanını öğrencilerle daha derinlemesine etkileşime ayırmalarına olanak sağlayabileceğini belirtiyor. Bu karmaşık algılar, GenAI hakkında bilgi eksikliğinden ve GenAI'nin uygulanmasına yönelik yetersiz resmi rehberlik veya yapıdan kaynaklanıyor olabilir. Birçok eğitimci GenAI'nin pedagojik uygulamada devrim yaratma kapasitesini kabul etse de (Eager & Brunton, 2023; Singh, 2023), literatür, öğretmenleri gelişen yapay zeka odaklı eğitim ortamlarına uyum sağlamak için gereken yetkinliklerle donatmak için sürekli mesleki gelişime kurumsal yatırımın şart olduğunu güçlü bir şekilde öne sürmektedir.

4.1.2 Öğrencilerin Görüşleri

Öğrencilerin yapay zekaya ilişkin görüşü olumlu ve coşkulu olmaktan eleştirel ve şüpheli olmaya kadar değişmekte olup, bazıları da yapay zeka alanında yol almanın öğrenme deneyimlerini geliştireceğine dair pragmatik bir bakış açısı sergilemektedir. İncelenen çalışmalar, öğrencilerin eğitim ortamlarında GenAI'yi nasıl algıladıkları ve onunla nasıl etkileşim kurdukları konusunda

dikkat çekici bir kuşak ayrımı ortaya koymaktadır. Daha eski kuşaklara kıyasla, Z kuşağı öğrencileri GenAI'nin potansiyel faydaları konusunda daha olumlu görüşlere sahip olma ve daha fazla iyimserlik sergileme eğilimindedir (Chan & Lee, 2023). Dijital yerliler olarak, bu kuşak özellikle yeni teknolojilere açıktır ve GenAI'yi üretkenliği, verimliliği ve kişiselleştirilmiş öğrenmeyi artırmak için bir araç olarak benimseme olasılığı daha yüksektir (Chan & Hu, 2023; Lee vd., 2023). Z kuşağının olumlu algısını şekillendiren ayırt edici bir özellik, GenAI'nin konuşma arayüzüdür; bazı öğrenciler bu aracın onlara bir tür sosyal destek sunduğunu iddia etmektedir. Okuma ve yazma gibi yalnız akademik görevleri daha etkileşimli hale getirme yeteneği, cazibesine katkıda bulunmaktadır (Yang vd., 2024). Öğrenciler, teknik olanaklarını takdir etmenin yanı sıra (Chan & Hu, 2023), GenAI'nin birçok disiplindeki pratik faydasını da belirtiyorlar (Kelly vd., 2023). Bu avantajlara rağmen, Z kuşağı öğrencileri genel olarak GenAI'yi insan öğretmenlerin yerine geçecek bir şey olarak görmüyor ve yapay zekanın öğretmenlerin pedagojik rolünün yerini almaktan ziyade tamamlayacağına olan güvenlerini dile getiriyorlar (Chan, 2023). Buna karşılık, olgun ve daha yaşlı öğrenciler GenAI'ye daha fazla temkinli yaklaşma eğilimindedir. Şüphelicilikleri sıklıkla etik kaygılardan kaynaklanmaktadır; bunlar arasında yapay zekanın değerlendirmelerde kötüye kullanılmasıyla ilişkili intihal ve akademik dürüstlük ihlalleri hakkındaki endişeler yer almaktadır (Barrett & Pack, 2023). Bu öğrenciler için, GenAI'nin öğretim ve öğrenmede benimsenmesi gizlilik, şeffaflık ve sosyal eşitlikle ilgili daha geniş etik soruları gündeme getirmektedir (Chan, 2023). Bu kaygılar, GenAI'nin yanlış veya taraflı içerik veya sözde "halüsinasyonlar" üretme eğilimi ve duygusal zekâ ve bağlamsal duyarlılık eksikliği gibi bilinen sınırlamalarıyla daha da artmaktadır (Chan & Lee, 2023). Yapay zeka tarafından üretilen çıktılardaki

yüzeysellik algısı bu şüpheciliği daha da güçlendirmektedir. Bazı öğrenciler GenAI'nin yanıtlarını aşırı genel, doğrulanması zor ve ileri düzey akademik görevler için gerekli entelektüel derinlikten yoksun olarak değerlendirmektedir (Chan & Hu, 2023; Šedlbauer vd., 2024). Dahası, öğrenciler arasında GenAI'ye aşırı güvenmenin eleştirel düşünmeyi azaltabileceği, yaratıcılık fırsatlarını kısıtlayabileceği ve nihayetinde uzun vadeli istihdam edilebilirliği olumsuz etkileyebileceği konusunda artan bir farkındalık vardır (Chan & Hu, 2023; Yang vd., 2024). Öğrencilerin iyimser ve şüpheci görüşlerine ek olarak, üçüncü bir öğrenci algısı kategorisi, yükseköğretimde GenAI kullanımına yönelik pragmatik bir duruş sergiler. Bu bakış açısı, coşku ve temkinlilik arasında kavramsal bir kesişim noktasında yer alır: Bu gruptaki öğrenciler, GenAI'nin pratik faydalarını kabul ederken sınırlamalarının da farkındadırlar. GenAI'yi, zenginleştirilmiş öğrenme deneyimleri için etkili bir şekilde kullanılabilmesi için rehberlik, eleştirel düşünme ve işbirlikçi katılım gerektiren destekleyici bir araç olarak görürler (Chan & Hu, 2023; Yang vd., 2024). Bu pragmatik yönelim, genellikle yeni teknolojileri keşfetme ve GenAI'yi yapıcı bir şekilde kullanmak için gerekli teknik yetkinlikleri geliştirme isteğiyle birlikte gelir (Yang vd., 2024). Bu kategorideki öğrenciler, daha fazla sorumluluk ve öğrenmeye yönelik proaktif bir yaklaşım sergileme eğilimindedirler. Özellikle, önceden konuyla ilgili bilgi sahibi olmasalar bile, bu öğrenciler GenAI'yi anlayışlarını desteklemek ve öğrenme sürecine anlamlı katkıda bulunmak için kullanabilirler (Cox vd., 2024). Bu ortaya çıkan eğilim, GenAI'nin deneyimsel ve katılımcı öğrenmeyi destekleme potansiyelini vurgulayarak, öğrencilere bilgi oluşturma ve akademik içerikle daha aktif bir şekilde etkileşim kurma konusunda uygulamalı fırsatlar sunmaktadır.

4.1.3 Kurumsal Görüşler

Kurumsal bakış açıları, GenAI'yi öğretim ve öğrenmeye entegrasyonuna rehberlik edecek stratejik çerçevelere duyulan kritik ihtiyacı vurgulamaktadır. Literatür, yükseköğretim kurumlarının genel yapay zekayı benimsenmesiyle ilişkili hem fırsatları hem de zorlukları ele alan kapsamlı politikalar geliştirerek proaktif liderlik rolleri üstlenmeleri gerektiğini öne sürmektedir. Örneğin, hem öğrenciler hem de eğitimciler için açık yönergeler, eğitim girişimleri ve etik protokoller oluşturmak, akademik ortamlarda genel yapay zekayı çevreleyen kaygı ve belirsizliği hafifletmek için elzem olarak kabul edilmektedir (Barrett & Pack, 2023). GenAI'nin gelişen doğası göz önüne alındığında, öğrenciler ve öğretmenler tarafından öğretim ve öğrenmede potansiyel kötüye kullanımı, özellikle akademik dürüstlük konusunda dile getirilen endişeler, kurumsal müdahalelere duyulan ihtiyacın altını çizmektedir. Bunlar arasında esnek bir resmi politika ve paydaşları etik karmaşıklıklarda yol almak ve suistimal risklerini azaltmak için gerekli becerilerle donatmak üzere tasarlanmış GenAI okuryazarlığı programlarının uygulanması yer almaktadır (Chan, 2023). Sonuç olarak, bu durum, eğitim bağlamlarında GenAI'nin sorumlu, şeffaf ve pedagojik açıdan sağlam kullanımını teşvik etmeye yönelik kurumsal bağlılığı yeniden teyit edecektir.

4.2 Akademik Dürüstlük: Dürüstlük ve Etik Sorunlar

Eğitimde GenAI üzerine yapılan literatürde intihal ve etik ihlal endişeleri tekrar eden bir temadır. Hem öğrenciler hem de eğitimciler, ödevleri uygun atıfta bulunmadan tamamlamak için GenAI araçlarının kullanımından rahatsızlık duymaktadır. (Barrett & Pack 2023), kurumların yazma görevlerinde GenAI'nin açıklanmadan kullanımını akademik dürüstlüğün ihlali olarak ele alması gerektiğini savunmaktadır. Bu tür olaylardaki artış, net

kurumsal politikaların eksikliğiyle birleştğinde sorunu daha da kötüleştirmektedir (Kaplan-Rakowski vd., 2023). Bu riskleri azaltmak için Chan (2023), veri gizliliği, algoritmik şeffaflık ve güvenliği kapsayan sağlam risk yönetimi çerçevelerini savunmaktadır. Öğrencilerin GenAI'yi sorumlu bir şekilde kullanma konusundaki güvenleri deneyimle birlikte artabilirken, kabul edilebilir kullanımı açıklayan ve atıfta bulunmanın ve eleştirel katılımın önemini pekiştiren kurumsal rehberliğe acil bir ihtiyaç vardır (Kelly vd., 2023).

5. Teknolojik Etkiler

5.1 Yazılım Geliştirmede Üretken Yapay Zekanın Durumu

GenAI'nin hızlı gelişimi, SDLC genelinde yazılım geliştirme uygulamalarını giderek daha fazla dönüştürüyor. Yapay zeka destekli geliştirme araçları arasında, ChatGPT gibi konuşma tabanlı dil öğrenme ortamları ve GitHub Copilot, Amazon CodeWhisperer, JetBrains AI Assistant ve Tabnine gibi doğrudan geliştirme ortamına entegre edilmiş asistanlar yaygın olarak benimsenmiş ve kod üretimi, açıklama ve inceleme gibi görevleri desteklemektedir. (Sergeyuk vd., 2025). Ampirik çalışmalar ve saha araştırmaları, geliştirme faaliyetlerinde sürekli olarak verimlilik artışları bildirmektedir; özellikle kod optimizasyonunda (%60 civarında), hata düzeltmede (%26) ve dokümantasyon desteğinde (%12) (Collante vd., 2025). Kanıtlar ayrıca, daha az deneyimli geliştiricilerin yapay zeka desteğinden orantısız bir şekilde faydalandığını ve daha yüksek göreceli verimlilik iyileştirmeleri elde ettiğini göstermektedir (Brynjolfsson vd., 2023; Dell'Acqua vd., 2023; Ng vd., 2024). Aynı zamanda, çalışmalar, geliştirme süresinin azalmasına rağmen kod kalitesinin genellikle istikrarlı kaldığını veya iyileştiğini göstermektedir (Shihab vd., 2025; Yadav & Mondal, 2025). Bununla birlikte, doğruluk garanti edilemez ve

uzun vadeli riskler devam eder; bu da insan doğrulaması ve denetimini elzem kılar. Bireysel verimliliğin ötesinde, sektör raporları, hızlandırılmış prototipleme, daha kısa pazara giriş süresi ve sorumluluğun ürün ve proje liderliğine kaydırılması da dahil olmak üzere daha geniş organizasyonel etkileri vurgulamaktadır (Karaci Deniz vd., 2023; Gnanasambandam vd., 2025). Aşağıdaki alt bölümler, çevik yazılım geliştirmenin yanı sıra GenAI'nin benimsenmesiyle ilişkili riskleri ve engelleri ele almadan önce, SDLC'nin aşamaları boyunca literatürü sentezlemektedir.

5.1.1 Planlama

Planlama aşamasında, GenAI, kapsam tanımları, zaman çizelgeleri, kilometre taşı yapıları, rol tanımları, iletişim planları ve risk değerlendirmeleri gibi temel proje unsurlarının oluşturulmasını destekler (Barcaui & Monat, 2023; Maggoo vd., 2025). Yapay zeka sistemleri ayrıca pazar analizleri yapmak, rekabetçi bilgileri sentezlemek ve ürün hedefleri ve vizyonlarını formüle etmek için de kullanılır (Dell'Acqua vd., 2023). Maliyet tahmini ve hikaye puanı yaklaşımı da uygulama alanları olarak araştırılmıştır (Wagner ve Wagner, 2024). Bulgular, proje başlatma ve planlama sırasında önemli verimlilik kazanımları olduğunu göstermektedir; bunlar arasında yeni projelerin daha hızlı kurulması ve teknik ekipler ile yönetim arasında daha iyi uyum sağlanması yer almaktadır (Brynjolfsson vd., 2023). GenAI genellikle yapılandırılmış istemler aracılığıyla kullanılır ve giderek Jira, Confluence veya Microsoft Project gibi proje yönetim araçlarına entegre edilmektedir. Bu yetenekler, risklerin erken tespitine ve yapılandırılmış proje hazırlığına katkıda bulunur.

5.1.2 Tasarım ve Uygulama

Tasarım ve uygulama aşaması, GenAI için en kapsamlı şekilde incelenen uygulama alanını temsil etmektedir. GitHub

Copilot gibi yapay zeka destekli kodlama araçları, gerçek zamanlı kod tamamlama, yeniden düzenleme önerileri, şablon oluşturma ve bağlam duyarlı optimizasyon sağlar. Ayrıca, kod yorumları ve API dokümantasyonu dahil olmak üzere otomatik dokümantasyon oluşturmayı ve kod yapısını ve sürdürülebilirliğini iyileştirmeye yönelik önerileri destekler. Deneysel ve saha çalışmaları, geliştirme hızında sürekli bir artış olduğunu bildirmektedir. Özellikle rutin görevler etkilenmekte olup, otomasyon standartlaştırılmış kodlama faaliyetleri için manuel çabayı azaltmaktadır. Birkaç analiz ayrıca inceleme verimliliğinde ve hata azalmasında iyileşmeler olduğunu göstermekte, ancak insan gözetimi esas olarak kalmaktadır (Collante vd., 2025) Uygulama tipik olarak Visual Studio Code veya IntelliJ gibi Entegre Geliştirme Ortamlarına (IDE'ler) entegrasyon yoluyla gerçekleşir; veri koruma ve uyumluluk gereksinimlerini karşılamak için genellikle güvenli API'ler veya izole modellerle birleştirilir.

5.1.3 Test ve Entegrasyon

Test ve entegrasyon aşamasında, GenAI, birim, entegrasyon ve uçtan uca test senaryolarını otomatik olarak oluşturmak için kullanılır (Atif vd., 2025). Ek uygulamalar arasında sahte nesnelerin ve sentetik test verilerinin oluşturulması, eksik test yolları ve kapsama boşlukları için öneriler ve yapay zeka destekli güvenlik analizi yer almaktadır. Literatürde, rutin senaryolar için manuel test çabalarında azalma ve daha geniş, daha hızlı test kapsamı ile uç durumların ve entegrasyon sorunlarının daha erken tespiti belgelenmiştir. Uygulamada, GenAI genellikle CI/CD işlem hatlarına entegre edilir ve test çerçevelerine bağlanır veya otomatik kod analizi ve test senaryosu oluşturma için doğrudan geliştirme ortamlarına yerleştirilir.

5.1.4 İşletme ve Bakım

Operasyon ve bakım aşamasında GenAI, logların, hata mesajlarının ve yığın izlerinin analizini destekleyerek tanısal bilgiler sağlar ve öğrenilen kalıplara dayalı potansiyel iyileştirme adımları önerir. Ayrıca, yetersiz belgelenmiş veya karmaşık eski kodları açıklamak, özetlemek ve yeniden yapılandırmak için kullanılır, böylece bakım kolaylığını ve bilgi aktarımını iyileştirir (Atif vd., 2025). Bildirilen etkiler arasında daha hızlı sorun tespiti ve çözümü, iyileştirilmiş izlenebilirlik ve otomatikleştirilmiş dokümantasyon ve bilgi koruma sayesinde personel değişimine karşı artırılmış dayanıklılık yer almaktadır. Entegrasyon genellikle Jira, ServiceNow veya Grafana gibi olay ve kayıt yönetimi platformlarında ve hassas ortamlarda yerel olarak dağıtılan veya erişim kontrollü yapay zeka sistemleri aracılığıyla uyumluluk risklerini azaltmak için gerçekleşir.

5.2 Siber Güvenlikte Üretken Yapay Zeka Devrimi

Etkin siber güvenlik önlemleri arasında güvenlik duvarları, şifreleme, çok faktörlü kimlik doğrulama ve sık yazılım güncellemeleri yer almaktadır. Siber güvenlikte GenAI kullanımı, özellikle ChatGPT'nin yükselişiyle birlikte dikkat çekmektedir. Genel olarak, GenAI çeşitli sektörlerde ve yaşamımızın çeşitli yönlerinde devrim yaratabilir. Ancak, bu teknolojiyle ilişkili zorlukların ve risklerin ele alınması, sorumlu ve sürdürülebilir bir kullanım sağlamak için çok önemlidir. Bazıları GenAI'yi faydalı, bazıları ise zararlı olarak görmektedir, çünkü tehdit aktörleri siber saldırılarda kullanmaya başlamıştır (Sai vd., 2024). Siber güvenlik alanı, GenAI'nin daha önemli bir olumlu etki göstermeye başladığı BT sektörünün hayati alanlarından biridir. Yapay zekanın siber güvenlikte kötü amaçlı olarak kullanıma potansiyeli, özellikle GenAI'nin ortaya çıkmasıyla birlikte, yapay zeka ve makine

öğrenimi kullanımının hızla genişlemesiyle artmaktadır (Wang 2024; Zhang vd. 2024). Ayrıca, GenAI yöntemleri, güvenlik ürünlerinin kimlik avı saldırılarını yüksek hassasiyet ve geri çağırma oranıyla tespit etmesine olanak tanır. Mevcut güvenlik yöntemleri GenAI'ye dayanmaktadır ve savunma saldırıları konusunda güçlü bir bilgi birikimi mevcuttur. Ağ segmentasyonu, güvenlik duvarları ve ağ koruması gibi ağ alanlarında GenAI kullanımı, hazırlıktan mekanize basınç testine kadar birçok göreve yardımcı olur, hızlı görünürlük ve potansiyel veri vektörü kaybını sağlar ve bir bakışta çözüm sunar (Sriram, 2024). GenAI, gerçek dünya senaryolarını simüle ederek güvenlik sistemi testlerini, performans değerlendirmesini, hata tespitini ve genel sistem hazırlığının iyileştirilmesini kolaylaştırır. Dahası, GenAI tehdit istihbaratı yetenekleri sergileyerek gelen tehditlerin verimli bir şekilde tanımlanmasını ve bunlara yanıt verilmesini sağlar. GenAI'nin sağlamlık ve tahmin doğruluğunda hala gelişmeye ihtiyacı olsa da, özellikle siber güvenlik olmak üzere çeşitli sektörlerde önemli ölçüde yardımcı olma potansiyeli yadsınamaz. GenAI, siber güvenliği devrimleştirmeye hazır, umut vadeden bir araç olarak ortaya çıkıyor.

6. Riskler ve Sınırlılıklar

6.1. Yanlış Bilgi Üretimi (Hallucination)

Büyük dil modelleri, gerçekte var olmayan bilgileri doğruymuş gibi sunabilmekte ve bu durum literatürde "hallucination" olarak adlandırılmaktadır. Özellikle bilgi doğruluğunun kritik olduğu sağlık, hukuk ve eğitim gibi alanlarda bu problem, üretken yapay zekâ sistemlerinin güvenilirliğini sınırlandıran önemli bir faktör olarak değerlendirilmektedir (Ji vd., 2023).

6.2. Model Önyargıları

Üretken yapay zekâ modelleri, eğitim verilerinde bulunan toplumsal ve kültürel önyargıları öğrenerek çıktılarına yansıtılabilmektedir. Bu durum belirli birey veya gruplara karşı ayrımcı sonuçların ortaya çıkmasına neden olabileceğinden, yapay zekâ sistemlerinin etik kullanımına ilişkin önemli tartışmaları beraberinde getirmektedir (Bender vd., 2021).

6.3. Veri Gizliliği Problemleri

Büyük dil modellerinin eğitildiği veri kümeleri içerisinde yer alan hassas bilgilerin istem dışı biçimde çıktılarda ortaya çıkabilmesi önemli bir gizlilik riski oluşturmaktadır. Araştırmalar, bazı durumlarda modellerin eğitim verilerindeki bilgileri yeniden üretebildiğini ve bunun veri güvenliği açısından dikkatle ele alınması gerektiğini göstermektedir (Carlini vd., 2021).

6.4. Telif Hakları ve Hukuki Sorunlar

Üretken yapay zekâ sistemlerinin telif hakkı ile korunan içerikler üzerinde eğitilmesi ve bu içeriklere benzer çıktılar üretebilmesi, fikri mülkiyet hakları konusunda çeşitli hukuki tartışmalara yol açmaktadır. Özellikle eğitim verilerinin kullanımı, eser sahiplerinin hakları ve üretilen içeriklerin mülkiyeti gibi konular günümüzde önemli araştırma alanları arasında yer almaktadır (Lemley & Casey, 2021).

6.5. Enerji Tüketimi ve Sürdürülebilirlik

Büyük ölçekli üretken yapay zekâ modellerinin eğitimi ve çalıştırılması yüksek hesaplama gücü gerektirdiğinden önemli miktarda enerji tüketimine neden olmaktadır. Bu durum, karbon ayak izi ve çevresel sürdürülebilirlik açısından yapay zekâ

teknolojilerinin uzun vadeli etkilerinin değerlendirilmesini gerekli kılmaktadır (Strubell vd., 2019).

