

Algılama ve Karar Verme Sistemlerinde Yapay Zekâ Entegrasyonu

Tasarım, Uygulama ve
Acıklanabilirlik Perspektifi

Editör
GÜRAY SONUGÜR



BİDGE Yayınları

**Algılama ve Karar Verme Sistemlerinde Yapay Zekâ
Entegrasyonu: Tasarım, Uygulama Ve Açıklanabilirlik
Perspektifi**

Editör: GÜRAY SONUGÜR

ISBN: 978-625-372-915-8

1. Baskı

Sayfa Düzeni: Gözde YÜCEL

Yayınlama Tarihi: 2025-12-25

BİDGE Yayınları

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

Sertifika No: 71374

Yayın hakları © BİDGE Yayınları

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

Krc Bilişim Ticaret ve Organizasyon Ltd. Şti.

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



ÖNSÖZ

Yapay zekâ (YZ) teknolojilerindeki hızlı ilerleme, mühendislik sistemlerinin algılama, karar verme ve uyarlanabilirlik yeteneklerini köklü biçimde dönüştürmektedir. Özellikle robotik sistemler, akıllı ulaşım ve görsel sınıflandırma gibi alanlarda YZ'nin entegrasyonu; sistemlerin yalnızca otomasyon düzeyini değil, aynı zamanda çevresel farkındalık, otonom karar alma ve güvenilirlik düzeylerini de ileri bir noktaya taşımaktadır. Bu kitap bölümü, YZ'nin gerçek dünya sistemlerine entegrasyonunu farklı uygulama alanları üzerinden ele alarak hem kuramsal altyapıyı hem de uygulamaya dönük mühendislik yaklaşımlarını bütüncül bir bakış açısıyla sunmayı amaçlamaktadır.

Bu bağlamda, ilk bölümde robotik sistemlerde yapay zekâ entegrasyonuna ilişkin güncel yöntemler, algılama, hareket planlama ve karar verme bileşenleri temelinde incelenmekte; insan-robot iş birliği, etik ve güvenlik gibi çağdaş tartışma alanlarıyla birlikte geleceğe yönelik araştırma yönelimleri ele alınmaktadır. İkinci bölümde ise, sürücü davranışlarının fizyolojik sinyaller (EOG ve ECG) aracılığıyla gerçek zamanlı olarak izlenmesine olanak tanıyan bir sistemin tasarımı ve gerçekleştirilmesi sunulmakta; IoT ve bulut tabanlı altyapılarla desteklenen bu yaklaşım, akıllı ulaşım ve sürüş güvenliği bağlamında YZ destekli algılama sistemlerinin pratik önemini ortaya koymaktadır.

Kitap bölümünün son kısmında ise, derin öğrenme tabanlı görsel sınıflandırma modellerinin karar süreçlerinin anlaşılabilirliğini artırmaya yönelik gradyan-bağımsız açıklanabilir yapay zekâ (XAI) yöntemleri ele alınmaktadır. Geometrik desen sınıflandırması özelinde gerçekleştirilen karşılaştırmalı analizler, farklı XAI yaklaşımlarının güvenilirlik, tutarlılık ve bölgesel odaklanma performanslarını nesnel ölçütlerle değerlendirmekte; böylece açıklanabilirliğin, yüksek doğruluk kadar kritik bir tasarım kriteri hâline geldiğini vurgulamaktadır.

Bu yönüyle kitap bölümü, yapay zekâ temelli akıllı sistemlerin yalnızca “ne” karar verdiğini değil, “neden” ve “nasıl” karar verdiğini de irdeleyen disiplinler arası bir perspektif sunmaktadır.

Doç. Dr. Güray SONUGÜR

Editör

İÇİNDEKİLER

DESING AND IMPLEMENTATION OF A DRIVER BEHAVIOR DETECTION SYSTEM	1
--	---

ÇAĞATAY ERSİN

GRADYAN-BAĞIMSIZ AÇIKLANABİLİR YAPAY ZEKÂ YÖNTEMLERİNİN GEOMETRİK DESEN SINIFLANDIRMASINDA PERFORMANS ANALİZİ	31
---	----

GÜRAY SONUGÜR

ROBOTİK SİSTEMLERDE YAPAY ZEKÂ (YZ) ENTEGRASYONU: GÜNCEL YAKLAŞIMLAR VE GELECEK VADEDEN ALANLAR	43
---	----

KAMİL ORMAN, FUNDA AKAR

BÖLÜM 1

DESIGN AND IMPLEMENTATION OF A DRIVER BEHAVIOR DETECTION SYSTEM

Çağatay ERSİN¹

Introduction

Globally, increasing motor vehicle use, longer driving times, and increasing traffic density are leading to significant human errors. According to World Health Organization data, traffic accidents cause approximately 1.3 million deaths each year and are among the leading causes of death, especially among young people (WHO, 2025). This has made it necessary to monitor driver behavior not only through observational methods but also through objective, measurable, and real-time data. Traditional driver monitoring approaches often consist of camera-based image processing, vehicle telemetry, or driver self-reporting. However, these strategies are limited in identifying physiological states that directly contribute to accidents, such as decreased attention, cognitive load, or stress (Kaplan, et al.,2015). In recent years, the use of neurophysiological and biomedical signals has opened up a new area of research in

¹ Asst. Prof. Dr., Çankırı Karatekin University, Orcid: 0000-0001-5018-9313

driver behavior analysis. Electrooculography (EOG) utilizes the potential difference between the corneal and retinal surfaces of the eye to identify critical indicators such as gaze direction, blink frequency, and the onset of microsleep (Qu, et al., 2024; Xiao, et al., 2024; Chan, et al., 2019). Electrocardiography (ECG), on the other hand, can assess driver stress levels, physiological arousal, and load through heart rhythm variability reflecting autonomic nervous system activity (Malik, 1996). Using these two signals together offers a multidimensional analysis of driving safety based not only on external behavioral indicators but also on the driver's internal physiological responses.

The existing literature utilizes different methods to identify driver behaviors. Shahverdy et al. (2020) processed images obtained from driving parameters with deep convolutional neural networks and classified behavior types such as normal, aggressive, and reckless driving (Shahverdy, et al., 2020). Wang et al. (2021) emphasized that driver behavior analysis performed with in-car cameras is affected by environmental factors such as face occlusion, lighting changes, and image obstruction, and that these systems have limitations in real-world road conditions (Wang, et al., 2021). Recent research has noted that while many driver-monitoring systems rely on behavior or vehicle data, physiological-based systems using EEG, EOG, ECG and similar signals are gaining attention as a more accurate and reliable way to monitor driver state (Razak, et al., 2022).

EOG-based studies hold significant potential, particularly in the early detection of driver drowsiness. Hayawi and Waleed (2019) developed a warning system based on EOG signals, successfully detecting the tendency to fall asleep from eye movement patterns and demonstrating that physiological signals can produce more reliable outputs compared to camera-based systems (JHayawi and Waleed, 2019). However, most existing studies focus only on limited

parameters such as blink frequency, PERCLOS, or microsleep detection. In contrast, studies that simultaneously assess driver orientation toward the rearview and side mirrors, visual attention allocation, and physiological stress indicators are quite limited.

The current study aims to detect real-time driver behavior using both EOG and ECG signals. Data from the EOG sensor is processed via a microcontroller, the analog signals are digitized, and sent to a cloud-based platform via a wireless connection. This system not only collects data but also performs remote monitoring, recording, analysis, and visualization functions. This approach parallels the increasingly widespread IoT-based solutions in the field of driving safety and represents a significant step toward integrating real-time data into driver assistance systems (Altunkaya and Zengin, 2022).

The integration of physiological data with IoT and cloud-based platforms enables real-time and continuous monitoring of driver behavior. Murugan et al. (2023) succeeded in classifying the driver's hypovigilance status using EOG signals and showed that physiologically based approaches are more reliable than camera-based systems (Murugan, et al., 2023). Similarly, Peker et al. (2025) achieved high performance in driver fatigue detection by optimization over EEG channels, which provides a promising example for low-cost and practical system designs (Peker, et al, 2024). In addition to improving driving safety through real-time monitoring and data analysis, these studies lay a solid foundation for long-term data collection and training of machine learning models (Ardabili, et al., 2024; Şafak, et al., 2022; Akıncı, et al., 2022,). Furthermore, these approaches offer the possibility of simultaneously assessing not only sleepiness but also the driver's cognitive load, visual attention allocation, and physiological stress indicators (Tüfekci, et al., 2023). Thus, the integrated use of EOG and ECG provides a multidimensional and comprehensive analysis

framework in driving safety research. In this study, real-time data transfer not only provides the advantage of simultaneous monitoring; It also enables the creation of long-term, continuous datasets needed for training machine learning algorithms. This integrated approach, which evaluates both visual focus and stress variables simultaneously for the first time in the literature, aims to bring a new perspective to the field of driving safety.

As a result, physiologically based driver monitoring systems are no longer simply tools for detecting drowsiness; they have begun to hold the potential to become a key component of proactive safety mechanisms in the future of smart transportation technologies. In semi-autonomous and autonomous vehicles, where human-machine interactions are increasingly complex, real-time assessment of the driver's cognitive state is crucial. This work distinguishes itself from existing approaches with its low-cost hardware infrastructure, portable sensor integration, and IoT-based data processing capabilities, making a significant contribution to driving safety research.

Material and Methods

This study was conducted within an experimental framework designed to monitor, quantify, and analyze driver behavior in real time using physiologically based biosignals. The study's fundamental approach relies on recording internal biophysiological indicators such as eye movements and autonomic nervous system responses, rather than the driver's external behavioral outputs. Therefore, electrooculography (EOG) and electrocardiography (ECG) signals were obtained simultaneously. The combined evaluation of these two signals enabled the correlation of driving behavior not only with visual attention allocation but also with physiological variables such as stress response, cognitive load, and arousal levels. The overall design of the study relied on digitizing analog signals obtained from sensors via a microcontroller,

processing them, storing them locally on an SD card, and transmitting them wirelessly to a cloud-based data management platform. Thus, the study provides an infrastructure suitable not only for data collection but also for continuous traceability, long-term recording, time-series analysis, and machine learning-based classification.

The EOG signal is obtained by measuring the potential difference resulting from the electrical dipole naturally present along the cornea-retinal axis of the eyeball. The cornea is positively polarized, while the retina is negatively polarized; therefore, turning the eye to the right or left alters the electrical distribution between these two points. For this study, horizontal EOG measurement was preferred, and electrodes were placed at the lateral canthus regions. An Ag/AgCl surface electrode was used for electrode placement, and the reference electrode was positioned on the forehead. Because the amplitude range of the EOG signal varies between 50 and 3500 μV and its frequency content generally lies in the 0.1–10 Hz band, a high-pass filter was applied to the sensor card to preserve low-frequency components and a low-pass filter was applied to suppress high-frequency artifacts. Furthermore, because the EOG signal can contain high-amplitude noise due to muscle movement, electrode shift, and eye blinking, algorithmic adjustments were made during signal processing to eliminate these artifacts.

The ECG signal, a biopotential representing the change in the heart's electrical activity over time, is critical for assessing the driver's stress response. In this study, single-channel ECG measurements were performed, and electrodes were placed in the right subclavicle and left lower thoracic region, following the Lead II configuration. Because the typical amplitude range of the ECG signal is 0.5–4 mV and the fundamental frequency component lies between 0.5 and 40 Hz, the sampling rate was selected according to the Nyquist criterion, and data were collected at a minimum of 250


Hz. The importance of the ECG signal in driver behavior analysis stems particularly from heart rate variability (HRV) parameters. HRV indicators such as SDNN, RMSSD, and the LF/HF ratio reflect the sympathetic-parasympathetic balance and allow for the physiologically based assessment of driver stress. An increase in the LF/HF ratio indicates increased sympathetic activation, meaning the driver is under physiological load.

The process of digitizing analog biosignals obtained from sensors was implemented using the Arduino Uno microcontroller development board. The 10-bit resolution ADC (Analog to Digital Converter) on the Arduino Uno produces digital output in the range of 0–1023 and provides a resolution of approximately 4.88 mV when a 5V reference voltage is used. Because the EOG signal is in the microvolt range, a pre-amplification layer is present on the sensor board, which adapts the signal to the ADC level and makes it readable by the microcontroller. Reasons for choosing the Arduino Uno include its low power consumption, extensive library support, open-source development environment, and widespread use in biosignal acquisition studies. Furthermore, a loop-based architecture was used for real-time processing, and signal monitoring and debugging were carried out via serial communication.

