

JOIN SSR

JOURNAL OF SMART SYSTEMS RESEARCH

Volume: 6 Issue: 01 Year: 2025 e-ISSN: 2757-6787





JOINSSR is in the category of peer-reviewed, online and open access international journal published by Sakarya University of Applied Sciences (SUBU) Scientific Publications Coordinatorship (BIYAK) SUBU. Our journal, which started its publication life with its first issue in December 2020, publishes 2 issues (June/December) per year. JOINSSR accepts publications in Turkish or English. Journal accepts research articles, review articles, letters to editor and technical notes in fields such as Artificial intelligence applications, Sensor technologies, Biomedical applications, Smart materials, Robotics, Bioinspired smart systems applications, Human-machine interaction. In all submitted articles, a double-blind peer-review system is used. Journal of Smart Systems Research is indexed by Index Copernicus, Cite Factor, Sobiad Attf Dizini and CrossRef.

Indexes					
Index Copernicus	https://journals.indexcopernicus.com/search/details?id=69849				
Cite Factor	https://www.citefactor.org/journal/index/28991/journal-of-smart-systems- research#.YpSKgVRBxPY				
Sobiad Atıf Dizini	https://atif.sobiad.com/index.jsp?modul=journals- detail&ID=Wd34v4wBQzmg-9NMHhAn				
Cross Ref	https://www.doi.org/				

JOURNAL BOARDS

Editor in Chief Prof. Dr. Zafer Tatlı **Editor** Prof. Dr. Yusuf Cav Prof. Dr. Fatih Çalışkan **Editorial Board** Dr. Muhammad Shahreeza Safiruz Bin Kassim, Department of Artificial Intelligence, University of Malaya (Malaysia) Dr. İsmail Esen, Makine Mühendisliği Bölümü, Karabük Üniversitesi (Turkey) Dr. Mehmet Aydın, Computer Science and Creative Technologies, University of the West of England (UK) Dr. Shyqyri Haxha, Department of Electronic Engineering, Royal Holloway University of London (UK) Dr. Enes KILINÇ, Makine Mühendisliği Bölümü, Karabük Üniversitesi (Turkey) Dr. Rasim TEMÜR, İnşaat Mühendisliği Bölümü, İstanbul Üniversitesi (Turkey) Dr. Hasan Arman, Department of Geology, United Arab Emirates University (UAE) Dr. Ahmet Türk, Metalurji Ve Malzeme Mühendisliği Bölümü, Manisa Celal Bayar Üniversitesi (Turkey) Dr. İbrahim Karaman, Materials Science and Engineering, Texas A&M University (USA) Dr. Rahul Ribeiro, Department of Mechanical Engineering, Alliance University (India) Dr. Murat Alçın, Mekatronik Mühendisliği Bölümü, Afyon Kocatepe Üniversitesi (Turkey) **Language Editor** Arş. Gör. Ali Kuyumcu **Technical and Layout Editor** Arş. Gör. Ali Kuyumcu

Secretaries

Arş. Gör. Ebru Yılmaz

İÇİNDEKİLER / CONTENTS

	Araştırma Makalesi/Research Article
1.	Comparative Study of Wireless Network Protocols using Ns-2 Network Simulator
	Ahmad Sabah, Ahmet Zengin1-10
2.	Hafif Elektrikli Araçlarda Yol Koşullarının Enerji Tüketimi Üzerindeki Etkisi: Modelleme, Simülasyon ve Analiz
	Mustafa Esen, Barış Boru11-27
3.	YOLOv11-based Detection of Wagon Brake Cylinder Conditions
	Murat Erhan Çimen28-44
4.	Kaotik Tabanlı PSO Algoritması ile PID Kontrol Parametrelerinin Optimizasyonu ve Sistem Performansının İncelenmesi
	Muhammed Salih Sarıkaya, Onur Demirel, Sezgin Kaçar, Adnan Derdiyok
5.	BLDC Motorlar İçin Sensörsüz Komütasyon Tabanlı Elektronik Hız Kontrol Cihazı Simülasyonu
	Mahmut Esat Çulfaz, Mücahit Soyaslan62-73



Research article Journal of Smart Systems Research (JOINSSR) 6(1), 1-10, 2025 Recieved: 11-Oct -2024 Accepted: 8-May-2025 https://doi.org/10.58769/joinssr.1565413



Comparative Study of Wireless Network Protocols using Ns-2 Network Simulator

Ahmad SABAH¹ , Ahmet ZENGIN²*

¹ Computer and Information Engineering, Sakarya University, Türkiye, ahmad.khoshnaw@gmail.com ² Computer and Information Engineering, Sakarya University, Türkiye, azengin@sakarya.edu.tr

ABSTRACT

Many factors affect the quality of wireless networks, but one of the most important is the movement between the nodes connected in one network. This movement leads to the presence of large packet loss as well as the impact on the energy of each node. Thus, it generally affects the network performance; several familiar routing protocols, such as AODV, DSR, and DSDV, are used to communicate between all nodes in the wireless network. This paper presents a comparison of performance and study of nodes in a single network based on Interactive Protocols (AODV) to study the metrics such as transmission rate, packet delivery rate, the average delay of Using the NS-2, determining the network, packet loss rate, and residual power at each node in the network simulator. The simulation results showed that increasing the traffic of the nodes increases the rate of packet loss and increases the remaining energy in the nodes in which there was a greater loss of packets, thus reducing the rate of packet delivery between the nodes, so the more the nodes have less movement, the higher the packet delivery rate and the lower the packet loss rate.

Keywords: AODV; Packet Loss; NS-2; Residual Energy; Performance

*Corresponding Author's e-mail: azengin@sakarya.edu.tr

Cite as: Sabah, A. & Zengin, A. (2025). Comparative Study of Wireless Network Protocols using Ns-2 Network Simulator, *Journal of Smart Systems Research*, 6(1), 1-10. <u>https://doi.org/10.58769/joinssr.1565413</u>

Creative Commons Attribution 4.0 International (CC BY 4.0) license (https://creativecommons.org/licenses/by/4.0/)

1. Introduction

Unsuccessful packets break down networks, create bottlenecks, and interrupt throughput and bandwidth [1]. Packet loss could also be costly. You'll have to spend a lot of money on extra IT equipment and bandwidth to handle the lag if you don't do everything possible to reduce packet loss in your system [2].

Consider packets as automobiles speeding along a freeway across your network. Sometimes there can be traffic on the road, for example, during rush hour or after lunch when all the employees of a large company return to their desks. The incident occurred when the 4-lane highway narrowed to two lanes, and many vehicles tried to merge. Some automobiles were unable to merge and were late for their appointments.

Packet loss and highway traffic are both common occurrences. Networks are manageable and impregnable, and they have constraints in terms of space [3] [4].

Packets must wait for delivery when network traffic reaches its maximum capacity. Unfortunately, packets are the first to remain when the network tries to capture traffic, and the connection can only handle a certain amount of traffic [5]. Fortunately, most software nowadays can automatically resend lost packets or slow down transfer speeds to allow each packet a chance to make it through [6].

In this study, we developed a wireless model scenario using the mobile wireless model presented in NS-2, got the trace result and, calculated the performance using the trace file, then displayed the results using the Gnuplot tool [7] to examine each result of the performance plot chart. There are two parts to this section.

In the first subsection, we defined the GOD, received, and sent delivery ratios and drooped packets and outlined a model scenario for establishing and operating a wireless network simulation with six nodes. In the second subsection, we started to calculate the performance of our model by using the awk scripts. Then, we started plotting the results as a chart using the Gnuplot tool, which helped us plot the results as line points and scatter charts. We can use the awk scripts to calculate the throughput performance (average or instant), residual energy, and packet delivery ratio.

2. Methodology

2.1 Network Simulator-NS-2

NS-2 is a C++-based object-oriented simulator with a front-end OTcl interpreter [8]. The emulator supports the C++ class structure (the assembly hierarchy in this document) and the OTcl interpreter class hierarchy (the translation hierarchy). The two hierarchies are similar, and from the user's perspective, there is a direct relationship between groups in the translation hierarchy and groups in the compilation hierarchy [9].

The TclObject class is at the very top of the hierarchy. The interpreter allows users to construct new simulator objects created within the interpreter and closely mirrored by a similar object in the compiled hierarchy. The TclClass class defines methods that automatically create the interpreted class hierarchy. Methods defined in the class TclObject are used to mirror user-created objects.

Other hierarchies exist in C++ code and OTcl scripts, but they are not replicated in the same way that TclObject is.

Many different organizations contribute to the structure and components of NS-2, and their strongest asset is in their rules. The number of models and joints in NS-3 is significantly less than in NS-2. Since

NS-3 is still in development, community participation is needed to add to and improve the supporting code[10].

3. Creating a wireless scenario model

We constructed a wireless situation scenario with six nodes. The topology comprises six mobile nodes (node0, node1, node2, node3, node4 and node5).

In this model, mobile nodes move in an area whose boundaries are defined as 500m x 500m.

The nodes start at the same point on the boundary. They then approach each other in the first simulation run. Then they clump in the middle; node2 and node3 connect using UPD protocol, and other nodes connect using TCP in the middle of the simulation. The node0 sends the packets to node 5. Packets are exchanged between nodes when they come within earshot of each other.

As they move away, packets are dropped, and the dropped packets increase from time nine until time 27 in the simulation scenario.

The Wi-Fi simulation begins by writing a TCL script named wireless.TCL, The Link Layer (LL), the Interface Queue (IfQ), the MAC layer, wireless channel nodes, and different network additives make up a mobile node.

#initialize	e the variables		
set val(cha	an) Channel/Wirel	essChannel ;#Char	nnel Type
set val(pro	op) Propagation/T	woRayGround ; # rad	dio-
propagation	n model	-	
set val (net	tif) Phy/WirelessP	hy ;# network inter	rface type
WAVELAN DSS	SS 2.4GHz	•	
set val(mac	c) Mac/802 11	; # MA(C type
set val(ifo	q) Queue/DropTail	l/PriQueue ;# int	terface
queue type			
set val(11)	LL	;# lin	nk laver
type			-
set val(ant	t) Antenna/OmniA	ntenna ;# ant	tenna
model			
set val(ifo	glen) 50	;# ma:	x packet
in ifg	-		-
set val (nn)	6	;# nur	mber of
mobilenodes	5		
set val(rp)	AODV	;# rou	ating
protocol			-
set val(x)	500	;# in met:	res
set val(y)	500	;# in met:	res
#Adhoc OnDe	emand Distance Vect	or	
#GOD Creat;	ion - General Opera	tions Director	
create-god	Şval(nn)		
set channel	II [new sval(chan)]		
set channel	12 [new sval(chan)]		
set channel	13 [new sval(chan)]		
toonfimure	the node		
\$nc. pode-or	onfig -adhogBouting	Swal (ma)	
-11 -11	Type Sval(11) \	foar(rp/ (
-m:	acTupe Sval(mac) \		
-if	foType Sval(ifg) \		
-i f	folen Sval(ifglen)	`	
-ar	ntType \$val(ant) \		
10 ⁻	(gorg) Lav? aqvTqor	N	
-ph	nyType \$val(netif)	N N	
-er	nergyModel "EnergyM	odel" \	
-ir	hitialEnergy 100.0	X	
-ta	xPower 0.9 ∖		
-r:	xPower 0.5 \		
-ic	dlePower 0.45 \		
-s]	leepPower 0.05 \		
-to	opoInstance \$topo \		

Figure 1: Developed NS-2 Script

At the start of a wireless simulation, we want to outline the kind for every of those network components. Additionally, we want to outline different parameters such as the sort of antenna, the radio-propagation model, the ad-hoc routing protocol utilized by cellular nodes, etc. We start our script wireless.tcl with a listing of those special parameters defined above; we can take the stairs under to symbolize the wireless network scenario:

- ✓ Initialize variables.
- ✓ Create a Simulator object.
- ✓ Create Tracing and animation files.
- \checkmark Creation of topography.
- ✓ Creation of General Operations Director (GOD).
- \checkmark Build the nodes.
- ✓ Create a link.
- \checkmark Set the position of the nodes.
- \checkmark Set mobility.
- ✓ Create TCP and UDP Traffic.
- \checkmark At last, run the simulation.

Figure 1 is our network simulation code and briefly clarifies each step mentioned.

4. Result and performance

4.1 The Files of Results

After running the simulation model by the command (> ns wireless.tcl), we got two file results; the first one is wireless.tr, which performs the trace file that we used to calculate the performance of our network model, as shown in Figure 2 the trace file we get after running the model.

The other file we get after running the tcl file is the NAM, representing our model's visualization. It shows us the whole scenario of how the nodes connect and move together, and we can see the send and response between the nodes. We can also see the dropping packet, as shown in Figure 2. Screenshots for our model NAM show the dropped packet (see Figure 3) and the node connection (see Figure 4).

4.2 Calculating and plotting performance

In our simulation, we focused on determining network model performance by writing scripts to extract the relevant data from the trace file (wireless.tr) and then plotting the data using the Gnuplot tool to calculate the following:

- 1. Residual energy of a node.
- 2. Mean throughput.
- 3. Instantaneous throughput.
- 4. Packet delivery ratio.

4.3 Average throughput

We got the result in Figure 5 using the awk script to calculate the average throughput we prepared for this aim.

Our simulation starts at time one and ends at time 29. The total time for the simulation is 30 seconds. The total number of packets received is 3939, with an average throughput of 1.09 kbps (see Table 1).

Ahmad Sabah, Ahmet Zengin Comparative Study of Wireless Network Protocols using Ns-2 Network Simulator

Open	• Jī		wireless.tr -/BSM553/exam/test		Save	-	. 6	8
		wireless.tcl		wireless.tr				×
1 M 2 M 3 M 4 M 5 M 5 M 5 M 5 M 5 M 5 M 5 M 5 M 5 M 5	4 1.0000 1 4 1.00000 1 4 1.00000 4 4 1.00000 2 4 1.00000 2 4 1.00000 3 4 1.00000 3 5 0.01 t tcp - t 1.0000 5 0.01 t cp - t 1.0000 5 0.01 t cp - t 1.0000 5 0.01 t cp - t 1.0000 5 0.01 t cp - t 1.0001 4 0.000 1 - 1.255 - 1 - t 1.0001 4 0.000 1 - t 1.0001 4 0.000 1 - t 1.0001 4 0.000 1 - t 1.0001 4 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.0001 5 0.000 1 - t 1.00001 - t 1.00000	WHELESLCL (210.00, 320.00, 6.00), (300.00, 1 (210.00, 320.00, 6.00), (300.00, 1 (270.00, 320.00, 6.00), (300.00, 1 (400.00, 200.00, 6.00), (300.00, 1 (400.00, 200.00, 6.00), (350.00, 2 (10.00, 230.00, 6.00), (230.00, 130 00000 -HS 0.00, 0.00), (230.00, 130 00000 -HS 0.00, (230.00, 130 00000 -HS 0.00, (230.00, 130 00000 -HS 0.00, (230.00, 130 00000 -HS 2.00, 2.00, 2.00, 130 00000 -HS 2.00, 2.00, 2.00, 2.00, 130 00000 -HS 2.00, 2.00, 2.00, 2.00, 130 00000 -HS 2.00, 2.00, 2.00, 2.00, 2.00, 130 00000 -HS 2.00, 2.00, 2.00, 2.00, 2.00, 130 00000 -HS 2.00, 2.00, 2.00, 2.00, 2.00, 130 00000 -HS 2.00,	40.00), 25.00 30.00), 5.00 40.00), 15.00 50.00), 15.00 50.00), 25.00 .00), 25.00 .00), 25.00 .00), 25.00 .00, 25.00 .00, 25.00 .00, 25.00 .00, 25.00 .00, 25.00 .00, 25.00 .00, 25.00 .00 .00 .00	WHTELESS.CF 3000 -NL AGT -NWMa 0 -Md 0 -M 3000 -NL RTR -NWMa 0 -Md 0 -M 300060 -NL RTR -NWMa 0 -Md 0 300060 -NL RTR -NWMa 0 -Md 0 -M -Pds 0 -Ps 0 -Pss 4 -Pc REQUEST 30006 -NL RTR -NWMa 0 -Md ffff 90006 -NL MAC -NWMa 0 -Rd ffff Pb 1 -Pd 5 -Pds 0 -Ps 2 -Pss 4 -Pc	s 0 - Mt 0 s 0 - Mt 0 - Ms 0 - Mt s 0 - Mt s 0 - Mt ffff - Ms REQUEST REQUEST	-IS 0. -IS 0. 0 -IS 0. 0 -IS 0. -IS 0. 0 -Mt 8	0 - Id 0 - Id 2.0 - 1 2.0 - 1 2.55 - 1 2.255 - 1 2.255 000 - I 800 - 1	td td td s
21 M 22 M 23 M	<pre>4 -t 1.0018 4 -t 1.0018 4 -t 1.0018 4 -t 1.0018</pre>	99 -n 5 -e 99.548679 99 -n 1 -e 99.548679 99 -n 3 -e 99.548679						
24 M 25 r 2	-t 1.0019 -t 1.0027 2.255 -Id -	00 -n 0 -e 99.548339 46844 -Hs 4 -Hd -Z -Ni 4 -Nx 429.99 1.255 -It AODV -IL 48 -If 0 -Ii 0 -	-Ny 319.99 -Nz 0.00 -Ne 99.54 Iv 30 -P aodv -Pt 0x2 -Ph 1 -F	18679 -Nl MAC -NwMa 0 -Md fff 26 1 -Pd 3 -Pds 0 -Ps 2 -Pss 4 -Pc	fffff -Ms REQUEST	z -Mt	800 - 1	Is
26 r	- t 1.0027	46941 -Hs 5 -Hd -2 -Ni 5 -Nx 269.99	-Ny 120.04 -Nz 0.00 -Ne 99.54	18679 -NI MAC -NwMa 0 -Md fff	fffff -Ms	2 -Mt	800 -1	IS INC

Figure 2: Trace file output (wireless.tr)



Figure 3. Nodes Motion and Drop packets.



Figure 4. Node0 and Node5 Connection

Function	Value
Start Time	1
Stop Time	29
Received Packets	3939
The throughput in kbps is	1.086713

Table 1: Average throughput

4.4 Instant throughput

Using the awk script (instant_throu.awk), we got the throughput by time for the simulation, and by using Gnuplot, we can plot this data as a line chart, as shown in Figure 5, the throughput line chart of the model. As shown in Figure 5, the throughput increases at nine seconds until 27, then reaches the highest throughput rate between 27 and 29 through the simulation scenario. The x-axis is the time, and the y-axis is the throughput.

4.5 Packet delivery ratio:

Using the awk script to calculate the packet delivery ratio, we obtained the sent and received packets with the dropped packets, which are lost packets [2]. The details in Table 2 show the result of the script.

Variable	Value
Sent packets	9615
Received packets	3939
Forwarded packets	2493
Dropped packets	5735
Packet Delivery Ratio	0.409672

Ahmad Sabah, Ahmet Zengin Comparative Study of Wireless Network Protocols using Ns-2 Network Simulator



Figure 5. Throughput per time

Our model shows a 41% delivery ratio with 59% loss packets, 9615 packets sent, and 3939 packets received. The lost packets are 5735 packets. Thus, packets were in nodes (0,2,3 and 5). The graph in Figure 6 shows us that the lost packets were extremely high according to the sent and received packets.





Figure 7. Node0 dropped packets by time.

In Figure 6, we can have a lot of dropped packets since the network nodes send 9615 packets and only 3939 packets are received; this affects the total dropped packets to be increased to 5735 dropped packets and only 2493 forward packets are transferred.

The graphs Figure 7-10 indicate the dropped packets in (Node0, Node2, Node3, and Node5, and the total dropped packets) in all nodes together) Through the simulation time, we can see that the number of dropped packets increases with the increase in simulation time. The highest dropped packet was node2, as shown in Figure 8.

Figure 7 shows the dropped packets in Node0, representing the node with fewer dropped packets than the others.

Figure 8 shows the first node of two nodes with a maximum dropped packets in our scenario, node2, and this node performs the highest drop packet rate among all nodes in our simulation scenario.





Figure 8. Node2 dropped packets by time.



Figure 9 depicts the rate of packet drops for node 3, which was moving in the middle of the simulated scenario and had a decent effect on a mobile node with this rate of packet loss.



Figure 10. Node5 dropped packets by time.

Figure 11. Dropped packets by node.

Figure 10 depicts the rate of missed packets for node 5, which serves as the study's focal point for the simulation scenario, as it moves away from and draws closer to the rest of the nodes.



Figure 12. The residual energy of a node

Figure 11 shows the total rate of dropped packets for each node in our simulation scenario. Node 2 has the greatest rate of dropped packets, more than 5000, which means it performs 95 percent of the drooped packets in the entire scenario time, with 5735 total drooped packets in our simulation scenario.

4.6 Residual energy of a node

The utility model represents the energy level of network nodes [11]. The initial value of the power model set on a node is the node's power level at the beginning of the simulation. İlkEnerji_ is the name of energy. The different "energy" in the simulation represents the energy level at each moment. The initialEnergy_ value is given as an input parameter. Every packet delivered and received causes a node to lose a certain amount of energy. As a result, the initial Energy_ value in a node decreases. The current energy value in a node after receiving or transmitting routing packets is known as residual energy. Data transmission between nodes is established using a UDP agent and CBR traffic. The residual energy of the node is determined by accessing the inbuilt variable "energy" in the findEnergy function at various points, and the script (resenergy.awk) yields the following result. From Figure 12, we can see that node1 and node4 have the highest residual energy compared to the other nodes, and node2 has the lowest residual energy.

5. Discussion and Conclusions

In this study, NS-2 is used to simulate a wireless scenario. TCP and UPD protocols are used, and FTP and CBR applications are attached to the protocols. The loss packets and total sent and received packets with the instant and average throughput are calculated residual energy for each node are calculated, dropped packets and thruput and residual energy were plotted using Gnuplot tool and excel, packet delivery ratio was 41% with 59% loss packet, Network Congestion causing more drop packets. When network traffic reaches its maximum, the packet must wait to be sent. Unfortunately, packets are first thrown when the network tries to capture traffic, and the connection can only do so much. Fortunately, most software today can automatically resend lost packets or slow down the transmission rate to give each packet a chance to be received.

6. Declarations

6.1 Study Limitations

Data (preliminary results of the system, limited number of volunteer data).

6.2 Acknowledgements

The authors thank researchers and students for their contributions to Sakarya University.

6.3 Funding source

There is no funding source.

6.4 Competing Interests

There is no conflict of interest in this study.

6.5 Authors' Contributions

All authors: developing ideas for the research, planning the materials and methods to reach the results, taking responsibility for the experiments, organizing and reporting the data, taking responsibility for the explanation and presentation of the results, taking responsibility for the literature review during the research, taking responsibility for the creation of the entire manuscript, reworking not only in terms of spelling and grammar but also intellectual content or other contributions.

References

- [1] A. A. K. Mohammad, and A. M. Abdul, "Optimised reactive resource aware routing for wireless infrastructure-less networks," *International Journal of Computer Applications in Technology*, vol. 72, no. 2, pp. 131-138, 2023.
- [2] J. Bienik *et al.*, "Impact of Packet Loss Rate on Quality of Compressed High Resolution Videos," *Sensors*, vol. 23, no. 5, pp. 2744, 2023.
- [3] C. A. G. d. Silva, and E. L. d. Santos, "A Compensation Model for Packet Loss Using Kalman Filter in Wireless Network Control Systems," *Energies*, vol. 16, no. 8, pp. 3329, 2023.
- [4] P. Kumar *et al.*, "CyberGuard: A Fortified Message Authentication Protocol with Digital Signatures in NS-2 Simulation Environment," *Scalable Computing: Practice and Experience*, vol. 26, no. 1, pp. 114-122, 2025.
- [5] S. Jahanbakhsh Gudakahriz *et al.*, "Link life time and energy-aware stable routing for MANETs," *International Journal of Nonlinear Analysis and Applications*, 2025.
- [6] A. Mhmood, and A. Zengin, "Performance Evaluation of MANET Routing Protocols AODV and DSDV Using NS2 Simulator," Sakarya University Journal of Computer and Information Sciences, vol. 4, no. 1, pp. 1-10, 2021.
- [7] M. Casquilho *et al.*, "Acceptance sampling in Quality Control: from theory to the Web: In PHP, Python, and gnuplot." pp. 1-6.
- [8] B. Zoradia, and G. Indumati, "Comparison Of Software Defined Networking With Traditional Networking Using Ns2 SimulatoR," *International Journal on Information Technologies & Security*, vol. 15, no. 3, 2023.
- [9] Q. Monnet, and L. Mokdad, "Chapter 28 DoS detection in WSNs: Energy-efficient designs and modeling tools for choosing monitoring nodes," *Modeling and Simulation of Computer Networks and Systems*, M. S. Obaidat, P. Nicopolitidis and F. Zarai, eds., pp. 795-840, Boston: Morgan Kaufmann, 2015.
- [10] "Ns2 versus Ns3 Comparison between Ns2 and Ns3.."
- [11] J. U. Kim *et al.*, "A Simple but Accurate Estimation of Residual Energy for Reliable WSN Applications," *International Journal of Distributed Sensor Networks*, vol. 11, no. 8, pp. 107627, 2015.