7. Gelecek Perspektifi

Üretken yapay zekâ teknolojilerindeki hızlı ilerleme, yalnızca mevcut uygulamaları dönüştürmekle kalmamakta, aynı zamanda gelecekteki teknolojik, ekonomik ve toplumsal yapıyı da yeniden şekillendirmektedir. Bu bağlamda yapay zekâ ajanları, insan-yapay zekâ iş birliği modelleri, eğitim ve çalışma hayatındaki dönüşüm ile yapay genel zekâ (AGI) tartışmaları, geleceğe yönelik en kritik araştırma alanlarını oluşturmaktadır.

7.1. Yapay Zekâ Ajanları ve Otonom Sistemler

Gelecekte yapay zekâ sistemlerinin yalnızca istemlere yanıt veren araçlar olmaktan çıkarak, kendi başına karar alabilen ve çok adımlı görevleri yerine getirebilen otonom ajanlara dönüşmesi beklenmektedir. Bu tür sistemler, planlama, muhakeme ve çevresel geri bildirimlere göre kendini güncelleme yetenekleri sayesinde daha karmaşık görevleri insan müdahalesi olmadan gerçekleştirebilecektir. Özellikle çok ajanlı sistemlerin gelişimi, yazılım geliştirme, lojistik ve siber güvenlik gibi alanlarda tamamen yeni bir otomasyon paradigması oluşturma potansiyeline sahiptir (LeCun vd., 2023). Bununla birlikte, otonom karar alma mekanizmalarının kontrol edilebilirliği ve güvenliği önemli araştırma sorunları arasında yer almaktadır.

7.2. İnsan–Yapay Zekâ İş Birliği

Yapay zekânın gelecekte insan emeğinin yerini tamamen alması yerine, insan yeteneklerini artıran bir “tamamlayıcı teknoloji” olarak konumlanması beklenmektedir. İnsan-yapay zekâ iş birliği, özellikle yaratıcı üretim, karar destek sistemleri ve bilgi işleme süreçlerinde verimliliği önemli ölçüde artırmaktadır. Bu yaklaşım,

otomasyonun yerini “artırılmış zekâ (augmented intelligence)” modeline bırakacağını öne sürmektedir. Araştırmalar, yapay zekâ destekli çalışma ortamlarının bireylerin karar alma süreçlerini hızlandırdığını ve bilişsel yükü azalttığını göstermektedir (Brynjolfsson vd., 2022). Ancak bu dönüşüm, iş gücü yapısında yeniden beceri kazanımı (reskilling) ihtiyacını da beraberinde getirmektedir.

7.3. Eğitim ve Çalışma Hayatının Geleceği

Yapay zekâ teknolojilerinin yaygınlaşması, eğitim sistemlerinin ve iş gücü piyasalarının yeniden yapılandırılmasını zorunlu kılmaktadır. Gelecekte eğitim sistemlerinin yalnızca bilgi aktarımına değil, aynı zamanda eleştirel düşünme, dijital okuryazarlık ve yapay zekâ ile iş birliği becerilerinin geliştirilmesine odaklanması beklenmektedir. İş gücü piyasasında ise rutin görevlerin otomasyonu artarken, yaratıcı ve analitik becerilere dayalı yeni mesleklerin ortaya çıkacağı öngörülmektedir. Bu dönüşüm, özellikle orta ve uzun vadede iş tanımlarının yeniden şekillenmesine neden olacaktır (Acemoglu & Restrepo, 2020). OECD raporları da benzer şekilde, dijital becerilerin eğitim politikalarının merkezine yerleşmesi gerektiğini vurgulamaktadır (OECD, 2023).

7.4. Yapay Genel Zekâ (AGI) Tartışmaları

Yapay genel zekâ (Artificial General Intelligence - AGI), insan seviyesinde bilişsel yeteneklere sahip sistemlerin geliştirilmesini ifade etmektedir. AGI'nin gerçekleşme olasılığı ve zamanlaması konusunda akademik çevrelerde önemli tartışmalar bulunmaktadır. Bazı araştırmacılar AGI'nin uzun vadede kaçınılmaz olduğunu savunurken, bu tür sistemlerin kontrolü, güvenliği ve etik sınırları konusunda ciddi riskler bulunduğunu belirtmektedir. Özellikle süper zekâ sistemlerinin insan değerleriyle uyumlu hale getirilmesi (alignment problemi), gelecekteki en kritik araştırma

alanlarından biri olarak kabul edilmektedir (Bostrom, 2014). Bu bağlamda OpenAI ve benzeri kuruluşlar, AGI'nin güvenli geliştirilmesi için yönetim ve düzenleme mekanizmaları üzerinde çalışmalar yürütmektedir (OpenAI, 2023).

8. Sonuç

Bu çalışma, GenAI'nin yapay zekada niteliksel bir değişimi temsil ettiğini ve yönetim ve organizasyonlardaki rolünün temelden yeniden değerlendirilmesini gerektirdiğini savunmaktadır. Yapay zekayı öncelikle belirsizliği azaltmaya ve optimizasyona odaklanan yakınsak bir teknoloji olarak gören geleneksel görüşün ötesine geçen (Amabile, 2020), GenAI'nin problem çözme görevlerindeki üretken yetenekleri, otomasyon ve verimliliği vurgulayan teorik çerçevelere meydan okumaktadır (Cabantous & Gond, 2011). Bu çalışma, dört temel boyut aracılığıyla GenAI'nin i) bir GPT olarak geniş uygulanabilirliği, ii) keşifsel inovasyonda katalitik rolü, iii) tamamlayıcı bir bilişsel araç olarak işlevi ve iv) demokratikleştirici etkisi – yaratıcılığı, inovasyonu ve insan potansiyelini desteklemek için gerekli olan farklı bakış açılarını entegre eden genişletilmiş bir paradigma önermektedir. Çalışmanın girişinde ortaya atılan, GenAI'nin birey, organizasyon ve toplum eksenindeki etkilerine dair bilgi sistemleri ve sosyo-teknik yaklaşımların nasıl bir bakış açısı sunabileceği sorusu, tam da bu genişletilmiş paradigma ekseninde yanıt bulmaktadır. Bilgi Sistemleri (IS) literatüründe geleneksel teknoloji kabul modelleri (TAM ve UTAUT gibi), kullanıcıların yeni sistemleri "faydalılık" ve "kullanım kolaylığı" gibi rasyonel parametreler üzerinden benimsediğini öne sürer. Ancak GenAI'nin hem yakınsak hem de ıraksak görevlerde kullanımı mümkün kılan ortaya çıkan yetenekleriyle karakterize edilen bu teknolojik faz değişimi, bireysel ve kurumsal adaptasyon süreçlerini basit bir araç kabulünün ötesine taşımıştır. Yapay zekanın bu çok boyutlu doğası, insan eyleminin ve hayal gücünün önemini azaltmak yerine

güçlendirmektedir. Sosyo-teknik bir perspektiften bakıldığında, GenAI'nin yazılım geliştirmeden (SDLC) yükseköğretime kadar yarattığı etkiler, teknik altyapı ile sosyal yapının (insan iradesi, etik kurallar, pedagojik ve kurumsal politikalar) birbirinden ayrılamayacağını kanıtlamaktadır. Sonuç olarak, bu teknolojilerin kurumsal ve toplumsal hedeflere hizmet edecek şekilde nasıl geliştirileceği ve uygulanacağı, teknolojik determinizmden ziyade insan iradesiyle şekillenecektir (Brusoni & Vaccaro, 2017). GenAI'nin potansiyelini gerçekleştirmek; tasarım, uygulama ve kullanımın merkezine insan refahını ve özerkliğini yerleştiren insan merkezli bir yaklaşım gerektirir. GenAI'nin demokratikleştirici yönleri, uygun politika ve yönetim uygulamalarıyla birleştğinde bu mekanizmaları güçlendirerek yaratıcılığı, yeniliği ve geniş çaplı paylaşılan büyümeyi teşvik edebilir (Brynjolfsson, 2022). Bu faydaları elde etmek için, insan katılımını, düşünmeyi ve etik sorumluluğu koruyan etkili hibrit özerkliği teşvik etmek amacıyla tamamlayıcı insan yeteneklerine ve örgütsel uygulamalara dikkat etmek çok önemlidir. Kuruluşlar ve toplum bu derin teknolojik geçişe uyum sağlarken, yenilik ve ekonomik büyüme için yapay zekanın uygulanmasını mümkün kılan, faydaların adil dağıtımını ve temel insan değerlerini ve özerkliğini koruyan insan odaklı gelişmeyi belirleyen bilinçli seçimler, GenAI'nin dönüştürücü potansiyelinin geniş çaplı paylaşılan refahla sonuçlanıp sonuçlanmayacağını belirleyecektir. İnsan becerilerinin geliştirilmesi ve refahının geleceği, öncelikle yapay zekanın genişleyen yeteneklerine değil, bu yeteneklerden insan merkezli amaç ve sonuçlara hizmet edecek yaklaşımlar geliştirme ve uygulama becerisine bağlı olabilir.

Kaynaklar

Acemoglu, D. & Restrepo, P. (2020). Robots and jobs: Evidence from US labor markets. *Journal of Political Economy*, 128 (6), 2188–2244. Doi: 10.1086/705716

Aggarwal, A., Mittal, M. & Battineni, G. (2021). Generative adversarial network: an overview of theory and applications. *Int J Inf Manag Data Insights*, 1 (1), 100004. Doi: 10.1016/j.jjime.2020.100004

Aldausari, N., Sowmya, A., Marcus, N. & Mohammadi, G. (2023). Video generative adversarial networks: a review. *ACM Comput Surv*, 25 (1), 1-30. Doi: 10.1145/3487891

Almasre, M. (2024). Development and evaluation of a custom GPT for the assessment of students' designs in a typography course. *Education Sciences*, 14 (2), 148. Doi: 10.3390/educsci14020148

Amabile, T. M. (2020). Creativity, artificial intelligence, and a world of surprises. *Academy of Management Discoveries*, 6 (3), 351-354. Doi: 10.5465/amd.2020.0136

Atif, M., Chopra, K., Kilic, O., Wang, T., Dong, Z., Leggett, C., Lin, M., Calafiura, P. & Habib, S. (2025). *CelloAI: Leveraging Large Language Models for HPC Software Development in High Energy Physics*. (23/06/2026 tarihinde <http://arxiv.org/abs/2508.16713> adresinden ulařılmıştır).

Bandi, A., Adapa, P. V. S. R. & Kuchi, Y. E. V. P. K. (2023). The power of generative AI: a review of requirements, models, input–output formats, evaluation metrics, and challenges. *Future Internet*, 15 (8), 260. Doi: 10.3390/fi15080260

Barrett, A. & Pack, A. (2023). Not quite eye to A.I.: Student and teacher perspectives on the use of generative artificial intelligence in the writing process. *International Journal of Educational Technology in Higher Education*, 20 (1), 59. Doi: 10.1186/s41239-023-00427-0

Bender, E. M., Gebru, T., McMillan-Major, A. & Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency (FAccT '21)*, 3-10 March 2021, Canada, (pp. 610–623). Doi: 10.1145/3442188.3445922

Birlasoft (2023). *A to Z of Generative AI, White Paper*. (23/06/2026 tarihinde <https://www.birlasoft.com/resources> adresinden ulaşılmıştır).

Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., ... Liang, P. (2021). On the opportunities and risks of foundation models. arXiv preprint arXiv:2108.07258. <https://arxiv.org/abs/2108.07258>

Bostrom, N. (2014). *Superintelligence: Paths, dangers, strategies*. Oxford: Oxford University Press.

Brusoni, S. & Vaccaro, A. (2017). Ethics, technology and organizational innovation. *Journal of Business Ethics*, 143 (2), 223-226. Doi: 10.1007/s10551-017-3465-1

Brynjolfsson, E., Li, D. & Raymond, L. R. (2023). *Generative AI at work*. NBER Working Paper Series, No. 31161. (23/06/2026 tarihinde <https://www.nber.org/papers/w31161> adresinden ulaşılmıştır).

Cabantous, L. & Gond, J. P. (2011). Rational decision making as performative praxis: Explaining rationality's éternel retour. *Organization Science*, 22 (3), 573-586. Doi: 10.1287/orsc.1100.0543

Carlini, N., Tramer, F., Wallace, E., Jagielski, M., Herbert-Voss, A., Lee, K., Roberts, A., Brown, T., Song, D., Erlingsson, Ú., Oprea, A. & Raffel, C. (2021). Extracting training data from large language models. *30th USENIX Security Symposium (USENIX Security 21)*, 11-13 August 2021, Vancouver, B.C., (pp. 2633–2650).

Carlini, N., Jagielski, M., Tramer, F., Fuchs, A., Nasr, M., Wallace, E., Smith, M., Wasiljew, D., Jones, C. & Oprea, A. (2024). Poisoning web-scale training datasets is practical. *IEEE Symposium on Security and Privacy (SP)*, 20-22 May 2024, San Francisco, CA, USA, (pp. 407–425). Doi: 10.1109/SP54263.2024.00179

Chan, C. K. Y. (2023). A comprehensive AI policy education framework for university teaching and learning. *International Journal of Educational Technology in Higher Education*, 20 (1), 38. Doi: 10.1186/s41239-023-00408-3

Chan, C. K. Y. & Hu, W. (2023). Students’ voices on generative AI: Perceptions, benefits, and challenges in higher education. *International Journal of Educational Technology in Higher Education*, 20 (1), 43. Doi: 10.1186/s41239-023-00411-8

Chan, C. K. Y. & Lee, K. K. W. (2023). The AI generation gap: Are Gen Z students more interested in adopting generative AI such as ChatGPT in teaching and learning than their Gen X and millennial generation teachers? *Smart Learning Environments*, 10 (1), 60. Doi: 10.1186/s40561-023-00269-3

Collante, A., Abedu, S., Khatoonabadi, S. H., Abdellatif, A., Alor, E. & Shihab, E. (2025). *The Impact of Large Language Models (LLMs) on Code Review Process*. (23/06/2026 tarihinde <http://arxiv.org/abs/2508.11034> adresinden ulaşılmıştır).

Corvello, V. (2025). Generative AI and the future of innovation management: a human centered perspective and an

agenda for future research. *J Open Innov Technol Mark Complex*, 11 (1), 100456. Doi: 10.1016/j.joitmc.2024.100456

Cox, G., Brown, R., Willmers, M., & Held, M. (2024). Learning along the way: A case study on a pedagogically innovative approach to engage medical students in the creation of open educational resources using ChatGPT. *Mousaion*, 42 (1), 21. Doi: 10.25159/2663-659X/14231

Dell'Acqua, F., McFowland, E., Mollick, E. R., Lifshitz-Assaf, H., Kellogg, K., Rajendran, S., Kraye, L., Candelon, F. & Lakhani, K. R. (2023). Navigating the Jagged Technological Frontier: Field Experimental Evidence of the Effects of AI on Knowledge Worker Productivity and Quality. *SSRN Electronic Journal*. Doi: 10.2139/ssrn.4573321

Dolata, M., Feuerriegel, S., & Schwabe, G. (2021). A sociotechnical view of algorithmic fairness. *Information Systems Journal*, 32(4), 754–818. <https://doi.org/10.1111/isj.12370>

Eager, B. & Brunton, R. (2023). Prompting higher education towards AI-augmented teaching and learning practice. *Journal of University Teaching and Learning Practice*, 20 (5), 1–19. Doi: 10.5172/jutlp.v20i5.09

Ertel, W. (2019). Introduction to artificial intelligence (2nd ed.). Cham, Switzerland: Springer. <https://doi.org/10.1007/978-3-319-58487-4>

G7 Academies of Science. (2019). Artificial intelligence and society: Statement of the G7 academies. Paris, France: G7 Academies of Science.

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. & Bengio, Y. (2014). Generative Adversarial Nets. *Advances in Neural Information Processing*

Systems (NeurIPS 2014), 8-13 December 2014, Montreal, Canada, (pp. 2672-2680).

Hager, G. D. (2017). *Artificial Intelligence for Social Good*. Washington: Computing Community Consortium.

Hagerty, A. & Rubinov, I. (2019). *Global AI Ethics: A Review of the Social Impacts and Ethical Implications of Artificial Intelligence*. (23/06/2026 tarihinde <https://arxiv.org/ftp/arxiv/papers/1907/1907.07892.pdf> adresinden ulaşılmıştır).

Hasse, A., Cortesi, S., Lombana-Bermudez, A. & Gasser, U. (2019). *Youth and Artificial Intelligence: Where We Stand*. Cambridge, MA: Berkman Klein Center for Internet & Society at Harvard University.

Ho, J., Jain, A. & Abbeel, P. (2020). Denoising diffusion probabilistic models. *Advances in Neural Information Processing Systems (NeurIPS 2020)*, 6-12 December 2020, San Diego, USA, (pp. 6840–6851).

Holt, M. (2018). *Artificial Intelligence in Modern Society*. Murray State University. (23/06/2026 tarihinde <https://digitalcommons.murraystate.edu/cgi/viewcontent.cgi?article=1148&context=bis437> adresinden ulaşılmıştır).

Hussein, B. R., Halimu, C., & Siddique, M. T. (2020). The future of artificial intelligence and its social, economic and ethical consequences. International Conference on Advances in Computing and Technology (ICACT 2020) Proceedings. <https://doi.org/10.48550/arXiv.2101.03366>

International Institute of Communications. (2020). *Artificial intelligence in the Asia-Pacific region*. London, UK: International Institute of Communications.

Jackaria, P. M., Hajan, B. H. & Mastul, A. R. H. (2024). A Comparative analysis of the rating of college students' essays by ChatGPT versus human raters. *International Journal of Learning, Teaching and Educational Research*, 23 (2), 478–492. Doi: 10.26803/ijlter.23.2.24

Ji, Z., Lee, N., Frieske, R., Yu, T., Su, D., Xu, Y., Ishii, E., Bang, Y., Madotto, A. & Fung, P. (2023). Survey of hallucination in natural language generation. *ACM Computing Surveys*, 55 (12), 1–38. Doi: 10.1145/3571730

Karaci Deniz, B., Gnanasambandam, C., Harrysson, M., Hussin, A. & Srivastava, S. (2023). *Unleash developer productivity with generative AI*. Technical report, McKinsey. (23/06/2026 tarihinde <https://www.mckinsey.com/capabilities/tech-and-ai/our-insights/unleashing-developer-productivity-with-generative-ai> adresinden ulaşılmıştır).

Gnanasambandam, C., Harrysson, M. & Singh, R. (2025). *How an AI-enabled software product development life cycle will fuel innovation*. Technical report, McKinsey. (23/06/2026 tarihinde <https://www.mckinsey.com/industries/technology-media-and-telecommunications/our-insights/how-an-ai-enabled-software-product-development-life-cycle-will-fuel-innovation> adresinden ulaşılmıştır).

Kaplan-Rakowski, R., Grotewold, K., Hartwick, P. & Papin, K. (2023). Generative AI and teachers' perspectives on its implementation in education. *Journal of Interactive Learning Research*, 34 (2), 313–338.

Kelly, A., Sullivan, M. & Strampel, K. (2023). Generative artificial intelligence: University student awareness, experience, and confidence in use across disciplines. *Journal of University Teaching and Learning Practice*, 20 (6), 1–16. Doi: 10.5172/jutlp.v20i6.02

Krakovski, S. (2025). Human-AI agency in the age of generative AI. *Information and Organization*, 35 (1), 100560. Doi: 10.1016/j.infoandorg.2025.100560

LeCun, Y., Hinton, G. & Bengio, Y. (2023). *A path towards autonomous machine intelligence*. arXiv preprint. (23/06/2026 tarihinde <https://arxiv.org/abs/2304.13712> adresinden ulaşılmıştır).

Lemley, M. A. & Casey, B. (2021). Fair learning. *Texas Law Review*, 99 (4), 743–786.

Li, B., Kou, X. & Bonk, C. J. (2023). Embracing the disrupted language teaching and learning field: Analyzing YouTube content creation related to ChatGPT. *Languages*, 8 (3), 197. Doi: 10.3390/languages8030197

Majumdar, D., & Chattopadhyay, H. K. (2020). Artificial intelligence and its impacts on the society. *International Journal of Law*, 6(5), 306–310.

Mannino, A. (2015). *Artificial Intelligence: Opportunities and Risks*. Policy Paper. Berlin: The Effective Altruism Foundation.

McCarthy, J., Minsky, M., Rochester, N. & Shannon, C. (1956). *A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence*. (23/06/2026 tarihinde <http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf> adresinden ulaşılmıştır).

Mohawesh, R., Ottom, M. A. & Salameh, H. B. (2025). A data-driven risk assessment of cybersecurity challenges posed by generative AI. *Decis Anal*, 15, 100580. Doi: 10.1016/j.dajour.2025.100580

Nadikattu, R. R. (2016). The Emerging Role of Artificial Intelligence in Modern Society. *International Journal of Creative Research Thoughts*, 4 (4), 906–911.

Nadimpalli, M. (2017). Artificial intelligence–Consumers and industry impact. *International Journal of Economics & Management Sciences*, 6(4), 1–3. Doi:10.4172/2162-6359.1000429

Naidu, A. (2019). *Review: Impact of Artificial Intelligence on Society*. Working Paper Series. India: Centre for Society and Policy.

Ng, A. & Jordan, M. (2001). On discriminative vs. generative classifiers: a comparison of logistic regression and naive Bayes. *Advances in Neural Information Processing Systems (NeurIPS 2001)*, 3-8 December 2001, Vancouver, Canada, (pp. 841–848).

Ng, K. K. B., Fauzi, L., Leow, L. & Ng, J. (2024). *Harnessing the Potential of Gen-AI Coding Assistants in Public Sector Software Development*. (23/06/2026 tarihinde <http://arxiv.org/abs/2409.17434> adresinden ulaşılmıştır).

OECD (2019). *Artificial Intelligence in Society*. Paris: OECD Publishing. Doi: 10.1787/eedfee77-en

OECD (2023). *OECD AI policy observatory: AI, work and education transformation reports*. Paris: Organisation for Economic Co-operation and Development. (23/06/2026 tarihinde <https://oecd.ai> adresinden ulaşılmıştır).