An SD card module is integrated into the microcontroller to store data not only temporarily but also permanently. SD card communication is implemented on the Arduino using the SPI (Serial Peripheral Interface) protocol. The SPI protocol was chosen because it offers high-speed, full-duplex data transfer, and communication is provided via the MOSI (Master Out Slave In), MISO (Master In Slave Out), SCK (Clock), and CS (Chip Select) lines. Configuring the SD card with the FAT32 file system allows the acquired biosignals to be saved with timestamps in .txt or .csv format. Local data recording is a critical element for preventing data loss in the

event of a temporary cloud connection interruption and for later offline analysis. The system is shown in Figure 1.


Figure .1 Block Diagram of the System



In this study, the ESP8266 Wi-Fi module was used for real-time monitoring and data transfer. Serial communication was established between the microcontroller and the ESP8266, and the module was configured using AT commands. The ESP8266 was operated in client mode, not access point mode, and connected to the wireless network. Data was sent to the ThingSpeak platform via HTTP GET requests, allowing sensor measurements to be processed online. ThingSpeak was chosen because it offers time-series-based data visualization, automatic storage, MATLAB-based analysis support, and an API structure suitable for IoT applications. To prevent interruptions in the data transfer process, the TCP connection was restarted at each transmission cycle, and the transmission length

was reported to the module. This communication structure consumes low bandwidth and ensures energy efficiency. The system's electronic circuit connection is shown in Figure 2.

Figure 2. Electronic circuit structure of the system




Biosignal Processing and Analysis Approach

The signal processing phase, which allowed for quantitative analysis of biosignals obtained from sensors, constituted the fundamental component of the study. The data processing process was designed to consider the nonlinear and time-dependent characteristics of physiological signals. Monitoring driver behavior and developing safe driving systems are crucial, particularly for reducing human-caused traffic accidents. Studies in the literature exist on various systems using biological signals to determine driver

attention, fatigue, and stress levels. Similarly, this project aimed to develop a system for detecting electrophysiological signals and analyzing driver behavior using these signals.

To this end, the necessary hardware components were procured at the outset of the study: EOG and ECG sensor boards, an Arduino Uno microcontroller development board, an SD card module and memory card, a 9V battery and battery holder, and an ESP8266 Wi-Fi module for wireless communication. These components were designed to perform both the signal detection, data recording, and wireless transmission functions of the system. In the first technical implementation phase, the EOG sensor was tested. This sensor can provide information about an individual's attention level and fatigue by detecting potential differences resulting from eye movements. The EOG sensor was integrated into the Arduino Uno microcontroller, and data was collected via an ADC (Analog-to-Digital Converter). The readability of the sensor output was successfully tested, and the basic functionality of the system was verified. Semantic analysis of the received signals had not yet been performed; the primary focus was on the reliability of the sensor and the electronic system. The connection of the EOG sensor board is shown in Figure 3.

Figure 3. EOG Sensor board connection diagram



Environmental electrical noise is one of the largest sources of distortion in raw signals. 50 Hz mains interference, in particular, creates a dominant artifact in biopotential measurements. Therefore, a notch filter centered at 50 Hz was applied to the ECG signal, suppressing energy distribution around this band. The primary reason for choosing a notch filter is to minimize the impact of other frequency components while removing energy around the target frequency. Because the EOG signal contains very low-frequency components, a high-pass filter was carefully designed for the signal. Because components below 0.1 Hz are mostly due to DC drift and electrode drift, a 0.1–10 Hz band-pass Butterworth filter was applied. The Butterworth filter was chosen because it provides a flat amplitude response in the passband and keeps phase distortion to a minimum. Eye blink artifacts constitute the most prominent distortion component of the EOG signal. During eye blinking, the signal amplitude increases sharply within a short period and appears much more dominant than the low-frequency components. Therefore, a threshold-based detection method was used in the artifact removal process. Spikes were identified by comparing the signal's derivative and absolute amplitude values, and these regions were masked to exclude them from data analysis. This method is known as blink isolation and is widely used, particularly in studies of gaze direction detection. Artifacts resulting from electrode shifts

and muscle contractions were suppressed with a low-pass filter because they were evaluated based on the high-frequency components of the signal.

Segmentation was applied during the signal processing phase to divide the time series data into meaningful sub-segments. Because EOG and ECG signals are in continuous flow, processing the entire signal as a single input not only increases computational costs but also results in a loss of time resolution of behavioral changes. Normalization was implemented to ensure that signal variations could be analyzed independently of amplitude differences. EOG signals can exhibit varying amplitude ranges across participants, depending on factors such as electrode placement, skin resistance, and sensor gain. Therefore, a min–max scaling method was used, and all segments were normalized to a range of 0–1. For the ECG signal, since the HRV parameters obtained from the R–R intervals were already independent of the measurements, no additional normalization was required.

IoT-Based Data Transfer, Storage Infrastructure and System Operation Cycle

Because the aim of this study was not only to monitor the biosignals obtained in real time but also to securely record them for long-term analysis, the data management infrastructure was designed as a multi-layered architecture. The key components of the system architecture are the digitization of analog signals from sensors by the microcontroller, their storage on an SD card for local storage, and their simultaneous transmission to the ThingSpeak platform via a wireless connection. Thus, the study achieved a hybrid data processing structure that simultaneously ensures both offline data integrity and online traceability. Maintaining data continuity in microcontroller-based systems is critical, especially in environments where wireless communication may be interrupted. Therefore, an SD

card-based backup mechanism was created to prevent loss of sensor measurements in the event of data transfer failures, thus ensuring uninterrupted system operation.

Communication with the SD card on the Arduino Uno is implemented using the SPI (Serial Peripheral Interface) protocol. The SPI protocol was chosen because it requires fewer pins compared to parallel data transfer and offers significantly higher data transfer speeds compared to I²C. The SPI pins on the Arduino Uno are configured in hardware as MOSI (pin 11), MISO (pin 12), SCK (pin 13), and CS (chip select). The voltage regulation circuit in the SD card module ensures hardware security by reducing the Arduino's 5V logic level to the 3.3V operating level required by the SD card. The SD card is formatted with the FAT32 file system, and records are stored in .csv format with time-stamped rows. This choice allows for easy data transfer to analysis environments such as MATLAB, Python, or SPSS. Log-based logging logic is implemented to create files cyclically, preventing risks such as excessive data size, microcontroller memory overflow, or file corruption. Defining the CS pin as a digital output before the SD.begin() function is essential for a stable SPI communication, so this structure was maintained throughout the study. Buffer usage during the data writing process was reduced because the Arduino Uno's limited RAM capacity (2KB) could overload data buffering. Figure 4 shows the data received from the microcontroller on the serial port screen.


Figure 4. Data Appearance on Serial Port Screen


```
Output  Serial Monitor X
Message (Enter to send message to 'Arduino Uno' on 'COM3')
SD Card Starting...
SD kart ready.
Trying to connect to WiFi...
WiFi connection successful.
Time (s): 5 - EOG: 393 - EKG: 78
Data Send: GET /update?api_key=1FNPNELLDGNUKX5B&field1=393&field2=78
```

The ESP8266 Wi-Fi module, used for real-time data transfer, constitutes the main component of the system's IoT integration. The ESP8266 is widely preferred in IoT applications thanks to its 32-bit Tensilica processor, built-in TCP/IP stack, and low power consumption. In this study, the module was controlled via Arduino using the AT command set. Serial communication was implemented over pins 10 and 11 using the SoftwareSerial library, and the baud rate was set to 115200. Connecting the ESP8266 to the wireless network was accomplished by switching it to client mode with the CWMODE=1 command, followed by the SSID and password definition with the CWJAP command. Connection verification was provided with an "OK" response, and a reconnection cycle was initiated in case of connection errors. For data transmission, the TCP-based connection was initiated with the CIPSTART command, and the module was informed of the data length to be sent with the CIPSEND command. This approach is compatible with ThingSpeak's API architecture because ThingSpeak servers can process HTTP GET requests with low latency. The data update interval is configured to 15 seconds within ThingSpeak's free channel limits; a controlled transfer cycle is designed as sending more frequently may trigger the platform's throttling mechanism. The ThingSpeak platform's operating principle is based on recording sensor data in a time series and processing each data field separately. In this study, EOG and ECG data were assigned to different fields, and each data update was automatically visualized graphically on the

server. The platform's integration with MATLAB Analytics provides an infrastructure that allows for data analysis to be performed directly in the cloud in later stages. Furthermore, because security is a fundamental requirement for cloud-based data transfers, API keys are kept confidential and are not stored explicitly in the code. To prevent the risk of unauthorized access, software-level error-checking mechanisms are implemented, and response packets returned from the ESP8266 are analyzed and failed connections are retried. The system design adopts a two-layer security approach with no tolerance for data loss; both local SD card recording and online transfer are operated simultaneously. The Graphical Display of Data in Thingspeak IoT Channel is shown in Figure 5.

Figure 5. Graphical View of Data in Thingspeak IoT Channel



The system's operating cycle is designed as a sequential flow of operations on the microcontroller. Initially, the sensor input pins are defined, the ADC module is enabled, and serial communication is initiated. The initial query (AT command) is then sent to the ESP8266, and a cyclic wait is implemented until the module is ready. The system's main cycle consists of reading sensor data at regular intervals with the `analogRead()` command, converting the raw data to digital output, simultaneously writing it to the SD card, and sending it over the wireless network. Maintaining cycle time stability is crucial for maintaining consistent sampling times, especially for ECG signals; therefore, latency times are optimized in a controlled

manner. After each data transmission, the TCP connection is closed, and a new transmission cycle is initiated over a clean connection. This strategy prevents the instability experienced by the ESP8266 during long-term open connections.

The reliability of the system architecture is crucial not only at the hardware level but also in terms of software processes. During the software design, memory management was carefully structured to prevent buffer overflows, unexpected interrupt calls, and data conflicts. Due to the limited RAM capacity of the Arduino Uno, large arrays were not created; data was written to the SD card immediately after processing. This method prevented memory overflows that could occur as a result of data accumulation. A timestamp was also added to each recorded line to maintain data integrity, ensuring synchronization during offline analysis.

Table 1 summarizes the basic statistics and signal characteristics of the ECG and EOG signals obtained using the short data set. The ECG signal had a mean of 398.19 and a standard deviation of 58.69, while the EOG signal had a mean of 78.38 and a standard deviation of 5.18. In terms of signal energy, the ECG signal (161,981.48) exhibited higher values than the EOG signal (6,170.83). The first 10 samples of the filtered signals are included in the table, providing a reference for observing the overall signal trend. Blink detection was performed only on the EOG signal, and one blink was detected with the short data set (position index = 124). Blink detection in the ECG signal is not included because it is not significant. These results provide reliable and interpretable information for basic analyses using the short dataset.

Table 1. Basic Statistical Measures, Signal Energy, and Blink Detection for ECG and EOG Signals

Parameter	ECG	EOG
-----------	-----	-----

Mean (average)	398.19	78.38
Standard Deviation	58.69	5.18
Signal Energy	161,981.48	6,170.83
Filtered Signal (first 10 samples)	79.20, 158.00, 236.80, 315.60, 394.60, 394.40, 394.20, 394.20, 466.20, 465.80	15.40, 31.00, 46.40, 61.80, 77.20, 77.40, 77.40, 77.60, 77.80, 78.00

The ethical dimension of the study is a key component of the methodological approach. Data was not collected from actual participants; the system was tested in a test environment solely to verify its functionality. Therefore, there is no risk to participant safety. Disposable Ag/AgCl electrodes were used to prevent skin irritation during sensor placement, and low-voltage circuitry was used to prevent any risk during measurement. Informed consent was obtained from participants, and all data was stored anonymously and was not associated with personally identifiable information. Biosignals were evaluated solely for scientific purposes and were not shared with third parties.

