

# JISTA

*Journal of Intelligent Systems:  
Theory and Applications*

MARCH 2024

ISSN: 2651-3927



**VOL 7 NO 1**

ARTIFICIAL INTELLIGENT > MACHINE LEARNING > DEEP LEARNING  
<https://dergipark.org.tr/en/pub/jista>



## Editorial Boards

---

### Honorary Editors

---

Zekai Şen, zsen@medipol.edu.tr, Istanbul Medipol University, Turkey

Burhan Turksen, bturksen@etu.edu.tr, TOBB ETU, Turkey

Harun Taşkın, taskin@sakarya.edu.tr, Sakarya University, Turkey

### Editor-In-Chief

---

Özer Uygun, ouygun@sakarya.edu.tr, Sakarya University, Turkey

### Editors

---

Enes Furkan Erkan, eneserkan@sakarya.edu.tr, Sakarya University, Turkey

Merve Cengiz Toklu, mertoklu@sakarya.edu.tr, Sakarya University, Turkey

### Area Editors

---

Mehmet Emin Aydın, mehmet.aydin@uwe.ac.uk, University of the West of England, UK

John Yoo, jyoo@bradley.edu, Bradley, University, USA

Salih Tutun, salihtutun@wustl.edu, Washington University in St. Louis, USA

Omar Mefleh Al-Araidah, alarao@just.edu.jo, Jordan University of Science and Technology, Jordan

Ayten Yılmaz Yalçın, ayteny@sakarya.edu.tr, Sakarya University, Turkey

Alper Kiraz, kiraz@sakarya.edu.tr, Sakarya University, Turkey

Caner Erden, cerden@subu.edu.tr, Sakarya University of Applied Sciences, Turkey

Muhammed Fatih Adak, fatihadak@sakarya.edu.tr, Sakarya University, Turkey

Muhammet Raşit Cesur, rasit.cesur@medeniyet.edu.tr, İstanbul Medeniyet University, Turkey

Zafer Albayrak, zaferalbayrak@subu.edu.tr, Sakarya University of Applied Sciences, Turkey

Sena Kır, senas@sakarya.edu.tr, Sakarya University, Turkey

Seda Hatice Gökler, sedahaticegokler@ksu.edu.tr, Kahramanmaraş Sütçü İmam University, Turkey

---

## Language Editor

---

Barış Yüce, b.yuce@exeter.ac.uk, Exeter University, United Kingdom

---

## Editorial Advisory Board

---

Ali Allahverdi, ali.allahverdi@ku.edu.kw, Kuwait University, Kuwait

Andrew Kusiak, andrew-kusiak@uiowa.edu, The University Of Iowa, United States of America

Ayhan Demiriz, ademiriz@sakarya.edu.tr, Gebze Technical University, Turkey

Barış Yüce, b.yuce@exeter.ac.uk, Exeter University, United Kingdom

Cemalettin Kubat, kubat@sakarya.edu.tr, Istanbul Gelişim University, Turkey

Dervis Karaboga, karaboga@erciyes.edu.tr, Erciyes University, Turkey

Eldaw E. Eldukhri, eeldukhri@ksu.edu.sa, King Saud University, College of Engineering Al-Muzahmia Branch, Saudi Arabia

Ercan Öztemel, eoztemel@marmara.edu.tr, Marmara University, Turkey

Hamid Arabnia, hra@cs.uga.edu, University of Georgia, United States of America

Lyes Benyoucef, lyes.benyoucef@Isis.org, Aix-Marseille University, Marseille, France

Maged Dessouky, maged@rcf.usc.edu, University of Southern California, Los Angeles, United States of America

Mehmet Savsar, mehmet.savsar@ku.edu.kw, Kuwait University, Kuwait

Mohamed Dessouky, dessouky@usc.edu, University Of Southern California, Los Angeles, United States of America

M.H. Fazel Zarandi, zarandi@aut.ac.ir, Amerikabir University Of Technology, Iran

Türkay Dereli, dereli@gantep.edu.tr, Hasan Kalyoncu University, Turkey

Witold Pedrycz, pedrycz@ee.ualberta.ca, University Of Alberta, Canada

Yılmaz Uyaroğlu, uyaroglu@sakarya.edu.tr, Sakarya University, Turkey

---

## Editorial Assistants

---

Elif Yıldırım, elifyildirim@sakarya.edu.tr, Sakarya University, Turkey



## Contents

### Research Articles

- 1. The Impact of Denial-of-Service Attacks and Queue Management Algorithms on Cellular Networks** 1-13  
*Muhammet ÇAKMAK*
- 2. Makine Öğrenimi Kullanarak Bir Mekanik Jiroskobun Yalpalama Tahmininde Zaman Serisi Modeli** 14-26  
*İlyas KACAR*
- 3. Bir E-Ticaret Firmasındaki Son Adım Teslimat Probleminin Farklı Senaryolar Altında İncelenmesi** 30-42  
*Fatma Duygu YILMAZER, Harun Reşit YAZGAN, Serap ERCAN CÖMERT*

### Letter to the Editor

- 1. Halk Sağlığı Alanında Makine Öğrenimi Analizinin Kullanımı** 27-29  
*Kübra Ecem TURGUTKAYA, Emine Didem EVCI KIRAZ*



# The Impact of Denial-of-Service Attacks and Queue Management Algorithms on Cellular Networks

Muhammet Çakmak<sup>1\*</sup> 

<sup>1</sup>Sinop University, Department of Computer Engineering, Sinop, Türkiye  
mcakmak@sinop.edu.tr

## Abstract

In today's digital landscape, Distributed Denial of Service (DDoS) attacks stand out as a formidable threat to organisations all over the world. As known technology gradually advances and the proliferation of mobile devices, cellular network operators face pressure to fortify their infrastructure against these risks. DDoS incursions into Cellular Long-Term Evolution (LTE) networks can wreak havoc, elevate packet loss, and suboptimal network performance. Managing the surges in traffic that afflict LTE networks is of paramount importance. Queue management algorithms emerge as a viable solution to wrest control over congestion at the Radio Link Control (RLC) layer within LTE networks. These algorithms work proactively, anticipating, and mitigating congestion by curtailing data transfer rates and fortifying defences against potential DDoS onslaughts. In the paper, we delve into a range of queue management methods Drop-Tail, Random Early Detection (RED), Controlled Delay (CoDel), Proportional Integral Controller Enhanced (PIE), and Packet Limited First In, First Out queue (pFIFO). Our rigorous evaluation of these queue management algorithms hinges on a multifaceted assessment that encompasses vital performance parameters. We gauge the LTE network's resilience against DDoS incursions, measuring performance based on end-to-end delay, throughput, packet delivery rate (PDF), and fairness index values. The crucible for this evaluation is none other than the NS3 simulator, a trusted platform for testing and analysis. The outcomes of our simulations provide illuminating insights. CoDel, RED, PIE, pFIFO, and Drop-Tail algorithms emerge as top performers in succession. These findings underscore the critical role of advanced queue management algorithms in fortifying LTE networks against DDoS attacks, offering robust defences and resilient network performance.

**Keywords:** DDoS attacks, LTE network, Ns-3 simulation

## DDoS Saldırıların ve Kuyruk Yönetimi Algoritmalarının Hücresel Ağlar Üzerindeki Etkisi

### Öz

Günümüzün dijital ortamında Dağıtılmış Hizmet Reddi (DDoS) saldırıları, dünyanın her yerindeki kuruluşlar için büyük bir tehdit olarak öne çıkıyor. Bilinen teknolojinin giderek ilerlemesi ve mobil cihazların yaygınlaşmasıyla hücresel şebeke operatörleri, altyapılarını bu risklere karşı güçlendirme baskısıyla karşı karşıya kalıyor. Hücresel Uzun Vadeli Evrim (LTE) ağlarına yapılan DDoS saldırıları büyük hasara, yüksek paket kaybına ve yetersiz ağ performansına yol açabilir. LTE ağlarını etkileyen trafikteki dalgalanmaları yönetmek büyük önem taşıyor. Kuyruk yönetimi algoritmaları, LTE ağları içindeki Radyo Bağlantı Kontrolü (RLC) katmanındaki tıkanıklığın kontrolünü ele geçirmek için geçerli bir çözüm olarak ortaya çıkıyor. Bu algoritmalar proaktif olarak çalışır, veri aktarım hızlarını azaltarak ve potansiyel DDoS saldırılarına karşı savunmayı güçlendirerek tıkanıklığı öngörür ve azaltır. Bu yazıda, Drop-Tail, Random Early Detection (RED), Controlled Delay (CoDel), Proportional Integral Controller Enhanced (PIE) ve Packet Limited First In, First Out queue (pFIFO) gibi çeşitli kuyruk yönetimi yöntemlerini derinlemesine inceliyoruz. Bu kuyruk yönetimi algoritmalarına yönelik titiz değerlendirmemiz, hayati performans parametrelerini kapsayan çok yönlü bir değerlendirmeye dayanır. LTE ağının DDoS saldırılarına karşı dayanıklılığını ölçüyoruz; performansı uçtan uca gecikmeye, üretime, paket dağıtım hızına (PDF) ve adalet endeksi değerlerine göre ölçüyoruz. Bu değerlendirmenin potası, test ve analiz için güvenilir bir platform olan NS3 simülatöründen başkası değildir. Simülasyonlarımızın sonuçları aydınlatıcı bilgiler sağlıyor. CoDel, RED, PIE, pFIFO ve Drop-Tail algoritmaları art arda en iyi performans gösterenler olarak ortaya çıkıyor. Bu bulgular, gelişmiş kuyruk yönetimi algoritmalarının, LTE ağlarını DDoS saldırılarına karşı güçlendirme, sağlam savunmalar ve esnek ağ performansı sunma konusundaki kritik rolünün önemini göstermektedir.

**Anahtar kelimeler:** DDoS atakları, LTE ağı, Ns-3 simülasyonu

\* Corresponding Author.  
E-mail: mcakmak@sinop.edu.tr

Received : 28 Dec 2022  
Revision : 14 Jun 2023  
Accepted : 28 Sep 2023

## 1. Introduction

The rapidly developing technology has increased the number of mobile phones used in cellular networks. Cellular network operators invest more in research and technology to secure against increasing data and network traffic. It is an important problem for attackers to cause network disruptions and block user services (Zenitani, 2023). DDoS attacks that occur in the LTE network cause mobile network users to disconnect or decrease the Quality of Service (QoS) (Feng et al., 2020).

DDoS attacks, which disrupt services on the network, are challenging to detect. DDoS attacks that occur in the LTE network affect all network layers but significantly affect the Radio Link Control (RLC) layer is a protocol layer in the LTE (Long-Term Evolution) wireless communication standard. It is responsible for ensuring the reliable transmission of data between the source and destination over the wireless link (Çakmak et al., 2021). One of the LTE cellular networks' main aims is developing queue management algorithms for RLC. Queue management method algorithms are used to ensure resource allocation and quality of service (QoS) during network congestion (Çakmak et al., 2022). Active Queue Management (AQM) algorithms enable efficient use of services such as delay, high bandwidth, and packet delivery speed. AQM mechanisms are used in LTE cellular networks under DDoS attacks (Wang and Wang, 2020). As a result, complete disconnection, connection slowdowns, disruptions of service, and potential data loss issues that could occur on the LTE network are prevented.

A DDoS attack occurring on a cellular LTE network can cause the entire network to go down, slowing it or preventing the use of network bandwidth. Choosing a practical algorithm for the security of the LTE network and the continuation of its services is crucial. Although DDoS attacks have been tested on the cellular LTE network to date, the performance of these attacks on queue management algorithms has not been assessed. Unlike other studies, this study evaluated the performance of queue management algorithms against DDoS attacks in the RLC layer of the cellular LTE network. Well-known Drop-Tail, RED, CoDel, PIE, pFIFO algorithms were compared under DDoS attacks in LTE networks according to end-to-end delay, throughput, PDF and fairness index values. PDF is a metric that measures the percentage of packets successfully delivered to their intended destination in a network.

DDoS attacks on LTE networks cause the network to be temporarily or completely disabled. It also causes disruption of services. Queue management algorithms create a preliminary protection area to prevent attacks and reduce their impact. It prevents congestion in queue buffers, controls packet drops, and regulates excessive demands.

Although loss-based, delay-based, rate based, queue-based, topology based, machine-learning based and hybrid-based studies have been carried out in LTE networks to date, the performance of DDoS attacks with queue management algorithms in LTE networks has not been examined. In this study, unlike others, the performances of the queue management algorithms in the LTE RLC layer under DDoS attacks were compared according to end-to-end delay, throughput, PDF and fairness index values using the NS-3 network simulator. Unlike others in these studies:

- The impact of queue management algorithms on the cellular LTE network under DDoS attacks was examined.
- Comparative performance of queue management algorithms against DDoS attacks in the RLC layer of the LTE network is shown.
- Well-known Drop-Tail, RED, CoDel, PIE, pFIFO algorithms were compared according to end-to-end delay, throughput, PDF and fairness index values under DDoS attacks in LTE networks.

The remainder of the study is organised as follows. In the second chapter, background and literature studies were examined. In the third section, an experimental framework and performance evaluation are provided. The results are given in the fourth section.

## 2. Background and Related Works

### 2.1. LTE Network Architecture

LTE, which stands for Long-Term Evolution, is a cellular communication standard that provides high mobile voice traffic and short messaging services (Wu et al., 2022). The LTE core network is divided into two main sections, as indicated in Figure 1, the E-UTRAN (Evolved Universal Terrestrial Access Network) and the EPC (Evolved Packet Core). The E-UTRAN disposes of an eNB (base station), which serves as the gateway between mobile terminals, radio antennas, and operators (Israr et al., 2021). eNBs are a base station that controls cell phones in the cell. It is defined as the eNB serving when the base station communicates with a mobile phone. eNBs communicate with mobile phones using analogue and digital signals via the air interface. eNB controls the operation of all mobile phones by sending signal messages (Zidic et al., 2023). eNBs are connected to the EPC via the S1 interface. The eNB accesses nearby base stations using the X2 interface for signalling and packet forwarding during transmission. EPC consists of three functional modules: Mobility Management Entity (MME), Service Gateway (S-GW), and Packet Data Network Gateway (PDN-GW). The MME delivers a paging message to the base station to provide service in the Core System (CS) domain. The S-GW connects LTE nodes and transmits user data packets. S-GW works like a router. In addition, S-GW sends the obtained data between the base station and the

PDN-GW (Mousavi et al., 2017). The Home Subscriber Server (HSS) is a central database that stores information about the cellular network operator's subscribers. The Policy Control and Pricing Rules Function (PCRF) decides on policy control. It also controls flow-based charging functions. The LTE network is connected to the rest of the Internet via PDN-GW (Oughton et al., 2022). The PDN-GW connects the EPC unit to external IP networks. PDN-GW forwards packets to external IP networks. It also allocates IP addresses to all users. It handles IP user traffic-related operations, including packet filtering.

LTE network architecture consists of Physical Layer (Layer 1), Medium Access Layer (MAC), Radio Link Control (RLC), Radio Resource Control (RRC), Packet Data Convergence Control (PDCP), and Non-Access Stratum (NAS) Protocols (Mousavi et al., 2019).




Figure 1. LTE Architecture (Gómez et al., 2014)

Figure 2 shows the data flow in the RLC, PDCP, and MAC layers.




Figure 2. LTE MAC, RLC and PDCP Layers (Gómez et al., 2014)

The RLC layer is used for segmentation, efficient transport, and sequential transmission. RLC analyses the initial data units containing information of a particular

type and ensures the security of the target data transmission. More control or security is needed at the RLC layer. Because the RLC layer is used in all transmission of data packets such as voice, video, and FTP, when a DDoS attack or other attack reaches the RLC level, it can cause packet loss or slow throughput, long packet delays, traffic congestion, and heavy and inefficient network performance.

## 2.2. DDoS Attacks

A DDoS attack is a malicious attempt to disrupt the regular traffic of the target server, service, or network by crushing it with a stream of internet traffic. DDoS attacks provide activity using multiple computer systems. These attacks can use resources such as computers, mobile phones, and IoT devices to execute an attack on the target. During a high-level DDoS attack, the victim network experiences unexpected traffic congestion, preventing regular traffic from reaching its destination. A standard method in a DDoS attack is for the attacker to send a stream of packets to a victim. This transmitted stream consumes significant resources, preventing the real user from accessing the resources (Ali et al., 2022; Said et al., 2022). Another method is to send malformed packets, which disable or blocks the application or protocol on the target machine. Some attacks block services by overloading the Internet infrastructure instead of targeting victims. A DDoS attack is also an effective attack technique to consume resources so that legitimate clients cannot receive internal or external services.

## 2.3. Queue Management Algorithms

Queue Management algorithms have been developed to detect and protect the network from this congestion. Queue management algorithms prevent packet loss in the network, reduce delays, detect network congestion, and recover congestion (Çakmak and Albayrak, 2018 ; Akhter et al., 2021). Passive queue management algorithms such as drop-tail only forward queued packets sequentially, while active queue management algorithms can pre-identify congestion and minimise packet transfer rate. This study evaluated several queue management algorithms, including well-known options like Drop-Tail, RED, CoDel, PIE, and pFIFO. Our analysis focused on their effectiveness in mitigating DDoS attacks on LTE networks.

Drop-Tail is simply the most straightforward queue management algorithm. It is often used in routers due to its simple control mechanism. Drop-Tail provides priority forwarding of the first packets to the queue. New packets are automatically rejected if the queue is full. The arrival speed of the packets can be greater than the output speed. Drop-Tail, the priority levels of all packets are the same and this causes traffic congestion and bottleneck.

RED is the first AQM algorithm for congestion. It calculates network congestion using the average queue

size to avoid congestion in RED packet switched networks. The RED algorithm manages the queue size using four parameters: the minimum threshold (Minth), the maximum threshold (Maxth), the maximum probability, and the weighting factor. The minimum and maximum points determine the queue sizes within which packets are marked. In contrast, the maximum likelihood sets the maximum drop probability for packets exceeding the maximum threshold. The weighting factor controls the rate at which the average queue size is computed over time, with higher values giving greater weight to recent samples. The algorithm works to maintain an average queue size. The packet drop probability value,  $P_d$ , varies linearly between zero and  $P_{max}$  as the mean queue size changes between the Minth and Maxth values. All incoming packets are dropped if the average queue size value exceeds Maxth (Paul et al., 2017). The RED algorithm controls the congestion structure due to packet drop because the packet drop mechanism operates according to the moving average of the past values.

CoDel was developed to solve the bottleneck problem in the network (Raghuvanshi et al., 2013). Congestion is detected by CoDel when the packet transmission time exceeds the set target value. After the congestion is detected, the signal is sent to drop the packet to avoid clutter in the queue. CoDel detects congestion in the network using the packet delay time. Buffer bloat causes packet losses to increase in the queue even when the buffer size is large. The CoDel algorithm efficiently controls the buffer-bloat problem. Unlike RED, CoDel is independent of parameters such as queue size and average, queue delay, and drop rate.

pFIFO is an active queue management algorithm based on the FIFO algorithm (Bisoy and Pattnaik, 2016). It is classified by considering different channels for network traffic. High-priority traffic is processed earlier. Its main purpose is a simple method to support differentiated service classes. The advantage of pFIFO is low computational load and traffic transmission generated in real-time applications. The most critical problem in the network is that the volume of high-priority traffic is high, the buffer space allocated for low-priority traffic is reduced, and overflow occurs. This causes packet drop on the network and slows down the network (Low et al., 2002).

PIE is designed to control latency in the network effectively (Pan et al., 2013). In PIE, the average queue rate is estimated relative to the non-moving queue. The speed is used to calculate the available delay. Then, the delay is periodically used to calculate the probability of falling. Finally, when the packet arrives at the destination, a packet is dropped (or flagged) based on that probability. PIE adjusts probability based on latency trend. Alpha and beta are statically selected parameters chosen to control the fall probability increase and are determined by control theoretical approaches. Alpha determines how the deviation between the current and target delay changes the probability. The beta makes

additional adjustments based on the lag trend. PIE is designed to improve time-sensitive performance and strives to provide interactive traffic and network stability while maintaining high connection usage. Adapting the control parameters in small increments voids large oscillations leading to unbalance (Pan et al., 2013).

#### 2.4. Related Works

Researchers and developers have proposed various queue management algorithms to address congestion and performance issues in wired and wireless networks. These algorithms aim to improve network performance by managing the flow of packets in the network queues. These algorithms aim to improve features like network utilisation, packet loss, and adaptability for different traffic loads.

The proposed AQMs aim to solve problems such as loss-based congestion control (Verma et al., 2022) delay-based congestion control and rate-based congestion control (Amer et al., 2020). For eNB on LTE, smRED (smart-RED), a smart AQM that works by adjusting the variance value in RED to prevent buffer congestion and packet drop in variable traffic loads at the RLC layer, enables packet programmers to work through single-cell and multicell handover and no failover. The study investigated the effects of the queue management algorithms on the network performance metrics, including throughput, delay, and deviation values. The adjusted variance value  $i$  of RED took different values in low and high-load situations, affecting the drop of packets accumulated in RCL buffers (Paul et al., 2017).

The authors introduced an innovative machine learning-based intrusion detection system to mitigate Distributed Denial of Service (DDoS) attacks within the LTE-A network. The proposed model effectively identifies DDoS flows targeting the eNB and utilises the random forest algorithm for attack classification. Remarkably, the system achieved an impressive accuracy rate of 99.95% in accurately identifying and classifying DDoS attacks (Gong et al., 2019).

In a separate study, the authors introduced the DDoS Threat Analysis and Response Framework (DTARS), which encompasses distributed real-time threat identification, behavioural monitoring, and validation of control plane operations specifically tailored for LTE networks (Krishnan et al., 2019).

In another study, the authors proposed an improved Neural Network (NN) model for intrusion detection, which identifies authenticated nodes and cluster heads (CH) using elliptic curve cryptography (ECC) in the LTE network for Machine Type Communication (MTC) devices. In case of an attack, the proposed model imposes a penalty and restricts the affected nodes from participating in MTC communication. Specifically, the improved NN was created using a new optimisation



algorithm called Whale with Three-Level Update (WTU) (Jyothi and Chaudhari, 2020).

The packet congestion feedback mechanism proposed by the authors was developed to avoid queue overflow in the LTE networks and reduce queuing delays. With the QoS value of the packets in the network, the packet is defined as TCP or UDP. An average value was calculated to estimate full queues, and low ranges for TCP and high ranges were determined for UDP. Setting the sender congestion window to high, medium and low according to the network traffic situation it has been tried to prevent the queue overflow in Evolved Node B (eNB) (Adesh and Renuka, 2019).

In another study, the authors classified DDoS attacks in the LTE network with logistic regression and decision tree machine learning algorithms (Ashfaq et al., 2022).

The authors examined the performance of AQMs operating in the RLC layer of the cellular LTE network according to end-to-end delay, throughput, PDF and fairness index values. The study has shown that the selection of the right queue management algorithm directly affects the performance of the network (Çakmak et al., 2021; Çakmak and Albayrak, 2022). The authors proposed an adaptive queue management algorithm operating at the RLC layer of the cellular LTE network. The proposed algorithm adaptively adjusts the network's throughput according to low, medium and high network load (Çakmak and Albayrak, 2022).

Praveen and Pratap (2021) proposed a congestion-sensitive resource allocation and routing protocol (CRR) based on hybrid optimisation techniques for IoT devices in smart city infrastructure. The proposed method uses a meta-heuristic algorithm to reduce total congestion and allocate IoT gateways. It also uses a swarm optimisation algorithm for the route discovery mechanism. The proposed ECRR technique was designed and implemented with the NS-2 simulator. The authors examined the AQM mechanism based on neural networks. The study aims to employ machine learning techniques to learn the behaviour of the Active Queue Management (AQM) mechanism. Specifically, the study seeks to develop a model that can predict the behaviour of the AQM mechanism in response to changes in network traffic conditions, such as variations in traffic volume or type, to improve network performance and reduce congestion. Obtains training examples considering the similarity of network traffic. The model uses the Gaussian method. The study demonstrates the effectiveness of the active queue management mechanism based on neural networks (Szyguła et al., 2021). In another study, the authors proposed the Federated Intelligence (FIAQM) architecture for AQM, using the Federated Learning approach. The proposed method dynamically adjusts the AQM parameters for a multi-domain environment, which is difficult to achieve with conventional AQM. The proposed FIAQM method uses a trained feedforward neural network trained on a network traffic

dataset to predict the behavior of the Active Queue Management (AQM) mechanism in response to changes in traffic conditions. In addition, the developed method improves the performance of FIAQM's inter-domain connections by reducing congestion in its connections while keeping the network data private in each participating domain (Gomez et al., 2021).

The authors propose an algorithm for fair bandwidth distribution, considering traffic class priority, connected loads of a node, and average queue size. The average queue size across the nodes is adjusted based on the gradient suggested for the Global Priority (GP) differential, which is a metric that assigns priorities to different types of network traffic based on their importance. Specifically, the proposed mechanism uses the GP differential to determine the relative importance of different traffic flows in the network and adjusts the average queue size accordingly. This allows for more efficient allocation of network resources and improved Quality of Service (QoS) for critical traffic flows. The node's speed is calculated based on the node's average queue size and GP. The proposed routing protocol is designed for Wireless Sensor Networks (WSN), networks of small, low-power devices equipped with sensors that collect and transmit data wirelessly. The protocol is optimised for WSNs, which typically have limited resources such as bandwidth, energy, and computational power and operate in environments where the network topology may change frequently. The proposed method is applied to a tree topology that deals with both Real-Time (RT) and Non-real-time (NRT) traffic classes (Swain and Nanda, 2021). Table 1 shows control mechanism literature for LTE networks.

**Table 1.** Control mechanism literature for LTE networks

Study	Year	Reference
Loss-based congestion control	2022	(Verma et al., 2022)
Delay-based congestion control	2021	(Lin et al., 2021)
Rate-based congestion control	2020	(Amer et al.)
	2019	(Paul et al.)
Topology-based mechanism	2021	(Swain and Nanda)
Machine-learning based control	2019	(Gong et al.)
	2020	(Jyothi and Chaudhari)
	2021	(Szyguła et al.)
	2021	(Gomez et al.)
Hybrid control mechanism	2021	(Praveen and Pratap)
	2022	(Çakmak and Albayrak)

Although loss-based, delay-based, rate-based, queue-based, topology-based, machine-learning-based, and hybrid-based studies have been carried out in LTE networks, the performance of DDoS attacks with queue management algorithms in LTE networks has not been examined. A DDoS attack on a cellular LTE network can cause a temporary disruption and potentially degrade the network's performance, as it overwhelms the network with many requests, making it difficult for

legitimate users to access network resources. However, it does not permanently turn off the entire network. Although security studies have been done in the cellular LTE network, the security of the RCL layer has not been directly tested. Preventing DDoS attacks that may occur at the RCL layer will increase the performance of cellular network security. In this study, unlike others, the versions of the queue management algorithms in the LTE RLC layer under DDoS attacks were compared according to end-to-end delay, throughput, PDF and fairness index values using the NS-3 network simulator.

### 3. Experimental Framework and Performance Assessment

In this section, the network topology and system parameters for the LTE network are determined. Then the simulation results were analysed and evaluated according to the end-to-end average throughput, delay, PDF and fairness index.