 \odot 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) license (https://creativecommons.org/licenses/by/4.0/)



Research articleJournal of Smart Systems Research (JOINSSR) 6(1), 11-27, 2025Recieved: 27-Feb -2025Accepted: 15-May-2025https://doi.org/10.58769/joinssr.1647818



Hafif Elektrikli Araçlarda Yol Koşullarının Enerji Tüketimi Üzerindeki Etkisi: Modelleme, Simülasyon ve Analiz

Mustafa ESEN^{1*} ^(D), Barış BORU ²

¹ Elektrik Elektronik Mühendisliği, Lisansüstü Eğitim Enstitüsü, Sakarya Uygulamalı Bilimler Üniversitesi, Sakarya, Türkiye. mustafaesen752@gmail.com
² Mekatronik Mühendisliği, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi,

Sakarya, Türkiye. barisb@subu.edu.tr

ÖΖ

Bu çalışmada, hafif elektrikli araçların farklı yol güzergâhlarındaki enerji tüketimi, sürüş dinamiklerine bağlı olarak analiz edilmiş ve araç bataryasının tepkisi deneysel sonuçlarla karşılaştırılmıştır. Çalışma kapsamında elektrikli aracın batarya paketi ve motoru için kapsamlı bir Simulink modeli geliştirilmiş ve bu model aracılığıyla farklı yol güzergâhlarındaki enerji tüketimi değişimleri incelenmiştir. Gerçekleştirilen simülasyonların deneysel veriler ile karşılaştırılması sonucunda, modelin %96-99 doğruluk oranına sahip olduğu görülmüştür. Ani hızlanmalar ve yavaşlamaların batarya verimi üzerinde belirleyici olduğu tespit edilmiştir. Ayrıca, sürüş profiline uygun batarya paketi seçimlerinin, toplam enerji verimliliği açısından kritik olduğu belirlenmiştir. Elde edilen sonuçlar doğrultusunda, hafif elektrikli araçların kullanım güzergâhlarına özel enerji yönetim stratejilerinin geliştirilmesi gerektiği önerilmektedir. Batarya ve motor seçimlerinin optimize edilmesi sayesinde, enerji tüketimi azaltılmakta ve araçların genel verimliliği artırılabilmektedir. Böylece, elektrikli araçların daha uzun menzil sunması ve kullanımının yaygınlaşması sağlanabilecektir.

Anahtar Kelimeler: Hafif elektrikli araçlar, enerji tüketim analizi, modelleme, batarya paketleri.

*Sorumlu Yazar e-postası: mustafaesen752@gmail.com

Cite as: Esen, M. & Boru, B. (2025). Hafif Elektrikli Araçlarda Yol Koşullarının Enerji Tüketimi Üzerindeki Etkisi: Modelleme, Simülasyon ve Analiz, *Journal of Smart Systems Research*, 6(1), 11-27. <u>https://doi.org/10.58769/joinssr.1647818</u>

Creative Commons Attribution 4.0 International (CC BY 4.0) license (https://creativecommons.org/licenses/by/4.0/)

The Effect of Road Conditions on Energy Consumption in Light Electric Vehicles: Modeling, Simulation and Analysis

ABSTRACT

In this study, the energy consumption of light electric vehicles over various road routes was analyzed based on driving dynamics, and the response of the vehicle battery was compared with experimental results. A comprehensive Simulink model was developed for the battery pack and motor of the electric vehicle, through which energy consumption variations across different road routes were examined. When the simulations were compared to actual data, the model's accuracy rate was found to be between 96 and 99%. For overall energy efficiency, it was found that choosing a battery pack that fits the driving profile is essential. Based on the findings, it is recommended that energy management strategies specific to the operating routes of light electric vehicles be developed. Accordingly, by optimizing battery and motor selection, energy consumption can be minimized, and the overall efficiency of the vehicles can be enhanced. Thus, electric vehicles will be able to offer longer driving ranges, and their widespread use can be promoted.

Keywords: Light electric vehicles, energy consumption analysis, modeling, battery packs.

1. Giriş

1800'lü yıllarda icat edilen elektrikli araçlar (EV), 1900-1912 yılları arasında en parlak dönemini yaşamış, ancak 1921-1960 yılları arasında içten yanmalı motorlu (İYM) araçların yaygınlaşmasıyla neredeyse tamamen ortadan kalkmıştır. 1960-1990 yılları arasında ise sınırlı sayıda da olsa yeniden ortaya çıkmıştır. Elektrikli araçlar, 1990 sonrasında yakıt tasarrufu ve çevre koruma ihtiyaçları doğrultusunda gelişen yeni batarya teknolojileriyle tekrar önem kazanmaya başlamıştır [1, 2]. Elektrikli araçların erken dönemdeki rekabet üstünlüğünü kaybetmesine neden olan eksiklikler henüz tamamen aşılamamıştır. Güç elektroniği ve mikroelektronik alanındaki önemli ilerlemeler, elektrikli araçlarda güç aktarma organlarını (elektrik motoru ve inverter) içten yanmalı motorlu araçların güç aktarma organları (aks ve diferansiyel) ile rekabet edebilmesini sağlamaktadır. Son yıllarda batarya teknolojisinde önemli bir ilerleme olmamasına rağmen, malzeme ve üretim teknolojilerinin gelişimi, gelişmiş batarya sistemi hedeflerine ulaşmak için umut vadetmektedir. Elektrikli araçların düşük güçlerde kullanılabilmesi ve bununla birlikte enerji tasarrufu sağlamaları, kullanım sırasında çevreyi kirletmemeleri ve yüksek teknolojik donanıma sahip olmaları sayesinde otomobillerin gelişim trendini belirleyen günümüzdeki en değerli ulaşım araçları haline gelmiştir [3]. Şekil 1'de elektrikli araç satışlarının içten yanmalı motorlu araç satışlarının içten yanmalı



Şekil 1. Elektrikli ve İYM Araç Satışı ve Gelecek Tahmini [4]

Elektrikli otomobillerin yaygınlaşması, 2010'lu yıllardan itibaren hız kazanmıştır ve küresel elektrikli binek araç stoğu, 2018 yılında bir önceki yıla göre %63 artarak 5 milyonun üzerine çıkmıştır. 2018 yılı itibariyle yollardaki elektrikli otomobillerin yaklaşık %45'i Çin'de bulunurken, Avrupa, küresel filonun %24'ünü, ABD ise %22'sini oluşturmaktadır. Elektrikli otomobil pazarı henüz gelişim aşamasında olsa

da 21. Yüzyılda elektrikli araçlar daha güçlü bir şekilde yeniden dikkatleri üzerine çekmiştir [4, 5]. Şekil 2'de elektrikli araç filosunun (BEV: Batarya Elektrikli Araç, PHEV: Plug-in Hibrit Elektrikli Araçlar) dünya üzerindeki dağılımı gösterilmektedir.



Şekil 2. Elektrikli Araç Filosunun Dünya Üzerindeki Dağılımı [5]

2040 yılına gelindiğinde, trafikteki toplam araç sayısının %58'inin elektrikli araçlardan oluşacağı öngörülmektedir [6]. Elektrikli araçların gelişimi ve sunduğu avantajlar elektrikli araçların günümüzde birçok alanda kullanılmasının önünü açmaktadır. Özellikle de şehir içi ulaşım ve lojistik alanlarında hafif elektrikli araçların kullanımı da popüler hale gelmektedir. Literatürde, hafif elektrikli araçlar genellikle "Light Weight Electric Vehicles" (LEV) olarak adlandırılmaktadır. LEV terimi; elektrikle çalışan, şehir içine uygun düşük hızda hareket eden ve çoğunlukla elektrikli araçlardan daha hafif yapıya sahip ve daha düşük güçlerde motorlar ile çalışabilen araçları tanımlamaktadır [7]. Uluslararası araç sınıflandırmalarında L7 kategorisi altında tanımlanan, hafif elektrikli araçlar, kendi içerisinde birçok alt kategoriye ayrılmaktadır. Bu çalışmada kullanılan araç modeli de L7e-A1 sınıfına ait hafif bir elektrikli araçtır.

Araç bileşenlerinin tasarımları; araç fiziksel özellikleri, kısıtları ve hedefler doğrultusunda yapılarak deneysel araç testlerinin ardından üretim aşamasına geçirilirler. Elektrikli araçlarda önemli unsur olan enerji tüketimleri ve verim testleri laboratuvar ortamında yapılabilmektedir. Laboratuvar test sonuçlarının doğruluğu çok fazla sayıdaki parametrenin veya sistemin ölçülmesi ve deneysel verilerin doğru bir şekilde kaydedilip işlenmesine bağlıdır. Gerekli olan testler için birçok donanıma sahip, araç test stantlarına ihtiyaç duyulmaktadır [8]. Yapılan testlerin ardından, araçların laboratuvar ortamında test edilmeleri ile birlikte sistemlerin hedeflenen değerler açısından uygunluğu kontrol edilmekte ve gerekliyse tasarımları revize edilmektedir.

Elektrikli araçlarda yapılan çalışmalar, genel olarak araçların; mekanik, elektrik ve elektronik teknolojisi üzerine yoğunlaşmaktadır. Ticari amaçlı yapılan çalışmaların yanı sıra alanda yapılan akademik çalışmaların başında batarya ve şarj sistemleri gelmektedir. Mevcut literatürde birçok çalışmada şarj yöntemleri incelenmekte ve geliştirilmektedir [9, 10]. Ayrıca elektrikli araçlarda batarya paketlerinin hızlıca bitmesinin önüne geçmek ya da şarj sürelerini kısaltacak çalışmalar yaparak hızlı şarj üzerine odaklanan çalışmalar yapılmaktadır [11].

Hamid Khayyam ve Alireza BabHadiashar, Plug-in Hybrid elektrikli araçlar için akıllı enerji yönetim sistemi geliştirmektedir. Makalelerinde, yapılan bu çalışmaya benzer şekilde farklı yol koşulları için bir dizi verisi oluşturarak hata tahminine dayalı bir hibrit öğrenme algoritması oluşturmaktadır. Böylece sistem çalışma sırasında öğrenir ve uygun ayarlamalar yapabilmektedir [12].

Elektrikli araçlar eğimli yollarda kullanılırken güç talebinin fazla olması dolayısıyla pillerin şarj ve

deşarj süreçleri etkilenmektedir. Xiangrui Zeng ve Junmin Wang tarafından yapılan çalışmada engebeli yerlerde kullanılan hibrit elektrikli araçların konumunu, seyahat yönünü ve bölgenin arazi bilgilerini kullanarak stokastik model tahminine dayalı kontrol tabanlı enerji yönetim sistemi stratejisi önerilmektedir. Böylece stokastik yakıt tüketimi ve batarya SOC modellemesi geliştirerek yüksek performanslı daha iyi bir enerji tüketimi sağlanması hedeflenmektedir [13].

Haluk Altay ve Haydar Livatyalı, 2021 yılında hafif elektrikli araçlar için bir çalışma gerçekleştirerek, elektrikli araç modeli içeren bir makale yayımlamışlardır. "Elektrikli Araçlar İçin Bir Şasi Dinamometresi Tasarımı" başlıklı çalışmada, Matlab & Simulink ortamında benzer bir sistem modeli oluşturulmuş ve simülasyonu gerçekleştirilmiştir [8]. Çalışmada dikkat çeken önemli noktalardan biri, elektrikli araç dinamiklerinin benzetim yoluyla analiz edilmesidir.

Ahmad Zaid Syakir Mohd Yazsid ve arkadaşlarının 2024 yılında gerçekleştirdiği çalışmada, elektrikli scooterların menzilini artırmak amacıyla kullanıcı giriş sinyali üzerine bir akım sınırlayıcı entegre edilerek, bataryadan motora aktarılan akımın azaltılması ve böylece enerji tüketiminin düşürülmesi hedeflenmiştir. Modelleme ve simülasyon çalışmaları MATLAB-Simulink ortamında gerçekleştirilmiştir [14]. Yapılan çalışmadan yararlanılarak, model oluşturma sürecinde araç gövdesi bloğu, tekerlek bağlantıları ve batarya paketi bağlantılarının tasarlanması ve sistemin doğru bir şekilde modellenmesi aşamalarında önemli destek alınmıştır.

Elektrikli araçlarda son yıllarda gelişim gösteren rejeneratif frenleme sistemi, hibrit ve elektrikli araçların enerji verimliliğini artırmak ve fren aşınmasını azaltmak için kritik bir teknolojidir. Elektrikli araçlarda enerjinin geri kazanımı üzerine yapılan çalışmalar, genellikle frenleme sırasında kaybedilen kinetik enerjinin geri kazanılmasına yöneliktir. Yalım Özçağlayan 2024 yılında MATLAB Simulink'te rejeneratif bir fren sistemine sahip olan hibrit bir aracın simülasyonunu gerçekleştirerek, rejeneratif frenlemenin sağladığı performans ve verimlilik kazanımlarını değerlendirmiştir [15]. Enerjinin geri kazanımına yönelik yapılan çalışmalar, rejeneratif frenlemenin sürdürülebilir ulaşım ve enerji yönetimi açısından önemli katkılar sunduğunu göstermektedir. Ancak, araçların enerji tüketimi yalnızca frenleme süreçlerinden değil, aynı zamanda sürüş koşullarından da etkilenmektedir.

Bu çalışma ile mevcut literatüre katkı sunacak Hafif Elektrikli Araçların enerji tüketim hesaplamalarını gerçekleştiren ve motor-batarya üzerindeki anlık ve toplam etkilerini analiz etme imkânı sunan bir model geliştirilmiştir. Geliştirilen model, 3 farklı pistte gerçekleştirilen yol testlerinde ölçülen veriler ile karşılaştırılarak modelin performansı ölçülmüştür. Çalışmaların çıktısı olarak hazırlanan makalenin 2. Bölümünde; modellenen aracın özellikleri ortaya konarak, geliştirilen model detaylandırılarak kullanılan bloklar açıklanmıştır. 3. Bölümde 3 farklı pist verileri ile birlikte yapılan simülasyonlar sunulmuştur. Son Bölüm olan 4. Bölümde elde edilen sayısal sonuçlar sunularak değerlendirilmiştir.

2. Materyal ve Yöntem

Deneysel çalışmaların modellenmesinde, Sakarya Uygulamalı Bilimler Üniversitesi bünyesinde faaliyet gösteren SUBÜ-TETRA kulübü tarafından enerji verimliliği yarışları için geliştirilen ve Şekil 3'te gösterilen Revolt EVO isimli elektrikli araç kullanılmıştır. Model, Revolt-EVO elektrikli aracına özgün olarak tasarlanmış olup, aracın özelliklerini taşımaktadır. Tasarlanan model Matlab & Simulink programı kullanılarak hazırlanmıştır. Model, bahsedilen aracın yarışacağı yarışma koşulları dikkate alınarak hazırlanmıştır. Belirli hız, güç ve batarya gerilimi sınırlarına dikkat edilmiştir. Modelin doğruluğu, daha önce elde edilen deneysel verilerle karşılaştırılarak ispatlanmıştır. Daha sonra elektrikli araçlar için kullanılabilirliği gösterilmiştir. Oluşturulan modelde araç sürücüsü dahil, itki gücüne sahip tekerleklerine kadar bütün sistemler yer almaktadır. Revolt EVO aracının hem tek motorlu hem de çift fırçasız doğru akım motoru (FDAM) motorlu modelleri tasarlanmıştır. Yapılan çalışmada, araç çift

motorlu konfigürasyona sahip olacak şekilde modellenmiştir.



Şekil 3. Revolt EVO Hafif Elektrikli Aracı

Gerçekleştirilen çalışmada, batarya, motor ve mekanik sistemleri içeren bir araç modeli oluşturularak, güzergâh değişikliklerinin enerji tüketimi ve performans üzerindeki etkilerini değerlendirmek amacıyla deneysel çalışmalar yapılmıştır. Modelde oluşturulan pist güzergâhlarının güç tüketimi üzerindeki etkileri, Revolt-EVO elektrikli aracının deneysel verileri ile karşılaştırılarak incelenmiştir. Sonuçlar doğrultusunda, gerilim seviyesinin artırılması durumunda; güç tüketiminde artış ya da azalış, düşürülmesi durumunda ise aracın hedeflenen hız ve menzile ulaşma ya da ulaşamama durumu incelenmiştir. Şekil 4'te Revolt EVO hafif elektrikli araç modeli gösterilmektedir.

Mustafa Esen, Barış Boru Hafif Elektrikli Araçlarda Yol Koşullarının Enerji Tüketimi Üzerindeki Etkisi: Modelleme, Simülasyon...



Şekil 4. Revolt EVO Hafif Elektrikli Araç Modeli

Oluşturulan modelde yer alan blokların kullanım şekilleri, aşağıdaki şekiller ve açıklamalar ile detaylandırılmaktadır.

Şekil 5'te gösterilen "Boylamsal sürücü" bloğu, araç şoförünü temsil etmektedir. Sürücü bloğunun "VelRef", "VelFdbk" ve "Grade" olmak üzere üç adet girişi bulunmaktadır. "VelRef", hedef hız-zaman bilgisini sağlarken, "VelFdbk" hız-zaman geri beslemesini, "Grade" ise yol eğimi bilgisini temsil etmektedir. "VelRef" sinyali ile "VelFdbk" sinyali arasındaki fark dikkate alınarak sürücünün hızlanma (AccelCmd) veya yavaşlama (DecelCmd) komutları oluşturulmaktadır [16]. Boylamsal sürücü bloğundaki referans geri bildirim verileri dikkatlice seçilmiştir; aksi takdirde hatalı sonuçlar ortaya çıkabilmektedir. Blok ayarlaması yapılırken girilen veriler, elektrikli araçlar için genellikle km/h veya m/s gibi birimlerden oluşmaktadır. Ancak farklı bir modellemede kullanıldığında birimler değişiklik gösterebilmektedir.



Şekil 5. Boylamsal Sürücü Bloğu

Çalışmada, üç farklı pist üzerinden modelleme çalışması gerçekleştirilmiş olup, güzergâhlar Şekil 6'da gösterilmektedir. Güzergâhlara bağlı oluşan hız-zaman bilgisini içeren grafikler Şekil 7'de gösterilen "Sinyal oluşturucu" bloğu ile elde edilmiştir. Hız-zaman grafikleri, güzergâhlarda yapılan deneme sürüşleri sonucunda elde edilmiştir. Şekil 7'de de gösterilen sinyal oluşturucu bloğu, aslında parçalı doğrusal yapıda değiştirilebilir sinyal grupları oluşturmaya yardımcı olmaktadır [17]. Ancak modelde, araç sürücüsünün kullanabileceği güzergâh ve hız bilgisi oluşturmak amacıyla kullanılmıştır. Ayrıca, "Sinyal oluşturucu" bloğu sayesinde çoklu sinyal değişimleri bir Excel tablosunda hazırlanarak sisteme entegre edilebilmektedir.





Şekil 7. Sinyal Oluşturucu Bloğu

Şekil 8'de hız-zaman grafiği gösterilen A pisti, 1950 metre uzunluğunda olan ve sürekli saat yönünde dönüşlerin bulunduğu bir güzergâhtır. Revolt-EVO elektrikli aracıyla yapılan deneysel çalışmalar, A

pisti üzerinde 1 saat içerisinde 30 tur tamamlanacak şekilde gerçekleştirilmiş ve böylece toplamda 59,5 km'lik bir mesafe kat edilmiştir.



Şekil 8. A Pistinin Hız-Zaman Grafiği

Şekil 9'da hız-zaman grafiği gösterilen B pisti, 1350 metre uzunluğunda olup 3 dakikada tamamlanacak şekilde deneysel çalışmalar gerçekleştirilmiştir. B pistini, A pistinden ayıran en temel fark, daha kısa süreli bir sürüşe sahip olması ve farklı noktalarda aracın tamamen durup yeniden harekete geçmesini gerektiren bir sürüş dinamiğine sahip olmasıdır. Bahsedilen senaryoda, özellikle şehir içi trafiğini taklit eden bir "dur-kalk" sürüş modeli temsil edilmektedir.



Şekil 9. B Pistinin Hız-Zaman Grafiği

Şekil 10'da hız-zaman grafiği sunulan C pisti, 420 metre uzunluğunda olup, deneysel çalışmalar her biri yaklaşık 1 dakika süren 13 tur üzerinden gerçekleştirilmiştir. Böylece, toplam 5460 metre uzunluğunda bir sürüş güzergâhı elde edilmiştir.



Şekil 10. C Pistinin Hız-Zaman Grafiği



Şekil 11. FDAM ve Motor Sürücü Devresi Bloğu İç Yapısı

Şekil 11'de gösterilen FDAM ve motor sürücü devresi bloğu iç yapısı, iki adet firçasız doğru akım motorunun (BLDC 1 ve BLDC 2) kontrolünü gerçekleştiren iki ayrı sürücü yapısını içermektedir. Her bir motor, bağımsız olarak kontrol edilen sürücüler üzerinden beslenmektedir.

Modelde yer alan "Kontrollü Voltaj Kaynağı1" ve "Kontrollü Voltaj Kaynağı2" blokları, motor sürücülere uygulanan gerilim sinyallerini üretmektedir. Gerilim kaynakları PWM modülasyon yoluyla kontrol edilmekte ve motorların hız/tork çıktıları üzerinde etkili olmaktadır [18].

FDAM'lerin sürülmesi, dört temel sinyalle çalışan bir sürücü bloğu aracılığıyla gerçekleştirilmektedir. "Motor Sürücü" bloğu; "REF", "REV", "BRK" ve "PWM" olmak üzere dört farklı giriş sinyaline sahiptir. "REF" girişi, motorun dönme hızını belirleyen referans sinyalini ifade ederken; "REV" sinyali, motorun dönme yönünü tersine çevirmek amacıyla kullanılmaktadır. "BRK" girişi ise, motorun frenleme moduna geçmesini sağlayan bir komut sinyalidir. Son olarak "PWM" sinyali, motor sürücüsüne uygulanan darbe-genişlik modülasyonlu kontrol sinyali olup, motorun besleme gerilimini düzenleyerek istenen performans karakteristiğini elde etmeye yardımcı olmaktadır [19].

Modelde kullanılan "Çözücü Yapılandırması (f(x) = 0)" bloğu, sabit sıfır değerini üretmekte olup, hem sistem toprağına (GND) hem de motor sürücülerinin ters yön girişine (REV) bağlanmıştır. Oluşturulan yapı sayesinde motorun ters yönde çalışması yazılımsal olarak engellenmiş ve yalnızca ileri yönde çalışmasına izin verilerek, kontrol yapısı sadeleştirilmiştir.

Aracın firçasız doğru akım motorlarının parametreleri "BLDC Motor 1" ve "BLDC Motor 2" bloklarına tanımlandıktan sonra motorlardan üretilen mekanik güç aks ve diferansiyel gibi güç aktarma organları olmadan doğrudan tekerleklere iletilmiştir. Elektriksel güç bağlantısı ise batarya paketine bağlanarak sağlanmıştır.

Araç tekerleğinin yarıçapı, "Pacejka lastik modeli" blokları içerisinde yer alan geometri sekmesinde 0,28m olarak tanımlanmış ve Revolt EVO modeline uygun şekilde belirlenmiştir. Simüle edilen aracın fiziksel ölçülerini içeren "Araç Gövdesi" bloğu ise simülasyon üzerinde doğrudan etkili bir bileşen olarak yer almaktadır. Blok içerisine; aracın ağırlığı, sürtünme katsayısı, ağırlık merkezinin ön ve arka tarafa olan mesafesi, zemine olan uzaklığı ve ön yüzey alanı gibi kritik parametreler tanımlanabilmektedir.

Araç gövdesine ait değerler "Araç Gövdesi" bloğuna tanımlandıktan sonra, firçasız doğru akım motoruna bağlı olan lityum iyon batarya paketi ve ilgili parametreler sisteme eklenmiştir. Söz konusu parametreler, aracın batarya paketine ait teknik özellikleri içermektedir. "Batarya Paketi" bloğu içerisinde; kullanılan pil türü (Lityum-İyon, Kurşun-Asit, Nikel-Metal-Hidrit, Nikel-Kadmiyum), batarya paketinin nominal gerilim ve akım değerleri ile şarj durumu tanımlanmaktadır [20]. Batarya paketlerinin hem sağlıklı hem de uzun ömürlü bir şekilde kullanılabilmesi için belirli bir gerilim seviyesinin altına düşülmemesi gerekmektedir. Modelde yer alan "Batarya Paketi" bloğu kullanılan bataryaya göre gerilim seviyesini otomatik olarak ayarlamaktadır.

