
BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİNDE İLERİ ARAŞTIRMALAR

Editör: Dr.Öğr.Üyesi Gökhan KUTLUANA

Bilgisayar Bilimleri ve Mühendisliğinde İleri Araştırmalar

Editör

Dr.Öğr.Üyesi Gökhan KUTLUANA

yaz
yayınları

2024

KÜNYE BİLGİLERİ

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

İÇİNDEKİLER

Autonomous Driving Technologies And Cyber Security In Vehicles	 1
<i>Selahattin Barış ÇELEBİ</i>	
<i>Ömer Ali KARAMAN</i>	
<i>Gökhan ÖZTÜRK</i>	
 Artificial Intelligence Supported Ob- ject Detection In Uavs	 41
<i>Mehmet Serhat CEYLAN</i>	
<i>Gül Fatma TÜRKER</i>	
 Artificial Intelligence Supported Ob- ject Detection In Uavs	 60
<i>Mehmet Serhat CEYLAN</i>	
<i>Gül Fatma TÜRKER</i>	
 Tiroit Hastalıklarının Derin Öğrenme İle Sınıflandırılması	 81
<i>Mehmet Süleyman YILDIRIM</i>	
 Diyabet Teşhisinde Açıklanabilir Yapay Zeka: Shap Ve Lime Yaklaşımı	 100
<i>Nadir SUBAŞI</i>	

Ekg Sınıflandırmada Graf Dönüşümü Temelli Yaklaşımlar	 116
--	------------------

Gökhan KUTLUANA

Kuantum Bilgi İşlem: Yeni Bir Hesap- lama Paradigması	 135
--	------------------

Gamzepelin AKSOY

Murat KARABATAK

Tıbbi Görüntülerde Yapay Zekâ Te- melli Nesne Tespiti Uygulamaları	 157
---	------------------

Hasan Ali AKYÜREK

Yapay Zeka Ve Sağlık: Biyomühen- dislik Perspektifinden Yenilikçi Yak- laşımlar	 199
--	------------------

Gizem TUTKUN

Ece ŞİMŞEK

Kübra YILDIRIM

Uğur BİLGE

Mustafa ÖZDOĞAN

Ahmet Yılmaz ÇOBAN

The Contribution Of Manned Model Simulators To Maritime Education In Turkey	 211
--	------------------

Özkan AKAR

AUTONOMOUS DRIVING TECHNOLOGIES AND CYBER SECURITY IN VEHICLES

Selahattin Barış ÇELEBİ¹

Ömer Ali KARAMAN²

Gökhan ÖZTÜRK³

1. INTRODUCTION

Today's automotive industry is turning towards alternative vehicle technologies due to environmental concerns (Öner et al., 2022). However, it is experiencing a digitalization-based transformation process that goes beyond traditional mechanical systems (Trovao, 2020). One of the most important components of this transformation is the development of autonomous driving technologies and equipping vehicles with internet-integrated systems (Bathla et al., 2022). However, while these technological advances improve the performance of vehicles, they also bring new security vulnerabilities. Cyber security, especially in connected vehicles, has become a critical issue for user safety, data privacy and operational continuity (J. Han et al., 2023). Figure 1 shows the intersection of autonomous driving technologies and cybersecurity measures and their importance for safe and reliable driving.

¹ Visiting Research Fellow: Department of Computer Science, University of Warwick, Coventry, UK. ORCID No: 0000-0002-6235-9348.

² Associate Professor Dr: Department of Electronics and Automation, Vocational School of Technical Sciences, Batman University, TÜRKİYE. ORCID No: 0000-0003-1640-861X.

³ Lecturer: Department of Mechanical and Metal Technologies, Vocational School of Technical Sciences, Batman University, TÜRKİYE. ORCID No: 0000-0002-2780-6966.



Figure 1. The relationship between autonomous driving and cybersecurity and safe use

Autonomous vehicles are systems that use software systems, sensors and continuous data communication to sense their environment and make decisions (Balachander et al., 2021). These vehicles have the potential to improve road safety and reduce human error (Szűcs & Hézer, 2022). However, cyber-attacks and malicious interference can pose serious risks to vehicle and road safety. Strong cybersecurity solutions are therefore essential for the reliable operation of autonomous driving technologies (Abou Abdalla & S.B, 2022).

Cybersecurity in autonomous vehicles means not only protecting against external attacks, but also ensuring secure communication of systems within the vehicle and minimizing system failures. It is also crucial for protecting user data and complying with legal regulations. Today, vehicle manufacturers and technology companies offer a variety of solutions ranging from secure software development processes to in-vehicle encryption techniques (Mlada et al., 2022). Autonomous vehicle technologies are also complex, consisting of several critical components. Advanced digital systems involve the integration of hardware such as sensors, processors and data storage units, while decision-making capabilities rely on AI and algorithms

that enable vehicles to make automated decisions by sensing environmental conditions(Liu et al., 2021). Environmental data processing enables vehicles to understand the world around them by collecting map, traffic, road and weather data (Shang et al., 2021). Furthermore, vulnerabilities include threats that autonomous systems face, such as cyber-attacks and software bugs. All these elements play an important role in ensuring that autonomous vehicles can operate safely, efficiently and sustainably (Chehri & Mouftah, 2019). Figure 2 presents the different components of autonomous vehicle technologies in layers, emphasizing the complex and multifaceted nature of these systems. This approach contributes to a holistic understanding of the subject.




Figure 2. Layered approach of autonomous vehicle technologies

The digital transformation and autonomous driving systems in the automotive industry require cyber security approaches to be differentiated from traditional defense methods. Therefore, cybersecurity solutions are not only a technological necessity, but also one of the fundamental building blocks of society's trust in these new generation vehicles. Therefore, addressing both the technological and ethical dimensions of autonomous vehicles and putting cybersecurity at the center of this

process is inevitable for a sustainable and reliable automotive future.

2. STRUCTURE AND SECURITY REQUIREMENTS OF AUTONOMOUS VEHICLES

With the proliferation of autonomous and connected vehicles, the development of secure communication protocols has become a priority requirement for vehicle safety. Vehicle safety consists of environmental data collection, analysis of this data by AI and automated decision-making. If we look at these stages.

a. Data Acquisition and Analysis: AI analyzes data from vehicle cameras and sensors (e.g., LIDAR, radar, etc.). This data includes obstacles on the road, other vehicles, pedestrians, or dangerous situations.

b. Decision Making: AI algorithms analyze this data and assess whether there is a threat to the safety of the vehicle. For example, a pedestrian suddenly crossing the road, another vehicle approaching at high speed, or a slippery road surface may pose a risk. If a risk is detected, the vehicle decides to take appropriate safety action. This may include actions such as reducing speed, stopping, or changing direction (Figure 3).




Figure 3. Decision making in autonomous vehicles

2.1. Components and Communication Infrastructures of Autonomous Vehicles

AI has been successfully applied in areas such as disease diagnosis in healthcare (Asif et al., 2023), surface roughness detection (K. Han et al., 2023), spam mail detection (Kaşoğlu & Yaman, 2023) and natural language processing (Sunar & Khalid, 2024). The successes achieved in these areas show that AI-based algorithms can also be applied in autonomous vehicles.

Autonomous vehicles require various critical components such as sensors, AI and communication infrastructures to work in seamless collaboration in order to navigate safely and driverless. These vehicles collect data from their surroundings using sensors such as LIDAR, radar and cameras. This data

plays a key role in the vehicles' environmental sensing and navigation processes (De Sousa & Andrade Gonçalves, 2011). The information collected by sensors is analyzed by AI algorithms, allowing vehicles to make real-time decisions. For example, AI and ML algorithms make safe driving decisions by detecting pedestrians, other vehicles and obstacles they may encounter on the road (Muhammad et al., 2021). Communication infrastructures, on the other hand, are only tools but also with other vehicles and traffic management systems. provides. This enhances information sharing between vehicles, ensuring safe and efficient driving (Djahel et al., 2015). However, the integration of these components brings new security challenges. Each component is vulnerable to cybersecurity threats and can become vulnerable to external attacks. Therefore, strengthening sensor and AI infrastructures and securing communication protocols against cyber-attacks are of utmost importance for autonomous vehicle safety (Sharma & Gillanders, 2022).

2.1 Environmental Sensing and Decision-Making Processes of Autonomous Vehicles

The environmental sensing and decision-making processes of autonomous vehicles enable vehicles to accurately perceive the conditions around them and make safe decisions based on this information. Environmental sensing is the coordinated work of various sensors that identify objects, pedestrians, and road conditions around the vehicle. In this process, in-vehicle sensors collect environmental data through technologies such as LIDAR, radar, and cameras. For example, LIDAR systems map the distance and size of objects around the vehicle in three dimensions, while radar sensors detect the speed and direction of moving objects (Fayyad et al., 2020). Figure 4 shows the stages of environmental sensing, data collection, AI processing and decision implementation of autonomous vehicles. Data from sensors is analyzed and transformed into safe driving decisions.




Figure 4. Sensors, artificial intelligence, communication infrastructures in autonomous vehicles

AI algorithms transmit the collected sensor data to the vehicle's decision-making system for processing. AI analyzes data to identify objects, detect obstacles, and create a safe route on the road. For example, the vehicle determines whether to stop or adjust its speed when a pedestrian or another vehicle approaches (Bazilinsky et al., 2021). Furthermore, the decision processes are integrated with inter-vehicle communication and traffic management to ensure safer and more efficient driving. Thus, vehicles make instant decisions based on environmental sensing data and move safely in traffic.

2.2 Specific Requirements for System Safety of Autonomous Vehicles

Ensuring system safety in autonomous vehicles is a critical requirement for reliable and uninterrupted operation of vehicles (Gao et al., 2022; Öztürk et al., 2021). In-vehicle control systems, AI algorithms and communication software are the

basic building blocks of these systems (Saravanan, 2020). However, a vulnerability in these software components can affect the behavior of the vehicle, endangering both passenger and environmental safety. Software used for inter-vehicle communication and data exchange between the vehicle and the environment is particularly vulnerable to malicious attacks. For example, attackers can manipulate the speed or route of a vehicle with inadequate software security measures. Measures such as encryption, authentication and secure data transfer should be implemented in software to prevent such threats. In addition, regular updating of software and patching of vulnerabilities is of paramount importance in increasing the resilience of the software infrastructure of autonomous vehicles.

To ensure the software security of autonomous vehicles, security requirements specific to each software component have been designed. Software components such as vehicle control systems, AI algorithms and communication protocols are vulnerable to external interference and malicious attacks (Rajapaksha et al., 2023). In particular, the security of AI software is of paramount importance; these systems perform critical functions, from environmental sensing to decision-making processes. However, manipulation or malicious data input into AI models can lead to incorrect decisions. For example, loading an incorrect data set into the system could result in the tool failing to detect obstacles correctly, thus causing security breaches. Therefore, strategies such as data validation, anomaly detection and attack prevention mechanisms should be implemented to improve the security of AI and other software systems (Mills et al., 2022). Ensuring software security is a fundamental requirement for autonomous vehicles to operate both reliably and sustainably. These security requirements not only enable vehicles to move safely, but also make autonomous driving systems more resilient to cyber threats. These requirements for each compo-

ment contribute to the sustainability of vehicle safety as autonomous vehicles become more widespread.

3. TYPES OF CYBER THREATS IN VEHICLES AND RISKS TO AUTONOMOUS VEHICLES

With the rapid development of autonomous vehicle technologies concerns about the safety of these vehicles are growing. In addition to traditional mechanical systems, modern vehicles rely heavily on digital technologies such as software, sensors, and communication protocols. This exposes them not only to the risk of physical damage, but also to cyber-attacks. Autonomous vehicles need to collect, process, and transmit large amounts of data to perform functions such as environmental sensing, decision making and inter-vehicle communication. However, the systems used in this process can be exposed to various security threats (Butt et al., 2022; Song et al., 2021). Cyber threats to vehicles are usually carried out through remote access, software manipulation and misuse of communication networks (Giannopoulos et al., 2017). For example, vehicles' electronic control units (ECUs) are at the heart of the autonomous driving system, controlling vital functions such as the engine, brakes, and steering. Attacks on ECUs can directly affect the functionality of the vehicle and lead to serious accidents (Elkhail et al., 2021).

In addition, attacks such as spoofing, or interception of GPS signals can compromise safety by disrupting vehicle navigation and location accuracy. Sensor manipulation can target vehicles' environmental sensing systems, causing false detection of pedestrians, other vehicles, or obstacles. The intensive use of Internet of Things (IoT) technologies in in-vehicle networks further increases security vulnerabilities. While in-vehicle networks enable different parts of vehicles to communicate with each other, they can be a vulnerable point against external inter-

ference. By targeting the in-vehicle network, an attacker can disrupt the functioning of the system or gain access to critical data (Kelarestaghi et al., 2021; Kılınçer et al., 2020). In addition, hacking or spoofing artificial intelligence-based systems used in autonomous vehicles can lead to the vehicle making erroneous decisions. Such risks threaten not only individual vehicle safety, but also the communication between vehicles connected to a large network. Developing effective cybersecurity measures against these threats is imperative for the safe deployment of autonomous vehicles. Vehicle manufacturers, software developers and regulators need to work together to establish standards and protocols. In this context, understanding and effectively managing cyber threats plays a key role in moving autonomous vehicles towards a secure future.

4. CYBER SECURITY STANDARDS IN VEHICLES, LEGAL REGULATIONS AND CRITERIA APPLIED TO AUTONOMOUS VEHICLES

The automotive industry has faced new safety challenges with the integration of software and electronic systems in the process of technological transformation. Digitalization in vehicles has become more complex with the proliferation of innovative technologies such as autonomous driving, connected vehicles and the IoT. This has made cybersecurity a critical requirement for the automotive industry (Luo et al., 2022). The presence of cyber vulnerabilities in vehicles is emerging as a serious problem that threatens not only individual users but also public safety, traffic order and economic systems. In this context, the ISO/SAE 21434 standard provides a global reference framework for managing cyber security risks throughout the life cycle of vehicles (ISO/SAE 21434, n.d.).

The ISO/SAE 21434 standard aims to secure vehicles with an approach that covers the entire automotive ecosystem,

from vehicle manufacturers to suppliers. The standard provides processes and methods for identifying, implementing, and verifying cybersecurity requirements. This standard, which takes into account the entire life cycle of vehicles from the design phase to recycling, has been prepared by taking into account the increasing cyber threats, especially in autonomous and connected vehicles (Macher et al., 2020). The standard requires vehicle manufacturers and suppliers to adopt risk assessment and management processes ranging from software security to hardware integration. ISO/SAE 21434 not only provides a framework for defining and implementing cybersecurity requirements, but also promotes international harmonization and cooperation. This standard covers processes such as threat analysis, assessment of attack scenarios, risk management and security verification to minimize cyber security risks (Ebrahimi et al., 2022; Kawanishi et al., 2023). In addition, it aims to ensure the long-term safety of vehicles by adopting a “sustainable security” approach in its constantly updated software and hardware infrastructures.

In today’s complex cyber threat environment, the implementation of ISO/SAE 21434 has become a strategic requirement for the automotive industry. Especially with the proliferation of autonomous vehicles and connected vehicle technologies, this standard is a critical building block to create a secure automotive ecosystem on a global level. Effective management of cybersecurity vulnerabilities will contribute to enhancing security at both individual and societal levels and increase the industry's credibility in this area.

5. PROTECTION METHODS AND ADVANCED SECURITY SOLUTIONS

There are various methods used to ensure/enhance the safety of autonomous and connected vehicles. Vehicle-to-Everything technology enables vehicles to communicate secure-

ly with other vehicles, infrastructure and pedestrians, but the security of these communication networks is of paramount importance. Data is protected with encryption, authentication, and secure communication protocols. In addition, AI and ML algorithms are used to detect and prevent cyber threats. Over-the-Air updates are a critical method to quickly address vulnerabilities. In-vehicle network segmentation maintains system integrity and enhances security.

5.1 Vehicle-to-Everything (V2X)

It aims to improve traffic safety and road efficiency by enabling vehicles to communicate with other vehicles (V2V), infrastructure (V2I), pedestrians (V2P) and cloud systems (V2N) (Figure 5). However, the security of these communication networks is at serious risk from malicious attacks(Chekole & Guo, 2021).




Figure 5. V2X communication

The encryption and authentication mechanisms used to secure V2X ensure that data is protected from unauthorized access and manipulation. For example, symmetric and asymmetric encryption methods secure the exchange of data between vehicles, preventing attackers from intercepting it (Xu & Ritcey, 2022). In addition, protocols designed for secure data transfer play a critical role, especially in preventing forged messages and maintaining the integrity of communication networks. The secure implementation of V2X technology makes it possible to protect not only the safety of individual vehicles, but also the integrity of the traffic ecosystem. In this context, the continuous development of encryption technologies and secure communication protocols offers a sustainable security strategy for autonomous vehicles (J. Wang et al., 2019).

5.2 AI Based Security Solutions

AI-based security solutions significantly strengthen the security infrastructure of autonomous vehicles by providing a powerful tool for the detection, analysis and prevention of cyber threats (Z. Wang et al., 2022). Especially the real-time processing of large amounts of data and making quick decisions based on this data makes the use of AI indispensable in security processes. Autonomous vehicles can achieve higher accuracy and reliability by using Ensemble Learning methods to process environmental data and make safe driving decisions (Hoel et al., 2023; Sunar & Tümen, 2023). With these techniques, it detects abnormal behaviors and attack patterns and provides proactive protection of in-vehicle systems. Artificial Neural Networks is a ML algorithm that mimics the working principles of the human brain and learns by processing information (Birecikli et al., 2020). Deep learning (DL) is an advanced AI technique that can perform more complex data analysis and modeling by increasing the layers of artificial neural networks (Çelebi & Emiroğlu, 2023). Deep learning models can be used to analyze in-vehicle

sensor data to detect suspicious activity and intervene (Alsaade & Al-Adhaileh, 2023). In addition, AI-powered systems are being implemented to identify vulnerabilities in the communication protocols of autonomous vehicles and close them quickly. AI-based security solutions provide resilience not only against existing threats, but also against new types of attacks that may emerge. In this context, making AI a standard in the security of autonomous vehicles is critical for a reliable and sustainable driving experience.

5.3 Real-time Attack Detection Solutions

Real-time attack detection and cyber defense mechanisms are another vital task in autonomous vehicles to prevent threats and maintain vehicle security. In particular, securing the communication protocols used in autonomous vehicles is one of the main ways to prevent data manipulation and malicious interference (Wu et al., 2020). Real-time attack detection, powered by ML and AI algorithms, detects deviations from normal network behavior, enabling immediate response. These systems minimize security breaches by identifying both known threats and unprecedented attack types (Nitesh et al., 2023). In addition, the integrated use of encryption and secure communication protocols ensures both confidentiality and integrity during data transfer. Table 1 presents the pseudo-code for real-time Attack detection and cyber defense mechanisms.

Table 1. Pseudocode for real-time attack detection and cyber defense mechanisms

Input:

Let us assume network traffic data D , trained machine learning model M , security protocols (E), encryption and secure communication protocols, learning rate α and total number of iterations T .

Algorithm:

1. Initialization:

- Label dataset D as normal (benign) or abnormal (attack).
- Train M to learn patterns of normal behavior and attacks:

$$\theta \leftarrow \arg \min_{\theta} \sum_{i=1}^n L(M(D_i), y_i)$$

Where θ represents model parameters and L is the loss function.

2. Real-Time Detection and Defense:

For $t = 1$ to T :

A. Analyze incoming data and compute model output:

$$P_t = M(D_t, \theta)$$

Where P_t is the detected potential threat at time step t .

B. Compare P_t with normal behavior to detect anomalies:

if $P_t \neq \text{Normal}$:

Classify the type of threat: $\text{Threat Type} \leftarrow f(P_t)$

Apply immediate countermeasures: $\text{Apply}(E)$.

C. Deploy defense mechanisms against the detected threat:

Update encryption and secure communication protocols:

$$E \leftarrow E + \Delta E$$

D. Optimize model parameters:

$$\theta \leftarrow \theta - \alpha \nabla_{\theta} L$$

3. Output:

Final model output $\hat{y}_T$ after optimization, providing threat detection and response results.

The pseudo-code in Table 1 describes the operation of a real-time attack detection and cyber defense system in autonomous vehicles. First, network traffic data is labeled as normal (benign) and abnormal (attack) and a ML model is trained to learn the difference between normal behavior and malicious activities. During operation, the system continuously analyzes incoming data, detects deviations from normal behavior and classifies threat types in real time. When threats are detected, it

takes measures to neutralize them by updating encryption and secure communication protocols. Model parameters are optimized at each iteration, increasing threat detection accuracy. The result is a proactive defense system that can respond quickly to both known and emerging threats, improving vehicle security.

Cyber defense mechanisms ensure that autonomous vehicles are resilient to both internal and external threats. These approaches encourage adopting a proactive rather than reactive strategy for vehicle security. Therefore, real-time attack detection is an essential part of modern vehicle security solutions.

5.4. Over-the-Air (OTA) updates

The complex software infrastructures of autonomous and connected vehicles require constant updating and improvement against security vulnerabilities. Over-the-Air (OTA) updates have become a critical method to quickly and effectively address vulnerabilities that may occur in the software and hardware components of vehicles (Chou & Li, 2023). OTA updates reduce security risks and optimize vehicle performance by remotely updating vehicle systems without requiring physical intervention. Encryption and secure communication protocols are a fundamental requirement to ensure the secure transmission and application of OTA updates. In particular, the integrity and authenticity of update packages must be protected against malicious attacks. Strong encryption methods and authentication mechanisms increase the reliability of vehicle systems by preventing unauthorized access (Howden et al., 2020; Plappert & Fuchs, 2023). The importance of OTA updates is not only limited to addressing existing vulnerabilities; it also ensures that software is continuously adapted to new threats. This approach contributes to creating a secure and sustainable digital ecosystem for both individual users and the automotive industry. OTA tech-

nology is therefore of great importance in modern vehicle security solutions.

5.5. Advanced In-Vehicle Network Security Protection Techniques

Autonomous and connected vehicles function by communicating between internal systems through complex network structures. However, the security and integrity of these networks can be vulnerable to malicious attacks. For example, let's take a vehicle that works with facial recognition technology; in this case, it is necessary to take precautions against the use of fake faces (Ibrahim Syed et al., 2023). In-vehicle network segmentation as another security solution is a critical strategy to minimize this risk and increase system security (Kang & Kang, 2016). This method segments in-vehicle networks, preventing an attack on one component from affecting the entire system. Segmentation enables more secure data flow between different components such as in-vehicle sensors, control units and communication modules. In addition, encryption and authentication protocols guarantee the confidentiality and integrity of data transmitted over these networks (Lee et al., 2021). Especially considering that autonomous vehicles operate with sensitive data, secure data sharing is critical to the security of both individual users and the overall system. In-vehicle network segmentation not only prevents current security threats, but also creates a more resilient structure against future attacks. Therefore, segmentation and secure data sharing are recognized as essential components in modern automotive security solutions.

6. AUTONOMOUS VEHICLES AND CYBER SECURITY TRENDS IN THE FUTURE

Autonomous vehicles are becoming increasingly intelligent and sophisticated through the convergence of AI and ML technologies. AI algorithms enable vehicles to analyze environ-

mental data in real time, optimize driving decisions and take proactive measures to prevent potential accidents. For example, deep learning models can process data from vehicle cameras and sensors to accurately identify pedestrians, other vehicles and road signs (Pavel et al., 2022). However, these technologies have a twofold impact on security. On the one hand, AI improves security by minimizing human errors, but on the other hand, it increases the vulnerability of systems to external attacks. In particular, the ability of AI models trained with the wrong data to make wrong decisions or be manipulated by cyber-attacks poses a significant threat (Dunn et al., 2020).

6.1. The Impact of Artificial Intelligence and Machine Learning on Safety in Autonomous Vehicles

ML plays a critical role for autonomous vehicles to continuously adapt to environmental conditions. In particular, unsupervised learning algorithms for anomalous behavior detection enable systems to react quickly to unexpected situations (Kong et al., 2017). However, this increases the dependency on the reliability and integrity of the data. By corrupting sensor data or generating fake data, an attacker could cause the vehicle to make incorrect decisions. To prevent such risks, secure data processing, model validation and attack detection mechanisms need to be developed. Furthermore, the communication infrastructure of autonomous vehicles must also be protected against cyber-attacks, as interference through V2V and V2I communication systems can lead to chain accidents (Feng & Haykin, 2019; Marcillo et al., 2022). In this context, the development of AI and ML-based safety solutions is critical for the sustainability of the autonomous vehicle ecosystem.

6.2. 5G's Potential Impact on Vehicle Safety

5G technology is revolutionizing the communication infrastructure of autonomous vehicles, offering significant potential for safety. Thanks to its high speed, low latency and increased connectivity, 5G enables real-time V2V and V2I communications. These features enable vehicles to make faster and more accurate decisions by enabling instant data exchange, which plays a vital role, especially in accident prevention (Ojo et al., 2022). For example, a 5G-enabled vehicle can process danger warnings from other vehicles in traffic within milliseconds and take measures such as sudden braking or lane changes. However, while this technology increases the security level of vehicles, it also brings with it the risks of cyber-attacks and data breaches. Given the sensitivity of data transmitted over the network, strengthening data encryption and security protocols in 5G infrastructure has become a necessity (Kakkar, 2020). However, the vast connectivity offered by 5G is accelerating the integration of smart cities by enabling many more devices to connect to the network simultaneously. This makes it possible for vehicles to effectively communicate not only with each other, but also with traffic lights, road infrastructure and other IoT devices. However, this vast ecosystem of connectivity creates a potential attack surface for malicious actors. For example, a cyber attacker could take control of traffic lights, causing chain accidents or manipulating the routes of vehicles. Therefore, network security, attack detection systems and AI-based defense mechanisms need to be developed to fully exploit 5G's potential for vehicle security. The safe operation of 5G-enabled autonomous vehicles requires international cooperation and standardization efforts to reduce the vulnerabilities of these technologies.

6.3. Blockchain and Autonomous Vehicle Security

Blockchain technology is an innovative solution that can improve the security and accuracy of autonomous vehicle data management. Thanks to its decentralized nature, blockchain can enable autonomous vehicles to securely process and store data collected from sensors, in-vehicle systems and environmental sources (Jain et al., 2021). Data stored on the blockchain is protected by cryptographic algorithms, making it virtually impossible to change or manipulate (Baygin et al., 2022). This helps prevent accidents and safety breaches by guaranteeing the accuracy of the data that autonomous vehicles use to make critical decisions. For example, in a blockchain-based system, vehicles can reliably share information such as speed, location and direction of surrounding vehicles while traveling, which increases security in V2V communication (Das et al., 2023)

One of blockchain's contributions to data security is its transparency into historical data. By recording every data record in an immutable way, blockchain technology makes it easier to identify the source of the problem in the event of an attack or malfunction. This offers a significant advantage, especially for vehicle manufacturers and insurance companies. For example, following an accident, vehicle behavior at the time of the accident can be examined and liability determined based on the data stored on the blockchain (Guo et al., 2020). However, the implementation of this technology brings some challenges. High data processing requirements and energy consumption are technical limitations that need to be considered in the integration of blockchain into the autonomous vehicle ecosystem. Furthermore, the scalability of blockchain networks is another key issue in scenarios involving a large number of vehicles (Kapassa et al., 2021).

The use of blockchain for autonomous vehicles not only ensures the accuracy and security of data, but also offers a defense mechanism against cyberattacks. For example, a blockchain-based system can prevent counterfeit devices or malicious actors from accessing the network by securing authentication processes. Furthermore, through the use of smart contracts, data sharing and transactions between autonomous vehicles can be fully automated and secure (Javed et al., 2020). These features allow vehicles to become more resilient to cybersecurity risks. While the advantages offered by blockchain show the potential to improve the security of autonomous vehicles, more research and development work is needed before this technology can be fully implemented. Standardization efforts and industry collaborations are critical for blockchain to be used effectively and safely in autonomous vehicles.

6.4. Future Threats

One of the biggest threats autonomous vehicles will face in the future is the potential for quantum computers to break existing cryptography systems. Today, autonomous vehicles rely on cryptographic algorithms such as RSA and ECC for communication and data security. However, quantum computers have the computational power to neutralize these algorithms with techniques such as the Shor algorithm (Monz et al., 2016). This could leave the communication infrastructure of autonomous vehicles (e.g., inter-vehicle communication and vehicle-to-grid communication) vulnerable. Quantum security requires the development and implementation of quantum-resilient algorithms to prevent this threat. Post-quantum cryptography systems could enable autonomous vehicles to become resistant to quantum attacks. However, technical and logistical issues such as standardization and performance optimization need to be solved before these technologies can be widely implemented (Figlarz & Hessel, 2022).

The security risks of autonomous vehicles are not limited to technological attacks; social engineering attacks also pose a significant threat. Social engineering aims to gain access to information by manipulating human behavior, but these techniques can also be used against autonomous systems. For example, malicious actors can mislead vehicles' environmental sensing systems to alter traffic signs or create false emergency information. Such manipulations can cause vehicles to make wrong decisions and cause accidents. To mitigate the effects of social engineering attacks, the environmental sensing and decision-making mechanisms of autonomous vehicles need to be more resilient and capable of verification. In particular, considering the fallibility of AI-based sensing systems, defense strategies such as multi-layer verification and suspect detection should be developed (Shamshirband et al., 2014).

Quantum security and social engineering attacks represent two key areas that will shape the security of autonomous vehicles in the future. Rapid adoption of post-quantum cryptography standards is a critical requirement to build an effective defense against quantum attacks, while awareness of social engineering attacks must be raised both technologically and ethically. The complexity of these threats necessitates international cooperation and multidisciplinary approaches. For autonomous vehicles to operate safely, it is vital to develop not only technical innovations but also training and awareness programs in social engineering and quantum security.

7. CONCLUSION

Autonomous vehicles and cybersecurity are two important elements that have had a transformative impact on the automotive industry. Thanks to technological advances, vehicles have evolved from being mere means of transportation to intelligent systems with capabilities such as environmental sensing, decision-making and interaction with other vehicles. However, these advances have also brought new security challenges. The combination of artificial intelligence, sensors and communication infrastructures of vehicles can make them vulnerable to malicious attacks. In this context, to ensure safe driving, security measures need to be taken both within the system components and during data transfer between these components. AI-based security solutions offer both an effective defense against existing threats and flexibility against new risks that may emerge in the future. Furthermore, V2X technologies improve traffic safety by enabling secure data communication between vehicles, but the security of these systems needs to be continuously improved. The decentralized security structures offered by blockchain technology offer significant potential to improve both data integrity and resistance to attacks. In the future, the increasing capacity of quantum computers to break traditional cryptographic methods and the increasing sophistication of social engineering attacks will necessitate a reconsideration of autonomous vehicle security. This will require the development of advanced security measures such as post-quantum cryptography and the implementation of international standards.

As a result, a multidisciplinary approach is required for autonomous vehicles to function safely. Collaboration between researchers, engineers and regulators will enable the creation of a safer and sustainable vehicle ecosystem, considering not only technical innovations, but also the ethical and societal dimensions of these innovations. Advances in cybersecurity will contribute to the security not only of autonomous vehicles, but also of all future intelligent systems.

REFERENCES

- AbouAbdalla, K. O., & S.B, G. (2022). Autonomous Vehicles: Improving Cyber Security. *International Journal of Advanced Research in Technology and Innovation*. <https://doi.org/10.55057/ijarti.2022.4.1.13>
- Alsaade, F. W., & Al-Adhaileh, M. H. (2023). Cyber Attack Detection for Self-Driving Vehicle Networks Using Deep Autoencoder Algorithms. *Sensors*, 23(8), 4086. <https://doi.org/10.3390/s23084086>
- Asif, A., Rajpoot, K., Graham, S., Snead, D., Minhas, F., & Rajpoot, N. (2023). Unleashing the potential of AI for pathology: Challenges and recommendations. *The Journal of Pathology*, 260(5), 564–577. <https://doi.org/10.1002/path.6168>
- Balachander, K., Venkatesan, C., & R., K. (2021). Safety driven intelligent autonomous vehicle for smart cities using IoT. *International Journal of Pervasive Computing and Communications*, 17(5), 563–582. <https://doi.org/10.1108/IJPC-10-2020-0182>
- Bathla, G., Bhadane, K., Singh, R. K., Kumar, R., Aluvalu, R., Krishnamurthi, R., Kumar, A., Thakur, R. N., & Basheer, S. (2022). Autonomous Vehicles and Intelligent Automation: Applications, Challenges, and Opportunities. *Mobile Information Systems*, 2022, 1–36. <https://doi.org/10.1155/2022/7632892>
- Baygin, M., Yaman, O., Baygin, N., & Karakose, M. (2022). A blockchain-based approach to smart cargo transportation using UHF RFID. *Expert Systems with Applications*, 188, 116030. <https://doi.org/10.1016/j.eswa.2021.116030>

- Bazilinskyy, P., Sakuma, T., & De Winter, J. (2021). What driving style makes pedestrians think a passing vehicle is driving automatically? *Applied Ergonomics*, 95, 103428. <https://doi.org/10.1016/j.apergo.2021.103428>
- Birecikli, B., Karaman, Ö. A., Çelebi, S. B., & Turgut, A. (2020). Failure load prediction of adhesively bonded GFRP composite joints using artificial neural networks. *Journal of Mechanical Science and Technology*, 34(11), 4631–4640. <https://doi.org/10.1007/s12206-020-1021-7>
- Butt, F. A., Chattha, J. N., Ahmad, J., Zia, M. U., Rizwan, M., & Naqvi, I. H. (2022). On the Integration of Enabling Wireless Technologies and Sensor Fusion for Next-Generation Connected and Autonomous Vehicles. *IEEE Access*, 10, 14643–14668. <https://doi.org/10.1109/ACCESS.2022.3145972>
- Çelebi, S. B., & Emiroğlu, B. G. (2023). Leveraging Deep Learning for Enhanced Detection of Alzheimer’s Disease Through Morphometric Analysis of Brain Images. *Traitement Du Signal*, 40(4), 1355–1365. <https://doi.org/10.18280/ts.400405>
- Chehri, A., & Mouftah, H. T. (2019). Autonomous vehicles in the sustainable cities, the beginning of a green adventure. *Sustainable Cities and Society*, 51, 101751. <https://doi.org/10.1016/j.scs.2019.101751>
- Chekole, E. G., & Guo, H. (2021). DARUD: Detecting and Arresting Rogue USB Devices in the V2X Ecosystem. *2021 IEEE International Conference on Service Operations and Logistics, and Informatics (SOLI)*, 1–6. <https://doi.org/10.1109/SOLI54607.2021.9672338>

- Chou, Y.-H., & Li, W.-W. (2023). Enhancing OTA Update Security in Zonal Architecture for Automobiles. *2023 IEEE 12th Global Conference on Consumer Electronics (GCCE)*, 761–762.
<https://doi.org/10.1109/GCCE59613.2023.10315400>
- Das, D., Banerjee, S., Chatterjee, P., Ghosh, U., & Biswas, U. (2023). A Secure Blockchain Enabled V2V Communication System Using Smart Contracts. *IEEE Transactions on Intelligent Transportation Systems*, 24(4), 4651–4660.
<https://doi.org/10.1109/TITS.2022.3226626>
- De Sousa, J. B., & Andrade Gonçalves, G. (2011). Unmanned vehicles for environmental data collection. *Clean Technologies and Environmental Policy*, 13(2), 369–380.
<https://doi.org/10.1007/s10098-010-0313-5>
- Djahel, S., Doolan, R., Muntean, G.-M., & Murphy, J. (2015). A Communications-Oriented Perspective on Traffic Management Systems for Smart Cities: Challenges and Innovative Approaches. *IEEE Communications Surveys & Tutorials*, 17(1), 125–151.
<https://doi.org/10.1109/COMST.2014.2339817>
- Dunn, C., Moustafa, N., & Turnbull, B. (2020). Robustness Evaluations of Sustainable Machine Learning Models against Data Poisoning Attacks in the Internet of Things. *Sustainability*, 12(16), 6434.
<https://doi.org/10.3390/su12166434>
- Ebrahimi, M., Striessnig, C., Castella Triginer, J., & Schmittner, C. (2022). *Identification and Verification of Attack-Tree Threat Models in Connected Vehicles*. 2022-01–7087.
<https://doi.org/10.4271/2022-01-7087>

- Elkhail, A. A., Refat, R. U. D., Habre, R., Hafeez, A., Bacha, A., & Malik, H. (2021). Vehicle Security: A Survey of Security Issues and Vulnerabilities, Malware Attacks and Defenses. *IEEE Access*, 9, 162401–162437. <https://doi.org/10.1109/ACCESS.2021.3130495>
- Fayyad, J., Jaradat, M. A., Gruyer, D., & Najjaran, H. (2020). Deep Learning Sensor Fusion for Autonomous Vehicle Perception and Localization: A Review. *Sensors*, 20(15), 4220. <https://doi.org/10.3390/s20154220>
- Feng, S., & Haykin, S. (2019). Cognitive Risk Control for Anti-Jamming V2V Communications in Autonomous Vehicle Networks. *IEEE Transactions on Vehicular Technology*, 68(10), 9920–9934. <https://doi.org/10.1109/TVT.2019.2935999>
- Figlarz, G. R., & Hessel, F. P. (2022). Applied Post-Quantum Secure Method for IoT Devices: A Case Study for Autonomous Vehicles Communication. *2022 IEEE 8th World Forum on Internet of Things (WF-IoT)*, 1–6. <https://doi.org/10.1109/WF-IoT54382.2022.10152075>
- Gao, C., Wang, G., Shi, W., Wang, Z., & Chen, Y. (2022). Autonomous Driving Security: State of the Art and Challenges. *IEEE Internet of Things Journal*, 9(10), 7572–7595. <https://doi.org/10.1109/JIOT.2021.3130054>
- Giannopoulos, H., Wyglinski, A. M., & Chapman, J. (2017). Securing Vehicular Controller Area Networks: An Approach to Active Bus-Level Countermeasures. *IEEE Vehicular Technology Magazine*, 12(4), 60–68. <https://doi.org/10.1109/MVT.2017.2647814>

- Guo, H., Li, W., Nejad, M., & Shen, C.-C. (2020). Proof-of-Event Recording System for Autonomous Vehicles: A Blockchain-Based Solution. *IEEE Access*, 8, 182776–182786. <https://doi.org/10.1109/ACCESS.2020.3029512>
- Han, J., Ju, Z., Chen, X., Yang, M., Zhang, H., & Huai, R. (2023). Secure Operations of Connected and Autonomous Vehicles. *IEEE Transactions on Intelligent Vehicles*, 8(11), 4484–4497. <https://doi.org/10.1109/TIV.2023.3304762>
- Han, K., Öztürk, G., & Aslan, A. (2023). Yapay Sinir Ağları Kullanarak Yüzey Pürüzlülüğü Tespiti. *International Conference on Pioneer and Innovative Studies*, 1, 487–492. <https://doi.org/10.59287/icpis.877>
- Hoel, C.-J., Wolff, K., & Laine, L. (2023). Ensemble Quantile Networks: Uncertainty-Aware Reinforcement Learning With Applications in Autonomous Driving. *IEEE Transactions on Intelligent Transportation Systems*, 24(6), 6030–6041. <https://doi.org/10.1109/TITS.2023.3251376>
- Howden, J., Maglaras, L., & Ferrag, M. A. (2020). The Security Aspects of Automotive Over-the-Air Updates: *International Journal of Cyber Warfare and Terrorism*, 10(2), 64–81. <https://doi.org/10.4018/IJCWT.2020040104>
- Ibrahim Syed, M., Asif, A., Shahzad, M., Khan, U., Khan, S., & Mahmood, Z. (2023). Towards face anti-spoofing. *Journal of Experimental & Theoretical Artificial Intelligence*, 1–17. <https://doi.org/10.1080/0952813X.2023.2247398>
- ISO/SAE 21434:2021. (n.d.). ISO. Retrieved November 27, 2024, from <https://www.iso.org/standard/70918.html>

- Jain, S., Ahuja, N. J., Srikanth, P., Bhadane, K. V., Nagaiah, B., Kumar, A., & Konstantinou, C. (2021). Blockchain and Autonomous Vehicles: Recent Advances and Future Directions. *IEEE Access*, 9, 130264–130328. <https://doi.org/10.1109/ACCESS.2021.3113649>
- Javed, M. U., Rehman, M., Javaid, N., Aldegheishem, A., Alrajeh, N., & Tahir, M. (2020). Blockchain-Based Secure Data Storage for Distributed Vehicular Networks. *Applied Sciences*, 10(6), 2011. <https://doi.org/10.3390/app10062011>
- Kakkar, A. (2020). A survey on secure communication techniques for 5G wireless heterogeneous networks. *Information Fusion*, 62, 89–109. <https://doi.org/10.1016/j.inffus.2020.04.009>
- Kang, M.-J., & Kang, J.-W. (2016). Intrusion Detection System Using Deep Neural Network for In-Vehicle Network Security. *PLOS ONE*, 11(6), e0155781. <https://doi.org/10.1371/journal.pone.0155781>
- Kapassa, E., Themistocleous, M., Christodoulou, K., & Iosif, E. (2021). Blockchain Application in Internet of Vehicles: Challenges, Contributions and Current Limitations. *Future Internet*, 13(12), 313. <https://doi.org/10.3390/fi13120313>
- Kaşoğlu, A., & Yaman, O. (2023). LBP Feature Extraction and Statistical Pooling-Based Image Spam Detection Model. *Computer Science*. <https://doi.org/10.53070/bbd.1268221>
- Kawanishi, Y., Nishihara, H., Yoshida, H., Yamamoto, H., & Inoue, H. (2023). A Study on Threat Analysis and Risk Assessment Based on the “Asset Container” Method and CWSS. *IEEE Access*, 11, 18148–18156. <https://doi.org/10.1109/ACCESS.2023.3246497>

- Kelarestaghi, K. B., Foruhandeh, M., Heaslip, K., & Gerdes, R. (2021). Intelligent Transportation System Security: Impact-Oriented Risk Assessment of in-Vehicle Networks. *IEEE Intelligent Transportation Systems Magazine*, 13(2), 91–104. <https://doi.org/10.1109/MITS.2018.2889714>
- Kılınçer, İ. F., Ertam, F., Yaman, O., & Şengür, A. (2020). An Effective Security Method Based on Combining 802.1x, DMZ and SSL-VPN for IoT Network Security. *Acta INFOLOGICA*, 4(2). <https://doi.org/10.26650/acin.779547>
- Kong, Z., Jones, A., & Belta, C. (2017). Temporal Logics for Learning and Detection of Anomalous Behavior. *IEEE Transactions on Automatic Control*, 62(3), 1210–1222. <https://doi.org/10.1109/TAC.2016.2585083>
- Lee, J., Kim, G., Das, A. K., & Park, Y. (2021). Secure and Efficient Honey List-Based Authentication Protocol for Vehicular Ad Hoc Networks. *IEEE Transactions on Network Science and Engineering*, 8(3), 2412–2425. <https://doi.org/10.1109/TNSE.2021.3093435>
- Liu, L., Lu, S., Zhong, R., Wu, B., Yao, Y., Zhang, Q., & Shi, W. (2021). Computing Systems for Autonomous Driving: State of the Art and Challenges. *IEEE Internet of Things Journal*, 8(8), 6469–6486. <https://doi.org/10.1109/JIOT.2020.3043716>
- Luo, F., Zhang, X., Yang, Z., Jiang, Y., Wang, J., Wu, M., & Feng, W. (2022). Cybersecurity Testing for Automotive Domain: A Survey. *Sensors*, 22(23), 9211. <https://doi.org/10.3390/s22239211>

- Macher, G., Schmittner, C., Veledar, O., & Brenner, E. (2020). ISO/SAE DIS 21434 Automotive Cybersecurity Standard—In a Nutshell. In A. Casimiro, F. Ortmeier, E. Schoitsch, F. Bitsch, & P. Ferreira (Eds.), *Computer Safety, Reliability, and Security. SAFECOMP 2020 Workshops* (Vol. 12235, pp. 123–135). Springer International Publishing. https://doi.org/10.1007/978-3-030-55583-2_9
- Marcillo, P., Leonardo Valdivieso Caraguay, Á., & Hernandez-Alvarez, M. (2022). *Security in Vehicle-to-Infrastructure Communications*. 13th International Conference on Applied Human Factors and Ergonomics (AHFE 2022). <https://doi.org/10.54941/ahfe1002210>
- Mills, R., Marnerides, A. K., Broadbent, M., & Race, N. (2022). Practical Intrusion Detection of Emerging Threats. *IEEE Transactions on Network and Service Management*, 19(1), 582–600. <https://doi.org/10.1109/TNSM.2021.3091517>
- Mlada, M., Holy, R., Jirovsky, J., & Kasalicky, T. (2022). Protection of personal data in autonomous vehicles and its data categorization. *2022 Smart City Symposium Prague (SCSP)*, 1–5. <https://doi.org/10.1109/SCSP54748.2022.9792557>
- Monz, T., Nigg, D., Martinez, E. A., Brandl, M. F., Schindler, P., Rines, R., Wang, S. X., Chuang, I. L., & Blatt, R. (2016). Realization of a scalable Shor algorithm. *Science*, 351(6277), 1068–1070. <https://doi.org/10.1126/science.aad9480>

- Muhammad, K., Ullah, A., Lloret, J., Ser, J. D., & De Albuquerque, V. H. C. (2021). Deep Learning for Safe Autonomous Driving: Current Challenges and Future Directions. *IEEE Transactions on Intelligent Transportation Systems*, 22(7), 4316–4336. <https://doi.org/10.1109/TITS.2020.3032227>
- Nitesh, K. T., Thirumala, A. K., Mohammed, U. F., & Ahmed, M. R. (2023). Network Security Threat Detection: Leveraging Machine Learning Algorithms for Effective Prediction. *2023 12th International Conference on Advanced Computing (ICoAC)*, 1–5. <https://doi.org/10.1109/ICoAC59537.2023.10249943>
- Ojo, S., Olugbade, S., & Ojo, T. P. (2022). A Review of Road Accidents Detection through Wireless Technology—5G, MIMO and Internet of Things. *Open Journal of Applied Sciences*, 12(12), 1968–1978. <https://doi.org/10.4236/ojapps.2022.1212137>
- Öner, C., Öztürk, G., & Tanyeri, B. (2022). Investigation of the Effect of Using Ultrasonic Fuel System on Exhaust Emissions in a Spark Ignition Engine. *Afyon Kocatepe University Journal of Sciences and Engineering*, 22(5), 1214–1224. <https://doi.org/10.35414/akufemubid.1024495>
- Öztürk, G., Tansu, M. N., & Uz, U. (2021). TÜRKİYE’DE HİBRİD VE ELEKTRİKLİ ARAÇLARA EĞİLİMİN ARAŞTIRILMASI. *EJONS INTERNATIONAL JOURNAL ON MATHEMATICS, ENGINEERING & NATURAL SCIENCES*, 5(20), 814–823. <https://doi.org/10.38063/ejons.517>

- Pavel, M. I., Tan, S. Y., & Abdullah, A. (2022). Vision-Based Autonomous Vehicle Systems Based on Deep Learning: A Systematic Literature Review. *Applied Sciences*, 12(14), 6831. <https://doi.org/10.3390/app12146831>
- Plappert, C., & Fuchs, A. (2023). Secure and Lightweight ECU Attestations for Resilient Over-the-Air Updates in Connected Vehicles. *Annual Computer Security Applications Conference*, 283–297. <https://doi.org/10.1145/3627106.3627202>
- Rajapaksha, S., Kalutarage, H., Al-Kadri, M. O., Petrovski, A., Madzudzo, G., & Cheah, M. (2023). AI-Based Intrusion Detection Systems for In-Vehicle Networks: A Survey. *ACM Computing Surveys*, 55(11), 1–40. <https://doi.org/10.1145/3570954>
- Saravanan, S. (2020). Smart Automotive Systems Supported by Configurable FPGA, IoT, and Artificial Intelligence Techniques: In P. Sharma & R. Nair (Eds.), *Advances in Systems Analysis, Software Engineering, and High Performance Computing* (pp. 108–132). IGI Global. <https://doi.org/10.4018/978-1-5225-9806-0.ch006>
- Shamshirband, S., Anuar, N. B., Kiah, M. L. M., Rohani, V. A., Petković, D., Misra, S., & Khan, A. N. (2014). Co-FAIS: Cooperative fuzzy artificial immune system for detecting intrusion in wireless sensor networks. *Journal of Network and Computer Applications*, 42, 102–117. <https://doi.org/10.1016/j.jnca.2014.03.012>
- Shang, S., Shen, J., Wen, J.-R., & Kalnis, P. (2021). Deep understanding of big geospatial data for self-driving cars. *Neurocomputing*, 428, 308–309. <https://doi.org/10.1016/j.neucom.2020.06.119>

- Sharma, P., & Gillanders, J. (2022). Cybersecurity and Forensics in Connected Autonomous Vehicles: A Review of the State-of-the-Art. *IEEE Access*, 10, 108979–108996. <https://doi.org/10.1109/ACCESS.2022.3213843>
- Song, H., Zhou, S., Chang, Z., Su, Y., Liu, X., & Yang, J. (2021). Collaborative processing and data optimization of environmental perception technologies for autonomous vehicles. *Assembly Automation*, 41(3), 283–291. <https://doi.org/10.1108/AA-01-2021-0007>
- Sunar, A. S., & Khalid, M. S. (2024). Natural Language Processing of Student’s Feedback to Instructors: A Systematic Review. *IEEE Transactions on Learning Technologies*, 17, 741–753. <https://doi.org/10.1109/TLT.2023.3330531>
- Sunar, A. S., & Tümen, V. (2023). Predicting the Work-Life Balance of Employees Based on the Ensemble Learning Method. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 12(2), 344–353. <https://doi.org/10.17798/bitlisfen.1196174>
- Szűcs, H., & Hézer, J. (2022). Road Safety Analysis of Autonomous Vehicles: An Overview. *Periodica Polytechnica Transportation Engineering*, 50(4), 426–434. <https://doi.org/10.3311/PPtr.19605>
- Trovao, J. P. (2020). Digital Transformation, Systemic Design, and Automotive Electronics [Automotive Electronics]. *IEEE Vehicular Technology Magazine*, 15(2), 149–159. <https://doi.org/10.1109/MVT.2020.2980097>
- Wang, J., Shao, Y., Ge, Y., & Yu, R. (2019). A Survey of Vehicle to Everything (V2X) Testing. *Sensors*, 19(2), 334. <https://doi.org/10.3390/s19020334>

- Wang, Z., Wei, H., Wang, J., Zeng, X., & Chang, Y. (2022). Security Issues and Solutions for Connected and Autonomous Vehicles in a Sustainable City: A Survey. *Sustainability*, 14(19), 12409. <https://doi.org/10.3390/su141912409>
- Wu, W., Li, R., Xie, G., An, J., Bai, Y., Zhou, J., & Li, K. (2020). A Survey of Intrusion Detection for In-Vehicle Networks. *IEEE Transactions on Intelligent Transportation Systems*, 21(3), 919–933. <https://doi.org/10.1109/TITS.2019.2908074>
- Xu, D., & Ritcey, J. A. (2022). Post-Quantum PHY-Layer Authentication for Secure Initial Access in V2X Communications. *GLOBECOM 2022 - 2022 IEEE Global Communications Conference*, 1758–1762. <https://doi.org/10.1109/GLOBECOM48099.2022.10001736>



Selahattin Barış ÇELEBİ, PhD received his bachelor's degree in Computer Engineering from Selçuk University, Konya, in 2009. He got his master's degree in Computer Engineering from Fırat University, Elazığ, Turkey, and completed his Ph.D. in Computer Engineering at Kırıkkale University, Kırıkkale. Dr. Çelebi is currently an Assistant Professor in the Department of Management Information Systems at Batman University, where he has been a faculty member since 2013. His research interests include artificial intelligence, data science, machine learning, image processing, and Python programming. He has authored several journal articles and actively participates in peer review processes for various scientific journals.