For the experimental environment,

- \* Firstly, eNB and nodes are created in the NS3 environment.

- \*Parameter of eNB is set.

- \*BotNets are placed according to the specified numbers in accordance with the topology.

- \*Simulation starts

- \*Drop-tail, RED, CoDel, pFIFO and PIE algorithms are run separately at simulation time.

- \*Test results are saved as end-to-end average throughput, delay, PDF and fairness index

- \*Simulation is terminated.

#### 3.1. Network Topology and Simulation Environment

One of the easiest and most effective ways to empirically observe traffic on the network is to use simulation. Using simulation, network nodes, connections and network traffic can be designed similarly to the real world (Jevtić et al., 2009) and (Weingärtner, et al., 2009). In addition, simulation makes it cheaper and easier to implement systems that are difficult and very expensive to implement in the real world. Ns3 network simulator is free open-source software developed for educational and research purposes and works on a discrete event basis. Parameter settings for the Ns3 simulation environment were made as follows:

- \*Basic eNB added

- \*MTU value for SGW and PDN-GW is set to 1500 bytes

- \*Inter-unit data rate was selected as 100 Gbps, which is the maximum supported by eNB

- \* eNB delay set to optimum value 0.01s

- \* eNB connection latency set to 2ms.

- \*TCP New Reno module was used as TCP traffic type

- \*Attackers' displacement feature was selected as RandomWalk2D

- \*For Droptail's package, a maximum of 50 packages, 100 ms interval and 5ms target value were selected

- \*For RED, the minth value for sending 50 packets of data is determined as 20 and the maximum value is 50. Queue weight value was determined as 0.002s

- \*Limit package setting for pFIFO was set as 50 packages

- \*Average queue delay value for PIE was set to 0.01s

- \*Simulation completed between 0.1s and 100s.

This study designed an LTE network structure and attack scenario suitable for the actual situation. Thus, the obtained data is more similar to the actual system. In the experimental environment, 1 eNB is attacked by DDoS with 10, 20, 40, 60, and 100 attackers, respectively. In simulation, data traffic starts from 0.1 seconds and the simulation takes 100 seconds. Drop-tail, RED, CoDel, pFIFO and PIE algorithms were run in each attack. The results were compared to the average end-to-end throughput, delay, PDF and fairness index. The simulation parameters showed in Table 2.

#### 3.2. Experimental Results

The simulation results were analysed using average end-to-end delay, throughput, PDF, and fairness index values. For the real-world simulation environment, a DDoS attack is carried out on 1 eNB by 10, 20, 40, 60 and 100 attackers, respectively.

Table 2. Simulation Parameters

SGW and PDN-GW Gateway		
	Parameters	Value
LTE	MTU (Maximum Transmission Unit)	1500 Bytes
	Data Rate	100 Gbps
	Delay	0.010 s
	Wired Link Capacity	100 Mbps
	Data Rate	100 Gbps
	Delay	2 ms
	Botnet Number	10, 20, 40, 60, and 100
	TCP Traffic Type	TCP New Reno
	Mobility	RandomWalk2D
	Queue Algorithms	
Drop-tail	Mode	(Bytes, Packets)
	Max Packets	50
CodeL	Mode	Packets
	Max Packets	50
	Interval	100 ms
RED	Target	5 ms
	Mode	Packets
	MeanPktSize	50
	IdlePktSize	1500*1000bytes
	MinTh, MaxTh	20,50
	Queue Limit	50
	Queue weight	0,002s

	Link Delay	20ms
pFIFO	Limit	50 packets
PIE	Average Queue Delay	0.01 s
<b>Simulation Time</b>		
	Simulation Start Time	0.1 s
	Total Simulation Time	100 s

Figure 3 shows the packet control flow structure of the Drop-tail RED, CoDeL, PIE and pFIFO algorithms for the simulation environment.




Figure 3. Simulation Packet Controller

Figure 4 shows the network topology of the simulation.




Figure 4. Simulation network topology

Pseudo code of the system.

- 1: procedure enodeb (parameters)
- 2: Initialize variable
- 3: Arrive packets on RLC
- 5: Attack on system
- 4: (Droptail, RED, CoDel, PIE, and pFIFO) apply on RLC
- 5: Check the packets
- 6: End the process

### 3.2.1 Average End-to-end Throughput

Drop-tail, RED, CoDel, pFIFO and PIE algorithms were compared using 10, 20, 40, 60 and 100 botnets in the LTE network environment. Table 3 shows the average throughput values of the LTE RLC layer under DDoS attacks. The variation of the end-to-end average throughput values according to the number of botnets is shown in Figure 5.

Table 3. End-to-end Throughput

AQM	Average Throughput (Kbps)				
	10 BotNets	20 BotNets	40 BotNets	60 BotNets	100 BotNets
Drop-Tail	2492,157	1593,321	1058,988	310,52	123,963
RED	2793,681	1953,759	1473,846	643,13	317,061
CoDel	2914,524	2047,491	1623,633	730,35	365,868
pFIFO	2554,671	1777,167	1386,537	566,55	217,539
PIE	2756,93	1866,50	1462,62	571,65	275,244

The average end-to-end output throughput values obtained with the increase in the number of botnets showed a natural decrease. CoDel algorithm showed the best performance in terms of end-to-end throughput value even in high botnet attack. Other best performing algorithms are listed as RED, PIE, pFIFO, and Drop-Tail respectively. The CoDel algorithm gives the best results due to early detection of packet drops and processing according to the queuing time of packets. Drop-Tail algorithm, which dropped incoming packets after the queue is full, gives the worst result among all algorithms. This shows that Drop-tail is the most vulnerable algorithm for high traffic.

The presented data outlines the Average Throughput (measured in Kbps) achieved by various AQM (Active

Queue Management) algorithms across different scenarios involving varying numbers of BotNets. When confronted with 10 BotNets, the CoDel algorithm exhibits the highest throughput at 2914.524 Kbps, closely followed by the PIE algorithm at 2756.93 Kbps. The RED algorithm also demonstrates commendable performance, achieving a throughput of 2793.681 Kbps. In contrast, both Drop-Tail and pFIFO algorithms yield lower throughputs at 2492.157 Kbps and 2554.671 Kbps respectively. As the number of BotNets increases to 20, 40, 60, and eventually 100, a discernible pattern emerges. CoDel consistently maintains its lead in throughput across all scenarios, showcasing its superior ability to handle network congestion, even in high-stress situations with a substantial number of BotNets. RED

and PIE algorithms also exhibit competitive performance, with both consistently achieving noteworthy throughput values. Conversely, Drop-Tail and pFIFO face considerable challenges, with their respective throughputs experiencing significant drops as

the number of BotNets increases. This comparative analysis underscores the efficacy of CoDel in managing network congestion and maximising throughput, particularly in scenarios with a high BotNet count.

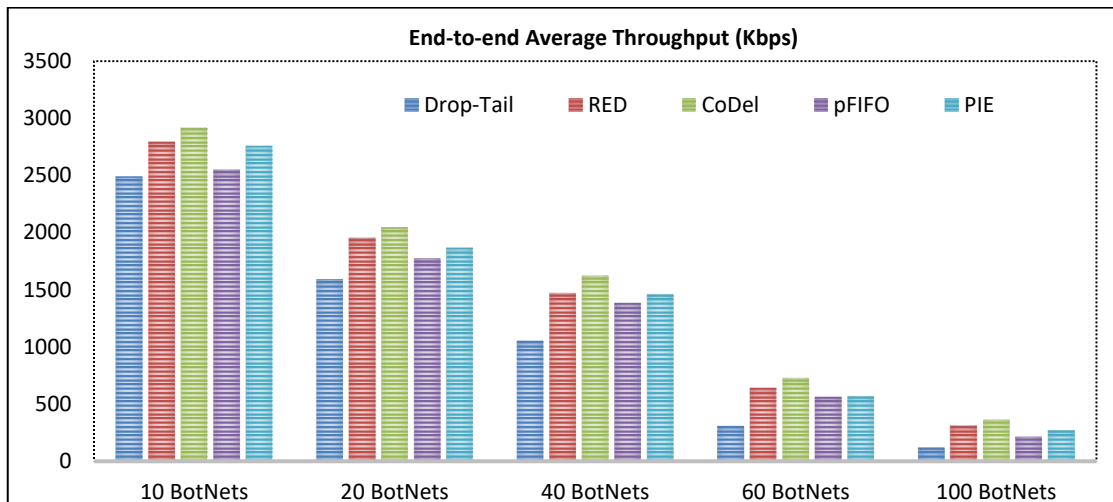


Figure 5. Average End-to-end Throughput Under DDoS Attacks

### 3.2.2 Average End-to-end Delay

Drop-tail, RED, CoDel, pFIFO and PIE were compared in an LTE network environment using 10, 20, 40, 60 and 100 botnets. Table 4 shows the average

throughput values of the LTE RLC layer under DDoS attacks.

Table 4. End-to-end Delay

AQM	Average Delay (ms)				
	10 BotNets	20 BotNets	40 BotNets	60 BotNets	100 BotNets
Drop-Tail	74,686	160,86	343,04	648,45	1809,8
RED	29,193	117,40	246,27	472,62	949,679
CoDel	26,751	104,43	208,85	395,81	766,104
pFIFO	44,6405	131,68	280,81	514,69	1050,6
PIE	41,59	126,50	268,73	488,34	988,104

Figure 6 shows the average end-to-end delay based on the number of botnets. Packets coming from the PDN-GW router significantly affect parameters such as modulation, encoding, and packet creation time. These parameters are adversely affected in a DDoS attack. CoDel does not use the size of the queue to manage the queue, it uses the queuing time of the packets. This ensures that the packet drop value of the CoDel algorithm is low. Thus, the end-to-end delay value of CoDel is lower than other algorithms. Dropping more packets due to a DDoS attack caused more delay. The CoDel algorithm has the best end-to-end delay performance, with the lowest packet loss rate under DDoS attack. The Drop-Tail drops the packets arriving to the queue from the front if the queue is full. Therefore, Drop-tail has the worst performance among all algorithms. This algorithm is followed by RED, PIE, pFIFO and Drop-Tail, respectively. The CoDel

algorithm is followed by RED, PIE, pFIFO and Drop-Tail, respectively.

Average Delay (measured in milliseconds) experienced with various AQM (Active Queue Management) algorithms across different scenarios involving varying numbers of BotNets. With 10 BotNets, the CoDel algorithm demonstrates the lowest delay at 26.751 ms, closely followed by the RED algorithm at 29.193 ms. In contrast, Drop-Tail experiences significantly higher delays at 74.686 ms. As the number of BotNets increases to 20, 40, 60, and eventually 100, a clear trend emerges. CoDel consistently maintains its lead in minimising delay across all scenarios, showcasing its superior ability to manage network congestion, even in high-stress situations with a substantial number of BotNets. RED and PIE algorithms also exhibit competitive performance, with both consistently achieving lower delay values. Conversely, Drop-Tail and pFIFO face

considerable challenges, with their respective delays experiencing substantial increases as the number of BotNets escalates. This comparative analysis

underscores the effectiveness of CoDel in reducing network delay and enhancing overall performance, particularly in scenarios with a high BotNet count.

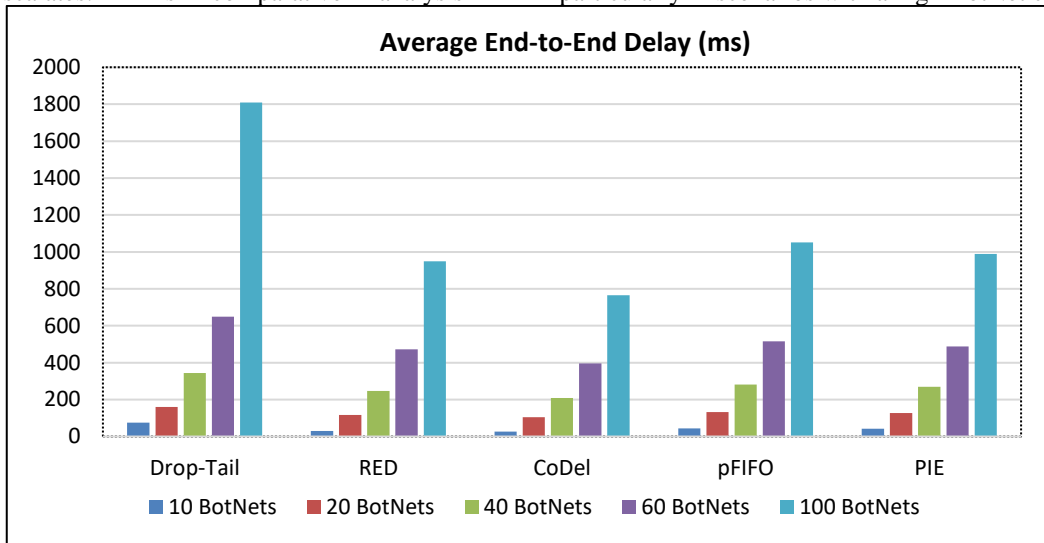


Figure 6. Average End-to-end Delay Under DDoS Attacks

### 3.2.3 Average End-to-end PDF

Drop-tail, RED, CoDel, pFIFO and PIE were compared using 10, 20, 40, 60 and 100 botnets in the

LTE network environment. Table 5 shows the average PDF values of the LTE RLC layer under DDoS attacks.

Table 5. End-to-end PDF

AQM	Average PDF(%)				
	10 BotNets	20 BotNets	40 BotNets	60 BotNets	100 BotNets
Drop-Tail	89	81	64	54	8
RED	97	87	75	69	51
CoDel	98	89	76	72	57
pFIFO	93	83	71	59	38
PIE	95	86	73	61	42

The packet delivery rate, PDF, is calculated as the ratio of the total packets sent to the total packets received. The PDF value is an important parameter that shows the network's performance. Figure 6 shows the end-to-end average PDF based on the number of botnets. As the number of botnets increases, the demanded amount of resources also increases. User packets are accumulated in the queues of the RLC layer. Accumulated packets are held for resource allocation. Due to the DDoS attack, there is a decrease in PDF value because the resource allocation is not sufficient. With an increasing number of botnets, all algorithms get lower PDF values due to excessive packet drop. CoDel, RED, PIE, pFIFO, and Drop-Tail get the best PDF values, respectively. Figure 7 shows the average end-to-end PDF values. The provided data illustrates the Average PDF percentages for various AQM (Active Queue Management) algorithms under different scenarios involving varying numbers of BotNets. When faced

with 10 BotNets, the CoDel algorithm outperforms its counterparts, achieving an impressive 98% Average PDF. Following closely behind, the PIE algorithm demonstrates substantial efficiency with a PDF of 95%. Meanwhile, Drop-Tail and pFIFO exhibit decreasing performance with PDF values of 89% and 93% respectively. As the BotNet count escalates to 20, 40, 60, and eventually 100, a clear trend emerges. Across all scenarios, CoDel consistently maintains its lead, demonstrating superior PDF percentages compared to other AQM strategies. RED and PIE algorithms also exhibit competitive performance, with both showcasing robust PDF percentages. Conversely, Drop-Tail and pFIFO face significant challenges as the number of BotNets increases, with notable reductions in their respective PDF values. This comparative analysis highlights the effectiveness of CoDel in managing network congestion, particularly in high-stress scenarios with a substantial number of BotNets.




Figure 7. Average End-to-end PDF Under DDoS Attacks

### 3.2.4 Average End-to-end Fairness Index

Drop-tail, RED, CoDel, pFIFO and PIE were compared using 10, 20, 40, 60 and 100 botnets in the LTE network environment. Table 6 shows the average


fairness index values of the LTE RLC layer under DDoS attacks.

Table 6. End-to-end Fairness Index

AQM	Fairness Index				
	10 BotNets	20 BotNets	40 BotNets	60 BotNets	100 BotNets
<b>Drop-Tail</b>	0,79	0,65	0,41	0,23	0,09
<b>RED</b>	0,88	0,81	0,66	0,58	0,41
<b>CoDel</b>	0,91	0,84	0,78	0,61	0,49
<b>pFIFO</b>	0,89	0,78	0,63	0,51	0,31
<b>PIE</b>	0,87	0,77	0,65	0,56	0,38

As the number of botnets connecting to eNB increases, the amount of resources also demanded increases. Normal users expect resource allocation, and a fair allocation of resources is required for requested resources. Figure 8 shows the end-to-end average fairness index values according to the number of botnets. As the DDoS attack increases, the packets coming into the queue begin to drop. Excessive packet

drops reduce the fairness index value of the network. Also, the attack causes network latency. CoDel does not use the size of the queue to manage the queue; it uses the queue time of the packets. This ensures that the fairness index value of the CoDel algorithm is high. The CoDel algorithm is followed by RED, PIE, pFIFO, and Drop-Tail, respectively.



**Figure 8.** Average End-to-end Fairness Index Under DDoS Attacks

Packets coming from the PDN-GW router significantly affect parameters such as modulation, coding, and packet generation time. These parameters are negatively affected in a DDoS attack. CoDel does not use the size of the queue to manage it; it uses the time it takes for packets to queue. This ensures that the packet drop rate of the CoDel algorithm is low. Therefore, the end-to-end delay value of CoDel is lower than that of other algorithms. More packets dropped due to a DDoS attack cause more delay. The CoDel algorithm yields the best results due to its early detection of packet drops and processing of packets according to their queue time. As the number of botnets increases, the amount of requested resources also increases. User

#### 4. Conclusion

In conclusion, our research underscores the paramount importance of robust queue management algorithms in fortifying LTE networks against the disruptive impact of DDoS attacks. Through a comprehensive examination of various techniques, our study extends the existing body of knowledge in network security beyond conventional paradigms. We have systematically evaluated the performance of CoDel, RED, PIE, pFIFO, and Drop-Tail algorithms under simulated DDoS scenarios, shedding light on their respective strengths and weaknesses. Notably, the CoDel algorithm emerges as the standout performer, leveraging packet waiting time to optimize packet loss, latency, and end-to-end transmission. The RED algorithm also demonstrates commendable performance, strategically regulating packet drop thresholds. Conversely, PIE, pFIFO, and Drop-Tail algorithms face notable challenges in packet control

packets are collected in the queues of the RLC layer. The accumulated packets are retained for resource allocation. Due to the DDoS attack, the PDF value decreases because the resource allocation is insufficient. With the increase in the number of botnets, all algorithms obtain lower PDF values due to excessive packet drops. As the DDoS attack escalates, the packets arriving in the queue begin to drop. Excessive packet drops reduce the fairness index value of the network. Additionally, the attack causes network delay. CoDel does not use the size of the queue to manage it; it uses the queue time of the packets. This ensures that the fairness index value of the CoDel algorithm is high.

during DDoS attacks, with Drop-Tail exhibiting a pronounced vulnerability. These findings provide critical insights for network administrators and security experts in devising robust defenses against escalating DDoS threats in LTE networks.

Furthermore, this study contributes significantly to the broader discourse on network security. By elucidating the nuanced interplay between LTE architecture and DDoS attacks, our research highlights the pivotal role of effective queue management in thwarting and mitigating such assaults. This comprehensive evaluation of queue management algorithms fills a notable gap in the current literature, offering practical guidance for implementing tailored security measures. Looking ahead, future research endeavors could focus on the development of AI-driven queue management algorithms fine-tuned for LTE networks, further enhancing the resilience of these crucial communication systems in the face of evolving cyber threats.

## References

- Albayrak, Z., Çakmak, M., 2018. A Review: Active Queue Management Algorithms in Mobile Communication. *International Conference on Cyber Security and Computer Science* 180–184.
- Ali, S.M., Çakmak, M., Albayrak, Z., 2022. Security Classification of Smart Devices Connected to LTE Network, in: *Lecture Notes in Networks and Systems*. [https://doi.org/10.1007/978-3-030-94191-8\\_91](https://doi.org/10.1007/978-3-030-94191-8_91)
- Amer, H., Al-Kashoash, H., Khami, M.J., Mayfield, M., Mihaylova, L., 2020. Non-cooperative game based congestion control for data rate optimization in vehicular ad hoc networks. *Ad Hoc Networks* 107. <https://doi.org/10.1016/j.adhoc.2020.102181>
- Ashfaq, M.F., Malik, M., Fatima, U., Shahzad, M.K., 2022. Classification of IoT based DDoS Attack using Machine Learning Techniques, in: *2022 16th International Conference on Ubiquitous Information Management and Communication (IMCOM)*. IEEE, pp. 1–6. <https://doi.org/10.1109/IMCOM53663.2022.9721740>
- Bisoy, S.K., Pattnaik, P.K., 2016. Design of feedback controller for TCP/AQM networks. *Engineering Science and Technology, an International Journal* 20. <https://doi.org/http://dx.doi.org/10.1016/j.jestch.2016.10.002>
- Çakmak, M., Albayrak, Z., 2022. AFCC-r: Adaptive Feedback Congestion Control Algorithm to Avoid Queue Overflow in LTE Networks. *Mobile Networks and Applications* 27. <https://doi.org/10.1007/s11036-022-02011-8>
- Çakmak, M., Albayrak, Z., 2020. Performance Analysis of Queue Management Algorithms Between Remote-Host and PG-W in LTE Networks. *Academic Platform Journal of Engineering and Science* 456–463. <https://doi.org/10.21541/apjes.662677>
- Çakmak, M., Albayrak, Z., Torun, C., 2021. Performance comparison of queue management algorithms in lte networks using NS-3 simulator. *Tehnicki Vjesnik* 28. <https://doi.org/10.17559/TV-20200411071703>
- F. M. Suaib Akhter, A., F. M. Shahen Shah, A., Ahmed, M., Moustafa, N., Çavuşoğlu, U., Zengin, A., 2021. A Secured Message Transmission Protocol for Vehicular Ad Hoc Networks. *Computers, Materials & Continua* 68, 229–246. <https://doi.org/10.32604/cmc.2021.015447>
- Gomez, C.A., Wang, X., Shami, A., 2021. Federated intelligence for active queue management in inter-domain congestion. *IEEE Access* 9, 10674–10685. <https://doi.org/10.1109/ACCESS.2021.3050174>
- Gómez, G., Pérez, Q., Lorca, J., García, R., 2014. Quality of service drivers in LTE and LTE-A networks. *Wirel Pers Commun* 75, 1079–1097. <https://doi.org/10.1007/s11277-013-1409-0>
- Gong, Y., Cao, J., Fu, Y., Guo, M., 2019. A DDoS attack detection model for LTE-A network. *Journal of Cyber Security* 4. <https://doi.org/10.19363/J.cnki.cn10-1380/tn.2019.01.03>
- Israr, A., Yang, Q., Li, W., Zomaya, A.Y., 2021. Renewable energy powered sustainable 5G network infrastructure: Opportunities, challenges and perspectives. *Journal of Network and Computer Applications*. <https://doi.org/10.1016/j.jnca.2020.102910>
- Jevtić, M., Zogović, N., Dimić, G., 2009. Evaluation of Wireless Sensor Network Simulators. *Proceedings of the 17th Telecommunications Forum TELFOR 2009 Belgrade Serbia*.
- Jyothi, K.K., Chaudhari, S., 2020. Optimized neural network model for attack detection in LTE network. *Computers & Electrical Engineering* 88, 106879. <https://doi.org/10.1016/j.compeleceng.2020.106879>
- Krishnan, P., Duttagupta, S., Achuthan, K., 2019. SDNFV Based Threat Monitoring and Security Framework for Multi-Access Edge Computing Infrastructure. *Mobile Networks and Applications* 24. <https://doi.org/10.1007/s11036-019-01389-2>
- Lin, Y., Li, L., Ren, P., Wang, Y., Szeto, W.Y., 2021. From aircraft tracking data to network delay model: A data-driven approach considering en-route congestion. *Transp Res Part C Emerg Technol* 131. <https://doi.org/10.1016/j.trc.2021.103329>
- Low, S.H., Paganini, F., Jiantao Wang, Adlakha, S., Doyle, J.C., n.d. Dynamics of TCP/RED and a scalable control, in: *Proceedings. Twenty-First Annual Joint Conference of the IEEE Computer and Communications Societies*. IEEE, pp. 239–248. <https://doi.org/10.1109/INFCOM.2002.1019265>
- Mousavi, H., Amiri, I.S., Mostafavi, M.A., Choon, C.Y., 2019. LTE physical layer: Performance analysis and evaluation. *Applied Computing and Informatics* 15. <https://doi.org/10.1016/j.aci.2017.09.008>
- Mousavi, H., Amiri, I.S., Mostafavi, M.A., Choon, C.Y., 2017. LTE physical layer: Performance analysis and evaluation. *Applied Computing and Informatics*. <https://doi.org/10.1016/j.aci.2017.09.008>
- N.D., A., A., R., 2019. Avoiding queue overflow and reducing queuing delay at eNodeB in LTE networks using congestion feedback mechanism. *Comput Commun* 146, 131–143. <https://doi.org/10.1016/j.comcom.2019.07.015>



- Oughton, E.J., Comini, N., Foster, V., Hall, J.W., 2022. Policy choices can help keep 4G and 5G universal broadband affordable. *Technol Forecast Soc Change* 176. <https://doi.org/10.1016/j.techfore.2021.121409>
- Pan, R., Natarajan, P., Piglione, C., Prabhu, M.S., Subramanian, V., Baker, F., VerSteeg, B., 2013. PIE: A lightweight control scheme to address the bufferbloat problem. *IEEE International Conference on High Performance Switching and Routing, HPSR* 148–155. <https://doi.org/10.1109/HPSR.2013.6602305>
- Paul, A., Kawakami, H., Tachibana, A., Hasegawa, T., 2017. Effect of AQM-Based RLC Buffer Management on the eNB Scheduling Algorithm in LTE Network. *Technologies (Basel)* 5, 59. <https://doi.org/10.3390/technologies5030059>
- Praveen, K. v., Prathap, P.M.J., 2021. Energy Efficient Congestion Aware Resource Allocation and Routing Protocol for IoT Network using Hybrid Optimization Techniques. *Wirel Pers Commun* 117. <https://doi.org/10.1007/s11277-020-07917-8>
- Raghuvanshi, D.M., Annappa, B., Tahiliani, M.P., 2013. On the effectiveness of CoDel for active queue management. *International Conference on Advanced Computing and Communication Technologies, ACCT* 107–114. <https://doi.org/10.1109/ACCT.2013.27>
- Said, A.A., Çakmak, M., Albayrak, Z., 2022. Performance of Ad-Hoc Networks Using Smart Technology Under DDoS Attacks, in: *Lecture Notes in Networks and Systems*. [https://doi.org/10.1007/978-3-030-94191-8\\_92](https://doi.org/10.1007/978-3-030-94191-8_92)
- Swain, S.K., Nanda, P.K., 2021. Adaptive queue management and traffic class priority based fairness rate control in wireless sensor networks. *IEEE Access* 9. <https://doi.org/10.1109/ACCESS.2021.3102033>
- Szyguła, J., Domański, A., Domańska, J., Marek, D., Filus, K., Mendla, S., 2021. Supervised learning of neural networks for active queue management in the internet. *Sensors* 21. <https://doi.org/10.3390/s21154979>
- Verma, H., Chauhan, N., Chand, N., Awasthi, L.K., 2022. Buffer-loss estimation to address congestion in 6LoWPAN based resource-restricted ‘Internet of Healthcare Things’ network. *Comput Commun* 181, 236–256. <https://doi.org/10.1016/j.comcom.2021.10.016>
- Wang, T., Wang, M., 2020. Hyperchaotic image encryption algorithm based on bit-level permutation and DNA encoding. *Opt Laser Technol* 132, 106355. <https://doi.org/10.1016/j.optlastec.2020.106355>
- Weingärtner, E., vom Lehn, H., Wehrle, K., 2009. A performance comparison of recent network simulators, in: *IEEE International Conference on Communications*. <https://doi.org/10.1109/ICC.2009.5198657>
- Wu, Z., Zhu, M., Li, Q., Xue, L., Yang, J., Chen, Z., Cao, Y., Cui, Y., 2022. Design of power monitoring system for new energy grid-connected operation based on LoRa and 4G technology. *Energy Reports* 8, 95–105. <https://doi.org/10.1016/j.egy.2022.10.038>
- Zenitani, K., 2023. From attack graph analysis to attack function analysis. *Inf Sci (N Y)* 119703. <https://doi.org/10.1016/j.ins.2023.119703>
- Zidic, D., Mastelic, T., Nizetic Kosovic, I., Cagalj, M., Lorincz, J., 2023. Analyses of ping-pong handovers in real 4G telecommunication networks. *Computer Networks* 227. <https://doi.org/10.1016/j.comnet.2023.109699>



# Makine Öğrenimi Kullanarak Bir Mekanik Jiroskobun Yalpalama Tahmininde Zaman Serisi Modeli

İlyas Kacar<sup>1\*</sup> 

<sup>1</sup> Niğde Ömer Halisdemir Üniversitesi, Mekatronik Mühendisliği Bölümü, Niğde, Türkiye

ikacar@gmail.com

## Öz

Jiroskobik tork üretebilmeleri nedeniyle, mekanik jiroskoplar uçak, uzay araçları gibi tamamen askıdaki veya tek/iki tekerlekli kara araçlarının dengelenmesinde sıklıkla kullanılmaktadır. Yüksek hızla dönen volan sayesinde jiroskobik tork üretmektedirler. Bu torkun kontrolü için yalpalama hızı uygulamak gerekmektedir. Çalışmada bir mekanik jiroskobun rijit dinamik analizi yapılarak 415 adet yalpalama hızı verisi toplanmıştır. Bu hızın açık çevrim tahmininde lineer olmayan, otomatik gerilemeli yapay sinir ağı (NAR) kullanılmıştır. Elde edilen modelde korelasyon değeri 0.998 ve hata karelerinin ortalamasının karekökü (RMSE) değeri de 0.016 rad/s olmuştur. Model çıktısı ile veri seti arasında yüksek doğrusal ilişki tespit edilmiştir. NAR ağı, veri üzerine herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmıştır. Kullanılan ağ parametreleri ve bu model ile elde edilen tahmin performansları çalışma içerisinde sunulmuştur.