Batarya bloğunun çıkışına bataryanın, akım, gerilim ve SOC (State of Charge) durumunu izlemek amacıyla "Bus Selector" (veri yolu seçicisi) bloğu eklenmiştir. Böylece batarya paketinin çıkış verileri olan SOC, akım ve gerilim değerleri seçilerek izlenebilir hale getirilmiştir.

Modelde yer alan tüm bloklar belirlenen değerlere göre tanımlandıktan sonra, simülasyon sonuçlarını görüntülemek için blokların çıkışlarında sonuç bölümleri oluşturulmuştur. Sonuçların bölümü, Simulink programının matematiksel blokları kullanılarak gerçekleştirilmiştir. Araç gövdesi ve rota bloklarına bağlı olarak, modelde aracın anlık hızını hesaplayan, hızlanma grafiğini gösteren ve katedilen toplam mesafeyi belirleyen model blokları Şekil 12'de gösterilmektedir.



Şekil 12. Araç Hızını ve Alınan Yolu Hesaplayan Blok

Şekil 13'te aracın modeli simüle edilirken, anlık olarak bataryadan çekilen akım, gerilim ve SOC (State Of Charge) değerleri hesaplanarak izlenebilmektedir. Bunların yanı sıra, aracın simülasyon boyunca katettiği mesafede harcanan toplam enerji miktarı da hesaplanmaktadır.



Şekil 13.Batarya Paketi Verilerini Hesaplayan Blok

Modelde yer alan bütün blokların parametreleri girilmiştir. Simülasyon sonuçları bölümünde model çıktıları değerlendirilmektedir.

3. Simülasyon Sonuçları

Simülasyon çalışmaları aracın değişebilecek güzergâhları üzerine gerçekleştirilmiş olup, sonuçlar güzergâhlara göre değişiklik göstermektedir.

İlk simülasyon, Revolt-EVO aracının daha önce yarıştığı A pistine ait verilere dayanarak gerçekleştirilmiştir. Yarış süresi 1 saat olacak şekilde belirlenmiş olup, zamana bağlı olarak hızlanma ve yavaşlama eğrisi oluşturulmuştur. A pistinin güzergâh yapısı dikkate alındığında, araç kalkıştan sonra tam durma noktasına gelmeden, yaklaşık 50 km/h ile 60 km/h arasında sabit bir hız aralığında ilerlemiş ve sürenin sonunda durmuştur. A pistine ait olan güzergâhın hız-zaman grafiği Şekil 7'de, verilen hız-zaman grafiğine göre yapılan simülasyon sonucunda elde edilen hızlanma eğrisi ise Şekil 14'te gösterilmiştir.



Şekil 14. A pistinin Güzergahına Ait Simülasyon Sonucu Hızlanma Grafiği

A pistine ait güzergâh üzerinde gerçekleştirilen simülasyonda araç, tanımlanan hareket senaryosuna uygun şekilde ilerleyerek toplamda 59,58 km yol katetmiştir. Aşağıda yer alan şekillerde, aracın bir saatlik sürüşü boyunca batarya gerilimi, bataryadan çekilen akım, batarya doluluk oranı (SOC) ve toplam tüketilen enerjiye ilişkin değişimler gösterilmektedir.



Şekil 15. Batarya Paketinin Anlık Gerilim Seviyesi

Şekil 15'te yer alan batarya paketinin anlık gerilim seviyesini gösteren grafik incelendiğinde, sürüş süresi boyunca batarya geriliminin 84 V'den 66,45 V'ye kadar gerilediği görülmektedir. Simülasyon sonucunda araç, pist üzerinde yaklaşık olarak 60 km/h hızla aynı şekilde en fazla 3,9 dakika daha ilerleyebilmektedir. Ancak, aracın ilerlemesi durumunda batarya paketi tamamen tükenmektedir. Lityum iyon tabanlı pillerin olumsuz özellikleri tam olarak burada ortaya çıkmaktadır. Lityum iyon pillerin geriliminin 2.5 V'nin altına düşmesi, kimyasal yapıları gereği ömürlerinin kısalmasına neden olmaktadır.



Şekil 16. Batarya Paketinden Çekilen Anlık Akım Grafiği

Şekil 16'da 1 saatlik sürüş süresi boyunca aracın bataryadan çektiği akımın zamana bağlı değişimini göstermektedir. Grafik incelendiğinde sürüş profiline uygun olarak farklı zaman aralıklarında farklı tepkiler verildiği gözlemlenmektedir. Araç başlangıçta harekete geçerken bataryadan yaklaşık 40 A seviyelerine kadar çıkan yüksek bir akım çekilmiştir. Çekilen yüksek akım, elektrikli araçlarda sıkça karşılaşılan ilk kalkış anına özgü yüksek tork ihtiyacının bir sonucudur. Başlangıçta motorun ani enerji talebi nedeniyle batarya sisteminde kısa süreli bir yüklenme meydana gelmiştir. Güzergâhın ilerleyen bölümlerinde, yaklaşık 60. saniyeden itibaren bataryadan çekilen akım değeri kararlı bir düzeye ulaşmış ve genel olarak 10–15 A aralığında seyretmektedir. 60 ile 3500 saniye arasındaki zaman dilimi, aracın sabit hızda ilerlediği veya düşük ivmelenmeye sahip sürüş koşullarında seyrettiği normal çalışma sürecini yansıtmaktadır. Akım değerlerindeki küçük genlikli salınımlar, sürüş esnasında karşılaşılan eğim değişimleri veya geçici hızlanma/frenlemelerden kaynaklanmaktadır.

Grafikte de görüldüğü üzere, sürüşün son bölümünde akım değerinin negatif yönde değiştiği gözlemlenmektedir. Görülen negatif akım, yüzeysel olarak rejeneratif frenleme etkisi izlenimi yaratmaktadır. Ancak kullanılan motor sürücüsünün donanımsal yapısı ve kontrol algoritması göz önüne alındığında, sistemde rejeneratif enerji geri kazanımı mekanizması bulunmamaktadır. Başka bir deyişle, son bölümde gözlenen negatif akım değerleri yalnızca ölçüm sisteminin matematiksel tepkisinden veya araç yavaşlarken motorun yük karakteristiğinden kaynaklı oluşan bir yansımadır. Pratikte bataryaya enerji geri beslemesi yapılmamaktadır. Bu nedenle güzergâhın son bölümünde oluşan negatif akım değerleri yorumlanırken sistemin teknik sınırları göz önünde bulundurulmalıdır. Modelde sınırlandırma işlemi FDAM'lerin çıkışına "Saturation" bloğu eklenerek gerçekleştirilmiştir. "Saturation" bloğu sayesinde motorlardan çekilen akımın minimum seviyesi 0A olacak şekilde ayarlanmıştır. Maksimum çekilen akım ise sistemin çekeceği akımdan yüksek bir değerde ayarlanmıştır. Böylece negatif akım bileşenleri modelden çıkarılmış ve simülasyon çıktıları, deneysel koşulları daha doğru yansıtacak şekilde düzenlenmiştir. Şekil 17'de modele "Saturation" bloğu eklendikten sonra oluşan akım-zaman grafiği gösterilmektedir.







Şekil 19. Aracın Tükettiği Anlık Enerji Grafiği

Mustafa Esen, Barış Boru

Hafif Elektrikli Araçlarda Yol Koşullarının Enerji Tüketimi Üzerindeki Etkisi: Modelleme, Simülasyon...

A pistine ait güzergâh simülasyonunda araç 1 saat boyunca 2264.010 W enerji harcamıştır.

Yukarıdaki grafiklerden de görüleceği üzere, araç ilk kalkışta normal seviyeden daha fazla akım çekmektedir ve tam bu noktada bataryada ani bir gerilim düşüşü meydana gelmektedir. Sık sık durup kalkış yapmak elektrikli araçlar için en büyük olumsuzluklardan biridir. Günlük kullanımda araçlar, ani hızlanmalar ve yavaşlamaların yanı sıra sık sık durup tekrar hareket etmek zorunda kalabiliyor. Bahsedilen senaryoyu simüle edebilmek için aynı araç modeli kullanılarak B ve C pistlerinde oluşturulan güzergâhların simülasyonları gerçekleştirilmiştir. Ayrıca, güzergâhlara ait sonuçlar karşılaştırılarak analiz edilmiştir.

İkinci simülasyon, B pistinin güzergâhında Revolt-EVO aracının, şehir içi kullanımda karşılaşılabilecek kısa süreli günlük sürüş koşullarındaki performansını değerlendirmek amacıyla gerçekleştirilmiştir. B pistinde hem yavaşlama hem de durma senaryoları yer almaktadır. Simülasyonun süresi 3 dakika olarak belirlenmiş ve hız, 50 km/h'yi geçmeyecek şekilde ayarlanmıştır. B pistine ait güzergâh üzerinde gerçekleştirilen simülasyon sonucunda araç senaryo kapsamında öngörülen şekilde hareket ederek, 3 dakika boyunca değişken hızlarda ilerleyerek 1.384 km mesafe katetmiştir. 3 dakikalık süre zarfında batarya paketi 84V seviyesinden 77,14 V seviyelerine gerilemiştir.

Simülasyon sonucuna göre A pistinde sabit hızda bir saat boyunca 17.58 V gerilim düşümü meydana gelmişken, B pistinde değişken hızlarda yalnızca 3 dakikada 6.86V gerilim düşümü meydana gelmiştir. Simülasyondan elde edilen sonuçlar doğrultusunda elektrikli araçların çok sık hız değişimlerinde yüksek enerji harcadığı görülmektedir. B pistine ait güzergâh simülasyonunda araç 3 dakikada 135.202 W enerji harcamıştır.

C pistine ait olan güzergâhta (üçüncü simülasyon) ise, A ve B pistlerindeki senaryoların birleşimiyle 13 dakikalık bir sürüş simülasyonu gerçekleştirilmiştir. İki pistin senaryoları birleştirilerek ani hızlanma ve yavaşlamaların daha sık tekrar ettiği, daha zorlu bir sürüş deneyimi sunan bir güzergâh tasarlanmıştır. C pistinin güzergâhında araç bu kez 13 dakika boyunca değişken hızlarda ilerleyerek 5.598 km mesafe katetmiştir. 13 dakikalık süre zarfında batarya paketi 84 V seviyesinden 71,52 V seviyelerine gerilemiştir. C pisti güzergâhı ile A pisti güzergâhının simülasyon sonuçları karşılaştırıldığında ani hızlanmaların ne kadar etkili olduğu gözükmektedir. Araç, C pistine ait güzergâh simülasyonunda değişken hızlarla hareket ederek 13 dakikada toplam 556.418 W enerji harcamıştır. A pistinde ise yaklaşık olarak sabit hızda ilerleyerek bir saat içinde 59.58 km yol almış ve 2264.010 W enerji tüketmiştir. Simülasyonların sonuçları değerlendirildiğinde, aracın batarya ve motor sisteminin sabit hızda daha verimli çalıştığı gözlemlenmiştir.

Yapılan bütün test senaryoları pratikte daha önceden elde edilmiş olan veriler ile karşılaştırılarak yapılmıştır. Bunun sonucunda ortaya çıkan deneysel sonuçlar ile simülasyon sonuçları ve % hata değerleri Tablo 1'de verilmektedir.

	A Pisti Güzergâhı			B Pisti Güzergâhı			C Pisti Güzergâhı		
Parametre	Deneysel Sonuçlar	Simülasyon Sonuçları	% Hata	Deneysel Sonuçlar	Simülasyon Sonuçları	% Hata	Deneysel Sonuçlar	Simülasyon Sonuçları	% Hata
Katedilen Mesafe (km)	58.50	59.58	1.84	1.350	1.384	2.51	5.460	5.598	2.52
Harcanan Enerji (W)	2248	2264.010	0.71	131	135.202	3.20	538	556.418	3.42
Ort. Hız (km/s)	58.4	59.32	1.57	27.5	27.2	1.09	26.8	27.3	1.86

Tablo 1. Deneysel Sonuçlar ve Simülasyon Sonuçlarının Karşılaştırılması

4. SONUÇLAR

Bu çalışmada Sakarya Uygulamalı Bilimler Üniversitesi SUBÜ TETRA kulübünün TÜBİTAK Uluslararası Efficiency Challenge 2024 yarışları için tasarladığı Revolt-EVO adlı aracın elektrik motoru ve batarya paketi verileri kullanılmıştır.

Hafif elektrikli araçların farklı yol koşullarındaki enerji tüketimi analiz edilerek batarya ve motor performansları incelenmiş, elde edilen deneysel veriler simülasyon sonuçlarıyla karşılaştırılmıştır. Gerçekleştirilen analizler sonucunda oluşturulan Simulink modelinin sonuçlarının, deneysel verilerle büyük ölçüde uyumlu olduğu görülmüştür. Farklı pistler üzerinde gerçekleştirilen güzergâhlarda, sürüş profilinin enerji tüketimi üzerinde önemli etkilere sahip olduğu tespit edilmiştir. Özellikle ani hız değişimlerinin batarya verimi üzerinde belirleyici olduğu belirlenmiştir. Aynı zamanda, yapılan tüm simülasyonlarda aracın elektrik motorunun her hız değerinde yeterli olduğu ve gücünün istenilen performansı sağlayabildiği açıkça görülmüştür.

Çalışma kapsamında, elektrikli araç simülasyon testlerinde performans ve enerji tüketimini belirlemek amacıyla bir araç modeli oluşturulmuş, bu modelin içerisindeki donanımın kontrolü sağlanarak üç farklı rota için özel olarak tasarlanmış sürüş senaryoları başarıyla gerçekleştirilmiştir. Elde edilen simülasyon sonuclarının deneysel verilerle karşılaştırılması sonucunda, simülasyon modelinin yüksek doğrulukta sonuclar verdiği gözlemlenmistir. Model sonuclarında, katedilen mesafe, harcanan enerji ve ortalama hız gibi parametrelerde simülasyon ile deneysel veriler arasındaki başarı oranı %96 ile %99 arasında değişmektedir. Model sonuçlarına göre A pisti güzergâhında; katedilen mesafe %98.16, harcanan enerji %99.29, ortalama hız ise %98.43 doğrulukla tahmin edilmiştir. Benzer şekilde, B pisti güzergâhında; katedilen mesafe %97.49, harcanan enerji %96.80 ve ortalama hız %98.91 oranlarında başarı sağlanmıştır. C pisti güzergâhında ise; katedilen mesafe %97.48, harcanan enerji %96.58 ve ortalama hız %98.14 doğrulukla elde edilmiştir. İncelemeler sonucunda, modeldeki en büyük hata payının, hız ve ivme değişkenliğinin yüksek olduğu C pistinde oluştuğu tespit edilmiştir. Simulink'te kullanılan sabit zaman adımlı çözümleyici, kısa süreli ve ani dur-kalk olaylarını yeterli çözünürlükte temsil edememiştir. Özellikle C pistinde yaşanan yüksek frekanslı dinamik değişimlerin etkisi model tarafından baştırılmış ve deneysel ölçümlerle model tahminleri arasındaki fark artmıştır. Genel değerlendirme sonucunda, modelin yüksek oranda doğruluğa sahip simülasyonlar sunduğunu, ayrıca elektrikli aracın performansını doğru bir şekilde yansıttığını ortaya koymaktadır.

5. BEYANNAME

1.1 Teşekkür

Yazarlar, Sakarya Uygulamalı Bilimler Üniversitesi kapsamında çalışmalarına devam eden SUBÜ-TETRA elektrikli araç kulübüne, araştırmacılarına ve öğrencilerine desteklerinden ve katkılarından dolayı teşekkür eder.

1.2 Rakip Çıkarlar

Bu çalışmada herhangi bir çıkar çatışması yoktur.

1.3 Yazarların Katkıları

Mustafa ESEN: Araştırma ve bilimsel çalışma için temel hipotezin veya fikrin oluşturulması, deneysel süreçlerin yürütülmesi, deneylerden elde edilen verilerin analiz edilmesi, bulguların mantıklı bir çerçevede değerlendirilmesi ve sunulması konularında sorumluluk üstlenmek, araştırma sürecinde ilgili

literatürün taranması, yazının tamamının veya ana bölümlerinin oluşturulması, makalenin biçimsel ve içeriksel düzenlemesinin yapılması ve yayımlanmak üzere gönderilmesi süreçlerine katkıda bulunmak.

Barış BORU: Sonuçlara ulaşmak gerekli materyallerin planlanması, verilerin mantıklı bir şekilde düzenlenmesi, makale teslim edilmeden önce yalnızca dilbilgisi ve yazım açısından değil aynı zamanda akademik içerik yönünden de kapsamlı bir gözden geçirme ve revizyon süreci yürütmek.

KAYNAKÇA

- [1] C. C. CHAN, "An Overview of Electric Vehicle Technology", *IEEE*, 0018-9219/1993, <u>https://doi.org/10.1109/5.237530</u>.
- [2] Kocagöz, E., ve İğde, Ç. S., (2022), "Elektrikli araç satın alma niyetini hangi faktörler etkiler? Bir tüketici araştırması", *Kahramanmaraş Sütçü İmam Üniversitesi Sosyal Bilimler Dergisi*, 19(özel sayı), 104-120. https://doi:10.33437/ksusbd.1133892.
- [3] Efendioğlu, İ., H., "Elektrikli Araç Satın Alma Niyetini Etkileyen Faktörler", İstanbul Gelişim Üniversitesi Sosyal Bilimler Dergisi, 11 (1), Nisan 2024, ss. 106-122, <u>https://dx.doi.org/10.17336/igusbd.1124491</u>.
- [4] Gür, N. ve Furuncu, Y., (2019), "Küresel Otomobil Sektörünün Değişimi ve Yerli Otomobil Projesinin Geleceği", SETA Raporu, No. 127, <u>https://doi.org/10.47140/kusbder.714905</u>

- [6] Altunsoy, Ü., (2021), "Kargo Taşımacılık Sisteminde Elektrikli Araçlar Kullanımı Üzerine İnceleme", International Anatolia Academic Online Journal / Fen Bilimleri Dergisi, 7(2).
- [7] Clairotte, M., Zardini, A. A., & Martini, G., (2016), "Phase 1 of the Environmental Effect Study on the Euro 5 step of L-category vehicles- Stocktaking and data mining (EUR 27994 EN), European Commission", *Joint Research Centre*, <u>http://dx.doi.org/10.2790/428149</u>.

[8] Altay H. Ve Livatyalı H., "Elektrikli Araçlar İçin Bir Şasi Dinamometresi Tasarımı", *MATİM*, 2022;20(1):17-28.

- [9] Durmuş, F.S. ve Kaymaz, H., "Elektrikli Araç Şarj Yöntemleri", Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi, 2020.
- [10] Ban, M., Zhang, Z., Li, C., Li, Z., ve Liu, Y., "Optimal scheduling for electric vehicle battery swappingcharging system based on nanogrids", *International Journal of Electrical Power & Energy Systems*, 2021, https://doi.org/10.1016/j.ijepes.2021.106967.
- [11] Tören, M., ve Mollahasanoğlu, H., "Elektrikli ve Hibrit Araçlardaki Elektrik Motorlarının İçten Yanmalı Motorlarda Oluşan [CO] _2 Emisyonunda Meydana Getireceği Değişimin Tahmini ve Verimliliğe Etkisi: Türkiye Örneklemesi", *ECJSE*, vol. 9, no. 3, pp. 1082–1097, 2022, doi: <u>https://10.31202/ecjse.1107454</u>.
- [12] Khayyam, H., Bab-Hadiashar, A., "Adaptive intelligent energy management system of plugin hybrid electric vehicle" *Energy*, vol. 69, pp. 319-335, 2014, <u>https://doi.org/10.1016/j.energy.2014.03.020</u>.
- [13] Zeng, X., ve Wang, J., "A Parallel Hybrid Electric Vehicle Energy Management Strategy Using Stochastic Model Predictive Control with Road Grade Preview", *IEEE Transactions on Control Systems Technology*, vol. 23, pp. 2416-2423, 2015, <u>https://doi.org/10.1109/tcst.2015.2409235</u>.
- [14] Ahmad Zaid Syakir Mohd Yazsid, Kumar, K., ve Zulkifli, S., (2024). Investigation of range extension of personal electric mobility by current-limiting mechanism. "ICREEM 2022" doi: <u>https://doi.org/10.1007/978-981-99-5946-4_14</u>

^[5] IEA (2019), Global EV Outlook 2019, <u>https://www.iea.org/reports/global-ev-outlook-2019</u>, (07.01.2025).

- [15] Özçağlayan, Y., "MATLAB Simulink'te Bir P2 Hibrit Elektrikli Araç Modeli Oluşturma ve Rejeneratif Fren Sistemi Optimizasyonu", 15th National Conference on Electrical and Electronics Engineering (ELECO), 79-8-3315-1803-5/24/, 2024, <u>https://doi.org/10.1109/ELECO64362.2024.10847079</u>.
- [16] MathWorks, (2025), Longitudinal Driver, MATLAB & Simulink, Inc, <u>https://ww2.mathworks.cn/help/autoblks/ref/longitudinaldriver.html</u>, (10.04.2025).
- [17] MathWorks, (2025), *Signal Builder*, MATLAB & Simulink, Inc, <u>https://www.mathworks.com/help/simulink/ref_obsolete_blocks/signalbuilder.html</u>, (10.04.2025).
- [18] MathWorks, (2025), Controlled Voltage Source, MATLAB & Simulink, Inc, <u>https://www.mathworks.com/help/sps/powersys/ref/controlledvoltagesource.html</u>, (10.04.2025).
- [19] MathWorks, (2025), H-Bridge, MATLAB & Simulink, Inc, <u>https://www.mathworks.com/help/sps/ref/hbridge.html</u>, (10.04.2025).
- [20] MathWorks, (2025), *Battery*, MATLAB & Simulink, Inc, <u>https://www.mathworks.com/help/sps/powersys/ref/battery.html</u>, (10.04.2025).



 \odot 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) license (https://creativecommons.org/licenses/by/4.0/)



Research article Journal of Smart Systems Research (JOINSSR) 6(1), 28-44, 2025 Recieved: 13-Mar -2025 Accepted: 29-Apr-2025 https://doi.org/10.58769/joinssr.1657438



YOLOv11-based Detection of Wagon Brake Cylinder Conditions

Murat Erhan ÇİMEN^{1*} 问

¹ Electrical and Electronics Engineering, Faculty of Technology, Sakarya University of Applied Sciences

ABSTRACT

Railway transportation stands out as a safe and efficient mode of transport for both freight and passengers. However, failures in train braking systems pose financial and safety risks. In this study, it is proposed to use the recently introduced YOLOv11 (You Only Look Once) models to monitor the mechanical brakes used in wagons. This approach aims to prevent the locking of wheels due to stuck mechanical brakes while the train is in motion, thereby avoiding continuous metal friction and mitigating risks such as flatted wheels, wheel fractures, rail damage, and fire hazards. Such failures not only cause material damage and operational disruptions but also lead to potential loss of life and costly accidents. Traditional methods of manually inspecting brake cylinders provide limited safety and are inefficient in terms of operational effectiveness. Therefore, the automatic monitoring and fault detection of brake cylinders have become crucial. To achieve this, a dataset consisting of three different classes—braked, empty, and evacuated—was used. Using this dataset, YOLOv11n, YOLOv11s, YOLOv11m, YOLOv11l, and YOLOv11x models were trained. The performance of these trained models was evaluated based on accuracy, precision, recall, and F1 scores. The results indicate that the YOLOv11X model is more suitable for cases where reducing false negatives (FN) is critical. However, when minimizing false positives (FP) is a priority, YOLOv11m or YOLOv11s models are more appropriate. For an overall balanced performance, the YOLOv11X model is preferable for the braked condition, while YOLOv11s or YOLOv11m models are more suitable for the evacuated condition. Ultimately, this study demonstrates that the detection of braking mechanisms in trains with high accuracy using YOLOv11 models can significantly contribute to reducing train accidents, thereby preventing loss of life and costly incidents.

Keywords: YoloV11, Railway Safety, Brake Cylinder Detection, Workplace Safety.

* Corresponding Author's email: <u>muratcimen@subu.edu.tr</u>

Cite as: Çimen, M.E. (2025). YOLOv11-based Detection of Wagon Brake Cylinder Conditions, *Journal of Smart Systems Research*, 6(1), 28-44. <u>https://doi.org/10.58769/joinssr.1657438</u>

http://biyak.subu.edu.tr

Creative Commons Attribution 4.0 International (CC BY 4.0) license (https://creativecommons.org/licenses/by/4.0/)

1 Introduction

Railways are one of the fundamental pillars of modern transportation systems, offering significant economic, environmental, and logistical advantages. Evolving since the Industrial Revolution, railway transportation has remained a reliable and efficient option for both passenger and freight transport. During the Ottoman period, a total of 8,619 km of railways were constructed, of which 4,136 km remained within today's borders. In the Republican period, between 1923 and 1950, a total of 3,764 km of railways were put into operation. However, between 1951 and 2003, in parallel with the development of road networks and vehicles, there was no balanced growth in other transportation modes. As a result, the total length of railway lines constructed during the 1951-2002 period remained at 945 km. Since 2003, with the adoption of railways as a state policy, the railway network, which was 10,959 km in 2003, reached 13,919 km by the end of 2023 (Demiryolu Sektör Raporu, 2023). Figure 1 shows a steam train.