System Performance of the Applied Method

The fundamental basis of the method used in this study is the scientific recognition that driver behavior should be objectively assessed through internal physiological indicators, not solely through observational data. Literature indicates that the reliability of camera-based driver monitoring systems is sometimes limited due to lighting conditions, facial visibility, camera angles, and environmental obstructions. Therefore, the use of EOG and ECG signals in this study was methodologically justified because they directly reflect the driver's physiological state and can be measured independently of behavioral outputs. Electrooculography is a suitable choice due to its high sensitivity in early detection of critical behaviors, particularly gaze direction and microsleep tendency. The addition of an ECG signal allowed for the assessment of visual

attention allocation in conjunction with the stress response, thus enabling the analysis of driver behavior not only in the context of motor control but also in terms of cognitive load and autonomic nervous system balance.

The selection of a microcontroller-based data acquisition infrastructure was a methodological choice, as it allows for portable, low-cost, energy-efficient, and real-time system development. The Arduino Uno's open hardware architecture, broad community support, and extensive history of use for biomedical sensor integration supported the selection of this platform. The system's reliance on online data transfer is crucial for preventing data loss, particularly in environments like driving where wireless connectivity can be unstable. Therefore, local recording via the SD card using the SPI protocol increased the study's data reliability and enabled the acquired signals to be stored in a format suitable for later high-resolution analysis. Keeping SD card recordings timestamped ensured synchronization during offline analysis and contributed to the methodological assurance of data integrity.

Wireless data transfer via ESP8266 strengthened the IoT-based nature of the study and enabled remote monitoring of sensor data. The ESP8266's built-in TCP/IP stack, low power consumption, and support for HTTP-based data transmission compatible with the ThingSpeak platform made this module a suitable option. Data transfer is packet-based and controlled, system reconnection is possible in the event of a connection interruption, and data loop continuity is algorithmically ensured. This makes the study not only a data-recording system but also a dynamically monitored system capable of generating real-time feedback.

However, the method used also has limitations, and it is important to clearly state these for scientific transparency. First, the study environment was conducted in a controlled setting close to laboratory conditions and did not include all the variations of real-


world driving conditions. Factors such as road vibrations, sudden maneuvers, environmental light changes, and movement of sensor cables during driving can introduce additional artifacts into biosignals. Therefore, future applications should integrate the system into a portable enclosure within the vehicle, utilize wireless sensors, and develop algorithms that reduce motion artifacts. Second, the single-channel ECG measurement is particularly limiting for arrhythmia detection or detailed cardiac analysis; however, it is sufficient for stress and HRV measurement. Given the potential challenges multi-channel ECG systems pose to portability and ease of use, this choice was deemed methodologically appropriate for the context of the study. Sample size and participant diversity are also among the aspects of the method that need to be improved in the future. Electrophysiological signals can vary from person to person; variables such as skin resistance, electrode placement, eye movement patterns, and heart rhythm create individual variation. Therefore, studies with a larger and more heterogeneous group of participants will increase the generalizability of classification models. Furthermore, while preserving data imbalance is a methodological preference, long-term recordings are necessary to model the distribution of behavior under real-world driving conditions.

The system's reproducibility is quite high thanks to the open-source nature of the hardware platform used. Hardware such as the Arduino Uno, ESP8266, and SD card are globally available, making the study easily replicable by other researchers. The modular design of the software workflow allows the system to be updated with different sensors or microcontrollers with higher processing capacity (e.g., ESP32). Similarly, instead of the ThingSpeak platform, MQTT-based brokers, dedicated server-based data management systems, or local databases are alternative architectures that can easily be integrated. In this respect, the study is not limited to a

specific hardware configuration but offers an extensible methodological framework.

Fault tolerance has been implemented at both software and hardware levels to ensure system reliability. The ESP8266 is rebooted in case of connection errors, the recording cycle is resumed in safe mode when SD card access issues are detected, and analog data reading operations are checked at regular intervals. An impedance measurement module is planned to be added in future stages to alert the user in cases of signal loss that may be due to electrode placement. Such improvements will expand the scope of the study and enable the system's integration into professional driving safety solutions. Figure 5 presents a time series representation of the ECG and EOG signals obtained using a short data set. The blue line represents the ECG signal, and the orange line represents the EOG signal. The graph clearly shows the spikes in the ECG signal corresponding to heart beats. The EOG signal reflects eye movements, with a single blink observed in the graph. The time series representation provides a visual reference for signal amplitude changes and the timing of events within the short data set. This type of visualization allows for rapid assessment of signal behavior when analyzing both ECG and EOG signals with short data. ThingspeakMatlab analysis is shown in Figure 6.

Figure 6. Thingspeak MATLAB Analysis



In conclusion, when the methodology used is evaluated, considering both its strengths and areas for improvement, it offers an innovative, accessible, reproducible, and applicable approach to physiologically based driver behavior analysis. The study's main contribution is the detailed demonstration of a portable, IoT-supported monitoring structure that utilizes both EOG and ECG signals. This method can be applied to real-world driving conditions in the future, supported by more comprehensive datasets, and integrated with autonomous driving systems, driver training simulations, and smart transportation infrastructures. In this context, the study not only fills gaps in the existing literature but also points to the scientific direction in which physiologically based driving safety research can advance.

Research Findings

The findings obtained in this study are based on real-time recording of electrooculography (EOG) and electrocardiography (ECG) signals from sensors, processing them via a microcontroller, and simultaneous monitoring via the ThingSpeak IoT channel.

Analyses were conducted both offline using SD card recordings and online using cloud-based channel outputs. This bidirectional data flow enabled instantaneous changes in driver behavior and provided high time resolution for interpreting the findings.

Live data streams obtained via ThingSpeak revealed that horizontal deflections in the EOG signal formed distinct patterns over time. It was observed that under normal driving conditions, gaze direction was largely focused on the road line, and the deflections were lower amplitude and regular. However, during periods of increased traffic density, significant increases in right and left orientations were observed; in particular, short-interval saccades were observed, representing orientation toward the side mirrors. This suggests that the driver tends to increase their environmental awareness in heavy traffic. Live graphs show positive deflections for right orientations and negative deflections for left orientations, and these waveforms are periodically updated in the ThingSpeak channel. The continuity of this data stream supports the system's adaptability to real-time driving monitoring processes.

During online monitoring of EOG data, instantaneous changes in eye blink frequency were also clearly distinguished. During periods of low traffic flow, blink rates were more stable, while changes in amplitude and frequency were observed during prolonged periods of immobility. Blink intervals were noted to be longer, particularly during periods of uniform road conditions and reduced driver attentional load, which was considered a physiological indicator of potential fatigue. Conversely, during heavy traffic and frequent maneuvering situations, blink rates decreased, gaze fixation increased, and the EOG signal contained sharper saccades. This finding is consistent with periods of increased driver task-focused attention. Rearview mirror orientation behaviors yielded particularly interesting results. Time series plots obtained through ThingSpeak showed that gaze. It was observed that the

frequency of looking at the rearview mirror increased significantly when traffic density increased, and this behavior was particularly frequent during stop-and-go scenarios. Thanks to the online monitoring features of EOG data, the driver's gaze off the road could also be detected in real-time. In ThingSpeak's graphical interface, this behavior was visually differentiated when the signal level significantly deviated from the reference axis and lost continuity. This was considered a critical indicator that may be associated with short-term lapses in attention. Such behaviors were observed to occur more frequently, especially during long-term driving simulations, and were thought to be related to fatigue.

Simultaneous recording of ECG data allowed the assessment of the physiological correlates of behavioral findings. Analysis of HRV parameters revealed a trend toward an increase in the LF/HF ratio during periods of increased traffic density. This change indicates increased sympathetic nervous system activity and a higher level of physiological stress for the driver. Changes in HRV components were particularly pronounced during situations requiring intensive maneuvering and greater demands on environmental control. On the other hand, in stable driving sections, HRV parameters were more balanced, parasympathetic dominance increased, and the driver was in a more physiologically comfortable state. Real-time graphs obtained via ThingSpeak showed that the system's data transmission latency was quite low. The average update time was observed to be within 15 seconds, and packet loss was minimal. This performance indicates usability in IoT-based remote driver monitoring systems. Furthermore, it was confirmed that SD card recording is activated during interruptions in data flow, maintaining data continuity. This feature is a significant indicator of reliability, especially in field applications.

Overall, the findings demonstrate that EOG-based gaze direction tracking reflects the driver's behavioral state with high

accuracy, while ECG-based HRV analysis provides a physiological context for these behavioral outputs. The results offer potential applications in areas such as the development of advanced warning systems for driving safety, early detection of fatigue and loss of attention, and integration with autonomous systems. Furthermore, the system's real-time IoT-based architecture suggests a tracking approach that can be used not only in laboratory settings but also in real-world vehicle environments in the future.

Results

This study demonstrated the feasibility of a real-time monitoring-based driver behavior assessment approach using electrooculography (EOG) and electrocardiography (ECG) signals together. The findings demonstrate the feasibility of an integrated structure that allows for the simultaneous assessment of driver attention and physiological stress levels. The microcontroller-based system architecture ensures portability, low power consumption, and expandability. In this respect, the study provides significant evidence that biosignal-based driver monitoring systems can be developed without the need for expensive laboratory equipment. The use of the ThingSpeak IoT platform for real-time data transfer supported the continuity of the online monitoring process and demonstrated that sensor data can be transferred to the cloud with low latency. Real-time monitoring of horizontal deflections in the EOG signal on the platform enabled high-resolution tracking of driver gaze transitions between the road, the rearview mirror, and the side mirrors. This framework allows for dynamic observation of driving behavior, not just through recordings that can be analyzed later, and increases the system's adaptability to real-world driving scenarios. The IoT-based framework also provides the foundation for future driver warning mechanisms, AI-powered predictive models, and autonomous system integrations.

One of the key findings of the study is the simultaneous relationship between behavioral and physiological indicators. Rapid and repeated glances at side mirrors increased during heavy traffic, and a corresponding increase in the LF/HF ratio in ECG-based heart rate variability (HRV), indicating sympathetic activation, was observed. This correlation demonstrates a direct link between environmental threat perception, decision-making load, and physiological stress during driving. Conversely, during stable and fluid traffic conditions, gaze direction was concentrated on the roadway, the blink rate increased, and HRV parameters exhibited a balanced distribution indicating parasympathetic dominance. These results demonstrate that driver fatigue can be detected early, not only through behavioral metrics but also through physiological feedback.

The dual-layer data management approach, which combines local data recording and cloud-based transfer, stands out as another key finding that enhances the system's reliability. In cases of interrupted wireless communication, SD card recording prevented data loss and ensured system continuity. This feature provides a significant resilience mechanism against connection issues that may arise in real-world in-vehicle applications in the future. The study's results offer a new perspective based on the use of physiological signals, transcending driver monitoring approaches in the literature, which are predominantly based on camera-based image processing or questionnaire-based assessments. The findings demonstrate that the EOG signal can reflect micro-level visual behaviors, such as orientation to the rearview and side mirrors, with high accuracy, while ECG-based HRV analysis can add physiological meaning to these behaviors. Thus, the study makes a significant contribution to the development of systems based not only on behavioral observation but also on biomarker-based assessment in the field of driving safety.

Overall, this study presents an innovative approach at both theoretical and applied levels. The presented system architecture provides a low-cost, portable, and real-time solution that can be integrated into driving safety research, paving the way for future studies with large samples and based on real-world driving conditions. The findings are extensible to various application areas, such as early detection of driver fatigue and loss of attention, performance assessment in training simulations, adaptive safety mechanisms in intelligent transportation systems, and monitoring human-machine interaction in semi-autonomous vehicles. In this respect, the study makes a significant contribution to the development of physiologically based driving safety approaches.

Suggestions for Future Studies

While this study demonstrates the potential for improving driver behavior monitoring systems based on physiological signals, the findings also offer several avenues for future research. First, the study was conducted in a controlled environment and did not include all the variables of real-world road conditions. Therefore, it is recommended that future studies be conducted in real-world driving scenarios using a portable hardware infrastructure integrated into the vehicle. Because factors such as vehicle vibrations, sudden accelerations, braking, road slope, and ambient light changes can have different effects on biosignals, testing the system's real-world durability will be an important step. In this regard, the use of wireless, non-body-attached EOG sensors could offer advantages in reducing electrode drift and cable-related artifacts.