OpenAI (2023). *GPT-4 technical report*. arXiv preprint. (23/06/2026 tarihinde <https://arxiv.org/abs/2303.08774> adresinden ulaşılmıştır).

Parra, V., Sureda, P., Corica, A., Schiaffino, S. & Godoy, D. (2024). Can generative AI solve geometry problems? Strengths and weaknesses of LLMs for geometric reasoning in Spanish.

International Journal of Interactive Multimedia and Artificial Intelligence, 8 (5), 65–74. Doi: 10.9781/ijimai.2024.02.004

PricewaterhouseCoopers (2024). *Global annual review 2024: A year of solving together*. [PwC]. (23/06/2026 tarihinde <https://www.pwc.com/gx/en/global-annual-review/2024/pwc-global-annual-review-2024.pdf> adresinden ulaşılmıştır).

Russell, S. J. & Norvig, P. (2016). *Artificial Intelligence: A Modern Approach*. Malaysia: Pearson Education Limited.

Russell, S. J. & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach* (4th ed.). New York: Pearson.

Russell, S., Dewey, D. & Tegmark, M. (2015). *Research Priorities for Robust and Beneficial Artificial Intelligence*. Association for the Advancement of Artificial Intelligence.

Sai, S., Gaur, A., Sai, R., Chamola, V., Guizani, M. & Rodrigues, J. J. P. C. (2024). Generative AI for transformative healthcare: a comprehensive study of emerging models, applications, case studies, and limitations. *IEEE Access*, 12, 31078–31106. Doi: 10.1109/ACCESS.2024.3367715

Salinas-Navarro, D. E., Vilalta-Perdomo, E., Michel-Villarreal, R. & Montesinos, L. (2024). Using generative artificial intelligence tools to explain and enhance experiential learning for authentic assessment. *Education Sciences*, 14 (1), 83. Doi: 10.3390/educsci14010083

Savage, N. (2023). Drug discovery companies are customizing ChatGPT: Here's how. *Nature Biotechnology*, 41 (5), 585-586. Doi: 10.1038/s41587-023-01789-2

Šedlbauer, J., Činčera, J., Slavík, M. & Hartlová, A. (2024). Students' reflections on their experience with ChatGPT. *Journal of*

Computer Assisted Learning, 40 (4), 1347–1986. Doi: 10.1111/jcal.12954

Sergeyuk, A., Golubev, Y., Bryksin, T. & Ahmed, I. (2025). Using AI-based coding assistants in practice: State of affairs, perceptions, and ways forward. *Information and Software Technology*, 178, 107610. Doi: 10.1016/j.infsof.2024.107610

Shihab, M. I. H., Hundhausen, C., Tariq, A., Haque, S., Qiao, Y. & Mulanda, B. W. (2025). The Effects of GitHub Copilot on Computing Students' Programming Effectiveness, Efficiency, and Processes in Brownfield Coding Tasks. *Proceedings of the 2025 ACM Conference on International Computing Education Research V.1*, 11-15 August 2025, Charlottesville, USA, (pp. 407–420). Doi: 10.1145/3702652.3744219

Shimizu, I., Kasai, H., Shikino, K., Araki, N., Takahashi, Z., Onodera, M., Kimura, Y., Tsukamoto, T., Yamauchi, K., Asahina, M., Ito, S. & Kawakami, E. (2023). Developing medical education curriculum reform strategies to address the impact of generative AI: Qualitative study. *JMIR Medical Education*, 9, e53466. Doi: 10.2196/53466

Singh, M. (2023). Maintaining the integrity of the South African university: The impact of ChatGPT on plagiarism and scholarly writing. *South African Journal of Higher Education*, 37 (5), 203–220. Doi: 10.20853/37-5-6124

Smith, M. L., & Neupane, S. (2018). Artificial intelligence and human development. Ottawa, Canada: International Development Research Centre. Retrieved from <https://idl-bnc-idrc.dspacedirect.org/>

Strubell, E., Ganesh, A. & McCallum, A. (2019). Energy and policy considerations for deep learning in NLP. *Proceedings of the*

57th Annual Meeting of the Association for Computational Linguistics, 28 July - 2 August 2019, Florence, Italy, (pp. 3645–3650). Doi: 10.18653/v1/P19-1355

Susarla, A., Gopal, R., Thatcher, J. B. & Sarker, S. (2023). The Janus effect of generative AI: Charting the path for responsible conduct of scholarly activities in information systems. *Information Systems Research*, 34 (2), 399–408. Doi: 10.1287/isre.2023.1224

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. & Polosukhin, I. (2017). Attention Is All You Need. *Advances in Neural Information Processing Systems (NeurIPS 2017)*, 4-9 December 2017, Long Beach, CA, USA, (pp. 5998-6008).

Van den Berg, G., & du Plessis, E. (2023). ChatGPT and generative AI: Possibilities for its contribution to lesson planning, critical thinking and openness in teacher education. *Education Sciences*, 13(10), 998. <https://doi.org/10.3390/educsci13100998>

Wagner, P. & Wagner, R. (2024). The Evolution of Technology in Artificial Intelligence and Its Impact on Project Management. D. Jude Hemanth, Utku Kose, Bogdan Patrut & Mevlut Ersoy (Ed.), *Innovative Methods in Computer Science and Computational Applications in the Era of Industry 5.0* içinde (s. 268–293). Cham: Springer Nature Switzerland. Doi: 10.1007/978-3-031-56322-5_19

Yadav, D. & Mondal, S. (2025). *Evaluating Pre-trained Large Language Models on Zero Shot Prompts for Parallelization of Source Code*. (23/06/2026 tarihinde https://osf.io/jmevx_v1 adresinden ulaşılmıştır).

Yang, Y., Luo, J., Yang, M., Yang, R. & Chen, J. (2024). From surface to deep learning approaches with Generative AI in higher

education: An analytical framework of student agency. *Studies in Higher Education*, 49 (5), 817–830. Doi: 10.1080/03075079.2023.2255284

BÖLÜM 4

DÖNGÜSÜZ YÖNLENDİRİLMİŞ KARMA ÇİZGELER (ACYCLIC DIRECTED MIXED GRAPHS – ADMGs)

NURCİHAN FAKİOĞLU¹
SEREL ÖZMEN AKYOL²

Giriş

Döngüsüz yönlendirilmiş karma çizgeler, modern nedensel çıkarım literatüründe gözlemlenemeyen gizil karıştırıcı etki (latent confounding) problemlerinin modellenebilmesi amacıyla geliştirilmiş en önemli çizge yapılarından biridir (Pearl, 2009; Richardson & Spirtes, 2002). Klasik yönlendirilmiş döngüsüz çizge modelleri gözlenen değişkenler arasındaki doğrudan nedensel ilişkileri başarılı biçimde temsil edebilmesine rağmen, gözlenemeyen ortak nedenlerin bulunduğu sistemlerde önemli sınırlılıklar bulunmaktadır (Spirtes et al., 2000). Gerçek dünya problemlerinin büyük çoğunluğunda, tüm değişkenlerin ölçülebilmesi mümkün değildir. Sağlık sistemlerinde genetik yatkınlıklar, sosyal bilimlerde ölçülemeyen davranışsal faktörler, finansal sistemlerde gizli ekonomik etkiler ve güvenlik sistemlerinde

¹Yükseklisans Öğrencisi, Eskişehir Osmangazi Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0009-0007-8208-2247

² Dr. Öğr. Üyesi, Eskişehir Osmangazi Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0000-0002-5344-4065

bilinmeyen saldırı mekanizmaları gibi birçok gizli değişken doğrudan gözlemlenememektedir (Hernán & Robins, 2020). Bu nedenle yalnızca yönlendirilmiş döngüsüz çizge yapıları kullanılarak yapılan modellemeler çoğu zaman eksik veya hatalı nedensel çıkarımlara yol açmaktadır.

Döngüsüz yönlendirilmiş karma çizge yapıları, yönlü kenarlar ile doğrudan nedensel etkileri, çift yönlü kenarlar ile ise gözlenemeyen ortak nedenlerden kaynaklanan bağımlılıkları aynı çizge üzerinde temsil edebilmektedir (Richardson, 2003). Böylece gözlemlenemeyen gizil karıştırıcı etkisi bulunan değişkenlerin yer aldığı problemleri doğrudan çizge yapı içerisinde modellenebilmektedir. Literatürde döngüsüz yönlendirilmiş karma çizgeler özellikle gizli değişkenler içeren yönlendirilmiş döngüsüz çizge modellerinin marjinal gösterimi, iç içe Markov modelleri, nedensel tanımlanabilirlik teorileri ve modern yapay sinir ağı temelli nedensel keşif sistemleriyle birlikte ele alınmaktadır (Bhattacharya et al., 2019; Painsaveine & Verdebout, 2017).

Son yıllarda yapay zekâ ve derin öğrenme alanındaki gelişmelerle birlikte döngüsüz yönlendirilmiş karma çizge çalışmaları yalnızca teorik istatistik alanında kalmamış, aynı zamanda biyomedikal veri analizi, gen regülasyon ağları, siber güvenlik, öneri sistemleri ve açıklanabilir yapay zeka gibi bir çok alanda aktif olarak kullanılmaya başlanmıştır (Schölkopf et al., 2021; Topol, 2019). Bu durum döngüsüz yönlendirilmiş karma çizge literatürünün hızla gelişmesine ve çok disiplinli bir araştırma alanına dönüşmesine neden olmuştur.

Döngüsüz yönlendirilmiş karma çizge literatürünün tarihsel gelişimi incelendiğinde alanın dört temel döneme ayrıldığı görülmektedir. İlk dönem olan 2000–2006 yılları arasında temel teorik yapıların oluşturulmasına odaklanılmıştır. Bu dönemde araştırmacılar özellikle gizil karıştırıcı etki problemlerini çizgesel olarak nasıl temsil edebileceklerini araştırmıştır. Tian ve Pearl

tarafından yapılan alıřmalar, gizil karıřtırıcı etkisi bulunan deęiřkenler ieren ynlendirilmiř dngsz izge yapılardan test edilebilir kısıtların sistematik biimde ıkarılmasını saęlamıřtır (Tian & Pearl, 2002). zellikle Verma kısıtı yaklařımı, yalnızca kořullu baęımsızlık iliřkileriyle ifade edilemeyen baęımlılıkların modellenenebilmesini mmkn hale getirmiřtir (Verma & Pearl, 1990).

Richardson tarafından 2003 yılında geliřtirilen m-ayrıřımı yaklařımı ise dngsz ynlendirilmiř karma izge anlamsallıęının temel tařlarından biri haline gelmiřtir (Verma & Pearl, 1990). Ynlendirilmiř dngsz izge modellerindeki d-ayrıřımı yaklařımının genelleřtirilmiř versiyonu olarak kabul edilen m-ayrıřımı, kořullu baęımsızlık iliřkilerinin dngsz ynlendirilmiř karma izge yapıları zerinden okunabilmesini saęlamıřtır. Bylece dngsz ynlendirilmiř karma izgeler yalnızca izgesel bir gsterim olmaktan ıkmiř, aynı zamanda olasılıksal izge modeller olarak kullanılabilir hale gelmiřtir.

2006–2015 yılları arasında izgeler zerinde tanımlanabilirlik teorileri n plana ıkmiřtır. Shpitser ve Pearl tarafından geliřtirilen ID algoritmaları, gizil karıřtırıcı bulunan yapılarda nedensel etkilerin tanımlanabilirlięini inceleyen en nemli alıřmalardan biri olmuřtur (Shpitser & Pearl, 2006). Bu algoritmalar sayesinde klasik arka kapı ve n kapı kriterlerinin yetersiz kaldıęı durumlarda bile nedensel etki hesaplamaları yapılabilmıřtir.

2015 sonrası dnemde i ie Markov modelleri ve parametreleřtirme alıřmaları hız kazanmıřtır. Bhattacharya vd. tarafından geliřtirilen sabitleme ve ekirdek mekanizmaları sayesinde kořullu baęımsızlık dıřındaki kısıtlar da izgesel modeller ierisine dahil edilmiřtir (Bhattacharya et al., 2019; Paindaveine & Verdebout, 2017). Son yıllarda ise NOTEARS, DAG-GNN, GraN-DAG ve Neural ADMG Learning gibi trevlenebilir yapı ęrenmesi

yöntemleriyle birlikte döngüsüz yönlendirilmiş karma çizgeler modern derin öğrenme sistemlerinin bir parçası haline gelmiştir (Yu et al., 2019; Zheng et al., 2018; Zhu et al., 2023).

Tablo 1 ADMG Literatürünün Tarihsel Gelişim Süreci

Dönem	Odak
2000-2026	Döngüsüz yönlendirilmiş karma çizge teorik temelleri
2006-2015	Tanımlanabilirlik ve Gizli İzdüşüm
2015-2020	İç içe Markov ve Parametseleştirme
2020-2026	Yapay sinir ağı temelli nedensel keşif ve yapay zeka entegrasyonu

Bir döngüsüz yönlendirilmiş karma çizge $G=(V,E,B)$ şeklinde tanımlanmaktadır. Burada V düğüm kümesi, E yönlü kenarları, B ise çift yönlü kenarları temsil etmektedir.

Döngüsüz yönlendirilmiş karma çizgeler yönlü ve çift yönlü kenarların aynı yapı içerisinde bulunduğu ancak yönlü çevrim içermeyen çizgelerdir. Bu yapı sayesinde hem doğrudan nedensel etkileri hem de gizil karıştırıcı etki bulunan problemleri aynı çizge üzerinde temsil edilebilmektedir (Evans, 2012). Literatürde çift yönlü kenarlar çoğunlukla gözlenemeyen ortak nedenlerin kısa gösterimi olarak yorumlanmaktadır.

Döngüsüz yönlendirilmiş karma çizge teorisinin merkezinde m-ayrışımı kavramı bulunmaktadır. Döngüsüz yönlendirilmiş çizge modellerindeki d-ayrışımı yaklaşımının genişletilmiş versiyonu olan m-ayrışımı, koşullu bağımsızlık ilişkilerinin karma çizge yapıları üzerinden okunmasını sağlamaktadır (Richardson, 2003). Bu yaklaşım sayesinde küresel Markov özelliği ve yerel Markov özelliği tanımları döngüsüz yönlendirilmiş karma çizge yapıları içinde geçerli hale getirilmiştir.

Bir diğer önemli teorik kavram gizli izdüşüm yaklaşımıdır. Gizli izdüşüm sayesinde gizil değişkenli döngüsüz yönlendirilmiş

çizge modelleri gözlenen değişkenler üzerine izdüşüm edilerek döngüsüz yönlendirilmiş karma çizge yapıları elde edilmektedir (Richardson & Spirtes, 2002). Böylece tüm gizil değişkenlerin açık biçimde modellenmesine gerek kalmadan gözlenen sistemin nedensel yapısı temsil edilebilmektedir.

İç içe Markov modelleri ise döngüsüz yönlendirilmiş karma çizge literatüründeki en önemli teorik gelişmelerden biri olarak kabul edilmektedir. Çünkü gizil değişkenli sistemlerde ortaya çıkan bazı bağımlılıklar yalnızca koşullu bağımsızlıklarla açıklanamamaktadır. Verma kısıtı gibi eşitlik tipi kısıtların modellenebilmesi amacıyla sabitleme, çekirdek ve koşullu döngüsüz yönlendirilmiş karma çizge yapıları geliştirilmiştir (Bhattacharya et al., 2019; Painsaveine & Verdebout, 2017). Bu yaklaşım döngüsüz yönlendirilmiş karma çizgelerin ifade gücünü önemli ölçüde arttırmıştır.

Döngüsüz Yönlendirilmiş Çizge(DAG), Maksimum Atasal Çizge(MAG) ve Döngüsüz Yönlendirilmiş Karma Çizge(ADMG)

Literatürde Döngüsüz Yönlendirilmiş Çizge (DAG), Maksimum Atasal Çizge (MAG) ve Döngüsüz Yönlendirilmiş Karma Çizge (ADMG) yapıları farklı problemlerin çözümü için kullanılmaktadır (Ali et al., 2009). Döngüsüz yönlendirilmiş çizge modelleri yalnızca gözlenen değişkenler arasındaki doğrudan nedensel ilişkileri temsil edebilmektedir. Bu nedenle gizil karıştırıcı etki bulunan sistemlerde çoğu zaman yetersiz kalmaktadır.

Maksimum atasal çizge yapıları ise gizil değişkenler ve seçim yanlılığı problemlerinin modellenebilmesi amacıyla geliştirilmiştir (Richardson & Spirtes, 2002). Maksimum atasal çizge modelleri atasal çizge semantiği kullanarak gizil karıştırıcı etkilerini dolaylı biçimde temsil etmektedir. Ancak döngüsüz yönlendirilmiş karma çizgeler, çift yönlü kenarlar sayesinde gizil

ortak nedenleri daha doğrudan ve daha yorumlanabilir biçimde modelleyebilmektedir.

Döngüsüz yönlendirilmiş karma çizge modellerinin en büyük avantajlarından biri koşullu bağımsızlık dışındaki kısıtları da temsil edebilmesidir. Özellikle iç içe Markov modelleri ile birlikte kullanıldığında Verma kısıtı gibi karmaşık bağımlılık yapıları modellenebilmektedir (Bhattacharya et al., 2019). Bu nedenle modern nedensel çıkarım literatüründe döngüsüz yönlendirilmiş karma çizgeler döngüsüz yönlendirilmiş çizge modellerine göre daha güçlü ve daha esnek yapılar olarak kabul edilmektedir.

Tablo 2 DAG, MAG ve ADMG Karşılaştırması

Özellik	DAG	MAG	ADMG
Gizil Karıştırıcı Etki	-	+	+
Yönlü Kenar	+	+	+
Yönsüz Kenar	-	+	+
Koşullu Bağımsızlık	+	+	+
Verma Kısıtı	-	Kısmen	+
Nedensel Tanımlanabilirlik	Orta	Güçlü	Çok Güçlü

Sinir Ağı Tabanlı Döngüsüz Yönlendirilmiş Karma Çizgeler (Neural ADMG Learning) ve Modern Yaklaşımlar

Son yıllarda en hızlı gelişen araştırma alanlarından biri sinir ağı tabanlı döngüsüz yönlendirilmiş karma çizge sistemleridir (Zhu et al., 2023). Başlangıçta NOTEARS ve DAG-GNN gibi diferansiyellenebilir yapı öğrenmesi yöntemleri yalnızca döngüsüz yönlendirilmiş çizge öğrenimi için geliştirilmiştir (Yu et al., 2019; Zheng et al., 2018). Ancak gerçek dünya problemlerinde gizil karıştırıcı etkilerinin yoğun olması nedeniyle daha sonra sinir ağı

tabanlı döngüsüz yönlendirilmiş karma çizge yaklaşımları önerilmiştir.

Sinir ağı tabanlı döngüsüz yönlendirilmiş karma çizge modelleri çizge yapısını doğrudan veri üzerinden öğrenebilmektedir. Özellikle biyomedikal veri kümeleri, gen regülasyon ağları ve sosyal ağ analizleri gibi yüksek boyutlu veri kümelerinde başarılı sonuçlar elde edilmiştir (Schölkopf et al., 2021). Bu modeller genellikle türevlenebilir optimizasyon teknikleri kullanarak çizge yapısını sürekli optimizasyon problemi haline dönüştürmektedir.

Bununla birlikte sinir ağı tabanlı döngüsüz yönlendirilmiş karma çizge sistemlerinin önemli sınırlılıkları bulunmaktadır. Öncelikle büyük ölçekli veri kümelerinde hesaplama maliyetleri oldukça yüksektir. Ayrıca açıklanabilirlik problemi halen önemli bir araştırma konusudur (Rudin, 2019). Sinir ağı tabanlı modellerin neden belirli bir nedensel yapı öğrendiğinin açıklanması çoğu zaman zordur. Bunun yanında gizil değişkenlerin doğrudan tahmini halen yeterince güçlü değildir.

Modern literatürde sinir ağı tabanlı döngüsüz yönlendirilmiş karma çizge sistemleri Markov tabanlı öznelik seçimi yöntemleriyle birlikte kullanılmaktadır. Bu sayede yalnızca tahmin performansı değil, aynı zamanda nedensel yorumlanabilirlik de artırılmaya çalışılmaktadır (Lundberg & Lee, 2017).

Tablo 3 Modern Sinir Ağı Tabanlı Nedensel Keşif Modellerinin Karşılaştırılması

Model	Döngüsüz Yönlendirilmiş Çizge	Gizil Karıştırıcı Etki	Sinir Ağı	Türevlenebilir
NOTEARS	+	-	-	+
DAG-GNN	+	-	+	+
Neural ADMG	+	+	+	+

Döngüsüz Yönlendirilmiş Karma Çizge Uygulama Alanları

Döngüsüz yönlendirilmiş karma çizge yapıları günümüzde birçok farklı uygulama alanında kullanılmaktadır. Sağlık alanında hastalık nedenlerinin modellenmesi, ilaç etkilerinin analizi ve klinik karar desteği sistemleri önemli kullanım alanlarıdır (Topol, 2019). Özellikle gizli genetik faktörlerin bulunduğu biyomedikal sistemlerde döngüsüz yönlendirilmiş karma çizge modelleri klasik istatistiksel yöntemlere göre daha başarılı sonuçlar verebilmektedir.

Biyoinformatik alanında gen regülasyon ağlarının çıkarılması için döngüsüz yönlendirilmiş karma çizge tabanlı yaklaşımlar kullanılmaktadır. Genetik sistemlerde birçok gizli biyolojik mekanizma bulunduğundan nedensel çizge modelleri önemli avantaj sağlamaktadır (Kavakiotis et al., 2017).

Siber güvenlik alanında saldırı yayılım modelleri, zararlı yazılım yayılımı analizleri ve anomali tespiti sistemlerinde nedensel keşif yöntemleri kullanılmaktadır (Carcillo et al., 2019). Özellikle bilinmeyen saldırı mekanizmalarının modellenmesi açısından gizli karıştırıcılık temelli döngüsüz yönlendirilmiş karma çizge sistemleri önem kazanmaktadır.