The transportation activities of passengers and cargo in Turkey for the years 2019, 2020, 2022, 2021, 2022, and 2023 are presented in Table 1 below. In 2023, passenger transportation increased by 7% compared to 2022, reaching 342.5 million passengers (including YHT, Conventional, Marmaray, Izban, Baskentray, and Gaziray). The number of passengers transported by YHT was 9.36 million in 2022, increasing to 11.86 million by the end of 2023. In freight traffic, there was a 19% decrease compared to the previous year, reaching a value of 13.1 billion ton-km in 2023. The total freight transported in 2023 amounted to 32.4 million tons. Table 1 presents the freight and passenger transportation activities (Demiryolu Sektör Raporu, 2023).



Figure 1: Steam train

Table 1: Passenger and Freight Transportation Activities in Turkey.

Passenger Transport	2019	2020	2021	2022	2023
Number of Passengers (Thousand passengers)	245.852	148.639	191.586	321.589	342.524
High Speed Train	8.274	2.833	4.376	9.364	11.865
Suburban Train	220.022	142.191	181.562	295.138	317.611
Conventional Train	17.556	3.615	5.648	17.087	13.048
Passenger Traffic (Million x km)	14.208	7.981	10.743	19.619	20.913
High Speed Train	2.678	941	1.507	3.244	4.165
Suburban Train	9.347	6.541	8.518	13.875	14.876
Conventional Train	2.183	499	718	2.500	1.872
Cargo Transport	2019	2020	2021	2022	2023
Freight Transportation (Thousand tons)	33.535	34.549	38.155	38.571	32.408
Load Traffic (Million x km)	14.707	15.428	15.862	16.188	13.108

There are various types of wagons used in railway transportation, including covered wagons, open wagons, flat wagons, tanker wagons, and passenger wagons, as shown in Figure 2. These wagons are designed to transport passengers or various types of cargo, depending on their structure. The transported goods may include food products, electronic devices, delicate materials, minerals, stones, coal, scrap metal, containers, heavy machinery, vehicles, liquid and gaseous substances, petroleum products, and liquefied gases.

Railway transportation is widely preferred worldwide as a safe and efficient transportation alternative. However, this mode of transport requires all components of the system to operate flawlessly (Yorgun, 1989). Braking systems, which have a significant impact on the movement and stopping of trains, play a critical role in railway safety. Even the slightest malfunction in these systems can lead to serious accidents in both passenger and freight transportation, resulting in significant economic losses (Rakshit et al., 2018). Traditionally, the maintenance and inspection processes of railway braking systems have been carried out manually by human labor (Çak & Çelebi, 2002). The methods used for repairs in the workshop not only carry the risk of human error but also fall short in terms of time and cost efficiency. Modern technologies offer new solutions to overcome these challenges. In particular, image processing techniques hold significant potential for the automatic monitoring of braking systems and the early



Figure 2: a) Covered wagon, b) Open wagon, c) Flat wagon, d) Tanker wagon, e) Passenger wagons, f) Sleeper wagon

detection of faults. Tasks such as image recognition and classification enable various operations to be performed efficiently (Cimen et al., 2021; M. E., Çimen et al., 2021; M. E. Çimen, 2024; M. E. Çimen et al., 2019, 2020; Y. Liu et al., 2020; Öztürk & Eldoğan, 2024; Pala et al., 2021, 2022; Yıldırım & Cagıl, 2020). In their study, Lisanti et al. used image processing techniques to extract serial numbers and IDs from wagons, enabling their recognition and classification. Additionally, they verified the correctness of their positioning to ensure railway safety (Lisanti et al., 2018). Similarly, Saina et al. proposed a study where they used drones to capture railway images. Using their proposed deep learning-based RCNN structure, they successfully detected and segmented fishplates on railway tracks (Saini et al., 2024). Wei et al. conducted a comparative study focusing on the detection of mispositioned fasteners in railway tracks. In this study, they utilized the Dense-SIFT method and compared CNN-based models

such as VGG16 and Faster R-CNN, achieving successful results (X. Wei et al., 2019). Shang et al. proposed a novel two-stage approach for rail defect detection, which focuses on both the localization and classification of target images (Shang et al., 2018). In another study, Marta Garcia Minguell and her team compared three object detection models—YOLOv5, Faster R-CNN, and EfficientDet—to identify issues on railway tracks. Their analysis, based on a dataset of 31 images featuring three track components (clip, fishplate, and rail), revealed that Faster R-CNN outperformed the other models in terms of accuracy (Minguell & Pandit, 2023). Additionally, Xiaohong Sun et al. introduced an enhanced version of the Faster R-CNN algorithm, designed to improve the detection of multi-class wheel hub faults by sharing convolution layers between Fast R-CNN and the Region Proposal Network (RPN) (Sun et al., 2019). Meanwhile, Gabriel Krummenacher and his colleagues proposed two machine learning techniques that leverage vertical force data, collected from a sensor system permanently installed on the railway track, to automatically identify wheel defects (Krummenacher et al., 2017).

A crucial aspect to consider is the implementation of undercarriage inspection systems for wagons. This method aims to ensure the safety of the lower components of the wagons. Kishore and his team developed algorithms aimed at extracting and localizing defective parts from the bogie (Kishore & Prasad, 2017). N. Sasikala and her colleagues proposed an adaptive multi-object, multi-template matching algorithm for recognizing train bogie components. This method achieved a recognition accuracy of 91%, with a false recognition rate of 15% (Sasikala et al., 2019). Meanwhile, detecting defects in pantograph-catenary systems is essential for ensuring safe and efficient railway operations. Chen and his team proposed a deep neural network-based method for detecting defects in the pantograph-catenary system (PCS) (Chen et al., 2022). Liu et al. used Generative Adversarial Networks (GANs) for pantograph-catenary arcing detection, attempting to identify arcs occurring in these areas (X. Liu et al., 2024). Yan et al. used the Inception V3 model for pantograph-catenary arc detection in trains and achieved successful results (Yan et al., 2025). Zahang et al. used the YOLO V5 model in their study for object detection on railway tracks and early warning purposes. The dangerous objects were distinguished, and the warning level was determined according to the obstacle's position and severity (Zhang et al., 2024). Brintha and Jawhar used a deep learning-based FOD-YOLO to identify fastener defects in railways, achieving successful results (Brintha & Joseph Jawhar, 2024). Chenghai et al. trained a revised YOLO V8-based model to detect defects such as chipping, cracks, and wear in railway switches, achieving successful results (Yu & Lu, 2024). Yang et al. used UAV images to detect foreign objects on railway tracks in their study. They trained a YOLO-based model on these images to identify foreign objects on railway tracks and provide early warnings, aiming to enhance safety (Y. Yang et al., 2025). Ghahremani et al. aimed to detect faults that might occur in solar panels during operation using drones. A dataset was created with images obtained by drones, and training was performed on YOLO V10 and YOLOv11 models, with successful results (A., Ghahremani et al., 2025). Yang et al. established unmanned aerial vehicle (UAV) highway distress detection using YOLOv11 and achieved successful results (Z. Yang et al., 2025). There are many versions of YOLO used in object detection. The YOLO V11 model, produced in 2024, pushes the boundaries further by addressing the challenges associated with real-time object detection, which is critical for applications requiring rapid and accurate responses. In recent years, it has been applied in various fields such as ship fire detection (Akhmedov et al., 2024), agriculture (Alif & Hussain, 2024; R., Sapkota et al., 2024), gaming (Savran & Bulut, 2024; Tian et al., 202 C.E.), energy (A. Ghahremani et al., 2025; Khanam et al., 2025), farming (Guarnido-Lopez et al., 2024; R. Sapkota & Karkee, 2025), biology (Mehta et al., 2025; W. Wei et al., 2025), and many more.

This study focuses on detecting the operational status of the brake cylinders of railway wagons. In the project, the condition of the braking systems was analyzed using image processing techniques and artificial intelligence algorithms. When the brakes are not functioning correctly, the locomotive pulls the train from the front, but the train's wheels remain locked. Since the conductor cannot check every wagon, the train continues to move with locked wheels. During this time, as the train moves for hundreds of kilometers, the wheels will not rotate, causing excessive heating due to the continuous metal-on-metal friction on the tracks, as shown in Figure 3. As a result of this heating, the lifespan of the wheels decreases and may cause instability in the wagon. Additionally, the heated wheels can cause the wagon made of metal parts to heat up and potentially lead to a fire. On the other hand, wagons carrying dangerous chemicals, oil, or aviation fuel can be at risk of explosions due to radiation from locked wheels. The method aims to increase safety while also reducing maintenance costs.



Figure 3: Broken malfunctioning brake

The main purpose of the study is to effectively monitor the status of brake cylinders in railway transportation using Yolov11 and to detect faults in advance. In this context, a dataset was created by collecting images of brakes collected from wagons and this dataset was classified. Then, the data collected on Yolo V11 models developed in recent years was trained and successful results were obtained. This study demonstrates that the detection of braking mechanisms in trains with high accuracy using YOLOv11 models can significantly contribute to reducing train accidents, thereby preventing loss of life and costly incidents.

2 Materials and Methods

In this study, the working principle of the mechanism that provides braking of the wagons used in railways will be explained. Then, YOLO will be explained for the classification of the image.

2.1 Brake Systems

Brake systems in trains are important components that ensure the safe stopping of wagons (Yorgun, 1989). The general structure of the system is given in Figure 4. Air brake systems are generally used in wagons. This system consists of brake cylinders and brake blocks that work with air pressure produced by compressors. Driver brake valve provides fast and effective braking through air brake systems and keeps the movement of wagons under control. In addition, there are mechanical brake systems used in emergency situations.



Figure 4: Brake Cylinders and Blocks

The triple valve is a critical component of the railway freight wagon braking system. This valve is used in air brake systems and ensures the automatic engagement and release of the brakes. The triple valve performs three main functions: braking, exhaust, and charging. During braking, compressed air from the air reservoirs is directed to the brake cylinders through the valve. In the exhaust process, the air pressure
in the brake cylinders is released, and the brake pads are separated from the wheels. The charging process fills the air reservoirs and ensures the continuous operation of the brake system (Yorgun, 1989). In this case, when the driver activates the valve, the triple valve opens to allow the braking of the cylinder, and the piston moves forward, causing the brake block to rub against the wheel. This results in braking.

2.2 YOLOV11

YOLO is an important artificial intelligence algorithm in the field of object detection. Operating as a single-stage convolutional neural network-based model, YOLO is used to identify and classify objects in images. This model provides fast and efficient solutions for real-time applications. The YOLO algorithm is a preferred method in various applications that require real-time object detection, particularly in image processing and artificial intelligence fields. Used effectively in areas such as autonomous vehicles, security systems, and video analysis, YOLO plays a crucial role in quickly and accurately detecting and classifying objects. The algorithm's high speed, accuracy, and multi-object classification capabilities have made it widely applicable in both industry and research.

YOLO algorithm, first introduced by Joseph Redmon and his team in 2015, has been successfully used in many object detection applications over time. The YOLOv7 object detection algorithm proposed by Wang and his colleagues has proven to outperform other object detection algorithms in the literature, achieving a success rate of 51.2%. The YOLO algorithm has garnered significant attention due to its ability to solve object detection problems quickly, making it a preferred method in many studies. Despite the existence of over ten versions of YOLO, YOLOv5 (M. E. Çimen, 2024; Y. Liu et al., 2020; Olorunshola et al., 2023; Öztürk et al., 2024), YOLOv8 (M. E. Çimen, 2024), and YOLOv10 (Ding et al., 2025) have emerged as the most prominent choices for edge deployment applications. These three variants are particularly notable for their excellent balance of speed, accuracy, and efficiency, making them ideal for environments with limited resources.

YOLOv11 was introduced in 2024 and brought significant innovations in the field of object detection. YOLOv11 represents the newest advancement in the YOLO series, bringing notable enhancements in speed, accuracy, and feature extraction. As depicted in Figure 5 (Rasheed & Zarkoosh, 2024), its architecture is composed of three primary elements: the backbone, the neck, and the head.

Backbone: The backbone is the primary component of YOLOv11, designed to extract crucial features from the input image across multiple scales. It consists of several convolutional (Conv) blocks, each made up of three subcomponents: Conv2D, BatchNorm2D, and the SiLU activation function, as shown in Figure 5. In addition to these Conv blocks, YOLOv11 incorporates several C3K2 blocks, which replace the previous C2f blocks used in YOLOv8 (A. Ghosh, 2024). The C3K2 blocks enable a more efficient implementation of Cross-Stage Partial (CSP) (C.-Y.Wang et al., 2021), as illustrated in Figure 13. The last two layers of the backbone include Spatial Pyramid Pooling Fast (SPPF) and Cross-Stage Partial with Spatial Attention (C2PSA) (K. He et al., 2015). The SPPF block uses multiple max-pooling layers to capture features at various scales effectively, while the C2PSA block applies an attention mechanism to improve the model's performance.

Neck: The neck is the second crucial part of YOLOv11, as shown in Figure 5. It consists of several convolutional layers, C3K2 blocks, concatenation operations, and upsampling layers, while also benefiting from the C2PSA mechanism. The primary role of the neck is to merge multi-scale features and pass them efficiently to the head blocks (A. Ghosh, 2024).

Head: The final component of YOLOv11 is the head, which is crucial for generating predictions. This module is responsible for classifying objects, calculating the objectness score, and accurately determining the bounding boxes around detected objects (N. Jegham et al., 2024).

Murat Erhan Çimen YOLOv11-based Detection of Wagon Brake Cylinder Conditions



Figure 5: YOLOV11 Architecture(Rasheed & Zarkoosh, 2024)

YOLOv11 improves the detection of both small and large objects by utilizing multi-scale detection and global feature maps, while integrating contextual information from the entire image into the model's decision-making process. YOLOv11 has been extensively tested on standard benchmarks such as COCO, demonstrating superior performance and efficiency, as illustrated in Figure 6. The model achieves state-of-the-art results in different variants, showing significant improvements in latency and accuracy compared to previous versions and other contemporary detectors (*Ultralytics YOLO Dokümanlar*, 2025).

In terms of real-time performance, YOLOv11 provides a significant advantage with its high image processing capacity, particularly in applications such as autonomous vehicles, surveillance systems, and live video analysis. Its modular architecture enables easy integration with various hardware and software platforms, allowing developers and engineers to efficiently use YOLOv11 in diverse applications (*Ultralytics YOLO Dokümanlar*, 2025). YOLOv11 ushers in a new era in object detection technology, offering significant improvements in accuracy, speed, and efficiency, making it an ideal object detection model for use in autonomous vehicles, surveillance systems, robotics, healthcare, and many other fields.

Murat Erhan Çimen YOLOv11-based Detection of Wagon Brake Cylinder Conditions



Figure 6: Performance of YOLOV11 Models (Ultralytics YOLO Dokümanlar, 2025)

3 Proposed Approach for Status Detection of Wagon Brake Cylinders

The scope of this study is focused on detecting the status of brake systems in railway wagons. In this context, as shown in Figure 7, images of the brake cylinders are captured by a camera when a wagon passes a specific point. These images are then evaluated using YOLOv11 to detect the status of the brake cylinders.



Figure 7: Detection of Brake Cylinder in Wagons Sample Image

In the discussion section, the conclusions of the current study are compared with the conclusions of similar studies in the literature while interpreting the possible reasons for the conclusions.

3.1 Dataset

The study focuses on the status detection of wagon brake cylinders, and a dataset has been created for this purpose. This dataset was primarily collected from wagons in the Sakarya region, on the internet, and through image capture. A total of 1,132 images were obtained. The numerical data regarding the images are provided in Table 2. Sample images are shown in Figure 8. After the dataset was collected, it was classified into three categories: Braked, Evacuated, and Empty. If the image contains a braked cylinder, it is classified as "Braked." If the cylinder in the image is not braked, it is classified as "Evacuated." If no cylinder is present in the image, it is classified as "Empty." The images were then randomly split into 20% for testing and 80% for training data.

Table 2: Dataset details.

Classes	Test	Training	Total	
	(Sample, %Rate)	(Sample, %Rate)	(Sample)	
Braked	340, %20	1360, %20	1700	
Evacuated	777, %20	3108, %20	3885	
Empty	3, %20	12, %80	15	
Total	1120	1120	5600	



a) Braked

b) Evacuated



After the data is trained on the models, it is necessary to test the accuracy of the model. In this context, the accuracy matrix of the tested model is provided in Table 3.

Table 3. Confusion Matrix.

		Actual				
		Positive	Negative			
cted	Positive	True Positive (TP)	False Negative (FN)			
Predi	Negative	False Negative (FN)	True Negative (TN)			

Accuracy: It indicates how accurately the model classifies in general. High correct classifications suggest that the model performs well. The formula for calculating accuracy is given in Equation 1.

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

Precision: These results demonstrate the accuracy and reliability of the developed system for detecting the status of brake cylinders. High values of precision and recall metrics indicate that the model can correctly identify positive classes and has a low error rate. The formula for calculating precision is given in Equation 2.

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

Recall: This recall-confidence curve is used to evaluate how well the model performs at different confidence levels. High recall values indicate that the model is generally successful in identifying positive examples. However, it should be noted that recall values may slightly decrease as the confidence level increases. This is important for determining the confidence level at which the model performs best. The formula for calculating recall is given in Equation 3.

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

F1 Score: It is the harmonic mean of precision and recall. It indicates that the model demonstrates a balanced performance overall. These results show the general performance of the developed system for detecting the status of brake cylinders. High F_1 values prove that the model is balanced and successful in both precision and recall metrics. This suggests that the system can be reliably and effectively used in industrial applications. The formula for calculating the F_1 Score is given in Equation 4.

$$F_{1} = \frac{2 \times Precision \times Recall}{Precision \times Recall}$$
(4)

4 Simulation Studies

Google Colab is used to train YOLOv11 models for detecting the Status Detection of Wagon Brake Cylinders. Transfer learning is applied by utilizing the pre-trained weights of YOLOv11 versions. The models used, the number of parameters of the models, and the size of the weight files are provided in Table 4. The training parameters of YoloV11 models are presented in Table 5.

Table 4. Yolo V11 Models details for detect the Status Detection of Wagon Brake Cylinder.

	YOLOv11n	YOLOv11s	YOLOv11m	YOLOv11I	YOLOv11X
Parameter	1.6	5.5	10.4	12.9	28.4
(Million)					
Memory	3.1MB	10.7MB	20.39MB	25.339MB	55.7MB

Table :	5.	Training	parameters	for	Yolo	V11	versions.
---------	----	----------	------------	-----	------	-----	-----------

Parameters	Value
Image size	640x640
Batch size	8
Epoch	5

5 Results and Discussion

To evaluate the performance of YOLOv11 models in detecting the status detection of wagon brake cylinder, the models are trained on a dataset. Then, the trained models were compared in terms of metrics such as TN, FN, FP, TP, accuracy, precision, and F_1 score. First, the training time of the trained model and the loss values obtained during the training process are provided in Table 6. Then, performance was measured in terms of classification using test data. For classification, confusion matrices for each model are given between Figure 9 and Figure 13. Subsequently, for each model, TP, FP, FN, TN, accuracy, precision, recall, and F_1 scores for the braked and evacuated classes are provided in Table 7 and Table 8.

When the loss values of the models are examined in Table 6, it can be seen that the lowest value is produced by the YOLOv11n model. On the other hand, the lowest performance is observed with the YOLOv11X model. This is due to the YOLOv11X model having a large number of parameters and the relatively low number of iterations chosen. Additionally, when the training durations of the models are examined, it is found that the YOLOv11n model can be trained in the shortest time, while the model that takes the longest time to train is the YOLOv11X model.

The confusion matrix produced by the YOLOv11n model, which was trained according to the dataset and later tested, is shown in Figure 9. Using the data from Figure 9, the TF, TP, FP, FN values obtained from the classification results for the YOLOv11n model were calculated in Table 7 and Table 8. Subsequently, accuracy, recall, and F_1 values were calculated using these values.

	YOLOv11n	YOLOv11s	YOLOv11m	YOLOv11I	YOLOv11X
Loss value	0.20173	0.20584	0.24551	0.24429	0.30835
Training Duration (sec)	1447.21	3786.04	9249.28	13384.3	25644.4

Table 6.	Yolo	V10	training	results.
----------	------	-----	----------	----------



Figure 9: Confusion Matrix for YOLOv11n

The confusion matrix produced by the YOLOv11s model, which was trained according to the dataset and later tested, is shown in Figure 10. Using the data from Figure 10, TF, TP, FP, FN values obtained from the classification results for the YOLOv11s model were calculated in Table 7 and Table 8. Subsequently, accuracy, recall, and F_1 values were calculated using these values.



Figure 10: Confusion Matrix for YOLOv11 s

The confusion matrix generated by testing the YOLOv11m model, which was trained on the dataset, is presented in Figure 11. Using the data from Figure 11, TF, TP, FP, and FN values obtained from the classification results of the YOLOv11m model were calculated in Table 7 and Table 8. Subsequently, these values were used to compute the accuracy, recall, and F_1 scores.



Figure 11: Confusion Matrix for YOLOv11 m

The confusion matrix generated by testing the YOLOv111 model, which was trained on the dataset, is presented in Figure 12. Using the data from Figure 12, TF, TP, FP, and FN values obtained from the classification results of the YOLOv111 model were calculated in Table 7 and Table 8. Subsequently, these values were used to compute the accuracy, recall, and F_1 scores.



Figure 12: Confusion Matrix for YOLOv111

The confusion matrix produced by the YOLOv11x model, which was trained according to the dataset and later tested, is shown in Figure 13. Using the data from Figure 13, TF, TP, FP, FN values obtained from the classification results for the YOLOv11x model were calculated in Table 7 and Table 8. Subsequently, accuracy, recall, and F_1 values were calculated using these values.



Figure 13: Confusion Matrix for YOLOv11x

The metrics for the Braked and Evaluated classes of all models have been calculated, and the results are presented in Table 7 and Table 8. The best results are marked in bold. For the TP result, when the Braked class is examined, it represents the number of instances where the actual data and the results produced by the model both correspond to Braked. The model with the highest value indicates the best performance. In this regard, it can be observed in Table 7 that the YOLOv11x model produced the best result for the Braked data. In Table 8, for the Evaluated class, the YOLOv11n model produced the best result. FN metric corresponds to cases where the actual data is Braked, but the model outputs Evaluated or Empty. A lower value for this metric is preferred. When examining Table 7 for the Braked class, it is observed that the YOLOv11x model produced the best result. FOr the Evaluated class in Table 8, the YOLOv11n model produced the best result. FOr the Evaluated class in Table 8, the actual class is either Empty or Evaluated class in Table 8, the when the actual class is either Empty or Evaluated. A lower FP value ensures the

model generates accurate results. In this context, Table 7 shows that the YOLOv11m model produced the best result for the Braked class. When examining Table 8 for the Evacuated class, it can be seen that many models produced similar results. On the other hand, the TN metric has been evaluated for the models. The TN metric represents the number of instances where a non-Braked data point is correctly classified as Empty or Evacuated. In this regard, Table 7 shows that the YOLOv11m model produced the best result for the Braked class. For the Evacuated class in Table 8, many models produced similar results. Based on the data provided in Table 7 and Table 8, the performance of different YOLOv11 models in brake cylinder detection has been compared. The results were evaluated based on accuracy, precision, recall, and F1-score. For the Braked (closed brake cylinder) condition, the YOLOv11x model achieved the highest accuracy (0.975) and F₁-score (0.9699), showing the best overall performance. However, the highest precision value of 0.9741 belongs to the YOLOv11m model. A high precision indicates that the model minimizes FP. The YOLOv11s model demonstrated a balanced performance with a recall value of 0.95 and a precision of 0.9645. Therefore, while the YOLOv11X model can be considered the best in terms of overall performance, the YOLOv11m model could be preferred for minimizing FP. For the Evacuated (open brake cylinder) condition, the YOLOv11s and YOLOv11m models achieved the highest accuracy (0.975), precision (0.9512), and recall (0.975), providing the most balanced results. YOLOv11X model, with a recall value of 0.96, minimized FN, while its precision was calculated to be 0.9366. The YOLOv11n model was identified as the model producing the most FP, with the lowest precision (0.9120).