**Anahtar Kelimeler:** Jiroskop, Makine öğrenimi, Otomatik gerilemeli yapay sinir ağı, Yalpalama.

## Time Series Model to Forecast the Precession of a Mechanical Gyroscope Using Machine Learning

### Abstract

Due to the gyroscopic torque production ability, mechanical gyroscopes are frequently used for balancing fully suspended or single/two-wheeled land vehicles such as airplanes and spacecraft. They produce gyroscopic torque thanks to the flywheel rotating at high speed. Precession is required to control this torque. In the study, 415 precession data were collected by performing a rigid dynamic analysis of a mechanical gyroscope. A non-linear autoregressive artificial neural network (NAR) is used to estimate this velocity. In the model obtained, the correlation value was 0.998 and the root mean square of error (RMSE) value was 0.016 rad/s. A high linear relationship was detected between the model output and the data set. The NAR network has eliminated the need for any pre-processing on the data. The network parameters used and the estimation performances obtained with this model are presented in the study.

**Keywords:** Gyroscope, Machine Learning, Nonlinear autoregressive network, Precession.

### 1. Giriş (Introduction)

Mekanik, optik ve elektromekanik olmak üzere çeşitli jiroskoplar mevcuttur. Birincil kullanımları yön bulma olsa da mekanik jiroskoplar, ürettikleri jiroskobik tork nedeniyle uçak ve uzay aracı gibi tamamen havada asılı duran araçlara yön vermek için kullanılmaktadır. Ayrıca karada da tek ve iki tekerlekli araçların otonom dengelenmesi için kullanılmaktadır. Hava, uzay ve savunma sanayi için kullanılan bir uygulamadır. Bir uzay aracı tamamen asılı olduğundan dolayı ya yakıt

itkisi ya da mekanik jiroskoplarla yön kontrolü sağlanabilmektedir. Savunma sanayisinde ise tek veya iki tekerlekli otonom araçların dengelenmesi için de kullanılmaktadır.

Mekanik jiroskopların çeşitli türleri vardır. Bu çalışmada ağırlık esasına dayanan jiroskoplar incelenmiştir. İlave olarak her türlü mekanik jiroskoplar yalpalama hızına bağlı olarak jiroskobik tork üretebilmektedir. Bu tip jiroskopta dönen volan, elastik torsiyon çubukları vasıtasıyla gimballere bağlıdır. Volan ayar hızı adı verilen özel bir hızda dönmektedir.

\* Sorumlu yazar  
E-posta adresi: ikacar@gmail.com

Alındı : 31 Mayıs 2023  
Revizyon : 14 Eylül 2023  
Kabul : 29 Eylül 2023

Literatür araştırması tahmin yöntemlerinin öneminin dünya çapında arttığını göstermektedir. Gerekli jiroskobik momentumu üretecek yalpalama hızını tahmin etmek için analitik formüller veya simülasyon yöntemleri kullanılmaktadır. Bununla birlikte, karmaşık geometriler için analitik formüller sınırlıdır. Bu nedenle geometrinin modele uyacak şekilde basitleştirilmesi, kabuller yapılması bir çare gibi gözükse de bunlar sonuçtaki hata miktarını artırmaktadır. Bu gibi durumlarda çözüm olarak dinamik simülasyonların kullanıldığı görülmektedir (Osman vd., 1982). Belirli koşullar altında, çalışılan olayın çoklu fiziğini ve güvenilir sonuçları elde etmek mümkündür (Kownacki, 2011). Kontrollü tork jiroskobu (CMG) ile donatılmış uzay aracına yapılan dinamik analiz sayesinde titreşimlerin faydalı yük performansı üzerindeki olumsuz etkisi araştırılabilmiştir (Sun vd., 2023). Dinamik analiz kullanılarak, mobil robotun ihtiyaç duyduğu gücü ve bisikleti dengelemek için gereken momenti hesaplamak mümkün olmuştur (Sucuoğlu vd., 2018). 5 kg ilave yük ve 17,5 kg kütleyle sahip iki tekerlekli, otonom sürüş yapan bir bisikleti dengeleme amacıyla kullanılan bir CMG'nin, 30 Nm'lik bir tork üretmesi gerektiği simülasyonla tespit edilmiştir (Kacar vd., 2021). 20,5 kg'lık bir bisiklet tekerleğini dengelemek için 9,25 Nm reaktif jiroskop torkunun gerekli olduğu analitik formüller kullanılarak hesaplanmıştır (Ahmed vd., 2016). Modal analiz sayesinde, her iki uçtan yataklanmış, merkezinde bir disk bulunan şaftın kritik frekansları hesaplanabilmiştir (Fan vd., 2018). Yapının analizi ve optimizasyonu sayesinde, modelin dinamik özelliklerinin büyük ölçüde iyileştirildiği (Xiu vd., 2021) ve ortaya çıkan gerilmelerin hâlâ izin verilen sınırın altında olduğu bildirilmiştir (Ahmed vd., 2016; He vd., 2022; Xiu vd., 2021). CMG tasarımlarının yüksek hassasiyetli simülasyonu sayesinde, karmaşık elektromekanik cihazları hızlı ve yüksek kalitede geliştirmek, optimum çalışma özelliklerini tespit etmek mümkündür. Böylece dinamik analizlerin imalattan önce gerekli ön çalışmaların yapılabilmesine olanak tanıdığı anlaşılmaktadır (Kostyuchenko ve Indygasheva, 2018).

Modelleme ve tahmin için (Amiroh vd., 2021) *model* ve *veri* esaslı (Tobon-Mejia vd., 2012) olmak üzere iki çeşit yöntem kullanılmaktadır. Model esaslı olanlar fiziksel akıl yürütmeye dayalıdır ve kesin çözümler üretmektedir. Modelleme ve tahmin yapmak için artıklar (kalıntılar, farklar) değerlendirilmektedir. Bununla birlikte, gerçek sistemlerin karmaşıklığından dolayı, bu tür matematiksel modellerin oluşturulması nispeten zordur. Gerçek sistemlerin karmaşık yapısını varsayımlarla basitleştirmek mümkün olsa da ne kadar çok varsayım varsa sonuçlarda o kadar çok sapma oluşabilmektedir. Veriye dayalı yaklaşımlar ise veri setleri üzerine yapılan istatistiksel işlemler sayesinde modelleme ve tahmin yapmaktadır. Karmaşık şekilli sistemler için veri esaslı yöntemler ilk tercihtir. Dash ve Venkatasubramanian (2000) ve Venkatasubramanian ve ark. (2003) kapsamlı bir araştırma yürütmüş, iki yöntemi

karşılaştırmış ve veriye dayalı yöntemin daha avantajlı olduğu sonucuna varmıştır (Dash ve Venkatasubramanian, 2000) (Venkatasubramanian vd., 2003). Veriye dayalı yöntemler ise iki kategoriye ayrılmaktadır: Biri yapay sinir ağları, derin öğrenme gibi yapay zekâ yöntemleri, diğeri ise istatistiksel öğrenme yöntemleridir (gizli Markov modeli (HMM), destek vektör makinaları (SVM) vb.) (Dong vd., 2020). Bir sürecin gözlenebilir kısmını temsil etmede ARIMA, SARIMA, SARIMAX, Poisson otomatik gerileyen, lineer vb. regresyon yöntemleri kullanılırken, sürecin gözlenemeyen kısmının tahmini için HMM ve SVM yöntemleri kullanılmaktadır.

Navigasyon sistemlerinde yapay sinir ağlarının (YSA) kullanılması, filtreleme algoritmalarının doğruluğunu artırmıştır (Jamil ve Kim, 2019). Nuswantoro ve ark. (2020) YSA algoritması ile jiroskop ve ivmeölçerden gelen verileri değerlendirilerek hareket tanımlama sürecini geliştirmişler ve sürücü durumunun tespitini %96,2 doğruluk düzeyi ile yapabildikleri (Nuswantoro vd., 2020). Kathpalia ve Gulati (2022) üç eksenli jiroskop verisini tek giriş tek çıkışlı çok katmanlı algılayıcı (MLP) ağında kullanarak GPS doğruluğunu iyileştirmiştir (Kathpalia ve Gulati, 2022). Papakonstantinou ve ark. (2022) makine öğrenimi tekniklerinden derin sinir ağı (DNN) ve rastgele orman sınıflandırıcısı (RFC) kullanarak bir uydunun tutum kontrolü için kullanılan CMG için tekillikten kaçınma sorununu ele almışlardır. RFC tekniğinin, DNN'ye kıyasla test verileri için gelişmiş doğruluk gösterdiğini belirtmişlerdir (Papakonstantinou vd., 2022).

Yazarların bilgisine göre, açık literatürde, NAR ağı kullanarak jiroskop yalpalamasının zaman serisi tahminini içeren bir çalışma mevcut değildir. Bu çalışmada bir mekanik jiroskobun, sonlu eleman simülasyonu esaslı rijit dinamik analizi gerçekleştirilmiş ve elde edilen yalpalama verisinin, zamana bağlı olarak modellenmesi için NAR ağı kullanılmıştır. Sonuçlar göstermiştir ki NAR ağı ile yüksek korelasyona sahip bir tahmin modeli oluşturulabilmektedir. Modeli oluşturmak için kullanılan ağ parametreleri ve bu model ile elde edilen tahmin performansları çalışma içerisinde sunulmuştur. İkinci bölümde mekanik jiroskobun çalışma esası verilmişken üçüncü bölümde yapılan dinamik analiz ve bu analizden elde edilen veri izah edilmiştir. Dördüncü bölümde modellerin randımanlarının değerlendirilmesinde kullanılan istatistiksel yöntemler izah edilmiştir. Beşinci bölümde NAR ağı ve altıncı bölümde sonuçlar ve tartışma verilmiştir. Yedinci ve son bölümde ise bu çalışmadan elde edilen temel çıkarımlar sunulmuştur. NAR ağının bu alanda ilk defa kullanılmış olması neticesinde elde edilen temel bilimsel katkı, jiroskop tasarımcılarına yöneliktir. Zira daha jiroskop tasarımı esnasında optimum boyutların, zaman diliminin, torkun, güç gereksiniminin belirlenmesi bu model ve dinamik analiz sayesinde mümkündür. Çalışmanın ikincil katkısı ise dinamik analizcilere olmaktadır. Çünkü simülasyonlarda dönen bir diskin veya çemberin

meydana getirdiği jiroskobik etkinin elde edilebilmesinin bazı püf noktaları mevcuttur. Bu hususlar metin içerisinde dinamik analiz ve veri toplama isimli başlık altında okuyuculara izah edilmiştir.

## 2. Kavramsal Çerçeve (Conceptual Framework)

Ağırlık torkunu dengelemek için jiroskobik tork üreten bir mekanik jiroskobun cisme sabitlenmiş bir eksen takımına göre açısal momentumdaki değişimin genel denklemi, klasik (Newtonian) mekaniğine göre Eşitlik (1) kullanılarak hesaplanmaktadır. Bu eşitlik, simülasyon sonuçlarının doğrulanması için kullanılmıştır.

$$\sum \vec{M} = \frac{d(\vec{L})_{xyz}}{dt} + \vec{\Omega} \times \vec{L} \quad (1)$$

Burada  $\sum \vec{M}$  ifadesi net tork olup, yönü ise, bağıntıya göre  $d\vec{L}$  veya  $\vec{\Omega} \times \vec{L}$  yönündedir.  $\vec{\Omega}$ , yalpalama olarak adlandırılan ikinci Euler açısındaki (Anonimouse, 2023) açısal hızdır.  $\vec{L}$  açısal momentum ve  $t$  ise zamandır. Açısal momentumun, volanın dönme hızı yönünde olacağı unutulmamalıdır. Volanın dönme hızı, yalpalama hızı ve moment eksenleri birbirlerine diktir. Jiroskobik tork üretmek için ağırlık kullanılan mekanik jiroskoplarda denklemin sol tarafı  $\sum \vec{M} = \vec{r} \times m\vec{g}$  ifadesine eşit olacaktır.  $\vec{r}$  moment kolu olup volan diskinin ağırlık merkezi ile dönme merkezi arasındaki fark,  $m$  volan kütlesi ve  $\vec{g}$  yerçekimi ivmesidir.

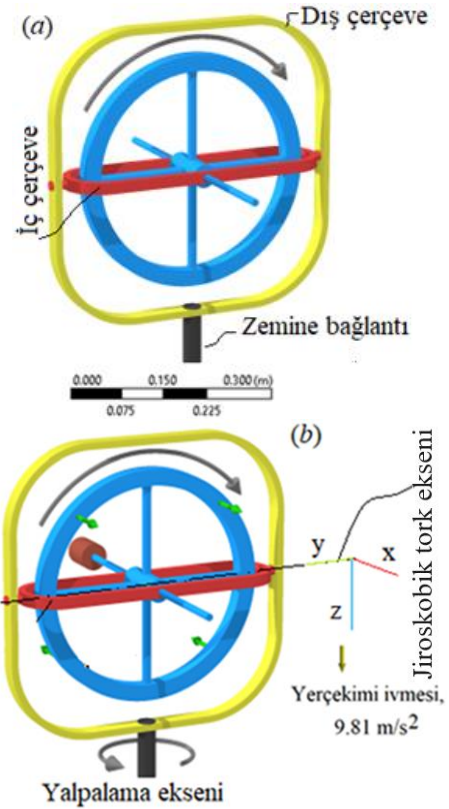
## 3. Metodoloji (Methodology)

### 3.1. Dinamik Analiz ve Veri Toplama (Dynamic Analysis and Data Acquisition)

Veri seti, sonlu eleman simülasyonuna dayalı dinamik simülasyon sonucunda elde edilmiştir. Simülasyonlar Ansys® yazılımı kullanılarak yapılmıştır (Ansys®, 2023). Analiz, toplam süresi 5 saniye olan iki adımda gerçekleştirilmiştir. Dinamik analizin iterasyonlarında minimum zaman adımı  $1e-7$  s ve maksimum zaman adımı  $5e-2$  s ile sınırlanmıştır. Dönen bir diskin veya çemberin meydana getirdiği jiroskobik etkinin hesaplanabilmesi için, diskin (veya çemberin) şaft ile birlikte yekpare olması yani birlikte dönmesi gerekmektedir. Eğer disk, şaft etrafında döndürülürse, jiroskobik tork elde edilemeyecektir! Zaman adımı sabit olduğu için eşit zaman aralıklarında, toplam 415 adet veri toplanmıştır. Volan kendi ana eksenini etrafında sabit bir açısal hızda döndürülmektedir. Bu esnada diğer iki eksenlerden birinde ağırlığın neden olduğu tork oluşurken, geriye kalan ekseninde de yalpalama meydana gelmektedir. Veri setini, yalpalama eksenindeki döner bağlantının yaptığı açısal hız ve karşılık gelen zaman

adımları oluşturmaktadır. Tek değişken yalpalama olup, zamana bağlıdır. Zamana bağlı serilerde çıktı değişkeni, belli bir gecikmeye bağlı olarak girdi olmaktadır. Bu çalışmada yalpalama verisi kendisine bir gecikmeli olarak bağlı olduğundan dolayı, yalpalama verisi çıktı iken, onun bir gecikmeli değeri ise girdi olmaktadır. Bu hâli ile bir girdi, bir çıktıya sahiptir. Verinin gecikme miktarının tayini müteakip başlıklar altında izah edilmiştir.

Her bir simülasyon, 3.40 GHz hızında çalışan dört çekirdekli işlemcili, 8 GB RAM'e sahip bir bilgisayarda 2.866 saniye sürmüştür. Şekil 1, bu çalışmada kullanılan ağırlık dengeleme ilkesine dayanan mekanik jiroskobu göstermektedir. Bir adet çember biçimli volan mevcuttur. Volanın dönme hızı, yalpalama hızı ve moment eksenleri birbirlerine dik olması nedeniyle gerektiğinde, bunların üçünü de sağlayabilmesi için, tasarlanan sistemde, volanın üç ekseninde de dönme hareketi yapabileceği kabiliyeti olması gerekmektedir.



**Şekil 1.** Çalışmada kullanılan mekanik jiroskop (NI, 2023) (a) kavramsal tasarımı, (b) ağırlık uygulanması hali (Mechanical gyroscope used in the study (a) conceptual design, (b) weight application)

Çalışmada Şekil 1'de verilen tasarım kullanılmış olup bu sayede volanın hem kendi eksenini etrafında hem de diğer iki eksen etrafında serbestçe dönebilmesine olanak sağlanmıştır. Böylece üç eksen etrafında da gerektiğinde olası dönüşler serbestçe yapılabilecektir. Yerçekimi ivmesi uygulanmıştır. Analizde kullanılan modelin temel varsayımları şunlardır: (1) malzemede

sönüm yoktur, (2) yatak sürtünmesi ihmal edilmiştir (3) yataklamalarda temas yüzeylerinin tamamı temas halindedir, (4) diğer dış koşullar dikkate alınmamıştır (5) Tüm parçalar rijittir. Bu nedenle eleman ağı üretilmemiştir. Rijit cisimlerde esneme veya hasar söz konusu değildir. Temas kullanılmamıştır.

Tork oluşmasına neden olan unsur ağırlıktır. Mevcut tasarıma göre kütle merkezinden dönme merkezine olan mesafe nedeni ile ağırlığın sebep olduğu tork  $Tork_W = \vec{r} \times m\vec{g} = 0.03 * 1.59 * 9.8066 = 0.468 \text{ kgm}^2/s^2$  olarak hesaplanmıştır.

Ham verilere değişken varyans testlerden biri olan Engle's ARCH testi uygulanmıştır. Ham verilerin değişken varyansa sahip olduğu görülmüştür. Herhangi bir regresyondan önce, araştırmacılar genellikle ham deneysel verilerdeki değişken varyansı ortadan kaldırmak, veriyi iyileştirmek için ön işlem(ler) uygulayabilmektedirler (Hossein ve Tabari vd., 2012; Shen vd., 2020; Taheri vd., 2021). Bununla birlikte uygulanan ön işlemin miktarı, şiddeti ne olursa olsun, herhangi bir işlem, verilerin doğallığını bozmakta ve olayı temsil etme yeteneğini azaltmaktadır. Bu nedenle çalışmada ham veriler üzerinde herhangi bir ön işlem yapılmamıştır. Bu sayede genel veri eğrisini yakalayabilmenin yanı sıra eğrideki tepe ve çukurları da yakalayabilmesi, NAR ağı'nın ayırt edici özelliklerinden birisi olacaktır.

Bütün parçaların malzemesi yapı çeliği olup özellikleri Tablo 1'de verilmiştir. CMG'ye ait geometrik özellikler ise Tablo 2'de verilmiştir.

**Tablo 1.** Malzeme özellikleri

Özellik	Değer
Yoğunluk ( $\text{kg}/\text{m}^3$ )	7850
Çekmedeki akma gerilmesi (MPa)	250
Basmadaki akma gerilmesi (MPa)	250
Çekmedeki maksimum gerilme (MPa)	460
Basmadaki maksimum gerilme (MPa)	460

**Tablo 2.** CMG'nin geometrik özellikleri

Özellik	Değer
<b>Dış çerçeve</b>	
Hacim ( $\text{m}^3$ )	7.39E-05
Asal atalet momenti, $I_{p1}$ , ( $\text{kg}\cdot\text{m}^2$ )	4.23E-03
Asal atalet momenti, $I_{p2}$ , ( $\text{kg}\cdot\text{m}^2$ )	4.73E-03
Asal atalet momenti, $I_{p3}$ , ( $\text{kg}\cdot\text{m}^2$ )	8.94E-03
Kütle (kg)	0.58
<b>İç çerçeve</b>	
Hacim ( $\text{m}^3$ )	1.64E-04
Asal atalet momenti, $I_{p1}$ , ( $\text{kg}\cdot\text{m}^2$ )	6.23E-03
Asal atalet momenti, $I_{p2}$ , ( $\text{kg}\cdot\text{m}^2$ )	5.92E-03
Asal atalet momenti, $I_{p3}$ , ( $\text{kg}\cdot\text{m}^2$ )	1.20E-02
Kütle (kg)	1.29
<b>Volan</b>	
Hacim ( $\text{m}^3$ )	1.01E-04

Disk kalınlığı (mm)	5.00
Asal atalet momenti, $I_{p1}$ , ( $\text{kg}\cdot\text{m}^2$ )	1.28E-03
Asal atalet momenti, $I_{p2}$ , ( $\text{kg}\cdot\text{m}^2$ )	1.26E-03
Asal atalet momenti, $I_{p3}$ , ( $\text{kg}\cdot\text{m}^2$ )	2.53E-03
Disk yarıçapı (mm)	4.00E+02
Mil çapı (mm)	5.00E+00
Kütle (kg)	7.95E-01
Kendi eksenine etrafındaki dönme hızı, $\omega$ (rad/s)	128
Volan ağırlık merkezinin CMG merkezine olan mesafesi (mm)	30



### 3.2. Model Performans Değerlendirmesi (Model Performance Assessment)

Bir modelin tahmin yeteneğini belirlemenin en uygun yolu, ham veriler ile modelin öngördüğü değerlerin aralarındaki farkı hesaplamaktır. Hata analizi bu amaçla sıklıkla kullanılan bir yöntemdir. Diğer bir popüler yöntem de çoklu veri kümeleri arasındaki ilişkileri belirlemek üzere korelasyon miktarını araştırmaktır. Yaygın olarak kullanılan hata fonksiyonları ve korelasyon formülü Eşitlik (2)'de verilmiştir.

$$MSE = \frac{1}{N} \sum_{t=1}^N (p(t) - o(t))^2 \quad (2.a)$$

$$RMSE = \sqrt{MSE} \quad (2.b)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |p(t) - o(t)| \quad (2.c)$$

$$MAPE = \frac{100}{N} \sum_{t=1}^N \frac{|p(t) - o(t)|}{o(t)} \quad (2.d)$$

$$\text{Kalıntı} = p(t) - o(t) \quad (2.e)$$

$$R = \frac{(\sum_{t=1}^N [p(t) - \bar{p}][o(t) - \bar{o}])}{\left( \sqrt{\sum_{t=1}^N [(p(t) - \bar{p})^2]} \sqrt{\sum_{t=1}^N [(o(t) - \bar{o})^2]} \right)} \quad (2.f)$$

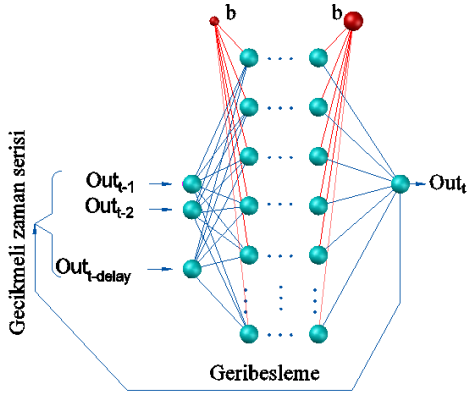
Burada  $o(t)$  veri setindeki değerler ve  $p(t)$  ise modeller tarafından tahmin edilen verilerdir.  $t$  ise zaman adıdır.  $R$  ifadesi korelasyon olup -1 ile 1 arasında değer almaktadır, birimi yoktur. MSE hatanın karesinin ortalamasıdır. MSE'nin karekökü RMSE'dir. MAE de mutlak hatanın ortalamasıdır. MSE, RMSE ve MAE değerlerinin sıfıra yakın olması istenir. RMSE incelenen veri ile aynı birimdeyken MAPE ise yüzde birimindedir. MSE ise birim<sup>2</sup> olmaktadır. MAE, hata ile aynı birimdedir.  $R$  veya  $R^2$  değerlerinin pozitif 1'e yakın olması, fonksiyonun tahmin ettiği değerler ile ham veri arasında kuvvetli bir lineer ilişkinin olduğunu göstermektedir. -1'e yakın olması ise kuvvetli bir ters lineer ilişki olduğunu göstermektedir. Sıfır, herhangi bir ilişki olmadığını göstermektedir. RMSE, MSE, MAE

gibi hata değerlerinin sıfıra yakın olması da tahmindeki ortalama hata değerlerinin azlığını göstermektedir.