Finansal sistemlerde dolandırıcılık tespiti, risk analizi ve ekonomik politika modellemesi gibi alanlarda nedensel çıkarım yöntemleri yaygınlaşmaktadır. Öneri sistemleri ve kullanıcı davranış analizlerinde de nedensel temsil öğrenmesi yaklaşımlarıyla birlikte döngüsüz yönlendirilmiş karma çizge modelleri kullanılmaktadır (Schölkopf et al., 2021).

Sonuç

Döngüsüz yönlendirilmiş karma çizge literatüründe halen çözülmemiş birçok problem bulunmaktadır. En önemli problemlerden biri ölçeklenebilir yapı öğrenmesi problemidir. Büyük ölçekli çizgelerde koşullu bağımsızlık testlerinin sayısı çok

hızlı arttığından yapı öğrenimi zor hale gelmektedir (Chickering, 2002).

Bir diğer önemli problem gizil değişkenlerin doğrudan tahmin edilememesidir. Günümüzde çoğu model gizil karıştırıcı etkilerin varlığını dolaylı biçimde modellemektedir ancak gerçek gizil yapıların tahmini halen oldukça zordur. Özellikle sürekli değişken sistemlerde teorik eksiklikler bulunmaktadır (Ng et al., 2022).

Sinir ağı tabanlı döngüsüz yönlendirilmiş karma çizge sistemlerinde açıklanabilirlik problemi de önemli bir araştırma alanıdır. Modern derin öğrenme tabanlı nedensel keşif modelleri yüksek performans elde etmesine rağmen, öğrenilen nedensel yapıların yorumlanabilirliği sınırlıdır (Doshi-Velez & Kim, 2017). Ayrıca birçok çalışma yalnızca kıyaslama veri kümeleri üzerinde test edilmiştir ve gerçek zamanlı sistemlerde yeterince doğrulanmamıştır.

Literatürde dikkat çeken bir diğer boşluk ise gerçek zamanlı nedensel keşif problemidir. Günümüzde çoğu döngüsüz yönlendirilmiş karma çizge sistemi çevrimdışı veri kümeleri üzerinde çalışmaktadır. Veri akışı ve çevrimiçi öğrenme senaryolarında nedensel yapı öğrenmesi halen açık araştırma problemi olarak kabul edilmektedir (Hinder et al., 2023; Runge, 2018).

Genel olarak değerlendirildiğinde döngüsüz yönlendirilmiş karma çizge literatürü, klasik döngüsüz yönlendirilmiş çizge modellerinin ötesine geçerek gizil karıştırıcı etki bulunan problemlerin modellenmesini mümkün hale getirmiştir. Özellikle iç içe Markov modelleri, tanımlanabilirlik algoritmaları ve sinir ağı tabanlı döngüsüz yönlendirilmiş karma çizge öğrenmesi yaklaşımları sayesinde alan son yıllarda hızlı biçimde gelişmiştir.

Modern yapay zekâ sistemlerinin açıklanabilirlik ihtiyacının artması ile birlikte nedensel çizge modelleri alanına olan ilgi de artmaktadır. Döngüsüz yönlendirilmiş karma çizge yapıları yalnızca teorik ve istatistik alanında değil, sağlık, biyoinformatik, güvenlik ve öneri sistemleri gibi uygulama alanlarında da önemli hale gelmiştir.

Gelecekte açıklanabilir, ölçeklenebilir ve gerçek zamanlı sinir ağı tabanlı döngüsüz yönlendirilmiş karma çizge sistemlerinin geliştirilmesi literatürdeki en önemli araştırma alanlarından biri olacaktır. Ayrıca temel modeller ve büyük dil modelleriyle nedensel temsil öğrenmesi yaklaşımlarının entegrasyonu, alanın gelecekteki yönelimlerinden biri olarak değerlendirilmektedir (Bommasani et al., 2021; Kıcıman et al., 2023).

Kaynakça

Ali, R. A., Richardson, T. S., & Spirtes, P. (2009). Markov equivalence for ancestral graphs. *The Annals of Statistics*, 37(5B), 2808-2837. <https://doi.org/10.1214/08-AOS626>

Bhattacharya, R., Nabi, R., & Shpitser, I. (2019). Nested Markov model parametrization. *Biometrika*, 106(2), 291-308. <https://doi.org/10.1093/biomet/asz001>

Bommasani, R., Hudson, D. A., Adeli, E., & others. (2021). On the opportunities and risks of foundation models. *arXiv preprint arXiv:2108.07258*.

Carcillo, F., Dal Pozzolo, A., Le Borgne, Y.-A., & others. (2019). Scalable framework for streaming fraud detection. *Information Fusion*, 41, 182-194. <https://doi.org/10.1016/j.inffus.2017.09.005>

Chickering, D. M. (2002). Optimal Structure Identification With Greedy Search. *Journal of Machine Learning Research*, 3(Nov), 507-554.

Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*.

Evans, R. J. (2012). Graphical Markov models for mixed graphs. *Statistical Science*, 27(2), 160-183. <https://doi.org/10.1214/11-STS376>

Hernán, M. A., & Robins, J. M. (2020). *Causal Inference: What If*. Chapman and Hall/CRC.

Hinder, F., Löwe, S., & Vaeth, M. (2023). Online causal structure learning in non-stationary environments. *ICML*.

Kavakiotis, I., Tsave, O., Salifoglou, A., & others. (2017). Machine learning and data mining methods in diabetes research. *Computational and Structural Biotechnology Journal*, 15, 104-116. <https://doi.org/10.1016/j.csbj.2016.12.005>

Kıcıman, E., Ness, R., Sharma, A., & Tan, C. (2023). Causal reasoning and large language models. *arXiv preprint arXiv:2305.00050*.

Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *NeurIPS*, 30, 4765-4774.

Ng, I., Zhu, S., Fang, Z., & others. (2022). Latent causal discovery with deep learning. *ICLR*.

Paindaveine, D., & Verdebout, T. (2017). Inference on the mode of weak directional signals: A Le Cam perspective on hypothesis testing near singularities. *The Annals of Statistics*, 45(2). <https://doi.org/10.1214/16-AOS1468>

Pearl, J. (2009). *Causality: Models, Reasoning, and Inference* (2. bs.). Cambridge University Press.

Richardson, T. S. (2003). Markov properties for acyclic directed mixed graphs. *Scandinavian Journal of Statistics*, 30(1), 145-157. <https://doi.org/10.1111/1467-9469.00323>

Richardson, T. S., & Spirtes, P. (2002). Ancestral graph Markov models. *The Annals of Statistics*, 30(4), 962-1030. <https://doi.org/10.1214/aos/1031689015>

Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206-215. <https://doi.org/10.1038/s42256-019-0048-x>

Runge, J. (2018). Causal network reconstruction from time series. *Chaos*, 28(7), 075310. <https://doi.org/10.1063/1.5025050>

Schölkopf, B., Locatello, F., Bauer, S., & others. (2021). Toward causal representation learning. *Proceedings of the IEEE*, 109(5), 612-634. <https://doi.org/10.1109/JPROC.2021.3058954>

Shpitser, I., & Pearl, J. (2006). Identification of joint interventional distributions in recursive semi-Markovian causal models. *AAAI*, 1219-1226.

Spirtes, P., Glymour, C., & Scheines, R. (2000). *Causation, Prediction, and Search* (2. bs.). MIT Press.

Tian, J., & Pearl, J. (2002). A general identification condition for causal effects. *AAAI*, 567-573.

Topol, E. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44-56. <https://doi.org/10.1038/s41591-018-0300-7>

Verma, T., & Pearl, J. (1990). Equivalence and synthesis of causal models. *UAI*, 220-227.

Yu, Y., Chen, J., Gao, T., & Yu, M. (2019). DAG-GNN: DAG structure learning with graph neural networks. *ICML*, 7154-7163.

Zheng, X., Aragam, B., Ravikumar, P., & Xing, E. P. (2018). DAGs with NO TEARS: Continuous optimization for structure learning. *NeurIPS*, 31, 9472-9483.

Zhu, S., Ng, I., & Chen, Z. (2023). Neural ADMG Learning for latent causal discovery. *arXiv preprint arXiv:2305.14010*.

BÖLÜM 5

SÖZLÜK TABANLI MAKİNE TOPLULUK MODELLERİ İLE TÜRKÇE METİNLERİN DUYGU POLARİTESİ TESPİTİ ÜZERİNE PERFORMANS ANALİZİ

MERVE PINAR¹

KÜBRA BUZLU²

AYŞE BERNA ALTINEL GİRGİN³

ESRA YILMAZ⁴

Giriş

Türkçe, sondan eklemeli morfolojik yapısı ve yüksek yapısal üretkenliği nedeniyle, doğal dil işleme (DDİ) alanında çözümleme ve modelleme açısından önemli dilsel zorluklar barındırmaktadır. Özellikle sondan eklemeli dil yapısı, kelime biçimlerinin ve anlam varyasyonlarının artmasına yol açmakta; bu durum özellikle duygu

¹ Dr., Marmara Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0000-0003-3041-6958

² YL Öğrencisi, Marmara Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0000-0001-7163-8843

³ Doç. Dr., Marmara Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0000-0001-5544-0925

⁴ Dr. Öğrencisi, Marmara Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0000-0003-2411-4937

analizi gibi anlamsal çözümleme gerektiren görevlerde modelleme sürecini daha karmaşık hâle getirmektedir. Türkiye’de internet kullanım oranının 2021’deki %77 seviyesinden 2026 yılı itibarıyla %95’in üzerine çıkması ve üretken yapay zekâ ile sosyal medya platformlarındaki kesintisiz içerik akışı, oldukça büyük bir Türkçe metinsel veri kaynağının oluşmasına neden olmuştur. X (Twitter) platformunun dünya genelinde 650 milyon aktif kullanıcıya dayanması ve üretken yapay zekâ entegrasyonlarıyla birlikte her dakika paylaşılan tweet sayısının 600 binin üzerine çıkması, dijital veri hacminin ulaştığı devasa boyutları açıkça gözler önüne sermektedir (Oğul et al.). Dolayısıyla hem Türkçenin morfolojik özellikleri hem de hızla artan veri üretimi birlikte değerlendirildiğinde, büyük ölçekli Türkçe metinleri doğru ve etkin biçimde analiz edebilecek duygu analizi sistemlerinin geliştirilmesi önemli bir gereklilik hâline gelmektedir.

Duygu Analizi (DA), bir metnin bağlamsal anlamını çıkarmayı amaçlayan bir süreçtir. Bu süreçte metinlerin içerdiği özellikler belirlenir, tanımlanır ve yorumlanır. DA DDİ teknikleri kullanılarak otomatikleştirilebilir. Geniş bir uygulama alanına sahiptir; örneğin, bir metnin duygu kutupluluğunu olumlu, olumsuz veya tarafsız olarak sınıflandırmak, bireylerin bir olay ya da nesneye yönelik görüşlerini, duygularını veya tutumlarını tespit etmek amacıyla kullanılabilir (Altinel, 2021; Graovac et al., 2020). Bu nedenle, pazarlama, siyaset, sosyal medya gibi pek çok alanda etkin bir şekilde kullanılmaktadır. Sosyal ağların yaygınlaşmasıyla birlikte DA giderek daha popüler bir araştırma konusu haline gelmiştir. İnsanların düşüncelerini ve duygularını sosyal medya platformlarında paylaşımları, bu alandaki veri miktarını önemli ölçüde artırmıştır. Veri toplama süreci DA çalışmalarında kritik bir adımdır. Özellikle daha büyük ve kapsamlı veri kümeleri kullanan çalışmaların daha yüksek doğruluk oranlarına ulaştığı gözlemlenmektedir. Ancak, uygun nitelikte veri bulmak çoğu zaman

güçtür. Ayrıca, verilerin etiketlenmesi maliyetli bir süreç olup insan uzmanlığı gerektirmektedir.

DA sürecinde karşılaşılan çeşitli zorluklar bulunmaktadır. Bu zorluklardan biri dil bağımlılığıdır. Farklı diller, farklı düzeylerde yapısal ve dilbilgisel zorluklar içerebilir. Örneğin, Türkçe sonan eklemeli bir dil yapısına sahiptir; bu yapı, kök kelimelere çeşitli eklerin getirilmesiyle yeni kelimeler oluşturulmasına olanak tanır. Bu durum, kelimelerin anlam yönelimlerinde önemli değişimlere neden olabilmektedir. Türkçenin bu morfolojik yapısı nedeniyle, dildeki tüm kelime çeşitlerini içeren kapsamlı bir Türkçe duygu sözlüğü oluşturmak ya da mevcut bir sözlük bulmak oldukça güç, hatta çoğu durumda imkânsız kabul edilmektedir (Altınel et al., 2022).

Türkçeye özgü diğer bir zorluk, Türk alfabesinde İngiliz alfabesinde bulunmayan bazı harflerin yer almasıdır. Bu durum, özellikle çok dilli DDİ sistemleri açısından ek zorluklar oluşturmaktadır. Ayrıca, Türkçe için mevcut duygu sözlüklerinin sınırlı kaynaklara sahip olması, analizlerin kapsamını ve doğruluğunu kısıtlayabilmektedir. Tüm bu etkenler birlikte değerlendirildiğinde, Türkçe üzerinde gerçekleştirilen DA çalışmalarının diğer dillerdeki uygulamalara kıyasla daha zorlu bir yapıya sahip olduğu görülmektedir. DA metinlerin farklı düzeylerde değerlendirilmesiyle gerçekleştirilebilmektedir. Bu düzeyler; görünüm düzeyi, belge düzeyi, cümle düzeyi ve kelime düzeyi olarak sınıflandırılmaktadır. Her düzey, metin içerisindeki duygu bileşenlerini farklı bağlamlarda analiz etmeyi amaçlamaktadır. DA'nın uygulanmasında çeşitli yöntemler kullanılmakta olup, bu yöntemler genellikle dört ana kategori altında toplanmaktadır: sözlük tabanlı yaklaşımlar, derlem tabanlı yaklaşımlar, makine öğrenimi (MÖ) tabanlı yaklaşımlar ve bu yöntemlerin birleştirilmesiyle elde edilen hibrit yaklaşımlar (Altınel, 2021, Altınel Girgin et al., 2022).

Bu çalışma, Türkçe duygu polaritesi tespiti görevine yönelik olarak geliştirilen üç farklı duygu sözlüğünün performansını çeşitli istatistiksel tabanlı anlamsal algoritmalar aracılığıyla karşılaştırmayı amaçlamaktadır. Çalışma kapsamında, Türkçe için halka açık üç yeni duygu sözlüğü oluşturulmuş ve literatürde ilk kez GDELT (Global Database of Events, Language, and Tone) verileri kullanarak Türkçe duygu polaritesi sözlüğü geliştirilmiştir. Bu doğrultuda duygu temelli semantik özellikler ile terim frekansı tabanlı ağırlıklandırma yöntemleri birleştirilerek hibrit bir metin temsili oluşturulmuş ve bu temsil üç farklı Türkçe veri kümesi üzerinde çeşitli makine öğrenmesi algoritmaları ile karşılaştırmalı olarak değerlendirilmiştir. Deneysel sonuçlar, sözlük tabanlı semantik bilginin istatistiksel metin temsilleri ile birlikte kullanılmasının Türkçe duygu polaritesi tespitinde sınıflandırma performansını artırabildiğini ve önerilen yaklaşımın birçok test senaryosunda temel yöntemlere kıyasla daha başarılı sonuçlar ürettiğini göstermektedir.

Bu makale beş ana bölümden oluşmaktadır. İkinci bölümde, Türkçe duygu analizi üzerine yapılan güncel çalışmalar ve literatürdeki yaklaşımlar özetlenmiştir. Üçüncü bölümde, çalışmada kullanılan veri kümeleri, oluşturulan duygu polarite sözlükleri, kullanılan metrikler, deney ortamı ve geliştirilen SentiAF, PolAF, EmoAF, BoostAF, SentiRF, PolRF, EmoRF ve BoostRF algoritmalarına ilişkin yöntemsel ayrıntılar sunulmuştur. Dördüncü bölümde, kullanılan yöntemlerin deneysel sonuçları ve temel yöntemlerle karşılaştırmalı performans analizleri detaylandırılmıştır. Beşinci ve son bölümde ise çalışmanın genel sonuçları değerlendirilmiş ve gelecekte yapılabilecek çalışmalar için önerilerde bulunulmuştur.

İlgili Çalışmalar

Günümüzde sosyal medya gibi büyük ve yapılandırılmamış veri kaynaklarından elde edilen metinler üzerinde gerçekleştirilen duygu analizi çalışmaları, sosyal bilimlerden sağlık alanına kadar önemli bir araştırma alanı haline gelmiştir. Bu doğrultuda, literatürde farklı yöntem ve araçlarla duygu durumunu belirlemeye yönelik çeşitli yaklaşımlar geliştirilmiş ve uygulanmıştır.

Karaöz ve Gürsoy (Karaöz & Gürsoy, 2018) tarafından gerçekleştirilen çalışmada, ileri düzey yazılım bilgisine sahip olmayan sosyal bilimcilerin de nispeten büyük veri kümeleri üzerinde duygu analizi gerçekleştirebilecekleri gösterilmeye çalışılmıştır. Bu amaçla, iki farklı duygu sözlüğü kullanılarak veri kümesindeki kelimelerin polarite değerleri belirlenmiş ve sözlük tabanlı bir duygu analizi uygulanmıştır. Çalışmada kullanılan veri seti, sekiz aylık bir dönemde bir televizyon kanalı hakkında atılmış 1.200.000 tweet'ten oluşmaktadır. Uygulama sürecinde yalnızca R programlama dili ve Excel-VBA araçları kullanılmıştır. Veri kümesi, sistemin eğitimi ve testi için %80 eğitim ve %20 test şeklinde ikiye ayrılmıştır. Elde edilen sonuçlara göre sistemin ortalama doğruluk oranı %68,12 olarak hesaplanmıştır. Bu doğruluk oranı, makine öğrenmesi gibi gelişmiş yöntemlerle gerçekleştirilen duygu analizi çalışmalarının genellikle daha yüksek başarı sağladığını göstermektedir. Çalışmanın temel avantajı, ileri düzey programlama bilgisi gerektirmemesi sayesinde geniş bir kullanıcı kitlesine hitap etmesidir. Buna karşılık, sınırlı doğruluk oranı çalışmanın başlıca dezavantajı olarak değerlendirilmektedir. Gelecekte yapılacak çalışmalarda, daha etkin metin ön işleme yöntemlerinin kullanılması ve duygu sözlüklerinin daha optimize edilmesiyle sistemin performansının artırılması hedeflenmektedir.

Shehu ve Tokat (Shehu & Tokat, 2019) tarafından gerçekleştirilen çalışmada, Türkçe duygu analizi amacıyla Rastgele Orman (Random Forest – RF) ve Destek Vektör Makineleri (Support

Vector Machine – SVM) algoritmalarının birlikte kullanıldığı hibrit bir makine öğrenimi yaklaşımı önerilmiştir. Çalışmada, veri kümesi olarak sırasıyla 3000 ve 10.500 kelimeden oluşan iki ayrı Türkçe mektup koleksiyonu kullanılmıştır. Duygu analizi için kullanılan sözlük, 27.000 İngilizce kelimenin Türkçeye çevrilmesiyle oluşturulmuştur. Analiz sürecinde öncelikle kelime köklerini çıkarmak için Zemberek (Akın & Akın, 2007) adlı DDİ aracı kullanılmıştır. Yazarlar, RF algoritmasının pozitif duyguları sınıflandırmada SVM'e kıyasla daha başarılı sonuçlar verdiğini, buna karşın SVM algoritmasının negatif ve nötr duyguları tespit etmede RF'ten daha üstün performans gösterdiğini rapor etmiştir. Bu bulgulardan hareketle, önerilen hibrit yöntemde veriler önce RF algoritması ile "pozitif" ve "diğerleri" şeklinde iki sınıfa ayrılmış; ardından "diğerleri" sınıfındaki örnekler SVM algoritması kullanılarak "pozitif", "negatif" ve "nötr" olarak yeniden sınıflandırılmıştır. Modelin performansına ilişkin bulgulara göre; 3000 içerikli veri kümesinde SVM %76,4, RF %75,9 ve hibrit yöntem %86,4 doğruluk oranına ulaşmıştır. 10.500 içerikten oluşan daha büyük veri kümesinde ise SVM %67,6, RF %71,2 ve hibrit yöntem %82,8 doğruluk oranı elde etmiştir. Bu sonuçlar, önerilen hibrit yaklaşımın klasik sınıflandırma yöntemlerine kıyasla daha yüksek doğruluk sağladığını göstermektedir. Çalışmanın öne çıkan yönleri; daha geniş duygu sözlüklerinin entegrasyonu ve sınıflandırma algoritmalarının geliştirilmesiyle doğruluk oranının artırılabilceği esnek ve geliştirilebilir bir model sunmasıdır. Ayrıca, önerilen hibrit yaklaşımın farklı veri kümeleri üzerinde test edilerek genellenebilirliğinin artırılması mümkündür.

Tuncer ve Çetintaş (Tuncer & Çetintaş, 2019) tarafından gerçekleştirilen çalışmada, Twitter platformundan elde edilen tweet'lerin duygusal içeriklerine göre olumlu, tarafsız ve olumsuz olarak sınıflandırılması ve aynı zamanda kötü niyetli içeriklerin tespiti amaçlanmıştır. Sınıflandırma sürecinde Karar Ağacı

(Decision Tree – DT) ve Naive Bayes (NB) algoritmaları kullanılmıştır. Çalışma kapsamında 20.000 tweet'ten oluşan bir veri kümesi derlenerek analizlerde kullanılmıştır. Veri işleme ve modelleme sürecinde Knime yazılımı ile Excel makroları destekleyici araçlar olarak kullanılmıştır. Elde edilen sonuçlara göre, DT algoritması ile ortalama %75,2 ve NB algoritması ile ortalama %56 doğruluk oranı elde edilmiştir. Çalışmanın önemli avantajlarından biri, sınıflandırma sürecinin ikili aşamalar hâlinde yürütülmesi sayesinde analizlerin daha gözlemlenebilir ve yorumlanabilir hâle gelmiş olmasıdır. Bununla birlikte, çalışmanın sınırlılığı olarak bazı Türkçe metinlerin çeviri ve ön işleme süreçlerinde eksikliklerin bulunduğu ifade edilmiştir.