Table 7.	Performance	Metrics for	Braked of	Yolov11 for	Brake Cylinder	Detection.
----------	-------------	-------------	-----------	-------------	----------------	------------

Model	ТР	FN	FP	TN	Accuracy	Precision	Recall	\mathbf{F}_1
YOLOv11n	187	13	8	392	0.965	0.958974	0.935	0.949763
YOLOv11s	190	10	7	393	0.971667	0.964467	0.95	0.960711
YOLOv11m	188	12	5	395	0.971667	0.974093	0.94	0.955571
YOLOv11I	191	9	8	392	0.971667	0.959799	0.955	0.963261
YOLOv11x	193	7	8	392	0.975	0.960199	0.965	0.969974

Table 8: Performance	e Metrics for I	Evacuated of	Yolov11 for	Brake Cylinder	Detection
----------------------	-----------------	--------------	-------------	----------------	-----------

Model	TP	FN	FP	TN	Accuracy	Precision	Recall	\mathbf{F}_1
YOLOv11n	197	3	19	381	0.963333	0.912037	0.985	0.974046
YOLOv11s	195	5	10	390	0.975	0.95122	0.975	0.975
YOLOv11m	195	5	10	390	0.975	0.95122	0.975	0.975
YOLOv11I	191	9	10	390	0.968333	0.950249	0.955	0.96162
YOLOv11x	192	8	13	387	0.965	0.936585	0.96	0.962494

As a result, the YOLOv11x model is recommended for situations where minimizing FN is critical. However, when FP need to be minimized, the YOLOv11m or YOLOv11s models may be more suitable. In terms of overall balance, YOLOv11x is recommended for the Braked condition, while YOLOv11s or YOLOv11m models are recommended for the Evacuated condition.

The findings obtained in this study have confirmed the effectiveness of algorithms for automatic detection and functionality analysis of brake cylinders. Image processing techniques and data obtained from sensors have enabled the system to achieve high accuracy rates in performance evaluation.

The following key findings were obtained during the research process:

- 1. Brake Cylinder Detection: The developed image processing algorithms detected brake cylinders with an accuracy rate of over 95%.
- 2. Performance Evaluation: YOLOv11 models can analyze the overall functionality of the brake systems, identifying potential performance losses in wagons or locomotives. Additionally, these analyses can serve as an important guide in planning the maintenance and repair processes for trains.

The findings have shown that the methods used in the study were successful. The technologies developed for effectively monitoring and analyzing the condition of brake systems have demonstrated the potential to enhance railway safety and reduce costs.

6 Conclusions

In this study, the use of YOLOv11 models to detect the status of brake cylinders in railway wagons has been examined. The primary objective of the study is to effectively monitor the brake cylinder status using YOLOv11 and to detect potential failures in advance. In this context, a dataset consisting of brake images collected from wagons was created and classified. Then, this dataset was trained on the YOLOv11 models developed in recent years, and successful results were obtained. The findings confirmed that image processing techniques and data obtained from sensors are effective for the automatic detection and functionality analysis of brake cylinders. The developed image processing algorithms detected brake cylinders with an accuracy rate of over 95%. YOLOv11 models are capable of analyzing the overall functionality of brake systems by identifying potential performance losses in wagons or locomotives. These analyses can serve as an important guide for planning the maintenance and repair processes of trains. As a result of performance evaluation, it was found that different YOLOv11 models are suitable for different priorities. The YOLOv11x model is recommended for situations where minimizing FN is critical. However, YOLOv11m or YOLOv11s models may be more suitable when minimizing FP is necessary. For a generally balanced performance, the YOLOv11x model is recommended for the "Braked" state, and YOLOv11s or YOLOv11m models are suggested for the "Evacuated" state. In conclusion, this study demonstrates that the high-accuracy detection of braking mechanisms in trains using YOLOv11 models can significantly reduce train accidents, thus preventing fatalities and costly incidents. The developed technologies have the potential to enhance railway safety and reduce maintenance costs.

References

A. Ghosh. (2024). Yolov11 overview. Https:// Learnopencv.Com/Yolo11/.

- Akhmedov, F., ., Nasimov, R., & Abdusalomov, A. (2024). Dehazing Algorithm Integration with YOLO-v10 for Ship Fire Detection. *Fire*, 7(9), 332.
- Alif, M. A. R., & Hussain, M. (2024). YOLOv1 to YOLOv10: A comprehensive review of YOLO variants and their application in the agricultural domain. *ArXiv Preprint ArXiv:2406.10139*.
- Brintha, K., & Joseph Jawhar, S. (2024). FOD-YOLO NET: Fasteners fault and object detection in railway tracks using deep yolo network . *Journal of Intelligent & Fuzzy Systems*, 46(4), 8123–8137.
- Çak, R., A. S., & Çelebi, M. (2002). Demiryollari İle Yolcu Taşlmacillği Ve Yolcu Vagonu Onarimi. Sakarya University Journal of Science, 6–1.
- Chen, R., Lin, Y., & Jin, T. (2022). High-speed railway pantograph-catenary anomaly detection method based on depth vision neural network. *IEEE Transactions on Instrumentation and Measurement*, 71, 1–10.
- Cimen, M., Boyraz, O., Yildiz, M., & Boz, A. (2021). A new dorsal hand vein authentication system based on fractal dimension box counting method. *Optik*, 226.
- Çimen, M. E. (2024). Comparison of Deep Learning and Yolov8 Models for Fox Detection Around the Henhouse. Journal of Smart Systems Research, 5(2), 76–90.
- Çimen, M. E., Boyraz, Ö. F., Garip, Z., Pehlivan, İ., Yıldız, M. Z., & Boz, A. F. (2021). Görüntü işleme tabanlı kutu sayma yöntemi ile fraktal boyut hesabı için arayüz tasarımı. *Politeknik Dergisi*, 24(3), 867–878. https://doi.org/10.2339/politeknik.
- Çimen, M. E., Garip, Z. B., Boyraz, Ö. F., Pehlivan, İ., Yıldız, M. Y., & Boz, A. F. (2020). An Interface Design For Calculation Of Fractal Dimension. 2019, 3–9.
- Çimen, M. E., Garip, Z., Pala, M. A., Boz, A. F., & Akgül, A. (2019). Modelling Of A Chaotic System Motion In Video With Artificial Neural Networks. *Chaos Theory And Applications*, 1(1).

C.-Y.Wang, A., Bochkovskiy, & H.-Y. M. Liao. (2021). Scaled-Yolov4: Scaling Cross Stage Partial Network. In Proceedings Of The Ieee/Cvf Conference On Computer Vision And Pattern Recognition, Pages, 13029– 13038.

Demiryolu Sektör Raporu. (2023).

- Ding, L., Tong, Y., Cui, Y., & Sun, Z. (2025). Improved Yolov10 Lightweight Bearing Surface Defect Detection Algorithm. *Preprints.Org*.
- Ghahremani, A., Adams, S. D., Norton, M., Khoo, S. Y., & Kouzani, A. Z. (2025). Detecting Defects In Solar Panels Using The Yolo V10 And V11 Algorithms. *Electronics*, *14*(2), 344.
- Ghahremani, A., Adams, S. D., Norton, M., Khoo, S. Y., & Kouzani, A. Z. (2025). Detecting Defects In Solar Panels Using The Yolo V10 And V11 Algorithms. *Electronics*, *14*(2), 344.
- Guarnido-Lopez, P., Ramirez-Agudelo, J. F., Denimal, E., & Benaouda, M. (2024). Programming And Setting Up The Object Detection Algorithm Yolo To Determine Feeding Activities Of Beef Cattle: A Comparison Between Yolov8m And Yolov10m. *Animals*, *14*(19), 2821.
- K. He, X. Zhang, S. Ren, & J. Sun. (2015). Spatial Pyramid Pooling In Deep Convolutional Networks For Visual Recognition. *Ieee Transactions On Pattern Analysis And Machine Intelligence*, *37*(9), 1904–1916.
- Khanam, R., Asghar, T., & Hussain, M. (2025). Comparative Performance Evaluation Of Yolov5, Yolov8, And Yolov11 For Solar Panel Defect Detection. *Solar*, *5*(1).
- Kishore, P. V. V., & Prasad, C. R. (2017). Computer vision based train rolling stock examination. *Optik*, 132, 427–444.
- Krummenacher, G., Ong, C. S., Koller, S., Kobayashi, S., & Buhmann, J. M. (2017). Wheel defect detection with machine learning. *IEEE Transactions on Intelligent Transportation Systems*, 19(4), 1176–1187.
- Lisanti, G., Karaman, S., Pezzatini, D., & Bimbo, A. D. (2018). A multi-camera image processing and visualization system for train safety assessment. *Multimedia Tools and Applications*, 77, 1583–1604.
- Liu, X., Wang, X., Quan, W., Gu, G., Xu, X., & Gao, S. (2024). A pantograph-catenary arcing detection model for high-speed railway based on semantic segmentation and generative adversarial network. *International Journal of Rail Transportation*, 1–22.
- Liu, Y., Lu, B., Peng, J., & Zhang, Z. (2020). Research on the use of YOLOv5 object detection algorithm in mask wearing recognition. *World Sci. Res. J*, 6(11), 276–284.
- Mehta, P., Vaghela, R., Pansuriya, N., Sarda, J., Bhatt, N., Bhoi, A. K., & Srinivasu, P. N. (2025). Benchmarking YOLO Variants for Enhanced Blood Cell Detection. *International Journal of Imaging Systems and Technology*, 35(1), 70037.
- Minguell, M. G., & Pandit, R. (2023). TrackSafe: A comparative study of data-driven techniques for automated railway track fault detection using image datasets. *Engineering Applications of Artificial Intelligence*, *125*, 106622.
- N. Jegham, C. Y. Koh, M. Abdelatti, & A. Hendawi. (2024). Evaluating the evolution of yolo (you only look once) models: A comprehensive benchmark study of yolo11 and its predecessors. ArXiv Preprint ArXiv:2411.00201.
- Olorunshola, O. E., Irhebhude, M. E., & Evwiekpaefe, A. E. (2023). A comparative study of YOLOv5 and YOLOv7 object detection algorithms. *Journal of Computing and Social Informatics*, 2(1), 1–12.
- Öztürk, G., & Eldoğan, O. (2024). Prediction of Multivariate Chaotic Time Series using GRU, LSTM and RNN. Sakarya University Journal of Computer and Information Sciences, 7(2), 156–172.
- Öztürk, G., Eldoğan, O., & Köker, R. (2024). Computer Vision-Based Lane Detection and Detection of Vehicle, Traffic Sign, Pedestrian Using YOLOv5. *Sakarya University Journal of Science*, 28(2), 418–430.
- Pala, M., Cimen, M., Yildız, M., Cetinel, G., Avcıoglu, E., & Alaca, Y. (2022). CNN-Based Approach for Overlapping Erythrocyte Counting and Cell Type Classification in Peripheral Blood Images. *Chaos Theory* and Applications, 4(2).
- Pala, M., Cimen, M., Yıldız, M., Eskiler, G., & Özkan, A. (2021). Holografik görüntülerde kenar tabanlı fraktal özniteliklerin hücre canlılık analizlerinde başarısı. *Journal of Smart Systems Research*, 2(2), 89–94.
- Rakshit, U., Malakar, B., & Roy, B. K. (2018). Study on longitudinal forces of a freight train for different types of wagon connectors. *IFAC-PapersOnLine*, 283–288.
- Rasheed, A. F., & Zarkoosh, M. (2024). YOLOv11 Optimization for Efficient Resource Utilization. *ArXiv Preprint ArXiv:2412.14790*. https://doi.org/10.48550/arXiv.2412.14790 Focus to learn more

- Saini, A., Singh, D., & Alvarez, M. (2024). FishTwoMask R-CNN: Two-stage Mask R-CNN approach for detection of fishplates in high-altitude railroad track drone images. *Multimedia Tools and Applications*, 83(4), 10367–10392.
- Sapkota, R., Meng, Z., Churuvija, M., Du, X., Ma, Z., & Karkee, M. (2024). Comprehensive performance evaluation of yolo11, yolov10, yolov9 and yolov8 on detecting and counting fruitlet in complex orchard environments. *ArXiv Preprint ArXiv:2407.12040*.
- Sapkota, R., & Karkee, M. (2025). Improved YOLOv12 with LLM-Generated Synthetic Data for Enhanced Apple Detection and Benchmarking Against YOLOv11 and YOLOv10. *ArXiv Preprint ArXiv:2503.00057*.
- Sasikala, N., Kishore, P. V. V., Kumar, D. A., & Prasad, C. R. (2019). Localized region based active contours with a weakly supervised shape image for inhomogeneous video segmentation of train bogie parts in building an automated train rolling examination. *Multimedia Tools and Applications*, 78, 14917–14946.
- Savran, M., & Bulut, H. (2024). Real-Time Error Detection In Digital Games Based on the YOLO V10 Model. 2024 8th International Artificial Intelligence and Data Processing Symposium (IDAP).
- Shang, L., Yang, Q., Wang, J., Li, S., & Lei, W. (2018). Detection of rail surface defects based on CNN image recognition and classification. 2018 20th International Conference on Advanced Communication Technology (ICACT), 45–51.
- Sun, X., Gu, J., Huang, R., Zou, R., & Giron Palomares, B. (2019). Surface Defects Recognition of Wheel Hub Based on Improved Faster R-CNN. *Electronics*, 8(5), 481.
- Tian, S., Lu, Y., Jiang, F., Zhan, C., & Huang, C. (202 C.E.). Improved Campus Vehicle Detection Method Based on YOLOv11 and Grayscale Projection-Based Electronic Image Stabilization Algorithm. *Traitement Du Signal*, 41(6), 3335.
- Ultralytics YOLO Dokümanlar. (2025, March 3). Https://Docs.Ultralytics.Com/Tr/Models/Yolo11/.
- Wei, W., Huang, Y., Zheng, J., Rao, Y., Wei, Y., Tan, X., & OuYang, H. (2025). YOLOv11-based multi-task learning for enhanced bone fracture detection and classification in X-ray images. *Journal of Radiation Research and Applied Sciences*, 18(1), 101309.
- Wei, X., Yang, Z., Liu, Y., Wei, D., Jia, L., & Li, Y. (2019). Railway track fastener defect detection based on image processing and deep learning techniques: A comparative study. *Engineering Applications of Artificial Intelligence*, 80, 66–81.
- Yan, Y., Liu, H., Gan, L., & Zhu, R. (2025). A novel arc detection and identification method in pantographcatenary system based on deep learning. *Scientific Reports*, 15(1), 3511.
- Yang, Y., Liu, Z. ., Chen, J., Gao, H., & Wang, T. (2025). Railway foreign object intrusion detection Using UAV images and YOLO-UAT. *IEEE Access*.
- Yang, Z., Lan, X., & Wang, H. (2025). Comparative Analysis of YOLO Series Algorithms for UAV-Based Highway Distress Inspection: Performance and Application Insights. *Sensors*, 25(5), 1475.
- Yıldırım, B., & Cagıl, G. (2020). Bir Montaj Parçasının Derin Öğrenme ve Görüntü İşleme ile Tespiti. *Journal of Intelligent Systems: Theory and Applications*, *3*(2), 31–37.
- Yorgun, H. (1989). Demiryolu taşıtlarında fren sistemlerinin incelenmesi. Anadolu Universitesi.
- Yu, C., & Lu, Z. (2024). YOLO-VSI: An Improved YOLOv8 Model for Detecting Railway Turnouts Defects in Complex Environments. *Computers, Materials & Continua*, 81(2).
- Zhang, Z., Chen, P., Huang, Y., Dai, L., Xu, F., & Hu, H. (2024). Railway obstacle intrusion warning mechanism integrating YOLO-based detection and risk assessment. *Journal of Industrial Information Integration*, *38*, 100571.



© 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) license (https://creativecommons.org/licenses/by/4.0/)



Research articleJournal of Smart Systems Research (JOINSSR) 6(1), 45-61, 2025Recieved: 5-May -2025Accepted: 13-Jun-2025https://doi.org/10.58769/joinssr.1692401



Kaotik Tabanlı PSO Algoritması ile PID Kontrol Parametrelerinin Optimizasyonu ve Sistem Performansının İncelenmesi

Muhammed Salih SARIKAYA^{1*}, Onur DEMİREL², Sezgin KAÇAR³, Adnan DERDİYOK⁴

¹ Mekatronik Mühendisliği, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye. <u>salihsarikaya@subu.edu.tr</u>

² Mekatronik Mühendisliği, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye. <u>onurdemirel@subu.edu.tr</u>

³ Elektrik ve Elektronik Mühendisliği, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye. <u>skaçar@subu.edu.tr</u>

⁴ Mekatronik Mühendisliği, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye. <u>derdiyok@subu.edu.tr</u>

ÖΖ

Bu çalışmada, Parçacık Sürü Optimizasyon Algoritmasının kaotik sistemlerle birleştirilerek kontrolcü tasarımı üzerindeki performansının iyileştirilmesi amaçlanmaktadır. Kontrol parametrelerinin optimum şekilde ayarlanması metodolojik yöntemlerle (Ziegler-Nichols, Adaptif yöntemler vb) veya çoğunlukla uzman bilgisine dayalı deneme-yanılma yaklaşımıyla gerçekleştirilmektedir. Daha etkin çözümler sunabilmeleri açısından meta-sezgisel optimizasyon algoritmalarının kullanımı son yıllarda ön plana çıkmaktadır. Bu çalışma kapsamında, Parçacık Sürü Optimizasyonu ve bu algoritmanın kaotik sistemlerle birleştirilmiş versiyonu olan Kaotik Parçacık Sürü Optimizasyonu kullanılarak PID kontrolcünün parametreleri optimize edilmiştir. Optimizasyon sürecinde performans kriteri olarak Zaman Ağırlıklı Hatanın Karesinin İntegrali esas alınmıştır. Elde edilen bulgular, kaotik sistemlerin Parçacık Sürü Optimizasyon algoritmasına entegrasyonunun, algoritmanın minimum hata değerine yakınsama başarımını artırdığını ortaya koymuştur.

Anahtar Kelimeler: DC motor kontrol, Kaotik sistemler, Kaotik tabanlı optimizasyon, Parçacık sürü optimizasyonu

* Sorumlu yazarın e-posta adresi: salihsarikaya@subu.edu.tr

Cite as: Sarıkaya, M.S., Demirel, O., Kaçar, S. & Derdiyok A. (2025). Kaotik Tabanlı PSO Algoritması ile PID Kontrol Parametrelerinin Optimizasyonu ve Sistem Performansının İncelenmesi, *Journal of Smart Systems Research*, 6(1), 45-61. <u>https://doi.org/10.58769/joinssr.1692401</u>

SUBÜ Bilimsel Yayınlar Koordinatörlüğü

http://biyak.subu.edu.tr

Creative Commons Attribution 4.0 International (CC BY 4.0) license (https://creativecommons.org/licenses/by/4.0/)

Optimization of PID Control Parameters Using a Chaotic-Based PSO Algorithm and Analysis of System Performance

ABSTRACT

This study aims to improve the performance of optimization algorithms in controller design by combining them with chaotic systems. The optimal tuning of control parameters is typically carried out using methodological approaches (such as Ziegler-Nichols, adaptive methods, etc.) or trial-anderror strategies that often rely on expert knowledge. In recent years, the use of metaheuristic optimization algorithms has gained prominence due to their ability to offer more effective solutions. Within the scope of this study, the parameters of the PID controller were optimized using the Particle Swarm Optimization algorithm and its version combined with chaotic systems, known as the Chaotic Particle Swarm Optimization. The performance criterion employed in the optimization process was the Integral of Time-weighted Squared Error. The results demonstrated that the integration of chaotic systems into the Particle Swarm Optimization algorithm enhances its ability to converge toward the minimum value. This study has shown that optimization algorithms combined with chaotic systems.

Keywords: DC motor control, Chaotic systems, Chaotic-Based optimization, Particle swarm optimization

1 Giriş

Parçacık Sürü Optimizasyonu (PSO), robotik, kontrol sistemleri ve yapay zekâ gibi çok çeşitli mühendislik alanlarında uygulanabilen, esnek ve güçlü bir meta-sezgisel optimizasyon yöntemi olarak dikkat çekmektedir. Yüksek boyutlu ve karmaşık çözüm uzaylarını etkili biçimde tarayabilen PSO, problemlere ilişkin optimal çözümler üretebilme yeteneğiyle öne çıkmaktadır.

PSO algoritmasının çeşitli uygulama alanlarındaki kullanımlarını inceleyen literatür çalışması yapılmış ve elde edilen sonuçlar derlenerek sunulmuştur. Zhong, PSO'nun bir robot kolunun dinamik parametrelerini etkili bir biçimde tanımlayabildiğini ve bu bağlamda Ağırlıklı En Küçük Kareler (AEKK) ve Genetik Algoritmalar (GA) gibi geleneksel yöntemlere kıyasla daha yüksek doğruluk ve daha hızlı yakınsama sağladığını ortaya koymuştur [1]. Benzer şekilde, Abedinifar vd. doğrusal olmayan dinamik sistemlerde parametre tanımlama amacıyla PSO'nun sıklıkla tercih edildiğini belirtmişlerdir [2]. Özellikle otonom sistemler bağlamında da PSO'nun dikkat çekici uygulamaları bulunmaktadır. Coşar, PSO ve diğer sürü zekâsı algoritmalarının insansız hava araçlarının (İHA) görev planlamasında hem bireysel hem de iş birliğine dayalı operasyonlarda önemli rol oynadığını vurgulamıştır [3]. Ayrıca, dinamik ve belirsizlik içeren ortamlarda çözüm kalitesini artırmak amacıyla PSO'nun adaptif versiyonları da geliştirilmiştir. Bu kapsamda, Adaptif PSO (APSO) gibi iyileştirilmiş varyantların, küresel optimum çözüme daha etkin ulaşabildiği gösterilmiştir [4]. PSO'nun yapay sinir ağları (YSA) ile entegrasyonu ise özellikle tahmin ve sınıflandırma görevlerinde öne çıkmaktadır.

Literatürde PSO, kontrol mühendisliği alanında da yaygın olarak kullanılmakta olup, özellikle PID kontrolörlerin parametrelerinin ayarlanmasında sıkça tercih edilmektedir. Peltier soğutma sistemi üzerinde gerçekleştirilen çalışmada, PSO ile optimize edilen PID parametrelerinin kontrol performansını anlamlı biçimde iyileştirildiği gösterilmiştir [5]. Tahtawi vd. AX-12 servo motorunun konum kontrolü için PSO-tabanlı bir PID kontrolör tasarlayarak, PSO'nun robotik sistemlerde kararlılık ve yanıt süresi açısından önemli iyileştirmeler sağladığını ortaya koymuştur [6]. Benzer şekilde, büyük zaman gecikmesine sahip boru hattı robotlarında PSO'nun etkinliğini test edilmiş ve algoritmanın bu tür sistemlerde başarılı sonuçlar verdiği gösterilmiştir [7]. Fırçasız DC (BLDC) motorların hız kontrolünde bulanık mantık ile PSO'yu birleştirilerek geleneksel yöntemlere kıyasla daha kararlı ve hızlı yanıt veren bir kontrol sistemi elde edilmiştir [8]. Moghaddas vd. benzer şekilde, DC motorların PID kontrolünde

PSO'nun kontrol performansını anlamlı şekilde artırdığını raporlamıştır [9]. Zhu vd. ise, fotovoltaik sabit basınçlı su tedarik sistemine yönelik çalışmalarında PID parametrelerinin PSO ile optimize edilmesini önermiş; simülasyon sonuçları, klasik PID kontrolörlere kıyasla PSO ile optimize edilmiş kontrol yapısının daha üstün dinamik yanıt ve kararlı durum performansı sergilediğini ortaya koymuştur [10]. Bu çalışmalar, PSO algoritmasının farklı mühendislik disiplinlerinde geleneksel yöntemlere kıyasla daha etkili çözümler sunabildiğini ve özellikle kontrol uygulamalarında başarıyla uygulanabileceğini göstermektedir.

Kaotik Parçacık Sürü Optimizasyonu (KPSO), geleneksel PSO algoritmasının geliştirilmiş bir varyantı olup, çok sayıda çalışmada ele alınmıştır. Kaos teorisinin PSO algoritmasına entegrasyonu, arama alanında çeşitliliği artırarak algoritmanın erken yakınsama ve yerel minimumlara takılma gibi temel sınırlılıklarını aşmasına olanak tanımaktadır. Bu doğrultuda, literatürde KPSO'nun çeşitli uygulama alanlarındaki kullanımları incelenmiş ve ilgili çalışmalardan elde edilen bulgular derlenerek sunulmuştur. Mühendislik yapı tasarımı alanında kullanmak üzere, karmaşık başlangıç koşulları ve doğrusal olmayan optimizasyon tekniklerini içeren KPSO algoritmasını önerilmiş ve geleneksel PSO'ya kıyasla daha hızlı yakınsama ve daha yüksek çözüm kalitesi sağlandığı ortaya koyulmuştur [11]. Makine öğrenmesi ve tarımsal görüntü işleme alanlarında Dong, KPSO algoritmasını Destek Vektör Makineleri ile entegre ettiği bir çalışmada, bitki hastalıkları ve zararlılarının tespiti için kullanılan sistemde kaotik dizilerin başlangıç popülasyonundaki çeşitliliği artırarak optimizasyon sürecinin başarımını artırdığını ve yerel minimumlara takılma olasılığını azalttığını göstermiştir [12].