### 3.3. NAR ile Modelleme (Modelling using NAR)

Şekil 2’de bu çalışmada kullanılan doğrusal olmayan, otomatik gerileyen, çok katmanlı algılayıcı ağı şematik olarak gösterilmiştir.  $b$ ’ler *bias* olup bir modelin tahmin değerlerini belli bir yöne doğru götürmeye yarayan değerlerdir. İstatistik ve makine öğreniminde sıklıkla kullanılan bir özelliktir. Ağ mimarisi  $Out(t) = f((t - 1), \dots, (t - d))$  yapısındadır.  $d$  terimi gecikme olup 2 olarak alınmıştır. Bu, iki adet giriş olacağını ve bunlarında çıkıştan iki adım geride olacağı anlamına gelmektedir.

Toplam veri setinin ilk %60’ı eğitim için, geri kalan %40’ı ise tahmin için kullanılmıştır. Veriler yazılım içerisinde başlangıçta normalleştirilmiştir. Veri normalizasyonu için, veri seti değişkenlerinin ölçüm ölçeğindeki dramatik değişiklik nedeniyle, tüm değişkenler (-1,1) aralığında minimum-maksimum ölçeklendirme yöntemi kullanılarak normalleştirilmiş bu da eğitim aşamasında daha iyi veri yorumu ve daha iyi model yakınsaması ve doğruluğu sağlamıştır. NAR ağları, yazılım kodları kullanılarak oluşturulmuştur (Heris, 2015). IoT (nesnelerin interneti) kullanan herhangi bir donanım uygulaması bu çalışmanın kapsamı dışındadır.

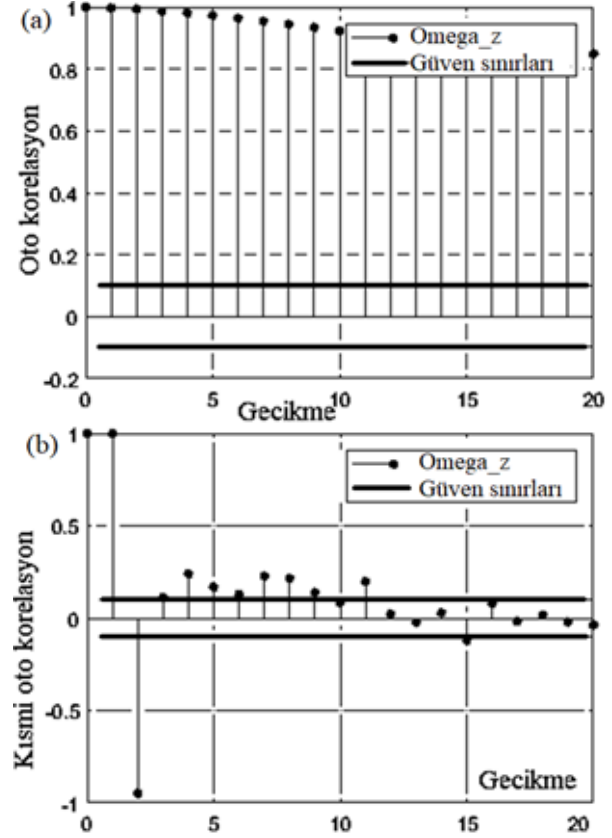


Şekil 2. NAR topolojisi (NAR topology)

Zaman gecikmelerini tespit etmek için korelogramlar kullanılmıştır (Şekil 3).

Şekilde sadece  $z$  bileşene dair diyagramlar verilmiş olup, diğer bileşmelerin de aynı desende olduğu görülmüştür. Yalpalamanın bileşenleri ve bileşkesi oto korelasyon ve kısmi oto korelasyon grafiklerinde değerlendirilmiştir. Her iki tip grafikten serideki verilerin kendi gecikmelerine bağlı olduğu yani rastgele olmadığı görülmektedir. Otokorelasyon fonksiyonu (OKF) giderek azalmaktadır. OKF katsayıları sıfırdan önemli ölçüde farklıdır ve yavaş yavaş sıfıra doğru düşmektedir. Kısmi otokorelasyon fonksiyonu (KOKF) ikinci gecikmeden sonra kesilmektedir. Daha fazla gecikme sıfıra yakın olup iki standart sapma kadarlık

güven sınırlarının hemen hemen içerisinde kalmaktadır. Bu durum 2 gecikmenin birbirleri ile yüksek ilişkili ve ikiden sonraki ardışık değerlerin birbiriyle ilişkili olmadığı anlamına gelmektedir. Bu davranış, serinin ilk iki gecikmeye bağlı ve otomatik gerileyen bir seri yani AR(2) türünde olduğunu göstermektedir.



Şekil 3.  $z$  doğrultusundaki yalpalama bileşenine ait (a) OKF (b) KOKF ((a) ACF (b) PACF for the precession component in the  $z$  direction)

YSA’da gizli katman sayısı ve gizli katmanlardaki nöronların sayısının belirlenmesinde tüm ağ türleri için kullanılabilecek tek bir yöntem henüz mevcut değildir. Optimum sayıyı tutturmak hayattır çünkü gizli katmanlarda çok az nöron kullanılması *yetersiz uydurma*, çok fazla nöron olması ise *aşırı uydurma* olarak adlandırılan hatalı durumlara neden olabilmektedir. Bununla birlikte veri seti ile modelde hesaplanan değerler arasında en yüksek korelasyona veya en büyük farka sahip modelin sıklıkla deneme-yanılma yoluyla belirlendiği görülmektedir (Amini vd. , 2021; Beigi ve Torki, 2021). Deneme-yanılma süreci zaman alıcı ve zaman-verimlilik ve maliyet açısından yetersizdir (Öğündür, 2019).

Gizli katmanların âdeti ise problemin karmaşıklığına bağlıdır. Sınır ağlarındaki daha fazla sayıda gizli katman, daha karmaşık özellikleri temsil etmektedir. Sıfır gizli katman, doğrusal ayrılabilir fonksiyonlarda veya kararlarda iyidir. 1 gizli katman, bir sonlu uzaydan diğerine sürekli bir eşleme içeren herhangi bir

fonksiyona yaklaşabilirken, 2 gizli katman, rasyonel aktivasyon fonksiyonları sayesinde isteğe bağlı bir karar sınırını isteğe bağlı doğrulukla temsil edebilmektedir. Herhangi bir düzgün işlemeyi herhangi bir doğrulukla yaklaştırabilmektedir (Heaton, 2008). Bu çalışma yalpalama uzayında tahminleme içerdiği için gizli katman sayısı 1 olarak belirlenmiştir.

Gizli katmanlardaki nöronların sayısı ile ilgili deneme-yanılma yoluyla üretilmiş bazı formüllerin literatürde verildiği de görülmüştür. Heaton (2008) Eşitlik (3)'teki formülü kullanarak gizli katmandaki nöron sayısı  $N_h$ 'nin en fazla olabilecek sayısını hesaplamıştır (Heaton, 2008).

$$N_h = \frac{N_s}{(\alpha * (N_i + N_o))} \quad (\text{Eş. 3})$$

Burada  $N_i$  giriş nöronlarının sayısıdır,  $N_o$  çıkış nöronlarının sayısı,  $N_s$  eğitim veri setindeki örnek sayısıdır.  $\alpha$ , keyfi bir ölçeklendirme çarpanı olup genellikle 2-10 arasında alınmaktadır. Örneğin  $N_s = 415$  ve  $N_i = 2$ ,  $N_o = 1$  ve  $\alpha = 10$  için gizli katmandaki nöron sayısı  $N_h \leq 14$  olmalıdır. İlave olarak gizli katman(lar)daki nöron sayısı giriş katmanı boyutu ile çıkış katmanı boyutu arasında olmalıdır. Bir başka yaklaşıma göre gizli katmandaki nöron sayısı, giriş katmanı boyutunun 2/3'ü ile çıkış katmanı boyutunun 2/3'ünün toplamı kadar olmalıdır. Başka bir yaklaşıma göre gizli nöronların sayısı, giriş katmanı boyutunun iki katından az olmalıdır. Öyleyse,  $N_h < 4$  olmalıdır. Master'a (1993) göre tek gizli katmanlı bir sinir ağı için gizli nöron sayısı  $N_h = \sqrt{N_i * N_o}$ 'tür. Yukarıdaki örnek için  $N_h \approx 2$  olacaktır. Bir örüntüye ve öznetelik çıkarımına giderek daha fazla yaklaşmak ve hedef sınıfı belirlemek için sonraki katmanlarda gizli nöronların sayısı azalmaya devam etmelidir (Masters, 1993). Sartori ve Antsaklis (1991),  $N_h = N_i - 1$  ile bir gizli katman kullanmıştır (Sartori ve Antsaklis, 1991). Buna göre  $N_h = 1$  olmalıdır. Rachmatullah ve ark. (2020)'na göre bir sinir ağı iki gizli katmana sahipse, birinci katmandaki nöron sayısı  $N_{h1} = N_o * r^2$  ve ikinci katmandaki nöron sayısı  $N_{h2} = N_o * r$  ile hesaplanmaktadır. Burada  $r = \sqrt[3]{N_i/N_o}$  olmaktadır (Rachmatullah vd., 2020). Buna göre  $N_{h1} = 2$  ve  $N_{h2} = 2$  olmalıdır. Tamura ve Tateishi (1997) iki gizli katman kullanmış, karşılık gelen gizli katmanın nöron sayısı  $N_h = 3 + N_i/2$  kullanılarak hesaplanmıştır (Tamura ve Tateishi, 1997). Buna göre  $N_{h1} = 4$  ve  $N_{h2} = 5$  olmalıdır. Tüm çalışmalar bir bütün halinde değerlendirildiğinde nöron sayısının 14'ü aşmaması ve 1'den büyük olması gerektiği sonucu çıkmaktadır. Bütün bu hususlar bir arada düşünüldüğünde, bu çalışmada gizli katmandaki nöron sayısı 5 olarak belirlenmiştir.

YSA eğitimi için kullanılan birçok algoritma arasında hız ve kararlılık sağladığı için Levenberg-Marquardt algoritması oldukça tercih edilmektedir

(Çavuşlu vd. , 2012). Ağırlıklara eğitimden önce ilk değer olarak sıfır verilmiştir. Hata yakınsaması olarak MSE gözlemlenmiştir. Bu çalışmada kullanılan ağ özellikleri Tablo 3'te verilmiştir.

**Tablo 3.** NAR ağ mimarisinin katman yapılandırması (Layer configuration of NAR net topology)

Parametre	Değer
Öğrenme sürecinde hata kriteri	MSE=0.02 birim <sup>2</sup>
Maksimum yineleme sayısı	1000
Gizli katman sayısı	1
Gizli katmandaki nöron sayısı	$N_h = 5$
Gizli katman(lar)daki aktivasyon fonksiyonu	Tanjant hiperbolik
Çıkış katmanındaki aktivasyon fonksiyonu	Lineer
Eğitim algoritması	Levenberg-Marquardt
Gecikme, $d$	2
Harici giriş	--
Çıkış nöronu	1
Çıkış eşiği	0.99
Öğrenme oranı, $\eta$	0.1
Momentum, $\alpha$	0.1
Öğrenme eşiği	0.0001
Veri kümesi bölümlenme	İlk 60% (eğitim+test+doğrulama) son 40% tahmin

"Eşik değer" terimi tabloda verilmiş olup 0 - 1 arasındadır. Eşik değerinin altındaki değerler hesaba katılmamaktadır. Böylece zayıf bilgi unutulmakta ve daha verimli bir ağ elde edilebilmektedir. Öte yandan ağı eğitirken, tahmin performansını iyileştirmek üzere eklenecek veya eksiltilecek değerleri belirlemek için "öğrenme hızı" ve "momentum" terimleri dikkate alınmaktadır. Momentum, ağırlıklar güncellenirken, uygulanacak değişimlere, önceki ağırlık değişimlerin belli bir oranda eklenmesini sağlamaktadır. Eğitim esnasında ağ ağırlıklarının bir önceki değişim değerlerinden ne ölçüde etkileneceğini belirlemektedir. Böylece hesaplanan ağırlık değerlerinin yerel optimuma takılıp kalması riski önlenmektedir. Çıktı ve hata çarpımının başına getirilecek çarpana ise "öğrenme hızı" denmektedir. Öğrenme hızı, ağ eğitiminin ne kadar süreceğini belirlemektedir. Yavaş öğrenme güçlü ağlar oluştururken, hızlı öğrenme zayıf ağlar oluşturmaktadır. Bununla birlikte yavaş öğrenme neticesinde adım büyüklüğü azalacağından, özellikle yerel minimumlara rastlandığında öğrenme yavaşlayıp durma riski mevcuttur. Öğrenme hızı terimi, 0 - 1 arasında değer alabilmektedir. Sayı ne kadar yüksekse öğrenme hızı o kadar yüksektir. Tecrübeler  $0.01 \leq \eta \leq 0.9$  aralığında seçilen öğrenme hızının iyi sonuçlar verdiğini göstermektedir.

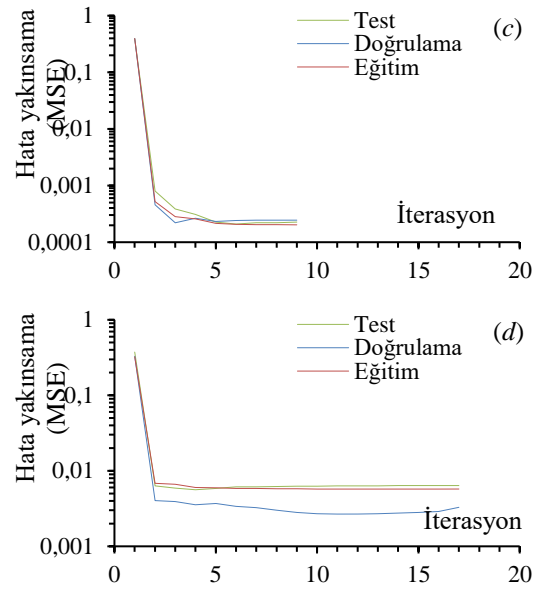
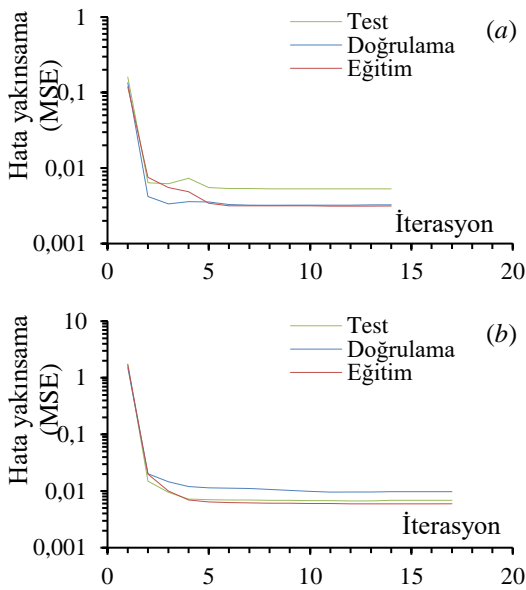
Veri kümesi esasen başlangıçta ikiye ayrıldı. İlk 60% (eğitim+test+doğrulama), son 40% tahmin için kullanılmıştır. %60'lık ilk bölüm ise ayrıca üç parçaya %70, %15 ve %15 (eğitim, test ve doğrulama)

bölünmüştür. Literatürde veri kümesi bölümlemesinin rastgele yapıldığı görülmüştür (Çavuşlu ve ark. 2012).

## 4. Sonuçlar ve Tartışma (Results and Discussions)

### 4.1. Doğrulama (Validation)

Eğitim esnasında izlenen MSE'deki hata yakınsama eğrileri Şekil 4'te verilmiştir. Eğriler incelendiğinde genel olarak eğitim, test ve doğrulama esnasında hatanın gittikçe sifıra yaklaştığı ve bu esnada da hatanın değişiminde herhangi bir sapma olmadığı görülmektedir. Bu durum ağların eğitimleri esnasında kararlılıklarını kaybetmediğini göstermektedir.

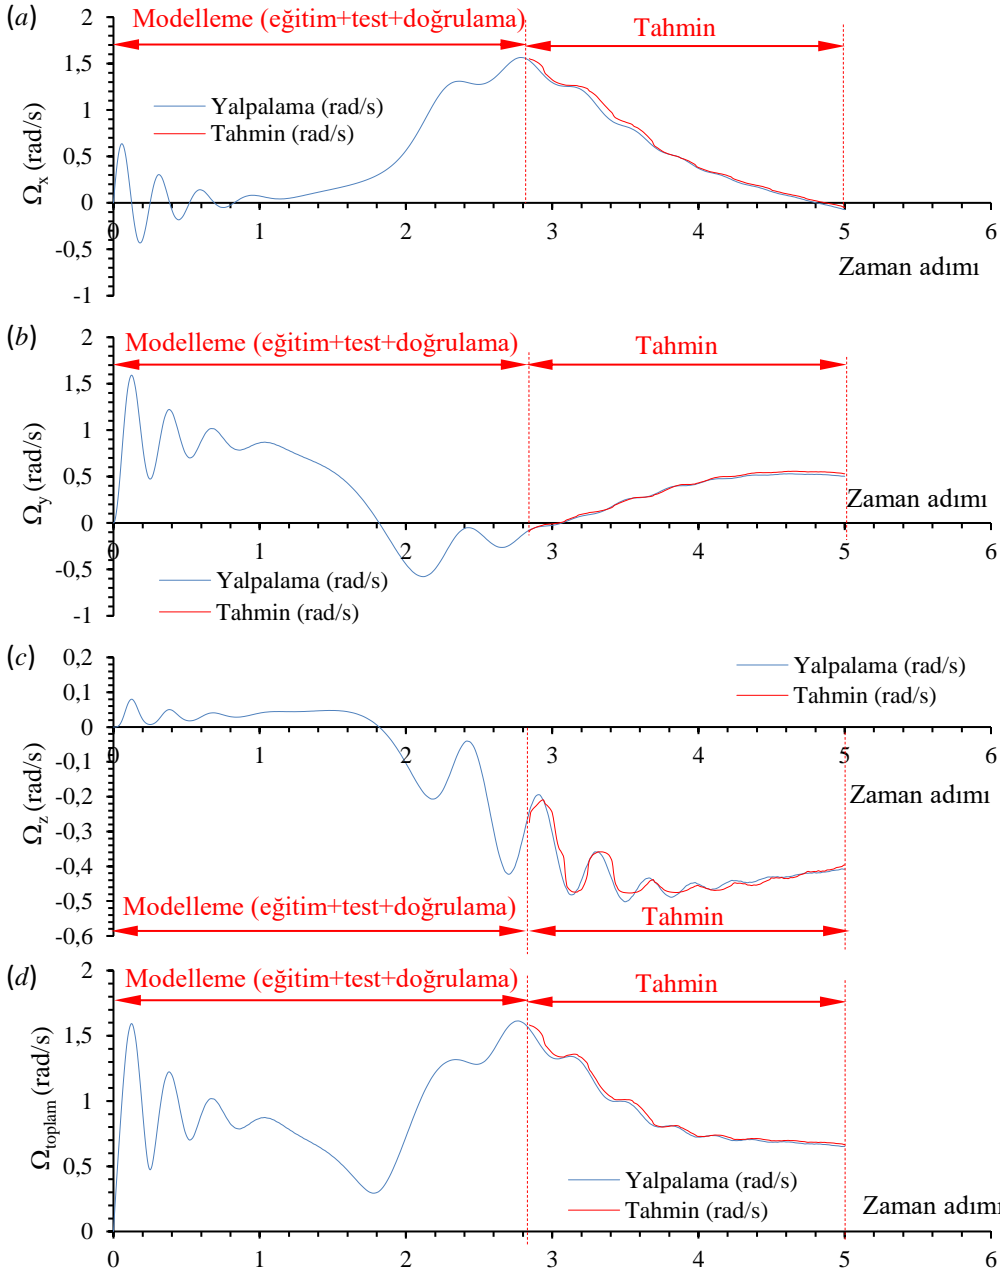


**Şekil 4.** Ağın eğitimi sırasında (a) x doğrultusundaki (b) y doğrultusundaki (c) z doğrultusundaki (d) bileşke yalpalamadaki hata yakınsaması, dikey eksen logaritmiktir (Error convergence during training of the networks where vertical axis is logarithmic (a) the network to predict the precession in the x-direction, (b) y-direction, (c) z-direction, (d) the resultant precession)



### 4.2. Tahmin eğrileri (Prediction curves)

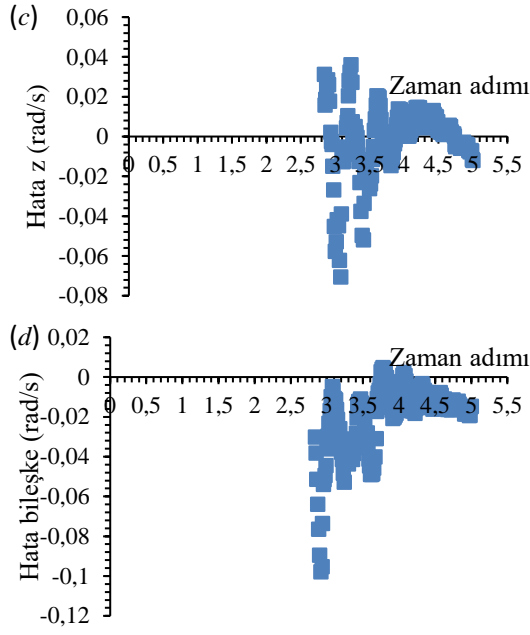
Modellerinin tahmin eğrileri sırasıyla Şekil 5'te karşılaştırılmıştır. Ağlar eğitim, test ve doğrulama sırasında tahmin verilerini bilmemekteydiler. Veri kümesinin son %40'lik kısmı, eğitime başlamadan önce tahmin için ayrılmıştı. Şekil 6'da yatay ekseninde zaman adımı hâlinde hata (veri seti ile model tahmin değerleri arasındaki fark) değerleri verilmiştir. Böylece her bir zaman adımıdaki ve her bir verideki hata tek tek görülebilmektedir. Fark hesaplaması model tahmini ve veri seti arasında yapıldığından dolayı verinin sadece test kısmına denk gelen kısmı görülmektedir. Farkın küçük olması, modelin tahmin ettiği değerlerin, veri setindeki değerlere çok yakın olduğu ve böylece model performansının yüksek olduğu anlamına gelmektedir.





Şekil 5. Ağın (a) x doğrultusundaki, (b) y doğrultusundaki, (c) z doğrultusundaki, (d) toplam yalpalama hızı (The precession in (a) x-direction, (b) y-direction, (c) z-direction, (d) the resultant precession)





**Şekil 6.** Ağın tahmini ile veri seti arasındaki fark (a)  $x$  doğrultusundaki, (b)  $y$  doğrultusundaki, (c)  $z$  doğrultusundaki, (d) bileşke yalpalamadaki hata (Difference between the network's prediction and the data set (a) error in  $x$ -direction, (b) error in  $y$ -direction, (c) error in  $z$ -direction, (d) error in the resultant precession)

Tablo 4'te NAR ağının tahmin performans metrikleri verilmiştir. Tüm veri için en fazla iterasyon sayısı 34 olmuştur. Tüm veri için yüksek ve pozitif korelasyon görülmektedir. Bu durum, oluşturulan ağların yaptığı tahminlerin, veri seti ile yüksek uyuma sahip olduğunu göstermektedir. Ancak tek başına yüksek korelasyon, modelin yüksek performansa sahip olduğunu ispata yeterli değildir. Bu nedenle hata metrikleri de incelenmiştir. RMSE metriğinin en yüksek değeri,  $\Omega_y$  verisinde  $\cong 0.124$  rad/s olmaktadır. Bu durum MSE, MAPE, MAE metriklerinde de benzerdir. En düşük hata ise  $\Omega_y$  tahminlemede oluşmaktadır.

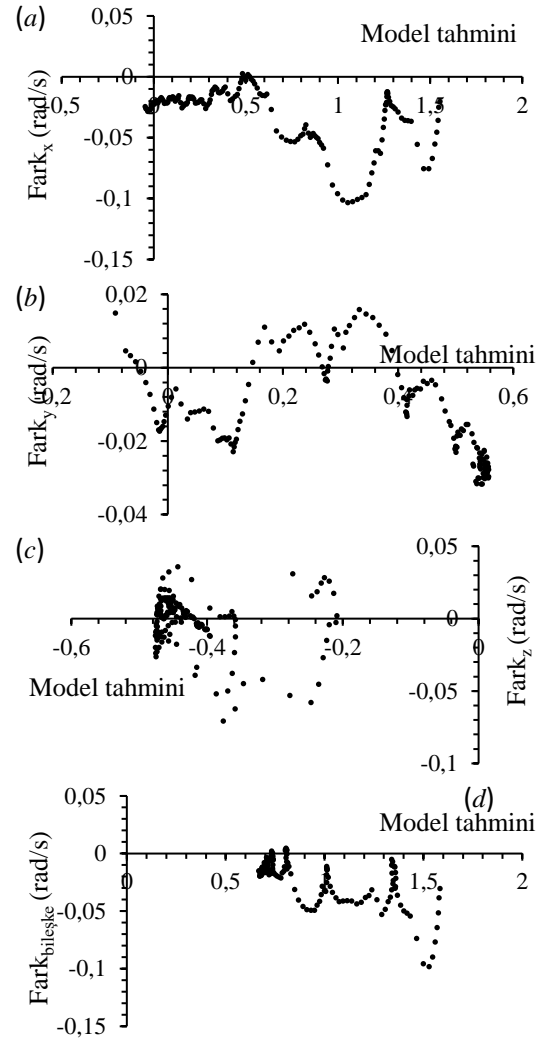
**Tablo 4.** NAR ağının tahmin performans metrikleri (Prediction performance metrics of the NAR net)

Yalpalama (rad/s)	$\Omega_x$	$\Omega_y$	$\Omega_z$	$\Omega_{bileşke}$
MAE (birim)*	0.032	0.007	0.014	0.02
MAPE (%)	3.543	2.387	-3.408	1.61
Hata (birim)	0.032	0.007	0.014	0.02
MSE (birim <sup>2</sup> )	0.015	0	0.001	0.011
RMSE (birim)	0.124	0.016	0.031	0.106
Hesaplama süresi (s)	0.709	0.941	0.726	0.927
$R$	0.971	0.998	0.922	0.928
İterasyon (adet)	12	13	10	34

(\*): Birimler değişkenlerin birimi (rad/s) ile aynıdır.

Şekil 7'de yatay ekseninde model tahmini hâlinde hata (veri seti ile model tahmin değerleri arasındaki fark)

değerleri verilmiştir. Böylece tahmin edilen değer arttıkça her bir verideki hatanın değişim biçimi görülebilmektedir. Bu sayede değerlerde varyansın değişip-değişmediği hakkında fikir elde edilebilmektedir. Değişen varyans istenmeyen bir durumdur çünkü en küçük kareler regresyonu, sabit varyansa varsayımına dayanmaktadır. Yani varyans sabit ise regresyon sonucu doğru olmaktadır. Şekillerde dağılımın salınım yapmakla birlikte sabit varyansa sahip olduğu ve sifıra yakın rastgele dağıldığı görülmektedir. Sabit ve rastgele dağılımlar sabit varyansı temsil etmektedir. Engle'nin ARCH testine göre ham veriler değişken varyans içermekteydi. Bununla birlikte, NAR modellerinin sabit varyansa sahip olması, değişken varyansa sahip ham veriler için herhangi bir ön işleme gereksiniminin ortadan kaldırıldığını göstermektedir.