Department of Computer Science, University of Warwick, Coventry, UK. sbariscelebi@gmail.com



Ömer Ali KARAMAN, PhD, received his bachelor's degree in Electrical and Electronics Engineering from Sakarya University. He got his master's degree in Electrical Education from Fırat University, Elazığ, Turkey, and completed his Ph.D. in Electrical and Electronics Engineering at Fırat University, Elazığ, Turkey. Dr. Karaman is currently an associate professor in the Department of Electronics and Automation at Batman University . His research interests include artificial intelligence, data science, machine learning, energy demand estimation. He has authored several journal articles and actively participates in peer review processes for various scientific journals.

Department of Electronics and Automation, Batman University, TÜRKİYE, omerralıkar@gmail.com



Gökhan ÖZTÜRK, graduated from the Department of Automotive Engineering at Fırat University, Elazığ in 2014. He completed his master's degree in Automotive Engineering at the same university in 2019. Since 2022, he has been pursuing his doctoral studies in Automotive Engineering at Fırat University. Between 2019 and 2021, he served as a lecturer in the Automotive Technology Program at Istanbul Gelişim University's Vocational School. Since 2021, he has been working as a lecturer in the Machine Program at Batman University's Vocational School of Technical Sciences. His research interests include internal combustion engines, electric vehicles, alternative fuels, and combustion processes.

**Department of Mechanical and Metal Technologies,
Batman University, TÜRKİYE. oz-
turk.gkhn23@gmail.com**

1. BİRİNCİ DERECE ALT BAŞLIK

Çalışmada ana başlıklar (birinci derecede alt başlık) GİRİŞ bölümünden başlayarak 12 Punto ve koyu şekilde tüm harfleri büyük olacak şekilde (1. 2. 3. biçiminde) numaralandırılmalıdır. SONUÇ bölümüne de numara verilmeli ancak KAYNAKÇA başlığına numara verilmemelidir. Çalışmada ana başlığın altında yer alacak alt başlıklar (İkinci derece alt başlık, 1.1. 1.2. ve 1.3. biçiminde; üçüncü derece alt başlık 1.1.1. 1.1.2. ve 1.1.3 şeklinde) yalnızca kelimelerin ilk harfleri büyük olacak şekilde ve tamamı koyu olarak yazılmalıdır.

KAYNAKÇA

Kaynak gösterme, kaynakça, dipnot, şekil, grafik şablonlarında APA 6 stili kullanılmalıdır.

SAĞLIK ALANINDA PEKİŞTİRMELİ ÖĞRENME

Muhammet KARADENİZ¹

1. GİRİŞ

Yapay zekâ (Artificial Intelligence) teknolojilerinin evrimi; 20. yüzyılın ortalarında kural tabanlı sistemlerle başlamış, 21. yüzyılda büyük veri analitiği ve makine öğrenmesi yöntemleriyle hız kazanmıştır. Elektronik sağlık kayıtlarının (Electronic Health Record) yaygınlaşması, yapay zekânın tıbbi veri analitiğinde kullanımını mümkün kılmış ve sağlık sistemlerinde verimliliği artırmada kritik bir rol oynamıştır (Y. Liu ve diğerleri, 2024). Bu gelişmeler, sağlık hizmetlerinde yapay zekânın hasta sonuçlarını iyileştirme ve maliyet etkinliğini artırma hedeflerine yönelmesini sağlamıştır. Aynı zamanda, daha etkili yönetim stratejilerinin geliştirilmesine de katkıda bulunmuştur (Y. Liu ve diğerleri, 2024; Yu, Liu, Nemati ve Yin, 2021).

Özellikle son yıllardaki Covid-19 pandemisi ile yapay zekânın sağlık alanındaki etkisi ve pekiştirmeli öğrenmenin (Reinforcement Learning) yapay zekâ ve makine öğrenimi alanlarında son yıllarda büyük ilerlemeler kaydetmesi ile pekiştirmeli öğrenmenin sağlık alanında karmaşık problemlere çözümler sunan güçlü bir yöntem olarak öne çıkmasını sağlamıştır (Atta Ur Rahman, Bibi Saqia, Yousef S. Alsenani ve Inam Ullah, 2024; Karadeniz ve Çağlar, 2023; Y. Liu ve diğerleri, 2024). Pekiştirmeli öğrenme, çevre ile etkileşim yoluyla öğrenme kabiliyeti sayesinde özellikle kişiselleştirilmiş tedavi planlaması,

¹ Doktora Öğrencisi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Enformatik Bölümü, muhammet.karadeniz.2019@ogr.iu.edu.tr, ORCID: 0000-0003-2819-0435.

dinamik karar destek sistemleri ve süreç iyileştirme gibi kritik alanlarda büyük bir potansiyele sahiptir (Y. Liu ve diğerleri, 2024; Yu ve diğerleri, 2021). Elektronik sağlık kayıtlarının ve biyomedikal dilin standardizasyonu, pekiştirmeli öğrenmenin sağlık uygulamalarına entegrasyonunu hızlandırmış ve doğal dil işleme (Natural Language Processing) gibi tekniklerin etkin kullanımını da beraberinde getirmiştir (Y. Liu ve diğerleri, 2024; Oh, Park, Lee, Kang ve Mo, 2022).

Aynı zamanda, pekiştirmeli öğrenmenin çevre ile doğrudan etkileşim kurma zorunluluğundan kaynaklanan maliyet ve riskler, çevrimdışı pekiştirmeli öğrenme gibi yeni yaklaşımların geliştirilmesine katkı sağlamıştır (Levine, Kumar, Tucker ve Fu, 2020; Prudencio, Maximo ve Colombini, 2024).

2. PEKİŞTİRMELİ ÖĞRENME

Pekiştirmeli öğrenme, bir ajan ile çevresi arasındaki etkileşimlere dayanarak ödülleri maksimize etmeyi amaçlayan bir makine öğrenmesi yöntemidir. Genellikle Markov Karar Süreçleri (Markov Decision Process) çerçevesinde modellenmektedir. Ajan (Agent), çevre (Environment), durum (State), eylem (Action) ve ödül (Reward) gibi temel bileşenleri bulunmaktadır. Ajan (Agent), çevresinden aldığı geri bildirimlerle optimal politikalar öğrenerek gelecekteki kararlarını bu doğrultuda şekillendirmektedir (Alpaydın, 2010; Gürsakal, 2018; Sutton ve Barto, 2018).

Pekiştirmeli öğrenme algoritmaları, temelde model tabanlı ve modelsiz yaklaşımlar olmak üzere ikiye ayrılmaktadır. Model tabanlı yaklaşımlar çevrenin dinamiklerini öğrenmeye çalışırken, modelsiz yaklaşımlar doğrudan optimal politikayı öğrenmeye odaklanmaktadır (Sutton ve Barto, 2018). Ayrıca, geleneksel pekiştirmeli öğrenme yöntemleri ile derin öğrenme tekniklerini birleştiren Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning), özellikle yüksek boyutlu verilerde etkili

çözümler sunmaktadır (Le, Rathour, Yamazaki, Luu ve Savvides, 2022; Zhou, Le, Luu, V Nguyen ve Ayache, 2021).

3. PEKİŞTİRMELİ ÖĞRENMENİN SAĞLIK ALANINDAKİ UYGULAMALARI

Pekiştirmeli öğrenme, sağlık alanında dinamik tedavi planlamalarından kronik hastalık yönetimine kadar geniş bir yelpazede etkili çözümler sunmaktadır (A A Abdellatif, Mhaisen, Mohamed, Erbad ve Guizani, 2023; Shakya, Pillai ve Chakrabarty, 2023). Örneğin, diyabet gibi kronik hastalıkların uzun vadeli yönetiminde kan şekeri kontrolü gibi karmaşık süreçler, pekiştirmeli öğrenme algoritmalarıyla optimize edilebilmektedir (Coronato, Naeem, De Pietro ve Paragliola, 2020; Tejedor, Woldaregay ve Godtliebsen, 2020). Yoğun bakım ünitelerinde (Intensive Care Unit) kullanılan pekiştirmeli öğrenme tabanlı sistemler, hasta sonuçlarını iyileştirmek ve kritik karar destek süreçlerini güçlendirmek için umut vadeden bir teknoloji olarak öne çıkmaktadır (S. Liu ve diğerleri, 2020). Sepsis yönetimi gibi alanlarda pekiştirmeli öğrenme modelleri, hastaların dinamik durumlarını izleyerek kişiselleştirilmiş tedavi planları oluşturmak için etkili bir yöntem sunmaktadır (Al-Hamadani, Fadhel, Alzubaidi ve Harangi, 2024; Smith, Khojandi ve Vasudevan, 2023).

Pekiştirmeli öğrenmenin; kişiselleştirilmiş tedavi planlarının oluşturulması, kemoterapi ve radyoterapi gibi alanlarda tedavi dozlarının optimize edilmesi gibi kritik uygulama alanları da bulunmaktadır (Atta Ur Rahman ve diğerleri, 2024; den Hengst, Grua, el Hassouni ve Hoogendoorn, 2020; Eckardt, Wendt, Bornhäuser ve Middeke, 2021). Diyabet yönetiminde bağlamsal bandit modelleri (Contextual Multi-armed Bandit), kişisel hasta verilerini dikkate alarak özelleştirilmiş tedavi önerileri geliştirmekte kullanılmaktadır (Oh ve diğerleri, 2022). Ayrıca, pekiştirmeli öğrenme algoritmalarının çevresel geri bildirim-

lerden öğrenme yeteneği, özellikle gerçek zamanlı ve kişiselleştirilmiş çözümler sunmasında önemli bir rol oynamaktadır (Atta Ur Rahman ve diğerleri, 2024).

Medikal görüntüleme alanında pekiştirmeli öğrenme; anomali tespiti, tümör lokalizasyonu ve organ segmentasyonu gibi karmaşık görevlerde başarıyla uygulanmaktadır. Özellikle medikal görüntüleme gibi alanlarda, bu teknikler ajanın görsel girdilerden anlamlı temsiller öğrenmesini sağlamakta ve tanı süreçlerini iyileştirmektedir. Bu teknikler, özellikle robotik destekli cerrahi gibi ileri uygulamalarda, gerçek zamanlı karar alma süreçlerini destekleyerek sağlık hizmetlerinin doğruluğunu ve etkinliğini artırmaktadır (Le ve diğerleri, 2022; Zhou ve diğerleri, 2021). Bunun yanında, doğal dil işleme tabanlı uygulamalar pekiştirmeli öğrenmenin sağlık hizmetlerindeki kullanımını çeşitlendirmektedir. Elektronik sağlık kayıtlarından bilgi çıkarımı, makine çevirisi, metin özetleme ve diyalog sistemleri gibi doğal dil işleme tabanlı uygulamalar, hasta ve doktor arasındaki iletişimi güçlendirerek daha kişiselleştirilmiş sağlık hizmetleri sunulmasını sağlamaktadır. Örneğin; tıbbi diyalog sistemleri ile hasta şikayetlerini analiz ederek önerilerde bulunulabilir ve böylelikle tedavi planları optimize edilebilir (Y. Liu ve diğerleri, 2024; Zhou ve diğerleri, 2021).

4. PEKİŞTİRMELİ ÖĞRENMENİN AVANTAJLARI VE SAĞLIK ALANINDAKİ GENEL SINIRLAMALAR

Pekiştirmeli öğrenme yöntemi, sağlık alanında karmaşık ve dinamik süreçleri yönetme yeteneğiyle öne çıkmaktadır. Bu yöntem, çevresel geri bildirimlerden öğrenme kabiliyeti sayesinde kişiselleştirilmiş tedavi planlarının oluşturulmasından, klinik süreçlerin optimize edilmesine kadar geniş bir yelpazede etkili çözümler sunmaktadır. Özellikle çevrimdışı pekiştirmeli öğrenme yöntemleri, retrospektif verilerle çalışarak riskli çevri-

miçi deneyimlerin önüne geçmekte ve güvenilir sonuçlar sunmaktadır. Böylelikle, pekiştirmeli öğrenmenin sağlık gibi hassas alanlarda da diğer makine öğrenmesi modelleri gibi etkin bir şekilde uygulanması mümkün hale gelmektedir (Atta Ur Rahman ve diğerleri, 2024; Levine ve diğerleri, 2020; Prudencio ve diğerleri, 2024). Fakat; pekiştirmeli öğrenme modellerinin diğer çoğu makine öğrenmesi modellerine kıyasla daha yüksek bellek ve hesaplama maliyetlerine sahip olması geniş ölçekli uygulamaları sınırlandıran önemli bir faktör olarak öne çıkmaktadır (Ladosz, Weng, Kim ve Oh, 2022; Oh ve diğerleri, 2022).

Etik ve yasal kaygılar ise diğer makine öğrenmesi yöntemleri gibi pekiştirmeli öğrenme yönteminin de sağlık alanında benimsenmesi için önemli bir engel teşkil etmektedir. Bu bağlamda, algoritmaların şeffaflık eksikliği, kullanıcı güvenliğini azaltabilmekte ve sağlık uzmanlarının karar verme süreçlerine entegrasyonunu zorlaştırabilmektedir (Atta Ur Rahman ve diğerleri, 2024; Smith ve diğerleri, 2023; Vishwanath, Dennis ve Slavkovik, 2024). Özellikle; açıklanabilir yapay zekâ (Explainable Artificial Intelligence) teknikleri, pekiştirmeli öğrenme modellerinin daha şeffaf ve güvenilir hale getirilmesi için potansiyel bir çözüm sunmaktadır. Diğer bir önemli husus ise; ödül fonksiyonlarının dikkatlice tasarlanması ve etik değerlendirmelerin yapılmasının, sağlık uygulamalarında pekiştirmeli öğrenmenin başarılı bir şekilde entegrasyonunu sağlamak için kritik bir öneme sahip olmasıdır (Milani, Topin, Veloso ve Fang, 2024; Vishwanath ve diğerleri, 2024).

Bunlara ilaveten; sağlık alanındaki verilerin kalitesi, diğer makine öğrenmesi modelleri gibi pekiştirmeli öğrenme modellerinin de başarısını doğrudan etkileyen kritik bir faktördür. Elektronik sağlık kayıtları ve diğer tıbbi veri setleri; eksik, dengesiz ve önyargılı olabildiği için bazı demografik grupların yeterince temsil edilmemesi nedeniyle yanıltıcı tahminlere ve yanlış politikaların öğrenilmesine yol açabilmektedir (Al-Hamadani ve

diğerleri, 2024; Atta Ur Rahman ve diğerleri, 2024; Shakya ve diğerleri, 2023; Zhou ve diğerleri, 2021). Düşük kaliteli veya taraflı veri setleri; pekiştirmeli öğrenme algoritmalarının adalet, doğruluk ve güvenilirlik gibi temel özelliklerini olumsuz etkilerken, dengesizlik model eğitim verilerine yansiyarak belirli grupların dışlanmasına sebep olabilmektedir (Atta Ur Rahman ve diğerleri, 2024; Eckardt ve diğerleri, 2021; S. Liu ve diğerleri, 2020; Smith ve diğerleri, 2023; Yu ve diğerleri, 2021). Heterojen yapıya sahip ve eksik veri kümeleri, algoritmaların performansını sınırlandırarak hasta güvenliği açısından risk oluşturmaktadır (Atta Ur Rahman ve diğerleri, 2024; Oh ve diğerleri, 2022; Smith ve diğerleri, 2023). Bu problemlerin üstesinden gelmek için; geniş ve dengeli veri setlerinin oluşturulması, eksik veri tamamlama, alt grup analizi, veri temizleme ve normalizasyon gibi tekniklerin uygulanması gerekmektedir (Atta Ur Rahman ve diğerleri, 2024; Levine ve diğerleri, 2020; Smith ve diğerleri, 2023). Ayrıca; veri artırma yöntemleri, kenar bilişim (Edge Computing) ve bulut teknolojilerinin etkin bir şekilde kullanılmasıyla verilerin eksikliklerinden kaynaklanan doğruluk kayıplarının önüne geçilebilecektir (Alaa Awad Abdellatif ve diğerleri, 2021; Coronato ve diğerleri, 2020).

5. SCOPUS VERİLERİ İLE VOSVIEWER ANALİZİ


VOSviewer gibi metin madenciliği temelli araçlar, yazarlar, yazarlar ve anahtar kelimeler arasındaki ilişkileri analiz ederek konu haritaları oluşturmak, literatürdeki temel alanları belirlemek ve araştırma konusu eğilimlerini tespit etmek için kullanılmaktadır (Artsın, 2020). Bu çalışmada da, pekiştirmeli öğrenmenin sağlık alanındaki kullanımını kapsamlı bir şekilde incelemek amacıyla VOSviewer yazılımı kullanılmıştır. Analizler, 24 Kasım 2024 tarihinde Scopus veri tabanından elde edilen verilere dayandırılmıştır. Veriler, yalnızca "reinforcement learning" ve "health" anahtar kelimelerini içeren makaleleri kapsayacak şekilde filtrelenmiştir. Scopus sorgusu şu şekilde yapıl-

mıştır: “(TITLE-ABS-KEY ("reinforcement learning") AND TITLE-ABS-KEY (health)) AND (LIMIT-TO (DOCTYPE, "ar"))”.

Elde edilen veriler kullanılarak; Scopus’un analiz araçları ve VOSviewer yazılımıyla görselleştirme yapılmıştır (Scopus, 2024; VOSviewer, 2024). Bu görseller, pekiştirmeli öğrenmenin sağlık alanındaki kullanımına dair anahtar kelimeler ve araştırma eğilimleri hakkında daha fazla fikir sunmaktadır.

5.1. Yıllara Göre Makale Sayısı

Şekil 1, Scopus veri tabanından elde edilen verilere dayalı olarak pekiştirmeli öğrenme ve sağlık alanındaki makalelerin yıllara göre dağılımını göstermektedir. X eksenı yılları, Y eksenı ise makale sayılarını temsil etmektedir.




Şekil 1: Yıllara göre makale sayısı

Şekil 1’e göre; 2018 yılından itibaren sağlık alanında pekiştirmeli öğrenme üzerine yapılan çalışmaların belirgin bir ivme kazandığı gözlemlenmektedir. Özellikle 2020 sonrası dönemde, COVID-19 pandemisinin dijital sağlık dönüşümüne etkisi ve yapay zekâ uygulamalarının hızla benimsenmesinin bu

yarattığını ve farklı araştırma alanlarına katkılar sunduğunu göstermektedir.

5.3. Ağ Haritası

Şekil 3, "Reinforcement Learning" ve "Health" anahtar kelimeleri arasındaki ilişkileri görselleştiren bir ağ haritası sunmaktadır. Bu harita, anahtar kelimeler arasındaki bağlantıların gücünü ve pekiştirmeli öğrenmenin odaklandığı araştırma alanlarını görsel olarak temsil etmektedir.




Şekil 3: Ağ Haritası

Şekil 3'e göre; haritanın merkezi, "Reinforcement Learning", "Deep Reinforcement Learning", "Healthcare" ve "Machine Learning" gibi temel terimlerle çevrilidir. Bu durum, pekiştirmeli öğrenmenin sağlık hizmetlerinde dinamik karar destek sistemleri, operasyonel verimlilik ve kişiselleştirilmiş tedavi planlamaları gibi uygulamalarda kritik bir rol üstlendiğini göstermektedir. Ayrıca, "Q-Learning" ve "Resource Allocation" gibi terimlerin güçlü bağlantılar oluşturması, pekiştirmeli öğ-

renmenin sağlık hizmetlerinde karar destek süreçlerini nasıl optimize edebileceği konusunda önemli bir işaret sunmaktadır.

5.4. Zaman Tabanlı Dağılım

Şekil 4, zaman tabanlı anahtar kelime dağılımlarını ve pekiştirmeli öğrenmenin sağlık alanındaki eğilimlerini göstermektedir. Şekil 4'teki renk tonları, anahtar kelimelerin yıllar içerisindeki evrimini ve dönemsel yoğunluklarını görselleştirmektedir.



Şekil 4: Zaman Tabanlı Dağılım

Şekil 4'e göre; 2021 yılı sonrası dönemde "Covid-19", "Critical Care" ve "Dynamic Treatment Regimes" gibi temalar ön plana çıkmıştır. Bu durum, COVID-19 pandemisinin, sağlık alanında pekiştirmeli öğrenme yöntemine olan akademik ve pratik ilgiyi artırarak dijital dönüşüm süreçlerini hızlandırdığına işaret etmektedir. Ayrıca, pekiştirmeli öğrenmenin sağlıkta dijital dönüşümü hızlandırarak kişiselleştirilmiş çözümler geliştirilmesine katkıda bulunduğu değerlendirilmektedir.

6. SAĞLIK ALANINDA GELECEĞİ: PEKİŞTİRMELİ ÖĞRENME PERSPEKTİFİ

Pekiştirmeli öğrenme, sağlık alanındaki geleceği açısından yenilikçi çözümler sunma potansiyeline sahiptir. Mevcut analizlerden de anlaşılacağı üzere, pekiştirmeli öğrenmenin katkıları yalnızca sorun çözmeye yönelik değil; aynı zamanda akıllı sağlık sistemlerinin daha verimli ve kişiselleştirilmiş hale gelmesini destekleyecek şekilde genişlemektedir. Özellikle, pekiştirmeli öğrenmenin; hastalık yönetimi, klinik karar destek sistemleri, kişiselleştirilmiş tedavi protokolleri ("precision medicine") ve kritik bakım ("critical care") gibi alanlarda önemli bir potansiyele sahip olduğu değerlendirilmektedir. Bunun yanı sıra, "internet of things (IoT)", "digital twin" ve "federated learning" gibi yenilikçi teknolojilerle entegre edilmesi, sağlık hizmetlerinde kapsamlı dönüşümlerin önünü açabilir.

Sağlık alanında pekiştirmeli öğrenmenin geleceği; etik ve yasal standartların geliştirilmesi, güvenilir algoritmaların tasarımı ve veri güvenliği gibi konularındaki gelişmelere bağlıdır. Algoritmaların adil sonuçlar üretmesi ve açıklanabilir yapay zekâ (XAI) tekniklerinin uygulanması, bu teknolojinin geniş çapta benimsenmesi için kritik öneme sahiptir (den Hengst ve diğerleri, 2020; Le ve diğerleri, 2022; Moussaoui, Akkad ve Benslimane, 2023; Prudencio ve diğerleri, 2024). Özellikle; farklı hasta gruplarını kapsayan daha büyük ve çeşitli veri kümeleriyle çalışabilecek pekiştirmeli öğrenme algoritmalarının geliştirilmesi, sağlık hizmetlerinde kişiselleştirilmiş çözümler sunma potansiyelini artırabilir (Oh ve diğerleri, 2022; Sivamayıl ve diğerleri, 2023).

Çevrimdışı pekiştirmeli öğrenme teknikleri, belirsizlik tahmini ve dinamik politika düzenleme gibi yaklaşımlar, sağlık sistemlerinde etik kaygıları azaltmaya ve daha güvenilir modeller geliştirmeye olanak sağlayabilir (Levine ve diğerleri, 2020;

Prudencio ve diğerleri, 2024). Bu tür gelişmeler; pekiştirmeli öğrenmenin sağlık hizmetlerinde yalnızca kişiselleştirilmiş tedavi planlamalarını değil, aynı zamanda karar destek sistemlerini güçlendirme ve operasyonel verimliliği artırma yönünde kullanımlarını da genişletebilir. Bağlamsal bandit modelleri gibi esnek algoritmaların geliştirilmesi, farklı hasta grupları için daha spesifik tıbbi çözümler sunmayı mümkün kılabilir (Oh ve diğerleri, 2022; Tejedor ve diğerleri, 2020).

Pekiştirmeli öğrenmenin akıllı sağlık sistemlerindeki geleceği, kişiselleştirilmiş tedavi ve dinamik hasta yönetimi gibi alanlarda daha geniş uygulama fırsatları sunabilir. Özellikle diyabet yönetimi gibi uzun vadeli tedavi süreçlerinde pekiştirmeli öğrenmenin etkinliği, sağlık sistemlerinde daha yaygın şekilde benimsenmesine katkıda bulunabilir (A A Abdellatif ve diğerleri, 2023; Alaa Awad Abdellatif ve diğerleri, 2021; Tejedor ve diğerleri, 2020). Bununla birlikte; pekiştirmeli öğrenmenin gerçek dünyadaki etkisini doğrulamak adına prospektif klinik çalışmaların gerçekleştirilmesi, bu teknolojinin pratikteki uygulanabilirliği için vazgeçilmez bir ihtiyaçtır (S. Liu ve diğerleri, 2020).

7. SONUÇ

Pekiştirmeli öğrenme, sağlık alanında; kişiselleştirilmiş tedavi, klinik karar destek sistemleri, hasta yönetimi ve operasyonel süreçlerin optimize edilmesi gibi kritik alanlarda güçlü bir potansiyele sahiptir. Bu kitap bölümü kapsamında yapılan analizler, pekiştirmeli öğrenmenin sağlık alanında dinamik ve yenilikçi çözümler sunduğunu göstermektedir. Özellikle, veri analitiği ve modelleme tekniklerinin gelişimiyle pekiştirmeli öğrenmenin karmaşık tedavi süreçlerinde etkili bir araç haline gelmesi öngörülmektedir.

Özellikle çevrimdışı pekiştirmeli öğrenme tekniklerinin retrospektif verilerle çalışabilmesi, gerçek zamanlı deneyimlerden kaynaklanabilecek riskleri en aza indirme potansiyeli taşımaktadır. Bu durum, sepsis yönetimi ve dinamik tedavi rejimleri gibi karmaşık klinik karar süreçlerinde pekiştirmeli öğrenmeyi güvenilir bir araç olarak öne çıkarmaktadır. IoT cihazlarından elde edilen veriler ve dijital ikiz (Digital Twin) teknolojisi, kişiselleştirilmiş tedavi planlarının daha etkin bir şekilde uygulanmasını sağlayarak bu alandaki çözümleri daha ileriye taşıyabilir.

Ancak, pekiştirmeli öğrenmenin sağlık alanında etkili bir şekilde uygulanabilmesi için çözülmesi gereken bazı önemli sorunlar bulunmaktadır. Öncelikle, veri güvenliği ve gizlilik sorunlarının "Federated Learning" gibi tekniklerle desteklenerek aşılması gerekmektedir. Bunun yanı sıra; eksik, önyargılı veya dengesiz veri kümelerinin modellenmesi, adil ve genellenebilir sonuçların elde edilmesi için veri kalitesinin ve çeşitliliğinin artırılması büyük önem taşımaktadır. Ayrıca, klinik uygulamalarda daha yüksek güven ve kabul sağlanabilmesi için açıklanabilir yapay zekâ tekniklerinin pekiştirmeli öğrenme modellerine entegre edilmesi gereklidir. Etik ve yasal standartların oluşturulması ve uygulanması da bu makine öğrenmesi yönteminin ve tekniklerinin geniş çapta benimsenmesi açısından kritik bir ge-

reklilik olarak öne çıkmaktadır. Son olarak, pekiştirmeli öğrenmenin sağlık alanındaki uygulama potansiyelini artırmak için tıp ve bilgisayar bilimi gibi disiplinler arasında güçlü bir iş birliği geliştirilmelidir.

Pekiştirmeli öğrenmenin sağlık hizmetlerinde sürdürülebilir bir dönüşüm yaratabilmesi için, sağlık verilerinin paylaşımını destekleyen güvenli ve etik bir altyapının oluşturulması gereklidir. Ayrıca, daha geniş veri kümeleriyle çalışabilecek, farklı hasta gruplarına uygun çözümler üretebilecek algoritmaların geliştirilmesi kritik bir öneme sahiptir. Teknolojik yeniliklerin etik kaygılar gözetilerek uygulamaya geçirilmesi ve toplum yararını ön planda tutacak bir yaklaşımla hayata geçirilmesi, bu alandaki ilerlemeleri hızlandırabilir.

Sonuç olarak, pekiştirmeli öğrenmenin sağlık alanındaki etkisinin daha geniş bir alana yayılabilmesi için hem teknolojik hem de etik açıdan dengeli ve sürdürülebilir yaklaşımlar benimsenmelidir. Pekiştirmeli öğrenmenin; kişiselleştirilmiş tedavi, medikal görüntüleme, yoğun bakım yönetimi ve kronik hastalık tedavisi gibi alanlardaki potansiyelini tam anlamıyla gerçekleştirebilmesi için disiplinler arası iş birliği ve yenilikçi çözümlerle desteklenmelidir.

KAYNAKÇA

- Abdellatif, A A, Mhaisen, N., Mohamed, A., Erbad, A. ve Guizani, M. (2023). Reinforcement Learning for Intelligent Healthcare Systems: A Review of Challenges, Applications, and Open Research Issues. *IEEE Internet of Things Journal*, 10(24), 21982-22007. doi:10.1109/IIOT.2023.3288050
- Abdellatif, Alaa Awad, Mhaisen, N., Chkurbene, Z., Mohamed, A., Erbad, A. M. ve Guizani, M. (2021). Reinforcement Learning for Intelligent Healthcare Systems: A Comprehensive Survey. *ArXiv*, abs/2108.04087. <https://api.semanticscholar.org/CorpusID:236956837> adresinden erişildi.
- Al-Hamadani, M. N. A., Fadhel, M. A., Alzubaidi, L. ve Harangi, B. (2024). Reinforcement Learning Algorithms and Applications in Healthcare and Robotics: A Comprehensive and Systematic Review. *Sensors*, 24(8). doi:10.3390/s24082461
- Alpaydın, E. (2010). *Introduction to machine learning* (2. bs.). MIT Press. https://doi.org/10.1007/978-1-62703-748-8_7.
- Artsın, M. (2020). BİR METİN MADENCİLİĞİ UYGULAMASI: VOSVIEWER. *Eskişehir Teknik Üniversitesi Bilim ve Teknoloji Dergisi B - Teorik Bilimler*, 8(2), 344-354. <https://dergipark.org.tr/tr/pub/estubtdb/issue/56628/644637> adresinden erişildi.

- Atta Ur Rahman, Bibi Saqia, Yousef S. Alsenani ve Inam Ullah. (2024). Data Quality, Bias, and Strategic Challenges in Reinforcement Learning for Healthcare: A Survey. *International Journal of Data Informatics and Intelligent Computing*, 3(3), 24-42. doi:10.59461/ijdiic.v3i3.128
- Coronato, A., Naeem, M., De Pietro, G. ve Paragliola, G. (2020). Reinforcement learning for intelligent healthcare applications: A survey. *Artificial Intelligence in Medicine*, 109, 101964. doi:https://doi.org/10.1016/j.artmed.2020.101964
- Den Hengst, F., Grua, E. M., el Hassouni, A. ve Hoogendoorn, M. (2020). Reinforcement learning for personalization: A systematic literature review. *Data Science*, 3, 107-147. doi:10.3233/DS-200028
- Eckardt, J.-N., Wendt, K., Bornhäuser, M. ve Middeke, J. M. (2021). Reinforcement Learning for Precision Oncology. *Cancers*, 13(18). doi:10.3390/cancers13184624
- Gürsakal, N. (2018). Makine öğrenmesi. *Baskı, Bursa: Dora Basım Yayın Dağıtım Ltd. Şti.*
- Karadeniz, M. ve Çağlar, C. (2023). THE IMPORTANCE OF ARTIFICIAL INTELLIGENCE-BASED DATA ANALYSIS IN THE CORONAVIRUS PANDEMIC PROCESS. *PANDEMIC AND THE CRITICAL ROLE OF KNOWLEDGE MANAGEMENT* içinde (ss. 203-217). IU Press. doi:10.26650/B/ET07.2023.004.11
- Ladosz, P., Weng, L., Kim, M. ve Oh, H. (2022). Exploration in deep reinforcement learning: A survey. *Information Fusion*, 85, 1-22. doi:https://doi.org/10.1016/j.inffus.2022.03.003

- Le, N., Rathour, V. S., Yamazaki, K., Luu, K. ve Savvides, M. (2022). Deep reinforcement learning in computer vision: a comprehensive survey. *Artificial Intelligence Review*, 55(4), 2733-2819. doi:10.1007/s10462-021-10061-9
- Levine, S., Kumar, A., Tucker, G. ve Fu, J. (2020). Offline Reinforcement Learning: Tutorial, Review, and Perspectives on Open Problems. *ArXiv*, abs/2005.01643. <https://api.semanticscholar.org/CorpusID:218486979> adresinden erişildi.
- Liu, S., See, K. C., Ngiam, K. Y., Celi, L. A., Sun, X. ve Feng, M. (2020). Reinforcement Learning for Clinical Decision Support in Critical Care: Comprehensive Review. *J Med Internet Res*, 22(7), e18477. doi:10.2196/18477
- Liu, Y., Wang, H., Zhou, H., Li, M., Hou, Y., Zhou, S., ... Zhang, R. (2024). A review of reinforcement learning for natural language processing and applications in healthcare. *Journal of the American Medical Informatics Association*, 31(10), 2379-2393. doi:10.1093/jamia/ocae215
- Milani, S., Topin, N., Veloso, M. ve Fang, F. (2024). Explainable Reinforcement Learning: A Survey and Comparative Review. *ACM Comput. Surv.*, 56(7). doi:10.1145/3616864
- Moussaoui, H., Akkad, N. El ve Benslimane, M. (2023). Reinforcement Learning: A review. *International Journal of Computing and Digital Systems*. <https://api.semanticscholar.org/CorpusID:259071067> adresinden erişildi.

- Oh, S. H., Park, J., Lee, S. J., Kang, S. ve Mo, J. (2022). Reinforcement learning-based expanded personalized diabetes treatment recommendation using South Korean electronic health records. *Expert Systems with Applications*, 206, 117932. doi:<https://doi.org/10.1016/j.eswa.2022.117932>
- Prudencio, R. F., Maximo, M. R. O. A. ve Colombini, E. L. (2024). A Survey on Offline Reinforcement Learning: Taxonomy, Review, and Open Problems. *IEEE Transactions on Neural Networks and Learning Systems*, 35(8), 10237-10257. doi:10.1109/TNNLS.2023.3250269
- Scopus. (2024). Scopus. Elsevier B. V. 24 Kasım 2024 tarihinde <https://www.scopus.com/search/form.uri?display=basic&zone=header&origin=searchbasic#basic> adresinden erişildi.
- Shakya, A. K., Pillai, G. ve Chakrabarty, S. (2023). Reinforcement learning algorithms: A brief survey. *Expert Systems with Applications*, 231, 120495. doi:<https://doi.org/10.1016/j.eswa.2023.120495>
- Sivamayil, K., Rajasekar, E., Aljafari, B., Nikolovski, S., Vairavasundaram, S. ve Vairavasundaram, I. (2023). A Systematic Study on Reinforcement Learning Based Applications. *Energies*, 16(3). doi:10.3390/en16031512
- Smith, B., Khojandi, A. ve Vasudevan, R. (2023). Bias in Reinforcement Learning: A Review in Healthcare Applications. *ACM Comput. Surv.*, 56(2). doi:10.1145/3609502
- Sutton, R. S. ve Barto, A. G. (2018). *Reinforcement learning: an introduction* (2. bs.). The MIT Press, Cambridge.

- Tejedor, M., Woldaregay, A. Z. ve Godtliebsen, F. (2020). Reinforcement learning application in diabetes blood glucose control: A systematic review. *Artificial Intelligence in Medicine*, 104, 101836. doi:<https://doi.org/10.1016/j.artmed.2020.101836>
- Vishwanath, A., Dennis, L. A. ve Slavkovik, M. (2024). Reinforcement Learning and Machine ethics:a systematic review. *ArXiv*, abs/2407.02425. <https://api.semanticscholar.org/CorpusID:270878083> adresinden erişildi.
- VOSviewer. (2024). VOSviewer Visualizing Scientific Landscapes. *Lieden University*. 24 Kasım 2024 tarihinde <https://www.vosviewer.com/> adresinden erişildi.
- Yu, C., Liu, J., Nemati, S. ve Yin, G. (2021). Reinforcement Learning in Healthcare: A Survey. *ACM Comput. Surv.*, 55(1). doi:10.1145/3477600
- Zhou, S. K., Le, H. N., Luu, K., V Nguyen, H. ve Ayache, N. (2021). Deep reinforcement learning in medical imaging: A literature review. *Medical Image Analysis*, 73, 102193. doi:<https://doi.org/10.1016/j.media.2021.102193>

ARTIFICIAL INTELLIGENCE SUPPORTED OBJECT DETECTION IN UAVS

Mehmet Serhat CEYLAN¹

Gül Fatma TÜRKER²

1. INTRODUCTION

1.1. The Importance of Drones in Modern Applications

Drone technology has revolutionized the modern world with its versatile use cases. In disaster management, drones are used in search and rescue missions with real-time imaging and thermal sensor technologies to locate disaster victims and analyze damage. In emergencies such as forest fires, they are used to identify fire hotspots and optimize strategy (Hassanalian & Abdelkefi, 2017).

In the agricultural sector, drones enable precision farming practices such as monitoring crop health, early detection of diseases and spraying or irrigation. Equipped with multispectral sensors, drones facilitate the mapping of farmland, increasing productivity. They also save time and resources on tasks such as planting and seeding (Puri et al., 2017).

In construction and infrastructure management, drones perform safe inspections in challenging areas. They contribute to project planning by providing detailed maps of tall structures, bridges or construction sites. Equipped with technologies such

¹ Doctoral Student, Suleyman Demirel University, Graduate School of Natural and Applied Sciences, Department of Computer Engineering, d2440138001@ogr.sdu.edu.tr, ORCID: 0000-0002-9523-3047.

² Assistant Professor, Suleyman Demirel University, Faculty of Engineering, Department of Computer Engineering, gulturker@sdu.edu.tr, ORCID: 0000-0001-5714-5102.

as 3D modeling and LiDAR, drones speed up construction processes and reduce the margin for error (Li & Liu, 2019).

In the logistics industry, drones transform delivery services, saving time. They offer an effective solution, especially in remote or high-traffic areas. In the e-commerce sector, fast delivery of orders is an advantage that increases customer satisfaction (Kellermann et al., 2020).

In environmental monitoring and geological surveys, drones offer precise data collection. They play critical roles in protecting forested areas, monitoring water resources or analyzing pollution. They also enable safe surveys in hazardous areas such as volcanic zones (Giordan et al., 2020).

In the future, drones are expected to be widely used in many areas, from air taxis to more advanced methods of environmental protection. It is clear that this technology has become an indispensable tool in the modern world with the solutions it offers to industrial and social needs.

1.2. The Role of Artificial Intelligence in the Development of Drone Capabilities

Artificial Intelligence (AI) is expanding the boundaries of drone technology, enabling more advanced, efficient and autonomous solutions across many industries. The integration of AI into drone systems enables these vehicles to not only collect data, but also analyze it and make decisions. These features increase operational efficiency in both businesses and public services (Caballero-Martin et al., 2024).

In agriculture in particular, AI-based drones analyze plant health with multispectral sensors, detecting pests and diseases at an early stage and offering more effective ways of intervention. Thanks to intelligent algorithms, these drones can make

recommendations to increase soil fertility, thus promoting sustainability in agricultural production (Javaid et al., 2023).

In security and public services, AI is making drones an important tool for real-time incident response. For example, drones used in emergencies can quickly identify accident victims thanks to AI, facilitating the work of rescue teams by providing accurate and instant information in disaster areas. In addition, AI-supported image processing enables faster and more effective inspection of critical infrastructures and detection of security vulnerabilities (Papayan et al., 2024).

AI's contributions to drone systems have also revolutionized the logistics and transportation industry. Drones equipped with AI save energy by optimizing routes and speed up delivery processes, especially in busy cities. For example, autonomous drones can analyze complex traffic patterns and choose the shortest and safest routes (Soori et al., 2023).

In the future, with the integration of AI, drones are expected to gain more autonomy and improve their learning capabilities. These technologies open the door to innovative applications in many fields, from environmental protection to urban planning. AI-powered drones will not only improve existing applications, but also enable the discovery of new areas of use.