Kontrol sistemlerine yönelik çalışmalar ise KPSO'nun klasik denetleyici tasarımlarına sağladığı katkıyı ortaya koymaktadır. Enerji sistemleri kapsamında, Huang vd, doğrudan tahrikli bir dalga enerjisi dönüştürücüsü için KPSO'yu kullanarak, algoritmanın değişen çalışma koşulları altında kontrol sisteminin tepki süresini azaltma potansiyeline sahip olduğunu ortaya koymuştur [13]. Yüksek hızlı taşıma sistemlerinde, Cheng, trenlerin kaldırma kanadı açısı tahrik sistemlerinin hassas kontrolü için KPSO tabanlı bir denetim stratejisi önermiş ve bu algoritmanın yüksek doğruluk gerektiren uygulamalarda etkin bir çözüm sunduğunu göstermiştir [14]. Mobil robotlar ve konumlandırma sistemleri özelinde, mobil konum tahmini problemi icin KPSO tabanlı yeni bir konumlandırma algoritması geliştirilmiştir [15]. Çalışmada, algoritmanın yüksek konum doğruluğu sağladığı ve sistemsel hata oranlarını azalttığı belirtilmiştir. Ayrıca, İnsansız Kara Araçları (İKA) için önerilen Model Öngörülü Kontrol (Model Predictive Control-MPC) yapısı için PSO-MPC tabanlı bir yol izleme algoritmasında, KPSO'nun karmaşık sürüş senaryolarında düşük doğruluk ve zaman gecikmesi gibi sorunları aşma konusundaki etkili rolü vurgulanmıştır [16]. Huang vd. direksiyon teli sistemleri için geliştirilen MPC yapısının optimizasyonunda KPSO'yu kullanmış ve bu sayede kontrol başarımını önemli ölçüde artırmışlardır [17]. Chu vd. kaotik başlangıç mekanizması ve uyarlanabilir hız faktörlerini entegre ederek İnsansız Hava Araçları (İHA) için KPSO tabanlı bir rota planlama algoritması geliştirmiş, bu yaklaşımın İHA'ların karmaşık çevrelerde güvenli ve etkin bir sekilde gezinmesini sağladığını göstermiştir [18]. KPSO, Lineer Kuadratik Regülatör ile entegre edilerek, PSO'nun hızlı yakınsama yeteneği ile kaotik algoritmaların keşif gücünü bir araya getirilmiş ve bu yapının kontrol uygulamalarındaki performans artışına önemli katkı sağladığı gösterilmiştir [19]. Engel önleyici bir kontrol sisteminde kendi kendini koruyabilen bir denetleyici parametrelerinin optimize edilmesinde KPSO'nun etkili sonuçlar verdiği bildirilmiştir [20]. Güç Sistemi Dengeleyicisi ve PID denetleyici parametrelerinin optimizasyonu için KPSO kullanılarak sistem kararlılığı ve dinamik yanıt açısından iyilestirmeler elde edilmistir [21]. Bu kapsamlı literatür değerlendirmesi, KPSO algoritmasının yalnızca klasik PSO'ya kıyasla daha güçlü bir çözüm sunmakla kalmadığını, aynı zamanda enerji, yapay zekâ, konumlandırma, otonom sistemler ve özellikle kontrol mühendisliği gibi çok çeşitli disiplinlerde yüksek başarımlı bir optimizasyon aracı olarak kullanılabildiğini göstermektedir. Literatürde kaotik PSO uygulamalarında, genellikle yalnızca atalet ağırlığının kaotikleştirilmesine odaklanıldığı ve kaotik yapı

olarak çoğunlukla ayrık zamanlı sistemlerin (örneğin, Logistic veya Tent map) tercih edildiği gözlemlenmektedir. Ancak bu yaklaşımlar, algoritmanın rastgele sayı üretim sürecine doğrudan müdahale etmediğinden ve kaotik etkinin algoritmanın tüm dinamiklerine yayılmasını sınırladığından, potansiyel performans iyileştirmeleri açısından yetersiz kalabilmektedir. Dolayısıyla bu çalışmada, PSO algoritmasında kullanılan rastgele sayılar sürekli zamanlı bir kaotik sistem aracılığıyla üretilmiştir. Böylece algoritmanın tüm parametre güncellemelerinde kaotik etkinin doğrudan yer alması sağlanmıştır. Bu yönüyle çalışma, hem kaotik yapıların PSO algoritmasına entegrasyonuna yönelik farklı bir yaklaşım sunmakta hem de sürekli zamanlı kaotik sistemlerin bu bağlamda uygulanabilirliğine dair literatüre özgün bir katkı sağlamaktadır.

2 Materyal ve Yöntem

Bu çalışmada DC motorun hız kontrolünde, kontrolcü parametrelerinin seçimine ait optimizasyon probleminin çözümü için PSO ve PSO'nun kaotik sistemlerle entegre edilmiş versiyonu olan KPSO kullanılmıştır. Bu optimizasyon tekniklerinde amaç fonksiyonu olarak Zaman Ağırlıklı Hatanın Karesinin İntegrali (ZAHKİ) seçilmiştir. ZAHKİ, hata karelerini zamana göre ağırlıklandırarak sistemin hızlı ve kararlı bir şekilde nihai değerine ulaşmasını hedeflemektedir.

2.1 Parçacık Sürü Optimizasyonu Algoritması

PSO doğadan esinlenilerek geliştirilen bir optimizasyon algoritmasıdır. PSO kuş ya da balık sürülerinin grup halinde hareket ederek bir hedefe ulaşma davranışlarından ilham alınan sürü tabanlı bir optimizasyon algoritmasıdır. PSO bir çözüm kümesini temsil eden "parçacıklar" ile çalışır. Bu parçacıklar, çözüm uzayında rastgele başlangıç noktalarından başlar. Yiyecek arama alanında rastgele bir şekilde dağılan sürü elemanları, yiyecek bulamadıklarında aynı anda yönlerini ve pozisyonlarını değiştirir. Yaptıkları bu yeni yön ve pozisyon değişikliklerinin ardından, sürü içindeki bireyler birbirleriyle yiyeceğin konumu ve yiyeceğe en yakın kuşun pozisyonu hakkında bilgi paylaşarak hedefe ulaşmaya çalışır. Arama alanındaki her bir parçacık, kendi pozisyonunu ve hızını, yiyeceğe en yakın olan parçacığa göre günceller. Bu bilgi paylaşımı sürecinde, her parçacık aşağıdaki iki önemli değeri hafızasında tutar ve bu iki değere göre hareket eder.

-Bireysel En İyi Konum (*pBest*): Parçacığın şimdiye kadar elde ettiği en iyi çözüm

-Sürü En İyi Konum (gBest): Tüm parçacıklar arasında elde edilen en iyi genel çözüm

PSO'da her bir iterasyonda parçacıkların hızları güncellenir. Güncelleme için kullanılan denklem aşağıda verilmiştir.

$$v_i(k+1) = w * v_i(k) + c_1 * r_1 * (pBest - x_i(k)) + c_2 * r_2 * (gBest - x_i(k))$$
(1)

Denklem (1)'de verilen k güncel iterasyon değerini, *i* parçacık sayısını, v_i *i*. parçacığın hızını, c_1 , c_2 öğrenme katsayılarını, x_i *i*. parçacığının pozisyonunu, w atalet ağırlığını ifade etmektedir. Atalet ağırlığı, parçacığın hızını ne kadar koruyacağını belirlerken, r_1 ve r_2 0 ila 1 arasında değişen rastgele değerlerdir.

Denklem (1) ile parçacıkların bir sonraki iterasyonda kullanacakları hız verileri elde edildikten sonra parçacıkların pozisyonları Denklem (2) ile güncellenir.

$$x_i(k+1) = x_i(k) + v_i(k+1)$$
(2)

PSO algoritmasına ait akış şeması Şekil 1'de verildiği gibidir.



Şekil 1: PSO akış şeması

Şekil 1'de başlangıç aşamasında parçacıkların pozisyonu ve hızı rastgele atanır. Uygunluk kontrolü aşamasında her parçacığın mevcut konumu bir amaç fonksiyonuyla değerlendirilerek bireyin ve sürünün en iyi konumları *pBest* ve *gBest* güncellenir. Parçacıkların hızı ve konumu sırasıyla Denklem 1 ve Denklem 2'ye göre güncellenir. Durum kontrolü aşamasında belirlenen durdurma kriterine (maksimum iterasyon sayısı veya hedef uygunluk değeri) ulaşıldıysa döngü durdurulur; aksi takdirde döngü devam ettirilir.

2.2 Kaotik Parçacık Sürü Optimizasyonu

Kaotik Parçacık Sürü Optimizasyonu, klasik PSO algoritmasının kaotik haritalarla geliştirilmiş bir türevidir. KPSO, klasik PSO'nun yerel minimuma sıkışma ve yetersiz çeşitlilik gibi sorunlarını aşmak amacıyla kaos teorisinden faydalanır. Kaotik sistemler, deterministik olmalarına rağmen, başlangıç koşullarına son derece duyarlı doğrusal olmayan dinamik sistemlerdir. Bu özellikleri optimizasyon süreçlerinde daha etkili bir keşif sağlayabilir. KPSO, PSO algoritmasının bazı bileşenlerini kaotik davranışla düzenler. Bu genellikle kaosun matematiksel temsili olan kaotik haritalarla, rastgele sayıların yerini alarak algoritmanın daha etkili bir şekilde çalışmasını sağlar. Bu işlem PSO'nun hız güncelleme denklemindeki rastgele sayılarında (r_1, r_2) gerçekleştirilir. Böylece, klasik PSO'nun rastgele arama davranışı yerine, kaotik davranışların daha düzenli ve etkili bir şekilde uygulanması sağlanır. Bu yaklaşım, algoritmanın daha geniş bir çözüm uzayını keşfetmesine ve yerel minimumdan kaçmasına yardımcı olur. Rastgele sayıların elde edilmesi için kullanılan Duffing-Van Der Pol Kaotik sistemine ait denklem aşağıda verilmiştir [22].

$$\dot{x}(t) = y(t)$$

$$\dot{y}(t) = a * (1 - x^{2}(t)) * y(t) - x^{3}(t) + b * \cos(c * z(t))$$

$$\dot{z}(t) = 1$$
(3)

Değişkenler a=0.2, b=5.8 ve c=3 olarak alınmıştır. Başlangıç koşulları ise x(0) = 0, y(0) = 0, z(0) = 0 olarak seçilmiştir. Otonom olmayan bu sistem z=t dönüşümüyle otonom hale getirilmiştir [23]. Değişkenler ve başlangıç koşulları literatürde yaygın kullanılan değerlerden seçilmiştir.

2.3 DC Motor Hız Kontrolü için PID Parametrelerinin PSO ve KPSO ile Optimizasyonu

Bu çalışmada, önerilen optimizasyon yaklaşımının etkinliği, PID kontrolör parametrelerinin ayarlanması problemi üzerinden değerlendirilmiştir. Bu doğrultuda, kullanılan algoritmaların amaç fonksiyonunu minimum değere yakınsama performansları analiz edilmiştir. DC motorun hız kontrolü uygulaması kapsamında, PID kontrolörün parametreleri, hata tabanlı ZAHKİ amaç fonksiyonu esas alınarak, Parçacık Sürü Optimizasyonu ve Kaotik Parçacık Sürü Optimizasyonu algoritmaları ile optimize edilmiştir. DC motorun kapalı çevrim kontrolüne ait blok diyagram Şekil 2'de verilmiştir.



Şekil 2: Tasarlanan sistemin blok diyagramı

DC motorun dinamik davranışı diferansiyel denklemler ile ifade edilir ve matematiksel modeli karmaşık frekans düzleminde transfer fonksiyonu ile verilir. DC motorun matematiksel modeli aşağıdaki gibidir.

$$V_{a} = i_{a}R_{a} + L_{a}\frac{di_{a}}{dt} + e_{b}$$

$$e_{b} = K_{e}\omega(t)$$

$$T = J\frac{d\omega}{dt} + B\omega + T_{l}$$

$$T = K_{m}i_{a}(t)$$
(4)

Denklem (4)'de V_a , i_a , R_a ve L_a sırasıyla motorun armatür gerilimi, akımı, direnci ve endüktansıdır. Ayrıca e_b zıt elektro motor kuvveti, K_e gerilim sabitini, T üretilen momenti, J atalet momentini, B sönümleme sabitini, T_l yük momentini, K_m moment sabitini ve ω motorun açısal hızını ifade etmektedir. DC motorun parametreleri Tablo 1'de verilmiştir [24].

R _a	0.517Ω
L_a	0.0573H
В	0.000244
J	$0.00000145 kgm^2/s^2$
K _e	0.0112Vs/rad
K_m	0.0112Nm/A
Redüktör oranı	1/52

Tablo 1: DC motor parametreleri

DC motorun hız kontrolünde kontrolcü olarak PID seçilmiştir. PID kontrolcünün K_p , K_i ve K_d parametrelerinin, DC motorun arzu edilen performansı sergileyecek şekilde ayarlanması gerekmektedir. Bu çalışmada kontrolcü parametreleri PSO ve KPSO algoritmaları kullanılarak belirlenmiştir. PID parametrelerinin optimizasyonunda hata sinyali e(t) minimize edilmesi amaçlanmıştır. Amaç fonksiyonu olarak ise Denklem (5) ile ifade edilen Zaman Ağırlıklı Kare Hata İntegrali kullanılmıştır.

$$ZAHK\dot{I} = \int te^2(t)dt$$
⁽⁵⁾

3 Bulgular

Bu bölümde, PSO ve KPSO algoritmaları kullanılarak optimize edilen PID kontrolcünün simülasyon ortamındaki performans sonuçları sunulmaktadır. Bu çalışma, MATLAB/Simulink R2022a sürümü kullanılarak gerçekleştirilmiştir. Simülasyon süresi 0.1 saniye olarak belirlenmiş, sabit zaman adımı ise 0.001 saniye olarak seçilmiştir. Tüm simülasyon çalışmaları, Windows-10 64-bit işletim sistemine sahip, 2.60 GHz işlemcili ve 12 GB RAM donanımlı bir bilgisayarda yürütülmüştür. PSO ve KPSO optimizasyon algoritmalarında kullanılan parametreler, Tablo 2'de detaylı bir şekilde verilmiştir.

	Parcacık sayısı $i=50$
KPSO	İterasyon sınırı=50
	Atalet ağırlığı (w)=1
	Bireysel öğrenme kat sayısı (c_1)=2.1
	Sosyal öğrenme kat sayısı (c_2)=2.1
	Parçacık sayısı i=50
PSO	İterasyon sınırı =50
	Atalet ağırlığı (w)=1
	Bireysel öğrenme kat sayısı (c_1)=2.1
	Sosyal öğrenme kat sayısı (c_2)=2.1

Tablo 2: Optimizasyon yöntemlerinde kullanılan parametreler

PID kontrolcünün K_p , K_i ve K_d parametreleri, KPSO ve PSO algoritmaları ile Tablo 2'de belirtilen parametreler kullanılarak, hata tabanlı ZAHKİ amaç fonksiyonu üzerinden optimize edilmiştir. KPSO ve PSO algoritmaları ile elde edilen amaç fonksiyonu uygunluk değerleri ve optimize edilmiş kontrolcü parametreleri Tablo 3'te sunulmuştur.

	K _p	K _i	K _d	Uygunluk Değeri
KPSO	42.161766	166.226012	0.248816	0.000016
PSO	28.024663	176.891949	0.04789	0.000038

Tablo 3: Optimize edilmiş PID parametreleri

Tablo 3 incelendiğinde, KPSO algoritmasının daha düşük bir amaç fonksiyonu uygunluk değeri elde ettiği görülmektedir. Optimize edilen PID parametreleri kullanılarak DC motorun kapalı çevrim hız performansı simülasyon ortamında test edilmiş ve elde edilen sonuçlar Şekil 3'te sunulmuştur.



Şekil 3: Optimize edilmiş PID kontrolcülerin, birim basamak referans sinyali karşısında elde edilen sistem yanıtları

Şekil 3 incelendiğinde, PSO ile optimize edilmiş PID kontrolcünün aşım yaparak referans değerine oturduğu, KPSO ile optimize edilmiş PID kontrolcünün ise aşım yapmadan referans değere oturduğu görülmektedir. PSO ve KPSO ile optimize edilmiş kontrolcülerin performanslarını karşılaştırmak için yapılan testler sonucunda elde dilen yükselme zamanı (Tr), yerleşme süresi (Ts), yüzde aşım değeri (%OS) ve kararlı hal hatası (KHH) değerleri, Tablo 4'te sunulmuştur.

	Tr(sn)	Ts(sn)	%OS	KHH
KPSO	0.022	0.032	0.6	0.0025
PSO	0.014	0.036	8.3	0.0020

Tablo 4: PID kontrolcü cevaplarının karşılaştırılması

Tablo 4'te verilen sonuçlara göre, KPSO algoritması kullanılarak optimize edilmiş kontrolcü ile kontrol edilen sistemin cevabı, aşım yapmadan 0.032 saniyede %0.25 hata ile referans değerine oturduğu görülmektedir. PSO algoritması kullanılarak optimize edilmiş kontrolcü ile kontrol edilen sistemin cevabı ise %8.3 aşım gerçekleştirerek 0.036 saniyede %0.20 hata değeri ile referans değerine oturduğu görülmektedir.

Şekil 4'te PSO ve KPSO algoritmalarıyla optimize edilen PID kontrolcülerinin birim basamak girişine karşılık ürettikleri kontrol sinyallerinin zamanla değişimi karşılaştırılmaktadır.



Şekil 4: PSO ve KPSO algoritmlarıyla ayarlanmış PID kontrolcüler tarafından birim basamak referans girişi için üretilen kontrol sinyalleri

Şekil 4 incelendiğinde, PSO tabanlı kontrolcü, başlangıç bölgesinden çıktıktan sonra önemli düzeyde salınım sergilemekte ve bu durum geçici rejim davranışını olumsuz yönde etkilemektedir. Buna karşın KPSO algoritması ile optimize edilen kontrolcü daha yumuşak bir geçiş sergilemekte ve kısa sürede kararlı hale gelmektedir.

Şekil 5'te, PSO ve KPSO algoritmaları ile optimize edilen PID kontrolcülerin birim basamak referans sinyaline karşılık oluşan hata sinyallerinin zamana bağlı değişimleri karşılaştırmalı olarak sunulmuştur. PSO algoritmasına kıyasla, KPSO algoritması ile elde edilen PID kontrolcünün hata sinyalinin daha düşük salınım ve daha düzenli bir geçiş eğilimi sergilediği görülmektedir.



Şekil 5: PSO ve KPSO algoritmaları ile ayarlanmış PID kontrolcüler tarafından birim basamak referans girişi altında elde edilen hata sinyalleri

Simülasyon ortamında, DC motora 0.05 saniyede 0.01Nm büyüklüğünde bozucu bir etki uygulanmış ve elde edilen sistem tepkileri Şekil 6'da verilmiştir.



Şekil 6: Bozucu etki altında, optimize edilmiş PID kontrolcüler tarafından birim basamak referans sinyali için elde edilen sistem yanıtları

Kontrolcülerin performansları Şekil 6'da gösterilmiştir. Bozucu etkinin uygulanmasının ardından, PSO algoritması ile optimize edilmiş PID kontrolcüsüyle elde edilen sistem yanıtı, referans değere kıyasla %25 oranında azalma göstermiştir. KPSO algoritması ile optimize edilmiş PID kontrolcüsü için ise bu azalma %20 olarak gerçekleşmiştir. Bozucu etki süresince, PSO-PID kontrolcüsü %2.5 oranında aşım sergilemiş ve 0.086 saniyede %1'lik yerleşme bandı içerisine kalıcı olarak girmiştir. Öte yandan, KPSO-PID kontrolcüsü aşım gerçekleştirmemiş ve 0.071 saniyede %1'lik yerleşme bandı içerisine kalıcı olarak girmiştir.

Şekil 7'de, 0.05 saniye anında sisteme 0.01 Nm büyüklüğünde bir bozucu etki uygulandığında, PSO ve KPSO algoritmalarıyla optimize edilmiş PID kontrolcülerinin ürettiği kontrol sinyallerinin zamana bağlı değişimi gösterilmektedir.



Şekil 7: PSO ve KPSO algoritmalarıyla ayarlanmış PID kontrolcüler tarafından, bozucu etki altında birim basamak referans girişi için üretilen kontrol sinyalleri

Şekil 7 incelendiğinde, bozucu etkinin uygulandığı anda, her iki kontrol yapısının da kontrol sinyalinde ani bir yükselme meydana gelmiş; sistemdeki denge bozulduğunda bu bozulmayı kompanse etmek için kontrolcülerin aktif şekilde müdahalede bulunduğu görülmektedir. Ancak, PSO ile elde edilen kontrol sinyali daha yüksek genlikli salınımlar sergileyerek tekrar dengeye ulaşmakta gecikirken, KPSO tabanlı kontrol yapısı bozucu etkinin etkisini daha hızlı ve daha az salınımla bastırabilmiştir.

Şekil 8'de, 0.05 saniye anında uygulanan 0.01 Nm büyüklüğündeki bozucu etki sonrası PSO ve KPSO algoritmalarıyla optimize edilen PID kontrolcülerine ait hata sinyallerinin zamana bağlı değişimi sunulmuştur.



Şekil 8: PSO ve KPSO algoritmaları ile ayarlanmış PID kontrolcüler tarafından, bozucu etki altında birim basamak referans girişi için elde edilen hata sinyalleri

Şekil 8 incelendiği zaman, bozucu etkinin uygulandığı 0.05 saniye sonrasında her iki kontrol yapısında da hata sinyalinde ani bir artış gözlemlenmiştir. Ancak PSO tabanlı kontrolcü bu bozulmaya daha büyük bir hata artışıyla tepki verirken, KPSO kontrolcüsünün verdiği tepki daha yumuşak ve kısa süreli olmuştur. Ayrıca, bozucunun ardından PSO kontrolcüsünde tekrar salınımlar oluştuğu, buna karşın KPSO'nun daha hızlı ve salınımsız biçimde dengeye ulaştığı görülmektedir.

Kontrolcülerin dinamik referans sinyalini izleme yeteneklerini değerlendirmek amacıyla, DC motor sistemine çeyrek periyotluk sinüzoidal bir referans sinyali uygulanmıştır. Şekil 9'da PSO ve KPSO algoritmalarıyla optimize edilen PID kontrolcülere ait hız yanıtları karşılaştırmalı olarak sunulmaktadır.



Şekil 9: Optimize edilmiş PID kontrolcüler tarafından, çeyrek periyotluk sinüzoidal referans sinyali için elde edilen sistem yanıtları

Şekil 9 incelendiğinde, ilk aşamalarda yetersiz tepki vererek referansın altında seyretmiştir. KPSO ile optimize edilen kontrolcü ise daha kısa sürede referans eğrisine yaklaşmaktadır. Her iki algoritma ile elde edilen kontrol sistemlerinin, referans sinyale karşılık gelen hız profilini genel olarak başarılı bir şekilde izlediği görülmektedir. Ancak KPSO algoritması, referans sinyale daha yakın seyreden bir hız yanıtı sunarak izleme performansı açısından üstünlük sağlamıştır.

Şekil 10'da çeyrek periyotluk sinüzoidal referans sinyali altında PSO ve KPSO algoritmalarıyla optimize edilen PID kontrolcülerine ait kontrol sinyallerinin zamana bağlı değişimi sunulmaktadır.



Şekil 10: PSO ve KPSO algoritmalarıyla ayarlanmış PID kontrolcüler tarafından, çeyrek periyotluk sinüzoidal referans sinyali için üretilen kontrol sinyalleri

Şekil 10 incelendiğinde, KPSO tabanlı kontrolcünün başlangıçta oldukça yüksek bir kontrol sinyali ürettiği, ancak bu değerin çok kısa sürede hızlı bir şekilde azaldığı ve sistemin kontrol sınırlarına daha hızlı şekilde ulaştığı görülmektedir. PSO algoritması ile optimize edilen kontrolcü ise daha düşük bir genlikle ve daha yumuşak bir kontrol tepkisi üretmiştir.

Şekil 11'de, sisteme çeyrek periyotluk sinüzoidal referans sinyali uygulanması durumunda PSO ve KPSO algoritmaları ile optimize edilen PID kontrolcülerinin oluşturduğu hata sinyallerinin zamana bağlı değişimi karşılaştırmalı olarak gösterilmektedir.



Şekil 11: PSO ve KPSO algoritmaları ile ayarlanmış PID kontrolcüler tarafından çeyrek periyotluk sinüzoidal referans sinyali altında elde edilen hata sinyalleri

Şekil 11 incelendiğinde, sistemin başlangıç tepkisinde PSO algoritması ile elde edilen PID kontrolcünün yaklaşık 0.055 seviyesinde bir maksimum hata değeri ürettiği gözlemlenmektedir. Buna karşılık, KPSO algoritması ile optimize edilen kontrolcü yaklaşık 0.03 değerinde daha düşük bir maksimum hata ile sistem yanıtını stabilize etmiş ve hatayı daha kısa sürede sönümlendirmiştir. KPSO algoritması hem daha düşük genlikte hem de daha kararlı bir hata profili sergileyerek izleme performansı açısından PSO algoritmasına göre üstünlük sağlamıştır. Oluşan hata sinyallerine ait Tip-1 norm değerleri incelendiğinde, PSO için 36.7112, KPSO için ise 26.7944 olarak hesaplanmıştır.