Kemaloğlu ve arkadaşları (Kemaloğlu et al., 2021) tarafından yürütülen çalışmada, sosyal medya verileri üzerinden Türkçe duygu analizi gerçekleştirilmiştir. Çalışmada, makine öğrenmesi algoritmaları olarak Lojistik Regresyon (Logistic Regression – LR) ve RF, derin öğrenme yöntemi olarak ise Uzun Kısa Süreli Bellek (Long Short-Term Memory – LSTM) ağı kullanılmıştır. Veri kümesi, beş farklı sosyal medya platformundan toplanan ve toplamda 28,189 gönderiden oluşan içeriklerden elde edilmiştir. Bu veriler, manuel olarak "pozitif", "negatif" ve "nötr" olmak üzere etiketlenmiştir. Etiketleme sonucunda veri kümesi; 5712 olumlu, 11.567 olumsuz ve 11.247 tarafsız içerik içermektedir. Deneysel sonuçlar, derin öğrenme modellerinin performans açısından makine öğrenmesi tabanlı yaklaşımlara kıyasla daha üstün olduğunu göstermektedir. RF algoritması, makine öğrenmesi yöntemleri arasında en yüksek doğruluk oranına (%84,24) ulaşırken, genel değerlendirmede LSTM modeli %84,46 doğruluk oranı ile en yüksek performansı sergilemiştir.

Ballı ve arkadaşları (Ballı et al., 2022) tarafından yürütülen çalışmada, Türkçe tweet'ler üzerinde duygu analizi gerçekleştirilmesi amaçlanmıştır. Çalışmanın temel hedefi, Twitter

kullanıcılarının paylaştığı içerikleri "olumlu", "olumsuz" ve "tarafsız" kategorilerine ayırarak duygu durumlarının belirlenmesidir. Bu doğrultuda, biri kamuya açık genel bir veri kümesi, diğeri ise 11.000 tweet içeren ve herkese açık olarak sunulan özel olarak oluşturulmuş SentimentSet adlı veri kümesi olmak üzere iki farklı Twitter veri kümesi kullanılmıştır. Veri kümeleri hazırlandıktan sonra, içeriklerin sınıflandırmaya uygun hâle getirilmesi amacıyla kapsamlı bir ön işleme süreci uygulanmıştır. Sınıflandırma sürecinde kullanılmak üzere metinler, TF-IDF (Term Frequency–Inverse Document Frequency) yöntemiyle sayısal vektörlere dönüştürülmüştür. Ardından, makine öğrenmesi algoritmaları olarak LR, RF, NB ve SVM; derin öğrenme yöntemi olarak ise LSTM modeli uygulanmıştır. Modellerin eğitilmesi ve test edilmesi sonucunda, RF ve LSTM algoritmalarının %85 doğruluk oranı ile en yüksek başarıyı sağladığı belirlenmiştir. Bu bulgular hem klasik makine öğrenmesi hem de derin öğrenme yöntemlerinin Türkçe sosyal medya verileri üzerinde etkili olabileceğini göstermektedir.

Mutlu ve Özgür (Mutlu & Özgür, 2022) tarafından gerçekleştirilen çalışmada, Türkçe metinler üzerinde hedefe yönelik duygu analizi gerçekleştirmeye odaklanan bir yöntem önerilmiştir. Hedefe yönelik duygu analizi, klasik duygu analizinden farklı olarak metnin genel duygusunu belirlemek yerine, belirli bir hedef veya bağlam doğrultusunda duyarlılığı tahmin etmeyi amaçlamaktadır. Bu amaç doğrultusunda, farklı mimariler kullanılarak BERT (Bidirectional Encoder Representations from Transformers) tabanlı modeller geliştirilmiş ve uygulanmıştır. BERT, DDİ alanında yaygın olarak kullanılan sinir ağı temelli bir modeldir. Çalışmada kullanılan veri kümesi, Twitter platformundan toplanan paylaşımlardan oluşmaktadır. Etiketleme sonuçlarına göre verilerin %19'u olumlu, %58'i olumsuz ve %23'ü nötr duygular içermektedir. Önerilen BERT modeli, bu veri kümesi üzerinde eğitilmiş ve test edilmiştir.

Deneyisel analizler sonucunda, önerilen modelin aynı veri kümesi üzerinde test edildiğinde %67 F1 skoru elde ettiği ve temel BERT modellerine kıyasla daha iyi bir performans sergilediği belirlenmiştir.

Aktaş ve arkadaşları (Aktaş et al., 2021), makine öğrenimi yöntemlerini kullanarak bir çevrimiçi yemek siparişi platformuna ait kullanıcı yorumları üzerinde Türkçe duygu analizi gerçekleştirmiştir. Önerilen model, kullanıcı incelemelerinin olumlu mu yoksa olumsuz mu olduğunu tahmin etmeyi amaçlamaktadır. Bu kapsamda, yemeksepeti.com üzerinden 676.000 kullanıcı yorumu toplanarak veri kümesi oluşturulmuştur. Bu yorumların 338.000'i olumlu, kalan 338.000'i ise olumsuz olarak etiketlenmiştir. Veri kümesine ön işleme adımları kapsamında köke indirgeme işlemi (lemmatization) ve normalizasyon işlemleri uygulanmıştır. Sınıflandırma sürecinde K-En Yakın Komşu (KNN), NB ve yapay sinir ağları (YSA) gibi çeşitli makine öğrenimi ve derin öğrenme algoritmaları kullanılmıştır. Deneyisel sonuçlara göre, yapay sinir ağı modeli %86,37 doğruluk oranı ile en yüksek performansı göstermiştir. NB ve KNN modelleri sırasıyla %83,55 ve %81,88 doğruluk oranlarına ulaşmıştır. Bu sonuçlar, derin öğrenme tabanlı yaklaşımların klasik makine öğrenimi yöntemlerine kıyasla daha yüksek doğruluk sağladığını ortaya koymaktadır.

Onan (Onan, 2022) tarafından yürütülen çalışmada, Türkçe metin madenciliği kapsamında dikkat mekanizması tabanlı derin öğrenme mimarilerinin performanslarının karşılaştırılması amaçlanmıştır. Metin sınıflandırma problemlerinde sıklıkla kullanılan Tekrarlayan Sinir Ağı (Recurrent Neural Network – RNN), LSTM ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit – GRU) mimarileri, özellikle sıralı veri yapılarında yaygın olarak tercih edilmektedir. Ancak bu mimariler, özellikle uzun diziler üzerinde öğrenme sırasında karşılaşılan kaybolan gradyan problemi nedeniyle öğrenme verimliliğini düşürebilmektedir. Bu sorunun

üstesinden gelmek amacıyla, çalışmada dikkat mekanizması entegre edilmiştir. Dikkat mekanizması, modelin giriş cümlesindeki tüm bilgiye erişmesini sağlayarak, daha etkili ve başarılı bir öğrenme süreci sunmayı hedeflemektedir. Çalışmada, LSTM, RNN ve GRU mimarileri üzerine dikkat mekanizmasının entegre edilmesiyle oluşturulan modeller deneysel olarak karşılaştırılmıştır. Elde edilen bulgular, dikkat mekanizması tabanlı derin öğrenme mimarilerinin duygu analizi problemi bağlamında metin sınıflandırma doğruluğunu artırdığını göstermektedir. Bu sonuç, dikkat mekanizmasının Türkçe metinler üzerinde derin öğrenme tabanlı duygu analizi uygulamalarında etkili bir katkı sunduğunu ortaya koymaktadır.

Engin ve arkadaşları (Kandiran et al., 2022) tarafından gerçekleştirilen çalışmada, COVID-19 pandemisi sürecinde uygulanan uzaktan eğitimin Türk toplumu üzerindeki etkileri, Twitter üzerinden elde edilen veriler aracılığıyla analiz edilmiştir. Veri toplama sürecinde, eğitimle ilgili 28 farklı etiket belirlenmiş ve bu etiketlere ilişkin 8545 Türkçe tweet, Twitter API aracılığıyla toplanarak bir veri kümesi oluşturulmuştur. Bu tweet'ler, Türkiye'de uzaktan eğitimin uygulandığı 16 Mart 2020 ile 17 Mayıs 2021 tarihleri arasında paylaşılmıştır. Çalışmada yalnızca sosyal medya verileri değil, aynı zamanda Türkiye Cumhuriyeti Sağlık Bakanlığı tarafından günlük olarak açıklanan COVID-19 vaka sayıları da dikkate alınmıştır. Bu kapsamda, vaka sayılarının tweet içerikleri üzerindeki olası etkileri değerlendirilmiştir. Analiz sürecinde, veri kümesinde en sık geçen kelimeler ve kelime öbekleri belirlenmiş; bu ifadelerin olumlu ya da olumsuz içerik taşıyıp taşımadığı incelenmiştir. Elde edilen bulgulara göre, vaka sayılarındaki artışla birlikte uzaktan eğitimle ilgili tweet sayısında da artış gözlemlenmiş; ayrıca, bu tweet'lerin büyük çoğunluğunun sağlıkla ilgili endişeler nedeniyle uzaktan eğitimi olumlu bir çözüm olarak değerlendiren içerikler olduğu tespit edilmiştir.

Taşar ve arkadaşları (Taşar et al., 2022) tarafından gerçekleştirilen çalışmada, Türkçe DDİ alanında duygu analizi gerçekleştirmek amacıyla Huggingface.co platformunda yer alan AutoTrain aracı kullanılmıştır. Çalışmanın temel amacı, AutoTrain platformunun Türkçe dilinde duygu analizi performansını değerlendirmek ve derin öğrenme tabanlı duygu analizi yöntemlerinin, alan uzmanı olmayan bireyler tarafından da uzman düzeyinde modeller üretilip üretilmeyeceğini test etmektir. AutoTrain, kullanıcıların herhangi bir kod yazmadan otomatik olarak makine öğrenimi modelleri eğitmesine olanak tanıyan bir platformdur. Çalışma kapsamında, AutoTrain aracı kullanılarak pozitif, negatif ve nötr olmak üzere üç sınıftan oluşan beş farklı duygu analizi modeli geliştirilmiş ve değerlendirilmiştir. Elde edilen deneysel sonuçlara göre, geliştirilen modellerin doğruluk oranları %95'in üzerinde çıkmıştır. Bu sonuçlar, AutoTrain platformunun Türkçe metinler üzerinde başarılı bir performans sergilediğini ortaya koymaktadır. Ayrıca, dengesiz dağılıma sahip bir veri kümesi üzerinde yapılan değerlendirmelerde, AutoTrain ile yalnızca bir saat içerisinde, uzman personel tarafından geliştirilen modellerle kıyaslanabilir başarıda bir duygu analizi modelinin üretilbildiği belirlenmiştir. Bu bulgular, düşük teknik bilgiye sahip kullanıcıların dahi yüksek doğruluk oranına sahip NLP modelleri geliştirebileceğini göstermektedir.

Çılgın ve arkadaşları (Çılgın et al., 2023) tarafından yürütülen çalışmada, Türkiye'de sosyal medya kullanıcılarının COVID-19 aşılarna yönelik tutumlarının incelenmesi amaçlanmıştır. Bu doğrultuda, Twitter üzerinden belirlenen etiketler aracılığıyla toplanan veriler ön işleme tabi tutulmuş ve ardından bir veri kümesi oluşturulmuştur. Sınıflandırma amacıyla altı farklı makine öğrenmesi algoritması kullanılmıştır: LR, KNN, SVM, NB, Ekstrem Gradyan Artırma (Extreme Gradient Boosting – XGBoost) ve RF. Deneysel analizler sonucunda, en yüksek doğruluk oranlarına

ulařan SVM, XGBoost ve RF algoritmalarının bir araya getirilmesiyle kolektif öğrenme yaklaşımına dayanan çoğunluk oylama yöntemi oluşturulmuştur. Bu kapsamda hem Sert Oylama (Hard Voting) hem de Yumuşak Oylama (Soft Voting) yaklaşımları değerlendirilmiştir. Elde edilen sonuçlara göre, Soft Voting yöntemi %90,5 doğruluk oranı ile hem bireysel makine öğrenimi algoritmalarından hem de Hard Voting yaklaşımından daha yüksek performans sergilemiştir. Bu bulgular, önerilen yöntem ile sosyal medya verileri aracılığıyla COVID-19 aşılara ilişkin toplumsal tutumların etkili bir şekilde izlenebileceğini ve analiz edilebileceğini göstermektedir.

Dönmez ve Aslan (Dönmez & Aslan, 2021) tarafından gerçekleştirilen çalışmada, NLP uygulamaları kapsamında metin sınıflandırma ve duygu analizi problemlerine yönelik yeni bir yaklaşım önerilmiştir. Çalışmada, metinlerdeki üst anlam ilişkilerini ortaya çıkarmak ve metnin duygusal içeriğini analiz edebilmek amacıyla, daha önce metin madenciliği alanında sınırlı sayıda kullanılmış olan Wavelet (Dalgacık Dönüşüm) yöntemi uygulanmıştır. Çalışmanın temel amacı, bu yöntemin duygu analizi probleminin çözümüne olan katkısını değerlendirmektir. Önerilen yöntemde, metinlerden terim-frekans matrisleri oluşturulmuş, ardından bu matrisler Haar dönüşüm matrisi ile çarpılarak D matrisi elde edilmiştir. Bu matrisin içerdiği ağırlıklara dayanarak, ilgili metnin hangi duygu sınıfına ait olduğu belirlenmiştir. Çalışmada, önerilen Wavelet yöntemi; SVM, Çok Katmanlı Yapay Sinir Ağları (Multilayer Perceptron – MLP) ve Çok Değişkenli Doğrusal Regresyon (Multivariate Linear Regression) gibi klasik sınıflandırma algoritmalarıyla hibrit olarak uygulanmıştır. Deneysel bulgular, Wavelet yöntemi ile geliştirilen bu hibrit modellerin, söz konusu algoritmaların doğruluk oranlarını yaklaşık %5 oranında artırdığını göstermektedir.

Kılıçer ve Şamlı (Kılıçer & Şamlı, 2023) tarafından gerçekleştirilen çalışmada, e-ticaret sitelerinde yer alan elektronik cihazlara ilişkin kullanıcı yorumları üzerinden Türkçe duygu analizi yapılmıştır. Çalışmada, ön işleme adımlarının uygulanmasının ardından 15.170 yorumdan elde edilen 11.412 Türkçe ürün yorumu analiz edilmiştir. Yorumlar, "pozitif", "negatif" ve "nötr" olmak üzere üç sınıfa ayrılmıştır. Sınıflandırma sürecinde WEKA arayüzü kullanılarak sekiz farklı makine öğrenmesi algoritması uygulanmıştır: IBK, KStar, NB, NB Multinomial (NBM), SVM, DT ve RF. Algoritmaların performansı, K-katmanlı çapraz doğrulama yöntemi kullanılarak; kesinlik (precision), duyarlılık (recall), F1 skor ve Eğri Altı Alan (Area Under the Curve – AUC) metrikleri üzerinden değerlendirilmiştir. Elde edilen bulgulara göre, NBM ve RF algoritmaları en yüksek başarıyı göstermiştir. NBM algoritması %84 AUC, %69 doğruluk ve %69 F-skor değerleriyle genel olarak en yüksek performansı sağlamıştır. RF algoritması ise %84 AUC, %68 doğruluk ve %66 F-skor ile güçlü bir alternatif olarak öne çıkmıştır. Çalışmanın dikkat çeken yönlerinden biri, nötr yorumların sınıflandırılmasında elde edilen yüksek başarı olmuştur. Bu durum, nötr duygu sınıfının doğru sınıflandırılmasının zorluklarına rağmen etkili yöntemlerin uygulanabildiğini göstermekte ve bu alanda daha fazla araştırma yapılması gerektiğine işaret etmektedir. Ayrıca, farklı makine öğrenimi algoritmalarının karşılaştırmalı olarak değerlendirilmesi, algoritma seçiminin duygu analizinin başarısı üzerindeki belirleyici etkisini açıkça ortaya koymuştur.

Arzu ve Aydoğan (Arzu & Aydoğan, 2023), Türkçe ürün yorumları üzerinde duygu sınıflandırması gerçekleştirmek amacıyla farklı Transformers tabanlı modelleri karşılaştırmalı olarak incelemişlerdir. Çalışmada 150.000 etiketli yorumu içeren TRSAv1 veri seti kullanılmış ve veri, dengeli şekilde pozitif, negatif ve nötr sınıflarına ayrılmıştır. Toplamda sekiz BERTurk ve iki ELECTRA varyasyonu olmak üzere on önceden eğitilmiş model

değerlendirilmiş, modellerin eğitimi Python dili ile Google Colab ortamında gerçekleştirilmiştir. Performans ölçümleri doğruluk ve F1 skor metrikleri üzerinden yapılmıştır. Ayrıca, üç farklı ön işleme stratejisi uygulanmıştır: ham veri, durak kelimeler, özel karakterler ve noktalama işaretlerinden arındırılmış veri, etkili-yoğun kelimeler çıkarılarak oluşturulmuş alternatif ön işlemeli veri. Ham veri ile yapılan deneylerde %82,89 doğruluk ve F1 skoru ile ConvBERTurk mC4 (uncased) modeli en iyi sonucu vermiştir. Durak kelimelerin çıkarılması bu oranı %83,05'e yükseltirken, etkili-yoğun kelimelerin çıkarılması doğruluk oranını %81,32'ye düşürmüştür. Elde edilen bulgular, ön işleme stratejilerinin model başarısı üzerinde önemli bir etkiye sahip olduğunu göstermekte; ConvBERTurk modelleri en yüksek başarıyı sergilerken, DistilBERTurk (cased) modelinin en düşük performansa sahip olduğu raporlanmıştır. Bu çalışma, Türkçe duygu sınıflandırma alanında Transformers mimarilerinin etkili birer alternatif olduğunu ortaya koymakta ve ön işleme adımlarının başarıya katkısını vurgulamaktadır.

Gündüz (Gündüz, 2023), Türkçe film yorumları üzerinde duygu analizi gerçekleştirdiği çalışmasında, Türkmenoğlu ve Tantuğ tarafından oluşturulan ve beyazperde.com'dan elde edilen 54.242 yorumdan oluşan veri setini kullanmıştır. Yorumlar ikili sınıflara (pozitif ve negatif) ayrılarak değerlendirilmiş ve Türkçeye özgü önceden eğitilmiş BERTurk modeli temel alınarak üç farklı yöntem uygulanmıştır: BERTurk'ten elde edilen derin temsiller ile SVM sınıflandırması, doğrudan ince ayarlanan BERTurk modeliyle sınıflandırma, ince ayarlı BERTurk modelinden çıkarılan temsillerin SVM algoritmasıyla sınıflandırılması. Üçüncü yöntem en başarılı sonuçları vermiş; %98,4 doğruluk ve %98,1 F1 skor ile diğer yaklaşımları geride bırakmıştır. Çalışmada doğruluk, duyarlılık, kesinlik ve F1 skor gibi değerlendirme metrikleri kullanılarak kapsamlı bir performans analizi gerçekleştirilmiştir. Elde edilen bulgular, BERTurk tabanlı derin temsillerin SVM ile

birleştirilmesinin Türkçe duygu analizinde yüksek doğruluk sağlayan güçlü bir yöntem olduğunu ortaya koymaktadır.

Görmez ve arkadaşları (Görmez et al., 2024), Türkçe metinlerde duygu analizi gerçekleştirmek amacıyla evrişimsel sinir ağı (CNN), Transformer tabanlı modeller ve hibrit yapılar olmak üzere üç farklı derin öğrenme yaklaşımı önermiştir. Çalışmada, 489.644 örnekten oluşan geniş ölçekli Winvoker veri seti ile 10.662 film yorumundan oluşan daha küçük ölçekli Beyazperde veri seti kullanılmıştır. Model performansını artırmak amacıyla hiperparametreler Bayesian optimizasyon yöntemiyle ayarlanmış; HTML temizliği, noktalama işaretlerinin ve etkisiz kelimelerin çıkarılması, Zemberek kütüphanesi ile metin normalleştirme ve nadir kelimelerin elenmesi gibi çeşitli ön işleme adımları uygulanmıştır. Deneysel sonuçlara göre, ön işleme yapılmamış verilerle Winvoker setinde %94,16, Beyazperde setinde %86,64 doğruluk oranı elde edilirken; ön işleme sonrası bu oranlar sırasıyla %94,64 ve %89,08'e yükselmiştir. Bu bulgular, ön işlemenin özellikle küçük veri setlerinde model performansını anlamlı ölçüde artırdığını ortaya koymuştur. Ayrıca, CNN tabanlı modelin Beyazperde veri setinde daha önce kullanılan LR ve Adaboost modellerine kıyasla daha başarılı olduğu, ancak daha büyük bir Beyazperde sürümüyle eğitilen BERT modelinin gerisinde kaldığı belirlenmiştir.

Altınel Girgin ve arkadaşları (Girgin et al., 2024) tarafından gerçekleştirilen bu derleme çalışmasında, metin madenciliği alanında önemli bir konu olan duygu analizinin temel kavramları açıklanmış ve özellikle Türkçe metinler üzerine yapılan çalışmalar sistematik bir biçimde incelenmiştir.