2. METHOD

2.1. Evolution of Drone Technology

Drone technology has undergone a rapid and dramatic evolution from the past to the present. The first unmanned aerial vehicles (UAVs) emerged in the late 19th century for military purposes. Target drones, especially during World War I, were used to attract enemy fire and for training purposes. In the 20th century, this technology became an important tool for military

reconnaissance, intelligence gathering and surveillance (Giones & Brem, 2017).

During the Cold War, the potential of drones increased even further. The United States used drones in reconnaissance and intelligence operations to gain strategic advantage over the Soviet Union. In the 1960s and 70s, during the Vietnam War, drones were used for tasks such as identifying ground targets and taking photographs. During this period, drones were made more durable and efficient, laying the foundation for their modern use (Asatryan & Kalpakian, 2021).

From the 1980s onwards, technological advances paved the way for drones to be used in civilian areas. Advances in GPS, camera and sensor technologies made drones effective tools in areas such as agriculture, construction and environmental monitoring. In the 2000s, drones reached a wider audience with commercial and recreational uses. Drone-based delivery initiatives by companies such as Amazon have shown that these vehicles can have a transformative role in the logistics industry (Nouacer et al., 2020).

Today, drone technology is supported by artificial intelligence, machine learning and IoT integration, enabling them to perform much more complex and autonomous tasks. Modern drones are being used in areas such as disaster response, infrastructure inspection, environmental monitoring and even film production (Magistretti & Dell’Era, 2019). These tools not only increase operational efficiency, but also offer opportunities to make human lives safer.

2.2. Overview of Object Detection in AI

Object detection is a fundamental application of AI and computer vision that involves identifying and classifying objects within an image or video. This process integrates multiple tasks such as image classification, localization and sample segmenta-

tion, enabling systems to recognize objects and determine their position within a scene (Dhillon & Verma, 2020).

Modern object detection methods utilize deep learning models, especially convolutional neural networks (CNNs), to achieve high levels of accuracy. Techniques such as YOLO (You Only Look Once), SSD (Single Shot MultiBox Detector) and R-CNN (Region-based CNN) have set the benchmark in this field. These models are trained on extensive datasets and use hierarchical feature extraction, enabling them to detect objects in real-time under various conditions such as occlusions, different scales and dynamic illumination (Kaur & Singh, 2023).

Object detection applications span numerous industries. In healthcare, it helps diagnose diseases from medical images, while in autonomous vehicles it is crucial for identifying pedestrians, traffic signs and obstacles. In the retail sector, it is used for inventory management and automated payment systems, while in security it enhances surveillance through anomaly detection and facial recognition (Kaur & Singh, 2022).

2.3. Recent Developments and Case Studies on Object Detection

In recent years, deep learning-based methods have made significant advances in drone object detection. In particular, algorithms such as CNN and YOLO offer great advantages in terms of both speed and accuracy (Zou et al., 2023). For example, in the agricultural sector, drones have been successfully applied to assess plant health and automate pest detection (Ariza-Sentís et al., 2024). In cities, drones are used to monitor traffic flow and detect accidents (Ghahremannezhad et al., 2023). In the security field, drones are effective in tasks such as border patrol and suspicious object tracking (Aslam & Curry, 2021). However, these technologies are being further developed when supported by larger data sets and powerful hardware systems.

2.4. Real-Time Object Detection Algorithms

Real-time object detection algorithms are essential to enable drones to identify and track objects in dynamic environments. The most widely used algorithms in this field include YOLO, SSD and Faster R-CNN (Lu et al., 2019). These models provide efficient solutions for detecting objects at high speeds, which is crucial for real-time applications in areas such as surveillance, agriculture and search and rescue missions. Each of these algorithms - YOLO, SSD and Faster R-CNN - has strengths and weaknesses, and which one to use depends largely on the specific requirements of the application, such as detection speed, accuracy and available computational resources. For UAVs, balancing these factors is crucial to ensure effective performance in real-world environments.

2.4.1. YOLO (You Only Look Once)




Figure 1. YOLO architecture

YOLO (Figure 1) is one of the most popular and efficient algorithms for real-time object detection. It works by framing object detection as a regression problem, where the task is to estimate bounding boxes and class probabilities directly from image pixels. This approach allows YOLO to process images all at once instead of scanning them region by region (Jiang et al., 2022). YOLO's biggest advantage is its speed; it can process

multiple objects in a single forward pass of the network and can reach frame rates of up to 45 frames per second in real-time applications (Diwan et al., 2023). However, YOLO may sacrifice some accuracy when detecting small or closely packed objects compared to other models.

2.4.2. SSD (Single Shot MultiBox Detector)




Figure 2. SSD architecture (Choi et al., 2021)

SSD (Figure 2) is another fast object detection model designed to perform well in real-time scenarios (Kumar & Srivastava, 2020). Like YOLO, SSD processes the entire image in a single pass, but takes a different approach by applying default bounding boxes at multiple feature map scales. This allows SSD to more effectively detect objects of various sizes, especially small objects that may be missed by models like YOLO (Kumar et al., 2020). SSD also uses a convolutional feature map to make predictions, providing a good balance between speed and accuracy. The algorithm is optimized for real-time use and achieves high frame rates while maintaining reasonable accuracy for a wide range of object detection tasks.

2.4.3. Faster R-CNN




Figure 3. CNN architecture (Balaji, 2020)

Faster R-CNN (Figure 3) represents a more complex but highly accurate approach to real-time object detection (Maity et al., 2021). Unlike YOLO and SSD, Faster R-CNN uses a two-step process. First, it generates region suggestions through a Region Proposal Network (RPN) and then classifies these regions into object categories using a Fast R-CNN detector. The two-step process allows Fast R-CNN to achieve high accuracy, especially in detecting smaller and more complex objects (Hmidani & Alaoui, 2022). However, it is generally slower than YOLO and SSD, which may make it less suitable for applications that require ultrafast detection. Despite this, Faster R-CNN is widely used in scenarios where precision takes precedence over speed, such as medical imaging or detailed security surveillance.

2.5. UAV Systems and Hardware Integration for Object Detection

In UAVs, advanced hardware systems are key to enhancing object detection. UAVs use a variety of sensors, including cameras, LiDAR, and radar, to gather detailed environmental data. This information is processed in real-time, enabling accu-

rate object detection and tracking, even in complex and dynamic environments (Hossain & Lee, 2019).

The successful integration of UAV systems relies on powerful on-board processing units that support AI-driven algorithms, particularly deep learning models like CNNs. These models analyze visual data to detect and classify objects with high accuracy. Given that UAVs are often deployed in fast-paced, real-time situations—such as search and rescue or surveillance—this hardware-software synergy ensures minimal delay in object detection, enhancing overall efficiency and effectiveness (Ahmed & Jenihhin, 2022).

UAVs for real-time object detection feature advanced communication systems to transmit data to ground stations or other UAVs, enabling collaboration in large-scale operations. Combining onboard and remote processing boosts efficiency and allows continuous accuracy improvement through machine learning feedback loops (Ahmed & Jenihhin, 2022).

The systems include stabilization and high-resolution imaging to reduce errors from drone movement and environmental factors. This enables reliable detection of small or concealed objects, improving UAV performance in harsh conditions. Advances in lightweight processors and compact sensors are making UAVs more capable of autonomously performing complex object detection tasks (Maltezos et al., 2021).

The integration of advanced hardware and AI is transforming UAVs into powerful tools for sectors like agriculture and defense, offering vital support in monitoring, surveillance, and disaster response missions.

2.6. Challenges in Object Detection for UAVs

Object detection in UAVs faces technical, environmental, and ethical challenges despite AI advancements. Dynamic environments and the need for real-time processing hinder performance, as UAVs' fast movement and limited processing power struggle with complex AI models. Energy and processing constraints necessitate algorithm optimization to balance accuracy and efficiency (Mittal et al., 2020).

Environmental factors further complicate object detection, with varying lighting, weather, and obstructions affecting performance. Low-resolution detection of small or distant objects reduces accuracy, while shadows, overlapping structures, and similar obstacles in urban areas add challenges. Additionally, limited or insufficiently diverse data hampers the generalizability of models across different scenarios (Yu et al., 2020).

Security and privacy concerns often result in regulatory restrictions, limiting the use of UAV technologies. Delays in real-time applications can hinder decision-making in critical missions like disaster response and military surveillance. Additionally, drones in hostile or harsh environments require robust algorithms to handle signal loss, interference, and extreme weather conditions effectively (Cazzato et al., 2020).

2.7. Pre-Trained Models and Transfer Learning for Drone Vision

Pre-trained models and transfer learning have become important in drone vision, especially for object detection tasks. Leveraging these techniques helps overcome challenges related to the limited computational power and data collection capabilities of UAVs (Walambe et al., 2021).

Pre-trained models are typically deep learning models trained on large datasets in computer vision tasks such as object

detection, classification and segmentation. By using these models, drones can immediately leverage prior knowledge and eliminate the need to start training from scratch, which is resource-intensive (Iman et al., 2023). For example, a model pre-trained on large, diverse image datasets such as ImageNet can detect a variety of objects in real-time without the need for large volumes of training data specific to a drone's environment.

Transfer learning takes this concept a step further by fine-tuning pre-trained models for specific tasks. In drone vision, transfer learning allows drones to apply learned features to tasks such as identifying specific objects such as vehicles or people in a new area, such as farmland, construction sites or surveillance areas (Kaur et al., 2021). For example, a model trained for general object detection can be fine-tuned with a smaller, domain-specific dataset collected by drones in specific operational environments.

One of the key benefits of using pre-trained models and transfer learning in drone technology is the significant reduction in the computational cost and time required to train models from scratch. This enables real-time object detection for UAVs where latency and processing power are critical. It also improves the accuracy of drone systems in various environmental conditions, making them more reliable in sectors such as agriculture, security and infrastructure inspection (Liu et al., 2023).

The ability of drones to leverage these techniques enables faster deployment and greater efficiency, improving the operational performance and scalability of drone-based systems in numerous applications.

2.8. Lightweight and Edge AI Models for Drones

Drone technology is increasingly being used in various fields such as agriculture, security, logistics and disaster management. However, the limited battery life, processing capacity and data connectivity requirements of these vehicles necessitate innovative solutions to make AI applications more efficient. In this context, lightweight and edge AI models stand out as effective methods to increase performance while ensuring energy efficiency in drone systems (McEnroe et al., 2022).

Lightweight AI models are optimized for devices with limited hardware capacity and can operate with high accuracy using less memory and processing power. These models are developed through optimization techniques such as parameter compression, quantization and information distillation (Hassanalian & Abdelkefi, 2017). For example, a compressed model can perform real-time image processing on a drone, enabling it to perform longer missions with lower energy consumption. In addition, edge AI technologies reduce reliance on cloud connectivity by performing calculations on-device. This reduces latency and increases data security (Aldossri et al., 2024). For example, a drone used in agriculture can locally analyze crop images, enabling pest detection and rapid response.

These technologies have the potential for wide application, particularly in areas such as security, agriculture, disaster management and logistics. Security drones can perform real-time facial recognition or suspicious movement analysis, while agricultural drones can monitor crop health and optimize spraying processes. In disaster management, they can play critical roles in damage assessment and search and rescue missions, while in logistics applications, they can reduce costs by optimizing routes (Yazid et al., 2021).

However, there are also some challenges in implementing these technologies. Issues such as enabling in-flight model updates, further increasing energy efficiency and ensuring coordination in multiple drone operations are the focus of research in this area. The continuous development of lightweight and Edge AI models will enable drones to become smarter, faster and more reliable, which will enable a wider range of uses of drone technology.

2.9. AI-Powered Drone Object Detection Applications

AI-powered drone object detection technology has revolutionized various sectors. Drones' ability to detect objects in their environment offers innovative solutions across fields like agriculture, security, transportation, and environmental protection. This technology provides speed, accuracy, and automation, making it a more efficient alternative to traditional methods (Ramachandran & Sangaiah, 2021).

In agriculture, AI-powered drone object detection aids farmers in crop health analysis and weed detection. Drones monitor large landscapes, identifying signs of disease early to accelerate response. This technology also promotes sustainability by enabling efficient water management and precise pesticide application (Talaviya et al., 2020).

In security, AI-powered drone object detection excels by providing constant surveillance over large areas and identifying specific objects or individuals. It is especially valuable for detecting dangerous items at crowded events or suspicious activity in border zones, giving security teams a critical advantage. Additionally, these systems reduce human error, enhancing overall safety (Laghari et al., 2024).

In disaster management and search-and-rescue operations, AI-powered drone object detection is crucial. During natural disasters like earthquakes, floods, and fires, drones can locate

people under debris or assist rescue teams by mapping hazardous areas. This technology speeds up response times, making life-saving efforts more effective (Papyan et al., 2024).

In transportation, drones can detect road and bridge damage, analyze traffic density, and quickly identify accident causes. By providing real-time data, they offer valuable insights for urban planners and transportation authorities, helping make systems more efficient and safer (Liu et al., 2024).

Overall, AI-powered drone object detection has the potential to enhance efficiency, safety, and sustainability across various sectors. As the technology rapidly evolves, it will lead to broader and more innovative applications in the future.

2.10. Future Directions of Drone Object Detection

The future of AI-based drone object detection will focus on developing more efficient algorithms and integrated systems. Advances in energy-efficient models and hardware will broaden the technology's use. Additionally, innovations like drone swarming and edge computing will enhance drones' intelligence and autonomy (Johnson, 2020). Autonomous decision-making systems will allow drones to operate in hazardous environments without human intervention. In natural disasters or search-and-rescue missions, fast and accurate object detection can be life-saving. However, establishing ethical and regulatory frameworks is crucial to ensure the safe and responsible use of this technology.

3. CONCLUSION

This study explores the current state and potential of AI-assisted drone object detection. Real-time detection algorithms like YOLO, SSD, and Faster R-CNN offer varying advantages in speed and accuracy, tailored to specific applications. Lightweight AI models and edge computing enhance drone efficiency, addressing processing and energy constraints, with significant applications in agriculture, security, disaster management, and logistics. Future advancements in energy-efficient algorithms, swarm technology, and autonomous systems will enable smarter, independent drone operations, particularly in critical areas. Ethical and regulatory frameworks remain essential for responsible deployment. AI-driven drones promise broader, safer, and more sustainable applications ahead.

REFERENCES

- Ahmed, F., & Jenihhin, M. (2022). A survey on UAV computing platforms: A hardware reliability perspective. *Sensors*, 22(16), 6286.
- Aldossri, R., Aljughaiman, A., & Albuali, A. (2024). Advancing Drone Operations through Lightweight Blockchain and Fog Computing Integration: A Systematic Review. *Drones*, 8(4), 153.
- Ariza-Sentís, M., Vélez, S., Martínez-Peña, R., Baja, H., & Valente, J. (2024). Object detection and tracking in Precision Farming: a systematic review. *Computers and Electronics in Agriculture*, 219, 108757.
- Asatryan, G., & Kalpakian, J. (2021). The drone age: how drone technology will change war and peace: by Michael J. Boyle, Oxford, Oxford University Press, 2020, 336 pp.,£ 22.99 (Hardback)(UK), ISBN 9780190635862. In: Taylor & Francis.
- Aslam, A., & Curry, E. (2021). A survey on object detection for the internet of multimedia things (IoMT) using deep learning and event-based middleware: approaches, challenges, and future directions. *Image and Vision computing*, 106, 104095.
- Balaji, S. (2020). Binary image classifier cnn using tensorflow. *Medium*. Aug, 28.
- Caballero-Martin, D., Lopez-Guede, J. M., Estevez, J., & Graña, M. (2024). Artificial Intelligence Applied to Drone Control: A State of the Art. *Drones*, 8(7), 296.
- Cazzato, D., Cimorelli, C., Sanchez-Lopez, J. L., Voos, H., & Leo, M. (2020). A survey of computer vision methods for 2d object detection from unmanned aerial vehicles. *Journal of Imaging*, 6(8), 78.

- Choi, H.-T., Lee, H.-J., Kang, H., Yu, S., & Park, H.-H. (2021). SSD-EMB: An improved SSD using enhanced feature map block for object detection. *Sensors*, 21(8), 2842.
- Dhillon, A., & Verma, G. K. (2020). Convolutional neural network: a review of models, methodologies and applications to object detection. *Progress in Artificial Intelligence*, 9(2), 85-112.
- Diwan, T., Anirudh, G., & Tembhurne, J. V. (2023). Object detection using YOLO: Challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*, 82(6), 9243-9275.
- Ghahremannezhad, H., Shi, H., & Liu, C. (2023). Object detection in traffic videos: A survey. *IEEE Transactions on Intelligent Transportation Systems*, 24(7), 6780-6799.
- Giones, F., & Brem, A. (2017). From toys to tools: The co-evolution of technological and entrepreneurial developments in the drone industry. *Business Horizons*, 60(6), 875-884.
- Giordan, D., Adams, M. S., Aicardi, I., Alicandro, M., Allasia, P., Baldo, M., De Berardinis, P., Dominici, D., Godone, D., & Hobbs, P. (2020). The use of unmanned aerial vehicles (UAVs) for engineering geology applications. *Bulletin of Engineering Geology and the Environment*, 79, 3437-3481.
- Hassanalian, M., & Abdelkefi, A. (2017). Classifications, applications, and design challenges of drones: A review. *Progress in Aerospace sciences*, 91, 99-131.
- Hmidani, O., & Alaoui, E. I. (2022). A comprehensive survey of the R-CNN family for object detection. 2022 5th International Conference on Advanced Communication Technologies and Networking (CommNet),

- Hossain, S., & Lee, D.-j. (2019). Deep learning-based real-time multiple-object detection and tracking from aerial imagery via a flying robot with GPU-based embedded devices. *Sensors*, 19(15), 3371.
- Iman, M., Arabnia, H. R., & Rasheed, K. (2023). A review of deep transfer learning and recent advancements. *Technologies*, 11(2), 40.
- Javaid, M., Haleem, A., Khan, I. H., & Suman, R. (2023). Understanding the potential applications of Artificial Intelligence in Agriculture Sector. *Advanced Agrochem*, 2(1), 15-30.
- Jiang, P., Ergu, D., Liu, F., Cai, Y., & Ma, B. (2022). A Review of Yolo algorithm developments. *Procedia computer science*, 199, 1066-1073.
- Johnson, J. (2020). Artificial intelligence, drone swarming and escalation risks in future warfare. *The RUSI Journal*, 165(2), 26-36.
- Kaur, J., & Singh, W. (2022). Tools, techniques, datasets and application areas for object detection in an image: a review. *Multimedia Tools and Applications*, 81(27), 38297-38351.
- Kaur, R., Kumar, R., & Gupta, M. (2021). Review on Transfer Learning for Convolutional Neural Network. 2021 3rd International Conference on Advances in Computing, Communication Control and Networking (ICAC3N),
- Kaur, R., & Singh, S. (2023). A comprehensive review of object detection with deep learning. *Digital Signal Processing*, 132, 103812.

- Kellermann, R., Biehle, T., & Fischer, L. (2020). Drones for parcel and passenger transportation: A literature review. *Transportation Research Interdisciplinary Perspectives*, 4, 100088.
- Kumar, A., & Srivastava, S. (2020). Object detection system based on convolution neural networks using single shot multi-box detector. *Procedia computer science*, 171, 2610-2617.
- Kumar, A., Zhang, Z. J., & Lyu, H. (2020). Object detection in real time based on improved single shot multi-box detector algorithm. *EURASIP Journal on Wireless Communications and Networking*, 2020(1), 204.
- Laghari, A. A., Jumani, A. K., Laghari, R. A., Li, H., Karim, S., & Khan, A. A. (2024). Unmanned aerial vehicles advances in object detection and communication security review. *Cognitive Robotics*.
- Li, Y., & Liu, C. (2019). Applications of multirotor drone technologies in construction management. *International Journal of Construction Management*, 19(5), 401-412.
- Liu, X., Li, J., Ma, J., Sun, H., Xu, Z., Zhang, T., & Yu, H. (2023). Deep transfer learning for intelligent vehicle perception: A survey. *Green Energy and Intelligent Transportation*, 100125.
- Liu, Z., Chen, C., Huang, Z., Chang, Y. C., Liu, L., & Pei, Q. (2024). A Low-Cost and Lightweight Real-Time Object-Detection Method Based on UAV Remote Sensing in Transportation Systems. *Remote Sensing*, 16(19), 3712.
- Lu, S., Wang, B., Wang, H., Chen, L., Linjian, M., & Zhang, X. (2019). A real-time object detection algorithm for video. *Computers & Electrical Engineering*, 77, 398-408.

- Magistretti, S., & Dell’Era, C. (2019). Unveiling opportunities afforded by emerging technologies: evidences from the drone industry. *Technology Analysis & Strategic Management*, 31(5), 606-623.
- Maity, M., Banerjee, S., & Chaudhuri, S. S. (2021). Faster r-cnn and yolo based vehicle detection: A survey. 2021 5th international conference on computing methodologies and communication (ICCMC),
- Maltezos, E., Douklias, A., Dadoukis, A., Misichroni, F., Karagiannidis, L., Antonopoulos, M., Voulgary, K., Ouzounoglou, E., & Amditis, A. (2021). The inus platform: A modular solution for object detection and tracking from uavs and terrestrial surveillance assets. *Computation*, 9(2), 12.
- McEnroe, P., Wang, S., & Liyanage, M. (2022). A survey on the convergence of edge computing and AI for UAVs: Opportunities and challenges. *IEEE Internet of Things Journal*, 9(17), 15435-15459.
- Mittal, P., Singh, R., & Sharma, A. (2020). Deep learning-based object detection in low-altitude UAV datasets: A survey. *Image and Vision computing*, 104, 104046.
- Nouacer, R., Hussein, M., Espinoza, H., Ouhammou, Y., Ladeira, M., & Castiñeira, R. (2020). Towards a framework of key technologies for drones. *Microprocessors and Microsystems*, 77, 103142.
- Papayan, N., Kulhandjian, M., Kulhandjian, H., & Aslanyan, L. (2024). AI-Based Drone Assisted Human Rescue in Disaster Environments: Challenges and Opportunities. *Pattern Recognition and Image Analysis*, 34(1), 169-186.

- Puri, V., Nayyar, A., & Raja, L. (2017). Agriculture drones: A modern breakthrough in precision agriculture. *Journal of Statistics and Management Systems*, 20(4), 507-518.
- Ramachandran, A., & Sangaiah, A. K. (2021). A review on object detection in unmanned aerial vehicle surveillance. *International Journal of Cognitive Computing in Engineering*, 2, 215-228.
- Soori, M., Arezoo, B., & Dastres, R. (2023). Artificial intelligence, machine learning and deep learning in advanced robotics, a review. *Cognitive Robotics*, 3, 54-70.
- Talaviya, T., Shah, D., Patel, N., Yagnik, H., & Shah, M. (2020). Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. *Artificial Intelligence in Agriculture*, 4, 58-73.
- Walambe, R., Marathe, A., & Kotecha, K. (2021). Multiscale object detection from drone imagery using ensemble transfer learning. *Drones*, 5(3), 66.
- Yazid, Y., Ez-Zazi, I., Guerrero-González, A., El Oualkadi, A., & Arioua, M. (2021). UAV-enabled mobile edge-computing for IoT based on AI: A comprehensive review. *Drones*, 5(4), 148.
- Yu, H., Li, G., Zhang, W., Huang, Q., Du, D., Tian, Q., & Sebe, N. (2020). The unmanned aerial vehicle benchmark: Object detection, tracking and baseline. *International journal of computer vision*, 128, 1141-1159.
- Zou, Z., Chen, K., Shi, Z., Guo, Y., & Ye, J. (2023). Object detection in 20 years: A survey. *Proceedings of the IEEE*, 111(3), 257-276.

TİROİT HASTALIKLARININ DERİN ÖĞRENME İLE SINIFLANDIRILMASI

Mehmet Süleyman YILDIRIM¹

1. GİRİŞ

Küçük ama hayati önem taşıyan bir endokrin organ olan tiroit bezi, kalp hızı ve kalp debisi, lipid metabolizması, ısı düzenlemesi ve iskelet büyümesi gibi metabolik işlevleri düzenlemede kritik bir rol oynar (Pi vd., 2022). Tiroit bozuklukları şiddetli olduğunda ölüme neden olabilen endokrin hastalıklarının ikinci önde gelen nedenidir (Parry & Macnab, 2017). Yaygın olarak görülen guatr hastalığı tiroit bezinin boyutlarının büyümesi anlamına gelmektedir (Baysal vd., 2022). Guatr hastalığı genellikle ağrısızdır fakat büyümüş guatr yutkunmayı ve nefes almayı zorlaştırabilir (Aghajanzadeh vd., 2018).

Tiroit bezinin hastalıklarının teşhisi sürecinde kan testleri, antikor testleri ve ultrason testleri gibi bir çok yöntem kullanılmaktadır (Allelein vd., 2019). Ayrıca sınırlı seviyede tiroit sintigrafisi de teşhis için kullanılmaktadır (Trimboli vd., 2024). Tiroit sintigrafisi tiroit dokusuna yoğunlaştırılan bir radyonükleit uygulanmasının ardından tiroit dokusunun görsel görüntüsünü sağlayan bir nükleer tıp prosedürüdür (Broome, 2006). Tiroit sintigrafisi sonuçlarının yorumlanması büyük ölçüde nükleer tıp asistanlarının deneyimlerine dayanmaktadır ve bu durum tanısal raporlamayı bir ölçüde öznel hale getirmektedir (Qiao vd., 2021).

¹ Dr. Öğr. Üyesi, Bilecik Şeyh Edebali Üniversitesi, Söğüt Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölüm Başkanlığı, mehmet.s.yildirim@bilecik.edu.tr, ORCID: 0000-0002-3998-1542.

Tıbbi görüntülerdeki bu zorluklar ile mücadele etmek için derin öğrenme tekniklerini kullanan sistemler ile birçok çalışma önerilmiştir. Tiroit hastalıklarının teşhisi için ultrason görüntülerinin sınıflandırılması ile yapılan bazı çalışmalar öne çıkmaktadır (Yadav vd., 2024). Derin öğrenme yöntemlerinin tiroit hastalıklarının tespitinde ultrason kesit ve videolarını kullandığı çok sayıda akademik çalışma bulunmaktadır.

Derin öğrenme teknikleri yoluyla ultrason görüntüleri kullanılarak tiroit nodüllerinin sınıflandırılması, tıbbi teşhiste önemli bir ilerleme olarak ortaya çıkmıştır. Bu yaklaşım, iyi huylu ve kötü huylu nodülleri tespit etmenin doğruluğunu ve verimliliğini artırmak için öncelikle evrişimli sinir ağlarını (CNN'ler) kullanır ve hastaların doğru teşhis ve tedaviye ulaşmasına katkı sağlar. CNN'ler görüntü sınıflandırma görevleri için yaygın olarak kullanılmaktadır ve iyi huylu ve kötü huylu tiroit nodüllerini ayırt etmede yüksek doğruluk gösterir (Pavithra S. & Naveen Kumar J.R, 2024; X. Yang & Zhu, 2024). Başka bir çalışmada attention modülüne sahip bir DenseNet modeli kullanılarak yeni bir model önerilmiştir. Tiroit nodülleri sınıflandırmada %94 üzerinde doğruluk ve hassasiyet elde edilmiştir (Tareke vd., 2024). Tarake vd. yaptıkları çalışmada gradyan ağırlıklı sınıf aktivasyon haritaları (Grad-CAM), model karar vermeye ilişkin içgörüler sağlamak ve klinik uygulamalar için güvenilirliği güçlendirmek için kullanılır. Ultrason görüntülemesinde derin öğrenmenin uygulanması, tiroit hastalıklarının tanı ve tedavisini hızlandırarak klinik kullanım için pratik kolaylık sunar (Archana vd., 2024; X. Yang & Zhu, 2024). Bir başka çalışma aynı zamanda pediatrik hastalarda tiroit ultrason görüntülerinin sınıflandırmasına uygulanabilirliğini vurgulamaktadır (Kumar vd., 2025).

Derin öğrenme teknikleri, sintigrafi ve histopatolojik görüntüler dahil olmak üzere çeşitli görüntüleme aracılığıyla tiroit hastalıklarının sınıflandırılmasında sıkça kullanılmaktadır. Çalışmalar sintigrafi görüntülerini analiz etmede evrişimli sinir

ağlarının (CNN'ler) etkinliğini göstermiştir ve tiroit nodül sınıflandırması için % 95.4 gibi yüksek doğruluk seviyelerine ulaşmıştır (Hannah vd., 2024). Derin evrişimli sinir ağlarını (DCNN'ler) kullanan çok merkezli bir çalışma tek foton emisyonlu bilgisayarlı tomografi (SPECT) görüntülerinden tiroit hastalıklarını teşhis etmek için bir model önermişler ve yüksek doğruluk ile sınıflandırma başarımı sağlamışlardır (Zhao vd., 2023). Ayrıca histopatolojik görüntülerden tiroit tümörlerinin sınıflandırılmasını geliştirmek, yüksek hassasiyet ve geri çağırma oranları elde etmek için EfficientNet ve ResNet gibi gelişmiş modeller kullanılmıştır (Deng vd., 2023; Linda vd., 2024). Bu bulgular, tiroit hastalığı yönetiminde tanısal doğruluğu ve klinik karar vermeyi iyileştirmek için derin öğrenmenin potansiyelinin altını çizmektedir. Tiroit sintigrafisi kullanılarak yapılan sınıflandırma çalışmaları da literatürde göze çarpmaktadır (P. Yang vd., 2021). Yang vd. yaptıkları çalışmada çeşitli derin öğrenme algoritmalarını kullanarak sintigrafi sınıflandırması yapmıştır. Çalışmada derin öğrenme yöntemleri ile etkili bir başarımlar sağlanmış olmasına rağmen gerçek değerlendirme kadar başarılı olmadığı yeni geliştirmelere ihtiyaç olduğu vurgulanmıştır.


Sınıflandırma problemlerinde sıkça kullanılan bir derin öğrenme modeli olan MobileNet'in deri kanserinin sınıflandırılması için yapılan çalışmada %89.41 doğruluk seviyesine ulaşmıştır (Şahin & Yıldırım, 2024). Mimarinin optimize edilmiş koşullarda % 95'e kadar yükseldiği dental implant sınıflandırmasındaki uygulamasında görülmektedir (Chang vd., 2024). Literatür incelendiğinde MobileNet mimarisinin tıbbi görüntülerin sınıflandırılmasında başarımlar sağlayacağı anlaşılmıştır. Tiroit hastalıklarının ultrason, histopatolojik görüntüler kullanılarak derin öğrenme yöntemleri ile sınıflandırılmasını öneren birçok çalışma görülmüştür. İncelenen yayınlar sonucunda tiroit sintigrafisi üzere yapılacak yeni çalışmalara ihtiyaç olduğu anlaşılmıştır. Ayrıca yapılacak geliştirmeler ile hekimlerin daha hızlı doğ-

ru teşhis yapabileceği ve hastaların tedavi sürecinin başarısının artacağı ön görülmektedir.

Bu çalışma kapsamında tiroit sınıflandırması için bir model önerilmektedir. Önerilen model ile tiroit sintigrafisi görüntüleri üzerinde eğitim ve test süreçleri gerçekleştirilmiştir. Çalışmanın sonraki bölümlerinde materyal ve metot, deneysel süreçler, sonuç ve tartışma bölümlerinden oluşmaktadır.

2. MATERYEL VE METHOD

Çalışmada kapsamında tiroit hastalıklarının sınıflandırılması için bir sistem önerilmiştir. Önerilen derin öğrenme tabanlı tiroit hastalıklarının sınıflandırılması sistemi Şekil 1'de görülmektedir. Bu sistem verisetinin yüklenmesi, ön işlemlerden geçirilmesi, modelin tanımlanması, eğitim süreçleri ve performans değerlendirme aşamalarından oluşmaktadır.




Şekil 1. Önerilen sistemin blok diyagramı

a. VERİSETİ

Bu çalışmada kullanılan veriseti Paraguay'daki Universidad Nacional de Asunción (IICS - UNA) bünyesindeki Instituto de Investigaciones en Ciencias de la Salud'un Nükleer Tıp Servisi'nde hazırlanmıştır (Grossling-Vallejos vd., 2024). Veriseti 235 hastaya ait 641 tiroit sintigrafisi görüntüsünü içermektedir. Tiroit sintigrafisi görüntüleri AnyScan SCP modeli MEDISO marka trimodal SPECT-CT-PET ekipmanı kullanılarak elde edilmiştir. Görüntüler Nükleer Tıp Servisi uzmanları tarafından


nükleer hekimler tarafından konulan teşhislere göre 16 gruba ayrılmıştır. Şekil 2’de verisetinin dağılım grafiği görülmektedir.



Şekil 2. Verisetinin dağılım grafiği

Çalışma kapsamında diğer gruplara göre etkili miktarda veri bulunan yaygın guatr ve multinodüler guatr grupları ele alınmıştır. Bu gruplarda sırasıyla 75 ve 105 anterior kesit bulunmaktadır. Şekil 3’de verisetinden örnek kesitler görülmektedir.


Verisetindeki kesitler 256x256 boyutunda sunulmuştur. Önerilen derin öğrenme modeli MobileNet’in giriş katmanı 224x224 boyutlarındadır. Bu nedenle veri ön işleme olarak veri-seti yeniden boyutlandırılmıştır.



Şekil 3. Verisetinden örnek kesitler

b. VERİ ÖN İŞLEME VE VERİ ARTTIRIMI

Ayrıca verisetinin kesit sayısındaki sınırlılık nedeniyle veri arttırımı yapılmıştır. Veri arttırımı için kesitler üzerinde rastgele döndürme, yatay ve dikey kaydırma, yatay ve dikey döndürme, rastgele eğim işlemleri uygulanmıştır. Şekil 4’de veri arttırmaya örnekler görülmektedir.



Şekil 4. Veri arttırmada kullanılan yöntemlere örnek kesitler


Verisetinin artırımı sonrasında 75 yaygın guatr ve 105 multinodüler guatr kesit sayısı 296 yaygın guatr 414 multinodüler guatr kesite yükselmiştir. Ayrıca veriseti eğitim, onaylama ve test kümesine ayrılmıştır. Tablo 1’de veri arttırımı öncesi ve sonrasında veri kümelerinin gruplara göre dağılımı görülmektedir.

Tablo 1. Arttırılmış verisetinin kümelere göre dağılımı

	Eğitim Kümesi	Onaylama Kümesi	Test Kü- mesi	Toplam
Yaygın Guatr	228	28	40	296
Multinodüler Guatr	312	48	54	414

c. MOBİLENET MİMARİSİ

Verisetinin üzerinde ön işlem ve veri arttırımı sonrasında dağıtım Derin öğrenme modelleri sınıflandırma problemlerinde sıkça kullanılmaktadır. Bu çalışmada MobileNet mimarisi ile tiroit sınıflandırma yapılmıştır. Şekil 5’de MobileNet mimarisi görülmektedir.



Şekil 5. MobileNet Mimarisi(Selvi vd., 2024)

MobileNet mimarisi mobil cihazlar gibi kaynak kısıtlı ortamlar için tasarlanmış hafif ve verimli bir evrişimli sinir ağıdır (Howard vd., 2017). Görüntü sınıflandırması ve nesne algılama gibi görüntü işleme problemleri için uygundur. Tasarımı, yüksek doğruluğu korurken parametre sayısını ve hesaplama maliyetini önemli ölçüde azaltan derinlemesine ayrılabilir kıvrımları vurgular. Genel olarak, MobileNet'in çok yönlülüğü ve verimliliği, onu modern bilgisayar görme görevlerinde değerli bir araç haline getirir.

d. PERFORMANS KRİTERLERİ

Derin öğrenme çalışmaları kapsamında model eğitimi tamamlandıktan sonra performansını çeşitli metriklerle ölçmek ve analiz etmek modelin etkinliğini anlamak için kritik öneme sahiptir. Bu çalışmada eğitilen modelin doğruluğunu ve etkinliğini anlamak için çeşitli metrikler kullanılarak başarımlar hesaplanması yapılmıştır. Model performansları, eğitim ve doğrulama kayıpları, karışıklık matrisi, hata metrikleri (doğruluk, duyarlılık, özgüllük, F1-skor), ROC eğrisi ve AUC gibi ölçümler kullanılarak değerlendirilmiştir.

		Tahmin	
		Doğru	Yanlış
Gerçek	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 6. Karmaşıklık Matrisi

Karmaşıklık matrisi, sınıflandırma başarısını görselleştirmek için kullanılır. Hata metrikleri, yaygın olarak modelin

genel performansını değerlendirmek için kullanılır. Kullanılan hata metrikleri karmaşıklık matrisine bağlı olan değerlerden elde edilmiştir. Şekil 6'da sunulan Karmaşıklık Matrisi'nde False Negatif (FN), gerçek pozitiflerin negatif olarak sınıflandırıldığı durumların sayısını göstermektedir. False Pozitif (FP), gerçek negatiflerin pozitif olarak sınıflandırıldığı durumların sayısını, True Pozitif (TP), gerçek pozitiflerin pozitif sınıflandırıldığı durumların sayısını ve True Negatif (TN), gerçek negatiflerin negatif sınıflandırıldığı durumların sayısını göstermektedir

Bu ölçeklerin birleşiminden elde edilen doğruluk (ACC), keskinlik (PRE), hatırlama (REC) ve F1 skor (F1) metrikleri ile sınıflandırma başarımı ölçülmüştür. Bu metrikler 0 ile 1 arasında değer almaktadır ve 1'ne kadar yaklaşırsa başarımlar o kadar artmaktadır. Çalışmada veriler 100 ile çarpılarak % olarak sunulmuştur. Denklem 1'de görülen ACC tüm doğru tahminlerin toplam tahminlere oranını gösterir. PRE Denklem 2'de görülmektedir ve modelin doğru pozitif tahminlerinin tüm pozitif tahminlere oranını ifade eder. REC ise gerçek pozitiflerin doğru tahmin edilme oranını gösterilmiştir (Denklem 3). Denklem 4'de görülen F1 PRE ve REC'in harmonik ortalamasıyla hesaplanmıştır. Ayrıca, karışıklık matrisi yardımıyla modelin her bir sınıf için doğru (TP, TN) ve yanlış (FP, FN) tahminlerinin sayıları analiz edilmiştir.

$$ACC = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (1)$$

$$PRE = \frac{TP}{(TP + FP)} \quad (2)$$

$$REC = \frac{TP}{(TP + FN)} \quad (3)$$

$$F1 = \frac{2 \cdot (PRE + REC)}{(PRE + REC)} \quad (4)$$

Alıcı çalışma karakteristik (ROC) eğrisi ve eğrinin altındaki alan (AUC) sınıflandırma modellerinin performansını karşılaştırmak için yaygın olarak kullanılır. ROC eğrisi, modelin doğru pozitif oranı (True Positive Rate, TPR) ve yanlış pozitif oranı (False Positive Rate, FPR) arasındaki ilişkiyi gösterir. Bu ilişki grafiksel olarak sunulduğunda bir eğri ile başarımlar alanı ortaya çıkartılır. Bu eğrinin altındaki alan AUC olarak belirlenir ve 0 ile 1 arasında değer alır. AUC değeri ne kadar yüksekse, modelin performansı o kadar iyidir.

3. DENEYSEL ÇALIŞMALAR


Bu çalışma kapsamında halka açık olarak sunulmuş güncel bir tiroit verisetinin en fazla görüntü bulunan 2 sınıfının MobileNet ile sınıflandırılması yapılmıştır.

a. EĞİTİM SÜREÇLERİ


Model üzerinde yapılacak eğitim için veriseti rastgele eğitim, onaylama ve test kümelerine ayrılmıştır. Ardından veriseti üzerinde veri artırımı uygulanmıştır. Verisetinin dağılımını belirleme işlemi veri arttırımından önce yapılarak kesitlerde aşırı benzerlik ve modelin eğitiminde aşırı öğrenmesi engellenmiştir. Çalışma kapsamında önerilen derin öğrenme modeli MobileNet ile verisetinin eğitim kümesi 100 tur eğitilmiş ve onaylama kümesinde her turun değerlendirilmesi yapılmıştır. Eğitim süreci 0.001 öğrenme oranı, 32 kesme boyutu, çapraz entropi ve adam optimizasyon fonksiyonu kullanılarak gerçekleştirilmiştir.

Eğitim süreci sonucunda eğitim ACC değeri %100'e ve onaylama ACC oranı %81.57'ye ulaşmıştır. Şekil 7'de ACC grafiğinin eğitim sürecinde değişimi görülmektedir. Ayrıca eğitim sürecinde hata değişimi incelendiğinde eğitim kümesindeki hata 0.29×10^{-4} e kadar ve onaylama kümesi hatası 1.05'e kadar

düşmüştür. Şekil 8’de eğitim sürecindeki hata değişimi görülmektedir.




Şekil 7. Eğitim sürecinde ACC değişim grafiği



Şekil 8. Eğitim sürecinde hata değişim grafiği

b. TEST SONUÇLARI

Eğitim süreçleri sonucunda verisetinden test için ayrılan küme üzerinde her turun denemesi gerçekleştirildi. Yapılan denemeler sonucunda el edilen en iyi tur sonuçlarına göre karşılaştırma matrisi Şekil 10’da görüldüğü gibi oluşmuştur.




Şekil 9. Test kümesinde en iyi turda elde edilen karşılaştırma matrisi

Bu turun sonucunda elde edilen metriklerin değerleri Tablo 2’de verilmiştir. Bu tablo incelendiğinde eğitime hiç dahil olmayan farklı kesitler üzerinde yapılan incelemede ACC değerinin %83.33’ye ulaştığı görülmektedir.

Tablo 2. Test kümesinde en iyi turda elde metrik sonuçları

ACC	PRE	REC	F1
%83.33	%81.57	%77.5	%79.48


Test süreçlerinde en iyi turda elde edilen sonuçların doğru tahmin ve yanlış tahmin edilme oranlarının karşılaştırılması ile elde edilen ROC eğrisi ve eğrinin altında kalan alanı temsil eden AUC değeri Şekil 10'da görülmektedir. Bu grafik incelendiğinde AUC değerinin %82.5 olduğu görülmektedir.



Şekil 10. En iyi tur için ROC eğrisi ve AUC değeri grafiği

Önerilen model ile yapılan sınıflandırma işlemine örnek sonuçlar Tablo 3'de sunulmuştur. Bu örnekler incelendiğinde karakteristik olarak multinodüler guatr a benzeyen ancak uzman değerlendirmesi sonucunda yaygın guatr olarak belirlenmiş kesitlerde sistemin başarısız olduğu görülmüştür. Ancak kesitlerin karakteristik yapısını öğrendiği anlaşılmıştır.

Tablo 2. Sınıflandırma sonuçlarına örnekler



Gerçek Etiket	Yaygın	Yaygın	Multimodüler	Multimodüler
Tahmin Etiketi	Yaygın	Multimodüler	Multimodüler	Multimodüler

4. SONUÇ VE TARTIŞMA

Tiroit hastalıkları yaygın olarak görülen tedavisi sağlanmadığı durumda hastaların can kaybına neden olabilen endokrin hastalıklarının önde gelen nedenlerinden biridir. Hastalığın teşhis ve tedavisinde önemli tanı yöntemlerinden biri tiroit sintigrafisidir. Tiroit sintigrafisi sonuçlarının yorumlanması nükleer tıp asistanlarının deneyimlerine bağlı olduğu için tanısal raporlamayı bir ölçüde öznel bir bakış açısına dayanmaktadır. Bu durum hekimler açısından bir zorluk oluşturmaktadır.

Tıbbi görüntü analizindeki bu zorlukların aşılması için öne çıkan derin öğrenme teknikleri ile sınıflandırma bir çözüm olarak görülmektedir. Literatür kaynaklarında bir çok çalışma ile derin öğrenme ile tiroit ultrason görüntülerinin sınıflandırılması için önerilerde bulunulduğu anlaşılmıştır. Ancak tiroit sintigrafisi hakkında çalışmalar halen geliştirilmeye ihtiyaç duymaktadır.

Bu çalışma ile tiroit sintigrafisi görüntülerinin derin öğrenme yöntemlerinden MobileNet ile sınıflandırılmasının etkinliği araştırılmıştır. MobileNet küçük boyutlu ve sınıflandırma alanında etkili bir modeldir. Çalışma kapsamında IICS – UNA tarafından sunulan tiroid sintigrafi veriseti kullanılmıştır. Bu verisetinde 16 tiroid hastalığına ait sintigrafi verilerinin gruplanmasına rağmen sadece 2 hastalık (yaygın ve multimodüler guatr) kesit sayısı sınıflandırma için uygun yoğunluktadır.

Çalışma için eğitim ve test süreçleri tamamlanmıştır. Yapılan testlerde ACC değeri %83.33 olarak tespit edilmiştir. Problemin zorluğu ve verisetinin kısıtları düşünüldüğünde bu doğruluk değerinin etkili bir değer olduğu anlaşılmaktadır. Bu çalışma ile tiroit hastalıklarının MobileNet ile sınıflandırması yapılmıştır. Önerilen modelin hekimler açısından değerlendirme zorluklarının giderilmesinde çözüm olabileceği ön görülmektedir.

Gelecek çalışmalarda daha geniş verisetleri ve gelişmiş derin öğrenme modelleri ile tiroit sintigrafisinin sınıflandırılması başarımının artırılması planlanmaktadır. Bu sayede geliştirilecek olan ve önerilen sistem ile tiroit hastalıklarının sınıflandırılması için hekimlere yardımcı araçlar geliştirilebileceği görülmüştür.