**Şekil 7.** Ağın tahmini ve fark dağılımı (a)  $x$  doğrultusundaki, (b)  $y$  doğrultusundaki, (c)  $z$  doğrultusundaki, (d) bileşke yalpalama (Estimation and difference distribution of the network (a)  $x$ -direction, (b)  $y$ -direction, (c)  $z$ -direction, (d) the resultant precession)

### 4.3. Tartışma (Discussion)

Jiroskop modelleme çalışmalarında sıklıkla regresyon ve nadiren SVM, HMM yöntemlerinin kullanıldığı görülmektedir. NAR ağı veri üzerine herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmıştır. Genel veri eğrisini yakalayabilmenin yanı sıra eğrideki tepe ve çukurları da yakalayabilmiştir. Modelin performans göstergesi olarak MAE, MAPE, Kalıntı, MSE, RMSE,  $R$  değeri kullanılmıştır.  $R=0.998$ ,  $RMSE=0.016$  rad/s değerleri elde edilebilmiştir. Shi ve ark. (2019) RMSE hatasını BP yöntemi için  $0.0135$  °C, SVM yönteminde  $0.0151$ °C ve LSTM yönteminde  $0.0112$  °C olarak bulmuştur (Shi vd., 2019). NAR yönteminin BP, SVM ve LSTM yöntemleriyle kıyaslanabilir nitelikte iyiliğe sahip olduğu söylenebilmektedir. Nikkhah ve ark. (2009) bir mekanik jiroskoptaki rastgele bozucu ve gürültüler nedeni ile oluşan hataları tahmin etmek üzere doğrusal ve doğrusal olmayan AR, ARMA, ANFIS ve NAR yöntemlerinin kullanımını araştırmış ve NAR ağının rasgele kayma analizi ve telafisi için en iyi çözüm olduğunu bildirmiştir (Nikkhah vd., 2009). Wang ve ark. (2022) yüksek hızda dönen hava ve uzay araçlarının tutum değişikliği parametrelerini tahmin etmek ve çözmek için BP, kapalı tekrarlayan birim (GRU), LSTM, BILSTM ağırları kullanmışlardır. Simülasyon ve deney sonuçlarının BILSTM'nin tahmin doğruluğunun diğerlerine kıyasla daha iyi olduğunu göstermiştir (Wang vd., 2022). Muthusamy ve Kumar (2022) uydularda kullanılan CMG'lerin hasar ve geriye kalan faydalı ömür tahmininde veriye dayalı bir model geliştirmek için Chebyshev sinir ağı kullanılmıştır. Model, çevrimiçi tahmin için %30 veri mevcut olduğunda %96,25 doğrulukla çalışmıştır (Muthusamy ve Kumar, 2022). Yang ve ark. (2023) jiroskobun kapalı döngü alt uzay

öngörülü kontrolünü gerçekleştirmişlerdir. CMG'lerin yörünge izleme problemi için bir çözüm sunmaktadır. Bu amaçla kapalı döngü alt uzay öngörülü kontrolü (CSPC) yöntemi kullanılmıştır. Konum kontrolü  $0.0128$ ° ortalama bağıl kare hatası ile sağlanabilmiştir (Yang vd., 2023). Wisesa ve Mahardika (2018) LSTM ağırları kullanarak jiroskobun ivmeölçer verilerine dayalı olarak hasar algılama modeli geliştirmişlerdir (Wisesa ve Mahardika, 2019). İvme tahmininde eğitim esnasında % 91,43 doğruluk ( $x$  doğrultusunda) elde ederken test esnasında % 92,31 doğruluk elde etmiştir. Yang ve ark. (2022) akıllı telefonlardaki ivme ölçmede kullanılan jiroskop sayesinde insan aktivitesi tanıma için aktivite grafiği tabanlı konvolüsyonel sinir ağı (CNN) kullanmışlardır (Yang vd., 2022). CNN modelinin ortalama tanıma doğruluğunu yaklaşık %5-10 arasında artırdığı bildirilmiştir. Huang vd (2022) derin öğrenmeye dayalı bir MEMS IMU jiroskop kalibrasyon yöntemi kullanmışlardır (Huang vd., 2022). Temporal convolutional ağ (TCN) kullanılmıştır. Modelin tutum ve konum doğruluğunun iyileştirildiği bildirilmiştir. Bu da önerilen yöntemin jiroskop hatasını etkili ve doğru bir şekilde kalibre edebileceğini kanıtlamaktadır.

Farklı modellere ait metriklerinin karşılaştırılması: Tablo 5'te verilmiştir. Tablodan görülmektedir ki literatürde çok farklı modeller kullanılmış, bununla birlikte farklı değişkenler incelenmiştir. Bu nedenle mevcut çalışma ile doğrudan kıyaslamak yerine her çalışmadaki farklı parametrelerin kendileri içerisinde değerlendirilmesi yapılabilmektedir. Bununla birlikte ML yöntemlerinin, diğer yöntemlere göre daha başarılı olduğu sonucu çıkartılabilmektedir. Bu hâli ile mevcut çalışmanın yalpalama tahmini konusunda özgünlük içerdiği anlaşılmaktadır.

**Tablo 5.** Farklı modellere ait metrikler

	Hata (birim)	RMSE (birim)	Doğruluk (%)	Metot
Mevcut çalışma	0.007 rad/s	0.016 rad/s	--	NAR
(Shi vd., 2019)	--	0.0112 °C	--	LSTM
(Shi vd., 2019)	--	0.0151°C	--	SVM
(Shi vd., 2019)	--	0.0135 °C	--	BP
(ZhouHu, 2008)	-0.0111 rad/s	--	--	ARMA
(Montoya-Chairez vd. , 2019)	13.25°	--	--	PD
(Montoya-Chairez vd., 2019)	1.3336°	--	--	PID
(Montoya-Chairez vd., 2019)	0.74515°	--	--	Adaptif
(Montoya-Chairez vd., 2019)	0.184°	--	--	YSA
(Pan vd. , 2019)	--	0.013 mrad/s	--	PID
(İbrahim vd. , 2023)	--	2.013 pulse/s	--	LSTM

(Muthusamy and Kumar 2022	--	--	96,25	Chebyshev NN
Yang, Wu et al. 2023		0.0128°	--	CSPC
(Wisesa and Mahardika 2019	--	--	92,31	LSTM
(P. Yang vd., 2022)	--	--	5-10 artış	CNN

## 5. Sonuçlar (Conclusions)

Bu çalışmada bir mekanik jiroskobun dinamik analizi yapılarak elde edilen yalpalama verisinin NAR ağı ile modellenmesi sağlanmıştır. Model performansı araştırılmıştır. Mekanik jiroskopların kullanım alanları havacılık, uzay ve otonom sürüş alanları olduğu için model tahminlerinin isabetli olması bu alanda faaliyet gösteren firmalar için faydalı olacaktır. Çalışma sonunda elde edilmiş olan temel çıkarımlar aşağıda maddeler halinde sıralanmıştır.

- Yalpalama hızının tahmininde NAR ağı hem eğri genel şeklini hem de eğrilerdeki pik ve çukurları yüksek temsil yeteneğine sahiptir. NAR ağı veri üzerine herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmıştır.
- $R=0.998$ ,  $RMSE=0.016$  rad/s değerleri elde edilmiştir olup model çıktısı ile veri seti arasında yüksek ilişki mevcuttur.

## 6. Destek ve Teşekkür Beyanı (Statement of Support and Acknowledgments)

Bu araştırma, kamu, ticari veya kâr amacı gütmeyen sektörlerdeki finansman kuruluşlarından herhangi bir hibe almamıştır.

## 7. Çatışma Beyanı (Conflict Declaration)

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

## 8. Teşekkür (Acknowledgment)

Rijit dinamik simülasyonları için kullanılan Ansys®'in eğitsel amaçlı kullanım imkânını sağlayan Karadeniz Teknik Üniversitesi'ne, Dr. Mehmet Seyhan'a teşekkür ederim. Bu çalışmanın inceleme ve değerlendirme aşamasında yapmış oldukları değerli katkılardan dolayı editör, hakem ve emeği geçenlere içten teşekkür ederim.

## Kaynaklar (References)

Ahmed, A., Adnaik, I., Bhavsar, D., & Sargar, T. S. (2016). Design and Analysis of Gyro Wheel for Stabilization of a Bicycle. *International Journal for Scientific Research & Development*, 4(04), 349-351.

Amini, G., Salehi, F., & Rasouli, M. (2021). Drying kinetics of basil seed mucilage in an infrared dryer: Application of GA-ANN and ANFIS for the prediction of drying time and moisture ratio. *Journal of Food Processing and Preservation*, 45(3), e15258. doi: 10.1111/jfpp.15258

Amiroh, K., Rahmawati, D., & Wicaksono, A. Y. (2021). Intelligent System for Fall Prediction Based on Accelerometer and Gyroscope of Fatal Injury in Geriatric. *Jurnal Nasional Teknik Elektro*, 10(3). doi: 10.25077/jnte.v10n3.936.2021

Anonimouse. (2023). Precession *Wikipedia®*. en.wikipedia.org: Wikimedia Foundation, Inc.,.

Ansys®. (2023). Academic Research Mechanical Products, 2021 R2, Help System, ANSYS Mechanical User's Guide: ANSYS, Inc.

Beigi, M., & Torki, M. (2021). Experimental and ANN modeling study on microwave dried onion slices. *Heat and Mass Transfer*, 57, 787-796.

Çavuşlu, M. A., Becerikli, Y., & Karakuzu, C. (2012). Hardware implementation of neural network training with Levenberg-Marquardt algorithm. *TBV Journal of Computer Science and Engineering*, 5(1), 1-7.

Dash, S., & Venkatasubramanian, V. (2000). Challenges in the industrial applications of fault diagnostic systems. *Computers & Chemical Engineering*, 24(2-7), 785-791.

Dong, L., Wang, J., Tseng, M.-L., Yang, Z., Ma, B., & Li, L.-L. (2020). Gyro Motor State Evaluation and Prediction Using the Extended Hidden Markov Model. *Symmetry*, 12(11). doi:10.3390/sym12111750

Fan, Y., Ding, H., Li, M., & Li, J. (2018). Modal Analysis of a Thick-Disk Rotor with Interference Fit Using Finite Element Method. *Mathematical Problems in Engineering*, 2018, 5021245. doi: 10.1155/2018/5021245

He, Z., Wen, T., Zhang, X., Li, H., Chen, X., & Liu, X. (2022, 25-27 Nov. 2022). *Multi-physics Coupling and Thermal Network Analysis of MSCMG*. Paper presented at the 2022 China Automation Congress (CAC).

Heaton, J. (2008). *Introduction to Neural Networks with Java*: Heaton Research.

Heris, M. K. (2015). Time-series prediction using ANFIS. *The Yarpiz Project, Fuzzy Systems*.

HosseinTabari, Kisi, O., Ezani, A., & Talaei, P. H. (2012). SVM, ANFIS, regression and climate based models for reference evapotranspiration modeling using limited climatic data in a semi-arid highland environment. *Journal of Hydrology*, 444-445, 78-89. doi: 10.1016/j.jhydrol.2012.04.007

Huang, F., Wang, Z., Xing, L., & Gao, C. (2022). A MEMS IMU Gyroscope Calibration Method Based on Deep Learning. *Ieee Transactions on Instrumentation and Measurement*, 71, 1-9. doi: 10.1109/TIM.2022.3160538

- Ibrahim, M., Badran, K., & Esmat, A. (2023). Anomaly Detection for Agile Satellite Attitude Control System Using Hybrid Deep-Learning Technique. *Aiaa Journal*, <https://doi.org/10.2514/2511.I011280>. doi: 10.2514/1.I011280
- Jamil, F., & Kim, D. (2019). Improving Accuracy of the Alpha-Beta Filter Algorithm Using an ANN-Based Learning Mechanism in Indoor Navigation System. *Sensors*, *19*, 3946. doi: 10.3390/s19183946
- Kacar, İ., Eroğlu, M. A., & Yalçın, M. K. (2021). Design and development of an autonomous bicycle. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, *10*(1), 364-372. doi: 10.28948/ngumuh.628580
- Kathpalia, N., & Gulati, T. (2022). 3 Axis Gyro Accelerometer & Artificial Intelligence based Enhancement of GPS Accuracy. *Measurement: Sensors*, 100618. doi: <https://doi.org/10.1016/j.measen.2022.100618>
- Kostyuchenko, T., & Indygasheva, N. (2018). Computer-aided design system for control moment gyroscope. *MATEC Web Conf.*, *158*, 01021.
- Kownacki, C. (2011). Optimization approach to adapt Kalman filters for the real-time application of accelerometer and gyroscope signals' filtering. *Digital Signal Processing*, *21*(1), 131-140. doi: 10.1016/j.dsp.2010.09.001
- Masters, T. (1993). *Practical Neural Network Recipes in C++*. Elsevier Inc. : Academic Press.
- Montoya-Chairez, J., Santibanez, V., & Moreno-Valenzuela, J. (2019). Adaptive control schemes applied to a control moment gyroscope of 2 degrees of freedom. *Mechatronics*, *57*, 73-85. doi: 10.1016/j.mechatronics.2018.11.011
- Muthusamy, V., & Kumar, K. D. (2022). Failure prognosis and remaining useful life prediction of control moment gyroscopes onboard satellites. *Advances in Space Research*, *69*(1), 718-726. doi: <https://doi.org/10.1016/j.asr.2021.09.016>
- Nikkhah, A., Heydari, P., Khaloozadeh, H., & Heydari, A. (2009). Gyroscope Random Drift Modeling, Using Neural Networks, Fuzzy Neural and Traditional Time-Series Methods. 6.
- NI, C. (2023). Gyroscope physics. *Cleonis*, *1*(1), 1.
- Nuswanto, F. M., Sudarsono, A., & Santoso, T. B. (2020, 29-30 Sept. 2020). *Abnormal Driving Detection Based on Accelerometer and Gyroscope Sensor on Smartphone using Artificial Neural Network (ANN) Algorithm*. Paper presented at the 2020 International Electronics Symposium (IES).
- Öğündür, G. (2019). Overfitting, underfitting and bias-variance contradiction. Retrieved 12.12.2020, 2020, from <https://medium.com>
- Osman, M. O. M., Sankar, S., & Dukkipati, R. V. (1982). Design synthesis of a gyrogrinder using direct search optimization. *Mechanism and Machine Theory*, *17*(1), 33-45. doi: 10.1016/0094-114X(82)90022-2
- Pan, S., Xu, Z., & Zhao, C. (2019). A novel single-gimbal control moment gyroscope driven by an ultrasonic motor. *Advances in Mechanical Engineering*, *11*(4), 1687814019844382. doi: 10.1177/1687814019844382
- Papakonstantinou, C., Daramouskas, I., Lappas, V., Moulianitis, V. C., & Kostopoulos, V. (2022). A Machine Learning Approach for Global Steering Control Moment Gyroscope Clusters. *Aerospace*, *9*(3). doi:10.3390/aerospace9030164
- Rachmatullah, M. I. C., Santoso, J., & Surendro, K. (2020). A Novel Approach in Determining Neural Networks Architecture to Classify Data With Large Number of Attributes. *Ieee Access*, *8*, 204728-204743. doi: 10.1109/ACCESS.2020.3036853
- Sartori, M. A., & Antsaklis, P. J. (1991). A simple method to derive bounds on the size and to train multilayer neural networks. *IEEE Transactions on Neural Networks*, *2*(4), 467-471. doi: 10.1109/72.88168
- Shen, L., Zhu, Y., Liu, C., Wang, W., Liu, H., Kamruzzaman, . . . Zheng, X. (2020). Modelling of moving drying process and analysis of drying characteristics for germinated brown rice under continuous microwave drying. *Biosystems Engineering*, *195*, 64-88.
- Shi, H., Hu, S., & Zhang, J. (2019). LSTM based prediction algorithm and abnormal change detection for temperature in aerospace gyroscope shell. *International Journal of Intelligent Computing and Cybernetics*, *12*(2), 274-291. doi: 10.1108/IJICC-11-2018-0152
- Sucuoglu, H. S., Bogrekci, I., Gultekin, A., & Demircioglu, P. (2018). Design, Analysis and Development of Mobile Robot with Flip-Flop Motion Ability. *IFAC-PapersOnLine*, *51*(30), 436-440. doi: <https://doi.org/10.1016/j.ifacol.2018.11.323>
- Sun, J., Cai, Z., Sun, J., & Jin, D. (2023). Dynamic analysis of a rigid-flexible inflatable space structure coupled with control moment gyroscopes. *Nonlinear Dynamics*, *111*(9), 8061-8081. doi: 10.1007/s11071-023-08254-8
- Taheri, S., Brodie, G., & Gupta, D. (2021). Optimised ANN and SVR models for online prediction of moisture content and temperature of lentil seeds in a microwave fluidised bed dryer. *Computers and Electronics in Agriculture*, *182*, 106003. doi: 10.1016/j.compag.2021.106003
- Tamura, S., & Tateishi, M. (1997). Capabilities of a four-layered feedforward neural network: four layers versus three. *IEEE Transactions on Neural Networks*, *8*(2), 251-255. doi: 10.1109/72.557662
- Tobon-Mejia, D. A., Medjaher, K., Zerhouni, N., & Tripot, G. (2012). A Data-Driven Failure Prognostics Method Based on Mixture of Gaussians Hidden Markov Models. *IEEE Transactions on Reliability*, *61*(2), 491-503. doi: 10.1109/TR.2012.2194177

- Venkatasubramanian, V., Rengaswamy, R., Kavuri, S. N., & Yin, K. (2003). A review of process fault detection and diagnosis: Part III: Process history based methods. *Computers & Chemical Engineering*, 27(3), 327-346. doi: 10.1016/S0098-1354(02)00162-X
- Wang, J. W., Deng, Z. H., & Shen, K. (2022). Virtual Gyros Construction and Evaluation Method Based on BILSTM. *Ieee Transactions on Instrumentation and Measurement*, 71. doi: 10.1109/TIM.2022.3212544
- Wisesa, I., & Mahardika, G. (2019). Fall detection algorithm based on accelerometer and gyroscope sensor data using Recurrent Neural Networks. *IOP Conference Series: Earth and Environmental Science*, 258, 012035. doi: 10.1088/1755-1315/258/1/012035
- Xiu, T., Yue-dong, L., Xin-xiao, L., & Er-yong, H. (2021). Structural Engineering Analysis for a Control Moment Gyroscope Framework. *Journal of Physics: Conference Series*, 1939, 012119. doi: 10.1088/1742-6596/1939/1/012119
- Yang, P., Yang, C., Lanfranchi, V., & Ciravegna, F. (2022). Activity Graph Based Convolutional Neural Network for Human Activity Recognition Using Acceleration and Gyroscope Data. *IEEE Transactions on Industrial Informatics*, 18(10), 6619-6630. doi: 10.1109/TII.2022.3142315
- Yang, X., Wu, X., Yu, X., & Basin, M. V. (2023). Closed-Loop Subspace Predictive Control of Gyroscope. *Ieee Transactions on Industrial Electronics*, 1-10. doi: 10.1109/TIE.2023.3286008
- Zhou, Z.-J., & Hu, C.-H. (2008). An effective hybrid approach based on grey and ARMA for forecasting gyro drift. *Chaos, Solitons & Fractals*, 35(3), 525-529. doi: 10.1016/j.chaos.2006.05.039



# Halk Sağlığı Alanında Makine Öğrenimi Analizinin Kullanımı

Kübra Ecem Turgutkaya<sup>1\*</sup>, Emine Didem Evcı Kiraz<sup>2</sup>

<sup>1</sup> Aydın Adnan Menderes Üniversitesi, Tıp Fakültesi, Halk Sağlığı Anabilim Dalı, Aydın, Türkiye

<sup>2</sup> Aydın Adnan Menderes Üniversitesi, Tıp Fakültesi, Halk Sağlığı Anabilim Dalı, Aydın, Türkiye

kturgutkaya@adu.edu.tr, devci@adu.edu.tr

## Öz

Yaklaşık olarak son on yılda, büyük veri ve yüksek işlem gücündeki ilerlemelerle desteklenen yapay zeka teknolojisi, hızlı bir gelişme göstermiş ve çeşitli uygulama alanlarında olağanüstü bir evreye girmiştir. Makine öğrenimi (MÖ), veri kümelerini kullanarak otomatik olarak öğrenen ve doğru tahminler ve öngörüler elde etmek için insan tarafından denetlenen veya denetlenmeyen sistemler oluşturmak için geliştirilen gelişmiş istatistiksel ve olasılıksal tekniklere dayanmaktadır. Bu yazıda halk sağlığı alanında kullanılan MÖ uygulamalarını araştırmak amaçlanmıştır. Bu uygulamalar 5 başlık altında incelenecektir. Bunlar; sağlık hizmeti kaynaklarının optimizasyonu, surveilyans, salgın tespiti ve acil durum yönetimi, sağlık davranışı analizi ve müdahale, hastalık teşhisi ve prognozu son olarak ise kişiselleştirilmiş tıp. Yıllar içinde teknoloji ilerledikçe, MÖ bu alanlardaki uygulamaların entegrasyonu, sağlık hizmetlerinin planlanması, dönüştürülmesi ve toplum sağlığı sonuçlarının iyileştirilmesinde daha da önemli bir rol oynayacaktır.

**Anahtar kelimeler:** Makine öğrenimi, Halk sağlığı, Yapay zeka

## The Use of Machine Learning Analysis in Public Health

### Abstract

In the last decade, supported by advances in big data and high processing power, artificial intelligence technology has rapidly progressed and entered an extraordinary phase in various application areas. Machine Learning (ML) relies on advanced statistical and probabilistic techniques to create automated systems that learn from datasets and generate accurate predictions and forecasts, either supervised or unsupervised by humans. This article aims to explore ML applications in the field of public health, which can be categorized into five main areas: optimization of healthcare resources, surveillance, outbreak detection and emergency management, health behavior analysis and intervention, disease diagnosis and prognosis, and finally, personalized medicine. As technology continues to advance over the years, the integration of ML applications in these areas will play an even more significant role in healthcare planning, transformation, and improving community health outcomes.

**Keywords:** Machine learning, public health, artificial intelligence

Yaklaşık olarak son on yılda, büyük veri ve yüksek işlem gücündeki ilerlemelerle desteklenen yapay zeka teknolojisi, hızlı bir gelişme göstermiş ve çeşitli uygulama alanlarında olağanüstü bir evreye girmiştir (Zeng, Cao ve Neill, 2020). Yapay zekanın bir dalı olan makine öğrenimi (MÖ) ise veri örneklerinden öğrenme problemini genel çıkarım kavramıyla ilişkilendirmektedir (Mitchell, 2006; Azuaje, 2006). MÖ, veri kümelerini kullanarak otomatik olarak öğrenen ve doğru tahminler ve öngörüler elde etmek için insan tarafından denetlenen veya denetlenmeyen sistemler oluşturmak için geliştirilen gelişmiş istatistiksel ve olasılıksal tekniklere dayanmaktadır (Shatte, Hutchinson ve Teague, 2019).

Son yıllarda, sağlık ve halk sağlığı alanlarında MÖ tekniklerinin kullanımı, karar verme süreçlerinin geliştirilmesinde güçlü bir araç olarak ön plana çıkmıştır (Rodrigues, Madeiro ve Marques, 2023). MÖ algoritmalarının büyük veri setlerini analiz etme, kalıpları tanımlama ve bu verileri uygulanabilir öngörülere dönüştürme yeteneği, sağlık hizmeti sunumu ve halk sağlığı girişimlerinin çeşitli yönlerinde yeni gelişmelere yol açmıştır (Rodrigues, Madeiro ve Marques, 2023).

Bu yazıda halk sağlığı alanında kullanılan MÖ uygulamalarını araştırmak amaçlanmıştır. Bu uygulamalar 5 başlık altında incelenecektir.

\* Sorumlu yazar.  
E-posta adresi: kturgutkaya@adu.edu.tr

### 1. Sağlık Hizmeti Kaynaklarının Optimizasyonu:

MÖ modelleri, geçmiş verileri inceleyerek ve hastaların demografik özellikleri, hastalık sıklığı ve kaynakların erişilebilirliği gibi faktörleri göz önünde bulundurarak hastane yatak kapasitesini, personel atanmasını ve sağlık hizmeti tedarik zincirini optimize etmede yardımcı olabilir (Pereira ve Marques, 2022; Jamal, 2023). Bu yaklaşım, verimliliği artırır, maliyetleri düşürür ve hastaların zamanında ve uygun sağlık hizmetlerine erişimini geliştirir (Rodrigues, Madeiro ve Marques, 2023).

### 2. Sürveyans, Salgın Tespiti ve Acil Durum Yönetimi:

MÖ, çeşitli veri kaynaklarını analiz ederek, sosyal medya akışları, internet aramaları, elektronik sağlık kayıtları, çevresel ve bakteriyolojik veriler dahil olmak üzere halk sağlığı sürveyans sistemlerinde ve acil durum yönetiminde kritik bir rol oynar (Zeng, Cao ve Neill, 2020; Huang vd., 2022; Masum vd., 2022; Zhu vd., 2022).

### 3. Sağlık Davranışı Analizi ve Müdahale:

MÖ algoritmaları, büyük çaplı sağlık davranışı verilerini analiz ederek risk faktörlerini tanımlamak, toplum sağlığı trendlerini anlamak ve hedefe yönelik müdahale stratejileri geliştirmek için kullanılabilir (Rodrigues, Madeiro ve Marques, 2023; Adamson vd., 2023). MÖ modelleri, giyilebilir cihazlardan, mobil uygulamalardan ve sosyal medya platformlarından veri toplayarak, bireylerin davranışları, alışkanlıkları ve sağlık sonuçları hakkında bilgi elde edebilirler (Goh vd., 2022).

### 4. Hastalık Teşhisi ve Prognozu:

MÖ algoritmaları, hastaların tıbbi kayıtları, laboratuvar sonuçları ve radyolojik görüntülemeleri gibi verileri analiz ederek farklı hastalıkların teşhis ve prognoz süreçlerine katkı sağlayabilir (Rodrigues, Madeiro ve Marques, 2023; Chui vd., 2017; Barrera vd., 2023; Wang vd., 2023). Bu algoritmalar, büyük veri setleri üzerinde eğitilerek, kalıpları tanıma ve doğru tahminler yapma yeteneklerini geliştirirler, bu da sağlık profesyonellerinin tedavi planları ve müdahaleler konusunda bilinçli kararlar almasına yardımcı olabilir (Rodrigues, Madeiro ve Marques, 2023; Tao vd., 2023).

MÖ modelleri, kanser (Kourou vd., 2015; Pei vd., 2022; Callender vd., 2023; Salem vd., 2023; Lee vd., 2023), kardiyovasküler hastalıklar (Bhatt vd., 2023), nörolojik rahatsızlıklar (Rodrigues vd., 2021; Battineni vd., 2022; Parab, Boster ve Washington, 2023) ve bulaşıcı hastalıklar (Santangelo vd., 2023) gibi sağlık sorunlarının erken teşhisini ve zamanında müdahalesini desteklemek için umut verici sonuçlar elde etmiştir.