Çevrimiçi kaynaklardan (sosyal medya, bloglar, haber siteleri vb.) üretilen büyük veri miktarının etkisiyle son yıllarda giderek daha fazla önem kazanan duygu analizine yönelik Türkçe literatür, çalışmada üç ana başlık altında sınıflandırılmıştır: sözlük

tabanlı yaklaşımlar, makine öğrenmesi tabanlı yaklaşımlar ve hibrit yöntemler. Bu kategorilendirme sayesinde araştırmacıların yöntemler, veri setleri ve kullanılan sözlükler bakımından karşılaştırmalı analiz yapabilmelerine olanak sağlanmıştır. Ayrıca, duygu seviyelerine dayalı analiz yapan çalışmalar da ayrı bir başlık altında ele alınmıştır. Literatürde yalnızca Türkçe duygu analizine odaklanan ve bu denli kapsamlı bir sınıflandırma sunan başka bir güncel derleme bulunmadığı belirtilerek çalışmanın özgün niteliği vurgulanmıştır. Bu yönüyle çalışma, Türkçe duygu analizi alanında önemli bir başvuru kaynağı niteliği taşımakta ve araştırma alanına anlamlı bir katkı sunmaktadır.

Tepecik ve Demir (Tepecik & Demir, 2023) tarafından gerçekleştirilen çalışmada, Türkçe ses kayıtlarına dayalı yeni bir duygu veri seti oluşturulmuş ve bu veri seti üzerinden duygu tespiti ile çeşitli makine öğrenimi algoritmalarının performansları analiz edilmiştir. Çalışmanın temel amacı, Türkçe duygu analizinde kullanılabilecek bir veri tabanı sunmak, BERT modelinin Türkçeye özgü yapısına katkı sağlamak ve makine öğrenimi algoritmalarının Türkçe dilindeki sınıflandırma başarılarını değerlendirmektir. Veri seti, Mozilla'nın Common Voice platformundan elde edilen ve büyük oranda haber videoları ile kullanıcı kayıtlarından oluşan 20.760 ses verisinin işlenmesiyle oluşturulmuş; tekrar eden, anlamsız ve sayısal ifadeler elendikten sonra 5001 metinden oluşan nihai veri seti elde edilmiştir. Her metin "negatif", "pozitif" veya "nötr" olarak etiketlenmiş; veri seti %48,7 nötr, %39,7 negatif ve %11,6 pozitif ifadeler içerecek şekilde dağılım göstermiştir. Duygu tespiti sürecinde BERT modeli ve Python programlama dili kullanılmış; NB, SVM, RF, DT ve KNN algoritmaları ile değerlendirme yapılmıştır. Vektörleştirme işlemleri Python ortamında hem CountVectorizer hem de TF-IDF ile gerçekleştirilirken, RapidMiner platformunda yalnızca TF-IDF yöntemi uygulanmıştır. Python ortamında en yüksek doğruluk oranı

%67 ile NB ve SVM algoritmalarından elde edilirken; RapidMiner ortamında en iyi sonuç %60,61 ile NB algoritmasına aittir. Sonuçlar, Türkçede CountVectorizer yöntemiyle NB'nin, TF-IDF yöntemiyle ise SVM algoritmasının daha etkili olduğunu ortaya koymuştur. Ayrıca, RapidMiner ortamında DT algoritmasının da bazı metriklerde tatmin edici sonuçlar verdiği raporlanmıştır. Çalışma, hem Türkçeye özgü bir ses temelli duygu veri seti sunması hem de BERT modelinin Türkçedeki uygulanabilirliğine yönelik örnek teşkil etmesi açısından literatüre önemli bir katkı sağlamaktadır.

Tablo 1. Literatür özeti karşılaştırma tablosu

Çalışma	Çalışmanın Yapıldığı Yıl	Model	Başarı Oranı
Koruyan	2025	MÖ tabanlı Sıfır-atış(zero-shot) metin sınıflandırma	%75-88 Doğruluk, %72-88 F1 skor
Tepecik ve Demir	2024	Naive Bayes (NB) ve SVM	%67 Doğruluk
Altunel Girgin ve ark.	2024	-	Derleme, kapsamlı inceleme
Görmez ve ark.	2024	CNN ve Transformer tabanlı model	%94,64 Doğruluk (Winvoker), %89,08 Doğruluk (Beyazperde)
Gündüz	2023	İnce ayarlı BERTurk + SVM	%98,4 Doğruluk, %98,1 F1 skor
Arzu ve Aydoğan	2023	ConvBERTurk mC4	%82,89 Doğruluk, %83.05 F1 skor (ön işlemeli)
Kılıçer ve Şamlı	2023	Naive Bayes Multinomial (NBM)	%69 Doğruluk, %69 F1 skor, %84 AUC
Ballı ve ark.	2022	Random Forest ve LSTM	%85 Doğruluk
Mutlu ve Özgür	2022	BERT	%67 F1 skor
Aktaş ve ark.	2022	CNN	%86,37 Doğruluk
Onan	2022	Dikkat mekanizmalı LSTM/GRU/RNN modelleri	%89,96 Doğruluk
Taşar ve ark.	2022	HuggingFace AutoTrain	%97 F1 skor
Çılgın ve ark.	2022	SVM + XGBoost + RF Topluluk Öğrenme	%90,5 Doğruluk
Kemaloğlu ve ark.	2021	LSTM	%84,24 Doğruluk
Dönmez ve Aslan	2020	Wavelet (Haar) + SVM/MLP/MLR hibrit modeller	%88 Doğruluk
Shehu ve Tokat	2019	RF + SVM Hibrit Model	%75,2 Doğruluk
Tuncer ve Çetintaş	2019	Karar Ağacı	%82,8 Doğruluk
Karaöz ve Gürsoy	2018	Sözlük tabanlı duygu analizi (R + Excel-VBA)	%68,12 Doğruluk

Koruyan (Koruyan, 2025), restoranlara yönelik müşteri yorumları üzerinden memnuniyet düzeyini analiz etmek amacıyla DDİ ve MÖ tabanlı bir sıfır-atış(zero-shot) metin sınıflandırma yöntemi önermiştir. Araştırma kapsamında, İzmir Körfezi çevresindeki 89 balık restoranına ait 2013–2023 yılları arasında yapılmış toplam 15.305 çevrimiçi müşteri yorumu analiz edilmiştir. Yorumların %89’u Türkçe olmak üzere 43 farklı dilde yazılmıştır. Çalışma, yorumları "yemek kalitesi", "servis kalitesi", "fiziksel

çevre" ve "adil fiyat" olmak üzere dört kalite boyutunda sınıflandırmayı hedeflemiştir. Model performansı doğruluk, kesinlik, duyarlılık ve F1 skoru gibi ölçütlerle değerlendirilmiş; veri dengesizliğini azaltmak amacıyla alt örnekleme yöntemi uygulanmıştır. Model genel olarak %75–88 doğruluk ve %72–88 F1 puanları ile başarılı sonuçlar elde etmiştir. Bununla birlikte, özellikle servis kalitesi gibi bazı sınıflarda düşük kesinlik ve duyarlılık değerleri gözlemlenmiş; bu durumun, yorumların kısa ve genel ifadeler içermesinden kaynaklı olduğu belirtilmiştir. Önerilen yöntem, restoran yöneticilerinin müşteri yorumlarını otomatik olarak analiz etmesine, güçlü ve zayıf yönleri belirlemesine ve farklı müşteri segmentlerine yönelik stratejiler geliştirmesine katkı sağlayacak niteliktedir. Gelecek çalışmalar için, veri artırımı, farklı dil modellerinin karşılaştırmalı olarak denenmesi ve duygu yoğunluğunun ölçülmesine yönelik önerilerde bulunulmuştur.


Yukarıda incelenen çalışmaların başarı oranları Tablo 1’de özetlenmiştir. Taşar ve arkadaşlarının (Taşar et al., 2022) çalışması %97 F1 puanı ile en yüksek F1 performansına ulaşmış ve AutoTrain platformunun Türkçe duygu analizi uygulamalarında yüksek doğruluk sağlayabildiğini göstermiştir. Bu bağlamda söz konusu çalışma, uzman bilgi gerektirmeden derin öğrenme temelli modellerin kısa sürede etkili bir şekilde geliştirilebileceğini ortaya koymakta ve doğal dil işleme alanına önemli katkı sunmaktadır. Literatürdeki bu çalışmaların detaylı incelenmesi, yöntemsel başarıların ve uygulama alanlarındaki etkilerin daha iyi anlaşılmasına olanak sağlamaktadır. Türkçe duygu analizi üzerine yapılan bu araştırmalar, farklı veri kümeleri ve yöntemler kullanarak çeşitli yaklaşımlar önermekte; her biri kendi içinde avantajlar ve sınırlılıklar barındırmaktadır. Duygu analizi alanında kullanılan algoritmaların ve ön işleme tekniklerinin çeşitliliği, bu araştırma alanının hem metodolojik hem de uygulamalı açıdan ne denli dinamik ve zengin olduğunu göstermektedir.

Literatürde Türkçe duygu analizi üzerine gerçekleştirilen çalışmalar incelendiğinde, çoğu araştırmanın belirli veri kümeleri üzerinde sınırlı sayıda yöntem kullanarak performans karşılaştırmaları yaptığı görülmektedir. Bununla birlikte, farklı veri kümeleri üzerinde yöntemlerin aynı deneysel çerçeve içerisinde sistematik olarak değerlendirildiği çalışmaların sınırlı olduğu dikkat çekmektedir. Bu çalışmada ise yaygın olarak kullanılan makine öğrenmesi algoritmaları farklı veri kümeleri üzerinde aynı deneysel ortamda değerlendirilmiş ve duygu temelli özellikler ile terim frekansı tabanlı özelliklerin birleştirildiği hibrit bir özellik temsili kullanarak kapsamlı bir performans analizi gerçekleştirilmiştir. Çalışma kapsamında, Türkçe için halka açık üç yeni duygu sözlüğü oluşturulmuş ve literatürde ilk kez GDELT verisi kullanılarak bu kapsamda Türkçe duygu polaritesi tespitinde kullanılmıştır. Bu doğrultuda duygu temelli semantik özellikler ile terim frekansı tabanlı ağırlıklandırma yöntemleri birleştirilerek hibrit bir metin temsili oluşturulmuş ve bu temsil üç farklı Türkçe veri kümesi üzerinde çeşitli makine öğrenmesi algoritmaları ile karşılaştırmalı olarak değerlendirilmiştir. Böylece, Türkçe duygu analizi alanındaki yöntemlerin karşılaştırmalı olarak değerlendirilmesine katkı sağlanmıştır.

Materyal ve metot

Bu çalışmada Sözlük Tabanlı Makine Öğrenmesi Topluluk Modelleri (STMTM) olarak adlandırılan sistemin genel mimarisi Şekil 1’de verilmiştir. Bu sistem; veri kümesi oluşturma, sözlük oluşturma ve sınıflandırma olmak üzere üç temel alt modülden oluşmaktadır. Sistemde kullanılan veri kümeleri ve duygu sözlükleri, ilgili alt modüller aracılığıyla oluşturulmuştur. Elde edilen bu veri kümeleri ve sözlükler, istatistiksel tabanlı anlamsal makine öğrenmesi algoritmalarının deneysel değerlendirmelerinde kullanılmıştır. Şekilde yer alan algoritmalar ise, bu çalışma

kapsamında geliştirilen istatistiksel tabanlı anlamsal makine öğrenmesi yöntemlerini temsil etmektedir.



Şekil 1. Sözlük tabanlı makine topluluk modelleri (STMTM) sisteminin genel mimarisi


Deneyde kullanılan sözlükler

Sözlüklerde kullanılan polarite değeri, bir sözcüğün olumlu (pozitif) ya da olumsuz (negatif) anlam taşıyıp taşımadığını ifade etmektedir. Buna karşılık, duygu polarite değeri yalnızca ikili (negatif/pozitif) bir sınıflandırmayla sınırlı kalmayıp; öfke, korku, sevinç, üzüntü, nezaket, hayal kırıklığı ve heyecan gibi daha ayrıntılı ve çeşitli duygusal durumların birleşimini yansıtmaktadır. Bu bağlamda, negatif değerler olumsuz duyguları, pozitif değerler ise olumlu duyguları temsil etmektedir.

Çeviri sözlük

Çeviri sözlüğü, daha önceki bir çalışmamızda (Altınel et al., 2022) oluşturulan ve SWNetTR sözlüğü (SAĞLAM et al., 2019; Sağlam et al., 2016) temel alınarak hazırlanan sözlük üzerine çeşitli eklemeler yapılmak suretiyle genişletilmiştir. Bu genişletme sürecinde, SWNetTR sözlüğünün kapsamını artırmak amacıyla 117 binden fazla kelime içeren SentiWordNet sözlüğü, Google Translate aracılığıyla Türkçeye çevrilmiş ve morfolojik analiz işlemleri GDELT verileri kullanılarak gerçekleştirilmiştir. Her bir kelime için

polarite değeri hesaplanmış, ayrıca kelimelere karşılık gelen duygu polarite değerleri de eklenmiştir. SWNetTR sözlüğünde yer almayan yeni kelimeler sözlüğe dahil edilerek toplamda 110.648 yeni kelime eklenmiştir. Son haliyle sözlük, 159.876 kelimedenden oluşmaktadır. Şekil 2’de bu çeviri sözlüğünün oluşturulma süreci şematik olarak sunulmaktadır.



Şekil 2. Çeviri sözlüğün oluşturulma şeması

GDELT sözlük

GDELT, dünya genelinde 100'den fazla dilde yayımlanan basılı, dijital ve web tabanlı haberleri sürekli olarak izleyerek, küresel toplumu şekillendiren kişi, yer, organizasyon, tema, kaynak, duygu, nicel veri, alıntı, görsel ve olayları tanımlamayı amaçlayan kapsamlı bir veri platformudur. Her günün her saniyesinde üretilen bu veri akışı, araştırmacılara açık ve ücretsiz bir bilgi işlem kaynağı sunmaktadır. Tablo 2’de, GDELT haber verilerinin işlenmesi ve bu verilerden duygu polarite değerlerinin hesaplanmasına yönelik işlemlerin örnekleri sunulmuştur.

Tablo 2. GDELT haber verilerinin duygu polarite deęerleri

Baęlantı	Ton Deęeri	Pozitif Skor	Negatif Skor	Polarite	Aktivite Referans Yoęunluę u	Kiři-Grup Referans Yoęunluę u	Kelime Sayısı
http://www.dunyabulteni.net/haberler/347681/	-0.96	3.37	4.33	7.69	26.44	1.44	199
http://haber.star.com.tr/spor/o-isimden-galata	-3.49	2.33	5.81	8.14	26.74	4.65	182
http://www.haber8.com/Haber/ali-ismail-kor	0.34	1.36	1.02	2.38	27.21	3.06	272
http://www.gazeteciler.com/gundem/erha	1.57	4.33	2.76	7.09	25.98	7.09	229
http://www.sozcu.com.tr/2015/gunun-icinde	4.81	6.73	1.92	8.65	16.83	0.00	186
http://haber.stargundem.com/gundem/1528	-1.16	3.10	4.26	7.36	25.19	5.43	142
http://www.halkinsesikibris.com/guncel-habe	-4.49	5.13	0.64	5.77	17.95	0.00	98
http://www.haber7.com/aydin/1683683-ay	-2.06	3.17	25.81	26.98	26.98	0.00	312

Bu süreçte, haber içeriklerine ait negatiflik ve pozitiflik düzeyleri, polarite deęeri, ton deęeri ve kelime sayısı gibi çeşitli özellikler ayrıntılı şekilde hesaplanmıştır. Bu hesaplamalar, haber metinlerinin duygusal tonu ile dilsel özelliklerinin derinlemesine analiz edilmesine olanak sağlamaktadır. Tablo 2'de sunulan genel hesaplamaların yanı sıra, belirli bir haber verisi üzerinde gerçekleştirilen detaylı analizlere odaklanmak da önemlidir. Böylelikle, GDELT verilerinde yer alan dilsel ve duygusal öğelerin mikro düzeyde nasıl deęerlendirildięi daha açık bir şekilde ortaya konulabilmektedir.


Mikro düzey analizler, yalnızca genel eğilimlerin belirlenmesine katkı sağlamakla kalmayıp, aynı zamanda bireysel içeriklerin duygu yoęunluklarını, ton dengelerini ve sözcük bazlı dağılımlarını da ortaya çıkararak daha derinlemesine bir kavrayış sunmaktadır. Bununla birlikte, bireysel haberlerin duygusal içeriklerinin ölçülmesi, sözlük tabanlı sistemlerin doğruluk, ölçeklenebilirlik ve bağlam içi anlamlandırma kapasitelerinin deęerlendirilmesi açısından da önemli bir referans noktası oluşturmaktadır. Şekil 3'te örnek bir haber verisine ait detaylı analiz sonuçları sunulmakta olup; ilgili verinin negatiflik ve pozitiflik

değerleri, polarite skoru, ton değeri ve kelime sayısı gibi özellikleri ayrıntılı biçimde gösterilmektedir.

```
{
  "Link":
  "http://www.haber7.com/aydin/1683683-aydin-da-
  trafik-kazasi-1-olu-1-yarali",
  "Tones": -20.6349206349206,
  "Positive Score": 3.17460317460317,
  "Negative Score": 23.8095238095238,
  "Polarity": 26.984126984127,
  "Activity Reference Density":
  26.984126984127,
  "Self/Group Reference Density": 0.0,
  "Word Count": 55,
  "Article": "PAYLAŞ Facebook'ta Paylaş
  Twitter'da Paylaş WhatsApp'ta Paylaş KAYNAK:
  AA EKLENME: 02 Aralık 2015, 11:51 GÜNCELLEME:
  02 Aralık 2015, 11:51"
}
```

Şekil 3. GDELT haber verilerinin işlenmesi

Bu çalışmada kullanılan GDELT sözlüğü, SWNetTR++ (SAĞLAM et al., 2019) sözlüğünün kapsamının GDELT verileri ile genişletilmesiyle oluşturulmuştur. Daha önceki çalışmalarımızda izlediğimiz yöntem (Altınel et al., 2022; Girgin & Şahin, 2023) temel alınarak, GDELT platformu üzerinden haber verileri sorgulanmış ve etiketlenmiş haber içerikleri çekilmiştir. Elde edilen veriler kullanılarak, formül tabanlı hesaplamalarla kelimelerin polarite değerleri belirlenmiş ve ayrıca her kelime için duygu polarite değerleri de eklenmiştir. Bu süreç sonunda oluşturulan sözlük, toplam 56.744 kelime içermekte olup, Türkçe duygu analizinde daha kapsamlı bir kaynak sunmaktadır.



Şekil 4. SaNeTR sözlüğünün oluşturulması

Türkçe için duygu analizi sözlüğü

SaNeTR sözlüğü Çeviri ve GDELT sözlüklerinin analiz edilmesi, düzenlenmesi ve bu iki sözlüğün anlamlı şekilde birleştirilmesi ile oluşturulmuştur. Şekil 4'te GDELT ve Çeviri sözlüğün birleştirilmesi ile SaNeTR sözlüğünün oluşturulması görselleştirilmiştir. Daha önce ilgili bölümde de belirtildiği üzere, GDELT sözlüğü; GDELT veri tabanındaki farklı yıllara ve aylara göre yapılandırılmış haber verilerinin indirilmesi ve bu haberlerde geçen kelimelerin, pozitif ve negatif bağlamlardaki kullanım sıklıkları dikkate alınarak polarite değerlerinin hesaplanması yoluyla oluşturulmuştur. Öte yandan, Çeviri sözlük, güncel SentiWordNet sözlüğünün Google Translate aracılığıyla Türkçeye çevrilmesiyle elde edilmiştir.

Tablo 3. SaNeTR sözlük örnek kelimeler

Kelime	Duygu Polarite Değeri	Duygu Polaritesi
aile adamı	0,125	Pozitif
akılcı olmayan	-0,375	Negatif
anlayışlılık	0,375	Pozitif
anma	0,5	Pozitif
ilahi	0,125	Pozitif
ilgisiz	-0,625	Negatif
ilgi	0,25	Pozitif
mantıklı olmak	0,375	Pozitif
manşet	-0,125	Negatif
profesyonelce	0,125	Pozitif
programsız	-0,625	Negatif
sabır	0,75	Pozitif
sadaka	0,5	Pozitif
sefil	-0,75	Negatif
sempati duymak	0,375	Pozitif
tefeci	-0,75	Negatif
tefekür	0,125	Pozitif
tehdit	-0,25	Negatif
yasa dışı	-0,625	Negatif
ölçülü	0,5	Pozitif

SaNeTR sözlüğü oluşturulurken, GDELT sözlüğünde yaklaşık 80.000, Çeviri sözlüğünde ise yaklaşık 40.300 kelime bulunmaktaydı. Her iki sözlükte ortak olan kelimeler için pozitif ve negatif polarite değerleri karşılaştırılmış, baskın anlam yoğunluğuna sahip değer temel alınarak ilgili kelimenin SaNeTR sözlüğüne eklenmesi sağlanmıştır. Ayrıca, farklı yazımlara sahip kelimeler için her iki sözlükteki polarite değerleri dikkate alınarak uygun biçimde kelime eklemesi yapılmıştır. Tüm bu işlemler sonucunda SaNeTR sözlüğü 120.000 kelime içerecek şekilde tamamlanmıştır. SaNeTR sözlüğüne ilişkin bir örnek Tablo 3'te sunulmuştur.

Deneylerde kullanılan metrikler

Gerçekleştirilen deneylerde doğruluk (accuracy) değeri aşağıdaki formül (1) ile hesaplanmıştır. Bu formülde TP algoritmaya göre pozitif olarak etiketlenip pozitif etiketli olan tweetlerin sayısı, TN algoritmaya göre doğru olarak etiketlenip aslında negatif etiketli tweetlerin sayısı, FP algoritmaya göre negatif olarak etiketlenip negatif etiketli olan tweetlerin sayısı, FN algoritmaya göre negatif olarak etiketlenip negatif etiketli olan tweetlerin sayısını ifade etmektedir.