KAYNAKÇA

- Aghajanzadeh, M., Asgary, M. R., Mohammadi, F., Darvishi, H., & Safarpour, Y. (2018). An investigation into symptoms, diagnosis, treatment, and treatment complications in patients with retrosternal goiter. *Journal of Family Medicine and Primary Care*, 7(1), 224-229.
- Allelein, S., Diana, T., Ehlers, M., Kanitz, M., Hermesen, D., Schott, M., & Kahaly, G. J. (2019). Comparison of a bridge immunoassay with two bioassays for thyrotropin receptor antibody detection and differentiation. *Hormone and Metabolic Research*, 51(06), 341-346.
- Archana, P., Keerthana, S., & Srusti, P. (2024). *Detection of Thyroid Diseases Using Deep Learning*. Paper presented at the 2024 Second International Conference on Advances in Information Technology (ICAIT).
- Baysal, A., Ercan, L. D., Yıldırım, N., Özkan, M., Celik, A., Erbil, Y., & Özçınar, B. (2022). Multinodüler Guatr Hastalarında Anksiyete ve Depresyon. *Aydın Sağlık Dergisi*, 8(3), 247-263.
- Broome, M. R. (2006). Thyroid scintigraphy in hyperthyroidism. *Clinical techniques in small animal practice*, 21(1), 10-16.
- Chang, H.-C., Yu, L.-W., Liu, B.-Y., & Chang, P.-C. (2024). Classification of the implant-ridge relationship utilizing the MobileNet architecture. *Journal of Dental Sciences*, 19(1), 411-418.
- Deng, C., Li, D., Feng, M., Han, D., & Huang, Q. (2023). The value of deep neural networks in the pathological classification of thyroid tumors. *Diagnostic pathology*, 18(1), 95.

- Grossling-Vallejos, B., Colmán, C. E. V., Rivas, R., Pedrozo, M. G., Giménez, G., Rojas, T., . . . Uldera, A. (2024). Thyroid scan image dataset for the study of thyroid pathologies in adult patients. *Data in Brief*, 111134.
- Hannah, S., Jeevitha, S., Anuradha, T., Anand, A. J., Porkodi, G., & Vijayakumar, R. (2024). *Thyroid Nodule Classification Model from Scintigraphy Images using Convolution Neural Networks*. Paper presented at the 2024 5th International Conference on Innovative Trends in Information Technology (ICITIIT).
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., . . . Adam, H. (2017). MobileNets: efficient convolutional neural networks for mobile vision applications (2017). *arXiv preprint arXiv:1704.04861*, 126.
- Kumar, J., Panda, S. N., & Dayal, D. (2025). Pediatric thyroid ultrasound image classification using deep learning: A review. *Applied Data Science and Smart Systems*, 264-277.
- Linda, B., Kamila, K., & Ilyas, B. R. (2024). Improving thyroid cancer diagnosis with advanced deep learning techniques. *Studies in Engineering and Exact Sciences*, 5(2), e9154-e9154.
- Parry, Z., & Macnab, R. (2017). Thyroid disease and thyroid surgery. *Anaesthesia & Intensive Care Medicine*, 18(10), 488-495.
- Pavithra S., & Naveen Kumar J.R. (2024). Research on Thyroid Cancer Detection and Classification Using Deep Learning over Ultrasound Images. *International Journal For Multidisciplinary Research*. doi:<https://doi.org/10.36948/ijfmr.2024.v06i04.26749>

- Pi, Y., Yang, P., Wei, J., Zhao, Z., Cai, H., & Yi, Z. (2022). Fusing deep and handcrafted features for intelligent recognition of uptake patterns on thyroid scintigraphy. *Knowledge-Based Systems*, 236, 107531.
- Qiao, T., Liu, S., Cui, Z., Yu, X., Cai, H., Zhang, H., . . . Li, D. (2021). Deep learning for intelligent diagnosis in thyroid scintigraphy. *Journal of International Medical Research*, 49(1), 0300060520982842.
- Selvi, D. K., Joshi, K., Vani, V., Vekariya, D., Natrayan, L., & Patil, H. (2024). *Transfer Learning Approaches for Improved Thyroid Detection*. Paper presented at the 2024 5th International Conference on Electronics and Sustainable Communication Systems (ICESC).
- Şahin, O., & Yıldırım, M. S. (2024). *Performance Comparison of Deep Learning Architectures for Skin Cancer Classification*. Paper presented at the 2024 8th International Artificial Intelligence and Data Processing Symposium (IDAP).
- Tareke, T. W., Leclerc, S., Vuillemin, C., Buffier, P., Crevisy, E., Nguyen, A., . . . Lalande, A. (2024). Automatic Classification of Nodules from 2D Ultrasound Images Using Deep Learning Networks. *Journal of Imaging*, 10(8), 203.
- Trimboli, P., Bojunga, J., Deandrea, M., Frasca, F., Imperiale, A., Leoncini, A., . . . Sadeghi, R. (2024). Reappraising the role of thyroid scintigraphy in the era of TIRADS: A clinically-oriented viewpoint. *Endocrine*, 1-6.
- Yadav, N., Dass, R., & Virmani, J. (2024). Deep learning-based CAD system design for thyroid tumor characterization using ultrasound images. *Multimedia Tools and Applications*, 83(14), 43071-43113.

- Yang, P., Pi, Y., He, T., Sun, J., Wei, J., Xiang, Y., . . . Zhao, Z. (2021). Automatic differentiation of thyroid scintigram by deep convolutional neural network: a dual center study. *BMC Medical Imaging*, 21, 1-9.
- Yang, X., & Zhu, G. (2024). *Ultrasound-based discrimination of thyroid cancer based on deep learning*. Paper presented at the 2024 5th International Conference on Artificial Intelligence and Electromechanical Automation (AIEA).
- Zhao, H., Zheng, C., Zhang, H., Rao, M., Li, Y., Fang, D., . . . Yuan, G. (2023). Diagnosis of thyroid disease using deep convolutional neural network models applied to thyroid scintigraphy images: a multicenter study. *Frontiers in Endocrinology*, 14, 1224191.

DİYABET TEŞHİSİNDE AÇIKLANABİLİR YAPAY ZEKA: SHAP VE LIME YAKLAŞIMI

Dr. Nadir SUBAŞI¹

1. GİRİŞ

Açıklanabilir Yapay Zeka (XAI), özellikle sağlık, finans, hukuk ve savunma gibi yüksek riskli sektörlerde, yapay zeka modellerinin daha şeffaf ve anlaşılır hale gelmesini sağlamak amacıyla geliştirilmiş bir yaklaşımdır. Derin öğrenme gibi karmaşık algoritmalar genellikle “kara kutu” olarak adlandırılır; çünkü bu sistemlerin iç işleyişi, kullanıcılar ve hatta geliştiriciler için bile anlaşılması zor olabilir. Bu durum, kullanıcıların yapay zeka tabanlı sistemlere güvenini azaltabilir ve yanlış kararlar alındığında hesap verebilirlik sorunu yaratabilir. XAI, bu zorlukların üstesinden gelmek için, yapay zekanın sonuç üretme süreçlerini daha açıklanabilir, şeffaf ve doğrulanabilir hale getiren yöntemler ve araçlar sunar.

Özellikle sağlık sektöründe, XAI'nin önemi hayat kurtarıcı olabilir. Örneğin, bir yapay zeka modeli, kanser teşhisi veya tedavi önerisi sunduğunda, doktorların bu kararın nasıl alındığını anlaması kritik bir gerekliliktir. Yalnızca doğru tahminler sunmak yeterli değildir; aynı zamanda bu tahminlerin dayandığı veriler, kullanılan algoritmalar ve çıkarılan sonuçların mantığı da açıklanabilir olmalıdır. Bu sayede doktorlar, yapay zekanın sunduğu önerileri değerlendirebilir, onaylayabilir veya alternatif bir yaklaşım benimseyebilir. Finans sektöründe de benzer şekilde, kredi notu değerlendirme veya risk analizi gibi süreçlerde XAI, kararların nasıl alındığını açıklayarak kullanıcıların güven-

¹ Öğretim Görevlisi, (Kırklareli Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Teknolojileri), nadir.subasi@klu.edu.tr, ORCID: 0000-0002-5657-9002.

nini artırır ve düzenleyici kurumların taleplerine yanıt verir(Wang, 2024).

XAI aynı zamanda etik ve hukuki çerçeveler açısından da büyük bir öneme sahiptir. Yapay zeka sistemlerinin kararlarını açıklayabilir hale getirmek, algoritmik ayrımcılığın önlenmesine yardımcı olur. Örneğin, bir iş başvurusunda bir adayın reddedilmesine neden olan faktörler, XAI yöntemleriyle açıklanabilir hale geldiğinde, sistemin adil ve önyargısız çalışıp çalışmadığı değerlendirilebilir. Bu durum, yapay zeka sistemlerinin geliştirilmesi ve uygulanmasında etik standartların sağlanmasına katkıda bulunur.

XAI, yalnızca kullanıcıların yapay zeka sistemlerine güvenini artırmakla kalmaz, aynı zamanda bu sistemlerin eğitim ve iyileştirilme süreçlerini de destekler. Açıklanabilirlik, geliştiricilerin modellerdeki hataları tespit etmesine ve sistemleri daha etkili hale getirmesine olanak tanır. Örneğin, bir modelin bir görüntüde yanlışlıkla ilgisiz bir bölgeyi önemli bir özellik olarak değerlendirdiği fark edildiğinde, bu tür sorunlar giderilebilir ve model daha güvenilir hale getirilebilir (Morato de Andrade & Sousa Alves, 2024).

Hem bireysel kullanıcılar hem de kurumsal düzeyde karar alıcılar için, yapay zekanın nasıl çalıştığını anlamak ve güven duymak, bu teknolojilerin kabul edilmesi ve benimsenmesi için kritik bir rol oynar. XAI, şeffaflık, etik uyum ve hesap verebilirlik gibi değerlerle yapay zeka teknolojisinin daha güvenilir ve faydalı hale gelmesini sağlayarak, bu alanda devrim niteliğinde bir etki yaratmaktadır.

2. XAI'NİN ÖNEMİ

Açıklanabilir Yapay Zeka (XAI), yapay zeka teknolojisinin giderek daha karmaşık hale gelmesiyle kritik bir ihtiyaç olarak ortaya çıkmıştır. Bu teknolojinin temel amacı, yapay zeka modellerinin genellikle anlaşılması zor olan karar mekanizmalar-

rını şeffaf ve yorumlanabilir hale getirmektir. Özellikle LIME (Local Interpretable Model-Agnostic Explanations) ve SHAP (SHapley Additive exPlanations) gibi popüler XAI teknikleri, kullanıcıların yapay zeka modelleri tarafından alınan kararların ardındaki mantığı görselleştirmelerine ve anlamalarına olanak tanır. Örneğin, bu teknikler, bir tahmin modeli üzerinde hangi özelliklerin nasıl bir etkiye sahip olduğunu detaylı bir şekilde açıklayabilir. Bu durum, hem uzmanlar hem de sıradan kullanıcılar için yapay zeka tabanlı sistemlerin güvenilirliğini ve kabul edilebilirliğini artırır. Araştırmalar, kullanıcıların anlamadıkları bir teknolojiye güvenmekte zorlandığını göstermektedir. XAI, bu güven sorununu ortadan kaldırarak yapay zekayı daha erişilebilir ve kullanılabilir bir hale getirmektedir (N. L. Rane & Paramesha, 2024)

2.1. Güven ve Şeffaflık

Güven, yapay zeka sistemlerinin benimsenmesinde kritik bir faktördür ve XAI'nin temel katkılarından biridir. LIME ve SHAP gibi araçlar, kullanıcıların yapay zeka modellerini anlamasına olanak tanırken, aynı zamanda bu modellerin davranışlarını doğrulamalarını sağlar. Örneğin, bir müşteri sınıflandırma modelinde, belirli bir müşterinin neden "yüksek risk" grubuna dahil edildiği LIME kullanılarak açıklanabilir. Bu tür açıklamalar, kullanıcıların yalnızca sonuca odaklanmak yerine süreci anlamalarını sağlar ve bu da daha bilinçli kararların alınmasına yardımcı olur (J. Rane, Kaya, Mallick, & Rane, 2024).

2.2. Etik Karar Verme

XAI, sadece şeffaflık sağlamanın ötesine geçerek etik bir çerçeve sunar. Örneğin, bir iş başvurusunda kullanılan yapay zeka modeli bir adayın reddedilmesine karar verdiyse, bu kararın altında yatan nedenler açıklanabilir hale getirilebilir. Böylece, modelin adil ve önyargısız çalışıp çalışmadığı değerlendirilebilir. Bu yaklaşım, toplumsal adaletin sağlanmasına ve algo-

ritmik önyargının azaltılmasına olanak tanır. Ayrıca, Avrupa Birliği Genel Veri Koruma Yönetmeliği (GDPR) ve önerilen AI Yasası gibi düzenlemeler, XAI'nin önemini artırmaktadır. Bu yasal çerçeveler, yapay zeka sistemlerinin şeffaf olmasını ve kullanıcıların kararları anlamasına olanak tanımasını şart koşmaktadır. XAI, bu tür yasal gerekliliklere uyum sağlayarak hem bireylerin haklarını korur hem de kurumların cezai yaptırımlardan kaçınmasına yardımcı olur (Adewale Abayomi Adeniran, Amaka Peace Onebunne, & Paul William, 2024).

2.3. Kritik Sektörlerde Uygulamalar

XAI'nin potansiyeli, yüksek riskli sektörlerdeki uygulamalarında net bir şekilde görülmektedir. Özellikle sağlık ve finans gibi alanlar, bu teknolojinin avantajlarını en çok kullanan sektörler arasında yer almaktadır.

Sağlık: Sağlık sektöründe XAI, teşhis ve tedavi süreçlerinde yapay zeka sistemlerinin oynadığı rolü netleştirmektedir. Örneğin, bir yapay zeka modeli bir hastanın kanser olduğunu teşhis ettiğinde, bu teşhisin neden ve nasıl alındığına dair bir açıklama gereklidir. XAI, doktorlara bu tür modellerin karar mekanizmalarını anlama ve doğrulama imkanı sunar. Bu durum, doktorların yapay zeka destekli kararları güvenle benimsemelerini ve bu kararları hastalara açıklamalarını kolaylaştırır. Ayrıca, hasta güvenini artıran bir unsur olarak, yapay zekanın sadece doğru sonuçlar üretmekle kalmayıp, aynı zamanda bunları şeffaf bir şekilde sunması gerektiğini vurgular (Adewale Abayomi Adeniran et al., 2024).

Finans: Finans sektöründe XAI, kredi değerlendirme, dolandırıcılık tespiti ve risk analizi gibi kritik alanlarda uygulanmaktadır. Örneğin, bir yapay zeka modeli bir müşterinin kredi başvurusunu reddettiğinde, bu kararın gerekçeleri açıklandığında hem müşteri güveni sağlanabilir hem de bankalar yasal düzenlemelere uyum gösterebilir. Ayrıca, XAI, algoritmik karar-

ların nasıl alındığına dair içgörüler sağlayarak bankaların risk yönetimi süreçlerini iyileştirmelerine ve müşteri katılımını artırmalarına yardımcı olur (N. L. Rane & Paramesha, 2024)

2.4. Zorluklar ve Gelecekteki Yönler

XAI'nin sağladığı avantajlara rağmen, bazı zorluklar hala çözüme kavuşturulmayı beklemektedir.

Performans ve Yorumlanabilirlik: Derin öğrenme gibi karmaşık yapay zeka modelleri genellikle yüksek doğruluk oranlarına sahiptir; ancak bu doğruluk genellikle modelin açıklanabilirliği ile ters orantılıdır. Daha basit ve anlaşılabilir modeller, genellikle doğruluk açısından daha düşük performans sergiler. Bu durum, yapay zeka araştırmacıları için önemli bir denge oluşturma gerekliliğini doğurur. XAI'nin temel hedeflerinden biri, yüksek performansa sahip modellerin açıklanabilirliğini artırmaktır. Bununla birlikte, bu hedefe ulaşmak hala önemli bir araştırma alanı olarak kalmaktadır (N. L. Rane & Paramesha, 2024)(Ara, 2024).

Yükselen Trendler: Gelecekteki araştırmalar, kullanıcı merkezli açıklanabilirliğe daha fazla odaklanmaktadır. Kullanıcı merkezli XAI, farklı kullanıcı gruplarının ihtiyaçlarına göre özelleştirilmiş açıklamalar sunmayı amaçlar. Örneğin, bir doktor için açıklanabilirlik, bir hastadan farklı bir şekilde ele alınmalıdır. Ayrıca, XAI'nin diğer yapay zeka paradigmalarıyla entegrasyonu, daha bütüncül ve etkili çözümler sunmak için önemli bir trend olarak karşımıza çıkmaktadır. Bu tür yenilikler hem kullanıcı deneyimini iyileştirecek hem de sistemlerin benimsenme oranını artıracaktır (N. L. Rane & Paramesha, 2024)(Ara, 2024)

XAI, yapay zeka sistemlerinin şeffaflık, etik ve kullanıcı güveni gibi temel sorunlarına çözüm sunarak, yapay zeka teknolojisinin evrimine önemli bir katkı sağlamaktadır. Bununla birlikte, model karmaşıklığı ve açıklanabilirlik arasındaki dengeyi

sağlamak gibi zorluklar, bu alanda devam eden araştırmaların önemini vurgulamaktadır. Gelecekte, XAI'nin daha geniş bir kullanıcı kitlesi için daha erişilebilir ve etkili hale gelmesi beklenmektedir.

3. XAI'NIN DERİN ÖĞRENME MODELLERİNDE KULLANIMI

A Derin öğrenme modellerinde Açıklanabilir AI (XAI) yöntemleri, günümüzün karmaşık yapay zeka sistemlerinin işleyişini daha anlaşılır hale getirmek ve güvenilirliğini artırmak açısından kritik bir öneme sahiptir. Bu yöntemlerin merkezinde, özellikle özellik önem analizi gibi yaklaşımlar yer alır. Özellik önem analizi, bir modelin tahminlerini oluştururken hangi girdilere ne derece bağımlı olduğunu değerlendirerek kullanıcıların bu süreçleri daha iyi anlamasına olanak tanır. Böylelikle, sadece yapay zeka modellerinin şeffaflığı artırılmakla kalmaz, aynı zamanda sistemlerin hata kaynakları veya önyargıları tespit edilerek güvenli bir şekilde iyileştirilmesi sağlanır. Bu bağlamda, SHAP (Shapley Additive Explanations) ve LIME (Local Interpretable Model-Agnostic Explanations) gibi popüler açıklanabilirlik teknikleri, girdi özelliklerinin model kararları üzerindeki etkisini açık bir şekilde ortaya koyarak hem teknik uzmanlar hem de son kullanıcılar için kolayca anlaşılabilir bilgiler sunar.

3.1. SHAP (Shapley Additive Explanations)

SHAP, işbirlikçi oyun teorisine dayanan birleşik bir özellik önemi ölçüsü sağlayan güçlü bir XAI yöntemidir. Bu yaklaşım, bir modelin kararına her bir girdinin ne derece katkıda bulunduğunu hassas bir şekilde hesaplamaya olanak tanır. SHAP değerlerinin temel avantajlarından biri, sunduğu açıklamaların tutarlılığı ve matematiksel sağlamlığıdır. Bu özellik, SHAP'ı özellikle karmaşık modellerde uygulanabilir hale getirir. Örneğin, bir kredi tahsis modeli için SHAP, bir başvurunun reddedilme nedenini detaylı bir şekilde açıklayarak hangi özelliklerin

bu kararı en çok etkilediğini gösterebilir. Bu bilgi, hem müşterinin durumu anlamasına hem de finans kuruluşunun karar verme süreçlerini daha şeffaf hale getirmesine yardımcı olur (Sarvesh Koli Komal Bhat Prajwal Korade, 2024).

SHAP ayrıca geniş bir model yelpazesinde uygulanabilirliği ile dikkat çeker. DeepShap adı verilen bir genişletme, SHAP yönteminin sinir ağı tabanlı derin öğrenme modelleriyle entegre edilmesini sağlar. Bu entegrasyon, SHAP'ı derin öğrenmenin karmaşık ve çoğu zaman opak olan yapılarını açıklamak için ideal bir araç haline getirir. Örneğin, bir görüntü sınıflandırma modelinde, DeepShap, bir modelin hangi piksel gruplarına odaklandığını açıklayarak modelin görsel verileri nasıl işlediğini görselleştirebilir. Bu, özellikle sağlık sektöründe, bir radyoloji görüntüsündeki kanser belirtilerini değerlendiren modellerde, modelin odaklandığı bölgeleri anlayarak kararın doğruluğunu ve güvenilirliğini değerlendirmek için kritik bir değer taşır (Ruiz, Gowtam Peesapati, & Cortes, 2023).

3.2. LIME (Local Interpretable Model-Agnostic Explanations)

LIME, model agnostik bir yöntem olarak, bir modelin yalnızca belirli bir tahminini anlamaya odaklanır. Yöntem, modelin yerel bir bölgesinde basitleştirilmiş bir açıklama üretmek için tahmin edilen sonucu taklit eden daha basit bir model oluşturur. Bu yaklaşım, özellikle çok sayıda özellik içeren yüksek boyutlu verilerle çalışan kullanıcılar için faydalıdır. Örneğin, bir hastanın diyabet riski olup olmadığını belirleyen bir modelde, LIME, o hastaya özel olarak hangi faktörlerin bu kararı etkilediğini açıklayabilir. Bu bilgi, klinisyenlerin, modelin kararlarını değerlendirme sürecini anlamasına ve modelin sonuçlarını hastalarla etkili bir şekilde paylaşmasına olanak tanır (Singh, Rani, & Srilakshmi, 2024).

3.3. Şeffaflık ve Güven Artışı

SHAP ve LIME gibi yöntemlerin bir diğer önemli katkısı, yapay zeka modellerine yönelik güveni artırmalarıdır. Bu yöntemler, kullanıcıların yalnızca model sonuçlarını anlamasına değil, aynı zamanda bu sonuçların ne kadar mantıklı ve güvenilir olduğunu değerlendirmesine olanak tanır. Örneğin, bir yüz tanıma modelinde SHAP, hangi yüz özelliklerinin tanıma kararını etkilediğini açıklayabilir ve bu bilgiler, modelin ayrımcılık içerip içermediğini kontrol etmek için kullanılabilir. Benzer şekilde, LIME, bir kararın tutarlı olup olmadığını test etmek için karar mekanizmasının basitleştirilmiş bir analizini sağlayabilir. Bu tür açıklamalar, yapay zekanın etik ve hukuki gerekliliklere uyumunu da destekler (Wang, 2024)(Salih et al., 2024).

3.4. Adalet ve Önyargı Azaltma

XAI yöntemleri, yalnızca şeffaflık sağlamakla kalmaz, aynı zamanda algoritmik önyargıları belirlemek ve düzeltmek için bir araç olarak da hizmet eder. SHAP, özelliklerin model sonuçlarına nasıl katkıda bulunduğunu açıkça göstererek, modelin belirli gruplar lehine veya aleyhine önyargılı çalışıp çalışmadığını tespit etme olanağı sunar. Örneğin, bir işe alım algoritması cinsiyet veya etnik köken gibi adil olmayan özelliklere dayalı olarak kararlar alıyorsa, SHAP bu eğilimleri kolayca ortaya çıkarabilir ve algoritmanın yeniden eğitilmesi için temel sağlayabilir. Bu tür iyileştirmeler, yapay zekanın etik standartlara uygun şekilde çalışmasını garanti altına alır (Ara, 2024).

3.5. Derin Öğrenme ve XAI

SHAP ve LIME gibi yöntemler, geleneksel makine öğrenimi modellerinin yanı sıra derin öğrenme modellerine de uygulanabilir hale gelmiştir. Derin öğrenme modellerinin karmaşıklığı göz önüne alındığında, bu modellerin şeffaflığını artırmak ve yorumlanabilirliğini sağlamak giderek daha önemli hale gelmiştir. DeepShap gibi yöntemler, sinir ağlarının iç işleyişini analiz

ederek, bu tür sistemlerin karar alma süreçlerini açıklamayı mümkün kılar. Örneğin, bir doğal dil işleme modelinde, SHAP, belirli kelimelerin veya ifadelerin tahmin edilen sonuca nasıl katkıda bulunduğunu belirleyebilir. Bu tür açıklamalar, modelin önyargılı bir şekilde dil kullanımını öğrenip öğrenmediğini kontrol etmek için değerli bilgiler sağlayabilir.

SHAP ve LIME gibi XAI yöntemleri, yapay zeka sistemlerinin açıklanabilirliğini artırarak kullanıcıların bu sistemlere olan güvenini artırır ve karar süreçlerini daha anlaşılır hale getirir. Bu yöntemler, özellikle etik, şeffaflık ve adalet gibi temel değerleri destekleyerek yapay zekanın geniş çapta kabul görmesini ve kullanılmasını kolaylaştırır. Aynı zamanda hem özellik önem analizi hem de model adaletinin geliştirilmesi gibi alanlarda sundukları katkılar, XAI'nin yapay zekanın geleceğinde vazgeçilmez bir rol oynayacağını göstermektedir (Kedar, 2024) .

4. MATERİYAL METOT


Bu çalışma, SHAP ve LIME yöntemlerini kullanarak, XGBoost sınıflandırıcı modeli ile diyabet tahmini yapmayı ve modelin karar mekanizmalarını yorumlanabilir hale getirmeyi hedeflemiştir. Özellikle diyabet gibi kronik hastalıkların erken teşhisinde, yapay zeka tabanlı yaklaşımların doğruluk ve güvenilirlik açısından sağlık sektöründe önemli bir rol oynadığı bilinmektedir. Çalışmanın temel amacı, yüksek performanslı bir tahmin modeli oluşturma yanı sıra, bu modelin karar alma süreçlerini anlamak ve açıklamak için modern XAI yöntemlerini kullanmaktır.

Çalışmada, yaygın olarak kullanılan “PIMA Indian Diabetes” veri seti kullanılmıştır. Bu veri seti, toplamda 768 bireye ait 8 özellikten oluşmaktadır ve diyabet teşhisi (pozitif veya negatif) üzerine odaklanmaktadır. Özellikler arasında Glikoz Seviyesi, Vücut Kitle İndeksi (BMI), Kan Basıncı, İnsülin Seviyesi, Gebelik Sayısı, Yaş, Cilt Kalınlığı ve Genetik Miras Fonksiyonu

bulunmaktadır. Veri setindeki her örnek, bireyin geçmiş sağlık ölçümleri ve diyabet teşhis durumunu temsil etmektedir. Veri setinde yer alan eksik veya yanlış girişler tespit edilerek uygun yöntemlerle doldurulmuştur. Örneğin, sıfır değerine sahip ölçümler (ör. insülin seviyesi sıfır olan girişler) medyan değerler ile değiştirilmiştir. Özellikler arasında ölçekleme farkı olduğundan, tüm değerler “min-max normalizasyonu” ile 0 ile 1 arasında yeniden ölçeklendirilmiştir. Veri, eğitim ve test seti olarak %80 eğitim ve %20 test oranında bölünmüştür. Eğitim aşamasında yapay zeka algoritması olarak XGBoost Sınıflandırıcı kullanılmıştır. XGBoost, gradyan artırma (gradient boosting) yöntemine dayalı, doğruluk oranı yüksek ve hızlı çalışan bir makine öğrenmesi algoritmasıdır. Model parametreleri olarak Öğrenme hızı (“learning rate”): 0.1, Maksimum derinlik (“max depth”): 6, Ağaç sayısı (“n_estimators”): 100 olarak seçilmiştir. Eğitim sonucunda, modelin genel doğruluk oranı “%88,4” olarak hesaplanmıştır. Bu oran, diyabet teşhisi gibi karmaşık bir problemde modelin yüksek performans sergilediğini göstermektedir.


4.1. SHAP Yöntemi

SHAP işbirlikçi oyun teorisine dayalı, model çıktılarındaki her bir girdinin etkisini ölçen güçlü bir açıklanabilir yapay zeka yöntemidir. SHAP, yalnızca modelin karar mekanizmalarını anlamakla beraber, aynı zamanda bu mekanizmaları görselleştirerek karmaşık yapay zeka modellerini daha şeffaf hale getirir. SHAP yöntemiyle tüm veri seti üzerinde çalışılarak, her bir özelliğin model tahminlerine ne derece katkıda bulunduğu hesaplanmıştır. Glikoz seviyesi ve vücut kitle indeksinin (BMI), model tahmininde en belirleyici özellikler olduğu Şekil 1’de görülmektedir.



Şekil 6 Model tahminindeki en belirleyici özellikler

SHAP, belirli bir bireyin diyabet teşhis tahmini için detaylı bir analiz sunarak, modelin hangi özelliklere odaklandığını görselleştirmiştir. Örneğin, glikoz seviyesi yüksek olan ve vücut kitle indeksi belirli bir eşik değeri aşan bireyler için, SHAP değerleri, bu özelliklerin karar üzerindeki olumlu veya olumsuz etkisini net bir şekilde Şekil 2’de görülmektedir.




Şekil 5 Rastgele bir hastanın değerlerinde sonucuna olan etkisi

4.2. LIME Yöntemi

LIME, bir modelin belirli bir tahminini açıklamaya odaklanan model agnostik bir yöntemdir. LIME, karmaşık bir modelin yerel olarak basitleştirilmiş bir temsilini oluşturarak, bireysel tahminlerin nedenlerini analiz eder. Diyabet teşhisi yapılan bir bireyin tahmini üzerinde çalışılarak, modelin kararına en çok hangi özelliklerin etki ettiğini görselleştirmiştir. Örneğin, bir bireyin glikoz seviyesi, yaş ve vücut kitle indeksinin model tahminine katkısı analiz edilmiştir. Özellikler segmentlere ayrılarak, her bir segmentin tahmin üzerindeki etkisi ayrı ayrı değerlendirilmiştir. LIME bu analizi görselleştirerek karar sürecini kullanıcı dostu hale getirmiştir. LIME yöntemiyle bir bireyin diyabet teşhis tahminine katkı sağlayan özelliklerin görselleştirilmesi. Grafikte, glikoz seviyesi ve BMI gibi kritik özelliklerin model kararını nasıl etkilediği Şekil 3'te gösterilmiştir.

4.3. Değerlendirme



Şekil 7 Rastgele bir hastanın değerlerinde sonucuna olan etkisi

Bu çalışma, XGBoost sınıflandırıcı modelinin diyabet teşhisi üzerindeki karar mekanizmalarını açıklamak amacıyla SHAP ve LIME yöntemlerini kullanmıştır. Çalışmanın sonuçları, XAI yöntemlerinin karmaşık modellerde şeffaflık sağlamada ve model davranışlarını açıklamada etkili olduğunu ortaya koymaktadır:

4.3.1. SHAP Analizi:

SHAP yöntemi, modelin genel davranışını anlamak için uygun bir araçtır. Çalışmada, glikoz seviyesi ve vücut kitle indeksinin diyabet teşhisinde en önemli faktörler olduğu gösterilmiştir. Ayrıca, SHAP görselleştirmeleri, bireysel tahminlerde modelin hangi verilere dayandığını açıkça ortaya koymuştur.

4.3.2. LIME Analizi:

LIME yöntemi, bireysel tahminlerin detaylı analizini sağlamıştır. Özellikle bireysel özelliklerin tahminlere olan katkısını görselleştiren LIME, kullanıcıların belirli bir kararın ardındaki nedenleri anlamasına olanak tanımıştır.

4.3.3. Genel Değerlendirme:

Her iki yöntem de diyabet teşhisi gibi hassas bir alanda model şeffaflığını artırmış ve kullanıcı güvenini sağlamıştır. SHAP, genel bir bakış sunarken, LIME bireysel kararların incelenmesi için etkili bir araçtır.

5. SONUÇ

Bu çalışmada, XAI yöntemleri olan SHAP ve LIME, XGBoost sınıflandırıcı modeli ile diyabet teşhisi problemi üzerinde değerlendirilmiştir. Yapılan analizler, XAI yöntemlerinin, model kararlarının anlaşılabilirliğini artırma ve kullanıcı güvenini sağlama konusunda güçlü araçlar olduğunu göstermiştir. SHAP yöntemi, modelin genel davranışını anlamak için kapsamlı ve tutarlı bir açıklama sağlamıştır. Glikoz seviyesi ve vücut kitle indeksinin, diyabet teşhisinde en belirleyici faktörler olduğu ortaya konulmuştur. Görselleştirmeler, bireysel tahminlerde hangi özelliklerin karar süreçlerine olumlu veya olumsuz katkıda bulunduğunu açıkça göstermiştir. LIME yöntemi, bireysel tahminlerin detaylı bir şekilde incelenmesine olanak tanımıştır. Yerel olarak basitleştirilmiş modellerle üretilen açıklamalar, kullanıcıların spesifik kararların ardındaki nedenleri anlamalarını sağlamıştır. Özellikle bireysel glikoz seviyesi ve yaş gibi değişkenlerin tahmin üzerindeki etkisi görselleştirilmiştir.

SHAP ve LIME yöntemleri, model şeffaflığını artırarak yapay zeka modellerinin "kara kutu" doğasını ortadan kaldırmaya yardımcı olmuştur. Elde edilen sonuçlar, diyabet gibi kronik hastalıkların teşhisinde yapay zeka sistemlerinin hem doğruluk hem de güvenilirlik açısından geliştirilebileceğini göstermektedir. SHAP, modelin genel davranışını anlamak için daha uygun bir araç olurken, LIME bireysel kararların detaylandırılmasında etkili bir yöntem olarak öne çıkmıştır.

Bu çalışma, XAI yöntemlerinin tıbbi teşhis alanında kullanım potansiyelini vurgulamış ve şeffaf, açıklanabilir yapay zeka sistemlerinin geliştirilmesi için bir temel sunmuştur. Gelecekte, daha büyük ve çeşitlendirilmiş veri setleri üzerinde yapılan analizler, bu yaklaşımların daha geniş bir uygulama alanına yayılmasını sağlayabilir. Ayrıca, SHAP ve LIME gibi yöntemlerin diğer XAI araçlarıyla entegrasyonu, daha etkili ve kullanışlı açıklama mekanizmalarının geliştirilmesine katkıda bulunabilir.

KAYNAKÇA

- Adewale Abayomi Adeniran, Amaka Peace Onebunne, & Paul William. (2024). Explainable AI (XAI) in healthcare: Enhancing trust and transparency in critical decision-making. *World Journal of Advanced Research and Reviews*, 23(3), 2447–2658. Retrieved from <https://doi.org/10.30574/wjarr.2024.23.3.2936>
- Ara, M. (2024, October 3). Enhancing AI Transparency for Human Understanding: A Comprehensive Review. Retrieved from <https://doi.org/10.20944/preprints202410.0262.v1>
- Kedar, Ms. M. M. (2024). Exploring the Effectiveness of SHAP over other Explainable AI Methods. *INTERANTIONAL JOURNAL OF SCIENTIFIC RESEARCH IN ENGINEERING AND MANAGEMENT*, 08(06), 1–5. Retrieved from <https://doi.org/10.55041/IJSREM35556>
- Morato de Andrade, O., & Sousa Alves, M. A. (2024). From ‘black box’ to ‘glass box’: using Explainable Artificial Intelligence (XAI) to reduce opacity and address bias in algorithmic models. *Revista Thesis Juris*, 13(1), 03–25. Retrieved from <https://doi.org/10.5585/13.2024.26510>
- Rane, J., Kaya, Ö., Mallick, S. K., & Rane, N. L. (2024). Enhancing black-box models: Advances in explainable artificial intelligence for ethical decision-making. In *Future Research Opportunities for Artificial Intelligence in Industry 4.0 and 5.0*. Deep Science Publishing. Retrieved from https://doi.org/10.70593/978-81-981271-0-5_4
- Rane, N. L., & Paramesha, M. (2024). Explainable Artificial Intelligence (XAI) as a foundation for trustworthy artificial intelligence. In *Trustworthy Artificial Intelligence in Industry and Society*. Deep Science Publishing. Retrieved from https://doi.org/10.70593/978-81-981367-4-9_1

- Ruiz, N. S., Gowtam Peesapati, S. K., & Cortes, J. M. (2023). XAI-Assisted Radio Resource Management: Feature Selection and SHAP Enhancement. In *ICC 2023 - IEEE International Conference on Communications* (pp. 2516–2521). IEEE. Retrieved from <https://doi.org/10.1109/ICC45041.2023.10279520>
- Salih, A. M., Raisi-Estabragh, Z., Galazzo, I. B., Radeva, P., Petersen, S. E., Lekadir, K., & Menegaz, G. (2024). A Perspective on Explainable Artificial Intelligence Methods: SHAP and LIME. *Advanced Intelligent Systems*. Retrieved from <https://doi.org/10.1002/aisy.202400304>
- Sarvesh Koli Komal Bhat Prajwal Korade, D. M. A. M. O. K. (2024). Unlocking Machine Learning Model Decisions: A Comparative Analysis of LIME and SHAP for Enhanced Interpretability. *Journal of Electrical Systems*, 20(2s), 598–613. Retrieved from <https://doi.org/10.52783/jes.1480>
- Singh, J., Rani, S., & Srilakshmi, G. (2024). Towards Explainable AI: Interpretable Models for Complex Decision-making. In *2024 International Conference on Knowledge Engineering and Communication Systems (ICKECS)* (pp. 1–5). IEEE. Retrieved from <https://doi.org/10.1109/ICKECS61492.2024.10616500>
- Wang, Y. (2024). A Comparative Analysis of Model Agnostic Techniques for Explainable Artificial Intelligence. *Research Reports on Computer Science*. Retrieved from <https://doi.org/10.37256/rrcs.3220244750>

EKG SINIFLANDIRMADA GRAF DÖNÜŞÜMÜ TEMELLİ YAKLAŞIMLAR¹

Gökhan KUTLUANA²

1. GİRİŞ

Elektrokardiyogram (EKG) kalbin elektriksel aktivitesini kaydeden ve kardiyolojik rahatsızlıkların belirlenmesi ve kalbin mevcut durumu hakkında detaylı bilgi veren önemli bir tanı ve teşhis aracıdır. EKG'den elde edilen verilerle ölçüm yapılan hastanın sağlıklı olup olmadığı, sağlıklı değil ise kalpteki atriyal fibrilasyon, miyokardiyal enfarktüs, taşikardi vb. ritim bozuklukları tespit edilebilmektedir(Davey & Sharman, 2018). Bilgisayar teknolojilerinin gelişimi ve sağlık alanında kullanımının artması ile EKG verilerinin yorumlanmasında bilgisayar tabanlı sistemler yaygın bir kullanım alanı bulmaktadır (Liu vd., 2021).

Zaman serileri graflar ile ifade edilebilen verilerdendir. Tıbbi, fiziksel, biyolojik, meteorolojik ve finansal birçok alanda oluşan zaman serisi verilerini karakterize etmek için yapılan veri analizi hayati öneme sahiptir(Ismail Fawaz vd., 2019; Silva vd., 2021; Supriya vd., 2016). EKG'de zaman serisi verilerinden ve kardiyolojik rahatsızlıkların tespit edilmesi için önemli bir araçtır.

EKG verilerinin sınıflandırılmasında geleneksel makine öğrenmesi yöntemleri ile modern derin öğrenme yaklaşımları yaygın olarak kullanılmaktadır. EKG verilerinin sınıflandırılmasında makine öğrenmesine alternatif olarak kullanılan derin öğrenme yöntemleri verilerden daha iyi özellik çıkarma ve daha

¹ Bu çalışma Ulusal Tez Merkezi 841296 Numaralı, "Graf dönüşümlü derin öğrenme ile EKG sinyallerinin sınıflandırılması" başlıklı Doktora Tezinden üretilmiştir.

² Dr. Öğr. Üyesi, Bartın Üniversitesi, Mühendislik, Mimarlık ve Tasarım Fakültesi, Bilgisayar Mühendisliği Bölümü, gkutluana@bartin.edu.tr, ORCID: 0000-0001-5004-8334

yüksek sınıflandırma performansı göstermesi sebebiyle yaygın bir kullanım alanı bulmuştur. Ve birçok EKG sınıflandırma çalışmasında kullanılmıştır (Al-Huseiny vd., 2020; Baloglu vd., 2019; Zhao vd., 2020). Derin öğrenme metotları içerisinde graf tabanlı çalışan yaklaşımlarda son yıllarda EKG sınıflandırma da kullanılmaktadır. Graf Evrişim Ağları (GCN) ve çeşitli türetimleri ve varyantları olan Graf Dikkat Ağları (GATS), Graf Örnek ve Toplama Ağları (GraphSAGE) ile yapılan çalışmalar bulunmaktadır (Andayeshgar vd., 2022; Jiang vd., 2020; Ma & Xia, 2023; Zhong vd., 2022).

Bir zaman serisi verisi olan EKG, graf dönüşümü temelli yaklaşımlar kullanılarak graf olarak temsil edilebilmektedir. EKG, graf özelliklerinden önemli öznitelikler çıkartılarak sınıflandırılabilirdiği gibi, doğrudan graf evrişim ağları ile öznitelikler çıkartılarak da sınıflandırılabilir. Graf dönüşümü temelli yaklaşımların kullanıldığı bu alanda birçok çalışma bulunmaktadır. (Kulp vd., 2016; Li vd., 2021; McCullough vd., 2017; Zhang & Small, 2006). Graf dönüşümü için görünürlük, geçişlilik ve yakınlık temelli yaklaşımlar bulunmaktadır. Ve çeşitli zaman serisi veri analizi çalışmalarında bu yaklaşımlar kullanılmıştır. Graf dönüşümü için kullanılan yaklaşımlarda veri noktalarının düğüm olduğu ve bu noktalar arasındaki görünürlük ilişkisinin ağı oluştururken bağlantı olarak belirlendiği görünürlük grafları kullanılmaktadır. Yakınlık ağlarında ise zaman serisi veri noktalarının durumlarının düğüme, bu noktalar arasındaki mesafe ve benzerlik değerlerinin de bağlantılara dönüştürülmektedir. Bir diğer yaklaşım olan geçiş ağı yaklaşımında ise veri içerisindeki ardışık noktaların çeşitli sembollere dönüştürülmesi ve ardından da belirlenen bir geçiş fonksiyonu ile sembollerin düğüme ve geçiş işleminin de ağlara dönüştürülmektedir.

Bu çalışmada bir zaman serisi olan EKG'nin sınıflandırılmasında graf dönüşümü temelli yaklaşımların kullanılma potansiyellerinden bahsedilerek bu alana dair genel bir bakış sağ-

lanmaya çalışılmıştır. Bu kapsamda sırasıyla zaman serisi ve elektrokardiyogram, zaman serisi verilerinin graflara dönüşümü ve ilgili çalışmalara yer verilmiştir.


2. ZAMAN SERİLERİ VE EKG

Zaman içinde birbirini izleyen eşit aralıklı noktalarda alınan bir veri dizisi olan zaman serisi istatistik, sinyal işleme, örüntü tanıma, ekonometri, finans, deprem tahmini, biyomedikal sinyallerin analizi vb. zamansal ölçüm içeren birçok alanda kullanılmaktadır (Lawton, 2001; Lund, 2007). Kullanılan bu alanlardan biri de EKG sinyalleridir.

2.1. Zaman Serisi

Biçimsel olarak, bir $Y = (Y_1, \dots, Y_t)$ zaman serisi, t zamanı tarafından indekslenen $\{Y_t\}_t$ rasgele değişkenlerin bir dizisi olan stokastik bir sürecin veya tamamen açık bir matematiksel ilişki ile temsil edilebilen dinamik bir deterministik sürecin sonlu bir gerçekleşmesidir. Zaman serilerinin analizinde verinin doğrusal olması ve doğrusal olmamasına göre farklı yaklaşımlar bulunmaktadır. Gerçek dünyada elde edilen birçok zaman serisi verisi hem doğrusal olmayan yapıda hem de yüksek boyutludur. Bu verilerin analizi için ağ bilimi temelli bazı yaklaşımlar bu verilerin yapısını anlamak için yeni öngörüler ve yeni bakış açıları sunmaktadır (Silva vd., 2021).


Tek değişkenli zaman serisi verileri bir t zamanı boyunca ölçülen Y_t değerleridir. Çok değişkenli zaman serileri bir vektör tarafından bir t zamanı boyunca $Y_t = (Y_{1,t}, Y_{2,t}, \dots, Y_{1,m})'$ ile ifade edilir. Çok değişkenli zaman serilerinin analizi standart istatistiksel yöntemlerden farklı olmalıdır. Bu nedenle çok değişkenli zaman serileri için doğrusal ve doğrusal olmayan modeller özel olarak geliştirilmiştir (Wei, 2019). Şekil 1'de çeşitli zaman serisi örnekleri verilmiştir.



Şekil 4. Çeşitli zaman serisi örnekleri (Rob J Hyndman & George, 2014)

2.2. EKG

Elektrokardiyografi vücudun çeşitli bölgelerindeki deri yüzeylerine yerleştirilen elektrotlar vasıtası ile kalbin elektriksel aktivitesini ölçen bir metottur. Ölçüm işleminin grafiğe dönüştürülmesi ile elektrokardiyogramlar oluşmaktadır. Oluşan elektrokardiyogramlar kardiyolojik hastalıkların tespit edilmesinde yardımcı olmaktadır. Elektrokardiyogram grafikleri kalbin iletim sistemi unsurlarından olan sinoatriyel düğümden itibaren purkinje fiberlerine olan süreçte elektriksel aktivitenin ölçülmesi ile oluşmaktadır. Kalp kas hücrelerinin elektriksel yüklerindeki değişimlerle sinyal verileri oluşmaktadır. Elektriksel aktivite sonucunda oluşan EKG dalga morfolojisi Şekil 2’de verilmiştir.



Şekil 5. EKG dalga morfolojisi (Goldberger vd., 2013).


Atriyaillerin uyarılması ve depolarize olması ile P dalgası oluşmaktadır. Ventriküllerin uyarılması ve depolarize olmasıyla QRS kompleksi oluşmaktadır. Belli bir süre geçtikten sonra ventriküllerin repolarizasyonu ile ST segmenti, T dalgası ve U dalgası oluşmaktadır.

2.2.1. Elektrokardiyogram Ölçümü

Vücudun çeşitli noktalarına elektrotlar yerleştirilerek kalp akımlarının voltajları saptanabilmektedir. Kalbin aktivitesini farklı bakış açıları ile değerlendirilmesini sağlayan elektrotların arasındaki voltaj farkları derivasyon olarak adlandırılmaktadır. EKG sinyallerini grafik olarak oluşturmak için genellikle 12-derivasyon EKG Ölçümü kullanılmaktadır (Goldberger vd., 2013; Güven, 2021).