**5. Kişiselleştirilmiş Tıp:** MÖ teknikleri, kişinin özel verilerini kullanarak bireye özel tedavi stratejileri

geliştirmeyi kolaylaştırarak kişiselleştirilmiş tıbbi çözümleri destekler (Rodrigues, Madeiro ve Marques, 2023; Ahamed ve Farid, 2019). Bu algoritmalar, genetik, demografik bilgiler, yaşam tarzı ve tıbbi geçmiş gibi kişisel özellikleri göz önünde bulundurarak tedavi sonuçlarını tahmin etmeye ve en iyi müdahaleleri önermeye yardımcı olabilir (Sebastiani vd., 2022).

Sonuç olarak MÖ verilere dayalı karar almayı mümkün kılarak sağlık ve halk sağlığı alanlarında devrim yaratmıştır (Rodrigues, Madeiro ve Marques, 2023). MÖ kullanımı, halk sağlığı alanında hastalık teşhisi ve izleme, kişiselleştirilmiş tıp, epidemiyoloji ve sağlık politikalarının geliştirilmesinde önemli bir araç olarak öne çıkmaktadır. Ancak mevcut durumda bu alanda bazı yetersizlikler de söz konusudur. Özellikle, veri gizliliği ve etik sorunlar, bu teknolojinin sağlık sektöründe geniş çaplı benimsenmesini zorlaştırmaktadır. MÖ sistemlerinin geliştirilmesi ve uygulanması sırasında etik standartların oluşturulması, veri gizliliği sorunlarını hafifletmek adına önemli olabilir.

Yıllar içinde teknoloji ilerledikçe, MÖ sağlık hizmetlerinin planlanması, dönüştürülmesi ve toplum sağlığı sonuçlarının iyileştirilmesinde daha da önemli bir rol oynayacaktır (Rodrigues, Madeiro ve Marques, 2023). Ayrıca MÖ uygulamaları, geleceğin en büyük halk sağlığı sorunu olan iklim değişikliği için de bir çıkış yolu olarak görülebilir. Etkilenebilirlik ve risk analizlerinde, tüm sektörlerle ait iklim parametrelerinin sağlık parametreleriyle birlikte analiz edilmesinde, ekolojik araştırmalarda ve coğrafi bilgi sistemlerinin entegrasyonu gibi önemli alanlarda MÖ kullanılabilir. Ulusal düzeyde, sağlık sektöründeki paydaşlar arasında etkili bir iş birliği ve standartlaştırma çabasının artırılması, makine öğreniminin daha etkili bir şekilde entegre edilmesini destekleyebilir. Uluslararası düzeyde ise, MÖ uygulamalarının genel etkisini değerlendirmek ve en iyi uygulamaları paylaşmak amacıyla küresel bir platform oluşturmak, bu alandaki potansiyeli daha da genişletebilir.

Gelecekte, makine öğreniminin halk sağlığı alanındaki rolünün güçlendirilmesi için daha fazla araştırma ve eğitim kaynağına yatırım yapılması gerekebilir. Bu çabaların ulusal ve uluslararası düzeyde koordineli bir şekilde yürütülmesi, makine öğreniminin halk sağlığı alanındaki potansiyelini tam anlamıyla gerçekleştirmek için hayati bir öneme sahiptir. Bu şekilde, makine öğreniminin sağlık politikalarını daha etkili bir şekilde desteklemesi ve halk sağlığına yönelik önemli katkılarda bulunması sağlanabilir.

Ahamed, F., Farid, F., 2019. Applying internet of things and machine-learning for personalized healthcare: Issues and challenges. Proceedings - International Conference on Machine Learning and Data Engineering, 2018, pp. 22–29.

Azuaje, F., 2006. Witten IH, Frank E: Data mining: practical machine learning tools and techniques 2nd edition. BioMedical Engineering OnLine, 5(1), pp. 1–3.

## Kaynaklar (References)

Adamson, B. et al., 2023. Approach to machine learning for extraction of real-world data variables from electronic health records. *Frontiers in Pharmacology*, 14(September), pp. 1–12.



- Barrera, F.J. et al., 2023. Application of machine learning and artificial intelligence in the diagnosis and classification of polycystic ovarian syndrome: a systematic review. *Frontiers in Endocrinology*, 14(September), p. e1106625.
- Battineni, G. et al., 2022. Artificial intelligence models in the diagnosis of adult-onset dementia disorders: a review. *Bioengineering*, 9(8), pp. 1–15.
- Bhatt, C.M. et al., 2023. Effective heart disease prediction using machine learning techniques. *Algorithms*, 16(2), p. 88.
- Callender, T. et al., 2023. Assessing eligibility for lung cancer screening: parsimonious multi-country ensemble machine learning models for lung cancer prediction. *PLoS medicine*, 20(10), p. e1004287.
- Chui, K.T. et al., 2017. Disease diagnosis in smart healthcare: Innovation, technologies and applications. *Sustainability (Switzerland)*, 9(12), pp. 1–23.
- Goh, Y.S. et al., 2022. Machine learning in health promotion and behavioral change: scoping review. *Journal of Medical Internet Research*, 24(6), p. e35831.
- Huang, C. et al., 2022. Novel spatiotemporal feature extraction parallel deep neural network for forecasting confirmed cases of coronavirus disease 2019. *Socio-Economic Planning Sciences*, 80(January), p. e100976.
- Jamal, A., 2023. Effect of telemedicine use on medical spending and health care utilization: a machine learning approach. *AJPM Focus*, 2(3), p. e100127.
- Kourou, K. et al., 2015. Machine learning applications in cancer prognosis and prediction. *Computational and Structural Biotechnology Journal*, 13, pp. 8–17.
- Lee, M.S. et al., 2023. Transitional zone prostate cancer: performance of texture-based machine learning and image-based deep learning. *Medicine*, 102(39), p. e35039.
- Masum, M. et al., 2022. Comparative study of a mathematical epidemic model, statistical modeling, and deep learning for COVID-19 forecasting and management. *Socio-Economic Planning Sciences*, 80(January), p. e101249.
- Mitchell, T.M., 2006. The discipline of machine learning. *Machine Learning*, 17(July), pp. 1–7.
- Parab, S., Boster, J. and Washington, P., 2023. Parkinson disease recognition using a gamified website: machine learning development and usability study. *JMIR Formative Research*, 7, p. e49898.
- Pei, Q. et al., 2022. Artificial intelligence in clinical applications for lung cancer: diagnosis, treatment and prognosis. *Clinical Chemistry and Laboratory Medicine*, 60(12), pp. 1974–1983.
- Pereira, M.A. and Marques, R.C., 2022. Is sunshine regulation the new prescription to brighten up public hospitals in Portugal. *Socio-Economic Planning Sciences*, 84(January), p. e101219.
- Rodrigues, P.M. et al., 2021. Lacsogram: a new EEG tool to diagnose Alzheimer's Disease. *IEEE Journal of Biomedical and Health Informatics*, 25(9), pp. 3384–3395.
- Rodrigues, P.M., Madeiro, J.P. and Marques, J.A.L., 2023. Enhancing health and public health through machine learning: decision support for smarter choices. *Bioengineering*, 10(7), pp. 1–5.
- Salem, B.S. et al., 2023. Early breast cancer detection and differentiation tool based on tissue impedance characteristics and machine learning. *Frontiers in Artificial Intelligence*, 6, p. e1248977.
- Santangelo, O.E. et al., 2023. Machine learning and prediction of infectious diseases: a systematic review. *Machine Learning and Knowledge Extraction*, 5(1), pp. 175–198.
- Sebastiani, M. et al., 2022. Personalized medicine and machine learning: a roadmap for the future. *Journal of Clinical Medicine*, 11(14), pp. 20–24.
- Shatte, A.B.R., Hutchinson, D.M. and Teague, S.J., 2019. Machine learning in mental health: a scoping review of methods and applications. *Psychological Medicine*, 49(9), pp. 1426–1448.
- Tao, X. et al., 2023. Predicting three-month fasting blood glucose and glycated hemoglobin changes in patients with type 2 diabetes mellitus based on multiple machine learning algorithms. *Scientific Reports*, 13(1), p. e16437.
- Wang, H. et al., 2023. A machine learning-based PET/CT model for automatic diagnosis of early-stage lung cancer. *Frontiers in Oncology*, 13(September), pp. 1–10.
- Zeng, D., Cao, Z. and Neill, D.B., 2020. Artificial intelligence enabled public health surveillance from local detection to global epidemic monitoring and control. *Artificial Intelligence in Medicine*, 109, pp. 437–453.
- Zhu, L. et al., 2022. Can artificial intelligence enable the government to respond more effectively to major public health emergencies? Taking the prevention and control of Covid-19 in China as an example. *Socio-Economic Planning Sciences*, 80(January), p. e101029.



# Bir E-Ticaret Firmasındaki Son Adım Teslimat Probleminin Farklı Senaryolar Altında İncelenmesi

Fatma Duygu Yılmaz<sup>1</sup>, Harun Reşit Yazgan<sup>2</sup>, Serap Ercan Cömert<sup>3\*</sup>

<sup>1,2,3</sup> Sakarya Üniversitesi, Endüstri Mühendisliği Bölümü, Sakarya, Türkiye  
duyguyedekci@gmail.com, yazgan@sakarya.edu.tr, serape@sakarya.edu.tr

## Öz

COVID-19 salgınının getirdiği yaşam koşulları ile birlikte dünya ticaretine birçok olumsuz etkisine rağmen e-ticarette hızlı bir gelişmeye yol açmıştır. Talebe istinaden artan e-ticaret hacminin vazgeçilmez unsuru olan lojistik kısmı üzerine daha fazla çalışmalar ve yatırımlar yapılmaya başlanmıştır. Lojistik maliyetlerinin en büyük kısmını oluşturduğu iddia edilen son adım teslimatı üzerine yapılan çalışmalarla birlikte kısıtlı kaynaklarla yüksek miktardaki talebe cevap verirken maliyetlerin de kontrol altında tutulabilmesi için çeşitli lojistik modelleri ortaya çıktığı görülmüştür.

Bu çalışmada, mobilya sektöründe e-ticaret faaliyeti yürüten bir firmanın en uygun son adım teslimatı stratejisini belirleyebilmek için çeşitli lojistik modelleri üç farklı senaryo altında incelenmiştir. Senaryoları çözümlenebilmek için p-medyan problemi, kümeleme analizi ve yerel arama destekli Clarke ve Wright tasarruf algoritmasına dayanan hiyerarşik bir optimizasyon modeli önerilmiştir. Belirlenen üç senaryodan elde edilen sonuçlar firmanın mevcut durumu ile karşılaştırılıp son adım teslimatı maliyetini minimize edecek olan en uygun seçenek yönetime sunulmuştur.

**Anahtar kelimeler:** Son adım teslimat, Kümeleme analizi, Clarke ve Wright tasarruf algoritması, Yerel arama

## Examining the Last Mile Delivery Problem in an E-Commerce Company under Different Scenarios

### Abstract

Despite the living conditions brought by the COVID-19 epidemic and its many adverse effects on world trade, it has led to a rapid development in e-commerce. Based on demand, more studies and investments have begun to be made in logistics, which is an indispensable element of the increasing e-commerce volume. With the studies on last-mile delivery, which is claimed to constitute the most significant part of logistics costs, it has been observed that various logistics models have emerged to keep costs under control while responding to high demand with limited resources.

This study examined various logistics models under three different scenarios to determine the most appropriate last-mile delivery strategy for a company operating e-commerce in the furniture industry. A hierarchical optimization model based on the p-median problem, cluster analysis, and local search-supported Clarke and Wright savings algorithm is proposed to analyze the scenarios. The results obtained from the three determined scenarios were compared with the company's current situation, and the most suitable option that would minimize the last step's delivery cost was presented to the management.

**Keywords:** Last Mile Delivery, Clustering Analysis, Clarke and Wright Savings Algorithm, Local Search

## 1. Giriş (Introduction)

Teknolojinin hızlı ilerleyişi ve küreselleşmenin etkisi ile tüketicilerin alışkanlıkları ve buna bağlı olarak davranışları her geçen gün değişiklik

göstermektedir. Geleneksel alışveriş şekilleri yerlerini internet alışverişine bırakırken 2020 başlarında ülkemizde de görülmeye başlanan koronavirüs sebebiyle bu davranış değişikliği daha hızlı gelişme göstermiştir. Pandemi süresince alınan önlemler ile birlikte uzun zaman dilimleri boyunca uygulanan

\* Sorumlu yazar.  
E-posta adresi: serape@sakarya.edu.tr

Alındı : 14 Ocak 2024  
Revizyon : 1 Şubat 2024  
Kabul : 4 Mart 2024

sokağa çıkma yasakları insanların ihtiyaçlarını evden çıkmaya gerek duymadan internet üzerinden karşılamaya yönlendirmiştir. Bu durum hali hazırda başlamış olan alışveriş davranışı değişikliğini hızlandırmıştır. İnternet alışverişinin avantajlarından biri müşteriye istediği ürünün evden çıkmadan kendisine getirilmesidir. Müşterinin ürüne gittiği bir alışveriş modelinden ürünün müşteriye iletildiği bir alışveriş modeline olan değişim pandeminin de etkisiyle hızlanmıştır. Ürünün müşteriye iletilmesi hali hazırdaki lojistik süreçlerini daha da yoğun ve karmaşık hale getirmiştir.

Lojistik süreçlerinde ürünler birçok lojistik aracı üzerinden ve birçok dağıtım noktasından geçebilmekte ve birçok transfer noktasında kalabilmektedir. Lojistik süreçlerinde çeşitli taşımacılık yöntemleri ve araçları kullanılmaktadır. Her ne yöntem kullanılsa da lojistik sürecinin en son adımı son adım teslimatı olarak adlandırılmaktadır. Son adım teslimatı, lojistik süreçlerinin en son adımı olup müşteriye ürünün ulaştığı son lojistik adımdır. Son adım teslimatı dağıtım deposundan çıkan ürünün müşteriye teslim edildiği adım olabileceği gibi dağıtım deposundan müşterinin teslim alacağı teslimat noktasına yapılan lojistik adımı da olabilmektedir. Yapılan çalışmalar sonucunda lojistik maliyetleri incelendiğinde son adım teslimatının “tüm lojistik zincirinin en pahalı, en az verimli ve çevresel olarak incelendiğinde havayı en çok kirleten seçenek” olduğu kabul edilmektedir (Gevaers vd., 2011). Bu durumda son adım teslimatı konusu hem mali açıdan hem de çevresel açıdan büyük bir önem arz etmektedir.

Bu çalışmada yurtdışında faaliyet gösteren bir e-ticaret firmasının son adım teslimat problemi ele alınmıştır. Ele alınan problemde son adım teslimatta ortaya çıkan maliyetleri minimize etmek için üç farklı alternatif senaryo oluşturulup bu senaryolar üzerinden elde edilen maliyetler firmanın mevcut durumu ile karşılaştırılacaktır. Firmadaki mevcut son adım teslimatı bir lojistik firması tarafından kargo hizmet alınarak gerçekleştirilmektedir. Birinci senaryoda ise, p-medyan problemi çözümlerle bir depo yeri belirlenmiş, tüm müşteri teslimatları bu depodan sağlanacak şekilde rotalar oluşturulup son adım teslimatı yapılmıştır (rotalama). Senaryo 1 de, mevcut durumdan farklı olarak kiralanan depo sebebiyle personel istihdamı ve araç kiralama maliyetleri de toplam maliyete eklenmiştir. İkinci senaryoda pareto analizine göre sipariş büyüklüğü en fazla olan bölgelerin verileri kullanarak yeni depo yeri belirlenmiş (p-medyan) ve bu noktalara teslimat yapılması sağlanmış (rotalama), diğer bölgelere olan teslimatlar için kargo firması aracılığıyla teslimatlar planlanmıştır. Bu senaryoda da senaryo 1'deki gibi personel istihdamı ihtiyacı hâsıl olmuş olup araç kiralama maliyetiyle birlikte toplam maliyete eklenmiştir. Üçüncü senaryoda ise pareto analizi ile sipariş yoğunluğunu oluşturduğu görülen 1. ve 2. bölgedeki müşteriler kümeleme algoritması yardımıyla gruplanmıştır. P-medyan problemi

çözülerek kümelenen 5 müşteri bölgesi için 5 ayrı müşteri teslimat noktaları belirlenmiş, teslimatların bu noktalardan yapılması durumu dikkate alınmıştır. Katımlı teslimat modeline teşvik için müşterilere bir sonraki siparişlerinde kullanılmak üzere hediye çeki tanımlanmış ve bu maliyet de senaryo maliyetine eklenmiştir.

Son adım teslimatı aşamasında ortaya çıkan araç rotalama problemini (ARP) çözmek amacıyla literatürde birçok yöntem geliştirilmiştir. Bu yöntemler kesin çözüm yöntemleri ve sezgisel yöntemler olarak iki ana kategoride incelenmektedir. ARP, NP-zor problem sınıfına girdiği için problemin boyutu büyüdükçe problemin kesin çözüm yöntemleri kullanılarak çözümü zorlaşmakta hatta bazen imkansız hale gelmektedir. Bu nedenle, genellikle makul çözüm süresi içerisinde optimuma yakın çözümler sağlama potansiyeline sahip olan sezgisel yöntemler geliştirilmiştir (Lenstra ve Rinnooy Kan, 1981). Üç senaryoda da rotaların elde edilmesinde sezgisel yöntemlerden Clarke ve Wright tasarruf algoritması kullanılmıştır. Clarke ve Wright tasarruf algoritmasının anlaşılmasının kolay olması ve diğer çözüm yöntemleri içerisinde uygulanabilirliği açısından esnek bir yöntem olması sayesinde geliştirildiği yıldan günümüze gerek klasik gerekse çeşitli varyasyonları ile birçok çalışmada kullanılarak geçerli sonuçlar elde ettiği literatürde görülmektedir (Cipta ve Hasibuan, 2023; Pamosoaji vd., 2019; Hariati vd., 2021).

Çalışmanın ikinci bölümünde son adım teslimat problemi ile ilgili detaylı bilgi ile probleme yönelik literatür çalışmasına yer verilmiştir. Üçüncü bölümünde ele alınan son adım teslimat probleminde kullanılan çözüm metodolojisi anlatılmıştır. Dördüncü bölümde uygulama kısmına yer verilmiş önerilen senaryolar ayrı ayrı analiz edilmiş ve sonuç bölümünde ise çıkarımlar yapılarak gelecek çalışmalar için önerilerde bulunulmuştur.

## 2. Son Adım Teslimat Problemi (Last Mile Delivery Problem)

"Son adım" terimi, telekomünikasyon ağının son aşaması olarak telekomünikasyon alanında ortaya çıkmıştır (Lim vd., 2018). Tedarik zincirlerinde Lim vd. (2018) son adım teslimatını, sipariş girişi noktasından başlayarak müşterinin tercih ettiği teslimat yerine kadar uzanan, işletmeden tüketiciye (B2C) teslimat sürecinin son ayağı olarak tanımlamıştır. Teslimat yöntemleri eve teslimat, teslimat noktası ve hibrit model olmak üzere üç başlıkta incelenmektedir.

Eve teslimat yöntemi, dağıtıcının, ürünü dağıtım deposundan doğrudan müşterinin adresine teslim etmesidir. Bu teslimat yönteminde son adım teslimatı adımı dağıtım deposundan müşteri adresine olan kısımdır. E-ticaret perakendeciliğinde en çok tercih edilen bu yöntemde teslimat zamanında belirtilen adreste bulunmalı ve ürün müşteri tarafından teslim alınmalıdır (Sanders, 2020). Müşteriye konfor

sağlaması avantajının yanı sıra adreste bulunamayan müşterilerin teslimatlarının sağlanamaması durumunda tekrar edilen teslimatın getirdiği maliyet yükü de dezavantajdır. Eve teslimat yönteminde ürünler müşteri adreslerine zamanında teslim edilmelidir. Bu teslimat yönteminde araçların zaman, kapasite ve mesafe kısıtları olmakta ve bu kısıtların yönetimi için araç rotalama problemleri ortaya çıkmaktadır.

Teslimat noktaları teslim yönteminde satıcı ürünleri müşteriye önceden belirttiği adrese teslim eder, müşteri gerekli bilgileri teslimat noktasındaki kişiler ile paylaşarak ürününü teslim alır (Ratchford vd., 2023). Bu yöntemin avantajı müşteriye teslimatın kesin olarak gerçekleşmesini sağlayıp tekrarlı işlemleri ortadan kaldırarak lojistik maliyetlerinin artmasını önlemesidir. Ayrıca paketleri müşterilere teslim ederek son mil teslimatını da kısaltmaktadır. İki tür teslim alma noktası bulunmaktadır. Bunlar; katılımlı teslim alma noktaları ve otomatik paket dolapları yani genel ismiyle katılımsız teslim alma noktalarıdır (Morganti vd., 2014; Weltevreden, 2008). Katılımlı teslim alma noktaları aynı zamanda hizmet noktaları olarak da adlandırılır ve müşterinin ödeme yapmak, paketini almak veya iade etmek için gidebileceği mağazalar, benzin istasyonları veya postaneler olabilmekte ve genellikle mesai saatleri içerisinde haftanın altı günü açıktır (Weltevreden, 2008). Otomatik paket dolapları akıllı dolap bankaları veya otomatik paket istasyonları olarak adlandırılır ve müşterilerin paketlerini pin kodu veya akıllı telefon kullanarak aldıkları paket dolap istasyonlarıdır ve genellikle hafta boyunca 24 saat açıktır (Faugere ve Montreuil, 2017a; Weltevreden, 2008). UPS, DHL ve Amazon gibi şirketler Kuzey Amerika ve Avrupa'da otomatik paket dolapları kullandığından beri dünya çapında popülerlikleri artmıştır (Faugere ve Montreuil, 2017a).

Son adım teslimatı probleminin çözümü, Dantzig ve Ramser'in (1959) bir ARP olan kamyon sevkiyatı problemini ele aldığı 1959 yılına kadar uzanmaktadır. Kamyonların sevk istasyonlarına olan toplam seyahat mesafesini en aza indirmek için kamyonlara istasyon atama problemini çözmüşlerdir (Dantzig ve Ramser, 1959).

Deutsch ve Golany (2018), otomatik teslimat dolaplarının yerlerinin belirlenmesi problemini ele almıştır. Çalışmada, problemin çözümü için ise 0-1 tamsayı bir matematiksel model önerilmiştir. Geliştirdikleri modelde gelir ile maliyetler arasındaki fark yani kar maksimize edilmeye amaçlanmıştır. Maliyetler arasında teslimat dolaplarının kurulumu, operasyonel maliyetler ve otomatik dolapların kullanımından kaynaklanan potansiyel müşteri kaybı yer almaktadır.

Eş Yürek (2018) yaptığı çalışmada kamyon ve insansız hava aracının eş zamanlı dağıtım problemini çalışmıştır. İlk olarak 2-aşamalı yinelemeli bir çözüm yaklaşımı geliştirdiğini, böylece aynı süre içinde dağıtım yapılabilecek müşteri sayısının %30 artabileceğini iddia etmiştir. İkinci olarak ise, orta ve

büyük boyutlu problemlerin çözümü için melez bir genetik algoritma (MGA) geliştirmiş, bundan elde edilen sonucun önceki yöntemden daha iyi sonuç ürettiği ama çözüm zamanı açısından daha kötü olduğunu rapor etmiştir.

Charisis ve Kaiser (2019), son adım teslimatı için bir hizmet noktaları ağı tasarlayarak, çoğunlukla paket sevkiyatları olmak üzere kargo teslimatı için alternatif bir yöntem önermiştir. Ortaya çıkan kapasiteli tesis yer seçimi problemi için çok amaçlı bir matematiksel model formüle etmişlerdir. Modeldeki ilk amaç ağdaki toplam maliyetlerin en aza indirilmesidir. Toplam maliyetler; her aday tesisin kullanımına ilişkin sabit maliyetler ve kargonun seçilen tesislere taşınmasına ilişkin maliyetler olmak üzere iki bileşenden oluşmaktadır. İkinci amaç ise seçilen tesislerden maksimum düzeyde faydalanılmasıdır. Son olarak, modelde yer alan önemli bir amaç, seçilen tesisler ile hedef düğümler arasındaki mesafelerin en aza indirilmesi, hedeflere yakın ve kolay erişilebilir konumların çıktı olarak sağlanmasıdır.

Janjevic vd. (2019) çalışmalarında toplama ve teslimat noktalarını çok kademeli dağıtım ağlarının tasarımına entegre etmek için bir yöntem önermiştir. Dağıtım ve toplama noktalarının konum kararlarını dikkate alan doğrusal olmayan bir matematiksel model geliştirmişlerdir. Çalışmada büyük boyutlu problemlerin çözümü için ise sezgisel bir yöntem önerilmiştir.

Karaoğlu (2019) yaptığı çalışmada ARP için yeni bir doğrusal matematiksel model geliştirdiğini, büyük boyutlu problemler için ise iki aşamadan oluşan yeni bir sezgisel algoritma geliştirdiğini, yöntemlerini örnek veri seti üzerinde sınamalar yapmıştır. Elde ettiği sonuçlara göre, geliştirdiği yöntemin en yakın komşuluk yöntemine göre %9 oranda daha iyi sonuçlar elde ettiğini belirtmektedir.

Orenstein vd. (2019), otomatik teslimat dolaplarının yerlerinin belirlenmesi problemini ele almıştır. Çalışmada, araçların seyahat maliyetleri, teslim edilmeyen paketlere ilişkin cezalar ve kullanılan her araç için sabit maliyetlerin toplamı olmak üzere toplam maliyeti en aza indirecek matematiksel model geliştirilmiştir. Problemin çözümü için ise tasarruf sezgiseli, petal sezgiseli ve geniş komşuluk aramalı tabu arama yöntemine dayanan bir çözüm yöntemi önerilmiştir.

Guerrero- Lorente vd. (2020) ise dağıtım merkezlerini, ara depoları ve otomatik teslimat dolaplarını konumlandırarak çok kademeli konumlandırma problemini ele almıştır. Problemin çözümü için önerdikleri modelde kapıdan teslimatı seçen müşterilere paketleri teslim edememenin maliyetlerini dikkate alınmıştır. Buna ek olarak, paketlerini iade etmeyi seçen müşterilerden paket toplama maliyetleri de dahil edilmiştir.

Kedia vd. (2020) ise çalışmasında şehir demografisi, nüfus sayısı ve potansiyel tesis konumları arasındaki seyahat mesafelerini dikkate alarak en az

sayıda otomatik paket dolaplarının en uygun yerlere kurulması problemini ele almıştır. Christchurch şehrinde örnek bir uygulama sunmuştur.

Lin vd. (2020)'de çalışmasında Kedia vd. (2020)'nin çalışmasında olduğu gibi otomatik paket dolaplarının en uygun konumlarının belirlenmesi üzerine çalışmıştır. Singapur'da örnek bir uygulama yaparak müşterilerin hizmet seviyesini en üst düzeye çıkarmayı düşünmüştür.