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

Bu ifadelerden hareketle kesinlik ve duyarlılık değerleri aşağıdaki formüller ile hesaplanmıştır. Kesinlik pozitif olarak tahmin edilen değerlerin gerçekte ne kadarının pozitif olduğunun oranını, duyarlılık pozitif olarak tahmin edilmesi gereken değerlerin ne kadarının pozitif olarak tahmin edildiğinin oranını ifade eder.

$$\text{Kesinlik (Precision)} = \frac{TP}{TP+FP} \quad (2)$$

$$\text{Duyarlılık (Recall)} = \frac{TP}{TP+FN} \quad (3)$$

(2) ve (3) nolu formülde TP algoritmaya göre pozitif olarak etiketlenip pozitif etiketli olan tweetlerin sayısı, FP algoritmaya göre negatif olarak etiketlenip negatif etiketli olan tweetlerin sayısı, FN algoritmaya göre negatif olarak etiketlenip negatif etiketli olan tweetlerin sayısını ifade etmektedir.

Kesinlik ve duyarlılık değerlerinin harmonik ortalaması F1 skor (F1 Score) olarak adlandırılır. Yukarıdaki ifadeler kullanılarak F1 Puanı aşağıdaki formül (4) ile hesaplanmıştır.

$$F_1 = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

Bu formülde kesinlik değeri (2) numaralı formül ile verilen eşitliği, duyarlılık değeri (3) numaralı formül ile verilen eşitliği ifade etmektedir.

Deney ortamı ve veri kümeleri

Deney ortamı

Tüm deneylerde, veri kümelerinin %70'i eğitim, kalan %30'u test amacıyla kullanılmıştır. Deneylerin ana değerlendirme metriği olarak F1 skoru (F1) seçilmiş ve tüm veri kümeleri üzerinde gerçekleştirilen deneylerde geleneksel 10 katlı çapraz doğrulama (CV) tekniği uygulanmıştır. Sonuçlar, veri kümelerinin test bölümlerinde elde edilen F1 puanlarının ortalaması alınarak raporlanmıştır. Deney sonuçları Tablo 6, Tablo 7 ve Tablo 8'de sunulmaktadır. Tüm deneyler, Intel i7-8750 @2.20 GHz CPU ve 32 GB RAM donanımına sahip bir makinede yürütülmüştür. Uygulamalar JAVA ve Python programlama dillerinde gerçekleştirilmiş olup, Python tarafında Scikit-learn ve TensorFlow kütüphaneleri kullanılmıştır. Scikit-learn kütüphanesinden temel

olarak SVM, RF ve Naive Bayes sınıflandırıcıları ile veri vektörleştirme işlemleri için `feature_extraction` ve değerlendirme için `metrics` modülleri kullanılmıştır. Ayrıca, Twitter verilerinin elde edilmesi amacıyla Python 3.6 ortamında TWINT kütüphanesinden yararlanılmış ve toplanan tüm veriler yerel bir sunucuda MongoDB veritabanına indekslenerek saklanmıştır. Toplanan verilerin ön işleme süreçlerinde ise JAVA programlama dilinde Zemberek kütüphanesi kullanılmıştır. Deneylerde kullanılan SVM modeli, Scikit-learn kütüphanesinin varsayılan parametreleri olan $C=1$, $dual=False$ ve $penalty='l2'$ değerleri ile yapılandırılmıştır.

Veri kümeleri


Bu çalışmada, duygusal polarite algılama görevinde üç farklı veri kümesi kullanılmıştır. Kullanılan veri kümelerinin boyutları ile pozitif ve negatif tweet yüzdelere ilişkin bilgiler Tablo 4'te sunulmuştur. Veri kümesi özellikleri, duygusal polarite algılama performansını etkileyen önemli faktörler arasında yer almakta olup, her bir veri kümesinin dağılımı çalışmada yapılan deneylerin kapsamını ve sonuçların genellenebilirliğini desteklemek amacıyla detaylı şekilde raporlanmıştır.

Tablo 4. Veri kümelerinin özellikleri

Veri Kümesi	Tip	Veri Kümesi Büyüklüğü	Pozitif Tweet Yüzdesi	Negatif Tweet Yüzdesi
Twitter-4k	Tweet	4202	63	37
GDELT-12k	GDELT Haber Verisi	12 000	36	64
Twitter-130k	Tweet	130 000	56	44

Bu çalışmada, duygusal polarite tespiti amacıyla üç farklı veri kümesi kullanılmıştır. Kullanılan veri kümeleri şunlardır:

Twitter-4k veri kümesi, 4202 tweet içermekte olup bunların %63'ü duygusal olarak olumlu, %37'si ise olumsuzdur; GDELT-12k veri kümesi, 12.000 haber verisinden oluşmakta ve verilerin %36'sı olumlu, %64'ü olumsuz olarak etiketlenmiştir; Twitter-130k veri kümesi ise 130.000 tweet içermekte olup %56'sı olumlu, %44'ü olumsuz duygusal içeriğe sahiptir. Şekil 5'te veri kümelerindeki pozitif ve negatif örneklerin dağılımı görsel olarak sunulmuştur.



Şekil 5. Veri kümelerinin duygusal polarite dağılım oranı

Twitter'dan toplanan veri kümeleri üzerinde kapsamlı bir ön işleme süreci uygulanmış; atıflar, hashtag'ler, URL bağlantıları, emojiler ve noktalama işaretleri tweet içeriklerinden çıkarılmıştır.


Tablo 5. Veri kümelerine uygulanan ön işleme adımları

Ön İşleme Adımları
Küçük harfe dönüştürme
Noktalama işaretlerinin kaldırılması
URL, hashtag ve atıf temizleme
Emoji ve özel karakterlerin kaldırılması
Sayısal ifadelerin temizlenmesi
Durak kelime (stop-word) filtreleme
Kök bulma (Zemberek ile)

Ayrıca, Zemberek doğal dil işleme aracı kullanılarak tweet'lerde kök bulma işlemi ve durak kelime filtrelemesi gerçekleştirilmiştir. Bu ön işleme adımları, verilerin temizlenerek model eğitime daha uygun hale getirilmesini sağlamıştır. Uygulanan ön işleme adımları Tablo 5'te verilmiştir.

Algoritmalar

Bu çalışmada kullanılan yöntemlerin genel mimarisi Şekil 6'da sunulmaktadır. Sistemin genel işleyişi kısaca özetlenecek olursa, öncelikle kullanılacak veri kümesi seçilmekte ve bu veri kümesi üzerinde kapsamlı bir ön işleme süreci uygulanmaktadır. Bu aşamada, etkisiz kelimeler çıkarılmakta, tüm harfler küçük harfe dönüştürülmekte, noktalama işaretleri kaldırılmakta ve normalizasyon işlemleri gerçekleştirilmektedir. Ön işleme sürecinin ardından, elde edilen kelimelerin sözlüklerdeki karşılıkları kontrol edilmekte ve ilgili duygu polarite değerleri belirlenmektedir. Sonrasında sınıflandırma algoritmaları uygulanarak veriler analiz edilmekte ve elde edilen sonuçlar F1 skor metriği kullanılarak değerlendirilmektedir.



Şekil 6. Sözlük Tabanlı Makine Topluluk Modelleri (STMTM) sisteminin genel mimarisi

SentiAF (Sentiment + TF-AF)

$$tweets = \bigcup_{i=1}^n tweet_i = \bigcup_{j=1}^m \{kelime_j TF - AF \text{ değeri}\} \quad (5)$$

Yukarıdaki formülde verilen TF-AF (abstract future weighting) (Biricik et al., 2009; BİRİCİK et al., 2012) değerinin hangi sınıf için hesaplanacağına aşağıdaki formülde ifade edilen şekilde belirlendi.

$$\begin{aligned} kelime_j TF - AF = \{ & \text{positive TF - AF ; if } kelime_j \text{ semantic polarity} > \\ & 0 \text{ negative TF - AF ; if } kelime_j \text{ semantic polarity} < 0 \end{aligned} \quad (6)$$

Pozitif anlamsal polarite değerine sahip kelimeler için pozitif sınıf TF-AF değeri aşağıdaki formüle göre hesaplandı.

$$W_{w,c} = \log \log (tfc_{w,c} + 1) \times \log \log \left(\frac{N}{N_w} \right) \quad (7)$$

Bu formülde $W_{w,c}$ pozitif sınıfta kelimenin TF-AF değerini, $\log (tfc_{w,c})$ kelimenin pozitif sınıfta geçme sayısı, N toplam tweet sayısı, N_w : Kelimenin geçtiği tweet sayısını ifade etmektedir.

Benzer şekilde negatif anlamsal polarite değerine sahip kelimeler için negatif sınıf TF-AF değeri aşağıdaki formüle göre hesaplandı.

$$W_{w,c} = \log \log (tfc_{w,c} + 1) \times \log \log \left(\frac{N}{N_w} \right) \quad (8)$$

Bu formülde $W_{-(w,c)}$ negatif sınıfta kelimenin TF-AF değerini, $\log(tfc_{-(w,c)})$ kelimenin negatif sınıfta geçme sayısı, N toplam tweet sayısı, N_{-w} : Kelimenin geçtiği tweet sayısını ifade etmektedir. Sonuçların doğruluğunu test etmek için (1) ve (4)

numaralı formülleri kullanarak doğruluk ve F1 skor değerleri hesaplandı.

PolAF (Polarity + TF-AF)

Bu algorithmada iki farklı durum tanımlanmıştır. Birinci durum A, ikinci durum ise B olarak adlandırılmıştır. A durumunda, tweet içerisindeki kelimelerin pozitif TF-AF değerlerinin toplamı hesaplanmıştır. B durumunda ise, tweet içerisindeki kelimelerin negatif TF-AF değerlerinin toplamı elde edilmiştir. Eğer $A > B$ koşulu sağlanıyorsa tweet pozitif olarak etiketlenmiş; aksi durumda, tweet negatif olarak etiketlenmiştir. Bu işlem, veri kümesindeki tüm tweetler için tekrarlanmıştır. Modelin başarımını değerlendirmek amacıyla, etiketlenen sonuçlar veri kümesindeki gerçek etiketlerle karşılaştırılmış ve doğruluk ile F1 skor değerleri hesaplanarak performans analizi gerçekleştirilmiştir.

$$A = \sum_{i=1}^n \text{kelime}_i \text{ TF} - \text{AF değeri (Pozitif)} \quad (9)$$

$$B = \sum_{i=1}^n \text{kelime}_i \text{ TF} - \text{AF değeri (Negatif)} \quad (10)$$

$$\{ \text{if } A > B \Rightarrow \text{tweet}_i \text{ pozitif ; } \text{else tweet}_i \text{ negatif} \} \quad (11)$$

EmoAF (Emotion-weighted TF-AF)

Bu algorithmada iki farklı durum tanımlanmıştır. Birinci durum A, ikinci durum ise B olarak ifade edilmiştir. A durumunda, incelenen tweet içerisindeki kelimelerin pozitif sınıfa ait TF-AF değerleri ile pozitif duygu değerleri toplanmıştır. B durumunda ise, aynı tweet içerisindeki kelimelerin negatif sınıfa ait TF-AF değerleri ve negatif duygu değerleri toplanmıştır. Eğer $A > B$ koşulu sağlanıyorsa tweet pozitif olarak, aksi durumda ise negatif olarak etiketlenmiştir. Bu işlem, veri kümesindeki tüm veriler için tekrarlanmıştır. Sonuçların doğruluğunu kontrol etmek ve modelin performansını değerlendirmek amacıyla, elde edilen etiketler veri

kümesindeki gerçek etiketlerle karşılaştırılmış ve doğruluk ile F1 skor metrikleri hesaplanmıştır.

$$A = \sum_{i=1}^n kelime_i TF - AF \text{ değeri} + kelime_i \text{ duygu (Pozitif)} \quad (12)$$

$$B = \sum_{i=1}^n kelime_i TF - AF \text{ değeri} + kelime_i \text{ duygu (Negatif)} \quad (13)$$

$$\{Eğer A > B \Rightarrow tweet_i \text{ pozitif} ; \text{ değil ise } tweet_i \text{ negatif}\} \quad (14)$$

BoostAF (Booster + TF-AF)

Bu algorithmada A ve B olmak üzere iki farklı durum oluşturulmuştur. A durumunda, incelenen tweet içerisindeki kelimelerin pozitif sınıfa ait TF-AF değerleri ve pozitif duygu değerleri toplanmıştır. Eğer kelime booster kelime listesinde yer alıyorsa, ilgili kelimenin pozitif duygu değeri dört ile çarpılarak toplam değere dahil edilmiştir. B durumunda ise, tweet içerisindeki kelimelerin negatif sınıfa ait TF-AF değerleri ve negatif duygu değerleri toplanmış; kelimenin booster kelime listesinde bulunması durumunda negatif duygu değeri dört ile çarpılarak toplam değere eklenmiştir. Eğer $A > B$ koşulu sağlanıyorsa tweet pozitif olarak, aksi durumda negatif olarak etiketlenmiştir. Elde edilen sonuçlar, veri kümesindeki gerçek etiketlerle karşılaştırılmış ve modelin doğruluğunu değerlendirmek amacıyla doğruluk ve F1 skor metrikleri hesaplanmıştır.

$$A = \sum_{i=1}^n kelime_i TF - AF + \begin{cases} kelime_i \text{ duygu} * 4, & \text{if } i \in \text{booster} || \text{seed words} \\ kelime_i \text{ duygu}, & \text{if } i \notin \text{booster} || \text{seed words} \end{cases} \text{ (Pozitif)} \quad (15)$$

$$B = \sum_{i=1}^n kelime_i TF - AF + \begin{cases} kelime_i \text{ duygu} * 4, & \text{if } i \in \text{booster} || \text{seed words} \\ kelime_i \text{ duygu}, & \text{if } i \notin \text{booster} || \text{seed words} \end{cases} \text{ (Negatif)} \quad (16)$$

$$\{Eğer A > B \Rightarrow tweet_i \text{ pozitif} ; \text{ değil ise } tweet_i \text{ negatif}\} \quad (17)$$

SentiRF (Sentiment + TF-RF)

$$tweets = \bigcup_{i=1}^n tweet_i = \bigcup_{j=1}^m \{ kelime_j TF - RF \text{ değeri} \} \quad (18)$$

Yukarıdaki formülde belirtilen kelimenin TF-RF (Term Frequency–Relevance Frequency) (Lan et al., 2008) değerinin hesaplanabilmesi için, kelimenin negatif veya pozitif sınıfa ait olup olmadığı belirlenmiştir. Bu amaçla, kelimenin duygu polaritesi değerine bakılmış ve uygulanacak işlem aşağıda verilen formül ile ifade edilmiştir.

$$\begin{aligned} kelime_j TF - RF = \{ & \text{pozitif } TF - RF ; \text{ if } kelime_j \text{ duygu polaritesi} > \\ & 0 \text{ negatif } TF - RF ; \text{ if } kelime_j \text{ duygu polaritesi} < 0 \end{aligned} \quad (19)$$

Burada pozitif sınıfa göre TF-RF değeri aşağıdaki formül ile hesaplandı.

$$TF - RF = tf_w * \log \left(2 + \frac{a}{(l,c)} \right) \quad (20)$$

Bu formülde tf_w kelimenin pozitif sınıfta geçme frekansını, a kelimenin pozitif sınıfta geçtiği toplam tweet sayısını, c kelimenin negatif sınıfta geçtiği toplam tweet sayısını ifade etmektedir.

Benzer şekilde negatif sınıf için TF-RF değeri hesaplanır. Negatif sınıfa göre TF-RF değeri aşağıdaki formül ile hesaplandı.

$$TF - RF = tf_w * \log \left(2 + \frac{a}{(l,c)} \right) \quad (21)$$

Bu formülde tf_w kelimenin negatif sınıfta geçme frekansını, a kelimenin negatif sınıfta geçtiği toplam tweet sayısını, c kelimenin pozitif sınıfta geçtiği toplam tweet sayısını ifade etmektedir.

PolRF (Polarity + TF-RF)

Bu yöntemde A ve B olmak üzere iki durum tanımlanmıştır. A durumunda, veri kümesindeki her bir tweet için kelimelerin pozitif sınıfa ait TF-RF değerleri toplanmıştır. B durumunda ise, aynı tweet içerisindeki kelimelerin negatif sınıfa ait TF-RF değerleri hesaplanarak toplamı elde edilmiştir. A ve B değerleri karşılaştırılmış; $A > B$ koşulu sağlandığında tweet pozitif olarak, aksi durumda ise negatif olarak etiketlenmiştir. Elde edilen sonuçlar, veri kümesindeki gerçek etiketlerle karşılaştırılmış ve sonuçların doğruluğunu değerlendirmek amacıyla doğruluk ve F1 skor metrikleri hesaplanmıştır.

$$A = \sum_{i=1}^n \text{kelime}_i \text{TF} - \text{RF} ; \text{ bütün tweetler için } (22)$$

$$B = \sum_{i=1}^n \text{kelime}_i \text{TF} - \text{RF} ; \text{ bütün tweetler için } (23)$$

$$\{ \text{Eğer } A > B \Rightarrow \text{tweet}_i \text{ pozitif} ; \text{ değil ise tweet}_i \text{ negatif} \} (24)$$

EmoRF (Emotion-weighted TF-RF)

EmoRF algoritması kapsamında, A ve B olmak üzere iki durum tanımlanmıştır. A durumunda, veri kümesindeki her bir tweet için kelimelerin pozitif sınıfa ait TF-RF değerleri ile varsa kelimelerin pozitif duygu polaritesi değerleri toplanmıştır. B durumunda ise, kelimelerin negatif sınıfa ait TF-RF değerleri ile varsa negatif duygu polaritesi değerleri hesaplanarak toplamı elde edilmiştir. $A > B$ koşulu sağlandığında tweet pozitif olarak, aksi durumda ise negatif olarak etiketlenmiştir. Elde edilen sonuçların doğruluğunu değerlendirmek amacıyla, tahmin edilen etiketler veri kümesindeki gerçek etiketlerle karşılaştırılmış ve doğruluk ile F1 skor metrikleri hesaplanmıştır.

$$A = \sum_{i=1}^n \text{kelime}_i \text{TF} - \text{RF} \\ + \text{kelime}_i \text{ duygu polaritesi} ; \text{ bütün tweetler için } (25)$$

$$B = \sum_{i=1}^n kelime_i TF - RF + kelime_i duygu polaritesi ; \text{ b\u00fct\u00fcn tweetler i\u00e7in } (26)$$

$$\{E\u011fer A > B \Rightarrow tweet_i \text{ pozitif} ; \text{ de\u011fil ise } tweet_i \text{ negatif}\} \quad (27)$$

BoostRF (Booster + TF-RF)

BoostRF algoritması kapsamında, A ve B olmak \u00fczere iki durum tan\u0131mlanm\u0131\u015ft\u0131r. A durumunda, veri k\u00fcmesindeki her bir tweet i\u00e7in kelimenin pozitif TF-RF de\u011feri ile varsa kelimenin pozitif duygu polaritesi de\u011feri toplanm\u0131\u015f; ayrıca kelime booster kelime listesinde yer al\u0131yorsa, ilgili pozitif duygu polarite de\u011feri d\u00f6rt ile \u00e7arp\u0131larak toplam de\u011fere eklenmi\u015ftir. B durumunda ise, kelimenin negatif TF-RF de\u011feri ile varsa negatif duygu polarite de\u011feri toplanm\u0131\u015f; kelimenin booster kelime listesinde bulunması durumunda, negatif duygu polarite de\u011feri d\u00f6rt ile \u00e7arp\u0131larak TF-RF de\u011feri ile toplam de\u011fere dahil edilmi\u015ftir. A>B ko\u015fulu sa\u011fland\u0131\u011f\u0131nda tweet pozitif olarak, aksi durumda ise negatif olarak etiketlenmi\u015ftir. Algoritmanın do\u011frulu\u011funu de\u011ferlendirmek amacıyla, elde edilen tahmin sonu\u00e7ları veri k\u00fcmesindeki ger\u00e7ek etiketlerle kar\u015fıla\u015ft\u0131r\u0131lm\u0131\u015f ve performans \u00f6l\u00e7\u00fct\u00fc olarak do\u011fruluk ve F1 skor de\u011ferleri hesaplanm\u0131\u015ft\u0131r.

$$A = \sum_{i=1}^n kelime_i TF - RF * \begin{cases} kelime_i duygu polaritesi * 4, \\ \text{if } i \in \text{booster} || \text{seed words} \\ kelime_i duygu polaritesi, \\ \text{if } i \notin \text{booster} || \text{seed words} \end{cases} \quad (Pozitif) \quad (28)$$

$$B = \sum_{i=1}^n kelime_i TF - RF * \begin{cases} kelime_i duygu polaritesi * 4, \\ \text{if } i \in \text{booster} || \text{seed words} \\ kelime_i duygu polaritesi, \\ \text{if } i \notin \text{booster} || \text{seed words} \end{cases} \quad (Negatif) \quad (29)$$

$$\{Eğer A > B \Rightarrow tweet_i \text{ pozitif} ; \text{ değil ise } tweet_i \text{ negatif}\} \quad (30)$$

Deneyisel bulgular

Deneyisel sonuçlar, Tablo 6, Tablo 7 ve Tablo 8’de sunulmuştur. Elde edilen bulgular, geliştirilen yaklaşımın tümüyle, temel algoritmalara kıyasla daha yüksek performans sergilediğini göstermektedir. Örneğin, GDELT Sözlüğü ile gerçekleştirilen deneylerde, SentiAF, PolAF, EmoAF, BoostAF, SentiRF, PolRF, EmoRF ve BoostRF algoritmalarının F1 skorları sırasıyla %78,47, %78,26, %78,90, %79,85, %78,26, %79,33, %80,36, %81,34 olarak ölçülürken, temel algoritmalar olan SVM, NB ve RF’nin F1 skorları sırasıyla %80,12, %76,25 ve %77,38 olarak belirlenmiştir. Benzer şekilde, Translated Dictionary ile yapılan deneyde, SentiAF, PolAF, EmoAF, BoostAF, SentiRF, PolRF, EmoRF ve BoostRF algoritmalarının F1 skorları sırasıyla %77,68, %77,3, %78,18, %79,11, %77,57, %78,63, %79,58, %80,92 olmuştur. Son olarak, SaNeTR sözlüğü ile gerçekleştirilen deneylerde SentiAF, PolAF, EmoAF, BoostAF, SentiRF, PolRF, EmoRF ve BoostRF algoritmalarının F1 skorları sırasıyla %80,03, %79,82, %80,47, %81,44, %79,82, %80,91, %81,96, %82,96 olarak ölçülmüştür.