12-derivasyon EKG, vücutta yer alan uzuvlara ve göğüs kısmına yerleştirilen 10 farklı elektrot ile kalbin 12 farklı elektriksel aktivite ölçümünü sağlamakta ve bu ölçümler ile kalbin elektriksel aktivitesine farklı açılardan değerlendirebilme imkânı sağlamaktadır. Oluşan bu derivasyonlar, uzuvlar arası elektriksel voltaj farklılıklarının ölçüldüğü I, II, III, aVR, aVL ve aVF uzuv (ekstremita) derivasyonları ile göğüs kafesinde yer alan 6 farklı yerleşimdeki elektrotlar arasındaki voltaj farklılıklarının ölçüldüğü V1, V2, V3, V4, V5, V6 göğüs derivasyonları olmak üzere

2 kısma ayrılır (Goldberger vd., 2013). Şekil 3'te 12-derivasyon EKG'ye ait sinyal formasyonu verilmiştir.



Şekil 6. 12-Derivasyon EKG.

3. ZAMAN SERİSİ VERİLERİNİN GRAFLARA DÖNÜŞÜMÜ


Zaman serisi verilerinin graflara dönüşümü için görünür-lük temelli, geçiş temelli ve yakınlık temelli graf yapıları kullanılmaktadır. Kullanılan bu yaklaşımlar, zaman serilerindeki verileri ve veriler arasındaki ilişkileri ortaya çıkartmakta ve çeşitli analizler yapılmasına olanak sağlamaktadır.

3.1. Graflar ve Kompleks Ağlar

Doğa ve toplumda yer alan internet, sosyal ağlar, biyolojik ağlar, elektrik dağıtım şebekeleri, sinir sistemi vb. birçok sistem kompleks ağ olarak tanımlanır (Barabási, 2016). Graflar bu sistemlerde yer alan bileşenleri düğüm ve aralarındaki ilişkileri tanımlayan ve kompleks sistemleri ifade etmek için kullanılan yapılardır.

Matematiksel olarak bir ağ, graf olarak ifade edilir. Bir graf V ve E çiftinin kümesinden $G = \{V(G), E(G)\}$ oluşur. V grafını oluşturan N adet düğümden oluşan düğümler dizisi $V = \{V_1, V_2, V_3, \dots, V_N\}$, grafta yer alan düğümler arasındaki bağlantılar (link, kenar) kümesi ise E ile ifade edilir. Grafta yer

alan iki düğüm v_i ve v_j olmak üzere, eğer $(v_i, v_j) \in E(G)$ ise bu düğümler bağlantılıdır. Graflarda düğümler arası yer alan bağlantılar yönlü veya yönsüz olabilmekte ve belirli bir ağırlık değeri alabilmektedir. Grafları düğüm ve bağlantıları ifade etmek için komşuluk matrisi kullanılmaktadır. Komşuluk matrisi A olmak üzere düğümler arası bağlantılar eğer $(v_i, v_j) \in E(G)$ ise $A_{i,j} = 1/w_{i,j}$, yok ise 0 değerini almaktadır.



Şekil 7. (a) Yönsüz graf örneği, (b) Yönlü graf örneği, (c) Yönsüz graftan elde edilen ağırlıklı komşuluk matrisi.

Kompleks ağların analiz edilmesinde ve ağa ait önemli bilgilerin elde edilmesinde komşuluk matrisi kullanılmaktadır. Kullanılan graf yapısı ile ağa ait parametreler hesaplanabilir. Hesaplanan bu parametrelerin bir kısmı ağa ait genel bilgi verirken, bir kısmı da düğüm ve düğüm bağlantısalılıkları ile ilgili bilgiler de vermektedir.

Gerçek dünyada yer alan sistemler alt sistemlerden ve dış sistemlerle bağlantılı olabilir. Bu bağlantılı olunan alt sistemler ve dış sistemlerdeki veriler sistemi anlamada yardımcı olabilir. Bu verilerin analiz edilmesi, tek katmanlı ağ yapıları yerine çok katmanlı ağlarla gerçekleştirilebilir. Çok katmanlı ağlar, tek katmanlı ağ yaklaşımını da kullanarak farklı özelliklerle oluşturulabilecek tek katmanlı farklı ağlar arasındaki düğümlerin birbirine bağlanabildiği ve her katmanda yer alan düğümlerin birbirlerinin alt kümesi olduğu bir ağ yapısıdır (Kivelä vd., 2014; Silva vd., 2021).

3.2. Görünürlük Grafları


Zaman serilerinin graf dönüşümü için kullanılan yaklaşımlardan biri görünürlük graflarıdır. Görünürlük grafları zaman serisi veri noktalarının her biri için bir düğüm oluşturur. Bu düğümler seri içerisinde ardışık sıralı bir şekilde seçilmektedir. Grafta yer alan bağlantılar ise bu ardışık veri noktaları arasında düz bir çizgi çekildiğinde herhangi bir düğüm aradaki görünürlüğü engellemiyorsa bağlantı oluşturulur ve bu işlem bütün seri veri noktaları için yapılır (Lacasa vd., 2008). Bağlantıları oluşturmak için eşitsizlik 1 kullanılır. Eşitsizlik 1’de (t_k, Y_k) bir zaman – genlik ikilisi ve $t_i < t_k < t_j$ zamanda farklı noktaları temsil etmek üzere eşitsizliğin sağlanması, i ve j düğümleri arasında bir bağlantı tanımlanması gerektiğini gösterir.

$$Y_k < Y_j + (Y_i - Y_j) \cdot \frac{(t_j - t_k)}{(t_j - t_i)} \quad (1)$$


Formül ile elde edilen doğal görünürlük grafi olarak adlandırılmaktadır. Doğal görünürlük grafi dışında yatay görünürlük graf yapısı da bulunmaktadır. Yatay görünürlük grafi veri noktası değerlerinin dikey y eksenini baz alınarak bağlantıların oluşturulduğu daha özel bir varyantıdır. Eşitsizlik 2’de yer alan formül ile iki nokta olan i ve j arasında görünürlüğü y eksenini değerleri ile kesen bir nokta yok ise bağlantı oluşturulmaktadır. Yatay görünürlük grafları, doğal görünürlük graflarının bir alt kümesi gibi düşünülmekte ve daha yerel özelliklerin incelendiği durumlarda tercih edilebilmektedir(Silva vd., 2021). Şekil 5’te Doğal görünürlük grafi ve yatay görünürlük grafları verilmiştir.

$$Y_i, Y_j > Y_k$$

(2)



(a)



(b)

Şekil 5. (a) Doğal görünürlük ağ örneği, (b) Yatay görünürlük ağ örneği (Silva vd., 2021).

Görünürlük graflarının bu iki varyantı dışında görünürlük şartının veri noktaları arasında bir l uzunluğu sınırlandırıldığı limitli penetre görünürlük grafi, bağlantıların veri noktalarının soldan sağa doğru ilerleyerek yönlü olarak oluşturulduğu yönlü görünürlük grafi, Düğümler arası bağlantıların belirli bir ağırlık değeri ile belirlendiği ağırlıklı görünürlük grafi ve doğal görünürlük ve yatay görünürlük graflarındaki bağlantı kümelerinin birbirinden çıkarılması ile elde edilen fark görünürlük grafi diğer varyantlarıdır.

3.3. Geçiş Grafları

Geçiş grafları, zaman serisi verisini temsil etmek üzere belirlenen semboller arasında geçiş kavramına dayanan bir ağ türüdür. Ardışık veriler çeşitli sembollere dönüştürülür ve belirlenen bir geçiş fonksiyonu ile semboller düğümlere geçiş işlemi de bağlantılara dönüştürülerek graf dönüşümü gerçekleştirilir. Çeyreklik Grafları (Pineda vd., 2020), Sıralı Bölme Geçiş Grafları (Kulp vd., 2016), Kaba-Taneli Faz Uzayı Grafları (Wang & Tian, 2016) ve Görünür Grafik Grafları (Stephen vd., 2015) geçiş graflarına örnek olarak verilebilir.

Çeyreklik grafları zaman serisi veri noktalarının genlik değerlerinin çeyreklik değerlere dönüştürülerek birbirine bağlanması ile oluşturulan bir graftır. Başlangıç verisinden itibaren her bir noktanın bulunduğu çeyreklik belirlenerek ardışığındaki veri noktasının bulunduğu çeyreklik ile bağlantı oluşturulmaktadır. Graf oluşturulduğunda çeyreklikler düğümleri ve çeyreklikler arasındaki geçiş olasılığını temsil eden ağırlıklarla bağlantılar birbirine yönlü olarak bağlanmaktadır (Pineda vd., 2020). Son durumda bir zaman serisi 4×4 'lük bir komşuluk matrisi ile temsil edilebilmektedir.

Diğer geçiş grafi yaklaşımlarına incelendiğinde, Sıralı bölme geçiş graflarında ardışık veri noktaları bir desen olarak tanımlanır ve oluşan desen yapıları ardışık olarak birbirine bağ-

lanması ile oluşur. Oluşan grafta veri noktaları genlik değerleri dikkate alınarak belirli bir uzunlukta desenlere dönüştürülür. Ve belirlenen bir zaman gecikmesi ile soldan sağa belirlenen uzunluk kadar kaydırılarak bağlantılar bu desenler arası oluşturulur (Kulp vd., 2016).

Kaba-Taneli Faz Uzaı grafları zaman serisi verisini tıpkı sıralı bölme geçiş graf dönüşümünde olduğu gibi belirlenen bir w pencere genişliği ve τ zaman gecikmesi ile $D=w$ boyutunda bir sembol dizisi vektörüne dönüştürerek graf için düğümleri oluşturur. Ardışık τ zaman gecikmesi ile oluşan her bir sembol dizisi kendisinden sonra gelenle bağlantı kurarak graftaki bağlantılar yönlü olarak oluşturulmaktadır(Wang & Tian, 2016).

Görünür grafçık grafları zaman serisi verilerinin belirlenen bir w pencere genişliği ve τ zaman gecikmesi olmadan iteratif olarak verinin sonuna doğru kaydırılarak her bir kaydırmada veriye ait bir grafçığın elde edildiği, oluşan grafçıkların aynı olanlarının tekil hale getirildiği ve bu grafçıklar arası bağlantı frekanslarının incelenmesini sağlayan bir graf dönüşümü yaklaşımıdır (Stephen vd., 2015)

3.4. Yakınlık Grafları

Yakınlık grafları çok boyutlu zaman serisi verilerinin arasındaki mesafe ve benzerlik ölçülerini kullanarak graf dönüşümünü gerçekleştirmektedir. Bu yaklaşım noktaları düğüme düğümler arası benzerlik ve mesafeleri bağlantılara dönüştürür.

Yakınlık grafi yaklaşımlarından biri çevrim graflarıdır. Veri noktalarının farklı uzunluktaki alt çevrimlere bölünerek bu çevrimler her birinin düğüm olduğu ve çevrimler arasındaki bağlantıların belirlenirken korelasyon katsayısı istatistiği değerinin kullandığı graf dönüşümüdür (Zhang & Small, 2006).

Korelasyon grafları zaman serisi verilerinin belirlenen bir w pencere uzunluğunda mümkün olan bütün alt parçaların

ağda düğüm olarak tanımlandığı ve bu parçaların aralarındaki bağlantıların Pearson korelasyonu ile hesaplandığı ve belirlendiği bir graf dönüşümüdür (Yang & Yang, 2008). Yineleme grafları ise zaman serisi verilerinin belirlenen bir w-boyutlu faz uzayına dönüştürüldüğü ve her bir veri noktasının vektör olarak ifade edildiği ve bu noktaların serideki diğer noktalar ile olan ilişkilerinin bağlantıları oluşturduğu bir graf dönüşümüdür (Marwan vd., 2009).

4. EKG SINIFLANDIRMADA GRAF DÖNÜŞÜMÜ TEMELLİ YAKLAŞIMLARI KULLANILDIĞI ÇALIŞMALAR

Bir zaman serisi verisi olan EKG için, graf dönüşümü yaklaşımları sınıflandırma amacı ile birçok çalışmada kullanılmıştır. Gerçekleştirilen çalışmalarda özellikle graf dönüşümlerinin ardından elde edilen özelliklerin, geleneksel makine öğrenmesi, derin öğrenme ve graf evrişim derin öğrenme algoritmaları ile sınıflandırılmaktadır.

Graf dönüşümü yaklaşımlarından olan görünürlük grafiğinin kullanılarak EKG'nin sınıflandırıldığı birçok çalışma bulunmaktadır. (EPMoghaddam vd., 2024)'nin tek derivasyon EKG kayıtları üzerinde gerçekleştirdiği ve kardiyak aritmi tespiti için gerçekleştirdiği çalışması örnek olarak verilebilir. Bu çalışmada veri görünürlük ağırları ile graflara dönüştürülmekte ve elde edilen grafta yer alan düğümler için graf özellikleri ve zaman serisi veri özelliklerinden elde edilen zamansal ve entropi tabanlı özellikler ile bir özellik vektörü oluşturulmakta ve düğümlere atanmaktadır. Oluşturulan özellikler ve graflar graf evrişim ağırları derin öğrenme, rastgele orman ve çok katmanlı sinir ağırları ile sınıflandırılmaktadır. Görünürlük ağırlarının kullanıldığı bir diğer çalışma (Kutluana & Türker, 2024)'in ağırlıklı görünürlük graf dönüşümü kullandığı ve 12-derivasyon EKG verisinde tanı sınıflandırması yapmış olduğu çalışmasıdır. Bu çalış-

mada ağırlıklar veri noktaları arasındaki pozitif ve negatif ilişkileri ortaya koyan bir fonksiyon ile hesaplanarak komşuluk matrisi oluşturulmaktadır. Komşuluk matrisinden düğüm komşulukları elde edilmekte ve derin öğrenme yöntemleri olan RESNET ve Inception ağları ile sınıflandırılmaktadır. Bir başka örnek çalışmada ise (Oliveira vd., 2024), görünürlük grafi ve onun çok katmanlı sinyaller için geliştirilen özel bir varyantı olan vektörel görünürlük graf yaklaşımı ile EKG verileri graflara dönüştürülmüş ve oluşan graflar graf evrişim ağları ile sınıflandırmıştır.

Geçiş grafları zaman serisi verilerinin graf dönüşümü için kullanılan bir diğer yaklaşımdır. Görünürlük grafları kadar yaygın bir kullanım alanı bulmasa da çeşitli EKG sınıflandırma çalışmalarında kullanılmıştır. (Cai vd., 2024) erken doğanlarda kalp sesleri ve nabızlar gibi çeşitli fizyolojik sinyallerdeki anormallikleri tespit etmekte sıralı bölme graflarını kullanmıştır. Sıralı bölme ağları ile EKG sinyallerini graflara dönüştürmekte ve graflardan sinyallerin çeşitli özelliklerini çıkartarak destek vektör makinaları ile sınıflandırmaktadır. Bir diğer çalışmada ise (Zeinalipour & Gori, 2023) EKG sinyallerini görünürlük ağları ve çeyreklik graflarını kullanarak dönüştürmekte ve elde edilen graflardan topolojik özellikleri çıkartarak destek vektör makinaları ile sınıflandırmaktadır.

5. SONUÇ

Son yıllarda popüler olan kompleks ağların, sistemleri tanımlamada ve analiz etmede kullanımı graflar ve graflardan elde edilen bilgilerin verilerin analiz edilmesinde farklı bakış açılarını ortaya koymaktadır. Graflar kullanılarak analiz edilebilen verilerden biri de zaman serisi verileridir. EKG düzenli tekrar eden periyodik sinyallerden oluşan ancak aritmiler, kalp yetmezliği, fiziksel aktivite seviyeleri, solunumdaki değişiklikler, duygusal durum ve ilaç kullanımı vb. çeşitli sebeplerle EKG sinyallerinde düzensizliklere ve değişikliklere neden olarak sinyal karmaşıklığının artmasına neden olabilir. Bununla birlikte zaman serisi verilerini analiz etmek için kullanılan graf dönüşümü temelli yaklaşımlar EKG'nin sinyal özelliklerini analiz etmek için kullanılabilir (Kutluana & Türker, 2024). Bu konu ile ilgili gerçekleştirilmiş çalışmalara bir önceki konu başlığında değinilmiştir. Bu çalışmalar değerlendirildiğinde bir tanı aracı olarak kullanılan EKG'nin sınıflandırılmasında graf dönüşümü yaklaşımları özellikle görünürlük grafları önemli bir yer tutmaktadır. Ve bu alan ile ilgili yapılan çalışmaların yavaş yavaş popülerlik kazandığı görülmektedir.

Ayrıca graf dönüşümü temelli yaklaşımlarla birlikte derin öğrenme ve graf temelli derin öğrenme yöntemlerinin de birçok çalışmaya entegre edildiği belirlenmiştir. Özellikle EKG sınıflandırma işleminde kullanılan bu yöntemler geleneksel makine öğrenmesi yöntemlerine başarılı bir alternatif sunmaktadır.

KAYNAKÇA

- Al-Huseiny, M. S., Abbas, N. K., & Sajit, A. S. (2020). Diagnosis of arrhythmia based on ECG analysis using CNN. *Bulletin of Electrical Engineering and Informatics*, 9(3). <https://doi.org/10.11591/eei.v9i3.2172>
- Andayeshgar, B., Abdali-Mohammadi, F., Sepahvand, M., Daneshkhah, A., Almasi, A., & Salari, N. (2022). Developing Graph Convolutional Networks and Mutual Information for Arrhythmic Diagnosis Based on Multichannel ECG Signals. *International Journal of Environmental Research and Public Health*, 19(17). <https://doi.org/10.3390/ijerph191710707>
- Baloglu, U. B., Talo, M., Yildirim, O., Tan, R. S., & Acharya, U. R. (2019). Classification of myocardial infarction with multi-lead ECG signals and deep CNN. *Pattern Recognition Letters*, 122. <https://doi.org/10.1016/j.patrec.2019.02.016>
- Barabási, A.-L. (2016). Network science introduction. *Network science*, 1-27. <https://doi.org/10.1007/978-1-4614-6744-1>
- Cai, Z., Ma, C., Li, J., & Liu, C. (2024). Hybrid Amplitude Ordinal Partition Networks for ECG Morphology Discrimination: An Application to PVC Recognition. *IEEE Transactions on Instrumentation and Measurement*, 73, 1-13. <https://doi.org/10.1109/TIM.2024.3400307>
- Davey, P., & Sharman, D. (2018). The electrocardiogram. *İçinde Medicine (United Kingdom)* (C. 46, Sayı 8). <https://doi.org/10.1016/j.mpmed.2018.05.004>

- EPMoghaddam, D., Muguli, A., Razavi, M., & Aazhang, B. (2024). A graph-based cardiac arrhythmia classification methodology using one-lead ECG recordings. *Intelligent Systems with Applications*, 22. <https://doi.org/10.1016/j.iswa.2024.200385>
- Goldberger, A. L., Goldberger, Z. D., & Shvilkin, Alexei. (2013). *Goldberger's clinical electrocardiography: a simplified approach*. Elsevier/Saunders.
- Güven, G. (2021). *Parmak Ucu Elektrokardiyogram ve Ses Sin-yali Tabanlı Biyometrik Tanıma Sistemi*. Işık University.
- Ismail Fawaz, H., Forestier, G., Weber, J., Idoumghar, L., & Muller, P. A. (2019). Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery*, 33(4). <https://doi.org/10.1007/s10618-019-00619-1>
- Jiang, Z., Almeida, T. P., Schlindwein, F. S., Ng, G. A., Zhou, H., & Li, X. (2020). Diagnostic of Multiple Cardiac Disorders from 12-lead ECGs Using Graph Convolutional Network Based Multi-label Classification. *Computing in Cardiology*, 2020-September. <https://doi.org/10.22489/CinC.2020.135>
- Kivelä, M., Arenas, A., Barthelemy, M., Gleeson, J. P., Moreno, Y., & Porter, M. A. (2014). Multilayer networks. *Journal of Complex Networks*, 2(3). <https://doi.org/10.1093/comnet/cnu016>
- Kulp, C. W., Chobot, J. M., Freitas, H. R., & Sprechini, G. D. (2016). Using ordinal partition transition networks to analyze ECG data. *Chaos*, 26(7). <https://doi.org/10.1063/1.4959537>

- Kutluana, G., & Türker, İ. (2024). Classification of cardiac disorders using weighted visibility graph features from ECG signals. *Biomedical Signal Processing and Control*, 87. <https://doi.org/10.1016/j.bspc.2023.105420>
- Lacasa, L., Luque, B., Ballesteros, F., Luque, J., & Nuño, J. C. (2008). From time series to complex networks: The visibility graph. *Proceedings of the National Academy of Sciences of the United States of America*, 105(13). <https://doi.org/10.1073/pnas.0709247105>
- Lawton, R. (2001). Time Series Analysis and its Applications. *International Journal of Forecasting*, 17(2). [https://doi.org/10.1016/s0169-2070\(01\)00083-8](https://doi.org/10.1016/s0169-2070(01)00083-8)
- Li, W., Wang, H., Zhuang, L., Han, S., Zhang, H., & Wang, J. (2021). Weighted multi-scale limited penetrable visibility graph for exploring atrial fibrillation rhythm. *Signal Processing*, 189. <https://doi.org/10.1016/j.sigpro.2021.108288>
- Liu, X., Wang, H., Li, Z., & Qin, L. (2021). Deep learning in ECG diagnosis: A review. *Knowledge-Based Systems*, 227. <https://doi.org/10.1016/j.knosys.2021.107187>
- Lund, R. (2007). Time Series Analysis and Its Applications: With R Examples. *Journal of the American Statistical Association*, 102(479). <https://doi.org/10.1198/jasa.2007.s209>
- Ma, H., & Xia, L. (2023). Atrial Fibrillation Detection Algorithm Based on Graph Convolution Network. *IEEE Access*, 11. <https://doi.org/10.1109/ACCESS.2023.3291352>

- Marwan, N., Donges, J. F., Zou, Y., Donner, R. v., & Kurths, J. (2009). Complex network approach for recurrence analysis of time series. *Physics Letters, Section A: General, Atomic and Solid State Physics*, 373(46). <https://doi.org/10.1016/j.physleta.2009.09.042>
- McCullough, M., Small, M., Iu, H. H. C., & Stemler, T. (2017). Multiscale ordinal network analysis of human cardiac dynamics. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 375(2096). <https://doi.org/10.1098/rsta.2016.0292>
- Oliveira, R. F., Moreira, G. J. P., Freitas, V. L. S., & Luz, E. J. S. (2024). *Leveraging Visibility Graphs for Enhanced Arrhythmia Classification with Graph Convolutional Networks*. <http://arxiv.org/abs/2404.15367>
- Pineda, A. M., Ramos, F. M., Betting, L. E., & Campanharo, A. S. L. O. (2020). Quantile graphs for EEG-based diagnosis of Alzheimer's disease. *PLoS ONE*, 15(6). <https://doi.org/10.1371/journal.pone.0231169>
- Rob J Hyndman, & George, A. (2014). Forecasting: Principles and Practice. *Principles of Optimal Design, September*.
- Silva, V. F., Silva, M. E., Ribeiro, P., & Silva, F. (2021). Time series analysis via network science: Concepts and algorithms. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 11(3). <https://doi.org/10.1002/widm.1404>
- Stephen, M., Gu, C., & Yang, H. (2015). Visibility graph based time series analysis. *PLoS ONE*, 10(11). <https://doi.org/10.1371/journal.pone.0143015>

- Supriya, S., Siuly, S., Wang, H., Cao, J., & Zhang, Y. (2016). Weighted Visibility Graph with Complex Network Features in the Detection of Epilepsy. *IEEE Access*, 4. <https://doi.org/10.1109/ACCESS.2016.2612242>
- Wang, M., & Tian, L. (2016). From time series to complex networks: The phase space coarse graining. *Physica A: Statistical Mechanics and its Applications*, 461. <https://doi.org/10.1016/j.physa.2016.06.028>
- Wei, W. W. S. (2019). Multivariate time series analysis and applications. İçinde *Multivariate Time Series Analysis and Applications*. <https://doi.org/10.1002/9781119502951>
- Yang, Y., & Yang, H. (2008). Complex network-based time series analysis. *Physica A: Statistical Mechanics and its Applications*, 387(5-6). <https://doi.org/10.1016/j.physa.2007.10.055>
- Zeinalipour, K., & Gori, M. (2023). Graph Neural Networks for Topological Feature Extraction in ECG Classification. İçinde *Smart Innovation, Systems and Technologies* (C. 360). https://doi.org/10.1007/978-981-99-3592-5_2
- Zhang, J., & Small, M. (2006). Complex network from pseudo-periodic time series: Topology versus dynamics. *Physical Review Letters*, 96(23). <https://doi.org/10.1103/PhysRevLett.96.238701>
- Zhao, Y., Cheng, J., Zhang, P., & Peng, X. (2020). ECG classification using deep CNN improved by wavelet transform. *Computers, Materials and Continua*, 64(3). <https://doi.org/10.32604/cmc.2020.09938>
- Zhong, M. H., Li, F., & Chen, W. (2022). Automatic arrhythmia detection with multi-lead ECG signals based on heterogeneous graph attention networks. *Mathematical Biosciences and Engineering*, 19(12). <https://doi.org/10.3934/mbe.2022581>

KUANTUM BİLGİ İŞLEM: YENİ BİR HESAPLAMA PARADİGMASI

Gamzepelin AKSOY¹

Murat KARABATAK²

1. GİRİŞ

Kuantum mekaniği, 20. yüzyılın başında, klasik fizik anlayışlarının ötesine geçerek mikroskobik dünyanın doğasını anlamamıza olanak sağlayan devrimsel bir teori olarak ortaya çıkmıştır. Albert Einstein, Max Planck ve Niels Bohr gibi bilim insanlarının katkılarıyla şekillenen bu teori, parçacıkların aynı anda birden fazla durumda bulunabileceğini ve birbirlerinden uzak olsalar da birbirleriyle anlık bağlantılar kurabileceklerini göstermiştir. Bu kavramlar, doğanın işleyişine dair derin bir değişim önererek, fiziksel dünyaya bakış açımızı köklü bir şekilde değiştirmiştir.

Kuantum teorisinin ortaya koyduğu süperpozisyon, dolanıklık gibi kavramlar, klasik bilgisayarların ötesine geçebilecek yeni bir bilgi işlem paradigmasının temel taşlarını oluşturmuştur. Kuantum bilgisayarları, klasik bilgisayarların işlem kapasitesinin çok ötesine geçerek, bazı hesaplamaları çok daha kısa sürede tamamlayabilir. Kuantum bitleri ve kuantum mantık kapıları gibi yenilikçi bileşenlerle çalışan bu sistemler, özellikle kriptografi, büyük veri analitiği ve yapay zeka gibi alanlarda devrim yaratma potansiyeline sahiptir.

¹ Dr., Isparta Uygulamalı Bilimler Üniversitesi Teknoloji Fakültesi Bilgisayar Mühendisliği Bölümü. gamzepelina@gmail.com ORCID No: 0000-0002-5328-2983

² Prof. Dr., Fırat Üniversitesi Teknoloji Fakültesi Yazılım Mühendisliği Bölümü. mkarabatak@firat.edu.tr ORCID No: 0000-0002-6719-7421
Bu çalışma Gamzepelin AKSOY'un EEG Sinyallerinin Sınıflandırılmasında Kuantum Tabanlı Karar Destek Sisteminin Gerçekleştirilmesi isimli doktora tezinden üretilmiştir.

Bu çalışmada, kuantum mekaniğinin temel ilkelerinin yanı sıra, kuantum bilgisayarlarının çalışma prensipleri incelenecek ve bu alandaki güncel gelişmeler, karşılaşılan zorluklar ve gelecekteki potansiyel uygulamalar üzerinde durulacaktır.

2. KUANTUM MEKANİĞİ VE HESAPLAMANIN EVRİMİ

Kuantum hesaplama kavramının ortaya çıkışı, kuantum fiziğinin temellerine dayanan uzun ve karmaşık bir süreci yansıtmaktadır. Bu görüş ilk kez gündeme geldiğinde, geniş çapta tartışmalara yol açmış ve kimya, fizik ve matematik gibi farklı bilim dallarındaki araştırmacıların ilgisini çekmiştir. Kuantum mekaniğindeki ilerlemeler, günümüzde kuantum hesaplamanın yapay zeka ve makine öğrenmesi alanlarında uygulanabilirliğinin önünü açmıştır.

Klasik fiziğin açıklamada yetersiz kaldığı siyah cisim radyasyonu ve fotoelektrik etki gibi olgular, yeni bir fiziksel paradigma arayışını başlatmıştır. 19. yüzyılın sonlarına doğru Max Planck'ın kara cisim radyasyonunu tanıtmaması, kuantum teknolojisinin temellerinin atılmasına öncülük etmiştir. Albert Einstein, 1905 yılında fotoelektrik etkiyi keşfederek ışıkla ilgili deneylerin yapılabilmesini sağlamış ve ışığın yalnızca dalga değil, aynı zamanda parçacık gibi davrandığı fikrini ortaya atmıştır (Drago, 2014). 1925 yılında Schrödinger, kuantum mekaniği çerçevesinde dalga denkleminin önemli bir öneri sunmuştur. 1926 yılında ise Lewis, foton kavramını geliştirerek, ışınım enerjisinin belirli bir yoldan geçerken ayrı birimler halinde hareket edebileceği fikrini ortaya koymuştur. 1927 yılında Heisenberg, kuantum mekaniğinin klasik mekanik ve kinematik kavramlarla açıklanamayacağını belirterek, bu alanda önemli bir keşifte bulunmuştur. Heisenberg'in belirsizlik ilkesi olarak bilinen bu araştırma, kuantum mekaniğini klasik fizikten ayıran farkları ortaya koymaktadır (Heisenberg, 1927).

Einstein'ın 1935 yılında geliştirdiği ERP paradoksu, kuantum mekaniğinde bir fiziksel olayın başka bir fiziksel olayı nasıl etkileyebileceğini açıklamaktadır. ERP paradoksu, bir sistemdeki ölçümün, dolanık durumdaki diğer bir sistemin durumunu etkileyebileceğini öne sürer. Bu paradoks, bir sistemde yapılan ölçümde elde edilen yanlış bir sonucun, dolanık olan diğer sistemin tahminlerinin de yanlış olmasına yol açacağını belirtir. Bu durum, kuantum mekaniği ile ilgili geleneksel kavramlardan farklıdır, çünkü klasik mekanikte sistemler bağımsızdır ve birinin durumu diğerini etkilemez (Einstein vd., 1935). Bu bağlamda, ERP paradoksu, kuantum dolanıklığının ve kuantum dünyasında ölçüm yapılırken elde edilen sonuçların birbirini nasıl etkilediğini anlamada önemli bir yere sahiptir. David Bohm, 1952'de kuantum teorisinin kendi içinde tutarlı olduğunu ancak bazı varsayımların deneysel olarak test edilemeyeceğini belirtmiştir. Bohm, bir parçacığın konumu ve momentumu belli olduğunda, dalga fonksiyonu tarafından yönlendirilen bu parçacığın olasılıksal davranışını belirleyeceğini açıklamış ve kuantum teorisinin, 'gizli değişkenler' perspektifinden yorumlanması gerektiğini vurgulamıştır. Bu görüş, Bohm mekaniği ya da pilot dalga teorisi olarak bilinir ve kuantum teorisine daha geniş bir kavramsal çerçeve kazandırmıştır (Bohm, 1952).

Kuantum mekaniğindeki ilerlemelerle birlikte, 1970'lerde 'Kuantum Bilgi Teknolojisi' kavramı ortaya çıkmıştır. 1981 yılında gerçekleştirilen bir konferansta, Richard Feynman, kuantum mekaniği prensiplerine dayanan bir bilgisayarın geliştirilmesi gerektiğini savunarak, kuantum bilgisayarlarının gelişiminde önemli bir adım atılmasına öncülük etmiştir. 1993 yılında Barnett ve arkadaşları, kuantum dolanıklık kavramını kullanarak bilginin uzak mesafelere iletilmesini mümkün kılmıştır. 2010 yılında ise D-Wave One, 128 kübit işlemciye sahip olan ilk kuantum bilgisayarı olarak tanıtılmıştır. 2014 yılında 100 kübitlik kuantum bilgisayarlar geliştirilmiş ve 2016'dan


itibaren IBM, kuantum hesaplama ortamını bulut üzerinden erişilebilir hale getirerek, kuantum devrelerinin uygulanmasını mümkün kılmıştır (Singh & Singh, 2016). Kuantum bilgi teknolojisinin yaygınlaşması ve kuantum bilgisayarlarının erişilebilirliğinin artması, kuantum hesaplama alanında bir dizi yeni araştırma ve çalışmanın yapılmasına imkan tanımıştır.

2.1. Kuantum Mekaniğinin Temel Deneyleri

Kuantum mekaniği, fiziksel olayları anlamak için ayrıntılı bir şekilde incelenen, ancak anlaşılması genellikle zor olan bir alandır. Bu alandaki çeşitli deneyler, kuantum mekaniğinin temel prensiplerini ve belirsizliklerini anlamak için yapılmıştır. Bu deneyler, modern fiziğin temellerini sorgulamanın yanı sıra kuantum fiziğinin karmaşıklığını anlamak için oldukça büyük öneme sahiptir.

2.1.1. Schrödinger'in Kedisi

Fizikçi Erwin Schrödinger, parçacıkların birden fazla konumda aynı anda bulunabilmesi ve birbirleriyle ışık hızından daha hızlı iletişim kurabilmesi gibi özelliklerinin, klasik fiziğin ötesinde yer alan davranışlar olduğunu belirtmiştir. 1935 yılında gerçekleştirdiği düşünce deneyinde, parçacıkların dalga özellikleri sayesinde potansiyel olarak birden fazla durumda bulunabileceğini, ancak gözlemlendiklerinde yalnızca tek bir durumda bulunduğunu vurgulamıştır.



Şekil 9. Schrödinger'in kedisi düşünce deneyi


Schrödinger'in Kedisi deneyinde, bir kutunun içine radyoaktif bir atom, bir çekiçle tetiklenen bir mekanizma ve bir kedi yerleştirilmiştir. Atomun belirli bir süre içinde radyoaktif bozunma olasılığı vardır. Bu olasılık gerçekleştiğinde, mekanizma harekete geçer ve kediyi öldüren bir serumun bulunduğu tüpü kırar. Kutu açılmadan önce, kedinin canlı mı yoksa ölü mü olduğu kesin olarak bilinmediğinden, kedinin hem canlı hem de ölü olduğu durumu kabul edilir. Ancak gözlem yapıldığında, kedinin durumu netleşir. Bu deney, kuantum mekaniğinin belirsizlik ilkesini ve süperpozisyon kavramını vurgulamak amacıyla düşünce düzeyinde gerçekleştirilen bir bilimsel araştırma olarak kullanılmaktadır (Yam, 1997). Schrödinger'in Kedisi, kuantum fiziğinin karmaşıklığını anlatan bir düşünce deneyidir ve 'gözlemci etkisi' ile kuantum mekaniğindeki belirsizliği vurgular.

2.1.2. Çift Yarık Deneyi

Kuantum mekaniğinin önemli deneylerinden biri olan çift yarık deneyi, ilk olarak Thomas Young tarafından fotonlar kullanılarak gerçekleştirilmiştir. Clinton Davisson ve Lester Germer ise elektronların düzenli bir yapıya çarptığında yayılan dalga benzeri desenler oluşturduğunu raporlamışlardır. Bu, elektronların dalga özelliklerinin bir sonucudur. Richard Feynman, aynı deneyi hem elektronlar hem de fotonlarla gerçekleştirdi.

rerek, tek tek fotonların yerlerini tespit etmeyi önermiştir (Rolleigh, 2010).

Young'un yaptığı deneyde, bir ışık kaynağı, iki yakın paralel yarıktan oluşan bir engelden geçirilmeye çalışılmıştır. Sonrasında, bu iki yarıktan geçen ışık dalgalarının ekranda oluşturduğu parlak ve karanlık bantlar incelenmiştir. Bu deney, ışığın hem dalga hem de parçacık özelliklerini gösteren ve kuantum mekaniğinin temel ilkelerinin anlaşılmasında önemli bir deneydir (Galiev, 2020). Şekil 2'de, çift yarık deneyinin görsel gösterimi yer almaktadır.



Şekil 10. Çift Yarık Deneyi

Dedektörler kullanılmadan gerçekleştirilen çift yarık deneyinde, parçacıkların her iki yarıktan geçerek birbirleriyle girişim yapması beklenmektedir. Ancak dedektörler kullanıldığında, parçacıkların hangi yarıktan geçtiğini belirlemek amacıyla hareketleri izlenir. Dedektörler, yarıklardan geçen parçacıkları algıladığında, her bir parçacığın hangi yarıktan geçtiği tespit edilir. Bu durumda, her bir parçacık yalnızca bir yarıktan geçer ve dedektörler bu geçişi kaydeder. Sonuç olarak, parçacıkların yalnızca bir yarıktan geçtiği belirlenmiş olur ve bu da çift yarık deseni yerine iki tek yarık deseninin oluşmasına yol açar. Bu durum, dedektörlerin kullanımının parçacıkların davranışlarını değiştirdiğini ve girişim deseninin gözlenmediğini gösterir. Bir foton ya

da başka bir kuantum nesnesi, hem parçacık hem de dalga gibi davranır; bu da kuantum mekaniğinde ‘dalga-parçacık ikiliği’ olarak adlandırılır. Klasik fiziğe göre anlaşılması zor olan bu deneysel sonuç, kuantum mekaniği teorisiyle tutarlı olduğu için önemli bir bulgudur (Rolleigh, 2010).

2.2. Kuantum Mekaniği ve Kuantum Hesaplamanın Temel Kavramları

Kuantum mekaniği, atom ve atom altı parçacıkların davranışlarını inceleyen bir fizik dalıdır ve klasik fiziğin açıklamakta yetersiz kaldığı birçok fenomeni açıklığa kavuşturur. Kuantum hesaplama ise bu temel kuantum prensiplerini kullanarak bilgi işlemeyi mümkün kılar ve klasik bilgisayarların çözmekte zorlandığı karmaşık problemleri çözme potansiyeline sahiptir. Kuantum süperpozisyonu, dolanıklık, ışınlanma ve kübit gibi kavramlar, kuantum hesaplamanın temel yapı taşlarını oluşturur. Bu kavramlar, kuantum bitlerinin aynı anda birden fazla durumu temsil edebilmesine ve birbirleriyle güçlü bir şekilde bağlantılı olmasına olanak tanır.

2.2.1. Süperpozisyon ve Paralel Evrenler

Kuantum durumlarının süperpozisyonu, Schrödinger’in dalga fonksiyonunun doğrusal doğasından kaynaklanan ve kuantum sistemlerinin temel ilkelerinden biri olan bir fenomendir. Schrödinger denklemi, kuantum mekaniğinde bir parçacığın durumunu tanımlayan doğrusal, ikinci dereceden bir kısmi diferansiyel denklem olarak kabul edilir. Kuantum süperpozisyonu, tüm doğrusal olarak bağımsız çözümlerin bir kombinasyonu olarak ifade edilir. Bu kavram, klasik fizikte doğrudan bir karşılık bulmaz, ancak kuantum mekaniğinde, özellikle parçacıkların birden fazla durumda aynı anda bulunabilmesi gibi olağandışı özelliklerin açıklanmasında kritik bir öneme sahiptir.

Kuantum süperpozisyonu, Schrödinger’in kedisi düşünce deneyi ile etkili bir şekilde açıklanabilir. Bu düşünce deneyinde,

bir kutuya yerleştirilen bir kedi, radyoaktif bir atomun bozunma olasılığına bağlı olarak ölüm riski taşımaktadır. Kutu açılmadan önce, kedinin durumu hakkında kesin bir bilgiye sahip olamayız. Yani, kedinin hem canlı hem de ölü olduğu kabul edilir. Bu durumda, kedi süperpozisyon halinde bulunur, yani hem yaşam hem de ölüm durumlarının bir kombinasyonudur. Ancak, kutunun açılması ve gözlem yapılmasıyla, kedinin durumu belirlenir ve süperpozisyon durumu çöker (Uttam, 2012). Süperpozisyonu açıklayan bir diğer deney ise çift yarık deneyidir. Bu deneyde, bir ışık demeti iki paralel yarıktan geçirildiğinde, her foton her iki yarıktan da geçiyormuş gibi davranır. Bu durum, fotonun süperpozisyon halinde olduğunu ve her iki yarıktan geçerek kendisiyle girişim yaptığını gösterir. Çift yarık deneyinin sonuçları, fotonların yalnızca bir yarıktan geçmesini beklediğimizde, süperpozisyonun ölçülmeden önce devam ettiğini ve yalnızca ölçüm yapıldığında bir duruma çöktüğünü ortaya koymaktadır (Uttam, 2012).

ψ , fotonun kuantum davranışını tam olarak açıklayan Schrödinger dalga fonksiyonudur. İki durumlu bir kuantum sistemi, karmaşık iki boyutlu bir Hilbert uzayında bir vektör olarak temsil edilebilir. $|\mu\rangle$ ve $|v\rangle$ Hilbert uzayının temel vektörlerini temsil eder. Bu durumda kübit gösterimi Denklem 1'deki gibidir (Djordjevic, 2022).

$$|\psi\rangle = \alpha|\mu\rangle + \beta|v\rangle \quad (1)$$

α ve β karmaşık olasılık genliklerini temsil etmektedir. $|\mu\rangle$ ve $|v\rangle$, kübitlerin temel durumlarını ifade eder. Genellikle, hesaplama temeli olarak $|0\rangle = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ ve $|1\rangle = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$ durumları kullanılır. Bir kuantum durumu, Denklem 2'de gösterildiği gibi, bu temel durumların bir süperpozisyonu şeklinde ifade edilir.

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle = \begin{pmatrix} \alpha \\ \beta \end{pmatrix} \quad (2)$$

Dalga fonksiyonu ile olasılık genliği arasındaki bağlantıyı ortaya koyan bu denklem, $|0\rangle$ ve $|1\rangle$ durumlarının kuantum süperpozisyonunu gösterir. Ancak, kuantum süperpozisyonu ölçülmeye çalışıldığında, klasik bir sonuç elde edilir, yani sistem ya 0 ya da 1 durumunda ölçülür. Bu sonuçların olasılıkları $|\alpha|^2$ ve $|\beta|^2$ ile orantılıdır. Daha basit bir ifadeyle, kuantum durumu belirlenmeye çalışıldığında, bu durum klasik bir bitin ölçümüne dönüşür. Ölçümlerin olasılıksal sonuçları Denklem 3'te gösterilmektedir.

$$1 = |\alpha|^2 + |\beta|^2 \quad (3)$$

Kuantum süperpozisyonu, bir kuantum sisteminin aynı anda birden fazla durumda bulunmasını sağlar. Bu özellik, kuantum paralellliğini mümkün kılar. n kübitin her biri, iki boyutlu Hilbert uzaylarında ($H_0, H_1, \dots, H_{n-1}$) bulunur. Eğer bu kübitler birbirleriyle etkileşim olmadan hazırlanmışsa, sistemin toplam durumu, matematiksel olarak tensör çarpımı kullanılarak tanımlanır. Tensör çarpımına ait gösterim ise Denklem 4'te verilmiştir.

$$|\psi_0\rangle \otimes |\psi_i\rangle \otimes \dots \otimes |\psi_{n-1}\rangle \in H_0 \otimes H_1 \otimes \dots \otimes H_{n-1} \quad (4)$$

Bu, tüm kübitlerin birleşik durumunu tanımlar ve bu durum, kuantum hesaplamalarda büyük bir avantaj sağlar. Çünkü birleşik durum, birden fazla durumu aynı anda işleyebilme kapasitesine sahip olduğu için, kuantum hesaplama sistemlerinin klasik hesaplama sistemlerine göre çok daha verimli çalışmasını mümkün kılar. Bu özellik, kuantum paralellliği sayesinde aynı anda çok sayıda olasılığı değerlendirme imkanı sunar (Djordjevic, 2022).

Kuantum bilgisayarlar, aynı anda birçok olasılığı işleyebilir. Bir n kübitli sistem, 2^n farklı durumu aynı anda değerlendirir.

rebilir. Bu özellik, kuantum bilgisayarların büyük veri setlerini işleme kapasitesini artırır ve onları klasik bilgisayarlardan çok daha hızlı kılar.


2.2.2. Dolanıklık ve Kuantum İletişimi

Kuantum dolanıklığı, kuantum mekaniğinin temel özelliklerinden biridir ve kuantum fenomenlerini matematiksel olarak açıklamak için kullanılan belirli kurallar setine dayanan bir yaklaşımdır. Bu kavram, Einstein, Podolsky ve Rosen'in ERP paradoksu ile Bell'in eşitsizliklerine dayanmaktadır. Schrödinger, dolanıklığı, birbirleriyle bilinen güçler aracılığıyla etkileşime giren sistemlerin, birbirlerinden ayrıldıklarında eskisi gibi davranamayacakları şeklinde tanımlamıştır (Yuan vd., 2010).

Birbirleriyle geçmişte etkileşimde bulunan iki sistem varsa, bu sistemlere genellikle tek bir durum vektörü atamak mümkün olmaz. Yani, bu sistemlerin bireysel durumları birbirlerinden bağımsız olarak tanımlanamayacağı için, her iki sistemin durum vektörleri ayrılamaz. Bu özellik, 'Ayrılmazlık İlkesi' olarak da bilinir ve iki sistemin birbirine bağlı ve ayrılmaz şekilde etkileşim içinde olmasını ifade eder. Dolanık bir duruma örnek olarak, singlet durumu sıklıkla gösterilir. Singlet durumunun matematiksel gösterimi Denklem 5'te yer almaktadır (Horodecki vd., 2001).

$$\Psi = \frac{1}{\sqrt{2}} (|01\rangle - |10\rangle) \quad (5)$$

İki parçacığın durumlarının birbirine bağlı olduğunu gösteren bu denklem, birleşik sistemin durumu olarak tanımlanır. Şekil 3'te, birbirleriyle dolanık olan bir sistemin basit bir gösterimi sunulmaktadır.