Nurcan (2020) çalışmasında üç farklı senaryoyu çalışmıştır. Senaryoları değerlendirirken performans kriteri olarak maliyet ve müşteri bekleme sürelerini dikkate almıştır. Yaptığı çalışmada zaman pencereli simetrik kapalı uçlu çok amaçlı ve çok seferli bir problemi tam sayılı programlama olarak modellemiş ve sonucunda maliyetlerde %32 oranda iyileşme sağlandığını iddia etmiştir.

Schwerdfeger ve Boysen (2020) çalışmalarında gün içinde yerlerini otonom olarak veya bir insan sürücü tarafından hareket ettirilerek değiştirebilen mobil otomatik teslimat dolaplarının konumlarının optimize edilmesi üzerine odaklanmıştır. Mobil teslimat dolapları gün içinde esnek bir şekilde konumlarını değiştirebilir, bu da konumları değişen müşteriler için erişilebilirliği artırır. Böylece müşteri memnuniyetini arttırmak amaçlanmaktadır.

Johnson ve Chaniotakis (2021) yaptığı çalışmada Washington D.C. kentsel ortamında son adım teslimatı kaynaklı çevresel kirliliği azaltmak amacıyla K-means yöntemi kullanarak en uygun teslimat noktası konumlarının belirlendiğini, teslimat içinde, E-kargo bisikletleri ile tamamladıklarını ifade etmişlerdir.

Liu vd. (2021)'de Guerrero-Lorente vd. (2020)'nin çalışmasında olduğu gibi çok modlu dağıtım beklentilerini karşılamak için, dağıtım merkezlerini, ara depoları ve otomatik teslimat dolaplarını konumlandırarak iki kademeli bir dağıtım sistemi üzerinde çalışmıştır. Çok modlu son adım teslimat sistemini iki aşamalı konum yönlendirme problemi olarak formüle etmiş ve çok amaçlı matematiksel model geliştirmiştir. Çalışmada, problemin çözümü için ise sezgisel bir algoritma önerilmiştir.

Tezkoşar (2022), son adım teslimatında kullanılan araçların motor düzeneklerinde kural tabanlı sistem tasarımı yerine derin öğrenme algoritmaları kullanarak kullanıcının kullanma şekline dayalı hangi çalışma şartlarında elektrikle, hibrit ya da yalnızca içten yanmalı motorun kullanılacağına karar verecek şekilde yapılabilecek olan düzenlemelerin karbon ayak izine etkisi üzerine çalışmıştır.

Bu çalışmada son adım teslimatı yöntemlerinden eve teslimat yöntemi ve teslimat noktaları yöntemleri dikkate alınarak farklı senaryolarda en doğru teslimat seçeneği belirlenmeye çalışılmıştır. Teslimat noktalarının yerleri zaman ve maliyet açısından müşteri adres noktalarına en uygun şekilde belirlenmelidir. Hem dağıtım noktaları (depo yerleri) hem de teslimat yöntemlerinin belirlenmesinde ileride detayları verilecek kümeleme yöntemi kullanılmıştır. Dağıtım

noktaları da belirlendikten sonra araç rotalama planlanması yapılarak dağıtım yöntemlerine göre en kısa sürede ve en az maliyetle dağıtımın sağlanabilmesi amaçlanmıştır.

### 3. Materyal ve Yöntem (Material and Method)

Bu çalışmada önerilen senaryoların çözümü için hiyerarşik bir optimizasyon modeli önerilmiştir. Önerilen model ve senaryolarda kullanılan adımları aşağıdaki tabloda özetlenmiştir.

**Tablo 1.** Hiyerarşik çözüm modeli (Hierarchical solution model)

Aşamalar	Senaryolar		
	1	2	3
Aşama 1: Kümeleme analizi ➤ <i>K-means algoritması</i>			✓.
Aşama 2: P-medyan problemi	✓.	✓.	✓.
Aşama 3: Araç rotalama problemi ➤ <i>Yerel arama destekli clarke-wright tasarruf algoritması</i>	✓.	✓.	✓.

#### 3.1. Kümeleme Analizi (Clustering analysis)

Kümeleme analizi, bir veri kümesinin farklılıklar içerip içermediğini belirlemek ve bu grupları benzerliklerine göre gruplamak için kullanılan istatistiksel bir metottür. Verilerin gruplanması ve tanımlanmasında sıkça kullanılan kümeleme analizi, homojen ya da heterojen gruplardaki verileri uygun yöntemlerle gruplamayı sağlamaya yardımcı olan bir yöntemdir (Romesburg, 2004).

Kümeleme analizinde benzerlik en önemli kavramdır. Analiz esnasında ele alınan tüm yöntemler benzerlik ölçütüne dayanır. Veriler arası benzerliklerin ölçülmesinde farklı yollar bulunmaktadır. Benzerliği ölçmenin en önemli yolları uzaklık ölçüleri ve korelasyona dayalı ölçülerdir (Karaoğlu, 2018).

Kümeleme analizi için birçok algoritma önerilmiştir; ancak, literatürde bu algoritmalar genellikle iki ana kategori altında toplanmıştır. Bunlar, hiyerarşik kümeleme teknikleri ve hiyerarşik olmayan kümeleme teknikleridir. Her iki teknik de kümeler arasındaki farklılıkları belirlemeyi ve kümeler içindeki benzerlikleri en üst düzeye çıkarmayı amaçlar. Hangi tekniğin tercih edileceği, genellikle kullanılacak küme sayısı ile ilişkilidir (Grabmeier ve Rudolph, 2002). Bu çalışmada hiyerarşik olmayan kümeleme yöntemlerinden K-means algoritması kullanılmıştır.

- K-Means Algoritması

K-means, 1967'de J.B. MacQueen tarafından geliştirilmiştir (MacQueen, 1967). Bu algoritmanın atama mekanizması, her verinin sadece bir küme içinde yer almasına olanak tanıyan en yaygın kullanılan

denetimsiz öğrenme yöntemlerinden biridir. Temel fikir, bu yöntemde merkezi noktanın bir küme temsil etmesidir (Han ve Kamber, 2001). K-Means kümeleme algoritmasını değerlendirmek için en sık kullanılan kriterlerden biri Hata Kareler Toplamı (SSE) kriteridir. En düşük SSE değerine sahip kümeleme sonuçları, en iyi sonuçları sağlamaktadır. Nesnelerin küme merkezine olan uzaklıklarının karelerinin toplamı (1) nolu denklem ile hesaplanmaktadır (Tan et al., 2006).

$$SSE = \sum_{i=1}^K \sum_{x \in C_i} |x - m_i|^2 \quad (1)$$

Burada  $C_i$   $i$ . kümedeki veri noktaları kümesini,  $x$   $C_i$  kümesinde bulunan bir nesneyi ve  $m_i$  ise  $C_i$  kümesinin merkez noktasını temsil etmektedir.

Algoritma, hata karelerinin toplamını azaltacak k adet grubu tespit etmeye çalışır. K-Means algoritması, kullanıcı tarafından belirlenen k parametresi ile n veriden oluşan veri kümesini k adet kümeye ayırır. Küme benzerliği, kümenin ağırlık merkezi olan kümedeki nesnelerin ortalaması ile ölçülmektedir (Xu ve Wunsch, 2005). K-Means algoritmasının adımları aşağıdaki şekilde özetlenebilir.

Adım 1: Küme Sayısını (k) belirle.

Adım 2: Küme sayısı (k) kadar merkez noktası belirle.

Adım 3: Her veriyi en yakın merkez noktaya atayarak kümeye dahil et.

Adım 4: Her kümenin yeni merkez noktasını, o kümeye ait veri noktalarının ortalaması olarak hesapla.

Adım 5: Yeni merkez noktaları hesaplandıktan sonra, durdurma kriteri (örneğin, merkez noktalarının değişim miktarının belirli bir eşik değer altına düşmesi) sağlanana kadar adım 3 ve 4' ü tekrar et.

### 3.2. P-Medyan problemi (P-Median problem)

P-medyan problemi ilk kez 1964 yılında Hakimi tarafından yer seçim problemleri kapsamında bir optimizasyon problemi olarak literatüre kazandırılmıştır. P-medyan problemi, n talep konumundan p tesis konumunun seçilmesi ve talep noktaları ile ilgili tesisler arasındaki talep ağırlıklı ortalama mesafenin en aza indirileceği şekilde talep noktalarının bu tesis konumlarına tahsis edilmesi olarak tanımlanmaktadır (Hakimi, 1964).

P-medyan probleminde, tesisler yalnızca ağdaki düğümler üzerinde konumlandırılabilirler. Bu durum, tesislerin ağıın herhangi bir noktasına yerleştirilmesine izin veren sürekli bir modelden elde edilen çözümlerin daha az etkili olabileceği izlenimini uyandırabilir. Ancak, Hakimi (1965), p-medyan probleminde açılacak tesislerin ağdaki düğümlere yerleştirildiğinde en az bir optimal sonucun bulunduğunu ispatlamıştır. Bu özellikten hareketle n düğümden ve açılacak p tesisden oluşan bir problemin potansiyel çözüm sayısı aşağıdaki (2) nolu denklem ile gösterilebilir.

$$\binom{n}{p} = \frac{n!}{p!(n-p)!} \quad (2)$$

P-medyan probleminin matematiksel modelinin parametreleri ve karar değişkenleri Tablo 2'de özetlenmiştir.

**Tablo 2.** Matematiksel modelinin parametreleri ve karar değişkenleri (Parameters and decision variables of the mathematical model)

Notasyonlar	
$n$	Toplam talep noktası sayısı
$i$	Müşteriler, $i \in \{1, 2, 3 \dots n\}$
$j$	Aday depo (veya teslimat noktası) yerleri, $j \in \{1, 2, 3 \dots n\}$
$p$	Açılması düşünülen depo (veya teslimat noktası) sayısı
Parametreler	
$w_i$	$i$ . müşterinin talebi
$d_{ij}$	$i$ . müşterinin $j$ . depoya (veya teslimat noktası) olan uzaklığı
Karar değişkenleri	
$y_{ij}$	Eğer $i$ müşterisi $j$ depoya (veya teslimat noktası) atanırsa 1, aksi halde 0
$x_j$	Eğer $j$ . noktada depo (veya teslimat noktası) açılmışsa 1, aksi halde 0

P-medyan modelinin amaç fonksiyonu ve kısıt denklemleri şöyledir (ReVelle ve Swain, 1970):

$$\text{Enaz} = \sum_{i=1}^n \sum_{j=1}^n w_i y_{ij} d_{ij} \quad (3)$$

$$\sum_{j=1}^n y_{ij} = 1 \quad \forall i \quad (4)$$

$$\sum_{j=1}^n x_j = p \quad (5)$$

$$y_{ij} \leq x_j \quad \forall i, j \quad (6)$$

$$x_j \in \{0, 1\} \quad \forall j \quad (7)$$

$$y_{ij} \in \{0, 1\} \quad \forall i, j \quad (8)$$

(3) nolu denklem yani amaç fonksiyonu, j depo (veya teslimat noktası) ile i müşterisi arasındaki mesafelerin talep ( $w_i$ ) ağırlıklı toplamını en aza indirmeyi hedeflemektedir. (4) nolu denklem her bir talep noktasının (müşterinin) yalnızca tek bir depoya (veya teslimat noktası) atanmasını sağlar. (5) nolu denklem açılacak olan deponun (veya teslimat noktası) p adet olmasını sağlamaktadır. (6) nolu denklem'de açık olan depolara (veya teslimat noktası) talep noktalarının atanmasını ifade etmektedir. (7) ve (8) nolu denklemler ise karar değişkenlerinin 0 veya 1 tam sayı değerlerini alması gerektiğini ifade etmektedir.

### 3.3. Araç rotalama problemi (Vehicle routing problem)

Araç Rotalama Problemi (ARP), bir işletmenin bir veya birkaç deposundan, her birinin farklı bir konumda yer aldığı belirli sayıda müşterisine hizmet verirken seyahat mesafesini veya süresini en aza indirmeyi hedeflediği bir optimizasyon problemidir (Toth ve Vigo, 2002a).

ARP, ilk kez 1959'da Dantzig ve Ramser tarafından literatüre kazandırılmıştır. Bu çalışmada yazarlar, benzin istasyonlarına benzin dağıtım problemlerine odaklanarak çözümlü içinde matematiksel programlama modelini oluşturmuşlardır. Clarke ve Wright ise 1964'te probleme sezgisel bir çözüm yöntemi önermiş, bu çalışma sonrasında ARP'ye olan ilgi daha da artmış ve birçok optimizasyon yöntemi geliştirilmiştir (Toth ve Vigo, 2002b).

En genel haliyle ARP'de, bir araç filosu için minimum maliyetli rota kümesi tasarlanır. Her rota, bir depodan başlar, bilinen müşteri kümesine hizmet ettikten sonra yine aynı depoda sona erer. Her müşteri bir araca atanmalı ve araca atanmış müşterilerin toplam talebi, o aracın kapasitesini aşmamalıdır. Araç kapasiteleri, tüm müşteri taleplerinin en büyüğünden daha büyük olduğu varsayılarak her bir araca bir veya birden fazla müşteri atanabilmektedir (Aydemir, 2006). ARP'ler sahip oldukları kısıtlara göre çeşitleri bulunmaktadır. Bunlara; kapasite kısıtlı araç rotalama problemi, zaman pencere kısıtlı araç rotalama problemi, zaman kısıtlı araç rotalama problemi ve çok depolu araç rotalama problemi örnek verilebilir.

Literatürde ARP'leri çözmek amacıyla birçok yöntem geliştirilmiştir. Bu yöntemler kesin çözüm yöntemleri ve sezgisel yöntemler olarak ikiye ayrılmaktadır. Kesin çözüm yöntemlerine, dal ve sınır, dal ve kesme, kesme düzlemi ve dinamik programlama örnek gösterilebilir. ARP NP-zor problem sınıfına girdiği için problemin boyutu büyüdükçe problemin kesin çözüm yöntemleri ile çözümü zorlaşmakta hatta bazen imkansız olmaktadır. Sezgisel yöntemler ise, problemlere yaklaşık çözümler bulma amacı güder ve genellikle hızlı bir çözüm elde etme avantajına sahiptir (Toth ve Vigo, 2002b). Bu çalışmada sezgisel yöntemlerden Clarke ve Wright tasarruf algoritması kullanılmıştır. Clarke ve Wright tasarruf algoritmasının elde ettiği sonuçları iyileştirmek için yerel arama yöntemleriyle desteklenmiştir.

#### • Clarke ve Wright tasarruf algoritması

1964 yılında, Clarke ve Wright tarafından geliştirilen Clarke ve Wright tasarruf algoritması çözüm hızı, esnekliği, çeşitli operasyonel kısıtları ele alma yeteneği ve optimuma yakın çözümler üretme yeteneği nedeniyle yaygınlaşmıştır (Ballou, 1992, Clarke ve Wright, 1964). Algoritmada amaç, tüm araçlar tarafından kat edilen toplam mesafeyi en aza indirmek ve dolaylı olarak seyahat esnasında gereken araç sayısını da en aza indirmektir.


Clarke ve Wright tasarruf algoritması, depoya geri dönmek yerine aynı yol üzerinde iki durak dâhil ederek tasarrufları hesaplamaya çalışır ve her durak için tasarrufları değerlendirir (Clarke ve Wright, 1964). En büyük tasarruflar daha sonra aynı rotada birleştirilir ve bu süreç belirli kısıtlar ihlal edilene veya iyileştirici bir çözüm bulunmayana kadar devam eder (Ballou, 1992). Ballou (1992), çalışmasında kısıt sayısının az olduğu küçük boyutlu problemlerde Clarke ve Wright algoritmasının ortalama çözümlerinin optimal çözümden sadece % 2 oranında saptığını göstermiştir.

Algoritma, depo ile her bir müşteri arasında bir gidiş-geliş rotası olmak üzere  $n$  adet uygulanabilir rota ile başlar. Belirli bir iterasyonda, iki rota  $(0, \dots, i, \dots, 0)$  ve  $(0, \dots, j, \dots, 0)$ , ortaya çıkan rota  $(0, \dots, i, j, \dots, 0)$  kapasite kısıtı açısından uygunsa birleştirilebilir. Bu rotalar birleştirilirse,  $s_{ij}=c_{i0}+c_{0j}-c_{ij}$  kadar bir tasarruf sağlanır.

#### • Yerel arama

Yerel arama, optimizasyon problemlerini deneysel başarı ile birleştiren birkaç genel yaklaşımdan biridir. Yerel aramanın arkasındaki temel fikir arama uzayında belirli bir nokta etrafında çözümler aramaktır. Aday bir çözümle başlayan ardından yinelemeli olarak bu noktadan, optimize edilmekte olan amacın iyileştirildiği bir komşu çözüme geçer. Yerel arama yöntemlerinde komşuluk yapısı çözüm hızının ve kalitesinin ana belirleyicisidir (Johnson ve ark, 1988). Komşuluk çözümleri oluşturmak için kullanılan yerel arama operatörlerine örnek olarak; ters çevirme, yer değiştirme, ekleme, 2-Opt ve 3-Opt verilebilir (Cömert, 2023). Bu çalışmada yerel arama operatörlerinden 2-Opt kullanılmıştır.

2-Opt; Croes (1958) tarafından gezgin satıcı problemini çözmek için önerilmiştir. Turdan iki yolu kaldırır ve oluşan iki yeni alt turu yeniden birleştirir. Bu bağlantı işlemi sadece yeni tur daha kısa ise tekrarlanır. Şekil 1'deki gibi [C1-C2] ve [C4-C5] müşterileri arasındaki mesafenin toplamının [C1-C4] ve [C2-C5] müşterileri arasındaki mesafenin toplamından büyük olduğunu varsayalım. C2 ve C4 müşterilerinin pozisyonlarını değiştirerek gerçekleştirilir (Cömert, 2023).



Şekil 1. 2-opt yönteminin işleyişinin gösterimi (Demonstration of 2-opt method)

#### 4. Uygulama (Application)

Bu çalışmada yurtdışında faaliyet gösteren bir e-ticaret firmasının en uygun son adım teslimat stratejisini belirlemek için üç farklı senaryo oluşturulmuştur. Senaryolardan elde edilen son adım teslimat maliyetlerinin firmanın mevcut durumu ile karşılaştırılması ve en uygun senaryonun seçilmesi amaçlanmaktadır.

E-ticaret firmasının faaliyet gösterdiği ülkede yerel bir lojistik firması ile depolama ve teslimat anlaşması

mevcuttur. Lojistik firması, kendi depo yerinde e-ticaret firmasının stoklarını tutmakta ve yine lojistik firmasının araçlarıyla müşterilere teslimatları sağlamaktadır. E-ticaret firması ve lojistik firması arasında hizmet sözleşmesi bulunmaktadır. Firma, depolama hizmeti için aylık 750 € hizmet bedeli ödemektedir. Lojistik firması faaliyet yürütülen ülkeyi altı ana bölgede gruplamıştır. Lojistik firması teslimat fiyatlandırması bölge ve ağırlıklara göre Tablo 3'te gösterilmiştir.

**Tablo 3.** Bölge ve ağırlığa göre taşıma maliyetleri (€) (Transport costs by region and weight)

Bölgeler	0-3 kg	3-7 kg	7-25 kg	25-50 kg	50-75 kg	75-100 kg
1	4,9	5,6	8,8	13,8	15,9	18,2
2	5,3	6,0	13,2	16,1	18,5	21,0
3	5,8	6,6	14,4	16,5	18,9	21,5
4	6,0	6,8	15,0	19,7	22,5	25,4
5	6,6	7,5	18,3	23,7	27,0	30,4
6	6,8	7,7	19,0	24,6	27,9	31,4

Mevcut durumda e-ticaret firması teslimatlarını Tablo 3'teki fiyatlara göre sağlamaktadır. Bölge 1 şehir merkezinde olup ürünün ağırlığı arttıkça taşıma maliyeti artmaktadır. Aynı zamanda şehir merkezinden uzaklaştıkça da taşıma maliyeti artmaktadır. 2019-2020-2021 yılında verilen siparişlerin müşteri adreslerine yapılan teslimatının mevcut durumdaki firmaya toplam maliyeti 23.065,605 €'dur. Firmanın mevcut durumdaki toplam maliyeti 50.065,61 € olup Tablo 4'te ayrıntılı olarak gösterilmiştir.

**Tablo 4.** Mevcut durumdaki maliyet kalemleri (Cost items in current situation)

Depolama Süresi (ay)	36
Depolama Bedeli (aylık)	750,00 €
Toplam Depolama Maliyeti	27.000,00 €
Son Adım Teslimatı Maliyeti	23.065,61 €
Mevcut Durumda Toplam Maliyeti	50.065,61 €

Depolama süresi veri kümesindeki siparişlerin tarih verileri baz alındığında 36 ay olarak belirlenmiştir. Lojistik firmasından aylık alınan depolama hizmeti bedeli 750,00 € üzerinden hesaplandığında veri kümesini oluşturan zaman dilimi için toplam maliyet 27.000,00 € olarak hesaplanmıştır. Depo, araç kiralama ve personel istihdam maliyetleri olmadığından toplam maliyet depolama maliyeti ve dağıtım maliyetinden oluşmaktadır.

#### 4.1. Senaryo 1 (Scenario 1)

Firma, birinci senaryoda 2.267 adet müşteri verisini kullanarak p-medyan algoritması yardımıyla açılması planlanan depo yeri koordinatlarını X eksenini için 44.6913173483826, Y eksenini için 20.5002660375264 olarak belirlemiştir. Belirlenen koordinatlarda bulunan depo yerlerinin ortalama kirası ülkenin online emlak satış - kiralama sitesi emsal verileri referans alınarak ortalama 210 €/ay olarak belirlenmiştir. Depoda faaliyet göstermek üzere depolama ve dağıtım görevi için 1 çalışan istihdam edilmesi planlanmıştır. Asgari ücret miktarı seçilen dönemdeki üç yılın ortalaması olarak 350€ olarak alınmıştır.

Firma dağıtım işlemi için 1 adet 3500 kg taşıma kapasiteli kamyonet tipi teslimat aracı kiralamayı planlamıştır. Ülkenin online araç satış-kiralama sitesi verileri referans alınarak ortalama 150 €/ay olarak belirlenmiştir. Faaliyet gösterilen ülkeye ait yakıt ücreti GlobalPetrolPrices sitesi verileri referans alınarak ortalama 1.748 €/lt kabul edilmiştir. Araç yakıt tüketimi 100 mil için 24 lt kabul edilmiştir.

Firma, koordinatları belirtilen depo yerinden haftalık olarak rota planlamaktadır. Alınan siparişler analiz edildiğinde 150 adet rota planlaması yapılması gerekmektedir. Teslimatların haftalık yapılması planlandığı için ilk haftaya ait müşteri lokasyon verileri ve 1. haftaya ait müşteri koordinat verileri Tablo 4'te gösterilmiştir.

**Tablo 4.** Senaryo 1 için birinci rotaya ait müşteri ve sipariş verileri (Customer and order data for the first route of scenario 1)

Müşteri	X	Y	Sipariş Tarihi
M1	43.34721361	20.61021912	2.01.2019
M2	44.27618337	20.74534037	3.01.2019
M3	45.92635677	20.05851377	3.01.2019
M4	44.70744124	20.47597179	5.01.2019
M5	44.73368841	20.32377310	7.01.2019
M6	44.84258357	20.38425464	8.01.2019



Birinci teslimata ait siparişlerin koordinatları belirlenen depo yerinden teslimatı için araç rotalama optimizasyonu yapılmış ve dağıtılması gereken rota Tablo 5'te gösterilmiştir.

**Tablo 5.** Senaryo 1 için birinci rotaya ait veriler (Data for the first route of scenario 1)

Durak	Sipariş Sayısı	Mesafe (Mil)
1	0	0,03
5	1	0,16
7	1	1,13
4	1	1,22
6	1	1,42
2	1	0,94
3	1	0,48
<b>Toplam</b>	<b>6</b>	<b>5,38</b>

Tablo 5'te görülmektedir ki dağıtım deposu 1.durak olarak isimlendirilmiştir. Dağıtım deposu 1 ile

başladığı için diğer müşterilerin sırlaması da 1 er artmıştır. Dağıtım deposundan ilk dağıtımın 4. müşteriye yapılması planlanmış olup toplam mesafe 0.03 mil olarak hesaplanmıştır. Ardından yapılan teslimatların mesafeleri sırasıyla 0.16, 1.13, 1.22, 1.42, 0.94 olarak hesaplanmıştır. Son adres verisinden dağıtım deposuna dönüş adımı ise 0.48 mil olarak hesaplanmıştır. Toplam rota uzunluğu 5.38 mil olarak belirlenmiştir. Araç rotalama optimizasyonu araç kapasitesi kısıtı olarak her bir rota için en fazla 20 sipariş olarak belirlenmiştir. Her müşterinin bir adet siparişi bulunmaktadır. Dağıtım aracının bir gün içerisinde yapabileceği maksimum yol mesafesi 20 mil olarak kabul edilmiştir. Maksimum yol mesafe kısıtı olan 20 mil sebebiyle bazı rotalar bir günde tamamlanamayıp birden fazla günde tamamlanmıştır. Yapılması planlanan 150 adet teslimata ilişkin oluşturulan rotalar neticesinde senaryo 1 için rota bazında toplam gidilecek mesafe tablosu Tablo 6'da belirtilmiştir.

**Tablo 6.** Senaryo 1 için tüm teslimatlara ait mesafe tablosu (Distance table for all deliveries for scenerio 1)

Rota	Toplam Mesafe (mil)	Rota	Toplam Mesafe (mil)	Rota	Toplam Mesafe (mil)	Rota	Toplam Mesafe (mil)	Rota	Toplam Mesafe (mil)
1	5,38	31	50,25	61	16,05	91	70,35	121	37,5
2	130,5	32	58,35	62	23,7	92	141,75	122	140,25
3	9,6	33	12,9	63	55,35	93	69,15	123	83,4
4	7,2	34	100,35	64	100,95	94	144	124	17,4
5	11,7	35	105,75	65	114,75	95	129,3	125	96,15
6	52,65	36	13,5	66	115,8	96	193,2	126	54,6
7	11,1	37	69	67	115,35	97	223,2	127	54,3
8	89,25	38	54,6	68	167,25	98	177,6	128	41,4
9	47,55	39	64,05	69	161,25	99	65,55	129	10,65
10	20,4	40	18,3	70	126	100	77,85	130	40,65
11	8,55	41	42,3	71	160,95	101	143,55	131	44,25
12	54,3	42	77,7	72	134,1	102	155,25	132	73,05
13	16,35	43	13,95	73	151,35	103	82,5	133	37,35
14	10,65	44	94,5	74	17,25	104	37,5	134	24,15
15	11,4	45	81,45	75	140,1	105	117	135	83,85
16	6,45	46	75,45	76	90,45	106	37,8	136	12,75
17	40,05	47	103,05	77	147,3	107	78,6	137	87,6
18	46,95	48	125,1	78	105,45	108	7,65	138	12,3
19	28,35	49	49,5	79	155,85	109	10,5	139	11,25
20	11,85	50	105	80	109,5	110	78,75	140	16,35
21	12,45	51	6,75	81	73,8	111	19,2	141	57,9
22	74,55	52	66,15	82	66,45	112	95,4	142	85,2
23	14,7	53	44,4	83	91,95	113	13,5	143	10,95
24	73,95	54	29,1	84	99,3	114	40,65	144	70,35
25	8,55	55	115,65	85	148,5	115	40,8	145	54,45
26	69	56	93	86	58,65	116	64,95	146	53,7
27	8,25	57	49,35	87	95,85	117	54,45	147	106,95
28	121,65	58	82,8	88	33,75	118	50,7	148	35,55
29	14,4	59	100,8	89	122,25	119	104,7	149	79,65
30	47,1	60	98,1	90	55,05	120	96,9	150	105,75

Tablo 6'daki verilere göre 150 farklı rota için kat edilen toplam yol mesafesi 10.382,23 mil'dir. Birinci senaryoya ait maliyetler Tablo 7'de gösterilmiştir.

