

**MÜHENDİSLİK BİLİMLERİNDE GÜNCEL ARAŞTIRMALAR VE
DİSİPLİNLERARASI UYGULAMALAR
CURRENT RESEARCH IN ENGINEERING SCIENCES AND
INTERDISCIPLINARY APPLICATIONS**


EDİTÖRLER

Doç. Dr. Emrehan YAVŞAN
Dr. Erhan KAHYA
Öğr. Gör. Mehmet Ali ŞİMŞEK

YAZARLAR

Prof. Dr. Reşat MUTLU
Prof. Dr. Uğur AKYOL
Doç. Dr. Ertuğrul KARAKULAK
Doç. Dr. Soner ÇELEN
Dr. Öğr. Üyesi Murat IŞIK
Dr. Öğr. Üyesi Mehmet Ali YALÇINKAYA
Dr. Öğr. Üyesi Erdal KILIÇ
Dr. Öğr. Üyesi Enes EFE
Dr. Öğr. Üyesi Rabia KORKMAZ TAN
Dr. Öğr. Üyesi Halil Nusret BULUŞ
Dr. Öğr. Üyesi Cemal POLAT
Dr. Fatma Funda ÖZDÜVEN
Dr. Erhan KAHYA
Dr. Nadir SUBAŞI
Dr. Mümine YILDIZ
Dr. Çetin YAĞCILAR
Öğr. Gör. Ersoy MEVSİM
Hasan KARAYAKA

DOI: <https://dx.doi.org/10.5281/zenodo.14252011>



Copyright © 2024 by iksad publishing house
All rights reserved. No part of this publication may be reproduced, distributed or
transmitted in any form or by
any means, including photocopying, recording or other electronic or mechanical
methods, without the prior written permission of the publisher, except in the case of
brief quotations embodied in critical reviews and certain other noncommercial uses
permitted by copyright law. Institution of Economic Development and Social

Researches Publications®

(The Licence Number of Publicator: 2014/31220)

TÜRKİYE TR: +90 342 606 06 75

USA: +1 631 685 0 853

E mail: iksadyayinevi@gmail.com

www.iksadyayinevi.com

It is responsibility of the author to abide by the publishing ethics rules.

Iksad Publications – 2024©

ISBN: 978-625-367-960-6

Cover Design: İbrahim KAYA

December / 2024

Ankara / Türkiye

Size = 16x24 cm

İÇİNDEKİLER

ÖNSÖZ.....1

CHAPTER 1

PREDICTION OF TEMPERATURE VALUES IN A HOT PRESSURIZED AIR DRYING SYSTEM USING ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM

Assist. Prof. Dr. Halil Nusret BULUŞ

Prof. Dr. Uğur AKYOL

Assoc. Prof. Dr. Soner ÇELEN.....3

CHAPTER 2

ANN-BASED PREY AND PREDATOR POPULATION PREDICTIONS FOR CANADIAN SNOWSHOE HARE AND LYNEX POPULATIONS

Assist. Prof. Dr. Rabia Korkmaz TAN

Prof. Dr. Reşat MUTLU.....23

BÖLÜM 3

İSTANBUL'DA SU TÜKETİMİ VE YAĞIŞ TAHMİNİ: YAPAY ZEKA YAKLAŞIMI

Dr. Öğr. Üyesi Enes EFE.....57

BÖLÜM 4

KURUMSAL BİLGİ GÜVENLİĞİ İÇİN ÇOK KATMANLI BİR GÜVENLİK YAPISI TASARIMI

Dr. Öğr. Üyesi Mehmet Ali YALÇINKAYA.....83

BÖLÜM 5

DERİN ÖĞRENME VE TARIMSAL UYGULAMALAR

Dr. Erhan KAHYA

Dr. Fatma Funda ÖZDÜVEN.....127

BÖLÜM 6

MİKRODENETLEYİCİ TABANLI OTOMOBİL ENJEKTÖRÜ AÇIK KALMA SÜRESİ ÖLÇME SİSTEMİ

Dr. Öğr. Üyesi Erdal KILIÇ

Öğr. Gör. Ersoy MEVSİM

Doç. Dr. Ertuğrul KARAKULAK.....163

BÖLÜM 7

BÜYÜK DİL MODELLERİNİN MÜHENDİSLİKTEKİ ROLÜ

Dr. Öğr. Üyesi Murat IŞIK.....179

BÖLÜM 8

AÇIKLANABİLİR AI (XAI): GÜVEN, HESAP VEREBİLİRLİK VE ETİK YAKLAŞIMLAR

Dr. Nadir SUBAŞI.....207

BÖLÜM 9

ÇOKLU SENSÖR ODOMETRİ VERİSİNİN FÜZYONU: GENİŞLETİLMİŞ KALMAN FİLTRESİ İLE FÜZYON VE PERFORMANS KARŞILAŞTIRMASI

Hasan KARAYAKA

Dr. Mümine YILDIZ.....225

BÖLÜM 10

MİKROALG ÜRETİMİNDE SÜRDÜRÜLEBİLİR ENDÜSTRİYEL UYGULAMALARIN İNCELENMESİ

Dr. Çetin YAĞCILAR

Dr. Öğr. Üyesi Cemal POLAT.....249

ÖNSÖZ

Bu kitap, günümüzün dinamik ve çok disiplinli alanlarından biri olan yapay zeka ve mühendislik uygulamalarına dair güncel bilgiler sunmaktadır. İçinde bulunduğumuz dijital çağda, teknolojinin hızla gelişmesi, çeşitli sektörlerde yenilikçi çözümler ve uygulamalar geliştirilmesini zorunlu kılar. Bu bağlamda, kitapta yer alan bölümler, hem teorik hem de pratik açıdan literatüre önemli katkılar sağlamaktadır.

İlk bölümde, sıcak basınçlı bir hava kurutma sisteminde sıcaklık değerlerinin tahmin edilmesi için Adaptif Nöral-Ağlı Bulanık Çıkarım Sisteminin kullanımı ele alınmaktadır. Bu çalışmanın ardından ikinci bölümde, bir av ve avcı popülasyonunun tahmin edilmesi için Yapay Sınır Ağı (YSA) tabanlı bir yaklaşım önerilmektedir. Önerilen YSA tabanlı yaklaşımın tahmin performansının, Lotka-Volterra denklemlerinden daha yüksek olduğu gösterilmektedir.

İstanbul'da su tüketimi ve yağış tahmini üzerine yapay zeka yaklaşımlarının incelendiği üçüncü bölüm, şehirlerin su yönetimi stratejilerine ışık tutmaktadır. Dördüncü bölümde kurumsal bilgi güvenliği için çok katmanlı bir güvenlik yapısı tasarımıyla günümüzün siber tehditlerine karşı etkili bir savunma mekanizmasının geliştirmesi ihtiyacı vurgulanmaktadır.

Derin öğrenmenin tarımsal uygulamalardaki rolünün incelendiği bölümde, tarım sektöründe verimliliği artırmak için yenilikçi yöntemlerin kullanımları sunulmaktadır. Altıncı bölümde mikrodenetleyici tabanlı bir sistemle otomobil enjektörünün açık kalma süresi ölçülmektedir.

Büyük dil modellerinin mühendislikteki rolü başlığı altında dil işleme teknolojilerinin mühendislik uygulamalarına entegrasyonu ve sağladığı avantajlar ele alınmaktadır. Sekizinci bölümde; güven, hesap verebilirlik ve etik perspektiflerinden açıklanabilir yapay zeka (XAI) üzerine yapılan tartışmalar derinlemesine incelenmektedir.

Dokuzuncu bölüm, çeşitli algılayıcılardan elde edilen odometri verisinin genişletilmiş kalman filtresiyle füzyon ve performans karşılaştırmasını analiz etmektedir. Kitabın son bölümünde mikroalg üretiminde sürdürülebilir endüstriyel uygulamalar incelenmektedir. Böylece çevresel sürdürülebilirliğe katkı sağlanmaktadır.

Bu kitap, alanında uzman yazarların katkılarıyla zenginleştirilmiş olup, okuyuculara güncel bilgiler ve yenilikçi yaklaşımlar sunmayı amaçlamaktadır. Bilimsel araştırmaların ve uygulamaların bir araya geldiği bu eser, hem akademik hem de endüstriyel pratikler için değerli bir kaynak olmayı hedeflemektedir.