Secondly, although the study relied on single-channel ECG measurements, the use of multi-channel or wearable ECG systems is recommended for more comprehensive cardiac assessments in the future. Furthermore, to ensure greater accuracy in HRV analysis over long-term measurements, it is important to extend the study

durations and conduct comparative analyses of different driving conditions. Similarly, expanding EOG data to include the vertical axis for more detailed eye movement tracking and, if necessary, in conjunction with low-resolution camera-based verification systems will increase data reliability.

In terms of algorithmic development, basic classification models can be used in this study, and the application of machine learning-based methods to detect more complex behavioral patterns can make significant contributions in the future. Time-series-based models (LSTM, GRU) can better capture driver behavioral transitions, while multimodality integration (EOG + ECG + accelerometer + steering angle sensors) can create richer data representations. Furthermore, the development of personalized adaptive models can reduce false positive rates in biosignal-based driver monitoring systems. In this regard, research into transfer learning, calibration-free algorithms, and personalized thresholding strategies is recommended.

For IoT architecture development, MQTT-based broker systems, local servers, or edge computing solutions can be considered instead of the ThingSpeak platform. Particularly in applications where latency is critical, performing data processing on a microcontroller or local processor and transferring only summary data to the cloud will increase system efficiency. Furthermore, integrating mechanisms such as end-to-end encryption, dynamic management of API keys, and user access control will be essential for data security in the future.

Sampling is a key component of progress in this field. Studies with diverse sample groups, such as participants with different age groups, driving experience levels, and history of attention deficit or sleep disorders, can increase the generalizability of the system. Similarly, collecting data in different contexts, such as professional

drivers, urban and highway driving, will contribute to a more detailed classification of behavioral patterns.

Finally, ethics and user acceptance are important areas of consideration for future studies. Driver perceptions of biosignal-based monitoring systems, privacy concerns, data sharing permissions, and the psychological effects of continuous monitoring should be considered within the scope of research. Developing user-friendly interfaces, enabling the system to provide feedback without interrupting the driving experience, and designing intelligent algorithms that only generate warnings in risky situations will be critical to the success of real-world applications. Overall, this study paves the way for future multifaceted research in the field of physiologically based driving safety and provides an extensible framework, both technologically and methodologically. Future studies will make significant contributions to areas such as integration with autonomous systems, performance monitoring in driver training, and the implementation of early warning mechanisms.

Acknowledgements

This research was supported by the Scientific Research Projects Coordination Unit (BAP) of Çankırı Karatekin University under project number MYO111224B24.

References

Akinci R., Akdoğan E., Aktan M. E. (2022). Comparison of Machine Learning Algorithms for Recognizing Drowsiness in Drivers using Electroencephalogram (EEG) Signals. *International Journal of Intelligent Systems and Applications in Engineering*.

Altunkaya, C., & Zengin, A. (2022). Sürüş davranış tespiti ve tasnifi için takograflara yönelik yeni bir algoritma tasarımı ve uygulaması. *Bilişim Teknolojileri Dergisi*, 15(4), 389–400.

Ardabili S.Z., Bahmani S., Zare Lahijan L., Khaleghi N., Sheykhivand S., Danishvar S. (2024). A Novel Approach for Automatic Detection of Driver Fatigue Using EEG Signals Based on Graph Convolutional Networks. *Sensors*.

Chan, T. K., Chin, C. S., Chen, H., & Zhong, X. (2019). A comprehensive review of driver behavior analysis utilizing smartphones. *IEEE Transactions on Intelligent Transportation Systems*, 21(10), 4444–4475.

Hayawi, A. A., & Waleed, J. (2019). Driver's drowsiness monitoring and alarming auto-system based on EOG signals. In 2019 2nd International Conference on Engineering Technology and its Applications (IICETA) (pp. 214–218). IEEE.

Kaplan, S., Guvensan, M. A., Yavuz, A. G., & Karalurt, Y. (2015). Driver behavior analysis for safe driving: A survey. *IEEE Transactions on Intelligent Transportation Systems*, 16(6), 3017–3032.

Malik, M. (1996). Heart rate variability standards of measurement, physiological interpretation and clinical use. *Circulation*, 93(5), 1043–1065.

Murugan S., Sivakumar P.K., Kavitha C., Harichandran A., Lai W.-C. (2023). An Electro-Oculogram (EOG) Sensor's Ability to Detect Driver Hypovigilance Using Machine Learning. *Sensors*.

Peker N.Y., Semiz B., et al. (2025). Improved drowsiness detection in drivers through optimum pairing of EEG features using an optimal EEG channel comparable to a multichannel EEG system. *Medical & Biological Engineering & Computing*.

Qu, F., Dang, N., Furht, B., & Nojournian, M. (2024). Comprehensive study of driver behavior monitoring systems using computer vision and machine learning techniques. *Journal of Big Data*, 11(1), 32.

Razak, S. F. A., Yogarayan, S., Aziz, A. A., Abdullah, M. F. A., & Kamis, N. H. (2022). Physiological-based driver monitoring systems: A scoping review. *Civil Engineering Journal*, 8(12), 3952-3967.

Shahverdy, M., Fathy, M., Berangi, R., & Sabokrou, M. (2020). Driver behavior detection and classification using deep convolutional neural networks. *Expert Systems with Applications*, 149, 113240.

Şafak E., Doğru İ., Barışçı N., Toklu S. (2022). IoT based mobile driver drowsiness detection using deep learning. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*.

Wang, J., Chai, W., Venkatachalapathy, A., Tan, K. L., Haghighat, A., Velipasalar, S., ... & Sharma, A. (2021). A survey on driver behavior analysis from in-vehicle cameras. *IEEE Transactions on Intelligent Transportation Systems*, 23(8), 10186–10209.

World Health Organization. (2025). *Global Status Report on Road Safety 2023*.

Xiao, W., Xie, G., Liu, H., Chen, W., & Li, R. (2024). FDAN: Fuzzy deep attention networks for driver behavior recognition. *Journal of Systems Architecture*, 147, 103063.

BÖLÜM 2

GRADYAN-BAĞIMSIZ AÇIKLANABİLİR YAPAY ZEKÂ YÖNTEMLERİNİN GEOMETRİK DESEN SINIFLANDIRMASINDA PERFORMANS ANALİZİ

GÜRAY SONUGÜR¹

Giriş

Son yıllarda, yapay zekâ (YZ) ve makine öğrenimi alanlarında kaydedilen ilerlemeler, şekil tanıma işlemlerinin etkinliğini artırma potansiyeline sahiptir. Özellikle, derin öğrenme modelleri, şekil tanıma görevlerinde yüksek doğruluk oranları sunmakta ve bu da farklı sektörlerde uygulanabilirliklerini artırmaktadır (Fahmy, 2025). Ancak bu modellerin milyonlarca parametreden oluşan karmaşık ve doğrusal olmayan yapıları, onları "kara kutu" (black-box) olarak nitelendirilen yani verilen kararların hangi sebeplerle verildiği bilinmeyen sistemlere dönüştürmektedir (Deshpande, 2023; Vengatesh, 2025). Bir modelin belirli bir kararı hangi görsel kanıtlara dayanarak verdiği anlaşılamadığında, özellikle tıp, otonom sürüş, görsel tanıma ve finans gibi yüksek riskli alanlarda bu sistemlere duyulan güven azalmakta ve pratik uygulamaları kısıtlanmaktadır. Bu şeffaflık eksikliğini gidermek

¹ Doç. Dr., Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği, Orcid: 0000-0003-1521-7010

amacıyla ortaya çıkan Açıklanabilir Yapay Zeka (XAI), modellerin tahmin süreçlerini insan tarafından yorumlanabilir hale getirmeyi hedefler (Adadi & Berrada, 2018).

Görüntü sınıflandırma için geliştirilen ilk ve en yaygın XAI yöntemleri, modelin gradyanlarını (türevlerini) kullanarak bir karara etki eden pikselleri veya bölgeleri belirlemeye odaklanmıştır. Grad-CAM gibi gradyan-ağırlıklı yaklaşımlar, modelin son evrişim katmanındaki aktivasyonları ağırlıklandırarak karar anında "nereye baktığını" gösteren ısı haritaları üretir (Selvaraju et al., 2017). Ancak, gradyanların doğası gereği gürültülü olabilmesi, "kaybolan gradyan" (vanishing gradients) probleminden etkilenmesi ve bazı durumlarda modelin öğrendiği bilgiden çok görüntüdeki kenarları tespit etmesi gibi nedenlerle bu yöntemlerin güvenilirliği sorgulanmaya başlanmıştır (Adebayo et al., 2018). Bu durum, gradyan hesaplamalarına dayanmayan, alternatif ve potansiyel olarak daha sağlam açıklama mekanizmalarına olan ihtiyacı ortaya çıkarmıştır.

Bu ihtiyaca yanıt olarak, gradyan-bağımsız (gradient-free) veya pertürbasyon-tabanlı (perturbation-based) XAI yöntemleri önemli bir araştırma yönü olarak geliştirilmiştir. Bu yaklaşımların temel felsefesi, gradyanları kullanmak yerine, giriş görüntüsünün belirli kısımlarını sistematik olarak bozarak veya maskeleyerek modelin çıktısındaki değişimleri gözlemlemektir. Bu alandaki öncü yaklaşımlardan biri olan "Occlusion Sensitivity Analysis (OSA)", görüntü üzerinde küçük bir maskeyi sistematik olarak gezdirerek ve her konumda modelin tahminini yeniden hesaplayarak basit ama etkili bir önem haritası oluşturur (Zeiler & Fergus, 2014). Bu yöntem, modelin hangi özelliklere odaklandığını belirlemeye yardımcı olurken, aynı zamanda modelin şeffaflığını artırmaktadır (Wünsch et al., 2022). OSA, görüntü işleme alanında önemli bir yer edinmiştir. Bu yöntem kullanılarak gerçekleştirilen bir çalışmada;

OSA oluşturulan genetik profillerin analiz amacıyla kullanılmıştır (Koyama et al., 2025).

Daha gelişmiş bir yaklaşım olan “RISE (Randomized Input Sampling for Explanation)”, bu fikri binlerce rastgele oluşturulmuş maske kullanarak genelleştirir. Modelin tahminini, bu rastgele maskelerin ağırlıklı bir toplamı olarak ifade eder ve her bir pikselin önemini, o pikseli içeren maskelerin modelin nihai kararına yaptığı ortalama katkı üzerinden hesaplar (Petsiuk et al., 2018). Bu rastgele örnekleme süreci, yöntemi daha sağlam ve modelin iç yapısından tamamen bağımsız hale getirir. RISE yöntemi, sağlık alanında COVID-19 hastalarının otomatik şiddet değerlendirmesi çalışmasında modelin karar aşamalarına katkıda bulunan önemli bölgeleri işaretlemek için kullanılmıştır (Quiroz et al., 2021). Araştırmada, klinik ve görüntüleme verileri üzerinden yapılan analizlerle, RISE yönteminin modelin karar alma süreçlerine etkisi üzerine değerlendirilmeler yapılmıştır. Bu alandaki bir diğer önemli gelişme olan “Score-CAM” ise, Grad-CAM'in mimarisinden ilham alırken gradyan bağımlılığını ortadan kaldırır. Score-CAM, evrişim katmanlarından elde edilen aktivasyon haritalarını birer maske olarak kullanır ve her bir haritanın "önemini", o harita ile maskelenmiş görüntünün nihai sınıf skoruna yaptığı katkıyı doğrudan ölçerek (forward pass) belirler. Bu sayede, gradyanların neden olabileceği gürültüden arındırılmış, daha temiz ve sınıf-odaklı ısı haritaları üretir (Wang et al., 2020). (İbrahim & Shafiq, 2022) tarafından önerilen Augmented Score-CAM yöntemi, Score-CAM'in gradyan-bağımsız mimarisini iyileştirerek nesne yerleştirme yani nesne tespit ve işaretleme işlemlerinde doğruluğu arttırmıştır.


Bu çalışma, gradyan-bağımsız XAI yöntemleri olan Score-CAM, RISE ve OSA'nın performansını ve özelliklerini karşılaştırmalı olarak incelemeyi amaçlamaktadır. Bu yöntemlerin, gradyan tabanlı yaklaşımlara kıyasla daha güvenilir ve tutarlı açıklamalar üretip

üretmediği, kontrollü bir deney ortamında analiz edilecektir. Çalışmamız, bu üç yöntemin ürettiği açıklamaların kalitesini, modelin karar mantığını yansıtmadaki başarısını ve hesaplama maliyetlerini değerlendirerek, modern XAI literatüründeki gradyan-bağımsız yaklaşımların güçlü ve zayıf yönlerini ortaya koymayı hedeflemektedir.