Şekil 11. Kuantum dolanıklığı

2.2.3. Kuantum Işınlanma

Kuantum ışınlama, klasik anlamda bir maddeyi bir yerden başka bir yere taşımaktan ziyade, bilgi aktarımını tanımlar. Klasik dünyada, bilgiler kolayca kopyalanabilirken, kuantum dünyasında bir kübitin tam olarak kopyalanması mümkün değildir. Bu durum, bilinmeyen bir kuantum durumunun ölçülmesinin sınırlarını belirler. Kuantum durumunun kopyalanması, durumun ölçülmesini gerektirir ve bu ölçüm, kuantum durumunu değiştirir.

1993 yılında Bennett vd, bir kuantum durumunun bir yerden başka bir yere aktarılmasının, ERP çiftleri (dolanık parçacık çiftleri) kullanılarak mümkün olduğunu göstermiştir. Bu süreçte Alice (mesajı gönderen kişi), paylaşılan dolanık parçacıklar üzerinde bir Bell durumu ölçümü yapar ve sonucu Bob'a gönderir. Bob (mesajı alan kişi), aldığı klasik bilgiyi kullanarak orijinal kuantum durumunu kendi parçacığı üzerinde yeniden oluşturur. Bu işlemin temelinde kuantum dolanıklığı yer alır. Dolanıklık, iki parçacık arasında mesafe ne olursa olsun devam eden güçlü bir bağlantı kurar. Dolanıklık, fiziksel bir kaynak olarak önceden dağıtılabilir ve bu durum ışınlamanın mesafeler arasında etkili olmasını sağlar. Bob, Alice'in ölçüm sonuçlarını almadıkça, yalnızca karışık bir durumu elde eder. Bu nedenle, bu süreç anlık bilgi aktarımını mümkün kılmaz.

Işınlanma süreci kuantum klonlama teoremini ihlal etmez. Çünkü Alice'in yaptığı Bell durumu ölçümü sonucunda orijinal parçacığın bilgisi tamamen yok olur. Heisenberg'in Belirsizlik İlkesi ve kuantum ölçüm teorisine göre, bir kuantum sistemini ölçmek, sistemin durumunu kaçınılmaz olarak değiştirir. Bu sayede ışınlama işlemi hem güvenli hem de kuantum mekanik prensiplerine uygun bir şekilde gerçekleşir (Yuan vd., 2010).

2.2.4. Hilbert Uzayı

Hilbert uzayı, kompleks vektör uzayı olarak tanımlanır ve öklidyen uzayların sonsuz boyutlu uzaylara genellemesi olarak kabul edilir. Kuantum mekaniğinde, fiziksel sistemlerin temsili için Hilbert uzayındaki vektörler kullanılır. Bu vektörler, sistemin olası tüm durumlarını temsil eden durum vektörleri olarak tanımlanır ve bir iç çarpım yapısına sahiptir. İç çarpım, iki vektör arasındaki mesafeyi ve ilişkileri belirlemeyi sağlar. Hilbert uzayı genellikle sonsuz boyutlu uzaylar için kullanılır, ancak günümüzde sonlu boyutlu uzayları da içerecek şekilde genişletilmiştir (Griffiths, 2014).

Bir iç çarpım, V uzayı üzerinde tanımlanan bir fonksiyon olup, $\langle \cdot, \cdot \rangle: V \times V \rightarrow \mathbb{C}$ şeklinde gösterilir. Bu fonksiyon, $u, v, w \in V$ ve $\lambda \in \mathbb{C}$ için aşağıdaki özellikleri sağlar: Denklem 6'da u ile v arasındaki iç çarpımın simetrik olduğunu ve v ile u arasındaki iç çarpımın karmaşık eşleniğine eşit olduğunu göstermektedir (Loaiza, 2017).

$$\langle u, v \rangle = \overline{\langle v, u \rangle} \quad (6)$$

Denklem 7, bir vektörle bir skaler (λ) çarpıldığında, bu skalerin iç çarpımın dışına çıktığını ifade etmektedir.

$$\langle \lambda u, v \rangle = \lambda \langle u, v \rangle \quad (7)$$

Denklem 8, iki vektörün toplamının başka bir vektörle olan iç çarpımının, bu iki vektörün ayrı ayrı iç çarpımlarının toplamına eşit olduğunu belirtmektedir.

$$\langle u + v, m \rangle = \langle u, m \rangle + \langle v, m \rangle \quad (8)$$

Denklem 9 ise, bir çarpımın bir vektör ile kendisi arasındaki değerin her zaman sıfır veya sıfırdan büyük olduğunu ifade etmektedir.

$$\langle u, v \rangle \geq 0 \text{ ve } \langle v, v \rangle = 0 \Leftrightarrow v = 0 \quad (9)$$

İç çarpım uzayındaki en önemli eşitsizliklerden biri olan Cauchy-Schwarz eşitsizliği, herhangi bir u, v vektörü için Denklem 10 ile ifade edilir:

$$|\langle u, v \rangle| \leq \|u\| \|v\| \quad (10)$$

Eşitlik, u ve v vektörleri lineer olarak bağımlı olduğu ve u vektörünün sıfır vektörü olmadığı durumda sağlanır. Vektörlerin normlarını göstermek için $\|u\|$ ve $\|v\|$ kullanılır. Hilbert uzayı, iç çarpımı olan ve bu iç çarpıma dayalı olarak tanımlanan bir vektör uzayıdır. Hilbert uzayının en basit örneği olan C^n ve iç çarpımı $x=(x_1, x_2, x_3, \dots, x_n)$ ve $y=(y_1, y_2, y_3, \dots, y_n)$ için Denklem 11'de verilmiştir (Loaiza, 2017).

$$\langle x, y \rangle = \sum_{i=1}^n x_i \bar{y}_i \quad (11)$$

Sonsuz boyutlu vektörlerin bir araya geldiği yapılar, Hilbert uzayı olarak adlandırılmaktadır. Hilbert uzayı, iç çarpım uzaylarının genelleştirmesi olup, tüm temel özelliklerini içermektedir. Kuantum bilgisayarlar, işlemleri gerçekleştirirken genellikle Hilbert uzayındaki vektörleri kullanmaktadır. Hilbert uzayı, kuantum mekaniği ve kubitlerin matematiksel yapılarının anlaşılmasında önemli bir rol oynamaktadır. Kubitlerin durumunu temsil etmek için genellikle Hilbert uzayındaki vektörler kullanılmaktadır.

2.2.5. Kuantum Bit (Kübit)

Kuantum bilişim, klasik hesaplama yöntemlerinin ötesine geçerek daha hızlı ve verimli bilgi işleme yetenekleri sunmayı amaçlamaktadır. Bu alandaki en temel yapı taşı, ‘kuantum bit’ ya da kısa adıyla ‘kübit’ tir. Klasik bitlerden farklı olarak, kübitler aynı anda hem 0 hem de 1 durumlarında bulunabilir. Bu özellik, kuantum mekaniğindeki ‘süperpozisyon’ ilkesine dayanır. Bunun yanı sıra, kübitler arasında ‘dolaşıklık’ adı verilen bir fenomene dayalı bir bağlantı da kurulabilir, böylece kübitlerin durumları birbirine bağlı hale gelir. Bu ilke doğrultusunda, kuantum bilgisayarları geleneksel bitler yerine kübitler kullanarak işlem yapar. Kübitlerin durumu, dönüş yönüne bağlı olarak 0 ile 1 arasında sonsuz sayıda değere sahip olabilir. Bu benzersiz özellikler, kuantum bilgisayarlarının bazı problemleri klasik bilgisayarlardan çok daha hızlı çözmesini sağlar (Yetiş & Karaköse, 2021).

Kuantum sisteminin durumları vektörlere karşılık gelir. Bir kuantum bitinde, 0 kuantum mantık durumu, iki boyutlu $\begin{pmatrix} 1 \\ 0 \end{pmatrix}$ vektörüne, 1 kuantum mantık durumu ise $\begin{pmatrix} 0 \\ 1 \end{pmatrix}$ vektörüne karşılık gelir. Bu vektörler ‘dirac braket’ gösterimi ile $|0\rangle \equiv \begin{pmatrix} 1 \\ 0 \end{pmatrix}$, $|1\rangle \equiv \begin{pmatrix} 0 \\ 1 \end{pmatrix}$ şeklinde ifade edilmektedir. Dirac braket notasyonu, kuantum mekaniğinde kuantum durumlarını ve operatörlerini temsil etmek için yaygın olarak kullanılan bir gösterim sistemidir.

Bir kübit için genel durum, $|\psi\rangle$, $\begin{pmatrix} \alpha \\ \beta \end{pmatrix}$ vektörü ile ifade edilir ve bu durum $\alpha|0\rangle + \beta|1\rangle$ şeklinde gösterilir. Bu gösterimdeki α ve β karmaşık sayılar olup, $|\alpha|^2 + |\beta|^2 = 1$ koşulunu sağlar. Bu, vektör bileşenlerinin karelerinin toplamının bir olması gerekliliği anlamına gelir ve bu koşula ‘normallik’ (normalization) denir. Normallik (normalization), kuantum mekaniğinde genlik-

lerin karelerinin olasılıklarla ilişkili olması nedeniyle ortaya çıkar. Özellikle, bir kübitin $|\psi\rangle$ durumunda hazırlandığını ve ardından bu kübitin 0 veya 1 değerini alıp almadığını belirlemek amacıyla bir ölçüm yapıldığını varsayalım. Bu durumda, yapılan ölçüm, $|\alpha|^2$ olasılığı ile 0 sonucunu ve $|\beta|^2$ olasılığı ile 1 sonucunu verir. Bu olasılıkların toplamı her zaman bir olmalıdır. Buna karşılık gelen satır vektörleri Denklem 12’de gösterildiği gibi ifade edilir.

$$\langle 0| \equiv \begin{pmatrix} 1 & 0 \end{pmatrix}, \langle 1| \equiv \begin{pmatrix} 0 & 1 \end{pmatrix}, \langle \psi| \equiv \begin{pmatrix} \bar{\alpha} & \bar{\beta} \end{pmatrix} \quad (12)$$

Bir kübit için, iki boyutlu kompleks vektör uzayı C^2 olarak tanımlanır. Dirac braket notasyonunun kullanılmasının nedeni, bu vektör uzayının, kuantum mekaniğinde, doğal bir iç çarpıma sahip olmasıdır. İç çarpım, denklem 13’te gösterildiği gibi satır vektörleri ile sütun vektörlerinin çarpımı olarak tanımlanır:


$$|\psi\rangle = \begin{pmatrix} \alpha \\ \beta \end{pmatrix} \text{ ve } |\phi\rangle = \begin{pmatrix} \gamma \\ \delta \end{pmatrix} \quad (13)$$

$\langle \phi| = (\bar{\gamma} \quad \bar{\delta})$ burada satır vektörleri $\langle \phi|$ ‘bra’ vektörünü, sütun vektörleri $|\psi\rangle$ ‘ket’ vektörünü temsil etmektedir. Ket, kuantum durumlarını ifade etmek için kullanılır. Bra ise ‘ket’in duali olarak bilinir. Bir bra ve ket’in iç çarpımını $\langle \phi|\psi\rangle$ şeklinde yazılır. Bu, $|\phi\rangle$ durumunun $|\psi\rangle$ durumuyla olan iç çarpımını temsil eder.

$$\langle \phi|\psi\rangle = (\bar{\gamma} \quad \bar{\delta}) \begin{pmatrix} \alpha \\ \beta \end{pmatrix} = \bar{\gamma}\alpha + \bar{\delta}\beta \quad (14)$$

Bu iç çarpım, kuantum durumlarının olasılık genliklerini ve diğer önemli özelliklerini hesaplamak için kullanılmaktadır. İç çarpımın $\langle \psi|\psi\rangle = |\alpha|^2 + |\beta|^2 = 1$ tanımı, kübitler için vektör uzayını Hilbert uzayına dönüştürmektedir (Lloyd & Computation, 2009).

Kübitler Bloch Küresi ile gösterilir ve bu küre üzerindeki her noktada bulunma olasılığına sahip bir dizi durumu içermektedir. Bir kübitin bloch küresi üzerindeki durumu Şekil 4'te gösterilmektedir.



Şekil 12. Bloch küresi üzerinde bir kübit'in durumu

Bloch küresine göre γ , θ , ϕ reel sayılar olmak üzere bir kübit, denklem 15'te verildiği gibi ifade edilmektedir.

$$|\psi\rangle = e^{i\gamma} \left(\cos\left(\frac{\theta}{2}\right) |0\rangle + e^{i\phi} \sin\left(\frac{\theta}{2}\right) |1\rangle \right) = e^{i\gamma} \begin{pmatrix} \cos\left(\frac{\theta}{2}\right) \\ e^{i\phi} \sin\left(\frac{\theta}{2}\right) \end{pmatrix} \quad (15)$$

Bloch küresindeki bir noktanın konumu, $0 \leq \theta \leq \pi$ aralığındaki yükselti açısı ve $0 \leq \phi \leq 2\pi$ aralığındaki azimut açısıyla tanımlanır. Bu küresel koordinat sistemi, kübitlerin durumlarını matematiksel olarak ifade etmek için kullanılır. Ayrıca, $e^{i\gamma}$ ifadesi global faz vektörünü temsil eder. Global fazın kuantum durumu üzerinde herhangi bir gözlemlenebilir etkisi yoktur. Bununla birlikte, $|0\rangle$ ve $|1\rangle$ durumları arasındaki faz farkları gözlemlenebilir özelliklerdir ve bu faz farkları, kübitlerle ilgili bilgilerin edinilmesinde önemli rol oynar (Yanofsky, 2007).








2.2.6. Kuantum Mantık Kapıları

Kuantum mantık kapıları, klasik mantık kapılarının işlevlerini yerine getiren, ancak kuantum mekaniğinin prensiplerine dayanan özel kapılardır.

Tek kübit işlemleri, Bloch küresi üzerinde bir kuantum durumunun belirli bir ekseninde döndürülmesiyle yapılır. Bu işlem, bir matrisle ifade edilir ve bu matris, X, Y, Z operatörlerinin özvektörlerine dayalı olarak kuantum hesaplamalarını tanımlar. Bu matrisler, kübitlerin durumlarını ve davranışlarını belirleyen matematiksel bir temsildir. Kübitlerin Bloch küresi üzerindeki dönüşlerini ve durum değişimlerini yöneten bu matrisler, kuantum bilgisayarlarının işleyişinin temelini oluşturur. İki ya da daha fazla kübitin kullanıldığı kapılarda, bir kontrol kübiti belirli bir birim işleminin hedef kübite uygulanıp uygulanmayacağını belirler. Klasik mantık kapılarındaki gibi, kontrol kübiti 0 olduğunda işlem yapılmazken, 1 olduğunda hedef kübite belirli bir işlem uygulanır. Kuantum mantık kapılarında da aynı şekilde, işlemlerin gerçekleştirilmesi için kontrol kübiti kullanılır. Bu mekanizma, kuantum bilgisayarlarının işlem sırasını ve yönünü belirlemek için önemlidir. Tablo 1’de, tek ve çoklu kübitler için kullanılan kuantum mantık kapıları özetlenmiştir (Roy, 2020).

Tablo 1. Kuantum mantık kapıları

	Operatör	Devre Temsili	Matris
Tek Kübit Kuantum Kapıları	Birim (I)		$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$
	Pauli-X		$\begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$
	Pauli-Y		$\begin{bmatrix} 0 & -i \\ i & 0 \end{bmatrix}$

Çoklu Kübit Kuantum Kapıları	Pauli-Z		$\begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$
	Hadamard (H)		$\frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}$
	Faz (S,P) $(\sqrt{Z}, P(\frac{\pi}{2}))$		$\begin{bmatrix} 1 & 0 \\ 0 & i \end{bmatrix}$
	$\frac{\pi}{8}$ (T)		$\begin{bmatrix} 1 & 0 \\ 0 & e^{i\pi/4} \end{bmatrix}$
	Kontrollü Değil (CNOT)		$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$
	Kontrollü Z (CZ)		$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & -1 \end{bmatrix}$
	Kontrollü Faz (CS)		$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & i \end{bmatrix}$

3. SONUÇLAR

Kuantum hesaplama, klasik hesaplama sistemlerinin sınırlarını aşarak, belirli problemlerin çok daha hızlı ve verimli bir şekilde çözülmesini mümkün kılmaktadır. Bu yeni hesaplama paradigmaları, özellikle süperpozisyon, dolanıklık gibi kuantum mekaniği temelli kavramlar sayesinde, bilgisayar bilimi ve mühendislik alanlarında devrim yaratma potansiyeline sahiptir. Kuantum bitler, bir kuantum bilgisayarının temel yapı taşlarını oluşturmakta ve geleneksel bitlerin çok ötesinde, aynı anda birden fazla durumu temsil edebilme özelliği sunmaktadır.

Bu çalışma, kuantum mekaniğinin temel ilkelerinin kuantum hesaplamadaki uygulamalarına nasıl yansıdığını ve bu kavramların matematiksel temellerini ele almıştır. Kuantum bilgisayarlarının potansiyelini ve pratikteki kullanımını anlayabilmek için, bu teorik temel bilgilerin anlaşılması kritik bir öneme sahiptir. Süperpozisyon ve dolanıklık gibi kavramlar, aynı zamanda kuantum bilgisayarlarının potansiyel uygulama alanlarını da genişletmektedir. Bu teknolojiler, özellikle yapay zeka, şifreleme ve biyoteknoloji gibi hızla gelişen alanlarda, henüz tam anlamıyla keşfedilmemiş büyük fırsatlar sunmaktadır.

Ancak, kuantum teknolojisi henüz gelişim aşamasında olup, bu alanda karşılaşılan teknik ve teorik zorluklar hala çözülme beklemektedir. Kuantum hata düzeltme, kuantum üstünlüğü ve daha stabil kuantum bilgisayarların tasarımı gibi konular, bu alandaki en önemli araştırma alanlarından bazılarıdır. Gelecekteki gelişmeler, kuantum hesaplamanın günlük hayatta ve endüstriyel uygulamalarda yaygın kullanımına kapı aralayabilir.

KAYNAKÇA

- Bohm, D. (1952). A Suggested Interpretation of the Quantum Theory in Terms of “Hidden” Variables. I. Physical Review, 85(2), 166-179. <https://doi.org/10.1103/PhysRev.85.166>
- Djordjevic, I. B. (2022). Chapter 3—Quantum information processing fundamentals. İçinde I. B. Djordjevic (Ed.), Quantum Communication, Quantum Networks, and Quantum Sensing (ss. 89-124). Academic Press. <https://doi.org/10.1016/B978-0-12-822942-2.00008-X>
- Drago, A. (2014). Einstein’s 1905 “Revolutionary” Paper on Quanta as a Manifest and Detailed Example of a “Principle Theory”. Advances in Historical Studies, 3(3), Article 3. <https://doi.org/10.4236/ahs.2014.33013>
- Einstein, A., Podolsky, B., & Rosen, N. (1935). Can Quantum-Mechanical Description of Physical Reality Be Considered Complete? Physical Review, 47(10), 777-780. <https://doi.org/10.1103/PhysRev.47.777>
- Galiev, S. hamil U. (2020). Nonlinear Quantum Waves in the Light of Recent Slit Experiments. İçinde S. U. Galiev, Evolution of Extreme Waves and Resonances (1. bs, ss. 423-463). CRC Press. <https://doi.org/10.1201/9781003038504-18>
- Griffiths, R. B. (2014). Hilbert Space Quantum Mechanics.
- Heisenberg, W. (1927). Über den anschaulichen Inhalt der quantentheoretischen Kinematik und Mechanik. Zeitschrift für Physik, 43(3), 172-198. <https://doi.org/10.1007/BF01397280>

- Horodecki, M., Horodecki, P., & Horodecki, R. (2001). Mixed-State Entanglement and Quantum Communication. İçinde G. Alber, T. Beth, M. Horodecki, P. Horodecki, R. Horodecki, M. Rötteler, H. Weinfurter, R. Werner, & A. Zeilinger (Ed.), *Quantum Information: An Introduction to Basic Theoretical Concepts and Experiments* (ss. 151-195). Springer. https://doi.org/10.1007/3-540-44678-8_5
- Lloyd, S., & Computation, I. Q. (2009). Quantum information science. *Notas de Aula, Curso Quantum-Mechanics*. <https://stuff.mit.edu/afs/athena.mit.edu/course/2/2.111/OldFiles/www/notes09/spring.pdf>
- Loaiza, M. (2017). A Short Introduction to Hilbert Space Theory. *Journal of Physics: Conference Series*, 839, 012002. <https://doi.org/10.1088/1742-6596/839/1/012002>
- Rolleigh, R. (2010). The Double Slit Experiment and Quantum Mechanics.
- Roy, P. K. (2020). Quantum Logic Gates.
- Singh, J., & Singh, M. (2016). Evolution in Quantum Computing. 2016 International Conference System Modeling & Advancement in Research Trends (SMART), 267-270. <https://doi.org/10.1109/SYSMAST.2016.7894533>
- Uttam, S. (2012). Chapter 4—Introduction to Quantum Information Processing. İçinde I. Djordjevic (Ed.), *Quantum Information Processing and Quantum Error Correction* (ss. 119-144). Academic Press. <https://doi.org/10.1016/B978-0-12-385491-9.00004-6>
- Yam, P. (1997). Bringing Schrödinger's Cat to Life. *Scientific American*, 276(6), 124-129.

- Yanofsky, N. S. (2007). An Introduction to Quantum Computing (arXiv:0708.0261). arXiv.
<https://doi.org/10.48550/arXiv.0708.0261>
- Yetiş, H., & Karaköse, M. (2021). Kuantum Uyarlamalı Genetik Algoritmalar için Çözüm Kalitesini Artıracak Yeni Bir Yaklaşım. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 33(1), Article 1.
<https://doi.org/10.35234/fumbd.749192>
- Yuan, Z.-S., Bao, X.-H., Lu, C.-Y., Zhang, J., Peng, C.-Z., & Pan, J.-W. (2010). Entangled photons and quantum communication. Physics Reports, 497(1), 1-40.
<https://doi.org/10.1016/j.physrep.2010.07.004>

TIBBİ GÖRÜNTÜLERDE YAPAY ZEKÂ TEMELLİ NESNE TESPİTİ UYGULAMALARI

Hasan Ali AKYÜREK¹

1. GİRİŞ

Tıbbi görüntüleme teknolojileri, modern tıpta hastalıkların erken teşhisinde ve tedavi süreçlerinin yönetilmesinde kritik bir rol oynamaktadır. Manyetik Rezonans Görüntüleme (MRG), Bilgisayarlı Tomografi (BT), Ultrasonografi (USG), Direkt Grafi (Röntgen) gibi görüntüleme yöntemleri ve histopatolojik preparatlar gibi farklı modaliteler, sağlık hizmetlerinin temel taşlarından biri haline gelmiştir.

Yapay zekâ teknolojilerindeki ilerlemeler, tıbbi görüntülemede yeni bir dönemin kapısını aralamıştır. Özellikle nesne tespiti algoritmaları, tıbbi görüntülerde tümör, hematoma, apse gibi patolojik yapıların ve damar tıkanıklığı, spinal kanal daralmaları gibi acil durumların hızlı ve doğru bir şekilde tespit edilmesini sağlamaktadır. Bu teknolojiler, yalnızca sağlık profesyonellerinin iş yükünü azaltmakla kalmayıp, aynı zamanda hastaların daha iyi bir tedavi sürecine daha hızlı bir şekilde ulaşmalarına olanak sağlamaktadır.

Bu çalışmada, tıbbi görüntüleme teknolojilerinin temel unsurları ve nesne tespiti uygulamalarının sağlık sektöründeki yeri, ilgili zorluklar ve bu teknolojilerin gelecekteki potansiyel yönelimleri üzerinde durulmaktadır. Bu bağlamda, veri hazırlama, algoritma seçimi, model eğitimi, doğrulama süreçleri ve klinik uygulamalardaki zorluklar detaylı bir şekilde ele alınmak-

¹ Dr. Öğr. Üyesi, Necmettin Erbakan Üniversitesi, Havacılık ve Uzay Bilimleri Fakültesi, Havacılık Elektrik ve Elektronik Bölümü, hakyurek@erbakan.edu.tr, ORCID: 0000-0002-0520-9888.

tadır. Ayrıca, yapay zekâ tabanlı bu yaklaşımların sağlık hizmetlerinde sunduğu fırsatlar ve gelecekteki potansiyel gelişmeler de tartışılmaktadır.

Bu çalışma, tıbbi görüntülerin analizinde nesne tespiti teknolojilerinin sağladığı faydaları incelemekte, mevcut yöntemlerin gelecekteki potansiyelini değerlendirmekte ve hem akademik araştırmacılar hem de klinik uygulayıcılar için temel bilgiler sunmaktadır.

1.1. Tıbbi Görüntüleme Teknolojilerinin Önemi

Tıbbi görüntüleme teknolojileri, hastaların doğru bir şekilde değerlendirilmesi, tedavi süreçlerinin etkin bir şekilde yönetilmesi ve hastalıkların erken teşhisi, tedavinin doğru planlanması ve hastaların etkin bir biçimde izlenmesi için vazgeçilmez araçlar olarak değerlendirilmektedir (Haman Bayari, Akin, & Tuncel, 2023; Kircher & Willmann, 2012; Kumrular & Polat, 2021).

Radyolojik görüntülemeler, hastalıkların tanısında ve takibinde kullanılan en yaygın yöntemlerdendir. BT ve MRG gibi teknikler, vücudun iç yapısını detaylı bir şekilde görüntüleyerek, anormalliklerin tespit edilmesine olanak sağlamaktadır. Özellikle BT, kemik yapıyı, kalsifikasyonu, taze kanamayı hızlı ve yüksek çözünürlükte görüntüleme sağlarken, MRG ise yumuşak doku görüntülemeye ve özellikle X ışını kullanmaması sebebiyle üstünlük göstermektedir. Bu teknolojilerin kombinasyonu ise klinik uygulamalarda daha kapsamlı bir değerlendirme yapılmasına olanak tanımaktadır (Haman Bayari vd., 2023; Kircher & Willmann, 2012; Kumrular & Polat, 2021).

USG, özellikle gebelik takibi ve karın bölgesi organlarının değerlendirilmesinde yaygın olarak kullanılan bir başka tıbbi görüntüleme tekniğidir. USG'nin avantajları arasında invazif olmaması, X ışını yaymaması ve gerçek zamanlı görüntüleme sağlaması bulunmaktadır. Bu özellikleri sayesinde, USG, acil

durumlarda hızlı karar verme süreçlerinde de önemli bir rol oynamaktadır. Bununla birlikte, USG'nin sınırlamaları da vardır; örneğin, derin dokuların görüntülenmesinde ve boşluklu organların boşlukları sebebiyle daha derin yapıları görememesi gibi zorluklar yaşanabilmektedir (Haman Bayari vd., 2023; Kircher & Willmann, 2012; Kumrular & Polat, 2021).

MRG, özellikle nörolojik hastalıkların tanısında, yumuşak doku görüntülemeye sağladığı yüksek çözünürlük sayesinde, beyin tümörleri, inme ve diğer nörolojik durumların değerlendirilmesinde sıklıkla kullanılmaktadır. Ayrıca, MR görüntüleme, fonksiyonel görüntüleme yöntemleriyle birleştirildiğinde, beyin aktivitelerinin izlenmesine olanak tanır ve bu da nörolojik araştırmalarda önemli bir araç haline gelmiştir (Haman Bayari vd., 2023; Kircher & Willmann, 2012; Kumrular & Polat, 2021).

BT, vücudun kesitsel görüntülerini oluşturarak, iç organların detaylı bir şekilde incelenmesine olanak tanımaktadır. Bu yöntem, acil durumlarda hızlı ve etkili bir tanı aracı olarak travma hastalarının değerlendirilmesinde ve kanser taramalarında yaygın olarak kullanılmaktadır. Ancak, BT'nin iyonize radyasyon kullanması, hastalar için potansiyel riskler oluşturabileceği için kullanımında dikkatli olunması gerekmektedir (Haman Bayari vd., 2023; Kircher & Willmann, 2012; Kumrular & Polat, 2021).

Tıbbi görüntüleme teknolojilerinin bir diğer önemli yönü, multidisipliner bir yaklaşım gerektirmesidir. Radyologlar, patoloğlar, cerrahlar ve diğer sağlık profesyonelleri, görüntüleme sonuçlarını yorumlamak ve hastaların tedavi süreçlerini planlamak için iş birliği yapmaktadır. Bu iş birliği, hastaların daha iyi bir sağlık hizmeti almasını sağlamakta ve multidisipliner tedavi yaklaşımlarının uygulanmasına olanak tanımaktadır (Kircher & Willmann, 2012; Kumrular & Polat, 2021).

Son yıllarda, tıbbi görüntüleme alanında yapay zekâ uygulamaları da önemli bir yer edinmiştir. Bu teknolojiler, görüntü işleme süreçlerini otomatikleştirerek, anormalliklerin daha hızlı ve doğru bir şekilde tespit edilmesine yardımcı olmaktadır. Yapay zekânın alt alanlarından makine öğrenimi yöntemlerinden biri olan derin öğrenme modelleri, büyük veri setleri üzerinde eğitilerek görüntülerdeki karmaşık desenleri tanıyabilmektedir (Eker & Duru, 2021; Karaman & Çınar, 2021).

Tıbbi görüntüleme teknolojilerinin gelişimi, sağlık hizmetlerinin kalitesini artırmakla kalmayıp, aynı zamanda maliyetleri de düşürmektedir. Daha doğru tanı ve tedavi yöntemleri, gereğinden fazla yapılacak müdahalelerin ve hastane yatış sürelerinin azaltılmasına yardımcı olmaktadır. Ayrıca, tıbbi görüntüleme yöntemleri, hastaların tedavi süreçlerinin izlenmesine olanak tanıyarak, sağlık hizmetlerinin etkinliğini artırmaktadır (Haman Bayari vd., 2023; Kircher & Willmann, 2012; Kumrular & Polat, 2021).

1.2. Nesne Tespiti Kavramı ve Uygulamaları

Nesne tespiti, bir görüntü veya video içerisindeki belirli nesnelerin konumlarını ve türlerini otomatik olarak belirleme işlemidir. Bu süreçte, görsel materyalde yer alan varlıklar (örneğin; insanlar, araçlar, hayvanlar veya tıbbi görüntülerdeki belirli dokular ve yapılar) yapay zekâ veya geleneksel görüntü işleme teknikleri yardımıyla algılanır, tanımlanır ve sınıflandırılır. Nesne tespiti hem nesnenin görüntü içindeki yerini işaretleyen bir konum bilgisini (örneğin koordinat veya sınırlayıcı kutu) hem de tespit edilen nesnenin hangi sınıfa ait olduğunu (örneğin “kedi”, “araç” ya da “tümör”) belirleyerek görüntüler ve videolardan otomatik anlam çıkarma, veri analizi, güvenlik uygulamaları, otonom sürüş teknolojileri, sağlık teşhis ve tedavi süreçleri gibi pek çok alanda kullanılmaktadır (Arserim & Usta, 2023; C. T. Cheng vd., 2019; Daş, Polat, & Tuna, 2019; Li, 2024; Shou vd.,

2022; Su, Huang, Ma, Song, & Hu, 2021; Taşyürek, 2023; Y. Zhang, Chen, Huang, & Gao, 2019).

Nesne tespiti, tıbbi görüntüleme alanında da tümör tespiti, lezyon analizi ve damar lümenini izleme gibi çeşitli uygulamalarda önemli bir yere sahiptir. Tıbbi görüntüleme teknolojileri, hastalıkların tanı ve tedavisinde büyük bir öneme sahipken, nesne tespiti de bu süreçlerin etkinliğini artırmaktadır. Özellikle, derin öğrenme tekniklerinin entegrasyonu, nesne tespitinin doğruluğunu ve hızını önemli ölçüde artırmıştır (Ayatollahi, Shokouhi, Mann, & Teuwen, 2021; C. T. Cheng vd., 2019).

Tümör tespiti, tıbbi görüntülemenin en önemli uygulamalarından biridir. Röntgen, MRG ve BT gibi görüntüleme yöntemleri, tümörlerin boyutunu, konumunu ve yapısını belirlemek için kullanılmaktadır. Bu görüntüler üzerinde uygulanan nesne tespiti algoritmaları, tümörlerin otomatik olarak tanımlanmasına ve sınıflandırılmasına olanak tanır. Örneğin, YOLO (You Only Look Once) gibi derin öğrenme tabanlı yöntemler, tümörlerin hızlı ve doğru bir şekilde tespit edilmesini sağlamakta ve klinik karar verme süreçlerini hızlandırmaktadır (Akgül, Kozan, Akyürek, & Taşdemir, 2024; Pang vd., 2019).

Lezyon analizi, nesne tespitinin bir diğer önemli uygulama alanıdır. Lezyonlar, çeşitli hastalıkların belirtisi olabileceğinden, doğru bir şekilde tespit edilmeleri kritik öneme sahiptir. Tıbbi görüntülerde lezyonların otomatik olarak tespit edilmesi, radyologların iş yükünü azaltmakta ve daha doğru tanı konulmasına yardımcı olmaktadır. Derin öğrenme teknikleri, lezyonların belirlenmesinde yüksek doğruluk oranları sunmakta ve hastaların tedavi süreçleri daha etkin bir şekilde yönetilmektedir (Ayatollahi vd., 2021; Bayraktar & Ayan, 2022).

Damar lümeninin tespiti, özellikle yoğun bakım üniteleri ve acil servis açısından önemli bir uygulamadır. Damar yolu açılması, hastaların tedavi süreçlerinde önemli bir adımdır ve bu

süreçte nesne tespiti teknikleri kullanılabilinmektedir. Örneğin, USG görüntüleri üzerinde yapılan nesne tespiti, damarların bulunması ve kateterlerin damar lümenine doğru bir şekilde yerleştirilmesine yardımcı olmaktadır. Bu tür uygulamalar, hastaların tedavi süreçlerinin güvenliğini artırmakta ve komplikasyon risklerini azaltmaktadır (Akgül vd., 2024).

Nesne tespitinin tıbbi görüntülemedeki rolü, yalnızca tanı süreçleriyle sınırlı değildir. Aynı zamanda, tedavi süreçlerinin izlenmesi ve hastaların takibi için de önemlidir. Örneğin, tümör tedavisi sonrası görüntüleme ile tümörün boyutundaki değişikliklerin izlenmesi, tedavi etkinliğinin değerlendirilmesi açısından önemlidir. Bu süreçte nesne tespiti, tedavi sonrası görüntülerde tümörlerin varlığını veya yokluğunu belirlemek için kullanılmaktadır (Cao, Duan, Yang, Yue, & Chen, 2019).

2. TIBBİ GÖRÜNTÜLER VE VERİLER

2.1. Tıbbi Görüntüleme Türleri ve Formatları

Tıbbi görüntüleme alanında, çeşitli veri formatları; görüntülerin depolanması, iletimi ve analizi için kritik bir rol oynamaktadır. DICOM (Digital Imaging and Communications in Medicine), TIFF (Tagged Image File Format) ve NIFTI (Neuroimaging Informatics Technology Initiative) gibi formatlar, tıbbi görüntülerin yönetimi ve işlenmesi açısından önemli özellikler sunmaktadır. Bu formatların her biri, belirli uygulama alanlarına ve ihtiyaçlara göre tasarlanmıştır.

DICOM, tıbbi görüntüleme için en yaygın standarttır ve klinik görüntü verilerinin ve meta verilerin yönetiminde önemli bir rol oynamaktadır. DICOM, farklı tıbbi görüntüleme cihazları ve sistemleri arasında veri alışverişini kolaylaştırarak, tıbbi görüntülerin ve ilişkili verilerin farklı satıcılar ve kurumlar arasında kolayca değiştirilebilmesini sağlamaktadır. DICOM'un sağladığı bu standart, görüntülerin kalitesini ve bütünlüğünü koruyarak, klinik karar verme süreçlerinde güvenilir bir temel oluşturur

(Aiello vd., 2021; Herz vd., 2017; Karagiannis, Magkos, Ntantogian, Cabecinha, & Fotis, 2023).

TIFF formatı, yüksek kaliteli görüntülerin depolanması için yaygın olarak kullanılan bir formattır. TIFF, kayıpsız sıkıştırma yöntemleri sunarak, görüntü kalitesinin korunmasını sağlar. Bu özellik, özellikle diş hekimliği gibi alanlarda, panoramik röntgen gibi görüntülerin depolanmasında önemlidir. Örneğin, yapılan bir çalışmada, TIFF formatındaki görüntülerin sıkıştırılması ile dosya boyutunun önemli ölçüde azaltıldığı ve depolama alanının verimli bir şekilde kullanıldığı gösterilmiştir. Ancak, TIFF formatı, DICOM'un sunduğu hasta bilgileri ve meta verileri gibi özellikleri içermez, bu nedenle genellikle DICOM ile kullanılmaktadır (Yasar, Apaydin, & Yilmaz, 2012).

NIFTI formatı, özellikle nöro-imge alanında yaygın olarak kullanılan bir formattır. NIFTI, beyin görüntüleme verilerinin depolanması ve analizi için optimize edilmiştir ve genellikle fonksiyonel Manyetik Rezonans Görüntüleme (fMRI) gibi tekniklerde kullanılır. NIFTI, görüntülerin yanı sıra, görüntülerin boyutları ve yönelimleri gibi bilgileri de içerir, bu da araştırmacıların görüntüleri daha etkili bir şekilde analiz etmelerine olanak tanımaktadır. NIFTI formatı, genellikle DICOM'dan dönüştürülerek kullanılır ve görüntülerin daha geniş bir analiz yelpazesine sahip olmasını sağlar. Tıbbi görüntüleme formatlarının seçimi, uygulamanın gereksinimlerine bağlıdır. DICOM, klinik uygulamalar için standart bir format olarak öne çıkarken, TIFF ve NIFTI gibi formatlar, belirli araştırma ve analiz ihtiyaçlarına göre tercih edilmektedir. Örneğin, DICOM formatı, hasta bilgilerini ve görüntüleri bir arada sunarak, klinik karar verme süreçlerinde önemli bir rol oynamaktadır. Öte yandan, TIFF formatı, görüntü kalitesinin ön planda olduğu durumlarda tercih edilirken, NIFTI formatı, nöro-imge ve araştırma uygulamalarında yaygın olarak kullanılmaktadır (Aiello vd., 2021; Herz vd., 2017).

2.2. Etiketleme ve Anotasyon Süreçleri

Doğru nesne tespiti için etiketleme ve anotasyon süreçleri, tıbbi görüntüleme alanında kritik bir öneme sahiptir. Bu süreçler, görüntülerdeki nesnelerin (örneğin tümörler, lezyonlar veya damar lümeni vb.) doğru bir şekilde tanımlanmasını ve sınıflandırılmasını sağlamak için gereklidir. Etiketleme, görüntülerin analiz edilmeden önce belirli nesnelerin veya bölgelerin işaretlenmesi anlamına gelirken, anotasyon, bu etiketlerin daha ayrıntılı açıklamalarla desteklenmesini içerir. Bu süreçlerin etkin bir şekilde uygulanması, makine öğrenimi ve derin öğrenme algoritmalarının başarısını doğrudan etkilemektedir (Mutlu & Kurnaz, 2023).

Etiketleme süreçleri, genellikle uzmanlar tarafından gerçekleştirilir ve bu uzmanlar, görüntüdeki nesneleri tanımlamak için belirli kriterlere göre çalışırlar. Örneğin, akciğer tümörlerinin tespiti için yapılan bir çalışmada, tümörlerin boyutları ve konumları gibi özellikler dikkate alınarak etiketleme yapılmaktadır (Mutlu & Kurnaz, 2023). Bu tür bir etiketleme, algoritmaların eğitiminde önemli bir rol oynar, çünkü doğru etiketlenmiş veriler, modelin nesneleri tanıma yeteneğini artırır. Ayrıca, etiketlenecek görüntünün kalitesi, modelin genel performansını etkileyen önemli bir faktördür; yanlış veya eksik etiketler, modelin hatalı sonuçlar üretmesine neden olabilmektedir. Bu nedenle görüntünün hatalardan arındırılması önemli bir süreç olarak değerlendirilmektedir (Ertas, 2023).

Anotasyon süreçleri, etiketleme ile çalışarak, görüntülerdeki nesnelerin daha ayrıntılı bir şekilde tanımlanmasını sağlar. Anotasyon, nesnelerin özelliklerini, boyutlarını, konumlarını ve diğer önemli bilgileri içerebilmektedir. Örneğin, bir lezyonun boyutu, şekli ve yoğunluğu gibi bilgiler, anotasyon sürecinde belirtilerek, modelin bu nesneleri daha iyi anlamasına yardımcı olmaktadır. Bu tür bilgiler, özellikle derin öğrenme algoritmala-

rının eğitiminde kritik öneme sahiptir, çünkü bu algoritmalar, nesnelerin karmaşık özelliklerini öğrenmek için büyük miktarda etiketlenmiş veriye ihtiyaç duymaktadır (Sümer, Engin, Ağildere, & Oğul, 2018).

Tıbbi görüntüleme alanında etiketleme ve anotasyon süreçlerinin etkinliği, kullanılan yöntemlere ve araçlara bağlıdır. Günümüzde, bu süreçleri hızlandırmak için çeşitli yazılımlar ve araçlar geliştirilmiştir. Bu araçlar, kullanıcıların görüntülerdeki nesneleri hızlı bir şekilde etiketlemelerine ve anotasyon yapmalarına olanak tanır. Örneğin, bazı yazılımlar, otomatik etiketleme algoritmaları kullanarak, insan müdahalesini en aza indirmeyi hedeflemektedir. Ancak, bu otomatik sistemlerin doğruluğu, genellikle insan uzmanlarının sağladığı etiketleme ile karşılaştırıldığında daha düşük olabildiği için hibrit yaklaşımlar da sıklıkla tercih edilmektedir (Dandil & Serin, 2020; Onan, 2022).

2.3. Veri Gizliliği ve Anonimleştirme

Tıbbi verilerde etik ve yasal gereklilikler, sağlık hizmetleri alanında veri gizliliği ve anonimleştirme süreçlerinin uygulanması hasta mahremiyetinin korunması ve veri güvenliğinin sağlanması açısından önemlidir. Tıbbi verilerin toplanması, işlenmesi ve paylaşılması sırasında uyulması gereken etik ve yasal standartlar, sağlık profesyonellerinin ve araştırmacıların sorumluluklarını belirlemekte ve hasta haklarını korumaktadır (Akal, 2021).

Veri gizliliği, tıbbi verilerin korunması için temel bir ilkedir. Hasta verilerinin gizliliği, yalnızca sağlık hizmeti sunan kurumlar tarafından değil, aynı zamanda bu verileri kullanan araştırmacılar ve diğer paydaşlar tarafından da sağlanmalıdır. Bu bağlamda, veri gizliliğini korumak için çeşitli yasal düzenlemeler ve standartlar bulunmaktadır. Örneğin, Türkiye’de 6698 sayılı Kişisel Verilerin Korunması Kanunu (KVKK) ve Avrupa Birliği’nin Genel Veri Koruma Yönetmeliği (GDPR), kişisel verile-

rin korunmasına yönelik sıkı kurallar getirmekte ve sağlık verilerinin işlenmesi sırasında dikkat edilmesi gereken etik ilkeleri belirlemektedir. Bu tür yasal düzenlemeler, hasta verilerinin izinsiz kullanımını engellemekte ve bireylerin mahremiyetini yasal zeminde korumayı hedeflemektedir (Akal, 2021).

Anonimleştirme, tıbbi verilerin gizliliğini sağlamak için kullanılan bir diğer önemli yöntemdir. Anonimleştirme süreci, bireylerin kimliklerinin belirlenememesi için verilerin değiştirilmesini içermektedir. Bu süreç, araştırmaların yürütülmesi sırasında hasta bilgilerini korurken, aynı zamanda veri analizi ve paylaşımını da mümkün kılmaktadır. Anonimleştirilmiş veriler, araştırmacılar tarafından daha güvenli bir şekilde kullanılabilir. Ancak, yanlış uygulamalar, bireylerin kimliklerinin açığa çıkmasına neden olabileceği için anonimleştirme sürecinin dikkatli bir şekilde uygulanması gerekmektedir (Vural, 2018).

Tıbbi verilerin etik kullanımı, yalnızca gizlilik ve anonimleştirme ile sınırlı değildir. Sağlık profesyonelleri ve araştırmacılar, hasta verilerini kullanırken etik ilkeleri göz önünde bulundurmalıdır. Bu ilkeler arasında, verilerin yalnızca belirli bir amaç için toplanması, hastaların bilgilendirilmesi ve onaylarının alınması, verilerin güvenli bir şekilde saklanması ve yalnızca gerekli durumlarda paylaşılması yer almaktadır (Akal, 2021; Benzinger, Ursin, Balke, Kacprowski, & Salloch, 2023).

3. NESNE TESPİTİ ALGORİTMALARINA GENEL BAKIŞ

3.1. Geleneksel Yöntemler

Nesne tespiti algoritmaları, görüntü işleme ve bilgisayarla görme alanında önemli bir yere sahiptir. Hough dönüşümü, kenar algılama (Canny ve Sobel) ve histogram analizleri gibi geleneksel yöntemler, nesne tespitinin temelini oluşturarak, daha karmaşık modern algoritmaların geliştirilmesine zemin hazırlamıştır.

Hough dönüşümü, özellikle düz çizgilerin ve diğer geometrik şekillerin tespiti için yaygın olarak kullanılan bir tekniktir. Bu yöntem, bir görüntüdeki noktaların parametre uzayında temsil edilmesiyle çalışır. Hough dönüşümünün temel avantajı, gürültüye karşı dayanıklı olması ve yerel bozulmalardan etkilenmemesidir. Bu özellikleri sayesinde, Hough dönüşümü, trafik işaretleri ve tıbbi görüntüler gibi çeşitli uygulamalarda etkili bir şekilde kullanılmaktadır. Hough dönüşümünün çeşitli varyasyonları, daireler ve elipsler gibi daha karmaşık şekillerin tespiti için de kullanılabilir (Dhanush; & Shetty, 2023; Jošth, Dubská, Herout, & Havel, 2011; Mingxing vd., 2015).