Şekil 12'de, DC motor sistemine uygulanan çeyrek periyotluk sinüzoidal referans sinyali altında, 0.05 saniyede bir bozucu etki uygulandığında PSO ve KPSO algoritmalarıyla optimize edilmiş PID kontrolcülerine ait hız yanıtları gösterilmektedir.



Şekil 12: Bozucu etki altında, optimize edilmiş PID kontrolcüler tarafından çeyrek periyotluk sinüzoidal referans sinyali için elde edilen sistem yanıtları

Şekil 12 incelendiği zaman, bozucu etkinin uygulandığı anda her iki kontrol yapısı da sistem yanıtında ani bir düşüş yaşamıştır. Ancak bu düşüşün büyüklüğü ve toparlanma süresi kontrolcü performansına göre farklılık göstermektedir. PSO tabanlı kontrolcü daha büyük bir sapma sergilerken, sistem cevabı referanstan önemli ölçüde uzaklaşmıştır. Buna karşılık, KPSO ile optimize edilen kontrolcü daha küçük bir sapma ile bozucu etkinin etkisini sönümlemiş ve referans sinyale daha hızlı şekilde geri dönmüştür.

Şekil 13'te, DC motor sistemine çeyrek periyotluk sinüzoidal referans sinyali uygulanırken, 0.05 saniyede sisteme bir bozucu etki eklenmiş ve PSO ile KPSO algoritmalarıyla optimize edilen PID kontrolcülerinin ürettiği kontrol sinyalleri zamana bağlı olarak karşılaştırılmıştır.



Şekil 13: Bozucu etki altında, PSO ve KPSO algoritmalarıyla optimize edilmiş PID kontrolcüler tarafından çeyrek periyotluk sinüzoidal referans sinyali için üretilen kontrol sinyalleri

Şekil 13 incelendiğinde, uygulanan bozucu etki sonrasında kontrol sinyallerinde ani ve yüksek genlikli tepkiler oluşmuştur. Bu noktada, KPSO algoritmasıyla optimize edilen kontrolcü, maksimum kontrol sinyaline daha hızlı ulaşarak bozucu etkiyi daha agresif şekilde bastırma eğilimindedir. PSO ile optimize edilen kontrolcü ise daha yumuşak ancak daha gecikmeli bir tepki üretmiştir. Zaman ilerledikçe, KPSO algoritmasıyla optimize edilen kontrolcünün kontrol sinyali daha kısa sürede kararlı hale gelirken; PSO algoritmasıyla optimize edilen kontrolcü, bozucu etki sonrası salınımlar sergileyerek sistemin yeniden kararlılığa ulaşmasını geciktirmiştir.

Şekil 14'te, PSO ile KPSO algoritmalarıyla optimize edilen PID kontrolcülerine ait hata sinyalleri zamana bağlı olarak karşılaştırılmıştır.



Şekil 14: Bozucu etki altında, PSO ve KPSO algoritmaları ile ayarlanmış PID kontrolcüler tarafından çeyrek periyotluk sinüzoidal referans sinyali için elde edilen hata sinyalleri

Şekil 14 incelendiği zaman, bozucu etki uygulandığı anda her iki kontrol yapısında da hata seviyesinde ani bir artış yaşanmıştır. Bununla birlikte, PSO algoritması ile optimize edilen kontrolcüde hata büyüklüğü yaklaşık 0.29 seviyelerine kadar yükselmiş ve ardından dalgalı bir geçici rejim oluşmuştur. KPSO algoritması ile elde edilen kontrolcü ise bozucu etkinin etkisini daha düşük bir hata tepkisi ile karşılamış, yaklaşık 0.24 seviyelerinde tepe yaparak daha kısa sürede ve daha düzgün bir geçişle hatayı bastırmıştır. Oluşan hata sinyallerine ait Tip-1 norm değerleri incelendiğinde, PSO için 56.6999, KPSO için ise 48.9492 olarak hesaplanmıştır.

4 Tartışma

Bu çalışmada, PSO ve KPSO algoritmaları kullanılarak optimize edilen PID kontrolcülerinin performansları karşılaştırmalı olarak incelenmiştir. Aynı optimizasyon parametrelerini kullanan KPSO'nun, klasik PSO'ya kıyasla daha düşük bir uygunluk değerine ulaşması, PSO algoritmasının kaotik sistemlerle entegrasyonunun amaç fonksiyonunun minimuma yakınsamasında daha etkili olduğunu ortaya koymaktadır. Ayrıca simülasyon sonuçlarından KPSO'nun daha kısa yerleşme süresi sağladığı ve aşım oranını önemli ölçüde azalttığı görülmektedir. Aynı zamanda kontrol edilen sisteme bir bozucu etki uygulandığında KPSO'nun PSO'ya kıyasla daha sağlam bir kontrolcü sağladığı görülmektedir. Bu bulgular, KPSO'nun daha hızlı ve etkili bir şekilde optimal çözüme ulaştığını kanıtlamaktadır. KPSO algoritmasının yalnızca sabit referanslara değil, aynı zamanda zamanla değişen referanslara karşı da daha uygun bir kontrol davranışı sergileyebildiği gösterilmektedir.

KPSO'nun klasik PSO'ya göre PID kontrolcü parametrelerinin optimizasyonunda daha üstün bir performans sergilemesi, kaotik sistemlerin optimizasyon süreçlerine entegrasyonunun önemli faydalar sunduğunu göstermektedir. KPSO'nun kaotik yapısı, algoritmanın optimum çözüme daha etkin bir biçimde ulaşmasını sağlamaktadır. Elde edilen sonuçlar, hassas kontrol gerektiren uygulamalarda KPSO'nun önemli avantajlar sunduğunu ve daha etkili kontrol stratejilerinin geliştirilmesine olanak tanıdığını ortaya koymaktadır. KPSO'nun sağladığı iyileştirmeler, bu alanda yapılacak gelecekteki araştırmalara değerli katkılar sağlaması beklenmektedir.

5 Beyanname

5.1 Rakip Çıkarlar

Bu çalışmada herhangi bir çıkar çatışması yoktur.

5.2 Yazarların Katkıları

Muhammed Salih SARIKAYA: Araştırmanın tasarımı ve uygulanması, literatür taraması, sonuçların analizi, makale yazımı.

Onur DEMİREL: Literatür taraması, makaleyi gözden geçirme ve düzenleme.

Sezgin KAÇAR: Düzenleme ve denetim.

Adnan DERDİYOK: Düzenleme ve denetim.

Kaynakça

- [1] Zhong, F. (2023). Dynamic parameter identification based on improved particle swarm optimization and comprehensive excitation trajectory for 6R robotic arm. Industrial Robot: The International Journal of Robotics Research and Application, 51(1), 148–166. https://doi.org/10.1108/ir-07-2023-0157
- [2] Abedinifar, M., Ertuğrul, Ş., & Arguz, S. (2022). Nonlinear model identification and statistical verification using experimental data with a case study of the UR5 manipulator joint parameters. *Robotica*, 41(4), 1348–1370. https://doi.org/10.1017/s0263574722001783
- [3] Cosar, M. (2023). Path planning via swarm intelligence algorithms in unmanned aerial vehicle population. *The Eurasia Proceedings of Science Technology Engineering and Mathematics*, 26, 439–450. https://doi.org/10.55549/epstem.1411059
- [4] Wang, D., Liu, L., Ben, Y., Dai, P., & Wang, J. (2023). Seabed terrain-aided navigation algorithm based on combining artificial bee colony and particle swarm optimization. *Applied Sciences*, 13(2), 1166. https://doi.org/10.3390/app13021166
- [5] Wen, S., Liu, P., Wang, D., & Cao, F. (2014). Optimal tracking control for a Peltier refrigeration system based on PSO. *In Proceedings of the 2014 International Conference on Advanced Mechatronic Systems* (pp. 567–571). https://doi.org/10.1109/icamechs.2014.6911610
- [6] Tahtawi, A., Putri, F., & Martin, M. (2023). Position control of AX-12 servo motor using proportionalintegral-derivative controller with particle swarm optimization for robotic manipulator application. *IAES International Journal of Robotics and Automation (IJRA)*, 12(2), 184–191. https://doi.org/10.11591/ijra.v12i2.pp184-191
- Yu, Y., Xu, Y., Wang, F., Li, W., Mai, X., & Wu, H. (2020). Adsorption control of a pipeline robot based on improved PSO algorithm. *Complex & Intelligent Systems*, 7(4), 1797–1803. https://doi.org/10.1007/s40747-020-00190-z
- [8] Anshory, I., Hadidjaja, D., & Sulistiyowati, I. (2021). Measurement, modeling, and optimization speed control of BLDC motor using fuzzy-PSO based algorithm. *Journal of Electrical Technology UMY*, 5(1), 17–25. https://doi.org/10.18196/jet.v5i1.12113
- [9] Moghaddas, M., Dastranj, M., Changizi, N., & Rouhani, M. (2010). PID control of DC motor using particle swarm optimization (PSO) algorithm. *Journal of Mathematics and Computer Science*, 1(4), 386– 391. https://doi.org/10.22436/jmcs.001.04.16

- [10] Zhu, X., Li, S., Cheng, H., & Fan, Z. (2022). Application of particle swarm optimization algorithm in photovoltaic constant pressure water supply electrical control system. *Journal of Physics: Conference Series*, 2203(1), 012061. https://doi.org/10.1088/1742-6596/2203/1/012061
- [11] Li, Q., & Ma, Z. (2021). A hybrid dynamic probability mutation particle swarm optimization for engineering structure design. *Mobile Information Systems*, 2021, 1–32. https://doi.org/10.1155/2021/6648650
- [12] Dong, Z. (2023). Crop disease and pest identification technology based on ACPSO-SVM algorithm optimization. *Engenharia Agrícola*, 43(5). https://doi.org/10.1590/1809-4430eng.agric.v43n5e20230104/2023
- [13] Huang, J., Yang, J., Xie, D., & Wu, D. (2019). Optimal sliding mode chaos control of direct-drive wave power converter. *IEEE Access*, 7, 90922–90930. https://doi.org/10.1109/access.2019.2925470
- [14] Cheng, S. (2024). Synchronous control of high-speed train lift wing angle of attack drive system based on chaotic particle swarm optimization and linear auto-disturbance resistant controller. *Electronics*, 13(8), 1448. https://doi.org/10.3390/electronics13081448
- [15] Yue, Y., Cao, L., Hu, J., Cai, S., Hang, B., & Wu, H. (2019). A novel hybrid location algorithm based on chaotic particle swarm optimization for mobile position estimation. *IEEE Access*, 7, 58541–58552. https://doi.org/10.1109/access.2019.2914924
- [16] Jin, M. (2024). Method for the trajectory tracking control of unmanned ground vehicles based on chaotic particle swarm optimization and model predictive control. *Symmetry*, 16(6), 708. https://doi.org/10.3390/sym16060708
- [17] Huang, C., Naghdy, F., & Du, H. (2019). Fault tolerant sliding mode predictive control for uncertain steer-by-wire system. *IEEE Transactions on Cybernetics*, 49(1), 261–272. https://doi.org/10.1109/tcyb.2017.2771497
- [18] Chu, H., Yi, J., & Yang, F. (2022). Chaos particle swarm optimization enhancement algorithm for UAV safe path planning. *Applied Sciences*, 12(18), 8977. https://doi.org/10.3390/app12188977
- [19] Abdullah, H. (2021). An improvement in LQR controller design based on modified chaotic particle swarm optimization and model order reduction. *International Journal of Intelligent Engineering and Systems*, 14(1), 157–168. https://doi.org/10.22266/ijies2021.0228.16
- [20] Zhu, H. (2024). Optimizing active disturbance rejection control for a stubble breaking and obstacle avoiding control system. *Agriculture*, 14(5), 786. https://doi.org/10.3390/agriculture14050786
- [21] Mijbas, A., Hasan, B., & Salah, H. (2020). Optimal stabilizer PID parameters tuned by chaotic particle swarm optimization for damping low frequency oscillations (LFO) for single machine infinite bus system (SMIB). *Journal of Electrical Engineering and Technology*, 15(4), 1577–1584. https://doi.org/10.1007/s42835-020-00442-5
- [22] Sarıkaya, M. S., Hamida El Naser, Y., Kaçar, S., Yazıcı, İ., & Derdiyok, A. (2024). Chaotic-based improved Henry gas solubility optimization algorithm: Application to electric motor control. *Symmetry*, 16(11), 1435. https://doi.org/10.3390/sym16111435
- [23] Awrejcewicz, J., & Mrozowski, J. (1989). Bifurcations and chaos of a particular van der Pol-Duffing oscillator. *Journal of Sound and Vibration*, 132(1), 89–100. https://doi.org/10.1016/0022-460X(89)90873-0
- [24] Sarıkaya, M. S., Demirel, O., Kaçar, S., & Derdiyok, A. (2025). Modelling and chaotic based parameter optimization of sliding mode controller. *Journal of Mathematical Sciences and Modelling*, 8(2), 42–55. https://doi.org/10.33187/jmsm.1617412



© 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) license (https://creativecommons.org/licenses/by/4.0/)



Research articleJournal of Smart Systems Research (JOINSSR) 6(1), 62-73, 2025Recieved: 22-May -2025Accepted: 21-Jun-2025https://doi.org/10.58769/joinssr.1703625



BLDC Motorlar İçin Sensörsüz Komütasyon Tabanlı Elektronik Hız Kontrol Cihazı Simülasyonu

Mahmut Esat ÇULFAZ^{1*} ^(D), Mücahit SOYASLAN ²

¹ Mekatronik Mühendisliği, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi Türkiye mahmutculfaz@subu.edu.tr

² Mekatronik Mühendisliği, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi Türkiye msoyaslan@subu.edu.tr

ÖΖ

Bu çalışmada, fırçasız doğru akım (BLDC) motorları için sensörsüz komütasyon yöntemine dayalı bir motor sürücüsünün tasarımı ve simülasyonu gerçekleştirilmiştir. Sistem, Atmega328P mikrodenetleyicisi kullanılarak geliştirilmiş olup, kontrol algoritması motorun rotor konumunu tespit etmek amacıyla ters elektromotor kuvveti (Back-EMF) sinyallerine dayanmaktadır. IR2101 MOSFET sürücü entegresi ve IRFZ14 N-kanal MOSFET'leri ile oluşturulan güç sürücü katı, üç fazlı yarım köprü topolojisiyle yapılandırılmıştır. Elektronik Hız Kontrol Cihazı (ESC) sisteminin davranışı Proteus yazılımı üzerinde modellenmiş, PWM (darbe genişlik modülasyonu) üretimi, faz komütasyonu ve geri besleme mantığı dahil olmak üzere tüm kontrol algoritması sanal ortamda test edilmiştir. Simülasyon sonuçlarına göre, sistem doğru faz sıralamasını uygulayarak motoru kararlı şekilde döndürmüş; PWM zamanlaması, faz voltajları ve BEMF sinyalleri osiloskop üzerinde başarıyla gözlemlenmiştir. Elde edilen veriler, sensörsüz ESC sistemlerinin düşük maliyetli ve güvenilir kontrol çözümleri sunduğunu ortaya koymaktadır.

Anahtar Kelimeler: BLDC Motor, ESC, Elektronik Hız Kontrol Cihazı, Simülasyon, Sürücü Tasarımı.

Creative Commons Attribution 4.0 International (CC BY 4.0) license (https://creativecommons.org/licenses/by/4.0/)

^{*} Sorumlu yazarın e-posta adresi: mahmutculfaz@subu.edu.tr

Cite as: Çulfaz, M.E. & Soyaslan, M. (2025). BLDC Motorlar İçin Sensörsüz Komütasyon Tabanlı Elektronik Hız Kontrol Cihazı Simülasyonu, *Journal of Smart Systems Research*, 6(1), 62-73. https://doi.org/10.58769/joinssr.1703625

Simulation of a Sensorless Commutation-Based Electronic Speed Controller for BLDC Motors

ABSTRACT

In this study, a sensorless commutation-based motor driver for brushless direct current (BLDC) motors was designed and simulated. The system was developed using an Atmega328P microcontroller, and the control algorithm operates based on back electromotive force (Back-EMF) signals to estimate rotor position. The power driver stage was configured as a three-phase half-bridge topology utilizing IR2101 MOSFET driver ICs and IRFZ14 N-channel MOSFETs. The behaviour of the Electronic Speed Controller (ESC) system was modelled in simulation, and the control algorithm (including PWM generation, phase commutation, and feedback logic) was tested in a virtual environment. Simulation results confirmed the correct phase sequence and stable motor operation. PWM timing, phase voltages, and BEMF signals were successfully observed on the virtual oscilloscope. The findings demonstrate that sensorless ESC systems offer low-cost and reliable control solutions for BLDC motors.

Keywords: BLDC Motor, ESC, Electronic Speed Controller, Simulation, Driver Design.

1 Giriş

Günümüzde endüstriyel otomasyon, elektrikli araçlar, insansız hava araçları (İHA) ve robotik sistemler gibi birçok alanda, yüksek verimlilik, düşük bakım ihtiyacı ve uzun ömür gibi avantajları nedeniyle BLDC motorlar yaygın biçimde tercih edilmektedir. Ancak bu motorların etkin kontrolü, özel sürücü devrelerini gerekli kılmaktadır. Bu bağlamda, elektronik hız kontrol cihazları (ESC), BLDC motorların hassas ve verimli biçimde çalışmasını sağlayan temel bileşenlerdir. BLDC motorlar, sabit mıknatıslı yapıya sahip olup, mekanik firçalar yerine elektronik komütasyonla çalışan motor türleridir. Her ne kadar "doğru akım" motoru olarak adlandırılsalar da, üç fazlı yapıları nedeniyle doğrudan doğru akımla calısmazlar ve elektronik komütasyon gerektirirler [1]. Rotorlarında sabit mıknatıslar, statorlarında ise elektriksel olarak kontrol edilen sargılar bulunan bu motorlarda, mekanik komütasyon yerine elektronik komütasyon kullanılması daha uzun ömür ve kararlı çalışma koşulları sağlar [2]. Bu avantajları sayesinde BLDC motorlar, otomotivden robotik sistemlere kadar pek çok alanda tahrik sistemi olarak yaygın biçimde kullanılmaktadır [3, 4]. Elektronik komütasyon ihtiyacı, BLDC motorları geleneksel doğru akım motorlarına göre daha karmaşık sürücü sistemlerine bağımlı hâle getirmektedir. Bu motorlar, MOSFET veya IGBT gibi anahtarlama elemanlarıyla çalışan üç fazlı gerilim kaynaklarına ihtiyaç duyar. Anahtarlama elemanlarının doğru zamanlamayla iletime geçmesi, sistemin güvenli ve verimli calısması acısından kritik öneme sahiptir [5]. BLDC motorların kontrolünde rotor konumunun doğru belirlenmesi, komütasyon sırasının sağlıklı yürütülebilmesi açısından kritik öneme sahiptir. Bu doğrultuda iki temel kontrol yaklaşımı öne çıkmaktadır: sensörlü ve sensörsüz yöntemler. Sensörlü yöntemlerde, rotor konumu fiziksel algılayıcılarla doğrudan tespit edilir. En yaygın kullanılan Hall etkili sensörler düşük maliyetli ve uygulanabilir çözümler sunarken, optik sensörler ve manyetik enkoderler gibi daha hassas alternatifler de bulunmaktadır. Sensörsüz kontrol teknikleri, rotor konumunu motorun elektriksel tepkilerinden tahmin etmeye dayanır. En yaygın yaklaşım, sargı uçlarındaki gerilimlerin analizine dayanan geri EMK (Back-EMF) yöntemidir. Bu yöntem orta ve yüksek hızlarda etkin sonuçlar sunarken, düşük hız ve ilk kalkış anlarında bazı sınırlamalara sahiptir. Alternatif olarak sıfır geçiş tespiti, adaptif gözlemciler, Kalman filtresi ve yüksek frekans enjeksiyonu gibi gelişmiş tekniklerle daha geniş hız aralıklarında hassas kontrol sağlanabilir. Bu çalışmada geliştirilen ESC sistemi; Atmega328P mikrodenetlevicisi (Arduino Nano), IR2101 MOSFET sürücü entegresi ve IRFZ14 MOSFET'lerinden oluşmaktadır. Sensörsüz komütasyon temelli kontrol algoritması, Proteus simülasyon ortamında modellenmis ve analiz edilmistir. Bu sayede, donanım üretimine geçilmeden önce sistemin doğruluğu ve performansı etkin biçimde değerlendirilmiştir. ESC performansında, kullanılan mikrodenetleyici ve MOSFET sürücülerinin özellikleri belirleyici rol oynamaktadır. IR2101 entegresi, yüksek ve alçak taraf MOSFET'leri güvenli ve zamanlamalı biçimde sürerken; IRFZ14 gibi düşük R DS(on) değerine sahip MOSFET'ler anahtarlama kayıplarını azaltarak verimliliği artırır.

2 Literatür Araştırması

BLDC motorlarının sürülmesine yönelik kontrol devreleri, son yıllarda literatürde sıkça ele alınan bir konu olmuştur. Yapılan çalışmalarda, farklı kontrol stratejileri ile sensörlü ve sensörsüz yöntemlerin kullanıldığı görülmektedir. Mikrodenetleyici ve FPGA tabanlı sistem tasarımları bu alanda öne çıkan yaklaşımlar arasında yer almakta, ayrıca simülasyon temelli analizlere de yaygın biçimde başvurulmaktadır. Literatürdeki çalışmaların çoğu, sistemin maliyet, kontrol hassasiyeti ve uygulanabilirlik gibi kriterlerine bağlı olarak farklı yöntemlerin tercih edildiğini göstermektedir. Bu bağlamda hem donanım hem yazılım açısından farklılık gösteren çözümler geliştirilmiştir.

Mukherjee, Ray ve Das, düşük maliyetli ve mikrodenetleyici tabanlı bir BLDC motor sürücü sistemi tasarlamış ve hem simülasyon hem donanım düzeyinde uygulamıştır [7]. Çalışmada, PIC18F4331 mikrodenetleyicisi ile 120° altı adımlı komütasyon ve Hall sensörlerine dayalı kapalı çevrim hız kontrolü gerçekleştirilmiştir. Proteus VSM yazılımı, gerçek zamanlı simülasyon ve donanım entegrasyonu açısından etkin şekilde kullanılmıştır. Sistem, basit bir aç-kapa kontrol algoritması ile PWM darbe oranını ayarlayarak motor hızını düzenlemektedir. Elde edilen simülasyon ve denevsel sonuçlar, önerilen yöntemin geçerliliğini ortaya koymuştur. Yan'ın çalışmasında, BLDC motorlara vönelik sürücü devresi tasarımı yapıldıktan sonra sistemin davranısı MATLAB ortamında simüle edilmiştir [8]. Simülasyonda, motorun dinamik özelliklerini temsil eden eşdeğer devre modeli oluşturulmuş; akım, moment ve devir sayısı gibi parametreler analiz edilmiştir. Farklı uyartım yöntemleri (bipolar ve unipolar) karşılaştırılarak hız ve moment üzerindeki etkileri gözlemlenmiştir. Elde edilen sonuçlar, yazılımsal analizlerin prototip geliştirme sürecinde önemli bir rehber olduğunu göstermektedir. İmren'in çalışmasında, fırçasız doğru akım motoru (BLDC) sürücüsünün hem matematiksel modeli hem de donanımda test edilebilecek bir simülasyon yapısı geliştirilmiştir [9]. MATLAB & Simulink ortamında oluşturulan motor modeli, HDL Coder ile VHDL koduna dönüstürülerek FPGA platformuna entegre edilmistir. Sistem, donanım-yazılım birlikte test vöntemi olan HIL (Hardware-in-the-Loop) yapısında gerçekleştirilmiştir. Simülasyon bloğunda trapezoidal komütasyon, üç fazlı motor dinamikleri, hall sensör tepkileri ve kontrol algoritması modellenmiştir. Elde edilen sonuçlar, tasarlanan sürücünün yazılım ve donanım geliştirme sürecine doğrudan katkı sağlamıştır. Avdoğdu ve Bayer'in calışmaşında, fircaşız doğru akım (BLDC) motorları için PIC 16F876 mikrodenetleyicisi tabanlı düşük maliyetli ve basit yapılı bir motor sürücü sistemi tasarlanarak uvgulanmıştır [10]. Sistem, hall sensörlerinden alınan rotor konum bilgilerine göre kapalı cevrim komütasyon gerçekleştirmiştir. Güç ve kontrol katı arasında optik izolasyon sağlanmış, inverter kısmında P ve N kanallı MOSFET'ler kullanılmış ve bu elemanlar TC4427 sürücü entegresi ile sürülmüştür. Yazılım ASM diliyle geliştirilmiş, PWM sinyali yazılımsal olarak üretilmiştir. Test sonuçları, sistemin kararlı çalıştığını ve pratik uygulamalarda güvenle kullanılabileceğini göstermiştir.