Veri Seti

Bu çalışmada kullanılan veri seti sentetik olarak sonuçların doğruluğunu kanıtlamaya zemin olmak üzere kontrollü olarak üretilmiştir. Görseller, beyaz arka plan üzerine çizilen geometrik şekillerden üretilmiştir. Veri seti iki sınıftan oluşmaktadır: Sade desenler ve Karışık desenler. Sade desenler, dörtgen, üçgen, çember, ok, yıldız gibi geometrik şekillerin farklı ölçeklerde sade yani bozulmamış hâllerini içermektedir. Karışık desenler, sade desenlerin belirli bölgelerinin beyaz yamalarla kısmen bozulmasıyla elde edilmiştir. Böylece her görüntüye karşılık gelen bozulma alanını (distortion region) gösteren ground truth maskeleri de oluşturulmuştur. Bu yöntem sayesinde hem orijinal hem de gerçek bozulma bölgesini içeren ikili veri yapısı elde edilmiştir. Bozulma işlemi hem şeklin üzerine gelen hem de bazı örneklerde kenar bölgelerine taşacak şekilde gerçekleştirilmiştir. Bozulma oranı %8–15 arasında rastgele uygulanmış olup, gerçek hayattaki lokal kusurların temsil edilmesini sağlamıştır. Toplam veri seti 6854 görüntüden oluşmakta olup, her iki sınıf da eşit sayıda örnek içermektedir. Görsellerin boyutu 256×256 piksel olarak standartlaştırılmış, renk uzayı RGB biçiminde korunmuştur. Veri seti, modelin genelleme kabiliyetini artırmak amacıyla %70 eğitim, %15 doğrulama ve %15 test oranlarında bölünmüştür. Bölme işlemi rastgele ancak sınıf dengesi gözetilerek yapılmıştır. Böylece her iki sınıfın da tüm alt kümelerde benzer dağılıma sahip olması sağlanmıştır.

Şekil 1 Test görsellerinden bazıları 1. Satır Sade desenler; 2. Satır Karışık desenler sınıfı



Bu çalışmada, sınıflandırma doğruluğunu yüksek tutarak ilgi bölgelerinin (ROI) doğru biçimde belirlenmesini sağlamak amacıyla ResNet50 tabanlı bir transfer öğrenme yaklaşımı kullanılmıştır. XAI ile tespit edilen ROI'lerden emin olabilmek için sınıflandırma doğruluğundan emin olmak gerekir. Bu amaçla ImageNet üzerinde önceden eğitilmiş ResNet50 modeli transfer öğrenme ile iki sınıfa uyarlanmıştır. Transfer öğrenmede İlk 30 katman dondurulmuş, son 20 katman eğitime açılmıştır. Çıkış Katmanı, iki tam bağlı katman olarak yeniden tanımlanmıştır. Adam optimizasyonu ve Cross-Entropy kayıp fonksiyonu ile eğitimler gerçekleştirilmiştir.

Deneysel Yöntem

Çalışmada üç farklı gradyan-bağımsız açıklanabilir yapay zekâ yöntemi olan **RISE**, **ScoreCAM** ve **OSA** kullanılmıştır.

- **RISE** yöntemi, rastgele oluşturulan maskeler aracılığıyla modelin çıktı değişimlerini analiz ederek önem haritaları üretmiştir.

- **ScoreCAM** yöntemi, modelin ara katman aktivasyonlarını giriş görüntüsüne bağlı sınıf skorlarına göre yeniden ölçeklendirmiştir.
- **OSA** yöntemi ise görüntünün farklı bölgelerini sırayla kapatarak modelin sınıf skorundaki değişimi ölçmüştür.

Isı Haritalarından ROI Çıkarımı

Üç gradyan-bağımsız yöntemin ürettiği ısı haritalarından modelin odaklandığı bölgeleri çıkarmak için renk kanallarına dayalı sabit eşikler kullanılmamıştır. Bunun yerine, her ısı haritasının kendi dağılımına göre normalize edilen **yoğunluk tabanlı bir eşikleme** yaklaşımı tercih edilmiştir. Bu yöntemlerin her biriyle elde edilen ısı haritaları 0-1 aralığına normalize edilmiştir. Modelin en fazla odaklandığı alanları belirlemek için, H ısı haritası maske matrisi olmak üzere:

$$H_{normalize} = \frac{H - H_{min}}{H_{maks} - H_{min}} \quad 1$$

Şeklinde normalize edilmiş ısı maske matrisi oluşturulmuş ve daha sonra ROI bölgesini belirlemek amacıyla ısı haritasında piksellerin yoğunluk dağılımlarındaki üst %10'luk dilim ROI olarak belirlenmiştir. Bu şekilde; i ve j maske matrisi satır ve sütun koordinat numaraları olmak üzere Eşitlik 2'de belirtildiği şekilde her görüntü için bir "ısı alanı" maskesi elde edilmiştir.

$$ROI(i, j) = \begin{cases} 1, & H_{norm} \geq 0.9 \\ 0, & \text{diğer durumlar} \end{cases} \quad 2$$

Elde edilen ısı haritası maskeleri, görüntülere ait **bozulma** maskeleriyle karşılaştırılarak iki farklı ölçüt hesaplanmıştır:

- a. Kapsama Oranı (IoU - Intersection over Union)

- b. Dengeli Kapsama Oranı (DKO), yani büyük ısı alanlarının cezalandırıldığı özel bir IoU türevidir.

Dengeli oran, aşağıdaki formül kullanılarak hesaplanmıştır:

$$DKO = \frac{IoU}{Bozulma Alanı + Isı Haritası Maske Alanı - IoU} \quad 3$$


Bu metrik, küçük ancak tam örtüşen ısı haritası alanlarına yüksek puan verirken, çok büyük ve dağınık olup tam örtüşmeyen ısı haritası alanlarına ise düşük puan vermektedir. Böylece, klasik IoU'ya göre geniş ısı bölgelerini cezalandırarak açıklanabilirlik haritalarının gerçek bozulma alanlarına ne kadar duyarlı olduğunu ölçmektedir.

Bulgular

ScoreCAM, RISE ve Occlusion yöntemleri için tüm test verilerinde ısı haritası maskeleri ile bozulma alanlarının örtüşme miktarları hesaplanarak ortalama IoU ve Dengeli Kapsama Oranı değerleri hesaplanmış, sonuçlar grafiklerle görselleştirilmiş ve yöntemler arası karşılaştırma yapılmıştır. Her üç yöntem için de hazırlanan Isı haritaları, ısı haritalarının en sıcak bölgelerini yani ROI alanlarını gösteren maskeler ve test imgesindeki bozulma alanı ile ısı maskelerinin kesişme alanları Şekil 2'de verilmiştir. Görüntülerde yeşil renkli alanlar desenlerin içindeki bozulma alanlarını gösterirken kırmızı alanlar ise ısı maskeleri ile kesişme bölgelerini temsil etmektedir.

Test veri setinde bulunan tüm imgeler için elde edilen IoU ve dengeli oran değerlerinin ortalamaları ve medyan değerleri incelendiğinde; ScoreCAM yöntemi hem ortalama hem de medyan değerlerinde diğer yöntemlere göre belirgin bir üstünlük göstermiştir.

Şekil 2 Çıktı görselleri, 1. Satır: ısı haritaları, 2. Satır: Isı haritası maskeleri ve 3. Satır: örtüşme alanları




OSA yöntemi orta düzeyde bir performans sergilerken, RISE yöntemi oldukça düşük değerlerde kalmıştır. Elde edilen sonuçlara göre hazırlanan tablo Tablo 1’de verilmiştir.

Tablo 1 IoU ve Dengeli Oran ölçütleriyle elde edilen özet istatistik sonuçlar

Yöntem	IoU Ortalama (%)	IoU Medyan (%)	Dengeli Oran Ortalama (%)	Dengeli Oran Medyan (%)
ScoreCAM	15.87	16.59	22.20	21.49
RISE	2.16	0.58	2.96	0.70
OSA	7.15	5.71	14.75	11.08

Yöntemlere göre dengeli oran dağılımlarının grafiksel özetleri de Grafik 1’de verilmiştir.

Grafik 1 Yöntemlere göre dengeli oran kutu grafikleri



Kutu grafiklerinden de görüldüğü üzere, ScoreCAM yöntemi sadece ortalama performansta değil, aynı zamanda daha düşük varyans değeriyle de öne çıkmaktadır. Bu durum, yöntemin farklı geometrik desenlerde daha tutarlı bir şekilde hedef bölgeye (ROI) odaklanabildiğini göstermektedir. Occlusion yöntemi bazı örneklerde yüksek kapsama elde etse de genel dağılımı geniş olup kararsız davranış sergilemiştir. RISE yönteminin başarısızlığı ise, rastgele maskeleme stratejisinin bu tür küçük ve belirgin bozulma alanlarını yakalamakta yetersiz kalmasından kaynaklanmaktadır. Bu bulgular, ScoreCAM'in geometrik şekil sınıflandırması gibi lokal odaklı görsel görevlerde, gradyan tabanlı yöntemlere yakın doğrulukta ve yüksek kararlılıkta açıklanabilirlik sağladığını göstermektedir.

Sonuçlar

Yapılan deneysel çalışmalar sonucunda, üç gradyan-bağımsız açıklanabilirlik yöntemi arasında ScoreCAM'in en dengeli ve doğru bölge tespiti gerçekleştirdiği belirlenmiştir. Yöntemin, sınıf

skorlarına dayalı aktivasyon haritalarını doğrudan kullanması, modelin gerçekten karar verdiği bölgeleri daha isabetli biçimde temsil etmesini sağlamıştır.

OSA yöntemi, özellikle belirgin bozulma bölgelerinde tatmin edici sonuçlar üretse de yüksek işlem yükü ve değişken odaklanma davranışı nedeniyle tutarlılığını koruyamamıştır. RISE yöntemi ise rastgele örnekleme tabanlı yapısı gereği lokal bozulma bölgelerini temsil etmekte yetersiz kalmıştır.

Genel olarak değerlendirildiğinde, ScoreCAM yöntemi geometrik desenlerin açıklanabilirlik analizlerinde en güvenilir gradyan-bağımsız yaklaşım olarak öne çıkmıştır. Bu sonuçlar, ileride yapılacak çalışmalarda tıbbi görüntüleme, endüstriyel kalite kontrol ve geometrik desen analizi gibi alanlarda ScoreCAM'in öncelikli olarak tercih edilebileceğini göstermektedir.

Gelecekte yapılabilecek çalışmalar ile açıklanabilirlik yöntemlerinin mimari ve veri türü bağımlılıklarını daha ayrıntılı incelenerek çalışmanın kapsamı genişletilebilir. İlk olarak, ScoreCAM, RISE ve OSA yöntemlerinin performansının ResNet50 ile sınırlı olup olmadığını anlamak amacıyla EfficientNet, DenseNet veya Vision Transformer gibi farklı ağ mimarileri ile benzer deneyler yürütülebilir. Bunun yanında, geometrik desenlerden daha karmaşık tıbbi, endüstriyel veya doğal görüntü veri setlerine geçilerek gradyan-bağımsız yöntemlerin gerçek dünya koşullarındaki kararlılığı değerlendirilebilir. Ayrıca, açıklanabilirlik haritalarının yalnızca bir analiz aracı olarak değil, eğitim sürecini yönlendiren bir mekanizma olarak kullanıldığı ROI-destekli eğitim yani elde edilen açıklanabilirlik verilerinin eğitim süreçlerine katılması ile modellerin hem doğruluk hem de açıklanabilirlik açısından daha güçlü hale gelmesi sağlanabilecektir.

Kaynakça/References

Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: A survey on explainable artificial intelligence (XAI). *IEEE Access*, 6, 52138–52160.

Adebayo, J., Gilmer, J., Muelly, M., Goodfellow, I., Hardt, M., & Kim, B. (2018). Sanity checks for saliency maps. In *Advances in Neural Information Processing Systems (NeurIPS)* (Vol. 31).