Kenar algılama, görüntülerdeki nesnelerin sınırlarını belirlemek için kullanılan bir başka önemli tekniktir. Canny kenar algılama, bu alandaki en popüler yöntemlerden biridir ve çok aşamalı bir süreçle çalışır. İlk olarak, görüntüdeki gürültüyü azaltmak için bir Gauss filtresi uygulanır. Ardından, görüntüdeki gradyanlar hesaplanarak, kenarların yerleri belirlenir. Canny yöntemi, yüksek doğruluk oranı ve düşük yanlış pozitif oranı ile bilinir, bu da onu tıbbi görüntüleme gibi hassas uygulamalar için uygun hale getirir (Tian, Li, & Zhang, 2015; Veeralakshmi, 2012). Sobel operatörü de kenar algılama için yaygın olarak kullanılan bir yöntemdir. Sobel, görüntüdeki gradyanları hesaplayarak, kenarların belirlenmesine yardımcı olur. Bu yöntem, özellikle basit ve hızlı olması nedeniyle birçok uygulamada tercih edilmektedir (C. Zhang & Fang, 2016).

Histogram analizi, görüntüdeki piksellerin yoğunluk dağılımını inceleyerek nesne tespiti için önemli bilgiler sağlar. Histogram, bir görüntüdeki farklı yoğunluk seviyelerinin sayısını gösterir ve bu bilgiler, görüntüdeki nesnelerin belirlenmesine yardımcı olabilir. Örneğin, bir görüntüdeki nesnelerin arka planından ayrılması için histogram eşikleme yöntemleri kullanılabilir. Bu yöntem, görüntüdeki nesnelerin belirginliğini artırarak, daha iyi bir nesne tespiti sağlar (Su vd., 2021).

3.2. Derin Öğrenme Tabanlı Yöntemler

Nesne tespiti algoritmaları, bilgisayarla görme ve yapay zekâ alanında önemli bir yere sahiptir. Geleneksel yöntemlerin yanı sıra, Convolutional Neural Networks (CNN), Region-based Convolutional Neural Networks (R-CNN), Fast R-CNN ve Faster R-CNN gibi derin öğrenme tabanlı yöntemler, nesne tespitinde devrim niteliğinde gelişmeler sağlamıştır.

Convolutional Neural Networks (CNN), görüntü işleme alanında en yaygın kullanılan derin öğrenme mimarilerinden biridir. CNN'ler, görüntülerdeki özellikleri otomatik olarak öğrenme yeteneğine sahip olup, bu özellikler sayesinde nesne tespitinde yüksek başarı oranları elde etmektedir. CNN'lerin temel yapısı, katmanlar arasında yer alan evrişim (convolution) ve birleştirme (pooling) işlemlerine dayanmaktadır. Bu işlemler, görüntüdeki önemli özelliklerin çıkarılmasına olanak tanır ve modelin nesneleri tanıma yeteneği artırılmaktadır (J. Huang vd., 2017; Li, 2024; Y. Zhang vd., 2019).

R-CNN, CNN mimarisinin nesne tespiti için özel bir uygulamasıdır. R-CNN, görüntüdeki potansiyel nesne bölgelerini (region proposals) belirlemek için selective search algoritmasını kullanır. Bu bölgeler daha sonra CNN ile işlenerek, nesnelerin sınıflandırılması sağlanmaktadır. R-CNN, nesne tespitinde önemli bir adım olarak kabul edilmekte olup, geleneksel yöntemlere göre daha yüksek doğruluk oranları sunmaktadır. Ancak, R-CNN'in en büyük dezavantajı, işlem süresinin uzun olmasıdır; çünkü her bir bölge için ayrı ayrı CNN uygulanması gerekmektedir (He, Gkioxari, Dollár, & Girshick, 2017).

Fast R-CNN, R-CNN'in geliştirilmiş bir versiyonudur ve işlem süresini azaltmayı hedefler. Fast R-CNN, görüntüyü tek bir CNN ile işler ve tüm nesne bölgeleri için özellik haritaları (feature maps) oluşturur. Bu özellik haritaları, daha sonra sınıflandırma ve nesne tespiti için kullanılır. Fast R-CNN, R-CNN'e

göre daha hızlı bir işlem süresi sunmakta ve gerçek zamanlı uygulamalarda daha etkili bir şekilde kullanılabilir (He vd., 2017). Fast R-CNN'in sağladığı bu avantajlar, nesne tespiti hızını artırmaktadır (Xu, Ren, Cai, & Zhang, 2023).

Faster R-CNN, Fast R-CNN'in bir başka geliştirilmiş versiyonudur ve nesne tespiti daha da hızlandırmayı hedefler. Faster R-CNN, Region Proposal Network (RPN) adı verilen bir yapı ekleyerek, potansiyel nesne bölgelerini otomatik olarak belirler. Böylece nesne tespiti süreci daha hızlı hale gelir ve işlem süresi önemli ölçüde azalır. Faster R-CNN, yüksek doğruluk oranları ve hızlı işlem süreleri ile dikkat çekmekte ve günümüzde birçok nesne tespiti uygulamasında kullanılmaktadır (He vd., 2017). Bu yöntem, özellikle tıbbi görüntüleme gibi alanlarda, nesnelerin hızlı ve doğru bir şekilde tespit edilmesine olanak tanır (Xu vd., 2023).

3.3. Yeni Nesil Algoritmalar

Yeni nesil nesne tespiti algoritmaları, derin öğrenme tekniklerinin gelişimi ile önemli bir ilerleme kaydetmiştir. Bu algoritmalar, özellikle YOLO, SSD (Single Shot MultiBox Detector) ve Transformer tabanlı yeni nesil yaklaşımlar ile nesne tespitinde yüksek doğruluk ve hız sunmaktadır.

YOLO, nesne tespitinde devrim niteliğinde bir yaklaşım sunmaktadır. YOLO, görüntüyü tek bir ağ geçişinde işleyerek, nesneleri tespit etme sürecini hızlandırır. Geleneksel yöntemlerde, nesne tespiti için görüntü üzerinde birden fazla geçiş yapılması gerekirken, YOLO bu süreci tek bir aşamada gerçekleştirir. Bu, gerçek zamanlı uygulamalarda büyük bir avantaj sağlar. YOLO, nesneleri tespit etmek için görüntüyü bir ızgara (grid) yapısına böler ve her bir hücrede nesne varlığını tahmin eder. Bu yöntem, özellikle hızlı ve etkili nesne tespiti gerektiren uygulamalarda, örneğin otonom araçlarda ve güvenlik sistemlerinde

yaygın olarak kullanılmaktadır (Akgül vd., 2024; Pang vd., 2019; Plata vd., 2022).

SSD, YOLO'ya benzer bir yaklaşım sergileyen bir diğer popüler nesne tespiti algoritmasıdır. SSD, görüntüyü tek bir geçişte işler ve farklı boyutlardaki nesneleri tespit etmek için birden fazla ölçek kullanır. Bu, SSD'nin farklı boyutlardaki nesneleri daha iyi tanımasına olanak tanır. SSD, ayrıca, nesne tespitinde yüksek doğruluk ve hızlı işlem süreleri sunarak, gerçek zamanlı uygulamalarda etkili bir şekilde kullanılmaktadır (Plata vd., 2022).

Transformers tabanlı yaklaşımlar, nesne tespitinde son yıllarda popülerlik kazanan bir diğer yöntemdir. Bu yöntemler, özellikle dikkat mekanizmaları (attention mechanisms) kullanarak, görüntüdeki önemli özellikleri daha etkili bir şekilde öğrenmektedir. Transformers, görüntü işleme alanında, nesne tespitinin yanı sıra, görüntü sınıflandırma ve segmentasyon gibi diğer görevlerde de kullanılmaktadır. Bu yaklaşımlar, büyük veri setleri üzerinde eğitilerek nesnelerin karmaşık ilişkilerini öğrenme yeteneğine sahiptir. Transformers tabanlı yöntemler, özellikle büyük ölçekli veri setleri ile çalışırken yüksek performans göstermektedir (Daş vd., 2019; Shou vd., 2022).

4. TIBBİ GÖRÜNTÜLERDE NESNE TESPİTİ İÇİN DERİN ÖĞRENME MODELLERİ

4.1. Veri Hazırlığı ve Ön İşleme

Tıbbi görüntülerde nesne tespiti için derin öğrenme modellerinin etkinliği, veri hazırlığı ve ön işleme süreçlerinin kalitesine doğrudan bağlıdır. Bu süreçler, görüntülerin analiz edilmeden önce uygun bir biçime getirilmesini sağlamak ve görüntü boyutlandırma, kontrast artırma ve veri artırımı teknikleri gibi ön işleme yöntemleri modelin genel performansını artırmaktadır.

Görüntü Boyutlandırma, derin öğrenme modellerinin girdi boyutlarının standartlaştırılması için kritik bir adımdır. Farklı kaynaklardan elde edilen tıbbi görüntüler, genellikle farklı boyut ve çözünürlüklerde olabildiği için modelin eğitim sürecinde tutarsızlıklara yol açabilir. Görüntü boyutlandırma, tüm görüntülerin belirli bir boyuta (örneğin 224x224 piksel) getirilmesini sağlar. Bu işlem, modelin daha hızlı ve etkili bir şekilde öğrenmesini sağlarken, aynı zamanda bellek kullanımını da optimize eder (Tahir vd., 2019). Örneğin, bir çalışmada, MRG ve BT görüntüleri üzerinde boyutlandırma işleminin, modelin sınıflandırma başarısını artırdığı gösterilmiştir (Tahir vd., 2019).

Kontrast Artırma, görüntülerin daha belirgin hale getirilmesi için kullanılan bir tekniktir. Tıbbi görüntülerde, özellikle tümörlerin ve lezyonların tespiti için kontrastın artırılması, bu yapıların daha iyi görünmesini sağlar. Kontrast artırma, genellikle histogram eşitleme veya adaptif histogram eşitleme (CLAHE) gibi yöntemlerle gerçekleştirilir. Bu teknikler, görüntüdeki düşük kontrastlı bölgelerin daha belirgin hale gelmesine yardımcı olur ve böylece modelin nesneleri tanıma yeteneğini artırmaktadır (C. T. Cheng vd., 2019; Feng, Wang, Wang, Ding, & Zhang, 2021). Yapılan bir araştırmada, kontrast artırma işleminin, beyin tümörü segmentasyonu üzerindeki etkisi incelenmiş ve bu işlemin modelin doğruluğunu artırdığı bulunmuştur (Feng vd., 2021).

Veri Artırımı Teknikleri, derin öğrenme modellerinin genel performansını artırmak için yaygın olarak kullanılan bir yöntemdir. Veri artırımı, mevcut veri setinin çeşitliliğini artırmak amacıyla görüntülerin çeşitli dönüşümlerle değiştirilmesini içerir. Bu dönüşümler arasında döndürme, ölçekleme, kaydırma, ayna görüntüleme ve gürültü ekleme gibi işlemler yer alır. Veri artırımı, modelin aşırı öğrenmesini (overfitting) önlemeye yardımcı olup ve daha genel bir model oluşturulmasını sağlamaktadır. Örneğin, bir çalışmada, veri artırımı tekniklerinin kullanı-

masıyla elde edilen genişletilmiş veri setinin, modelin genel başarısını önemli ölçüde artırdığı gösterilmiştir (Yu, Sun, Xiong, Gao, & Qu, 2022).

4.2. Modellerin Eğitimi ve Doğrulanması

Tıbbi görüntülerde nesne tespiti için derin öğrenme modellerinin eğitimi ve doğrulanması, etkili bir model geliştirmek için önemli bir aşamadır. Bu süreç, veri kümesinin uygun bir şekilde bölünmesi ve değerlendirme metriklerinin belirlenmesi ile başlayıp ve eğitim sürecinin başarımlı ölçütleri olan değerlendirme metrikleri ile devam etmektedir.

Veri Kümesi Bölünmesi, derin öğrenme modellerinin eğitiminde önemli bir adımdır. Genellikle, veri kümesi üç ana bölüme ayrılır: eğitim (train), doğrulama (validation) ve test (test) setleri. Eğitim seti, modelin öğrenme sürecinde kullanılan verileri içerirken, doğrulama seti, modelin hiperparametrelerini ayarlamak ve modelin genel performansını değerlendirmek için kullanılır. Test seti ise, modelin gerçek dünya verileri üzerindeki performansını değerlendirmek için ayrılır. Bu bölünme, modelin aşırı öğrenmesini (overfitting) önlemeye yardımcı olur ve modelin genelleme yeteneğini artırmaktadır (Hosny vd., 2018; Philbrick vd., 2019).

Eğitim seti genellikle veri kümesinin %70-80'ini oluştururken, doğrulama ve test setleri sırasıyla %10-15 ve %10-15 oranında ayrılır. Bu oranlar, veri kümesinin büyüklüğüne ve modelin karmaşıklığına bağlı olarak değişebilir. Örneğin, büyük veri setlerinde, test setine daha büyük bir oranı ayrılabilirken, küçük veri setlerinde bu oranlar daha dengeli olabilir (Philbrick vd., 2019).

Değerlendirme Metrikleri, modelin performansını ölçmek için kullanılır. Tıbbi görüntülerde nesne tespiti için yaygın olarak kullanılan değerlendirme metrikleri arasında mAP (mean

Average Precision) ve IoU (Intersection over Union) bulunmaktadır.

mAP, nesne tespitinde modelin doğruluğunu ölçmek için kullanılan bir metriktir. mAP, her bir nesne sınıfı için ortalama doğruluğu hesaplayarak, tüm sınıflar için genel bir performans değerlendirmesi sağlar. Bu metrik, özellikle çok sınıflı nesne tespiti görevlerinde yaygın olarak kullanılmaktadır (Faes vd., 2019; Sheller, Reina, Edwards, Martin, & Bakas, 2019).

IoU, tespit edilen nesne ile gerçek nesne arasındaki örtüşmeyi ölçen bir metriktir. IoU, tespit edilen nesne alanının gerçek nesne alanı ile kesişim alanının oranı olarak tanımlanır. Bu metrik, nesne tespitinin doğruluğunu değerlendirmek için yaygın olarak kullanılmakta ve genellikle belirli bir eşik değeri (örneğin 0.5) ile karşılaştırılarak değerlendirilir (Chang, Huang, Liu, Chung, & Juan, 2021; C. T. Cheng vd., 2019).

4.3. Güncel Çalışmalar

Tıbbi görüntülerde nesne tespiti için derin öğrenme modellerinin retinal anomali tespiti, COVID-19 teşhisi, kemik metastazı tespiti, hücre canlılığı değerlendirmesi, gastroskopi, kan transfüzyonu, beyaz kan hücresi tespiti ve histoloji tabanlı çekirdek tespiti gibi örnekler, bu teknolojilerin sağlık alanında nasıl devrim yarattığını göstermektedir.

Retinal Anomali Tespiti: Özellikle diyabetik maküler ödem gibi retinal hastalıkların belirtilerinin erken teşhisi için derin öğrenme tabanlı algoritmalar kullanılmaktadır. Optik Kohrens Tomografi (OCT) ve fundus görüntüleri kullanarak diyabetik maküler ödemin tespitinde derin öğrenme yöntemlerinin etkinliğini göstermiştir. Bu çalışma, derin öğrenme algoritmalarının, geleneksel yöntemlere göre daha yüksek doğruluk oranları sağladığını ortaya koymuştur (Kang vd., 2020; Manikandan, Raman, Rajalakshmi, Tamilselvi, & Surya, 2023).

COVID-19 Teşhisi: Derin öğrenme tabanlı modeller, akciğer röntgenleri ve BT görüntüleri üzerinde eğitilerek COVID-19'un varlığını hızlı bir şekilde tespit etmekte kullanılmaktadır (Sahin, Ulutas, Yuce, & Erkoc, 2023).

Kemik Metastazi Tespiti: Derin öğrenme algoritmaları, kemik görüntülerinde metastatik lezyonların otomatik olarak tespit edilmesini sağlamaktadır (D.-C. Cheng, Hsieh, Yen, & Kao, 2021).

Gastroskopi: Sindirim sistemi hastalıklarının teşhisinde derin öğrenme tabanlı nesne tespitinin önemli bir uygulama alanıdır. Gastroskopi sırasında elde edilen görüntüler üzerinde derin öğrenme algoritmaları kullanılarak, polip ve diğer anormalliklerin otomatik olarak tespit edilmesi sağlanmaktadır (Akalın & Yumuşak, 2024).

Beyaz Kan Hücresi Tespiti: Beyaz kan hücrelerinin periferik yayma preparatlarında otomatik tespiti için geliştirilen derin öğrenme tabanlı modeller, kan örneklerinde beyaz kan hücrelerinin sayısını ve türlerini belirlemek için kullanılmaktadır (M. Huang, Wang, Wan, & Zhou, 2023).

Sperm Tespiti: Üreme sağlığı alanında derin öğrenme uygulamalarının bir örneğidir. Derin öğrenme algoritmaları, sperm hücrelerinin otomatik olarak tespit edilmesi ve sınıflandırılması için kullanılmaktadır. Bu uygulama, fertilite değerlendirmelerinde önemli bir rol oynamakta ve sperm kalitesinin belirlenmesine yardımcı olmaktadır (Yuzkat, Ilhan, & Aydin, 2023).

Tümör Lokalizasyonu: Tıbbi görüntülemede derin öğrenme yöntemlerinin etkili bir şekilde kullanıldığı bir alandır. Derin öğrenme tabanlı modeller, tümörlerin konumunu, boyutunu ve çevre doku ile ilişkisini belirlemek için görüntüleri analiz ederek ve cerrahi müdahale planlamasında etkili bir araç haline

gelmektedir (Shen vd., 2019; Umer, Sharif, Kadry, & Alharbi, 2022).

Vitiligo Lezyonları: Cilt hastalıklarının tespitinde derin öğrenme algoritmaları, vitiligo lezyonlarının otomatik olarak tespit edilmesi için kullanılmaktadır (Dixit, Sharma, Gupta, Singh, & Chaudhary, 2024).

Beyin Tümörü Tespiti: Tıbbi görüntülemede derin öğrenme yöntemlerinin dikkat çekici uygulamalarından biridir. Derin öğrenme tabanlı algoritmalar, MRG görüntülerinde beyin tümörlerinin otomatik olarak tespit edilmesi için kullanılmaktadır (Sheller vd., 2019; Tahir vd., 2019).

Meme Kanseri Tespiti: Derin öğrenme uygulamalarının en yaygın kullanıldığı alanlardan biridir. Derin öğrenme tabanlı modeller, mamografi ve USG görüntüleri üzerinde meme kanserinin otomatik olarak tespit edilmesi için kullanılarak erken teşhis olanakları artırılmaktadır (Ayatollahi vd., 2021; Choi vd., 2019; Dalmis vd., 2018; Kim & Kim, 2022; Samala vd., 2019; Sha, Hu, & Rouyendegh, 2020; Shinzaki vd., 2023).

Stenoz Tespiti: Damar hastalıklarının teşhisinde derin öğrenme yöntemlerinin önemli bir uygulamasıdır. Derin öğrenme tabanlı algoritmalar, Koroner anjiyografi görüntülerinde stenozun otomatik olarak tespit edilmesi ile hastaların tedavi süreçleri daha etkin bir şekilde yönetilmektedir (Akgül vd., 2024; Cao vd., 2019).

Kolon Polipleri Tespiti: Sindirim sistemi hastalıklarının teşhisinde derin öğrenme uygulamalarının bir diğer önemli örneğidir. Derin öğrenme tabanlı modeller, kolon görüntülerinde poliplerin otomatik olarak tespit edilmesi için kullanılmaktadır (Yu vd., 2022).

Dental Çürük Tespiti: Derin öğrenme tabanlı modeller, periapikal ve bitewing radyografilerde dental çürüklerin otoma-

tik olarak tespit edilmesinde kullanılmaktadır. Örneğin, Lee ve arkadaşları, bitewing radyografilerinde erken dental çürük tespiti için derin öğrenme yöntemlerini kullanmış ve bu yöntemlerin yüksek doğruluk oranları sağladığını göstermiştir (Lee vd., 2021).

Safra Taşı Tespiti: Derin öğrenme uygulamalarının bir diğer önemli alanıdır. Pang ve arkadaşları, BT görüntülerinde safra taşlarının otomatik olarak tespit edilmesi için YOLO tabanlı bir model geliştirmiştir. Bu çalışma, derin öğrenme yöntemlerinin safra taşı tespitindeki etkinliğini göstermektedir (Pang vd., 2019).

Akciğer Nodülü Tespiti: akciğer kanseri teşhisinde derin öğrenme tabanlı modeller, akciğer BT görüntülerinde nodüllerin otomatik olarak tespit edilmesini sağlamaktadır (Liang vd., 2023).

Tıbbi görüntülerde nesne tespitine yönelik derin öğrenme modellerinin başarılı örnekleri, bu teknolojinin sağlık hizmetlerine sağladığı önemli katkıları açıkça göstermektedir. Dental çürük tespitinden safra taşı analizine, retinal anomali tanısından COVID-19 teşhisine kadar çok çeşitli uygulamalar, derin öğrenmenin teşhis ve tedavi süreçlerine getirdiği devrim niteliğindeki dönüşüme işaret etmektedir.

5. TEKNİK VE KLİNİK ZORLUKLAR

5.1. Verinin Yetersizliği ve Dengesizliği

Tıbbi görüntülerde nesne tespiti için derin öğrenme modellerinin eğitimi ve uygulanması sırasında karşılaşılan en büyük zorluklardan biri, veri yetersizliği ve dengesizliğidir.

Veri Yetersizliği, derin öğrenme modellerinin eğitiminde önemli bir engel teşkil etmektedir. Tıbbi görüntüleme alanında, belirli hastalıkların veya durumların tespiti için yeterli sayıda etiketlenmiş veri elde etmek genellikle zordur. Özellikle nadir

hastalıklar veya belirli lezyon türleri için veri setleri sınırlı kalabilmektedir. Bu durum, modelin genel performansını olumsuz etkileyebilir, çünkü derin öğrenme algoritmaları genellikle büyük veri setlerine ihtiyaç duyar. Yetersiz veri, modelin aşırı öğrenmesine (overfitting) yol açabilir; bu da modelin eğitim verisine iyi uyum sağlamasına rağmen, yeni veriler üzerinde düşük performans göstermesine neden olur (Deveci & Esen, 2022).

Dengesiz Sınıflar Problemi, veri yetersizliği ile ortaya çıkan bir diğer önemli sorundur. Tıbbi görüntüleme veri setlerinde, bazı sınıflar (örneğin, kanserli lezyonlar) diğerlerine (örneğin, sağlıklı dokular) göre çok daha az sayıda örnek içerebilir. Bu durum, modelin dengesiz sınıflar arasında öğrenme sürecinde zorluk yaşamasına neden olur. Dengesiz sınıflar, modelin daha sık görülen sınıflara odaklanmasına ve nadir görülen sınıfları göz ardı etmesine yol açabilir. Bu durum modelin genel doğruluğu düşürebilirken, nadir sınıfların tespitindeki başarısı düşebilir (Deveci & Esen, 2022).

Bu sorunların üstesinden gelmek için çeşitli stratejiler ve teknikler geliştirilmiştir. Veri Artırımı (data augmentation), sınırlı veri setlerini genişletmek için yaygın olarak kullanılan bir yöntemdir. Bu teknik, mevcut görüntülerin çeşitli dönüşümlerle (döndürme, ölçekleme, kaydırma vb.) değiştirilmesi ile modelin daha fazla örnekle eğitim almasını sağlayarak, aşırı öğrenme riski azaltmaktadır (Akgül vd., 2024; Deveci & Esen, 2022).

Dengeleme Yöntemleri, dengesiz sınıflar problemini ele almak için kullanılan bir diğer yaklaşımdır. Bu yöntemler, az sayıda örneğe sahip sınıfların sayısını artırmak (örneğin, örnek çoğaltma) veya daha fazla örneğe sahip sınıfların sayısını azaltmak (örneğin, örnek çıkarma) şeklinde uygulanabilir. Ayrıca, bazı algoritmalar, dengesiz veri setleri üzerinde daha iyi performans gösterecek şekilde tasarlanmıştır. Örneğin, sınıf ağırlıklandırma (class weighting) yöntemi, daha az temsil edilen sınıf-

lara daha yüksek ağırlıklar vererek, modelin bu sınıfları daha fazla dikkate almasını sağlamaktadır (Deveci & Esen, 2022; Yu vd., 2022).

5.2. Modelin Genelleme Kapasitesi

Tıbbi görüntülerde nesne tespiti için derin öğrenme modellerinin genelleme kapasitesi, bir modelin eğitim setinde görüldüğü veriler dışında, yeni ve daha önce karşılaşmadığı veriler üzerinde ne kadar iyi performans gösterdiğini ifade eder ve bu durum modellerin eğitim setindeki verilerle sınırlı performans göstermesi nedeniyle önemli bir zorluk teşkil etmektedir. Derin öğrenme modelleri, genellikle büyük veri setleri üzerinde eğitilerek karmaşık ilişkileri öğrenme yeteneğine sahip olsalar da bu modellerin genelleme yetenekleri, eğitim verilerinin kalitesine ve çeşitliliğine bağlıdır (Africano, Arponen, Rinta-Kiikka, & Pertuz, 2024; Liang vd., 2023).

Eğitim setinde yeterince temsil edilmeyen sınıflar veya durumlar, modelin bu sınıfları tanıma yeteneğini olumsuz etkileyebilir. Örneğin, belirli bir hastalığın nadir görülen türleri için eğitim verisi yetersizse, model bu türleri tespit etmede başarısız olabilmektedir. Az sayıda örnek ve dengesiz sınıflar, genelleme kapasitesini etkileyen önemli faktörlerdir. Tıbbi görüntüleme alanında, bazı hastalıklar veya durumlar için sınırlı sayıda etiketlenmiş veri nedeniyle modelin belirli sınıflar üzerinde yeterince eğitim alamamasına ve dolayısıyla bu sınıfların tespitinde düşük performans göstermesine yol açmaktadır (Gaya-Vilar vd., 2024). Örneğin, nadir görülen tümör türleri veya belirli lezyonlar için yeterli veri olmaması, modelin bu durumları doğru bir şekilde tanımasını engelleyebilir.

Transfer Öğrenme, genelleme kapasitesini artırmak için kullanılan bir diğer etkili yöntemdir. Bu yaklaşım, önceden eğitilmiş bir modelin, yeni bir görev için yeniden eğitilmesini içerir. Örneğin, bir model, geniş bir veri seti üzerinde eğitim aldı-

tan sonra, daha küçük bir tıbbi görüntü seti üzerinde ince ayar (fine-tuning) yapılarak kullanılabilmesi sınırlı veri setleri ile çalışırken modelin performansını artırmakta etkili olmaktadır (Samala vd., 2019).

5.3. Hesaplama Gücü ve Süreç Maliyetleri

Tıbbi görüntülerde nesne tespiti için derin öğrenme modellerinin uygulanması, hesaplama gücü ve süreç maliyetleri açısından önemli zorluklar içermektedir.

Büyük derin öğrenme modelleri, genellikle milyonlarca parametre içerir ve bu nedenle yüksek hesaplama gücü gerektirir. Özellikle, konvolüsyonel sinir ağları (CNN) gibi karmaşık mimariler, büyük veri setleri üzerinde eğitim alırken, güçlü grafik işleme birimlerine (GPU) ihtiyaç duymaktadır. Bu durum, yüksek performanslı donanım ve enerji tüketimi gereksinimi nedeniyle derin öğrenme uygulamalarının maliyetlerini artırıcı bir etken olarak görülmektedir (Xiao, Choi, & Sun, 2018).

Süreç maliyetleri, derin öğrenme modellerinin eğitim ve uygulama aşamalarında önemli bir rol oynamaktadır. Eğitim süreci, büyük veri setlerinin işlenmesi ve modelin optimize edilmesi için zaman alıcıdır. Bu süreç, genellikle saatler veya günler sürebilir ve bu da yüksek enerji maliyetlerine yol açmaktadır. Özellikle, büyük ölçekli sağlık verileri ile çalışırken, bu maliyetler daha da artmaktadır (Purushotham, Meng, Che, & Liu, 2018).

Enerji Tüketimi, büyük derin öğrenme modellerinin çalıştırılması sırasında dikkate alınması gereken bir diğer önemli faktördür. Yüksek hesaplama gücü gereksinimleri, enerji tüketimini artırmakta ve bu da maliyetleri yükseltmektedir. Özellikle, büyük veri setleri üzerinde eğitilen modeller, uzun süreli işlem süreleri gerektirdiğinden, enerji maliyetleri önemli bir sorun haline gelebilir (Mese, Altintas Taslicay, & Sivrioglu, 2024).

5.4. Klinik Kabul ve Güvenilirlik Sorunları

Tıbbi görüntülerde nesne tespiti için derin öğrenme modellerinin klinik kabulü ve güvenilirlik sorunları, sağlık personelinin bu modellerin sonuçlarını güvenle kullanılmasını etkileyen faktörlerdendir.

Klinik kabul sorunları, derin öğrenme tabanlı modellerin sağlık hizmetlerinde benimsenmesini etkileyen temel faktörlerdendir. Sağlık profesyonelleri, yapay zekâ sistemlerinin karar verme süreçlerine entegre edilmesi konusunda genellikle temkinli yaklaşmaktadır. Bir çalışmada, hastalar ve ailelerinin yapay zekâ müdahalelerine karşı duyduğu tereddütlerin, veri gizliliği, hasta güvenliği ve yapay zekâ müdahalelerinin uygunluğu gibi konulardan kaynaklandığı belirtilmiştir. Bu durum, sağlık personelinin yapay zekâ sistemlerine olan güvenini zedeleyebildiği gibi bu sistemlerin klinik uygulamalarda benimsenmesine karşı ön yargı oluşturmaktadır (Kwong vd., 2022).

Yapay zekâ sistemlerinin karar verme süreçlerinde kullanılabilmesi için, bu sistemlerin güvenilir ve doğru sonuçlar üretmesi gerekmektedir. Ancak, bu sistemlerinin "kara kutu" olarak algılanması, sağlık profesyonellerinin bu sistemlere güven duymasını zorlaştırmaktadır (Fiske, Henningsen, & Buyx, 2019). Özellikle, bu sistemlerinin nasıl çalıştığı ve karar verme süreçlerinin arka planında nelerin yer aldığı konusunda yeterli bilgiye sahip olmamak, sağlık personelinin bu sistemlere olan güvenini azaltmaktadır (Benzinger vd., 2023).

Sağlık profesyonellerine, yapay zekâ sistemlerinin nasıl çalıştığı, hangi verileri kullandığı ve sonuçların nasıl yorumlanması gerektiği konusunda eğitim verilmesi, bu sistemlerin benimsenmesini artırabilmektedir (Tsopra vd., 2021). Ayrıca, bu sistemlerinin klinik uygulamalarda nasıl entegre edileceği konusunda net bir rehberlik sağlanması da önemlidir (Bouman vd., 2023).

Yapay zekâ sistemlerinin karar verme süreçlerinin şeffaf bir şekilde sunulması, sağlık profesyonellerinin bu sistemlere olan güvenini artırabileceği ve özellikle açıklanabilir yapay zekâ yaklaşımları, sağlık profesyonellerinin bu sistemlerinin sonuçlarını daha iyi anlamalarına yardımcı olarak klinik karar verme süreçlerinde daha etkin bir şekilde kullanılmasını sağlayacaktır (Saner, Saner, Abufarhaneh, Broering, & Raptis, 2024; Wang, Yuan, Ding, & Zhou, 2021).

6. GELECEĞE YÖNELİK PERSPEKTİFLER

Tıbbi görüntülerde nesne tespiti için derin öğrenme modellerinin geleceği, yapay zekâ alanındaki transfer öğrenimi, multitask öğrenme ve federated learning (federatif öğrenme) gibi yenilikçi yönelimlerle şekillenmektedir.

Transfer Öğrenimi, derin öğrenme modellerinin genelleme kapasitesini artırmak için önemli bir yöntemdir. Transfer öğrenimi, bir modelin bir görevde öğrendiği bilgilerin, benzer bir başka görevde kullanılmasını sağlar. Bu yaklaşım, özellikle sınırlı veri setleri ile çalışırken büyük avantajlar sunmaktadır. Transfer öğrenimi, tıbbi görüntüleme alanında, nadir hastalıkların tespitinde ve sınırlı veri setleri ile çalışırken büyük bir potansiyele sahiptir (Africano vd., 2024; Chen vd., 2022).

Multitask Öğrenme, birden fazla görevin aynı anda öğrenilmesini sağlayan bir yaklaşımdır. Bu yöntem, farklı görevler arasında bilgi paylaşımını teşvik ederek, modelin genel performansını artırabilir. Örneğin, bir modelin hem tümör tespiti hem de lezyon segmentasyonu gibi iki farklı görevi aynı anda öğrenmesi, her iki görevin de doğruluğunu artırabilir. Gao ve arkadaşları, multitask öğrenmenin, derin öğrenme uygulamalarında nasıl etkili bir şekilde kullanılabileceğini ve bu yaklaşımın sağlık alanındaki potansiyelini vurgulamıştır (Gao, Yoon, Wu, & Chu, 2020). Bu tür bir yaklaşım, özellikle çoklu hastalıkların veya durumların tespitinde faydalı olabilir (Zhou vd., 2022).

Federated Learning (federatif öğrenme), veri gizliliği ve güvenliği konularında önemli bir çözüm sunmaktadır. Bu yöntem, verilerin merkezi bir sunucuda toplanmadan, yerel cihazlarda eğitim yapılmasına olanak tanıyarak kullanıcıların verileri gizli kalırken, modelin genel performansı artırma avantajı sağlamaktadır. Federatif öğrenme, özellikle sağlık verilerinin gizliliğinin kritik olduğu durumlarda büyük bir avantaj sunmaktadır (Sheller vd., 2019).

7. SONUÇ

Tıbbi görüntülemede yapay zekâ temelli nesne tespiti yöntemleri, son yıllarda tanı ve tedavi süreçlerini önemli ölçüde iyileştirme potansiyeliyle ön plana çıkmaktadır. Özellikle radyolojik yöntemler (USG, MRG, BT) ve histopatolojik preparatların incelenmesi gibi farklı tıbbi modalitelerdeki görüntülerin analizi, derin öğrenme tabanlı modellerin sunduğu yüksek doğruluk ve hız avantajlarıyla desteklenmektedir (Eker & Duru, 2021; Kircher & Willmann, 2012; Kumrular & Polat, 2021). Bu yaklaşımlar, tümör tespiti, lezyon analizi ve damar lümen belirleme gibi kritik uygulamalarda nesne tespitini daha etkili hale getirerek klinik karar verme süreçlerine nitelikli katkı sağlamaktadır (Akgül vd., 2024; Pang vd., 2019).

Derin öğrenme modellerinin performansını artıran önemli faktörler arasında veri kalitesi, etik ve yasal uyumluluk, anonimleştirme ve standart görüntü formatlarının (DICOM, TIFF, NIfTI) etkin kullanımı bulunmaktadır (Aiello vd., 2021; Herz vd., 2017; Yasar vd., 2012). Aynı zamanda, etiketleme ve anotasyon süreçlerinin dikkatli yürütülmesi, makine öğrenimi algoritmalarının daha başarılı sonuçlar üretmesini sağlayarak model performansının yükseltilmesinde kritik bir rol oynamaktadır (Mutlu & Kurnaz, 2023). Bunun yanı sıra, veri mahremiyeti, veri güvenliği ve hasta haklarının korunması da tıbbi verilerde

etik ve yasal gerekliliklerin uygulanmasında göz önünde bulundurulması gereken öncelikli unsurlardır (Akal, 2021).

Geleneksel nesne tespiti yöntemlerinden (Hough dönüşümü, kenar algılama, histogram analizleri) günümüzün derin öğrenme tabanlı yaklaşımlarına (CNN, R-CNN, Fast/Faster R-CNN, YOLO, SSD, Transformers) kadar uzanan geniş bir yöntem yelpazesi, tıbbi görüntülerdeki nesne tespitini her geçen gün daha etkin ve verimli hale getirmektedir (Daş vd., 2019; He vd., 2017; J. Huang vd., 2017; Plata vd., 2022; Y. Zhang vd., 2019). Bu gelişimin devamlılığında, görüntü işleme ön adımları (boyutlandırma, kontrast artırma, veri artırımı) ve eğitim, doğrulama ile test aşamalarının dikkatli bir şekilde organize edilmesi, elde edilen modellerin sahada güvenilir sonuçlar sunmasında belirleyici olmaktadır (Chang vd., 2021; C. T. Cheng vd., 2019; Feng vd., 2021; Tahir vd., 2019; Yu vd., 2022).

Bununla birlikte, veri yetersizliği, dengesiz veri dağılımları, yüksek hesaplama gücü gereksinimleri ve uzun eğitim süreleri gibi pratik zorluklar, modelin genelleme kapasitesi ve klinik kabulü açısından dikkate alınması gereken konulardır (Africano vd., 2024; Akgül vd., 2024; Deveci & Esen, 2022; Gaya-Vilar vd., 2024; Liang vd., 2023; Samala vd., 2019; Szenicer vd., 2019). Ayrıca, modellerin açıklanabilirliği, şeffaflığı ve sağlık personelinin bu teknolojilere olan güveni de klinik ortamlarda yapay zekâ tabanlı çözümlerin benimsenmesini doğrudan etkilemektedir (Benzinger vd., 2023; Bouman vd., 2023; Fiske vd., 2019; Kwong vd., 2022; Saner vd., 2024; Tsopra vd., 2021; Wang vd., 2021).

Geleceğe yönelik bakıldığında, transfer öğrenimi, multi-task öğrenme ve federated learning gibi yeni yaklaşımlar, daha genelleştirilebilir, güvenli ve ölçeklenebilir modellerin geliştirilmesine imkân tanımaktadır (Africano vd., 2024; Chen vd., 2022; Gao vd., 2020; Sheller vd., 2019; Zhou vd., 2022).

Sonuç olarak, yapay zekâ destekli nesne tespiti yöntemlerinin tıbbi görüntüleme alanında sağladığı teknolojik ilerlemeler, klinik uygulamalarda daha etkin, hızlı ve güvenilir tanı-tedavi süreçlerinin önünü açmaktadır. Bu alandaki yenilikçi çözümlerin geliştirilmesi, etik ve yasal standartlara uyum, veri gizliliği ve kaliteli anotasyon süreçleriyle desteklenerek, tıbbi görüntülemenin gelecekte daha verimli, güvenilir ve hasta odaklı hale gelmesine katkı sunacaktır. Böylelikle, yapay zekâyâ dayalı nesne tespiti yöntemlerinin genişleyen kullanım alanı, sağlık hizmetlerinin kalitesini artırarak tıp alanındaki yenilikçi uygulamalara yön vermeye devam edecektir.

KAYNAKÇA

- Africano, G., Arponen, O., Rinta-Kiikka, I., & Pertuz, S. (2024). Transfer learning for the generalization of artificial intelligence in breast cancer detection: a case-control study. *Acta Radiologica*, 65(4), 334-340. doi:10.1177/02841851231218960
- Aiello, M., Esposito, G., Pagliari, G., Borrelli, P., Brancato, V., & Salvatore, M. (2021). How does DICOM support big data management? Investigating its use in medical imaging community. *Insights Imaging*, 12(1), 164. doi:10.1186/s13244-021-01081-8
- Akal, Ş. (2021). Elektronik Sağlık Kayıt Sistemleri. İçinde N. Bozbuğa & S. Gülseçen (Eds.), *Tıp Bilişimi* (pp. 79-106): IU PRESS.
- Akalın, F., & Yumuşak, N. (2024). Derin öğrenme tabanlı topluluk sınıflandırıcı yaklaşımı ile gastrointestinal anomalilerin tespiti. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 30(3), 366-373. doi:10.5505/pajes.2023.90602
- Akgül, M., Kozan, H. İ., Akyürek, H. A., & Taşdemir, Ş. (2024). Automated stenosis detection in coronary artery disease using yolov9c: Enhanced efficiency and accuracy in real-time applications. *Journal of Real-Time Image Processing*, 21(5), 177. doi:10.1007/s11554-024-01558-x
- Arserim, M. A., & Usta, A. (2023). İnsansız hava aracından çekilen videolar kullanılarak derin öğrenme yaklaşımı ile nesne tespiti. *Dümf Mühendislik Dergisi*. doi:10.24012/dumf.1191160

- Ayatollahi, F., Shokouhi, S. B., Mann, R. M., & Teuwen, J. (2021). Automatic breast lesion detection in ultrafast DCE-MRI using deep learning. *Med Phys*, 48(10), 5897-5907. doi:10.1002/mp.15156
- Bayraktar, Y., & Ayan, E. (2022). Diagnosis of interproximal caries lesions with deep convolutional neural network in digital bitewing radiographs. *Clin Oral Investig*, 26(1), 623-632. doi:10.1007/s00784-021-04040-1
- Benzinger, L., Ursin, F., Balke, W. T., Kacprowski, T., & Salloch, S. (2023). Should Artificial Intelligence be used to support clinical ethical decision-making? A systematic review of reasons. *BMC Med Ethics*, 24(1), 48. doi:10.1186/s12910-023-00929-6
- Bouman, P. M., Noteboom, S., Nobrega Santos, F. A., Beck, E. S., Bliault, G., Castellaro, M., . . . Steenwijk, M. D. (2023). Multicenter Evaluation of AI-generated DIR and PSIR for Cortical and Juxtacortical Multiple Sclerosis Lesion Detection. *Radiology*, 307(2), e221425. doi:10.1148/radiol.221425
- Cao, Z., Duan, L., Yang, G., Yue, T., & Chen, Q. (2019). An experimental study on breast lesion detection and classification from ultrasound images using deep learning architectures. *BMC Med Imaging*, 19(1), 51. doi:10.1186/s12880-019-0349-x
- Chang, Y. J., Huang, T. Y., Liu, Y. J., Chung, H. W., & Juan, C. J. (2021). Classification of parotid gland tumors by using multimodal MRI and deep learning. *NMR Biomed*, 34(1), e4408. doi:10.1002/nbm.4408

- Chen, W. M., Fu, M., Zhang, C. J., Xing, Q. Q., Zhou, F., Lin, M. J., . . . Pan, J. S. (2022). Deep Learning-Based Universal Expert-Level Recognizing Pathological Images of Hepatocellular Carcinoma and Beyond. *Front Med (Lausanne)*, 9, 853261. doi:10.3389/fmed.2022.853261
- Cheng, C. T., Ho, T. Y., Lee, T. Y., Chang, C. C., Chou, C. C., Chen, C. C., . . . Liao, C. H. (2019). Application of a deep learning algorithm for detection and visualization of hip fractures on plain pelvic radiographs. *Eur Radiol*, 29(10), 5469-5477. doi:10.1007/s00330-019-06167-y
- Cheng, D.-C., Hsieh, T.-C., Yen, K.-Y., & Kao, C.-H. (2021). Lesion-Based Bone Metastasis Detection in Chest Bone Scintigraphy Images of Prostate Cancer Patients Using Pre-Train, Negative Mining, and Deep Learning. *Diagnostics*, 11(3). doi:10.3390/diagnostics11030518
- Choi, J. S., Han, B. K., Ko, E. S., Bae, J. M., Ko, E. Y., Song, S. H., . . . Hahn, S. Y. (2019). Effect of a Deep Learning Framework-Based Computer-Aided Diagnosis System on the Diagnostic Performance of Radiologists in Differentiating between Malignant and Benign Masses on Breast Ultrasonography. *Korean J Radiol*, 20(5), 749-758. doi:10.3348/kjr.2018.0530
- Dalmis, M. U., Vreemann, S., Kooi, T., Mann, R. M., Karssemeijer, N., & Gubern-Merida, A. (2018). Fully automated detection of breast cancer in screening MRI using convolutional neural networks. *J Med Imaging (Bellingham)*, 5(1), 014502. doi:10.1117/1.JMI.5.1.014502

- Dandil, E., & Serin, Z. (2020). Derin Sinir Ağları Kullanarak Histopatolojik Görüntülerde Meme Kanseri Tespiti. *European Journal of Science and Technology*, 451-463. doi:10.31590/ejosat.780705
- Daş, R., Polat, B., & Tuna, G. (2019). Derin Öğrenme ile Resim ve Videolarda Nesnelerin Tanınması ve Takibi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(2), 571-581. doi:10.35234/fumbd.608778
- Deveci, A., & Esen, M. F. (2022). Medikal Sentetik Veri Üretimiyle Veri Dengelemesi. *İstatistik Ve Uygulamalı Bilimler Dergisi*(5), 17-27. doi:10.52693/jsas.1105599
- Dhanush;, & Shetty, P. (2023). Image Feature Extraction Using Hough Transform. *International Research Journal of Modernization in Engineering Technology and Science*. doi:10.56726/irjmets39204
- Dixit, A., Sharma, A., Gupta, K., Singh, R. K., & Chaudhary, A. (2024). Vitiligo Detection Using Machine Learning. *Educational Administration: Theory and Practice*, 30(5), 10981-10991. doi:10.53555/kuey.v30i5.4874
- Eker, A., & Duru, N. (2021). Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları. *Acta Infologica*, 0(0), 0-0. doi:10.26650/acin.927561
- Ertas, M. (2023). Güçlendirilmiş Gradyan Minimizasyonu Kullanarak Medikal Görüntülerde Gürültü Arındırma. *Uludağ University Journal of the Faculty of Engineering*, 163-176. doi:10.17482/uumfd.1139249

- Faes, L., Wagner, S. K., Fu, D. J., Liu, X., Korot, E., Ledsam, J. R. E., . . . Keane, P. (2019). Feasibility of Automated Deep Learning Design for Medical Image Classification by Healthcare Professionals with Limited Coding Experience. *SSRN Electronic Journal*. doi:10.2139/ssrn.3402015
- Feng, D., Wang, X., Wang, X., Ding, S., & Zhang, H. (2021). Deep Convolutional Denoising Autoencoders with Network Structure Optimization for the High-Fidelity Attenuation of Random GPR Noise. *Remote Sensing*, 13(9), 1761. doi:10.3390/rs13091761
- Fiske, A., Henningsen, P., & Buyx, A. (2019). Your Robot Therapist Will See You Now: Ethical Implications of Embodied Artificial Intelligence in Psychiatry, Psychology, and Psychotherapy. *J Med Internet Res*, 21(5), e13216. doi:10.2196/13216
- Gao, F., Yoon, H., Wu, T., & Chu, X. (2020). A feature transfer enabled multi-task deep learning model on medical imaging. *Expert Systems with Applications*, 143, 112957. doi:10.1016/j.eswa.2019.112957
- Gaya-Vilar, A., Cobo, A., Abad-Uribarren, A., Rodriguez, A., Sierra, S., Clemente, S., & Prado, E. (2024). High-resolution density assessment assisted by deep learning of *Dendrophyllia cornigera* (Lamarck, 1816) and *Phakellia ventilabrum* (Linnaeus, 1767) in rocky circalittoral shelf of Bay of Biscay. *Peerj*, 12, e17080. doi:10.7717/peerj.17080
- Haman Bayarı, S., Akin, S., & Tuncel, M. (2023). Bilgisayarlı Tomografi, Pozitron Emisyon Tomografisi ve Nükleer Manyetik Rezonans Görüntülemede Temel Kavram ve İlkeler. *Batı Karadeniz Tıp Dergisi*, 7(3), 269-278. doi:10.29058/mjwbs.1362825

- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). *Mask R-CNN*. Paper presented at the 2017 IEEE International Conference on Computer Vision (ICCV).
- Herz, C., Fillion-Robin, J. C., Onken, M., Riesmeier, J., Lasso, A., Pinter, C., . . . Fedorov, A. (2017). dcmqi: An Open Source Library for Standardized Communication of Quantitative Image Analysis Results Using DICOM. *Cancer Res*, 77(21), e87-e90. doi:10.1158/0008-5472.CAN-17-0336
- Hosny, A., Parmar, C., Coroller, T. P., Grossmann, P., Zeleznik, R., Kumar, A., . . . Aerts, H. (2018). Deep learning for lung cancer prognostication: A retrospective multi-cohort radiomics study. *PLoS Med*, 15(11), e1002711. doi:10.1371/journal.pmed.1002711
- Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A., . . . Murphy, K. (2017). *Speed/Accuracy Trade-Offs for Modern Convolutional Object Detectors*. Paper presented at the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- Huang, M., Wang, B., Wan, J., & Zhou, C. (2023). *Improved blood cell detection method based on YOLOv5 algorithm*. Paper presented at the 2023 IEEE 6th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC).
- Jošth, R., Dubská, M., Herout, A., & Havel, J. (2011). *Real-Time Line Detection Using Accelerated High-Resolution Hough Transform*. Paper presented at the Scandinavian Conference on Image Analysis.