Bu bulgular hem GDELT hem de Translated Dictionary ve SaNeTR sözlüklerinin, Türkçe dilinde duygu algılama görevinde Twitter-4K veri kümesi üzerindeki sınıflandırma performansını anlamlı ölçüde artırdığını ortaya koymaktadır. Söz konusu performans artışı Tablo 6’da detaylı olarak sunulmuştur.

Tablo 6. Algoritmaların Twitter-4k veri kümesi üzerindeki F1 skor deney sonuçları

	Senti AF	Pol AF	Emo AF	Boos t AF	Senti i RF	Pol RF	Emo RF	Boos t RF	SV M	NB	RF
GDEL T	78,47	78,2 6	78,9 0	79,8 5	78,2 6	79,3 3	80,3 6	81,3 4			
Çeviri	77,68	77,3 7	78,1 8	79,1 1	77,5 7	78,6 3	79,5 8	80,9 2	80,1 2	76,2 5	77,3 8
SaNeTR	80, 03	79,8 2	80,4 7	81,4 4	79,8 2	80,9 1	81,9 6	82,9 6			

Kullanılan algoritmaların (sözlük tabanlı yöntemler) ve temel algoritmaların (standart sözlüksüz yöntemler), GDELT-12K veri kümesi üzerindeki deneysel sonuçları Tablo 7'de gösterilmektedir.

Tablo 7. Algoritmaların GDELT-12k veri kümesi üzerindeki F1 skor deney sonuçları

	Senti AF	Pol AF	Emo AF	Boost AF	Senti RF	Pol RF	Emo RF	Boost RF	SVM	NB	RF
GDELT	80,04	78,83	80,78	81,25	79,83	80,29	81,97	82,37			
Çeviri	79,23	78,92	79,77	80,67	79,52	80,20	81,17	82,54	81,92	77,76	78,8
SaNeTR	81,63	81,42	82,08	83,07	81,42	82,53	83,60	84,62			

Elde edilen sonuçlara göre, genel olarak sözlük tabanlı yöntemlerin sözlüksüz yöntemlere göre daha iyi performans gösterdiği görülmektedir. Örneğin, GDELT sözlüğü kullanılarak yapılan deneylerde sözlük tabanlı algoritmalar olan SentiAF, PolAF, EmoAF, BoostAF, SentiRF, PolRF, EmoRF ve BoostRF algoritmalarının F1 skorları sırasıyla %80,04, %78,83, %80,78, %81,25, %79,83, %80,29, %81,97 ve %82,37 olarak ölçülmüştür. Buna karşılık sözlüksüz çalışan temel algoritmalar olan SVM, NB

ve RF'nin F1 skorları sırasıyla %81,92, %77,76 ve %78,8'dir. Ayrıca Çeviri sözlüğü kullanılarak yapılan deneylerde de sözlük tabanlı algoritmalar olan SentiAF, PolAF, EmoAF, BoostAF, SentiRF, PolRF, EmoRF ve BoostRF algoritmalarının F1 skorları sırasıyla %79,23, %78,92, %79,77, %80,67, %79,52, %80,20, %81,17 ve %82,54 olarak elde edilmiştir. Son olarak, SaNeTR sözlüğü kullanılarak yapılan deneylerde sözlük tabanlı algoritmalar SentiAF, PolAF, EmoAF, BoostAF, SentiRF, PolRF, EmoRF ve BoostRF için elde edilen F1 skorları sırasıyla %81,63, %81,42, %82,08, %83,07, %81,42, %82,53, %83,60 ve %84,62 olmuştur. Bu sonuçlar, üç sözlük içinde en iyi sınıflandırma performansının SaNeTR sözlüğüyle elde edildiğini açıkça göstermektedir. Yapılan deneyler sonucunda, Türkçe duygu polaritesi tespitinde sözlük tabanlı yöntemlerin standart sözlüksüz yöntemlere göre genel olarak daha başarılı ve tutarlı sonuçlar verdiği anlaşılmaktadır. Özellikle önerilen SaNeTR sözlüğü ile sözlük tabanlı yöntemlerin başarımının önemli ölçüde arttığı görülmektedir.

Geliştirilen yaklaşımın ve temel algoritmaların, Twitter-130K veri kümesindeki deneysel sonuçları Tablo 8'de sunulmaktadır. Elde edilen sonuçlara göre, kullanılan algoritmaların tamamı bu veri kümesindeki tüm temel algoritmalarından daha yüksek performans göstermiştir.

Tablo 8. Algoritmaların Twitter-130k veri kümesi üzerindeki F1 skor deney sonuçları

	Senti AF	Pol AF	Emo AF	Boos t AF	Senti RF	Pol RF	Emo AF	Boos t RF	SV M	NB	RF
GDELT	80,8 2	80,6 1	81,2 7	82,25	80,6 1	81,7 1	82,7 7	83,78			
Çeviri	80,0 1	79,6 7	80,5 6	81,48	79,9 2	81,9 7	81,9 2	83,31	82,9 7	78,6 2	79,2 6
SaNeT R	82,4 3	82,2 4	82,8 0	83,38	82,6 1	83,3 4	83,6 7	84,92			

Örneğin, GDELT Sözlüğü kullanılarak gerçekleştirilen deneyde, SentiAF, PolAF, EmoAF, BoostAF, SentiRF, PolRF, EmoRF ve BoostRF algoritmalarının F1 puanları sırasıyla %80,82, %80,61, %81,27, %82,25, %80,61, %81,71, %82,77 ve %83,78 olarak ölçülmüştür. Aynı veri kümesinde temel algoritmalar olan SVM, NB ve RF için elde edilen F1 skorları ise sırasıyla %82,97, %78,62 ve %79,26'dır.

Çeviri Sözlüğü ile yapılan deneylerde ise, kullanılan algoritmaların F1 skorları sırasıyla %80,01, %79,67, %80,56, %81,48, %79,92, %81,97, %81,92 ve %83,31 olarak hesaplanmıştır. Son olarak, SaNeTR sözlüğü ile gerçekleştirilen deneyde, aynı algoritmaların F1 skorları sırasıyla %82,43, %82,24, %82,80, %83,38, %82,61, %83,34, %83,67 ve %84,92 olarak elde edilmiştir. Bu bulgular, SaNeTR sözlüğünün, özellikle büyük veri kümesi üzerinde en iyi sınıflandırma performansını sağladığını açıkça ortaya koymaktadır. Hem GDELT hem de Çeviri sözlüklerinin performansa olumlu katkı sağladığı görülse de SaNeTR sözlüğü ile elde edilen sonuçlar en yüksek başarı oranlarını sunmuş ve Türkçe duygu analizi görevinde en etkili sözlük alternatifi olduğunu bir kez daha doğrulamıştır.

Sunulan algoritmaların üstünlüğü, hem sözlüklerdeki duygu polarite değerlerinin katkısı hem de destekleyici/tohum kelime listesinin kullanımı ile açıklanabilir. GDELT duygu polarite sözlüğü, mevcut SWNetTR++ sözlüğünün kapasitesi 84.744 kelimeye çıkarılarak oluşturulmuştur. Ayrıca Türkçe için 159.876 kelimedenden oluşan tercüme edilmiş bir duygu polarite sözlüğü oluşturuldu. Bu duygu sözlüklerinin her ikisine de araştırmacıların istekleri üzerine erişilebilir.

Sonuçlar ve Tartışma

Bu çalışmada, Türkçe metinlerin DA görevini gerçekleştirmek amacıyla istatistiksel temelli yeni anlamsal algoritmalar geliştirilmiş ve bu algoritmaların etkinliği farklı duygu polarite sözlükleriyle test edilmiştir. Üç farklı sözlük oluşturulmuştur: İlk olarak SWNetTR sözlüğünün Google Translate kullanılarak genişletilmiş versiyonu oluşturulmuş ve yaklaşık 159.876 terim içeren geniş kapsamlı bir çeviri sözlüğü elde edilmiştir. İkinci olarak, GDELT veritabanı kullanılarak 84.744 terimlik bir sözlük hazırlanmıştır. Üçüncü sözlük olan SaNeTR ise, önceki iki sözlüğün birleşiminden elde edilmiş ve yaklaşık 120.000 kelime içermektedir.

Geliştirilen algoritmaların performansı, farklı boyutlardaki (Twitter-4k, GDELT-12k, Twitter-130k) veri kümeleri üzerinde değerlendirilmiş ve SVM, Naive Bayes ve Random Forest gibi temel algoritmalarla kıyaslanmıştır. Yapılan deneylerin sonucunda, sözlük tabanlı geliştirilen algoritmaların, sözlüksüz yöntemlere göre daha yüksek sınıflandırma başarımı sağladığı açıkça gözlemlenmiştir. Özellikle SaNeTR sözlüğü kullanılarak gerçekleştirilen deneyler, %84,92'ye varan F1 puanlarıyla en yüksek performansı göstermiştir.

Literatürde, sosyal medya verileri kullanılarak derin öğrenme tabanlı duygu analizi gerçekleştiren çalışmalara rastlanmaktadır. Çevik ve arkadaşları (Çevik & Kilimci, 2020) tarafından yapılan

çalışmada Word2Vec kelime yerleştirme modeli ile CNN mimarisi bir araya getirilmiş ve Parkinson hastalığına ilişkin İngilizce Twitter verileri üzerinde yaklaşık %75 doğruluk oranı elde edilmiştir. Söz konusu çalışmada, kelime yerleştirme modeli olarak Word2Vec'in diğer modellere (GloVe, FastText) kıyasla daha başarılı sonuçlar verdiği raporlanmıştır.

Çoban ve arkadaşları (Çoban & Özyer, 2018), Türkçe ve İngilizce Twitter mesajları üzerinde gerçekleştirdikleri çalışmada, duygu analizi amacıyla farklı terim ağırlıklandırma yöntemlerini karşılaştırmış ve özellikle PTW, ITW ve RelDF gibi denetimli yaklaşımların geleneksel yöntemlere kıyasla daha yüksek sınıflandırma başarısı sağladığını raporlamışlardır. Bu çalışmada kullanılan veri kümeleri sosyal medya içeriklerinden oluşmakta ve sınıflandırma doğruluğu %97,6'ya kadar ulaşmaktadır. Ancak söz konusu yöntemlerin başarıları büyük ölçüde kısa metin yapısına ve iki sınıflı veri kümesine bağlı olarak değerlendirilmiştir.

Bu bağlamda elde edilen bulgular, kullanılan yöntem hem sözlük temelli hem de istatistiksel yaklaşımlar açısından etkili ve uygulanabilir olduğunu göstermekte olup çalışmanın literatüre sunduğu önemli katkılar şunlardır:

1. Türkçe duygu analizi için üç farklı, geniş kapsamlı ve herkese açık duygu polarite sözlüğü oluşturulmuştur.

2. Türkçe duygu analizi problemini çözmek için istatistiksel tabanlı yeni anlamsal algoritmalar geliştirilmiş ve bu algoritmalar sözlüksüz yöntemlere göre üstün performans göstermiştir.

3. Geliştirilen sözlüklerin ve algoritmaların Türkçe metinlerde duygu polaritesi belirleme üzerindeki olumlu etkileri kapsamlı deneylerle doğrulanmıştır.

Elde edilen sonuçlar, duygu temelli özellikler ile terim frekansı tabanlı özelliklerin birlikte kullanılmasının sınıflandırma

performansını olumlu yönde etkilediğini göstermektedir. Terim frekansı tabanlı yöntemler metindeki istatistiksel kelime dağılımlarını temsil ederken, polarite ve duygu özellikleri metnin semantik duygu bilgisini yansıtmaktadır. Bu iki farklı bilgi türünün hibrit bir özellik temsili içerisinde birleştirilmesi, modelin metnin hem yapısal hem de anlamsal özelliklerini birlikte öğrenmesine olanak sağlamaktadır. Bu nedenle kullanılan özellik kombinasyonları, yalnızca tek bir özellik türüne dayanan modellere kıyasla daha yüksek sınıflandırma başarımları göstermiştir.

Bu çalışmada kullanılan yöntemler ağırlıklı olarak sözlük tabanlı ve kural temelli yaklaşımlara dayanmaktadır ve herhangi bir model optimizasyonu süreci içermemektedir. Buna karşılık SVM ve RF gibi makine öğrenmesi algoritmaları denetimli öğrenme yöntemlerine ait olup eğitim verisi üzerinden model oluşturulmaktadır. Dolayısıyla bu yöntemler farklı model kategorilerine ait olmakla birlikte, bu çalışmada gerçekleştirilen karşılaştırma aynı model sınıfına ait yöntemlerin doğrudan karşılaştırılması amacıyla yapılmamıştır. Bunun yerine sözlük tabanlı istatistiksel ağırlıklandırma yaklaşımlarının, yaygın olarak kullanılan denetimli öğrenme yöntemleri karşısındaki görece performansını referans bir çerçevede değerlendirmek amaçlanmıştır. Ayrıca sözlük tabanlı yaklaşımlar eğitim verisi gerektirmemeleri, daha düşük hesaplama maliyetine sahip olmaları ve yorumlanabilirlik sağlamaları gibi avantajlara sahiptir. Bu nedenle çalışmada söz konusu yöntemlerin performansı, literatürde yaygın olarak kullanılan öğrenen modeller ile değerlendirilerek yöntemlerin pratik uygulanabilirliği açısından karşılaştırmalı bir analiz sunulmuştur.

Gelecekte yapılacak çalışmalar kapsamında oluşturulan duygu polarite sözlüklerinin daha fazla kelime eklenerek genişletilmesi planlanmaktadır. Ayrıca, farklı makine öğrenimi ve derin öğrenme modelleriyle hibrit algoritmalar geliştirilerek

sınıflandırma performansının daha da artırılması hedeflenmektedir. Ek olarak, farklı veri kümeleri üzerinde gerçekleştirilecek kapsamlı testlerle algoritmaların genellenebilirliği ve başarımı daha detaylı olarak incelenecektir.

Teşekkür

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 120E187 numaralı hibe ile kısmen desteklenmiştir. Yazarlar destek olan TÜBİTAK'a teşekkürlerini sunar.

Bu çalışma Marmara Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından 11558 nolu proje ve 11635 nolu proje kapsamında desteklenmiştir.

Kaynaklar

Akın, A. A., & Akın, M. D. (2007). Zemberek, an open source NLP framework for Turkic languages. *Structure*, 10(2007), 1–5.

Aktaş, Ö., Coşkun, B., & Soner, İ. (2021). Turkish sentiment analysis using machine learning methods: application on online food order site reviews. *Journal of Artificial Intelligence and Data Science*, 1(1), 1–10.

Altınel, A. B. (2021). Türkçe metinlerde makine öğrenmesi algoritmalarının duygu analizi problemi üzerindeki performansının kıyaslanması. *Avrupa Bilim ve Teknoloji Dergisi* (28), 1056–1061.

Altınel, A. B., Buzlu, K., & İpek, K. (2022). Performance analysis of different sentiment polarity dictionaries on Turkish sentiment detection. *2022 International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*,

Altınel Girgin, A. B., & Gümüşçekiçi, G. (2022). Multi-class Turkish sentiment analysis using machine learning algorithms. *Proceedings of the 3rd International Conference on Applied Engineering and Natural Sciences (ICAENS 2022)* (pp. 2091–2096). Konya, Türkiye.

Arzu, M., & Aydoğan, M. (2023). Türkçe duygu sınıflandırma için transformers tabanlı mimarilerin karşılaştırılması analizi. *Computer Science(IDAP-2023)*, 1–6.

Balli, C., Guzel, M. S., Bostanci, E., & Mishra, A. (2022). Sentimental analysis of Twitter users from Turkish content with natural language processing. *Computational Intelligence and Neuroscience*, 2022(1), 2455160.

Biricik, G., Diri, B., & Sönmez, A. C. (2009). A new method for attribute extraction with application on text classification. *2009*

Fifth International Conference on Soft Computing, Computing with Words and Perceptions in System Analysis, Decision and Control,

Biricik, G., Diri, B., & Sönmez, A. C. (2012). Abstract feature extraction for text classification. *Turkish Journal of Electrical Engineering and Computer Sciences*, 20(7), 1137–1159.

Çevik, F., & Kilimci, Z. H. (2020). Derin öğrenme yöntemleri ve kelime yerleştirme modelleri kullanılarak Parkinson hastalığının duygu analiziyle değerlendirilmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 27(2), 151–161.

Çılgin, C., Gökçen, H., & Gökşen, Y. (2023). Sentiment analysis of public sensitivity to COVID-19 vaccines on Twitter by majority voting classifier-based machine learning Twitter’da COVID-19 aşılara karşı kamu duyarlılığının çoğunluk oylama sınıflandırıcısı temelli makine öğrenmesi ile duygu analizi. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38(2).

Çoban, Ö., & Özyer, G. T. (2018). Twitter duygu analizinde terim ağırlıklandırma yönteminin etkisi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(2), 283–291.

Dönmez, İ., & Aslan, Z. (2021). Metin Duygu sınıflandırılmasında hibrit wavelet yönteminin kullanımı. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 36(2), 701–714.

Girgin, A. B. A., Gümüşçekiçi, G., & Birdemir, N. C. (2024). Turkish sentiment analysis: A comprehensive review. *Sigma Journal of Engineering and Natural Sciences*, 42(4), 1292–1314.

Girgin, A. B. A., & Şahin, S. (2023). Improving the performance of sentiment analysis by ensemble hybrid learning algorithm with NLP and cascaded feature extraction. *International*

Journal of Advances in Engineering and Pure Sciences, 35(1), 125–141.

Görmez, Y., Arslan, H., & Atak, B. (2024). Türkçe metinlerde duygu analizi: Derin öğrenme yaklaşımlarının ve ön işlem süreçlerinin model performansına etkisi. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 36(1), 509–520.

Graovac, J., Radovic, M., & Girgin, B. A. (2020). ML-SPD: Machine Learning based Sentiment Polarity Detection. 2020 International Conference on INnovations in Intelligent SysTems and Applications (INISTA),

Gündüz, H. (2023). Derin Transformatörlerden Çift Yönlü Kodlayıcı Temsilleri ve Destek Vektör Makineleri ile Türkçe Film Yorumları Üzerine Duygu Analizi. Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi, 26(2), 542–549.

Kandırın, E., Gumus, B., & Özer, M. A. (2022). Covid-19 pandemi sürecinde uzaktan eğitimin twitter yansımalarının duygu analizi. International Journal of Social Sciences and Education Research, 8(3), 228–242.

Karaöz, B., & Gürsoy, U. T. (2018). Adaptif öğrenme sözlüğü temelli duygu analiz algoritması önerisi. Bilişim Teknolojileri Dergisi, 11(3), 245–253.

Kemaloğlu, N., Küçüksille, E., & Özgünsür, M. (2021). Turkish sentiment analysis on social media. Sakarya University Journal of Science, 25(3), 629–638.

Kılıçer, S., & Şamlı, R. (2023). E-ticaret sitelerindeki Türkçe ürün yorumları üzerine makine öğrenmesi algoritmaları ile duygu analizi. Veri Bilimi, 6(2), 15–23.

Koruyan, K. (2025). Restoran Müşteri Yorumlarının Duygu Analizi: Sıfır-Atış Metin Sınıflandırma Yaklaşımı. Journal of Intelligent Systems: Theory and Applications, 8(1), 47–62.

Lan, M., Tan, C. L., Su, J., & Lu, Y. (2008). Supervised and traditional term weighting methods for automatic text categorization. *IEEE transactions on pattern analysis and machine intelligence*, 31(4), 721–735.

Mutlu, M. M., & Özgür, A. (2022). A dataset and BERT-based models for targeted sentiment analysis on Turkish texts. *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics: Student Research Workshop*,

Oğul, İ. Ü., Özcan, C., & Hakdağı, Ö. Spark Destek Vektör Makinesi ile Metin Sınıflandırma Text Classification with Spark Support Vector Machine.

Onan, A. (2022). Türkçe Metin Madenciliği için Dikkat Mekanizması Tabanlı Derin Öğrenme Mimarilerinin Değerlendirilmesi. *Avrupa Bilim ve Teknoloji Dergisi* (34), 403–407.

Sağlam, F., Genc, B., & Sever, H. (2019). Extending a sentiment lexicon with synonym--antonym datasets: SWNetTR++. *Turkish Journal of Electrical Engineering and Computer Sciences*, 27(3), 1806–1820.

Sağlam, F., Sever, H., & Genç, B. (2016). Developing Turkish sentiment lexicon for sentiment analysis using online news media. *2016 IEEE/ACS 13th International Conference of Computer Systems and Applications (AICCSA)*,

Shehu, H., & Tokat, S. (2019). A hybrid approach for the sentiment analysis of Turkish Twitter data. *The International Conference on Artificial Intelligence and Applied Mathematics in Engineering*,

Taşar, D. E., Özcan, C., & Koruyan, K. (2022). Autotrain Yaklaşımı ile Duygu Analizi. *Proceeding Book*, 30.

Tepecik, A., & Demir, E. (2023). Üç duygu ile etiketlenmiş Türkçe ses kayıt verilerinin makine öğrenim algoritmalarıyla analizi. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 39(2), 709–716.

Tuncer, T., & Çetintaş, D. (2019). Bir Sosyal Ağdan Alınan Verilerin Anlamsal Kutuplandırılması. Computer Science, 4(1), 1–6.