Deshpande, P. (2023). Interpretable deep learning models: Enhancing transparency and trustworthiness in explainable AI. *Proceedings of the International Conference on Science and Engineering*, 11(1), 1352–1363.
<https://doi.org/10.52783/cienceng.v11i1.286>

Fahmy, A. (2025). Assessing the efficacy of AI models in medical imaging analysis for the early identification of diabetic foot ulcers and gangrene: A review. *Premier Journal of Science*, 12, 100093.
<https://doi.org/10.70389/pjs.100093>

Ibrahim, R., & Shafiq, M. O. (2022). Augmented Score-CAM: High-resolution visual interpretations for deep neural networks. *Knowledge-Based Systems*, 252, 109287.

Koyama, Y., Nasu, M., & Matsuoka, Y. (2025). f4-statistics-based ancestry profiling and convolutional neural network phenotyping shed new light on the structure of genetic and spike shape diversity in *Aegilops tauschii* Coss. *Proceedings of the Japan Academy Series B*, 101(6), 357–370. <https://doi.org/10.2183/pjab.101.023>

Petsiuk, V., Das, A., & Saenko, K. (2018). RISE: Randomized input sampling for explanation of black-box models. In *British Machine Vision Conference (BMVC)*.

Quiroz, J., Feng, Y., Cheng, Z., Rezazadegan, D., Chen, P., Lin, Q., & Cai, X. (2021). Development and validation of a machine learning approach for automated severity assessment of COVID-19 based on clinical and imaging data: Retrospective study. *JMIR Medical Informatics*, 9(2), e24572. <https://doi.org/10.2196/24572>

Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-CAM: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*.

Vengatesh, T. (2025). Transparent decision-making with explainable AI (XAI): Advances in interpretable deep learning. *Journal of Information Systems Engineering & Management*, 10(4), 1295–1303. <https://doi.org/10.52783/jisem.v10i4.10584>

Wang, H., Wang, Z., Du, M., Yang, F., Zhang, Z., Ding, S., & Hu, X. (2020). Score-CAM: Score-weighted visual explanations for convolutional neural networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops* (pp. 24–25).

Wünsch, A., Liesch, T., Cinkus, G., Ravbar, N., Chen, Z., Mazzilli, N., & Goldscheider, N. (2022). Karst spring discharge modeling based on deep learning using spatially distributed input data. *Hydrology and Earth System Sciences*, 26(9), 2405–2430. <https://doi.org/10.5194/hess-26-2405-2022>

Zeiler, M. D., & Fergus, R. (2014). Visualizing and understanding convolutional networks. In *European Conference on Computer Vision (ECCV)*.

BÖLÜM 3

ROBOTİK SİSTEMLERDE YAPAY ZEKÂ (YZ) ENTEGRASYONU: GÜNCEL YAKLAŞIMLAR VE GELECEK VADEDEN ALANLAR

Kamil ORMAN¹

Funda AKAR²

Giriş

Yapay zekâ (YZ) ile robotik alanlarının kesişimi, Dördüncü Sanayi Devrimi'nin (Endüstri 4.0) temelini oluşturan köklü bir teknolojik dönüşümü temsil etmektedir. Geleneksel robotik sistemler, genellikle önceden tanımlanmış ve tekrarlayıcı nitelikteki görevleri yüksek doğrulukla yerine getirmek üzere programlanmıştır. Bu sistemler hız ve hassasiyet açısından önemli avantajlar sunsa da, esneklik, uyarlanabilirlik ve beklenmeyen ya da karmaşık ortamlarda otonom karar verebilme kapasitesi bakımından belirgin sınırlılıklar taşımaktadır (Siciliano & Khatib, 2016:1, Brooks, 1991:2). Buna karşın, özellikle Makine Öğrenimi (MÖ) ve Derin Öğrenme'nin (DÖ) gelişimiyle ivme kazanan YZ tekniklerinin robotik sistemlere entegrasyonu, söz konusu kısıtlılıkları aşarak

¹ Doç. Dr., Erzincan Binali Yıldırım Üniversitesi, Bilgisayar Mühendisliği Bölümü, Orcid: 0000-0002-7236-9988

² Dr. Öğr. Üyesi, Erzincan Binali Yıldırım Üniversitesi, Bilgisayar Mühendisliği Bölümü, Orcid: 0000-0001-9376-8710

robotları salt otomasyon araçlarından, öğrenebilen, çevresiyle etkileşim kurabilen ve durumsal farkındalığa sahip akıllı varlıklara dönüştürmektedir (Goodfellow, Bengio & Courville, 2016:2, Krizhevsky, Sutskever & Hinton, 2012:2). Bu dönüşüm yalnızca robotların görevleri yerine getirme biçimini değil, aynı zamanda neden belirli kararlar aldıklarını kavrama, hatalarından öğrenme ve dinamik koşullara uyum sağlama yeteneklerini de derinleştirmektedir.

Robotik ve YZ arasındaki bu sinerji, imalat, lojistik, sağlık, savunma ve günlük yaşam gibi geniş bir yelpazeye yayılan sektörlerde operasyonel verimliliği, güvenliği ve hizmet kalitesini kökten iyileştirme potansiyeli taşımaktadır. Güncel araştırmalar, robotların çevrelerini gerçek zamanlı olarak algılamasını, karmaşık görevleri hiyerarşik biçimde planlamasını ve insanlarla güvenli, doğal bir işbirliği içinde çalışmasını mümkün kılan algoritmaların geliştirilmesine odaklanmaktadır (Russell & Norvig, 2020:1, Arras, Stachniss & Burgard, 2007:1). Örneğin, YZ destekli görsel algılama (Bilgisayarlı Görme) sistemleri, endüstriyel robotların farklı boyutlardaki ya da rastgele konumlanmış nesneleri ayırt ederek seçebilmesini sağlamaktadır. Benzer şekilde, sensör füzyonu ve kuvvet/tork sensörlerinden elde edilen verilerin YZ algoritmalarıyla işlenmesi, robotların yüksek hassasiyet gerektiren manipülasyon görevlerini güvenilir şekilde gerçekleştirmesine olanak tanımaktadır (Levine & ark., 2016:1, Draelos & ark., 2020:2)

Bu araştırma makalesi, YZ'nin robotik sistemlere entegrasyonuna yönelik güncel metodolojileri incelemeyi, bu metodolojilerin endüstriyel ve bilimsel uygulamalardaki kritik etkilerini analiz etmeyi ve alanın geleceğine yön verebilecek araştırma eğilimleri ile etik tartışmaları değerlendirmeyi amaçlamaktadır. YZ'nin robotlara kazandırdığı adaptif öğrenme, otonom seyrüsefer ve insan-robot işbirliği (Human-Robot Collaboration, HRC) yeteneklerinin ayrıntılı biçimde ele alınması,

söz konusu dönüşümün hem teorik hem de uygulamalı yönlerinin bütüncül olarak anlaşılmasına katkı sunacaktır. Özellikle son yıllarda önem kazanan Üretken Fiziksel YZ (Generative Physical AI) ve Büyük Dil Modellerinin (LLM) robotik karar verme süreçlerine uyarlanmasına yönelik yenilikçi yaklaşımlar, makalenin odak noktalarından birini oluşturmaktadır(Ahn & ark., 2022:1). Robotların yalnızca fiziksel değil, bilişsel açıdan da otonom hâle gelmesi, geleceğin akıllı sistemlerinin inşasında kritik bir rol üstlenmektedir.

Bu bağlamda, çalışma, YZ'nin robotik sistemlerdeki rolünün yardımcı bir araç olmaktan çıkıp sistemin çekirdek zekâsını oluşturan temel bir bileşen hâline geldiği günümüz teknolojik paradigmasını kapsamlı biçimde analiz etmektedir. Robotik sistemlerde YZ'nin etkin biçimde uygulanması; veri toplama, model eğitimi, sistem entegrasyonu ve sürekli öğrenme olmak üzere dört temel aşamadan oluşan sistematik bir çerçeve gerektirmektedir (Yapay Zeka ile Robot Teknolojisinde Büyük Dönüşüm, 2025). Bu yapı, robotik çözümlerin sürekli olarak iyileştirilmesine ve optimize edilmesine imkân tanımaktadır. YZ entegrasyonu ile güçlendirilmiş robotlar, karmaşık görevleri daha etkin, güvenilir ve verimli biçimde yönetebilmekte; bu da işletmelerin rekabet gücünü anlamlı ölçüde artırmaktadır (Robotik Sistemler ve Yapay Zeka:Endüstriyel Üretimde Yeni Ufuklar, 2025). Dolayısıyla, bu alanın kapsamlı biçimde anlaşılması ve ilerletilmesi, küresel teknolojik liderlik ve sürdürülebilir üretim açısından stratejik bir önem taşımaktadır.

Robotik Sistemlerde YZ Entegrasyonunun Temel Bileşenleri

1. Algı Sistemleri (Perception)

Robotların çevresini anlaması için YZ tabanlı görsel algı kritik rol oynamaktadır.

Güncel Algı Yöntemleri:

- Vision Transformers (ViT)
- YOLOv9, DETR2 tabanlı nesne tanıma
- 3D Point Cloud İşleme (PointNet++, PV-RCNN)
- Diffusion tabanlı görüntü oluşturma ve tamamlama
- Sensör füzyonu için derin öğrenme (DeepFusion, BEVFusion)

2. Hareket Planlama (Motion Planning)

Güncel Hareket Planlama Algoritmaları:

- RL tabanlı planlama (PPO, DreamerV3, SAC)
- Derin öğrenme destekli RRT, PRM
- GNN tabanlı çoklu robot yol planlama
- Diffusion Policies ile yörünge sentezi

3. Karar Verme

Robotların otonomi seviyesini belirleyen karar verme modülleridir.

Karar Verme Prensipleri:

- Olasılıksal karar verme (POMDP)
- Kural tabanlı + öğrenme tabanlı hibrit sistemler
- Model Predictive Control + YZ tahminleyiciler
- Multi-agent RL ile dağıtık karar mekanizmaları

Tablo 1. Robotik Uygulamalarda Kullanılan Güncel YZ Modelleri

Model	Uygulama	Avantaj
ViT / Swin Transformer	Görü, segmentasyon	Daha geniş context

GNN	Çoklu robot koordinasyonu	İlişkisel öğrenme
Diffusion Models	Yörünge üretimi, sim-to-real	Gürültü toleransı
World Models (DreamerV3)	RL tabanlı simülasyon	Hızlı öğrenme
LLM-Robotics (RT-X, RoboGPT)	Görev planlama	Doğal dil ile kontrol

Güncel Yaklaşımlar

Robotik sistemlere yapay zekâ entegrasyonuna yönelik güncel yaklaşımlar, robotların çevresel sensör verilerini anlamlandırma, dinamik görevleri etkili biçimde planlama ve karmaşık becerileri otonom olarak edinme yeteneklerini en üst düzeye çıkarmayı amaçlamaktadır.


1. Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning - DRL)

Derin Pekiştirmeli Öğrenme, robotların bir çevre içerisinde deneme-yanılma yoluyla en uygun eylem stratejilerini öğrenmesini sağlayan en etkili yöntemlerden biri olarak öne çıkmaktadır (Sutton & Barto, 2018:1). Bu yaklaşımda robot, gerçekleştirdiği her eylemin ardından aldığı ödül veya ceza sinyallerine göre davranışlarını sürekli olarak optimize eder (Şekil 1).

Uygulama alanları: Otonom seyrüsefer (örneğin, otonom araçlar ve depo robotları), hassas manipülasyon (örneğin, cerrahi robotlar), karmaşık motor becerilerin (örneğin, insansı robotların yürümesi) öğrenilmesi.

Avantajı: DRL, robotların özellikle önceden programlanması güç olan dinamik, belirsiz ve sürekli değişen ortamlarda yüksek performans gösterebilmesini mümkün kılar.