- Kang, E. Y., Hsieh, Y. T., Li, C. H., Huang, Y. J., Kuo, C. F., Kang, J. H., . . . Hwang, Y. S. (2020). Deep Learning-Based Detection of Early Renal Function Impairment Using Retinal Fundus Images: Model Development and Validation. *JMIR Medical Informatics*, 8(11), e23472. doi:10.2196/23472
- Karagiannis, S., Magkos, E., Ntantogian, C., Cabecinha, R., & Fotis, T. (2023). Cybersecurity and Medical Imaging: A Simulation-Based Approach to DICOM Communication. *Applied Sciences*, 13(18), 10072. doi:10.3390/app131810072
- Karaman, M., & Çınar, S. (2021). Abdominal bilgisayarlı tomografi görüntülerinde böbrek taşlarının sınırlarının ve sayılarının görüntü işleme yöntemleri kullanılarak tespiti. *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*. doi:10.28948/ngumuh.953423
- Kim, Y. J., & Kim, K. G. (2022). Detection and Weak Segmentation of Masses in Gray-Scale Breast Mammogram Images Using Deep Learning. *Yonsei Med J*, 63(Suppl), S63-S73. doi:10.3349/ymj.2022.63.S63
- Kircher, M. F., & Willmann, J. K. (2012). Molecular body imaging: MR imaging, CT, and US. part I. principles. *Radiology*, 263(3), 633-643. doi:10.1148/radiol.12102394
- Kumrular, R. K., & Polat, A. (2021). Klinik Uygulamalarda İleri Biyomedikal Görüntüleme Teknolojileri. *European Journal of Science and Technology*. doi:10.31590/ejosat.840321

- Kwong, J. C. C., Erdman, L., Khondker, A., Skreta, M., Goldenberg, A., McCradden, M. D., . . . Rickard, M. (2022). The silent trial - the bridge between bench-to bedside clinical AI applications. *Front Digit Health*, 4, 929508. doi:10.3389/fdgth.2022.929508
- Lee, S., Oh, S. I., Jo, J., Kang, S., Shin, Y., & Park, J. W. (2021). Deep learning for early dental caries detection in bitewing radiographs. *Sci Rep*, 11(1), 16807. doi:10.1038/s41598-021-96368-7
- Li, T. (2024). A comparison of deep learning-based object detection for unmanned aerial vehicle. *Applied and Computational Engineering*, 47(1), 186-192. doi:10.54254/2755-2721/47/20241325
- Liang, H., Hu, M., Ma, Y., Yang, L., Chen, J., Lou, L., . . . Xiao, Y. (2023). Performance of Deep-Learning Solutions on Lung Nodule Malignancy Classification: A Systematic Review. *Life (Basel)*, 13(9), 1911. doi:10.3390/life13091911
- Manikandan, S., Raman, R., Rajalakshmi, R., Tamilselvi, S., & Surya, R. J. (2023). Deep learning-based detection of diabetic macular edema using optical coherence tomography and fundus images: A meta-analysis. *Indian J Ophthalmol*, 71(5), 1783-1796. doi:10.4103/IJO.IJO_2614_22
- Mese, I., Altintas Taslicay, C., & Sivrioglu, A. K. (2024). Synergizing photon-counting CT with deep learning: potential enhancements in medical imaging. *Acta Radiol*, 65(2), 159-166. doi:10.1177/02841851231217995

- Mingxing, D., Zhang, Y., Chen, G., Zhang, L., Li, H., Wang, D., & Guosheng, X. (2015). Research on Method of Character Recognition Based on Hough Transform and RBF Neural Network. *Matec Web of Conferences*, 31, 16001. doi:10.1051/matecconf/20153116001
- Mutlu, M., & Kurnaz, Ç. (2023). Akciğer tümör tespiti için mikrodalga sistem tasarımı ve analizler. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38(4), 2261-2278. doi:10.17341/gazimmfd.1038999
- Onan, A. (2022). Türkçe Metin Madenciliği için Çalışan Bellek Bağlantıları Tabanlı Uzun Kısa Süreli Bellek Mimarisi. *European Journal of Science and Technology*. doi:10.31590/ejosat.1080239
- Pang, S., Ding, T., Qiao, S., Meng, F., Wang, S., Li, P., & Wang, X. (2019). A novel YOLOv3-arch model for identifying cholelithiasis and classifying gallstones on CT images. *Plos One*, 14(6), e0217647. doi:10.1371/journal.pone.0217647
- Philbrick, K. A., Weston, A. D., Akkus, Z., Kline, T. L., Korfiatis, P., Sakinis, T., . . . Erickson, B. J. (2019). RIL-Contour: a Medical Imaging Dataset Annotation Tool for and with Deep Learning. *J Digit Imaging*, 32(4), 571-581. doi:10.1007/s10278-019-00232-0
- Plata, I. T., Panganiban, E. B., Alado, D. B., Taracatac, A. C., Bartolome, B. B., & Labuanan, F. R. E. (2022). Comparative Performance Analysis of Real-Time Methods for Cassava Phytoplasma Disease (CPD) Detection based on Deep Learning Neural Networks. *International Journal of Emerging Technology and Advanced Engineering*, 12(2), 55-64. doi:10.46338/ijetae0222_07

- Purushotham, S., Meng, C., Che, Z., & Liu, Y. (2018). Benchmarking deep learning models on large healthcare datasets. *J Biomed Inform*, 83, 112-134. doi:10.1016/j.jbi.2018.04.007
- Sahin, M. E., Ulutas, H., Yuce, E., & Erkoç, M. F. (2023). Detection and classification of COVID-19 by using faster R-CNN and mask R-CNN on CT images. *Neural Computing and Applications*, 35(18), 13597-13611.
- Samala, R. K., Heang-Ping, C., Hadjiiski, L., Helvie, M. A., Richter, C. D., & Cha, K. H. (2019). Breast Cancer Diagnosis in Digital Breast Tomosynthesis: Effects of Training Sample Size on Multi-Stage Transfer Learning Using Deep Neural Nets. *IEEE Trans Med Imaging*, 38(3), 686-696. doi:10.1109/TMI.2018.2870343
- Saner, F. H., Saner, Y. M., Abufarhaneh, E., Broering, D. C., & Raptis, D. A. (2024). Comparative Analysis of Artificial Intelligence (AI) Languages in Predicting Sequential Organ Failure Assessment (SOFA) Scores. *Cureus*, 16(5), e59662. doi:10.7759/cureus.59662
- Sha, Z., Hu, L., & Rouyendegh, B. D. (2020). Deep learning and optimization algorithms for automatic breast cancer detection. *International Journal of Imaging Systems and Technology*, 30(2), 495-506. doi:10.1002/ima.22400
- Sheller, M. J., Reina, G. A., Edwards, B., Martin, J., & Bakas, S. (2019). Multi-Institutional Deep Learning Modeling Without Sharing Patient Data: A Feasibility Study on Brain Tumor Segmentation. *Brainlesion*, 11383, 92-104. doi:10.1007/978-3-030-11723-8_9

- Shen, L., Margolies, L. R., Rothstein, J. H., Fluder, E., McBride, R., & Sieh, W. (2019). Deep Learning to Improve Breast Cancer Detection on Screening Mammography. *Sci Rep*, 9(1), 12495. doi:10.1038/s41598-019-48995-4
- Shinzaki, W., Manabe, H., Kubota, M., Inui, H., Hojo, T., Ito, T., . . . Komoike, Y. (2023). Breast cancer local recurrence after mastectomy with immediate latissimus dorsi myocutaneous flap reconstruction: A case report. *SAGE Open Med Case Rep*, 11, 2050313X231177510. doi:10.1177/2050313X231177510
- Shou, Y., Meng, T., Ai, W., Xie, C., Liu, H., & Wang, Y. (2022). Object Detection in Medical Images Based on Hierarchical Transformer and Mask Mechanism. *Comput Intell Neurosci*, 2022, 5863782. doi:10.1155/2022/5863782
- Su, R., Huang, W., Ma, H., Song, X., & Hu, J. (2021). *SGE NET: Video Object Detection With Squeezed GRU and Information Entropy Map*. Paper presented at the 2021 IEEE International Conference on Image Processing (ICIP).
- Sümer, E., Engin, M., Ağildere, M., & Oğul, H. (2018). Monitoring Nodule Progression in Chest X-ray Images. *Pamukkale University Journal of Engineering Sciences*, 24(5), 934-941. doi:10.5505/pajes.2018.89166
- Szenicer, A., Fouhey, D. F., Munoz-Jaramillo, A., Wright, P. J., Thomas, R., Galvez, R., . . . Cheung, M. C. M. (2019). A deep learning virtual instrument for monitoring extreme UV solar spectral irradiance. *Sci Adv*, 5(10), eaaw6548. doi:10.1126/sciadv.aaw6548

- Tahir, B., Iqbal, S., Usman Ghani Khan, M., Saba, T., Mehmood, Z., Anjum, A., & Mahmood, T. (2019). Feature enhancement framework for brain tumor segmentation and classification. *Microsc Res Tech*, 82(6), 803-811. doi:10.1002/jemt.23224
- Taşyürek, M. (2023). Adversarial Attack Detection With Convolutional Neural Networks on Images for Selection of the Most Suitable Model in Object Detection. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(4), 2353-2363. doi:10.21597/jist.1281262
- Tian, D., Li, D., & Zhang, Y. (2015). *Medical Image Segmentation Based on Fractional-Order Derivative*. Paper presented at the 2015 Asia-Pacific Energy Equipment Engineering Research Conference.
- Tsopra, R., Fernandez, X., Luchinat, C., Alberghina, L., Lehrach, H., Vanoni, M., . . . Burgun, A. (2021). A framework for validating AI in precision medicine: considerations from the European ITFoC consortium. *BMC Med Inform Decis Mak*, 21(1), 274. doi:10.1186/s12911-021-01634-3
- Umer, M. J., Sharif, M., Kadry, S., & Alharbi, A. (2022). Multi-Class Classification of Breast Cancer Using 6B-Net with Deep Feature Fusion and Selection Method. *J Pers Med*, 12(5), 683. doi:10.3390/jpm12050683
- Veeralakshmi, M. S. (2012). Boundary Exposure Using Intensity and Texture Gradient Features. *Iosr Journal of Computer Engineering*, 8(1), 28-33. doi:10.9790/0661/0812833
- Vural, Y. (2018). Veri Mahremiyeti: Saldırıları, Korunma ve Yeni Bir Çözüm Önerisi. *Uluslararası Bilgi Güvenliği Mühendisliği Dergisi*, 4(2), 21-34. doi:10.18640/ubgmd.664416

- Wang, Q., Yuan, L., Ding, X., & Zhou, Z. (2021). Prediction and Diagnosis of Venous Thromboembolism Using Artificial Intelligence Approaches: A Systematic Review and Meta-Analysis. *Clin Appl Thromb Hemost*, 27, 10760296211021162. doi:10.1177/10760296211021162
- Xiao, C., Choi, E., & Sun, J. (2018). Opportunities and challenges in developing deep learning models using electronic health records data: a systematic review. *J Am Med Inform Assoc*, 25(10), 1419-1428. doi:10.1093/jamia/ocy068
- Xu, J., Ren, H., Cai, S., & Zhang, X. (2023). An improved faster R-CNN algorithm for assisted detection of lung nodules. *Computers In Biology And Medicine*, 153, 106470.
- Yasar, F., Apaydin, B., & Yilmaz, H. H. (2012). The effects of image compression on quantitative measurements of digital panoramic radiographs. *Med Oral Patol Oral Cir Bucal*, 17(6), e1074-1081. doi:10.4317/medoral.17912
- Yu, C., Sun, W., Xiong, Q., Gao, J., & Qu, G. (2022). Double-Balanced Loss for Imbalanced Colorectal Lesion Classification. *Comput Math Methods Med*, 2022, 1691075. doi:10.1155/2022/1691075
- Yuzkat, M., İlhan, H. O., & Aydın, N. (2023). Detection of sperm cells by single-stage and two-stage deep object detectors. *Biomedical Signal Processing and Control*, 83, 104630.
- Zhang, C., & Fang, J. (2016). *Edge Detection Based on Improved Sobel Operator*. Paper presented at the 2016 International Conference on Computer Engineering and Information Systems.

- Zhang, Y., Chen, Y., Huang, C., & Gao, M. (2019). Object Detection Network Based on Feature Fusion and Attention Mechanism. *Future Internet*, 11(1), 9. doi:10.3390/fi11010009
- Zhou, W., Deng, Z., Liu, Y., Shen, H., Deng, H., & Xiao, H. (2022). Global Research Trends of Artificial Intelligence on Histopathological Images: A 20-Year Bibliometric Analysis. *Int J Environ Res Public Health*, 19(18), 11597. doi:10.3390/ijerph191811597

YAPAY ZEKA VE SAĞLIK: BİYOMÜHENDİSLİK PERSPEKTİFİNDEN YENİLİKÇİ YAKLAŞIMLAR

Gizem TUTKUN¹

Ece ŞİMŞEK²

Kübra YILDIRIM³

Uğur BİLGE⁴

Mustafa ÖZDOĞAN⁵

Ahmet Yılmaz ÇOBAN⁶

1. GİRİŞ

Yapay zeka (YZ), insan zekasını taklit eden, öğrenme, problem çözme ve karar verme yeteneklerini içeren bir bilgisayar teknolojisi (Spicer, Khwaounjoo, & Cakmak, 2021). Gelişmiş algoritmalar ve büyük veri işleme kapasiteleri sayesinde yapay zeka, mühendislik, finans, eğitim gibi birçok sektörde dönüşüm yaratmıştır (Pham & Pham, 1999). 1956 yılında John McCarthy tarafından “Artificial Intelligence” (Yapay Zeka) olarak tanımlanan bu kavram, günümüzde birçok sektörde olduğu gibi sağlık alanında da devrim yaratmıştır (Benko & Sik Lányi, 2009). Büyük veri analitiği, genetik araştırmalar ve tıbbi görüntüleme gibi alanlarda YZ, hız ve doğruluk açısından önemli

¹ Akdeniz Üniversitesi, Sağlık Bilimleri Enstitüsü, Tıbbi Biyoteknoloji, gizemtutkun17@gmail.com, ORCID: 0000-0002-6184-4974.

² Doçent, Akdeniz Üniversitesi, Sağlık Bilimleri Enstitüsü, Tıbbi Biyoteknoloji, ecesimsek@akdeniz.edu.tr, ORCID: 0000-0002-7642-6601.

³ Doktor, Akdeniz Üniversitesi, Sağlık Bilimleri Enstitüsü, Tıbbi Biyoteknoloji, kubrayildirim@akdeniz.edu.tr, ORCID: 0000-0003-0558-8619.

⁴ Profesör, Akdeniz Üniversitesi, Sağlık Bilimleri Enstitüsü, Tıbbi Biyoteknoloji, ubilge@akdeniz.edu.tr, ORCID: 0000-0002-5186-1092.

⁵ Profesör, Memorial Sağlık Grubu, ozdoganmd, ORCID: 0000-0000-0000-0000.

⁶ Profesör, Akdeniz Üniversitesi, Sağlık Bilimleri Fakültesi, Beslenme ve Diyetetik, aycoban@akdeniz.edu.tr, ORCID: 0000-0002-8815-6063.

avantajlar sunmaktadır (Rama Krishna et al., 2023). Sağlık hizmetlerinin daha erişilebilir, bireyselleştirilmiş ve etkili hale gelmesi için YZ, güçlü bir araçtır (Parekh, Shaikh, Simran, Manan, & Hasibuzzaman, 2023).

2. BİYOMÜHENDİSLİK: YAPAY ZEKA VE SAĞLIK ARASINDAKİ KÖPRÜ

Yapay zeka ve sağlık birleşimi, biyomühendislik disiplini ile mümkün hale gelmektedir. Biyomühendislik, biyolojik sistemleri anlamak ve mühendislik prensipleriyle bu sistemlere çözüm üretmek amacıyla çalışan bir bilim dalıdır (Pavlovic, 2015). YZ, biyomühendislik kapsamında sağlık problemlerine odaklanarak, tanı, tedavi, ilaç geliştirme ve önleyici sağlık hizmetlerinde inovatif çözümler sunmaktadır. Biyomühendislik sayesinde YZ, sağlık alanındaki veri karmaşıklığını yönetmekte, bireyselleştirilmiş tıp uygulamalarını mümkün kılmakta ve hastalık yönetiminde çığır açmaktadır (Bhambri & Rani, 2024). Bu bağlamda, YZ'nin alt dallarından makine öğrenmesi (ML) ve derin öğrenme, sağlık hizmetlerinin dönüşümünde kilit rol oynamaktadır.

3. MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME: ÇALIŞMA PRENSİPLERİ

Makine öğrenmesi, sistemlerin verilerden öğrenmesini ve bu öğrenimi kullanarak gelecekteki durumları tahmin etmesini sağlayan bir yapay zeka dalıdır (Mahesh, 2020). Sağlık sektöründe ML, büyük veri kümelerinden anlamlı bilgiler çıkararak hastalıkların teşhisinde ve tedavi planlamasında kullanılır (Lalli & Amutha, 2020).

ML'nin üç temel yaklaşımı:

1. **Denetimli Öğrenme (Supervised Learning):** Bu yaklaşım, etiketli veri kümeleri üzerinde çalışır. Model, giriş verileri ile bu verilere karşılık gelen etiketler arasındaki ilişkileri öğrenerek yeni veriler için tahminlerde bulunabilir (Humbert-Droz, Mukherjee, & Gevaert, 2022). Örneğin, genetik profil ve klinik veri kullanılarak bir hastanın belirli bir kansere yatkınlığı tahmin edilebilir (Kim & Kim, 2018).
2. **Denetimsiz Öğrenme (Unsupervised Learning):** Etiketlenmemiş veri kümeleri üzerinde çalışarak gizli desenleri ve yapıları keşfeder. Genetik verilerden hasta alt gruplarını veya biyobelirteç kümelerini belirlemek için kullanılabilir (Lopez, Tucker, Salameh, & Tucker, 2018). Örneğin, bir hasta popülasyonunda benzer tedavi yanıtlarına sahip olan bireylerin kümelenmesi (Huang et al., 2021).
3. **Pekiştirmeli Öğrenme (Reinforcement Learning):** Ödül ve ceza mekanizmasıyla öğrenme sağlayan bu yaklaşım, özellikle dinamik sistemlerde kullanılabilir (Lan, Liu, & Zhao, 2020). Klinik tedavi stratejilerinin veya ilaç dozlarının optimize edilmesi gibi alanlarda etkili sonuçlar sunmaktadır (Liu, Shen, & Pan, 2022).

Derin Öğrenme (DL), yapay sinir ağlarını kullanarak ML'nin daha karmaşık problemleri çözmesine olanak tanır. Çok katmanlı yapısı sayesinde, DL özellikle tıbbi görüntüleme ve genetik veri analizinde öne çıkmıştır (Ali, Hardie, Narayanan, & Kebede, 2022).

Derin öğrenme modellerinin temelindeki yapay sinir ağları, veriyi analiz etmek ve anlamlı sonuçlar çıkarmak için giriş, ara (gizli) ve çıkış katmanlarından oluşur. Her bir ara katman, veriyi işleyerek daha karmaşık özelliklerin öğrenilmesini sağlar

(Janiesch, Zschech, & Heinrich, 2021). Örneğin, giriş katmanı, tıbbi bir görüntünün piksel değerlerini alır; gizli katmanlar, görüntüdeki kenarları, dokuları ve daha ileri seviyede tümör yapısını analiz eder; çıkış katmanı ise, görüntüde tümörün varlığını veya yokluğunu sınıflandırır (Ker, Wang, Rao, & Lim, 2018).

4. SAĞLIK ALANINDAKİ UYGULAMALAR

Sağlık hizmetleri gerek veri miktarının büyüklüğü gerekse karmaşık yapısı nedeniyle oldukça zorlu bir çalışma alanıdır (Yaqoob, Salah, Jayaraman, & Al-Hammadi, 2022). Sağlık sektöründe karşılaşılan temel problemler aşağıdaki gibi özetlenebilir:

- **Erken Tanı ve Teşhis Zorlukları:** Hastalıkların erken teşhisi, özellikle kanser gibi ölümcül hastalıklarda hasta yaşam süresini uzatmak ve tedavi maliyetlerini düşürmek açısından kritik öneme sahiptir. Ancak erken evrede belirtilerin tespit edilmesi zordur ve uzmanlık gerektirir (Hunter, Hindocha, & Lee, 2022).
- **Kişiselleştirilmiş Tedavi Eksikliği:** Hastaların genetik yapıları, yaşam tarzları ve hastalık ilerleyişi birbirinden farklıdır. Bu durum, standart tedavi yöntemlerinin her hasta için aynı derecede etkili olmamasına neden olur. Daha hassas ve bireyselleştirilmiş yaklaşımlar gereklidir (Khan, Badhiwala, Grasso, & Fehlings, 2020)(Khan, Badhiwala, Grasso, & Fehlings, 2020).
- **Veri Karmaşıklığı:** Sağlık sektörü, genetik dizilimlerden tıbbi görüntülemeye kadar geniş bir yelpazede büyük miktarda veri üretmektedir. Bu verilerin anlamlı bilgiler çıkaracak şekilde analiz edilmesi için güçlü araçlara ihtiyaç duyulmaktadır (Beam & Kohane, 2018; Lv & Qiao, 2020).
- **Uzman Eksikliği:** Bazı bölgelerde radyolog, onkolog gibi uzmanların eksikliği, teşhis ve tedavi süreçlerinde gecikmelere yol açmaktadır. Bu durum, özellikle kaynakların sınırlı ol-

duğu gelişmekte olan ülkelerde daha belirgindir (Mahmoud, Jaramillo, & Barteit, 2022).

Bu sorunların çözümü, yapay zeka ve makine öğrenmesi gibi mühendislik temelli yaklaşımların sağlık sektörüne entegrasyonu ile mümkün hale gelmektedir.

4. GELECEK PERSPEKTİFİ

Makine öğrenmesi ve derin öğrenme, sağlık alanında birçok çalışmada probleme yenilikçi çözümler sunabilir. Bu örnekler, farklı hastalıkların teşhisi, tedavisi ve sağlık hizmetlerinin iyileştirilmesinde kullanılabilir.

- 1. Radyolojik Görüntü Analizi:** Derin öğrenme tabanlı modeller, röntgen, manyetik rezonans (MR) ve bilgisayarlı tomografi (BT) taramalarında tümör, nodül ve diğer anormallikleri tespit etmekte kullanılabilir (Wang, Zhu, Wang, & Zhang, 2021). Bu modeller aynı zamanda BT taramalarını analiz ederek akciğer nodülleri tespit edebilmektedir. Böylelikle radyologlara destek sağlamaktadır (Dritsas & Trigka, 2022). Aynı zamanda beyin tümörlerinin sınıflandırılması için de MR taramalarında, glioblastoma gibi beyin tümörlerinin derecesinin belirlenmesi ve sınıflandırılması için derin öğrenme algoritmaları kullanılabilir (Buchlak et al., 2021).
- 2. Genetik Veri Analizi:** Makine öğrenmesi, DNA ve RNA dizilim verilerini analiz ederek farklı kanser türlerini sınıflandırabilmektedir. Örneğin, genetik profillere dayanarak meme kanseri hastalarını sınıflandırılması için modeller geliştirilmiştir (Wu & Hicks, 2021). Epigenetik veriler ile de kanser tespiti için ML modelleri kullanılabilir. DNA metilasyon profillerini analiz eden ML modelleri, belirli kanser türlerinin biyobelirteçlerini tespit edebilmektedir (Yassi, Chatterjee, & Parry, 2023). Genetik mutasyonların büyük veri analizleriyle nadir gö-

rülen hastalıkların tanımlanmasında önemli rol oynayan ML sistemleri de geliştirilmiştir (Schaefer, Lehne, Schepers, Prasser, & Thun, 2020).

3. **Kişiselleştirilmiş Tıp:** Kansere hastalarında kullanılan kemoterapötik ilaçlara bireysel yanıtları tahmin eden modeller, hastalara uygun ilaç seçimini kolaylaştırmaktadır (Khan, Badhiwala, Grasso, & Fehlings, 2020). Örneğin, gen ekspresyon verilerinden kemoterapiye duyarlılık veya direnç tahminleri yapılabilmektedir (Park & Yi, 2022).
4. **Hastalık Risk Tahmini:** ML ile farklı etnik kökenlere sahip bir popülasyonda kardiyovasküler hastalık risk tahmini yapılabilir (Ward et al., 2020). COVID-19 gibi bulaşıcı hastalıkların yayılımını izlemek ve tahmin etmek için ML modelleri kullanılabilir (Agrawal, Madaan, Roy, Kumari, & Deore, 2021).
5. **İlaç Geliştirme ve Yeniden Konumlandırma:** Google DeepMind tarafından geliştirilen AlphaFold, protein yapılarını tahmin ederek ilaç geliştirme süreçlerini hızlandırmaktadır (David, Islam, Tankhilevich, & Sternberg, 2022). Makine öğrenmesi, mevcut ilaçların farklı hastalıklara yönelik etkinliklerini tahmin ederek yeni tedavi seçenekleri sunmaktadır (Wang, Ding, Lei, Liao, & Wu, 2022).

5. SONUÇ

Yapay Zeka, makine öğrenmesi ve derin öğrenme gibi mühendislik yetenekleri sayesinde sağlık sektöründe çığır açan çözümler sunmaktadır. Bu teknolojiler, özellikle erken tanı, kişiselleştirilmiş tedavi ve büyük veri analizi gibi alanlarda etkili sonuçlar sağlamaktadır (Parekh, Shaikh, Simran, Manan, & Hasibuzzaman, 2023).

Gelecekte, YZ'nin sağlık hizmetlerini daha erişilebilir, etkili ve sürdürülebilir hale getireceği öngörülmektedir. Daha sofistike algoritmalar ve güçlü işbirlikleriyle, yapay zeka destekli biyomühendislik, insan sağlığını iyileştirme yolunda devrim yaratacaktır. Bu nedenle, teknolojinin sağlık alanında doğru ve etik bir şekilde uygulanması, toplum yararı için kritik bir öneme sahiptir.

KAYNAKÇA

- Benko, A., & Sik Lányi, C. (2009). History of Artificial Intelligence. In *Encyclopedia of Information Science and Technology, Second Edition* (pp. 1759–1762). IGI Global. doi:10.4018/978-1-60566-026-4.ch276
- Bhambri, P., & Rani, S. (2024). Bioengineering and Healthcare Data Analysis. In *Computational Intelligence and Blockchain in Biomedical and Health Informatics* (1st Edition, p. 25).
- Huang, Y., Liu, Y., Steel, P. A. D., Axsom, K. M., Lee, J. R., Tummalapalli, S. L., ... Zhang, Y. (2021). Deep significance clustering: a novel approach for identifying risk-stratified and predictive patient subgroups. *Journal of the American Medical Informatics Association*, 28(12), 2641–2653. doi:10.1093/jamia/ocab203
- Humbert-Droz, M., Mukherjee, P., & Gevaert, O. (2022). Strategies to Address the Lack of Labeled Data for Supervised Machine Learning Training With Electronic Health Records: Case Study for the Extraction of Symptoms From Clinical Notes. *JMIR Medical Informatics*, 10(3), e32903. doi:10.2196/32903
- Kim, B. J., & Kim, S. H. (2018). Prediction of inherited genomic susceptibility to 20 common cancer types by a supervised machine-learning method. *Proceedings of the National Academy of Sciences of the United States of America*, 115(6), 1322–1327. doi:10.1073/pnas.1717960115

- Lalli, M., & Amutha, S. (2020). Applications of Deep Learning and Machine Learning in Healthcare Domain-A Literature Review. *International Journal of Electrical Engineering and Technology*, 11(8), 113–126. doi:10.34218/IJEET.11.8.2020.011
- Lan, X., Liu, Y., & Zhao, Z. (2020). Cooperative control for swarming systems based on reinforcement learning in unknown dynamic environment. *Neurocomputing*, 410, 410–418. doi:10.1016/j.neucom.2020.06.038
- Lopez, C., Tucker, S., Salameh, T., & Tucker, C. (2018). An unsupervised machine learning method for discovering patient clusters based on genetic signatures. *Journal of Biomedical Informatics*, 85, 30–39. doi:10.1016/j.jbi.2018.07.004
- Mahesh, B. (2020). Machine Learning Algorithms - A Review. *International Journal of Science and Research (IJSR)*, 9(1), 381–386. doi:10.21275/art20203995
- Parekh, A.-D. E., Shaikh, O. A., Simran, Manan, S., & Hasibuz-zaman, Md. Al. (2023). Artificial intelligence (AI) in personalized medicine: AI-generated personalized therapy regimens based on genetic and medical history: short communication. *Annals of Medicine & Surgery*, 85(11), 5831–5833. doi:10.1097/MS9.0000000000001320
- Pavlovic, M. (2015). *Bioengineering*. Cham: Springer International Publishing. doi:10.1007/978-3-319-10798-1
- Pham, D. T., & Pham, P. T. N. (1999). Artificial intelligence in engineering. *International Journal of Machine Tools and Manufacture*, 39(6), 937–949. doi:10.1016/S0890-6955(98)00076-5

- Rama Krishna, S., Rathor, K., Ranga, J., Soni, A., D, S., & N, A. K. (2023). *Artificial Intelligence Integrated with Big Data Analytics for Enhanced Marketing*. In *2023 International Conference on Inventive Computation Technologies (ICICT)* (pp. 1073–1077). IEEE. doi:10.1109/ICICT57646.2023.10134043
- Spicer, C., Khwaounjoo, P., & Cakmak, Y. O. (2021). Human and Human-Interfaced AI Interactions: Modulation of Human Male Autonomic Nervous System via Pupil Mimicry. *Sensors*, 21(4), 1028. doi:10.3390/s21041028

THE CONTRIBUTION OF MANNED MODEL SIMULATORS TO MARITIME EDUCATION IN TURKEY

Özkan AKAR¹

1. INTRODUCTION

Reducing marine accidents is an important agenda item for both national and international maritime organizations. Reports published by organizations such as the International Maritime Organization (IMO), the International Convention for the Safety of Life at Sea (SOLAS), and the International Convention for the Prevention of Pollution from Ships (ICPPS) reveal that approximately 33% of marine accidents are caused by human error (Hreniuc, Bătrânca, & Modiga, 2010). This situation demonstrates that the effective training of captains and ship pilots plays a critical role in maritime safety.

Although practical training on real ships seems to be the most direct solution, high costs, safety risks, and the rarity of encountering critical situations are the limitations of this method (Hreniuc et al., 2010). Computer-aided simulators can create scenarios for different ship types in various sea conditions and accelerate training processes. However, the inability to fully simulate complex hydrodynamic events mathematically is one of the shortcomings of this method (Kobylnski, 2011).

This method, which has gained importance in recent years, involves practice on scaled-down real ship models. Manned model ships allow participants to practice in a safe en-

¹ PhD, , Vocational School of Maritime Technologies, Iskenderun Technical University, Iskenderun, Hatay, Turkey. E-mail: ozkan.akar@iste.edu.tr, ORCID: 0000-0002-8126-2883

vironment while enabling them to learn through mistakes and gain experience (Modiga et al., 2010).

Maritime education in Turkey is carried out by approximately 15 universities and around 40 maritime vocational high schools at the undergraduate and secondary education levels. While these institutions offer undergraduate programs such as maritime transportation and management engineering, as well as marine engineering operations, secondary education provides basic maritime training through maritime technical and vocational high schools.

The use of modern technology in maritime education in Turkey is widespread, and training programs are designed in accordance with STCW (Standards of Training, Certification, and Watchkeeping for Seafarers) standards. In these institutions, training tools such as Full Mission Bridge Simulators, radar/ECDIS simulators, engine room simulators, and GMDSS communication systems are commonly used.

Undergraduate-level maritime programs provide practical training such as offshore navigation and port maneuvers through bridge simulators. Meanwhile, vocational high schools develop students' practical skills with basic navigation and tug-assisted maneuver simulations. Especially radar and ARPA systems are used to enhance students' abilities to make accurate decisions in safe navigation and crisis situations (Hreniuc & Batrinca, 2014). Although simulation technologies in Turkey meet international standards, there are currently no training centers for manned model ships.

2. THE ROLE AND TECHNICAL DETAILS OF MANNED MODEL SIMULATORS IN MARITIME TRAININGUCING THE CARBON FOOTPRINT OF TRAWL FISHING

Energy In maritime training, manned model simulators (MMS) are training tools that realistically reflect the hydrodynamic effects of ship maneuvers using scaled models. The ship models used in these simulators are scaled-down versions of real ships, reduced at a ratio of 1:24 to 1:25 (Kobylnski, 2011). The scaling ratio is determined based on the Froude law, ensuring the hydrodynamic behavior of ships is accurately represented. However, as the Reynolds law cannot be fully satisfied, certain limitations arise, particularly in small models, due to phenomena such as flow separation. These effects are largely mitigated when models with lengths ranging from 8 to 15 meters are used (Kobylnski, 2011).



Figure 1 Training and Manned Model Simulators (MMS) for Ship Applications (<https://www.portrevel.com/>)



Figure 2. Training and Manned Model Simulators (MMS) for Ship Applications in a Canal (www.ilawashiphandling.com.pl)



Figure 3. Training and Manned Model Simulators (MMS) for Bulk Carrier Ship Applications (<https://www.portrevel.com/>)

Manned Model Simulators (MMS) are conducted on specially prepared lakes, artificial canals, and basins. These areas are equipped with scaled geographical structures to simulate real-world conditions. For example, the training area used at the Itawa Ship Handling Research and Training Centre is located on Lake Simcoe and is structured to include the following elements according to training needs:

1. **Narrow Channels:** A 140-meter-long channel, representing approximately 3.3 kilometers in reality, is utilized to provide maneuvering training in confined passages with bank effects.
2. **Shallow Water Areas:** A region approximately 360 meters wide simulates 1.5 kilometers of shallow water maneuvers. In this area, current generators can be employed to create various current scenarios.
3. **Narrow Deep-Water Passages:** Simulating about 2.5 kilometers, narrow water passages represent areas such as river mouths or fjords, where currents and confined water maneuvers are practiced (Kobylinski, 2011).

The wind effect cannot be fully represented due to scaling limitations. While the wind force is required to decrease by the ratio of λ^3 , this effect cannot be perfectly achieved in scaled models. However, due to the sheltered training areas, the wind effect generally remains minimal (Kobylinski, 2011).

The primary advantage of MMS systems lies in the natural occurrence of hydrodynamic interactions. Specifically, bank effects, shallow water effects, current effects, tug-assisted maneuvers, and ship-to-ship interactions can be accurately and reliably simulated in manned model simulators. Kobylinski (2011) noted certain limitations in simulating such effects through computer-based Full Mission Bridge Simulators (FMBS). For instance, complex hydrodynamic effects (e.g., bank effects,

shallow water conditions) are often simulated with simplified mathematical models in FMBS systems, leading to accuracy issues during critical maneuvers (Gofman & Manin, 1999; Gronarz, 2010).

In conclusion, MMS systems allow for the accurate representation of hydrodynamic effects in maritime training, enabling students to experience real-world scenarios directly. MMS technology, as applied in centers such as Ilawa, Port Revel, and Warsash, provides high precision, particularly in close interaction and complex maneuver scenarios. These systems play a complementary role alongside electronic simulators, significantly contributing to the reduction of maritime accidents and the enhancement of ship operators' competencies (Kobylnski, 2011; Gofman & Manin, 2000).

3. MANNED MODEL SHIP TRAINING CENTERS AROUND THE WORLD

The Manned ship model training centers are designed to enhance ship maneuvering skills in the maritime industry by providing training with scaled ship models that reflect real hydrodynamic conditions. These centers, which are limited in number worldwide, allow pilots, captains, and ship crews to gain experience in critical maneuvering scenarios. The features and training programs offered by these centers are detailed below.

The Port Revel Ship Handling Centre, located near Grenoble, France, plays a pioneering role in manned ship model training worldwide. Operating on a specially designed 5-hectare lake, the center utilizes 1:25 scale models of tankers, container ships, and passenger vessels. The facility is designed to simulate various port scenarios and geographical structures such as the Suez Canal. Ships are tracked using a DGPS system, and ma-

neuvers are analyzed for post-training evaluation (Hreniuc & Batrinca, 2014). The program includes training on port and canal maneuvers, wind effects, and the use of AZIPOD systems.



Figure 4 General Overview of the Training Center (www.portrevel.com/)

The Warsash Maritime Academy, located near Southampton, England, operates with 7 scaled models capable of simulating 9 different types of ships. The facility also supports berthing and towage training using radio-controlled tugboats. Maneuvers performed during training can be monitored and analyzed in real time using GPS-based tracking systems. The training programs include modules such as emergency procedures, twin-screw ship maneuvers, and pilotage courses, with course durations ranging between 20 and 40 hours (Hreniuc & Batrinca, 2014).

The Iława Ship Handling Research and Training Centre, located in Poland, operates on a 22-hectare lake with an exten-

sive training area. The training fleet includes various ship types, ranging from VLCC tankers to Panamax bulk carriers. Equipped with specialized systems for tug-ship cooperation training, the center uses GPS-based tracking technology to analyze maneuvers. Programs include various training scenarios such as port maneuvers, shallow water effects, and tug-assisted operations. Notably, hands-on training with ships possessing unique handling characteristics is a key focus (Hreniuc & Batrinca, 2014).



Figure 5.View of the Training Center in a Coastal Bay (www.unitedkingdomlovers.uk/)

The Iława Ship Handling Research and Training Centre, located in Poland, operates on a 22-hectare lake with an extensive training area. The training fleet includes various ship types, ranging from VLCC tankers to Panamax bulk carriers. Equipped with specialized systems for tug-ship cooperation training, the center uses GPS-based tracking technology to analyze maneuvers. Programs include various training scenarios such as port maneuvers, shallow water effects, and tug-assisted operations. Notably, hands-on training with ships possessing unique handling characteristics is a key focus (Hreniuc & Batrinca, 2014).

The Port Ash Ship Handling Centre, located in the Newcastle region of Australia, is a training facility designed specifically for pilots, focusing on enhancing pilotage skills. The center conducts realistic scenarios, including port entries and exits, as well as the effects of wind and currents. To create a highly realistic training environment, the center utilizes the geographical conditions of the surrounding region.



Figure 6 General Overview of the Training Center (www.portash.com.au)

The Massachusetts Maritime Academy, located in the United States, employs cross-training techniques to enhance maneuvering skills. Practical training with scaled ship models focuses on critical scenarios such as anchoring, berthing, wind effects, and maneuvering in shallow water conditions. The training is supported by real-time tracking and analysis systems, allowing participants' performance to be evaluated effectively.

4. A MARITIME TRAINING CENTER BASED ON MANNED MODEL SIMULATORS IN TURKEY: PROPOSAL AND BENEFITS

Turkey, with its strategic location surrounded by seas on three sides and situated on major international maritime trade routes, serves as a significant hub in the maritime sector. Maritime education in the country is provided by university maritime faculties and technical high schools, supported by programs utilizing modern simulation systems to train crews to international standards. However, the electronic simulators currently used in training do not fully reflect hydrodynamic effects. Therefore, establishing a manned model simulator-based maritime training center in Turkey would bring a significant improvement in the quality of maritime education.

Manned model simulators involve training conducted with scaled prototypes of real ships, typically at a ratio of 1:24 to 1:25, in specially prepared water basins. These models realistically simulate hydrodynamic conditions such as shallow water effects, bank effects, channel transits, and currents, allowing maritime students to gain practical experience. Centers like the *Ilawa Ship Handling Research and Training Centre* in Poland offer complex scenarios, including narrow water transits, channel maneuvers, shallow water operations, and ship handling in currents, with high realism and minimal risk. The models used, typically 8 to 15 meters long, can fully replicate hydrodynamic behaviors due to their scaled design (Kobylinski, 2011). Establishing such a center in Turkey would address a significant gap in maritime education.

Maritime education in Turkey currently relies on electronic simulators, including Full Mission Bridge Simulators, radar/ECDIS systems, and engine room simulators. These systems provide theoretical knowledge and limited practical experi-

ence. However, electronic simulators simplify complex hydrodynamic phenomena such as bank effects, ship-to-ship interactions, shallow water effects, and currents through mathematical models, which compromises accuracy (Gofman & Manin, 2000). In contrast, manned model simulators automatically and accurately reflect hydrodynamic effects, enabling students to gain experience in conditions close to real-life scenarios. Errors made during training pose no risk, allowing participants to gain confidence and expertise in a safe environment.

To fully utilize Turkey's maritime potential, it is proposed to establish a manned model simulator training center under the Ministry of Transport and Infrastructure in regions such as İskenderun, İzmir, Istanbul, or the Black Sea. These areas are ideal due to their proximity to existing maritime infrastructure and logistical advantages. The water basin for such a center should cover approximately 20 to 25 hectares and be designed to include bank effects, shallow water areas, current-influenced waterways, and narrow channel transits. This would enable realistic and controlled practice for critical scenarios such as port entries and exits, tug-assisted berthing, and ship maneuvers in current-influenced areas.

A training center based on manned model simulators would significantly enhance maritime education in Turkey. Such systems would allow students and professional mariners to develop practical maneuvering skills by experiencing realistic hydrodynamic effects. Additionally, the center would provide a competitive advantage at the international level and position Turkey as a regional leader in maritime education. Simulation centers of this kind, recommended by the International Maritime Organization (IMO), play a crucial role in reducing human errors, which account for a significant portion of maritime accidents. Similar centers in Poland, France, and the United Kingdom have become attractive training facilities for participants

from both domestic and international regions (Hreniuc & Batrinca, 2014; Kobylinski, 2011).

In conclusion, establishing a manned model simulator-based maritime training center in Turkey would contribute significantly to improving safety in the maritime sector, enhancing the quality of education, and reducing maritime accidents caused by human error. Such a facility would elevate the quality of maritime education at both national and international levels, positioning Turkey as a strong educational hub in this field.

REFERENCES

- Gofman, A. D., & Manin, V. M. (1999). Ship handling simulators validity - the real state and the ways of mathematical models correction. In Proceedings of HYDRONAV'99 - Manoeuvrability '99. Ostroda, Poland.
- Gofman, A. D., & Manin, V. M. (2000). Shiphandling simulator validity. International Conference on Marine Simulation and Ship Manoeuvring (MARSIM). Orlando, Florida.
- Gronarz, A. (2010). Shallow water, bank effect and canal interaction. AZIPILOT Project Report WP 2.2a.
- Hreniuc, V., & Batrinca, G. (2014). A pleading for ship manned models as a “physical” simulator in the ship handling training process. *Procedia Engineering*, 69, 1410-1419. <https://doi.org/10.1016/j.proeng.2014.03.136>
- Kobylnski, L. K. (2011). Capabilities of ship handling simulators to simulate shallow water, bank and canal effects. *International Journal on Marine Navigation and Safety of Sea Transportation*, 5(2), 247-

BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİNDE İLERİ ARAŞTIRMALAR

yaz
yayınları

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