Tablo 7'de yer alan maliyetleri inceleyecek olursak, veri setinin süresi olan 36 ay için belirlenen depo bölgesinde depolama maliyeti aylık 210,00 Euro

üzerinden toplam 7.560,00 Euro olarak hesaplanmıştır. Depo kiralamasıyla ortaya çıkan personel ve araç maliyeti ise dönemin güncel ücretleri üzerinden hesaplanıp sırasıyla 12.600,00 € ve 5.400,00 € olarak belirlenmiştir. Dağıtım için kat edilen toplam mesafe 10.382,23 mil olarak hesaplanmıştır. Mil başına yakıt

tüketimi 0,24 lt kabul edilip yakıt maliyeti ortalama 1,75 Euro üzerinden toplam 4.360,54 Euro olarak hesaplanmıştır. Depolama, personel, araç ve yakıt maliyetleri toplandığında senaryo 1'e ait toplam maliyet 29.920,54 Euro olarak hesaplanmıştır.

**Tablo 7.** Senaryo 1'e ait maliyetler (Costs of Scenario 1)

Maliyet Kalemleri	Senaryo 1
Kiralama Süresi (ay)	36
Depo kiralama Bedeli (aylık)	210,00 €
Toplam Depolama Maliyeti	7.560,00 €
Çalışan Sayısı	1
Toplam Çalışan Maliyeti (aylık)	350,00 €
Toplam Çalışan Maliyeti	12.600,00 €
Aylık Araç Kirası	150,00 €
Toplam Araç Maliyeti	5.400,00 €
Kat Edilen Son Adım Mesafesi (mil)	10.382,23
Yakıt Tüketimi (lt/mil)	0,24
Ortalama Yakıt (lt)	1,75 €
Toplam Yakıt Maliyeti	4.360,54 €
Toplam Senaryo Maliyeti	29.920,54€

#### 4.2. Senaryo 2 (Scenario 2)

Müşterilerin adresleri altı adet bölgeye ayırarak incelediğinde, siparişlerin miktarlarını Tablo 8'de gösterilmiştir.

Tablo 8'de yer alan verilere göre siparişlerin % 79,6 lık kısmı Bölge 1 ve Bölge 2 den geldiği görülmektedir. Pareto (ABC) analizi yaklaşıma göre ikinci senaryoda siparişlerin % 79,6 lık kısmını oluşturan Bölge 1 ve 2 deki siparişlerin maliyet analizine odaklanmaya karar verilmiş olup bu bölgelere

**Tablo 9.** Senaryo 2 için birinci rotaya ait müşteri ve sipariş verileri (Customer and order data for first route of scenario 2)

Müşteri	X	Y	Sipariş Tarihi	Teslimat
M4	44.70744124	20.47597179	5.01.2019	1. Teslimat
M5	44.73368841	20.32377310	7.01.2019	1. Teslimat
M6	44.84258357	20.38425464	8.01.2019	1. Teslimat

Birinci teslimata ait siparişlerin koordinatları belirlenen depo yerinden teslimatı için araç rotalama optimizasyonu yapılmış ve dağıtılması gereken rota Tablo 10'da gösterilmiştir.

**Tablo 10.** Senaryo 2 için birinci rotaya ait veriler (Data for the first route of Scenario 2)

Durak	Sipariş Sayısı	Mesafe (Mil)
1	0	1,06
2	1	2,15
3	1	1,12
4	1	3,11
Toplam	3	7,44

Araç rotalama optimizasyonu araç kapasitesi kısıtı olarak her bir rota için en fazla 20 sipariş olarak belirlenmiştir. Her müşterinin bir adet siparişi bulunmaktadır. Dağıtım aracının bir gün içerisinde yapabileceği maksimum yol mesafesi 20 mil olarak kabul edilmiştir. Yapılması planlanan 150 adet teslimata ilişkin oluşturulan rotalar neticesinde rota

ait siparişler e-ticaret firması tarafından kiralanmış depo yerinden teslim edilmesi, diğer bölgelere kargo yapılmasına karar verilmiştir. Alınan karar doğrultusunda yarı zamanlı çalışan istihdam etmek yeterli bulunmuştur.

**Tablo 8.** Bölgelere Göre Sipariş Miktarları (Order Quantities by Regions)

Bölgeler	Sipariş Miktarı	Sipariş Oranı (%)
1	1544	50,7
2	880	8,9
3	189	6,2
4	165	5,4
5	178	5,8
6	88	2,9

Bölge 1 ve Bölge 2 deki adres verilerini dikkate alarak P-Median algoritması ile dağıtım yapılması planlanan depo yeri koordinatları X 44.749977640368 Y 20.4403234405758 olarak belirlenmiştir. Belirlenen koordinatlarda bulunan depo yerlerinin ortalama kirası ülkenin online emlak satış - kiralama sitesi emsal verileri referans alınarak ortalama 260 €/ay olarak kabul edilmiştir. Dağıtım işlemleri için kiralanacak araç, yakıt ve çalışan parametreleri senaryo 1 ile aynıdır.

Firma, koordinatları belirtilen depo yerinden haftalık olarak rota planlamaktadır. Alınan siparişler analiz edildiğinde 150 adet rota planlaması yapılması gerekmektedir. 1. haftaya ait müşteri koordinat verileri ve sipariş tarihleri aşağıdaki Tablo 9'da gösterilmiştir.

bazında toplam gidilecek mesafe tablosu Tablo 11'de belirtilmiştir.

Tablo 11'de yer alan verilere göre kat edilen toplam yol mesafesi 2.245,65 mil'dir. İkinci senaryoya ait maliyetler Tablo 12'de gösterilmiştir.

Tablo 12'deki maliyetleri inceleyecek olursak, veri setinin süresi olan 36 ay için belirlenen depo bölgesinde depolama maliyeti senaryo 1 deki depo adresinden daha merkezi olduğu için aylık 260,00 Euro üzerinden toplam 9.360,00 Euro olarak hesaplanmıştır. Depo kiralamasıyla ortaya çıkan personel ve araç maliyeti ise dönemin güncel ücretleri üzerinden hesaplanıp sırasıyla 6.300,00 € ve 5.400,00 € olarak belirlenmiştir. Dağıtım için kat edilen toplam mesafe 2.245,65 mil olarak hesaplanmıştır. Mil başına yakıt tüketimi 0,24 lt kabul edilip yakıt maliyeti ortalama 1,75 Euro üzerinden toplam 943,17 Euro olarak hesaplanmıştır. Bölge 1 ve 2 dışında kalan müşterilere ait siparişlerin kargo ile gönderilmesi maliyetleri mevcut durumdaki gibi 6009,73 Euro olarak hesaplanmıştır. Depolama, personel, araç, yakıt ve

kargo maliyetleri toplandığında 2. senaryoya ait toplam maliyet 28.012,90 Euro olarak hesaplanmıştır.

**Tablo 11.** Senaryo 2 için tüm teslimatlara ait mesafe tablosu (Distance table for all deliveries for scenerio 2)

Rota	Toplam Mesafe (mil)	Rota	Toplam Mesafe (mil)	Rota	Toplam Mesafe (mil)	Rota	Toplam Mesafe (mil)	Rota	Toplam Mesafe (mil)
1	7,44	31	10,95	61	16,2	91	19,95	121	15,9
2	18,3	32	16,65	62	9,6	92	20,55	122	15,15
3	8,1	33	12,45	63	18,75	93	18,45	123	10,65
4	7,2	34	19,65	64	16,35	94	20,7	124	16,05
5	11,7	35	12,9	65	20,25	95	20,1	125	8,55
6	7,5	36	14,1	66	22,05	96	35,25	126	4,35
7	10,2	37	20,25	67	25,05	97	37,95	127	1,5
8	15,6	38	16,35	68	24,15	98	38,85	128	13,8
9	11,55	39	14,7	69	25,5	99	21	129	8,25
10	14,55	40	17,4	70	27,15	100	24,3	130	10,35
11	6,9	41	15,75	71	25,35	101	22,5	131	15,3
12	11,25	42	12	72	22,05	102	23,85	132	10,2
13	16,35	43	7,2	73	24,15	103	14,25	133	9,45
14	10,95	44	14,4	74	17,7	104	16,2	134	8,4
15	10,8	45	15,9	75	18,75	105	18,75	135	8,85
16	6,45	46	23,1	76	20,7	106	10,05	136	12,75
17	15,3	47	14,25	77	21,75	107	18,9	137	10,5
18	15	48	15,6	78	16,35	108	7,95	138	12,15
19	15,15	49	16,2	79	19,8	109	6,3	139	8,4
20	12	50	11,55	80	15,3	110	8,7	140	15,3
21	13,35	51	6,6	81	19,05	111	13,05	141	6,75
22	10,8	52	20,1	82	13,95	112	17,25	142	14,85
23	14,7	53	16,65	83	17,85	113	13,2	143	9,3
24	8,7	54	15,45	84	16,65	114	17,7	144	17,25
25	8,7	55	9,75	85	18,75	115	8,25	145	14,85
26	9,3	56	15,3	86	14,85	116	13,8	146	7,2
27	7,5	57	15,3	87	17,4	117	18,45	147	8,85
28	13,65	58	18,15	88	15,75	118	8,25	148	16,05
29	14,25	59	19,05	89	17,85	119	13,5	149	16,8
30	10,95	60	15,15	90	15,3	120	12,15	150	13,8

**Tablo 12.** Senaryo 2'ye ait maliyetler (Costs of Scenario 2)

Maliyet Kalemleri	Senaryo 2
Kiralama Süresi (ay)	36
Depo kiralama Bedeli (aylık)	260,00 €
Toplam Depolama Maliyeti	9.360 €
Çalışan Sayısı	1
Toplam Çalışan Maliyeti (aylık)	175,00 €
Toplam Çalışan Maliyeti	6.300,00 €
Aylık Araç Kirası	150,00 €
Toplam Araç Maliyeti	5.400,00 €
Kat Edilen Son Adım Mesafesi (mil)	2.245,65
Yakıt Tüketimi (lt/mil)	0,24
Ortalama Yakıt (lt)	1,75 €
Toplam Yakıt Maliyeti	943,173 €
Kargo ile ürün gönderme maliyeti	6009,73 €
Toplam Senaryo Maliyeti	28.012,9 €

#### 4.3. Senaryo 3 (Scenario 3)

Üçüncü senaryoda ise katılımlı model olan teslimat noktası modeli değerlendirilmek istenmektedir. Bu senaryoda Bölge 1 ve Bölge 2 deki adresler kümeleme algoritmasıyla aşağıdaki gibi 5 bölgeye ayrılmıştır. Belirlenen 5 bölgeye ait adresler için p-medyan yöntemiyle 5 adet teslimat noktası belirlenmiştir. Belirlenmiş teslimat noktası adreslerine teslimat yapacak depo yeri X-44.749977640368 Y-

20.4403234405758 olup birinci senaryodaki adres bilgisi ile aynıdır.

Müşterilerin teslimat noktalarından siparişlerini teslim almaları senaryosunda her bir müşteri için sonraki siparişinde kullanmak üzere 5€ değerinde hediye kuponu tanımlanmaktadır. Toplam sipariş sayısı 2267'dir. 1.rotaya ait rota sıralaması ve mesafeleri Tablo 13'te gösterilmiştir.

**Tablo 13.** Senaryo 3 için birinci rotaya ait veriler (Data for the first route of Scenario 3)

Durak	Sipariş Sayısı	Mesafe (Mil)
1	0	1,12
2	1	2,26
3	1	1,19
4	1	0,38
5	1	1,17
6	1	2,43
Toplam	3	7,55

Teslimat noktalarına haftalık yapılacak olan sevkiyatın toplam mesafesi 7,55 mil'dir. 150 haftalık teslimat için bu mesafe 1132,5 mil'dir. Üçüncü senaryoya ait maliyetler Tablo 14'te gösterilmiştir.

**Tablo 14.** Senaryo 3'e ait maliyetler (Costs of Scenario 3)

Maliyet Kalemleri	Senaryo 3
Kiralama Süresi (ay)	36
Depo kiralama Bedeli (aylık)	260,00 €
Toplam Depolama Maliyeti	9.360 €
Çalışan Sayısı	1
Toplam Çalışan Maliyeti (aylık)	175,00 €
Toplam Çalışan Maliyeti	6.300,00 €
Aylık Araç Kirası	150,00 €
Toplam Araç Maliyeti	5.400,00 €
Kat Edilen Son Adım Mesafesi (mil)	1132,5
Yakıt Tüketimi (lt/mil)	0,24
Ortalama Yakıt (lt)	1,75 €
Toplam Yakıt Maliyeti	475,65 €
Hediye çeki maliyeti	11.335 €
Kargo ile ürün gönderme maliyeti	6009,73 €
Toplam Senaryo Maliyeti	38.880,38 €

Tablo 14'te yer alan maliyetleri inceleyecek olursak, veri setinin süresi olan 36 ay için belirlenen depo bölgesinde depolama maliyeti aylık 260,00 Euro üzerinden toplam 9.360,00 Euro olarak hesaplanmıştır. Depo kiralamasıyla ortaya çıkan personel ve araç maliyeti ise dönemin güncel ücretleri üzerinden hesaplanıp sırasıyla 6.300,00 € ve 5.400,00 € olarak belirlenmiştir. Dağıtım için kat edilen toplam mesafe 1.132,5 mil olarak hesaplanmıştır. Mil başına yakıt tüketimi 0,24 lt kabul edilip yakıt maliyeti ortalama 1,75 Euro üzerinden toplam 475,65 Euro olarak hesaplanmıştır. Bu maliyetlere ek olarak katılımlı teslimat modeline teşvik için müşterilere bir sonraki alışverişlerinde kullanmak üzere verilen 5 Euro bedelindeki hediye çeki maliyeti 11.335 Euro olarak hesaplanmıştır. 1. ve 2. bölge dışındaki müşterilere yapılacak kargolama maliyeti ise mevcut durumdaki dağıtım maliyetleri göz önüne alınarak 6009,73 Euro olarak hesaplanmıştır. Depolama, personel, araç, yakıt, hediye ve kargolama maliyetleri toplandığında senaryo 3 ait toplam maliyet 38.880,38 Euro olarak hesaplanmıştır.

**Tablo 15.** Senaryolara ait maliyetler (Costs of scenarios)

Maliyet kalemleri/Senaryolar	Mevcut durum	Senaryo 1	Senaryo 2	Senaryo 3
Kargo Maliyeti (€)	23.065,61	-	6.009,73	6.009,73
Depolama Maliyeti (€)	27.000,00	7.560,00	9.360,00	9.360,00
Çalışan Maliyeti (€)	-	12.600,00	6.300,00	6.300,00
Araç Kiralama Maliyeti (€)	-	5.400,00	5.400,00	5.400,00
Yakıt Maliyeti (€)	-	4.360,54	943,173	475,65
Hediye Çeki Maliyeti (€)	-	-	-	11.335,00
Toplam Maliyet (€)	50.065,61	29.920,54	28.012,90	38.880,38

Tablo 15'te senaryo maliyetleri gösterilmiştir. Kargo maliyeti açısından değerlendirdiğimizde mevcut durumdaki tüm teslimatlar lojistik firması tarafından sağlandığı için en yüksek kargo maliyeti bu senaryoya aittir. Senaryo 1'de dağıtım hizmeti alınmamakta olup senaryo 2 ve 3 te ise pareto analiziyle daha az sipariş alınan bölgeler tespit edilmiş olup bu bölgelere kargo hizmeti alınmaktadır. Depolama maliyeti açısından değerlendirdiğimizde mevcut durumda depolama hizmeti lojistik firmasından sağlanmakta fakat bununla birlikte araç, çalışan ve yakıt maliyetleri sıfır olmaktadır. Önerilen üç senaryoda ise e-ticaret firmasının depo kiralaması planlanıp depolama maliyeti ucuz indirilmiştir. Ancak depo kiralaması maliyetiyle birlikte personel, araç ve yakıt masrafları oluşmuş ve bu senaryolarda maliyet hesaplarına katılmıştır. Diğer senaryolardan farklı olarak 3. senaryoda ise en az son adım teslimat masrafı olmasına rağmen katılımlı teslimat modeline teşvik için verilen hediye çeki maliyeti senaryo 3'ün maliyetinin artmasına ve senaryo 3'ün tercih edilebilir olmamasına sebep olmuştur.

## 5. Sonuç ve Öneriler (Conclusion and Recommendations)

Bu çalışmada, mobilya sektöründe faaliyet gösteren bir e-ticaret firmasının son adım teslimat problemi ele

alınmıştır. Firma için en uygun son adım teslimatı stratejisini belirleyebilmek için çeşitli lojistik modelleri üç farklı senaryo altında incelenmiştir.

Çalışılan üç farklı senaryo maliyetleri firmanın mevcut durum maliyeti ile karşılaştırılmış ve senaryo 2'ye ait maliyetin en düşük maliyet olduğu görülmüştür. Senaryo 2'yi diğer senaryolardan avantajlı kılan durum NP-Zor olarak sınıflandırılan bu problemin çözümünde birden fazla modelin çözümde birlikte kullanılması olmuştur. Bu senaryoda kullanılan Pareto analizi yardımıyla maliyetin büyük kısmını oluşturan siparişlerin merkeze yakın olan bölgelerden geldiği görülmüş, taşıma mesafesinin kısaltılması için dağıtım deposu bu bölge özelindeki adreslerin verilerini kullanarak bulunmuştur. Böylece taşıma mesafesi ve buna bağlı olarak taşıma maliyeti senaryo 3'ten az olmasına rağmen toplam maliyet tablosuna bakıldığında senaryo 2 tercih edilebilir olmuştur. Senaryo 3'ün toplam maliyetini yükselten nokta ise katılımlı teslimat modeliyle gelen müşteriyi katılıma ikna etme maliyetidir. Katılımlı modellerin teslimatında müşteri için tercih edilebilir olmasını sağlayan hediye çeki ödülü senaryo 3'ün maliyetlerinin düşmesine engel olmuştur. Son adım teslimatı maliyeti daha düşük olmasına rağmen katılımlı modelin getirdiği fazladan maliyet kalemi bu senaryonun tercih edilmesini önlemiştir.

Bu çalışma göstermektedir ki farklı metotların birlikte kullanımıyla oluşan hibrit model tercih

edildiğinde maliyetleri mevcut duruma göre yaklaşık %44 daha azdır. Senaryo 2'deki modelin uygulamaya geçilmesi ile birlikte personel istihdamı araç ve depo kiralama gibi fazladan maliyetler oluşmasının yanında bu işlemlerin getirebileceği ekstra sorunlar da ortaya çıkması mümkündür. Çalışmada bu yeni eklenebilecek durumların getirebileceği problemler kapsam dışı bırakılmıştır. Bu noktada karar e-ticaret firmasının yönetimine bırakılmıştır.

## Kaynaklar (References)

- Aydemir, E., 2006. Esnek Zaman Pencere Araç Rotalama Problemi ve Bir Uygulama. Yüksek Lisans Tezi, Gazi Üniversitesi.
- Ballou, R. H., 1992. Business Logistics Management: Instructor's Manual with Software, Prentice Hall.
- Charisis, A., Kaisar, E., 2019. Multiobjective Capacitated Location-Allocation Model for Urban Logistics Delivery Facilities (No. 19-00706).
- Cipta, H., Hasibuan, M. F., 2023. Optimal Vehicle Routing Problem (VRP) For the distribution of medical devices by applying the clarke-wright algorithm. International Journal of Science and Environment (IJSE), 3(1), 7-12.
- Clarke, G., Wright, J. W., 1964. Scheduling of vehicles from a central depot to a number of delivery points. Operations research, 12(4), 568-581.
- Croes, G. A., 1958. A method for solving traveling-salesman problems. Operations Research, 6(6), 791-812.
- Dantzig, G. B., Ramser, J. H., 1959. The truck dispatching problem. Management science, 6(1), 80-91.
- Deutsch, Y., Golany, B., 2018. A parcel locker network as a solution to the logistics last mile problem. International Journal of Production Research, 56(1-2), 251-261.
- Ercan Cömert, S., 2023. Çok amaçlı elektrikli araç rotalama probleminin hiyerarşik bir metasezgisel algoritma ile çözümü. Doktora Tezi, Sakarya Üniversitesi.
- Eş Yürek, E., 2018. İnsansız hava aracı destekli araç rotalama problemi, Doktora Tezi, Uludağ Üniversitesi.
- Faugere, L., Montreuil, B., 2017. Smart locker bank design: A scenario based optimization approach. In Actes du Congrès International de Génie Industriel (Proceedings of Industrial Engineering Congress).
- Gevaers, R., Van de Voorde, E., Vanelslender, T., 2011. Characteristics and typology of last-mile logistics from an innovation perspective in an urban context, City distribution and urban freight transport: Multiple perspectives, pp. 56-71.
- Grabmeier, J., Rudolph, A., 2002. Techniques of cluster algorithms in data mining. Data Mining and knowledge discovery, 6, 303-360.
- Guerrero-Lorente, J., Gabor, A. F., Ponce-Cueto, E., 2020. Omnichannel logistics network design with integrated customer preference for deliveries and returns. Computers & Industrial Engineering, 144, 106433.
- Hakimi, S.L., 1964. Optimum Location of Switching Centers and the Absolute Centers and Medians of a Graph. Operations Research, 12(3), 450-459.
- Hakimi, S.L., 1965. Optimum distribution of switching centers in a communication network and some related graph theoretic problems. Operations Research, 13(3), 462-475.
- Han, J., Kamber, M., 2001. Data Mining and Concepts Techniques, San Francisco: Morgan Kaufmann Publishers Inc.
- Hariati, A., Prasetya, N. H., Cipta, H., 2021. The effectiveness of clarke wright and sequential insertion algorithm in distribution routing aqua. Quadratic: Journal of Innovation and Technology in Mathematics and Mathematics Education, 1(1), 15-22.
- Janjevic, M., Winkenbach, M., Merchán, D., 2019. Integrating collection-and-delivery points in the strategic design of urban last-mile e-commerce distribution networks. Transportation Research Part E: Logistics and Transportation Review, 131, 37-67.
- Johnson, D., Chaniotakis, E., 2021. Innovative last mile delivery concepts: Evaluating last mile delivery using a traffic simulator. 7th International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS), pp. 1-6.
- Karaođlan, Y., 2018. Farklı kümeleme analizi yöntemleri ile Türkiye'deki illerin sosyo-ekonomik özelliklerine göre sınıflandırılması ve karşılaştırılması. Yüksek Lisans Tezi, Sivas Cumhuriyet Üniversitesi.
- Karaođlu, G., 2019. E-ticaret lojistiğinde fiziksel dağıtım uygulamaları; talep üzerine dağıtım hizmetleri için model oluşturulması ve bir uygulama. Doktora Tezi, İstanbul Üniversitesi Cerrahpaşa Lisansüstü Eğitim Enstitüsü.
- Kedia, A., Kusumastuti, D., Nicholson, A., 2020. Locating collection and delivery points for goods' last-mile travel: A case study in New Zealand. Transportation Research Procedia, 46, 85-92.
- Lenstra, J.K., Rinnooy Kan, A.H.G., 1981. Complexity of vehicle routing and scheduling problems. Networks, 11(2), 221-227.
- Lim, S. F. W., Jin, X., Srai, J. S., 2018. Consumer-driven e-commerce: A literature review, design framework, and research agenda on last-mile logistics models. International Journal of Physical Distribution & Logistics Management, 48(3), 308-332.
- Lin, Y. H., Wang, Y., He, D., Lee, L. H., 2020. Last-mile delivery: Optimal locker location under multinomial logit choice model. Transportation Research Part E: Logistics and Transportation Review, 142, 102059.
- Liu, D., Deng, Z., Zhang, W., Wang, Y., Kaisar, E. I., 2021. Design of sustainable urban electronic grocery distribution network. Alexandria Engineering Journal, 60(1), 145-157.
- MacQueen, J., 1967. Some methods for classification and analysis of multivariate observations. Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability, 1(14), 281-297.
- Morganti, E., Dablanc, L., Fortin, F., 2014. Final deliveries for online shopping: The deployment of pickup point networks in urban and suburban areas. Research in Transportation Business & Management, 11, 23-31.
- Nurcan, D., 2020. E-ticaret lojistiğinde son adım dağıtım hizmetlerine yönelik çok seferli ve zaman pencere sayısal bir yaklaşım. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi.
- Orenstein, I., Raviv, T., Sadan, E., 2019. Flexible parcel delivery to automated parcel lockers: models, solution methods and analysis. EURO Journal on Transportation and Logistics, 8(5), 683-711.
- Pamosoaji, A. K., Dewa, P. K., Krisnanta, J. V., 2019. Proposed modified Clarke-Wright saving algorithm for capacitated vehicle routing problem. International Journal of Industrial Engineering and Engineering Management, 1(1), 9-16.

- Ratchford, B., Gauri, D. K., Jindal, R. P., Namin, A., 2023. Innovations in retail delivery: Current trends and future directions. *Journal of Retailing*, 99(4), 547-562.
- ReVelle, C., Swain, R., 1970. Central Facilities Location. *Geographical Analysis*, 2(1), 30-42.
- Romesburg, H. C., 2004. *Cluster Analysis for Researchers*, Lulu Press, North Carolina.
- Sanders, N. R., 2020. *Supply chain management: A global perspective*, John Wiley & Sons.
- Schwerdfeger, S., Boysen, N., 2020. Optimizing the changing locations of mobile parcel lockers in last-mile distribution. *European Journal of Operational Research*, 285(3), 1077-1094.
- Tan, P. N., Steinbach, M., Kumar, V., 2006. *Introduction to Data Mining*, Addison Wesley.
- Tezkoşar, B., 2022. Hibrit scooter kullanarak şehir içi teslimatta karbon ayak izi azaltılması. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi.
- Toth, P., Vigo, D., 2002a, An overview of vehicle routing problems-chapter 1, The vehicle routing problem, SIAM, Philadelphia, pp. 1-26.
- Toth, P., Vigo, D., 2002b. The vehicle routing problem, Philadelphia: SIAM Monographs on Discrete Mathematics and Applications.
- Weltevreden, J. W., 2008. B2c e-commerce logistics: the rise of collection-and-delivery points in The Netherlands. *International Journal of Retail & Distribution Management*, 36(8), 638-660.
- Xu, R., Wunsch, D., 2005. Survey of Clustering Algorithms. *IEEE Transactions on Neural Networks*, 16(3), 645-678.