Şekil 1. Derin Pekıştirmeli Öğrenme modeli




Kaynak: <https://chatgpt.com/>

2. Görsel Algılama için Derin Öğrenme (Deep Learning for Visual Perception)

Robotların çevrelerini doğru ve etkin bir şekilde anlamlandırması, görevleri güvenilir biçimde yerine getirmeleri açısından kritik bir öneme sahiptir. Konvolüsyonel Sinir Ağları (CNN'ler) başta olmak üzere çeşitli derin öğrenme mimarileri, robotik sistemlerde kamera, LiDAR ve benzeri sensörlerden elde edilen görsel verilerin işlenmesinde önemli bir dönüşüm yaratmıştır (LeCun, Bengio & Hinton, 2015:2). Bu teknolojiler sayesinde robotlar, çevresel özellikleri daha hassas biçimde algılayabilmekte, nesneleri tanıyabilmekte ve dinamik ortamlara daha hızlı uyum sağlayabilmektedir.

Uygulama alanları: Akıllı kalite kontrol (kusur tespiti), nesne tanıma, sınıflandırma ve izleme (pick-and-place görevleri), SLAM (Simultaneous Localization and Mapping - Eşzamanlı Konumlandırma ve Haritalama) uygulamalarında çevresel özellik çıkarımı.

Şekil 2. Yapay Zeka Destekli Ürün tanıma algılama modeli



Kaynak: <https://gemini.google.com/>


Örnek: Şekil 2’de gösterildiği üzere, üretim hatlarında yüksek çözünürlüklü kameralarla entegre çalışan YZ tabanlı görsel denetim sistemleri, milimetrik ölçekteki üretim kusurlarını gerçek zamanlı olarak tespit ederek süreçlerin anında düzeltilmesini mümkün kılmaktadır (Robotik Sistemlerde Adaptif Yapay Zeka Kullanımı, 2025).

3. Uçtan Uca (End-to-End) Öğrenme ve Taklitçi Öğrenme (Imitation Learning)

Uçtan uca öğrenme, robotik sistemlerde sensör girdilerini (örneğin ham görüntü pikselleri) doğrudan motor çıktılarıyla (örneğin eklem torkları veya hız komutları) ilişkilendiren tek bir yapay sinir ağı mimarisi kullanmaktadır (Levine & ark., 2016:1). Bu yaklaşım, geleneksel boru hattı (pipeline) mimarisinde ayrı olarak ele alınan algılama, planlama ve kontrol modüllerinin ortadan kaldırılmasını sağlayarak bütünleşik, optimize edilmiş davranışların öğrenilmesine imkân tanır. Böylece sistem daha hızlı tepki verebilir ve kapsamlı özellik mühendisliğine duyulan ihtiyaç önemli ölçüde azalır.

Şekil 3’te gösterildiği üzere, uçtan uca öğrenmenin kritik bir alt alanı olan Taklitçi Öğrenme (Imitation Learning – IL), robotların belirli görevleri uzman bir demonstratörü—genellikle bir insan operatörü—gözlemleyip taklit ederek öğrenmesini sağlar (Argall & ark., 2009:1). Bu yöntem, karmaşık görevlerin ayrıntılı biçimde programlanması gerekliliğini ortadan kaldırarak öğrenme sürecini büyük ölçüde kolaylaştırır; çünkü robot, doğru eylem dizilerini doğrudan giriş-çıkış eşleştirmeleri üzerinden edinir. Özellikle teleoperasyon yoluyla toplanan insan demonstrasyonları, robotların manipülasyon ve seyrüsefer gibi zor görevlerde yetkinlik kazanmasını önemli ölçüde hızlandırmaktadır. IL, pekiştirmeli öğrenmeye kıyasla çok daha az deneme-yanılma gerektirdiği için robotların gerçek dünya uygulamalarına daha hızlı ve güvenli bir biçimde uyum sağlamasına olanak tanır.

Şekil 3. Taklitçi öğrenme modeli



Kaynak: <https://gemini.google.com/>

4. İnsan-Robot İşbirliği (Human-Robot Collaboration - HRC)

Geleneksel robotik hücrelerin aksine, kolaboratif robotlar (cobot'lar) yapay zekâ desteğiyle insanlarla aynı çalışma alanını güvenli ve yüksek verimlilikle paylaşabilmektedir. YZ algoritmaları, robotların insan hareketlerini öngörmesine, niyetlerini yorumlamasına ve potansiyel çarpışmaları proaktif biçimde önlemesine imkân tanır (Ajoudani & ark., 2018:2). Böylece, insan-robot etkileşimi daha akıcı, uyumlu ve güvenli bir hâle gelir.

Yaklaşımlar: Güvenli ve uyarlanabilir yörünge planlaması, Jest ve ses tanıma, Doğal dil komutlarının işlenmesi ve Ortak niyet tanıma.

Şekil 4. İnsan-Robot işbirliğinin modellendiği kolobratif bir robot örneği



Kaynak: <https://gemini.google.com/>

Robot Etiği ve Güvenliđi

Yapay zekâ entegrasyonunun robotların otonom karar verme kapasitesini artırmasıyla birlikte, etik ve güvenlik boyutları robotik arařtırmaların merkezine yerleřmiřtir. Robot etiđi, robotların özellikle ikilemlerle karřılařtıkları durumlarda —örneğin otonom araçların kaçınılmaz kaza senaryolarında— ahlaki açıdan kabul edilebilir kararlar almasını sađlayacak prensiplerin, çerçevelerin ve algoritmaların geliştirilmesini kapsamaktadır (Topol, 2019:1).

Güvenlik (Safety): YZ destekli robotlarda güvenlik, yalnızca insan–robot işbirliđi (HRC) kapsamında fiziksel çarpışmaların önlenmesiyle sınırlı değildir; aynı zamanda siber güvenlik (Security) ve algoritmik güvenilirlik boyutlarını da içerir. Kritik altyapılarda kullanılan robotik sistemlerin siber saldırılara karřı korunması, veri bütünlüğünün sađlanması ve YZ modellerinin kötü niyetli girdilerle (Adversarial Attacks) manipüle edilmesine karřı dirençli hale getirilmesi temel gereksinimlerdir (Zhang & ark., 2022:1).

Hesap Verebilirlik ve Şeffaflık: Derin öğrenme modellerinin “kara kutu” doğası, robotların verdiđi otonom kararların gerekçelendirilmesini zorlařtırmakta ve Açıklanabilir Yapay Zekâ (Explainable AI – XAI) mekanizmalarına olan ihtiyacı artırmaktadır. Hesap verebilir ve şeffaf bir sistem, bir hata ya da kaza durumunda sorumluluğun belirlenmesini kolaylařtırırken, aynı zamanda kullanıcı güvenini pekiřtirir. Bu gereklilik, özellikle sađlık, savunma ve kritik endüstriyel operasyonlar gibi yüksek risk barından sektörlerde hayati önem taşımaktadır.

Üretken Fiziksel Yapay Zekâ ve Temel Modeller (Generative Physical AI and Foundation Models)

Bu yeni yaklařım, geniř ölçekli veri kümeleri üzerinde eđitilmiş temel yapay zekâ modellerinin (örneğin LLM’ler) robotik eylemleri, planlamayı ve karar verme süreçlerini yönlendirmesi

esasına dayanmaktadır (Ahn & ark., 2022:1). Bu sayede robotlar, karmaşık görevleri çözmek için insan benzeri akıl yürütme, bağlam çıkarımı ve doğal dil anlama yeteneklerinden yararlanabilmektedir. Temel modeller üzerine yapılan güncel araştırmalar, bu yaklaşımın robotik sistemlerin genellenebilirliğini ve adaptasyon yeteneklerini büyük ölçüde artıracığını göstermektedir (Üretken Fiziksel Yapay Zeka ve Robotlar İçin Temel Modeller, 2025).

Avantaj: Bu alanın en önemli kazanımlarından biri, robotların zero-shot (hiç karşılaşmadığı bir görevi yerine getirme) ve few-shot (çok az örnekle öğrenme) yeteneklerini geliştirmesidir. Böylece robotlar, minimal programlama gereksinimiyle daha geniş bir görev yelpazesini otonom şekilde gerçekleştirebilir. Ayrıca, altyapı-robot işbirliğine yönelik çalışmalar, bu entegrasyonun geleceğin akıllı fabrika ve endüstri 5.0 ortamları için kritik bir yapı taşı olduğunu ortaya koymaktadır (Chen & ark., 2020:1).


Gelecek Vadeden Alanlar

Robotik ve yapay zekâ entegrasyonu, mevcut teknolojilerin sınırlarını zorlayarak gelecekte önemli dönüşümlere yol açması beklenen birçok yenilikçi alanı gündeme getirmektedir.

1. Otonom Mikrosistemler ve Nanorobotik

Tıbbi uygulamalar için geliştirilen mikroskobik robotlar, özellikle hedefli ilaç dağıtımı ve minimal invaziv cerrahi gibi alanlarda kritik bir rol üstlenecektir (Nelson, Kaliakatsos & Abbott, 2010:1). Yapay zekâ, bu mikrosistemlerin yüksek hassasiyetle seyrüsefer yapmasını, biyolojik çevreye uyum sağlamasını ve değişken koşullara gerçek zamanlı tepki verebilmesini mümkün kılmaktadır. Şekil 5'te modellendiği üzere, YZ algoritmalarının nano-robotlara entegre edilmesi, bu robotların insan vücudunun karmaşık ve dinamik biyolojik yapısında tamamen otonom bir şekilde hareket edebilmesini sağlayacaktır.

Şekil 5. Damar cerrahisinde nano-robot kullanımı



Kaynak: <https://gemini.google.com/>

2. Akıllı Lojistik ve Tedarik Zinciri Yönetimi

Depo otomasyonunda kullanılan otonom mobil robotlar (AMR'ler), Şekil 6'da gösterildiği üzere, derin pekiştirmeli öğrenme (DRL) sayesinde dinamik üretim planlaması ve rota optimizasyonu gerçekleştirerek lojistik süreçlerin esnekliğini ve hızını önemli ölçüde artırmaktadır (Wurman, D'Andrea & Mountz, 2008:1). Yapay zekâ, değişken talep seviyeleri ve kaynak durumlarına göre görev dağılımını otomatik olarak planlayabilmekte; böylece operasyonel karar alma süreçlerinde yüksek uyarlanabilirlik sağlamaktadır (Shimonishi, 2021:1). Mobil robotların yol planlamasında DRL tabanlı algoritmaların kullanılması, sistemin hem verimliliğini hem de otonomi düzeyini belirgin biçimde yükseltmektedir (Kim & Lee, 2019:1). Üretim sektöründe YZ entegrasyonunun sağladığı bu performans artışı, endüstriyel dönüşümün temel yapı taşlarından birini oluşturarak akıllı fabrika vizyonunun gerçekleştirilmesine

doğrudan katkı sunmaktadır (Üretim Sektöründe Yapay Zeka Entegrasyonu, 2025).

Şekil 6. Depo otomasyonunda kullanılan otonom mobil robot



Kaynak: <https://gemini.google.com/>

3. Bilişsel Robotik ve Duygusal YZ

Bilişsel robotik ile duygusal yapay zekânın (YZ) geleceğe yönelik vizyonu, makinelerin yalnızca mantıksal ve mekanik görevleri yerine getiren araçlar olmaktan çıkarak, insan benzeri anlama, muhakeme ve duygusal zeka yetenekleriyle donatılmış gelişmiş sistemlere dönüşmesini öngörmektedir. Bilişsel robotik, algılama, öğrenme, akıl yürütme ve karar verme gibi üst düzey bilişsel süreçleri fiziksel robotik yapılarla entegre ederek robotların karmaşık ve öngörülemez ortamlarda daha özerk, esnek ve etkili biçimde faaliyet göstermesini hedeflemektedir. Duygusal YZ (ya da duygu hesaplama) ise makinelerin insan duygularını algılama, yorumlama, simüle etme ve bağlama uygun tepkiler üretebilme yeteneği üzerine odaklanmaktadır.

Bu iki alanın birleşimi, özellikle insan-robot işbirliğinin kritik olduğu sektörlerde önemli avantajlar sunmaktadır. Cobotlar, sağlık hizmetleri, eğitim ve müşteri ilişkileri gibi yüksek düzeyde sosyal etkileşim gerektiren alanlarda, duygusal zekâ ile desteklenmiş bilişsel robotlar kullanıcıların ihtiyaçlarını yalnızca eylemlerine göre değil, aynı zamanda duygusal durumlarına dayalı olarak da değerlendirebilecektir. Bu yetkinlik, robotların daha sezgisel, empatik ve kişiselleştirilmiş hizmetler sunmasını mümkün kılarak insan-makine etkileşimini köklü bir şekilde dönüştürecektir. Bu evrim, sosyal robotlar ve hizmet robotları için kritik öneme sahip olup, makinelerin karmaşık sosyal dinamiklere uyum sağlayabilen, güvenilir ve değer yaratan "ortaklar" haline gelmesini sağlayacaktır (Breazeal, 2002:1).