Literatürdeki birçok çalışma, sensörlü kontrol sistemlerine veya donanıma dayalı testlere odaklanmaktadır. Örneğin, Mukherjee ve arkadaşları hall sensörlü hız kontrolü geliştirirken, Aydoğdu ve Bayer düşük maliyetli bir sensörlü sistem tasarlamıştır [7, 10]. Simülasyon temelli çalışmalarda ise genellikle hazır motor modelleri üzerinden analiz yapılmakta, kontrol algoritmaları bütüncül olarak ele alınmamaktadır [8, 9]. Bu çalışmada ise, sensörsüz komütasyon temelli bir kontrol algoritması Proteus ortamında tam devre modeliyle entegre biçimde uygulanmış, BEMF sinyalleri üzerinden sıfır geçiş algılaması gerçekleştirilmiştir. Donanım üretimine gerek kalmadan sistemin kontrol mantığı yazılım düzeyinde test edilerek, literatürdeki mevcut yaklaşımlara göre düşük maliyetli ve bütünleşik bir çözüm sunulmuştur.

3 Materyal ve Metodoloji

3.1 Simülasyon Ortamı ve Araçları

Simülasyon sisteminde kontrol birimi olarak Atmega328P tabanlı Arduino Nano sanal bileşeni tercih edilmiştir. Arduino bileşeni, hem PWM üretimi hem de komütasyon mantığının uygulanması açısından kullanılmış ve Proteus ortamında fiziksel mikrodenetleyicinin davranışı taklit edilmiştir. Bu mikrodenetleyici, sensörsüz komütasyon için gerekli olan 6-step geçiş algoritmasını çalıştırmakta ve üç

fazlı çıkışları kontrol etmektedir.



Şekil 1: Motor Sürücü Diyagramı

Güç sürücü katı, IR2101 yüksek/alçak taraf MOSFET sürücü entegresi ile modellenmiştir. Bu entegre, Arduino'dan gelen PWM sinyallerini izole etmeksizin alarak üç fazlı MOSFET anahtarlama devresini kontrol etmektedir. Her faz için IRFZ14 model numaralı N-kanal MOSFET'ler kullanılmış ve bunlar üçlü yarım köprü topolojisinde bağlanmıştır. Proteus ortamında IR2101 entegresiyle birlikte bu MOSFET'lerin davranışları detaylı olarak gözlemlenebilmiştir. Ayrıca, simülasyon sürecinde BLDC motorun modellenmesi için Proteus'ta hazır bir motor modeli kullanılmış; bu model üzerinden faz gerilimleri, akımlar ve motorun dönüş yönü gibi fiziksel parametreler ölçülmüştür.

Va	12 V	
RPM	600 dev/dk	
Ra	6 ohm	
La	10 mH	

Sistemin geri besleme kısmı, hall sensör yerine boşta kalan fazlardan elde edilen ters elektromotor kuvveti (BEMF) sinyalleri üzerine kurgulanmış ve bu sinyaller dijital karşılaştırıcı (komparatör) ile sıfır geçiş noktalarında tespit edilmiştir. Sistemin doğruluğu, Proteus üzerinde yerleştirilen osiloskop ve voltmetre bileşenleri yardımıyla analiz edilmiş faz gerilimlerinin dalga şekilleri ve PWM sinyallerinin zamanlaması gerçek zamanlı olarak değerlendirilmiştir. Böylece donanımsal üretim yapılmaksızın ESC yapısının doğru çalıştığı sanal ortamda gösterilmiştir. Şekil 1'de Proteus ortamında kurulan simülasyon devresi gösterilmiştir.



Şekil 2: Simülasyon Devre Şeması

3.2 MOSFET Anahtarlama Yapısı

BLDC motorların üç fazlı yapısı, her fazın belirli bir sırayla enerjilendirilmesini gerektirir. Bu işlem, genellikle altı adımlı (6-step) komütasyon algoritması ile gerçekleştirilir. Bu çalışmada kullanılan simülasyon devresinde her faz için iki adet IRFZ14 N-kanal MOSFET kullanılmış ve toplamda altı MOSFET'ten oluşan bir üç fazlı yarım köprü topolojisi kurulmuştur.MOSFET'lerin anahtarlanması, Arduino (Atmega328P) tarafından üretilen PWM sinyalleri ile kontrol edilmektedir.

Her komütasyon adımında bir faz PWM sinyali ile sürülürken diğer iki faz HIGH/LOW seviyelerine ayarlanmakta ve bu döngü sürekli olarak altı adımda tamamlanmaktadır. Bu sayede motor sargılarında sıralı bir akım akışı sağlanmakta ve rotor sürekli döndürülmektedir.MOSFET'lerin anahtarlanmasında dikkat edilen en önemli nokta, aynı fazın üst ve alt tarafındaki MOSFET'lerin aynı anda iletime geçmemesidir. Bu duruma "çapraz iletim" (shoot-through) denir ve devre elemanlarının zarar görmesine neden olabilir.Bu nedenle IR2101 entegresi, uygun ölü zaman (dead-time) oluşturarak iki MOSFET arasında güvenli bir geçiş sağlamaktadır.Simülasyon ortamında MOSFET'lerin açılma ve kapanma durumları, IR2101 çıkış uçları (HO- high output ve LO- low output) üzerinden izlenebilmekte ve PWM zamanlaması osiloskop yardımıyla doğrulanabilmektedir. Böylece fazlar arasındaki akım yönü ve motorun dönüş yönü gözlemlenebilir hâle gelmiştir. Şekil 2'de tek faz MOSFET bağlantı şeması paylaşılmıştır.



Şekil 3: Tek Faz MOSFET Bağlantısı

3.3 MOSFET Sürücü Kullanımı ve IR2101 Entegresinin Çalışma Prensibi

BLDC motor sürücü sistemlerinde, MOSFET'lerin hızlı ve güvenli bir şekilde anahtarlanabilmesi için doğrudan mikrodenetleyici bağlantısı yeterli değildir. Mikrodenetleyiciler genellikle düşük akım sağlayabildikleri için yüksek kapasiteli MOSFET kapılarının doğrudan sürülmesinde yetersiz kalır. Ayrıca, üç fazlı sistemlerde üst (high-side) MOSFET'lerin kapı gerilimi, motor faz gerilimine göre dinamik olarak değiştiğinden, bu gerilimi güvenli şekilde uygulayacak bir ara katmana ihtiyaç duyulmaktadır. Bu tür durumlarda MOSFET sürücü entegreleri devreye girer.

Bu çalışmada IR2101 yarım köprü sürücü entegresi kullanılarak hem alt (low-side) hem de üst (highside) MOSFET'ler sürülmüştür. IR2101, iç yapısında yer alan bootstrap devresi ile yüksek taraf MOSFET'in kapı gerilimini dinamik olarak oluşturur. Böylece hem düşük hem de yüksek taraf MOSFET'ler doğru zamanlamayla sürülebilir. Entegre, input pinlerinden aldığı PWM sinyaline göre HO ve LO uçlarından çıkış vererek MOSFET kapılarını kontrol eder.



Şekil 4: Tek Faz için MOSFET Sürücü Entegresi

Proteus simülasyon devresinde her faz için bir IR2101 entegresi kullanılmıştır. Toplam üç adet IR2101 entegresiyle üç fazın tamamı sürülmüş, giriş PWM sinyalleri Arduino üzerinden sağlanmıştır. Bu yapı sayesinde MOSFET'lerin güvenli bir şekilde açılıp kapanması ve motorun düzgün komütasyonu sağlanmıştır. Şekil 3'te IR2101 ile tek faz MOSFET sürücü entegre bağlantı şeması verilmiştir.

3.4 Sensörsüz Geri Besleme: Ters Elektromotor Kuvveti Algılaması

BLDC motorlarda, rotor pozisyonunun doğru belirlenmesi komütasyon sırasının sağlıklı yürütülebilmesi açısından kritik öneme sahiptir. Sensörsüz kontrol yöntemlerinde, bu bilgi harici hall sensörleri yerine motor fazlarından elde edilen ters elektromotor kuvveti (Back-EMF, BEMF) sinyalleri üzerinden çıkarılır [10]. Bu yöntem, sistem maliyetini düşürmenin yanı sıra fiziksel sensör arızalarının da önüne geçer.

BEMF temelli sürücü sistemlerinde, her komütasyon adımında bir faz sürülmez ve bu boşta kalan fazdan alınan BEMF sinyali analog karşılaştırıcı veya ADC (analog-dijital çevirici) aracılığıyla izlenir. Sıfir geçiş anı (zero crossing) tespit edildiğinde, rotorun manyetik alan yapısından dolayı bu sinyalin sıfıra yaklaşması bir sonraki komütasyonun zamanlamasını belirler. Simülasyonda, boşta kalan fazın gerilimi gerilim bölücü dirençler aracılığıyla Arduino'nun analog girişine uygulanmıştır. Bu sinyal program içinde dijital olarak yorumlanarak sıfır geçiş anında komütasyon adımı ilerletilmiştir. Şekil 4'te Back-EMF bağlantı şeması paylaşılmıştır.



Şekil 5: Back-EMF Bağlantı Şeması

 $\mathbf{e}(\mathbf{t}) = K_e \cdot \boldsymbol{\omega}(\mathbf{t})$

(1)

- e(t): Zamanla değişen BEMF gerilimi (V)
- K_e : BEMF sabiti (V·s/rad veya V/rpm)
- ω(t): Rotorun açısal hızı (rad/s)

Denklem (1), ters elektromotor kuvveti (BEMF) ile rotorun açısal hızı (ω) arasında doğrusal bir ilişki olduğunu göstermektedir. Başka bir deyişle, rotor ne kadar hızlı dönerse, stator sargılarında indüklenen BEMF gerilimi de o oranda artış gösterir. Bu ilişki, sabit mıknatıs alanına ve sargı yapısına sahip BLDC motorlarda, rotor hızı ile indüklenen gerilim arasındaki bağıntının temelini oluşturur. Bu nedenle, BEMF sinyalleri rotorun anlık pozisyonu hakkında dolaylı bilgi vermekte olup, sensörsüz komütasyon algoritmalarında rotor konumunun ve dönüş hızının tahmini için etkin bir geri besleme kaynağı olarak kullanılmaktadır.

3.5 Kontrol Akış Diyagramı

BLDC motorun sensörsüz kontrolü, sistemin başlatılması, PWM üretimi, BEMF sinyallerinin sıfır geçişlerinin algılanması ve bu geçişlere göre komütasyon adımının güncellenmesi gibi yazılım adımlarıyla gerçekleştirilir; Şekil 5'teki akış diyagramı, mikrodenetleyici yazılımının karar yapısını ve komütasyon adımlarının hangi koşullarda değiştiğini özetlemekte olup, bu akışın simülasyon ortamında
doğru modellenmesi, gerçek zamanlı kontrol mantığının doğruluğunu test etmek açısından önemlidir.



Şekil 6: Kontrol Akış Şeması

4 Bulgular ve Tartışma

4.1 Mikroişlemciden MOSFET Sürücülere Gelen PWM Sinyalleri

Şekil 6'da IR2101 entegresinin HIN (High-side Input) pinine uygulanan PWM sinyalinin osiloskop görüntüsü gözükmektedir. Bu sinyal, ESC yazılımı tarafından Atmega328P mikrodenetleyicisi kullanılarak üretilmiş olup, IR2101'in üst MOSFET'i sürmesi amacıyla HO çıkışını tetikler. PWM sinyali yaklaşık 16 kHz frekansta olup, darbe genişliği motor hızını belirleyen temel parametredir. Bu sinyalin düzgün, kayıpsız ve sabit frekansta olması ESC'nin kararlı çalışması açısından kritik öneme sahiptir.



Şekil 7: MOSFET Sürücüye Gelen PWM Sinyalleri

4.2 BEMF Sinyalleri

Şekil 7'de BLDC motorun üç fazından alınan BEMF sinyallerinin, gerilim bölücü devre sonrası mikrodenetleyiciye iletilen noktalarından (mcu_senseA/B/C) ölçülen osiloskop görünümü gösterilmiştir. Her faz için $33k\Omega$ – $10k\Omega$ dirençlerden oluşan gerilim bölücü devresi aracılığıyla alınan sinyaller, motorun dönüşü sırasında ortaya çıkan faz gerilimlerini temsil etmektedir. Bu sinyallerin sıfır geçiş anları, sensörsüz komütasyon algoritmasında faz geçiş zamanlarının belirlenmesi amacıyla kullanılmıştır. Sinyaller, Atmega328P mikrodenetleyicisinin analog karşılaştırıcı girişlerine bağlanarak gerçek zamanlı işlenmiştir.



Şekil 8: BEMF Sinyalleri

4.3 Motor Faz Sinyalleri

Şekil 8'de BLDC motorun üç faz çıkışındaki gerilimlerin zamanla değişimi (motor_A, motor_B, motor_C) paylaşılmıştır. Bu osiloskop görüntüsünde, ESC tarafından uygulanan 6-step trapezoidal komütasyon algoritmasına uygun olarak her bir motor fazına sırasıyla gerilim uygulandığı görülmektedir. Sinyaller arasında yaklaşık 120° elektriksel faz farkı bulunmakta olup, bu durum ESC sisteminin doğru sırayla fazları sürerek rotor hareketini sağladığını göstermektedir. Fazlara uygulanan gerilimler, IRFZ14 MOSFET'lerinin anahtarlanması ile gerçekleştirilmiş ve PWM modülasyonu ile darbeli bir yapı kazanmıştır. Görselde, her faz için gerilim profili belirgin biçimde ayrılmış olup, sistemin simetrik ve dengeli çalıştığı gözlemlenmektedir.



Şekil 9: Motor Faz Sinyalleri

Bu çalışmada, sensörsüz komütasyon yöntemiyle çalışan bir BLDC motor sürücüsü Proteus ortamında simüle edilmiştir. Sistem, Atmega328P mikrodenetleyicisiyle üretilen PWM sinyallerinin IR2101 entegresi aracılığıyla üç fazlı MOSFET devresine iletilmesiyle çalışmaktadır. Motorun yönü ve hızı, fazlardan alınan BEMF sinyalleriyle belirlenmiştir.Simülasyon sonuçlarına göre, motor doğru komütasyon sırasıyla çalışmış, PWM sinyalleri kararlı şekilde iletilmiş ve BEMF sinyallerinin sıfır geçişleri başarılı biçimde algılanmıştır. Faz gerilimlerinin 120° faz farkıyla sıralandığı ve motorun düzgün döndüğü gözlemlenmiştir.

Bu sonuçlar, geliştirilen sistemin temel işlevlerini doğru şekilde yerine getirdiğini ve sensörsüz kontrolün etkili bir şekilde uygulanabildiğini göstermektedir. Ayrıca simülasyon, donanım aşamasına geçmeden önce sistemin doğrulanması açısından önemli bir araç olarak değerlendirilmiştir.

5 Sonuçlar

Bu çalışmada, sensörsüz komütasyon yöntemine dayalı bir BLDC motor sürücü sistemi Proteus simülasyon ortamında geliştirilmiş ve analiz edilmiştir. Atmega328P mikrodenetleyicisi, IR2101 MOSFET sürücü entegresi ve IRFZ14 MOSFET'lerinden oluşan yapıda; PWM üretimi, faz anahtarlaması ve BEMF sinyallerine dayalı geri besleme algoritması başarıyla uygulanmıştır. Simülasyon bulguları, motorun doğru faz sıralamasıyla kararlı şekilde döndüğünü, PWM sinyallerinin düzenli üretildiğini ve sıfır geçiş tespitinin başarılı biçimde gerçekleştirildiğini göstermektedir.

Elde edilen veriler, düşük maliyetli bileşenlerle sensörsüz BLDC motor kontrolünün etkin bir biçimde gerçekleştirilebileceğini ortaya koymaktadır. Ayrıca, Proteus tabanlı simülasyon süreci, donanım üretimine geçmeden önce algoritmaların doğrulanması açısından önemli bir test ortamı sunmuştur. Ölçüm sonuçlarına göre PWM sinyallerinde yaklaşık %50 duty cycle elde edilmiş, sinyallerin frekansı 20 kHz olarak ayarlanmıştır. Motorun simülasyon ortamında 1200–1500 rpm aralığında çalıştığı ve bu devirlerde BEMF sinyallerinin yeterli genlikte algılanabildiği gözlemlenmiştir. Bu kapsamda, düşük maliyetli bileşenlerle gerçekleştirilen sensörsüz sürücü sisteminin hem yazılım hem donanım yönüyle etkin bir performans sergilediği söylenebilmektedir.

Simülasyon çıktıları, sistemin farklı açılardan etkinliğini ortaya koymaktadır. Üretilen PWM sinyallerinin frekansı yaklaşık 20 kHz olarak belirlenmiş ve %50 duty cycle değerinde kararlı biçimde üretildiği gözlemlenmiştir. Bu frekans seviyesi, hem motor sürücü devresinde anahtarlama kayıplarını minimize etmekte hem de MOSFET'lerin ısınmasını kontrol altında tutmaktadır. PWM sinyalleri IR2101 sürücü entegresi aracılığıyla üç fazlı çıkışlara aktarılmış, böylece motorun tork üretimi dengeli şekilde sağlanmıştır. BLDC motorun çalıştığı devir aralığı, simülasyon sırasında 500 ila 600 rpm arasında değişmektedir. Bu aralık, sistemin sensörsüz olarak orta hız bölgesinde istikrarlı

calışabileceğini göstermektedir. Bu hız aralığında BEMF (Back Electromotive Force) sinyalleri her fazda net şekilde algılanabilmiş ve sıfır geçiş noktaları başarılı şekilde tespit edilmiştir. Sıfır geçiş tespiti algoritması, her bir fazın gerilim sinyalinin referans (yarım DC besleme) ile karşılaştırılması esasına dayalıdır ve komütasyonun doğru zamanlamayla yapılmasına olanak sağlamıştır. Çalışmanın bir diğer önemli çıktısı, geliştirilen algoritmanın gerçek zamanlı sistemler için potansiyel taşımasıdır. Yazılım vapısının modüler olarak geliştirilmesi sayesinde, PWM üretimi, sıfır geçiş tespiti ve faz kontrolü ayrı bloklar halinde test edilmiştir. Bu yaklaşım, algoritmanın donanım ortamına aktarılmadan önce esnek biçimde denenebilmesine olanak tanımıştır. Proteus tabanlı simülasyon ortamı, fiziksel devre üretimi öncesinde önemli bir ön test imkânı sunmuş ve hata payını azaltmıştır. İlerleyen çalışmalarda sistemin gerçek donanım üzerinde test edilmesi, algoritmanın saha koşullarındaki kararlılığı açısından büyük önem arz etmektedir. Özellikle düşük devirlerde BEMF sinyallerinin genliklerinin zayıflaması, analog karsılastırıcılarla yapılan sıfır geçis tespitinin güvenilirliğini azaltmaktadır. Bu nedenle, ADC (Analogto-Digital Converter) tabanlı dijital sinyal işleme tekniklerinin entegre edilmesi, düşük hızlarda daha doğru geri besleme alınmasına katkı sağlayabilir. Ayrıca, literatürde etkinliği kanıtlanmış ileri düzey sensörsüz tekniklerden biri olan yüksek frekans enjeksiyonu (High Frequency Injection) yöntemi gibi alternatif yaklaşımların değerlendirilmesi, düşük hız performansını artırma açısından faydalı olacaktır.

Sistemin mevcut hali açık çevrim modda çalışmaktadır. Bu durum, motor hız ve akımındaki olası değişimlerin sürücü tarafından telafi edilememesine neden olabilir. Bu nedenle ileride kapalı çevrim kontrol (closed-loop control) tekniklerinin, özellikle PI veya adaptif kontrolcü tabanlı yaklaşımların entegrasyonu ile daha kararlı ve hassas bir motor kontrolü sağlanması mümkün olacaktır. Ek olarak, sistemin uzun süreli çalışma performansının değerlendirilmesi amacıyla MOSFET'lerin ve sürücü elemanlarının termal davranışı incelenmeli; uygun soğutma çözümleri entegre edilmelidir.

İlerleyen çalışmalarda sistemin gerçek donanım üzerinde test edilmesi, yazılımın sahadaki kararlılığını değerlendirmek açısından önem arz etmektedir. Özellikle düşük hızlarda zayıflayan BEMF sinyallerinin güvenilir biçimde algılanabilmesi için analog karşılaştırıcı yerine ADC tabanlı dijital işleme yöntemleri tercih edilebilir. Sistem, kapalı çevrim hız veya akım geri besleme kontrolü ile geliştirilebilir; bu sayede daha hassas ve adaptif bir motor kontrolü sağlanabilir. Ayrıca, düşük hız performansını artırmak amacıyla ileri düzey sensörsüz sürüş tekniklerinin (örneğin yüksek frekans enjeksiyonu) entegrasyonu değerlendirilebilir. Son olarak, sürücü bileşenlerinin termal performansı ve uzun süreli çalışma koşullarındaki davranışı da gelecekteki uygulamalarda dikkate alınmalıdır.

Genel olarak değerlendirildiğinde, geliştirilen ESC sistemi, hem yazılım hem donanım açısından güçlü bir temel sunmakta ve gelecekteki gerçek zamanlı motor kontrol uygulamaları için uygulanabilir bir altyapı oluşturmaktadır.

6 Beyanname

6.1 Rakip Çıkarlar

Bu çalışmada herhangi bir çıkar çatışması yoktur.

6.2 Yazarların Katkıları

Sorumlu Yazar Adı SOYADI: Mahmut Esat ÇULFAZ

Araştırma fikrinin oluşturulması, literatür incelemesi, tasarım süreçleri, makale yazımı.

2. Yazar Adı SOYADI: Mücahit SOYASLAN

Araştırma fikrinin oluşturulması, literatür incelemesi, tasarım süreçleri, makale yazımı.

Kaynakça

[1] A. S. Al-Adsani, M. E. AlSharidah, and O. Beik, "BLDC motor drives: a single hall sensor method and a 160° commutation strategy," IEEE Trans. Energy Convers., vol. 36, no. 3, pp. 2025–2035, Sep. 2021, doi: 10.1109/TEC.2020.3046183.

[2] S. Derammelaere, M. Haemers, J. De Viaene, F. Verbelen, and K. Stockman, "A quantitative comparison between bldc, pmsm, brushed dc and stepping motor technologies," in 19th Int. Conf. Electr. Mach. Syst. (ICEMS), Nov. 2016, pp. 1-5. [Online].

[3] D. Mohanraj et al., "A review of bldc motor: state of art, advanced control techniques, and applications," IEEE Access, vol. 10, pp. 54833–54869, 2022, doi: 10.1109/ACCESS.2022.3175011.

[4] B. Banu Rekha, B. Somasundaram, L. Ashok Kumar, and P. Balekai, "A technical review on advantages of using ec bldc fans in factory and commercial buildings," Energy Eng., vol. 115, no. 3, pp. 57–74, May 2018, doi: 10.1080/01998595.2018.12002418.

[5] K. FATHONI and A. B. UTOMO, "Perancangan kendali optimal pada motor arus searah tanpa sikat melalui metode lqri," (in Indonesia), ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron., vol. 7, no. 2, p. 377, May 2019, doi: 10.26760/elkomika.v7i2.377.

[6] M. Soyaslan, "External Rotor BLDC Motor Design for a Light Electric Vehicle: 24 Slot/22 Pole Combination," in 2023 18th Conference on Electrical Machines, Drives and Power Systems (ELMA), 2023, pp. 1–4. doi: 10.1109/ELMA58392.2023.10202463.

[7] A. Mukherjee, S. Ray, and A. Das, "Development of Microcontroller Based Speed Control Scheme of BLDC Motor Using Proteus VSM Software," International Journal of Electronics and Electrical Engineering, pp. 1–7, 2014, doi: 10.12720/ijeee.2.1.1-7.

[8] Yan, G. (2009). Fırçasız Doğru Akım Motor Analizi ve Sürücü Devre Tasarımı (Yüksek lisans tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü). İstanbul.

[9] İmren, B. (2022). Fırçasız Doğru Akım Motoru Sürücüsünün Simülasyonu, Tasarımı ve Gerçekleştirilmesi (Yüksek lisans tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü). İstanbul.

[10] Aydoğdu, Ömer, and Mert Bayer. "PIC Tabanlı Fırçasız DC Motor Sürücüsü Tasarımı." Elektrik-Elektronik Mühendisliği Bölümü, Selçuk Üniversitesi, Konya (2008).



 $\ensuremath{\mathbb{C}}$ 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) license (https://creativecommons.org/licenses/by/4.0/)