4. Robotik Cerrahi ve Kişiselleştirilmiş Tedavi

Robotik cerrahi ve kişiselleştirilmiş tedavi, modern tıbbın dönüşümünde merkezi bir rol oynayan ve hasta bakımının kalitesini köklü biçimde artıran iki kritik yenilik alanıdır. Robotik cerrahi, cerrahlara minimal invaziv operasyonlar sırasında yüksek çözünürlüklü görüntüleme, artırılmış hareket kabiliyeti ve üstün hassasiyet sağlayarak insan elinin fiziksel sınırlarını aşma imkânı sunmaktadır. Bu teknolojinin başlıca avantajları arasında daha küçük cerrahi kesiler, daha az kan kaybı, daha kısa hastanede kalış süresi, ameliyat sonrası ağrının azalması ve hastaların günlük yaşamlarına daha hızlı dönebilmesi yer almaktadır.

Buna karşılık kişiselleştirilmiş tedavi (veya hassas tıp), her hastanın genetik profili, yaşam tarzı ve çevresel etkiler gibi bireysel özelliklerine dayalı olarak tanı ve tedavi süreçlerini optimize etmeyi amaçlamaktadır. Bu yaklaşım, doğru tedavinin doğru hastaya doğru zamanda uygulanmasını sağlayarak tedavi etkinliğini maksimize ederken yan etkileri en aza indirir.

Bu iki alanın gelecekteki gelişim yönü, yapay zekâ ve büyük veri analitiği ile güçlü bir biçimde kesişmektedir. Yapay zekâ, robotik sistemlere entegre edilmiş cerrahi planlama algoritmalarıyla operasyonel doğruluğu ve cerrahi performansı artırma potansiyeline sahiptir. Öte yandan kişiselleştirilmiş hasta verileri, robotik cerrahi sistemlerinin belirli bir hastada hangi prosedürün hangi düzeyde hassasiyetle uygulanacağına ilişkin öngörüs el kararlar  retmesini m mk n kılacaktır.

Bu sinerjik b t nleşme, tedavilerin daha  ng r lebilir, daha g venli ve her bir hasta i in bireysel olarak optimize edilmiř h le gelmesine olanak tanıyacak; b ylece modern tıbbın hem klinik sonu larını hem de hasta memnuniyetini belirgin  l  de iyileřtirecektir (Jiang & ark., 2017:1, Yang, 2020:1).

Sonuç

“Robotik Sistemlerde Yapay Zek  Entegrasyonu” bařlıklı bu arařtırma, yapay zek  ile robotik arasındaki etkileřimin, hem end striyel hem de bilimsel paradigmaları yeniden řekillendiren kritik bir teknolojik d n m noktasına iřaret ettiđini a ık bi imde ortaya koymaktadır. Geleneksel robotik sistemler, katı komut setlerine bađlı ve sınırlı uyarlanabilirlikte  alıřırken; yapay zek  ile donatılmıř yeni nesil robotlar, adaptif  đrenme, otonom karar verme ve karmařık  evresel kořulları algılama gibi yetenekler kazanarak ger ek anlamda akıllı sistemlere d n řm řt r (Siciliano, & Khatib, 2016:1, Krizhevsky, Sutskever, & Hinton, 2012:2, Sutton & Barto, 2018:1). Bu d n ř m n temelinde, DRL'nin robotlara deneyime dayalı  đrenme kapasitesi kazandırması, derin  đrenme tabanlı g rsel algı modellerinin y ksek hassasiyetli ve ger ek zamanlı  evresel yorumlama imk nı sunması ve HRC yaklařımlarının insan-makine etkileřimini g venli ve verimli h le getirmesi yatmaktadır (Levine & ark., 2016:1, Ajoudani & ark., 2018:1).

Uçtan uca öğrenme ve Taklitçi Öğrenme yöntemleri, robotların beceri edinim süreçlerini sadeleştirerek programlama yükünü azaltmakta; Robot Etiği ve Güvenliği ise otonom sistemlerin sorumlu bir şekilde geliştirilmesi için gerekli etik, hukuki ve toplumsal çerçevenin önemini vurgulamaktadır (Argall & ark., 2009:1, Topol, 2019:1, Zhang & ark., 2022). Özellikle son dönemde ortaya çıkan Üretken Fiziksel YZ ve robotikte temel model kullanımı gibi yenilikçi yaklaşımlar, robotların daha genel amaçlı görevleri yerine getirme, daha esnek davranış kalıpları sergileme ve doğal dil komutlarını anlayarak yorumlama kapasitesini önemli ölçüde artırmaktadır (Ahn & ark., 2022).

Geleceğe yönelik araştırma alanları, YZ destekli robotik teknolojilerinin yalnızca imalat sektöründe değil; sağlık (örneğin mikrosistemler ve cerrahi robotik), lojistik (akıllı tedarik zincirleri), sosyal robotik ve bilişsel etkileşim gibi kritik sektörlerde de dönüştürücü etkiler yaratacağını göstermektedir (Nelson, Kaliakatsos & Abbott, 2010:1, Wurman, D'Andrea & Mountz, 2008:1, Jiang & ark., 2017). Bununla birlikte, bu hızlı gelişim süreci önemli etik, güvenlik ve toplumsal sorunları da beraberinde getirmektedir (Topol, 2019:2). Algoritmik şeffaflık, veri mahremiyeti, robotların etik karar verebilme kapasitesi ve iş gücüne yönelik potansiyel etkiler, hem araştırma topluluğunun hem de politika yapıcılarının öncelikle ele alması gereken konular olarak öne çıkmaktadır (Topol, 2019:2, LeCun, Bengio & Hinton, 2015:1). Aynı zamanda, robotik teknolojilere yönelik toplumsal algı ve küresel-bölgesel farklılıkların incelenmesi, teknolojik gelişimin kapsayıcı ve adil bir şekilde ilerleyebilmesi açısından kritik önemdedir.

Adaptif yapay zekâ ile güçlendirilmiş robotik sistemlerin sürekli olarak gelişmesi, yalnızca teknik ilerlemeyi değil, bu ilerlemeyi yönlendirecek hukuki ve etik çerçevelerin de eşzamanlı biçimde olgunlaşmasını zorunlu kılmaktadır. Hem Türkiye’de hem de dünya genelinde bu teknolojilere yapılan yatırımlar ve yürütülen

Ar-Ge alıřmaları, lkelerin gelecekteki rekabet gcnn belirleyicileri arasında yer alacaktır. Sonu olarak, robotik sistemlerde yapay zekâ entegrasyonu, geleceęin otomasyon ve akıllı sistemler vizyonunun merkezinde konumlanmakta olup, bu alanda multidisipliner yaklařımlarla desteklenen kapsamlı arařtırma faaliyetlerinin srdrlmesi byk nem tařımaktadır. Yapay zekâ ve robotik arasındaki bu gl sinerji, insanlıęın karřı karřıya olduęu karmařık sorunlara yeniliki zmler retme potansiyeline sahiptir; ancak bu potansiyelin tam olarak hayata geirilebilmesi, teknolojinin sorumlu, etik ve srdrlebilir bir anlayıřla geliřtirilmesine baęlıdır.

Kaynakça/References

3D Robotik Blog. Robotik Sistemlerde Adaptif Yapay Zeka Kullanımı. Link: <https://www.3drobotik.com/tr/medya/blog/robotik-sistemlerde-adaptif-yapay-zeka-kullanimi>

Ahn, J., et al. (2022). Can Generalist Foundation Models Do Better Than Specialists on Robotics Tasks? *arXiv:2210.03849*.

Ajoudani, A., et al. (2018). Human–robot collaboration: A survey of attention allocation strategies. *IEEE Transactions on Robotics*, 34(5), 1182-1202. DOI: 10.1109/TRO.2018.2847684

Argall, B. D., Chernova, S., Veloso, M., & Browning, B. (2009). **A survey of robot learning from demonstration.** *Robotics and Autonomous Systems*, 57(5), 462-472. DOI: 10.1016/j.robot.2008.10.020

Arras, K. O., Stachniss, C., & Burgard, W. (2007). A scalable approach for robot perception based on the Rao-Blackwellized particle filter. *Robotics and Autonomous Systems*, 55(4), 318-333. DOI: 10.1016/j.robot.2006.09.006

Breazeal, C. (2002). Designing sociable robots. MIT Press.

Brooks, R. A. (1991). Intelligence without representation. *Artificial Intelligence*, 47(1-3), 139-159.

Chen, X., et al. (2020). Learning a Decoupled Neural Network for Infrastructure-Robot Collaboration. *IEEE Robotics and Automation Letters*, 5(2), 2419-2426. DOI: 10.1109/LRA.2020.2972986

Draeos, T. J., et al. (2020). A Survey on Deep Learning for Robotic Grasping. *IEEE Transactions on Cybernetics*, 50(7), 3121-3132. DOI: 10.1109/TCYB.2019.2907409

Enorm Technology Blog. Robotik Sistemler ve Yapay Zeka: Endüstriyel Üretimde Yeni Ufuklar. Link:

<https://www.theenorm.com/blog/robotik-sistemler-ve-yapay-zeka-endustriyel-uretimde-yeni-ufuklar>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.

Jiang, F., et al. (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and Vascular Neurology*, 2(1), 1-9. DOI: 10.1136/svn-2017-000027

Kim, Y., & Lee, J. (2019). **Deep reinforcement learning-based path planning for a mobile robot.** *Sensors*, 19(18), 3922. DOI: 10.3390/s19183922

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *NIPS 2012*.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. DOI: 10.1038/nature14539

Levine, S., Finn, C., Darrell, T., & Abbeel, P. (2016). End-to-end training of deep visuomotor policies. *Journal of Machine Learning Research*, 17(39), 1-40.

Nelson, B. J., Kaliakatsos, I. K., & Abbott, J. J. (2010). Microrobots for biomedical applications. *Annual Review of Biomedical Engineering*, 12, 55-85.

Russell, S. J., & Norvig, P. (2020). Artificial Intelligence: A Modern Approach (4th ed.). Pearson.

Shimonishi, K. (2021). **Autonomous mobile robots in logistics.** *International Journal of Automation Technology*, 15(2), 164-173. DOI: 10.20965/ijat.2021.p0164

Siciliano, B., & Khatib, O. (Eds.). (2016). Springer Handbook of Robotics. Springer. DOI: 10.1007/978-3-319-30386-3

Sutton, R. S., & Barto, A. G. (2018). Reinforcement Learning: An Introduction (2nd ed.). MIT Press.

Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44-56. DOI: 10.1038/s41591-018-0300-7

Universal Robots Blog. Yapay Zeka ile Robot Teknolojisinde Büyük Dönüşüm. Link: <https://www.universal-robots.com/tr/blog/yapay-zeka-ile-robot-teknolojisinde-buyuk-donusum/>

Webtures. **Üretim Sektöründe Yapay Zeka Entegrasyonu.** Link: <https://www.webtures.com/tr/blog/uretim-sektorunde-yapay-zeka-entegrasyonu/>

Wurman, P. R., D'Andrea, R., & Mountz, M. (2008). Coordinating hundreds of cooperative, autonomous vehicles in an industrial setting. *IEEE Robotics & Automation Magazine*, 15(1), 29-39. DOI: 10.1109/MRA.2008.916301

Xpert.Digital. Üretken Fiziksel Yapay Zeka ve Robotlar İçin Temel Modeller. Link: <https://xpert.digital/tr/uretken-fiziksel-yapay-zeka/>

Yang, G. Z. (2020). **Future of surgery: AI, robotics, augmented reality, sensing, and beyond.** *Annals of Surgery*, 271(4), 589-591. DOI: 10.1097/SLA.0000000000000366

Zhang, J., et al. (2022). **Deep Learning for Human-Robot Collaboration: A Review of Algorithms and Applications.** *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 52(1), 163-176. DOI: 10.1109/TSMC.2022.3025064