EDİTÖRLER

Doç. Dr. Emrehan YAVŞAN

Dr. Erhan KAHYA

Öğr. Gör. Mehmet Ali ŞİMŞEK

CHAPTER 1

PREDICTION OF TEMPERATURE VALUES IN A HOT PRESSURIZED AIR DRYING SYSTEM USING ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM

Assist. Prof. Dr. Halil Nusret BULUŞ¹

Prof. Dr. Uğur AKYOL²

Assoc. Prof. Dr. Soner ÇELEN^{3*}

Corresponding Author: Soner ÇELEN

¹ Tekirdağ Namık Kemal Üniversitesi, Çorlu Mühendislik Fakültesi, Tekirdağ. Türkiye, nbulus@nku.edu.tr, ORCID ID: 0000-0003-1844-6484

² Tekirdağ Namık Kemal Üniversitesi, Çorlu Mühendislik Fakültesi, Tekirdağ. Türkiye, uakyol@nku.edu.tr, ORCID ID: 0000-0003-3707-0929

³ Tekirdağ Namık Kemal Üniversitesi, Çorlu Mühendislik Fakültesi, Tekirdağ. Türkiye, scelen@nku.edu.tr, ORCID ID: 0000-0001-5254-4411

Introduction

Among the yarn dyeing methods, dyeing in the bobbin is known as the most commonly used method. Bobbin dyeing is the most suitable and economical method for obtaining colored yarns (Mahmudova, 2018).

In the textile industry, drying is a lengthy and energy-demanding process that heavily influences the overall cost of textile finishing. As a result, exploring innovative methods is essential for minimizing energy usage, reducing expenses, and mitigating environmental impacts (Galoppi et al., 2017).

The drying of bobbin yarn is a process involving heat and mass transfer. Due to factors such as the structure of the drying equipment, yarn type, dye type, and the winding state of the yarn, the drying quality may be affected, and different processes need to be applied depending on the specific conditions.

The shorter the drying time of the yarn, the less energy is consumed, resulting in reduced costs. However, the drying time is closely related to the drying temperature. The higher the temperature, the faster the evaporation rate and the shorter the duration. Due to the different thermal properties of various fibers, the temperature at each stage of drying also varies. Beyond a certain threshold, overdrying will occur, leading to structural changes in the fiber material. Overdrying affects the breaking strength and elongation of the fibers, resulting in a hard, brittle texture and a yellowing effect. Dust may also form during the winding process. Overdrying can cause dye migration in yarns dyed with direct dyes. Selecting the appropriate drying temperature and duration based on the fiber type and winding state of the bobbin yarn is

a crucial step in preventing overdrying. Vacuum dryers are prone to causing overdrying

Among the research focused on textile bobbin drying: Galoppi et al. (2017) conducted an experimental analysis of the cotton yarn bobbin drying process. They developed a test setup modeled on the geometry of industrial dryers and assessed the impact of drying air pathways and operating conditions by performing tests under various configurations, temperatures, and pressures. Similarly, Akyol et al. (2010) investigated the thermo-physical properties of wool yarn bobbins during convective drying, utilizing an inverse method for their measurements. One of the studies on drying with pressurized hot air was carried out by Karakoca (2017). In this study, pressurized hot air was passed through dyed wool yarn bobbins and the mathematical modeling of this system was carried out. The model transformed the drying process into a nonlinear heat transfer problem. The finite difference method is the method used to solve the model. Another study on drying wool yarn bobbins with pressurized hot air was carried out by Ribeiro and Ventura (1995). This study was an experimental study. Akyol et al. (2011) assessed the influence of thermodynamic conditions on wool bobbin drying, highlighting the substantial effect of air pressure and demonstrating that the process could be described using a logarithmic model. Later, Akyol et al. (2013) identified the optimal operating conditions, showing how drying temperature, pressure, and mass flow rate affect both drying time and energy consumption. Toraman (2010) simulated the drying behavior of wool yarn bobbins under different drying conditions using existing empirical and semi-empirical drying models available in the literature.

In a study by Akal et al. (2017), analyses were performed for different bobbin diameters, and an appropriate numerical model was found to simulate the drying behavior.

In recent years, machine learning methods have been widely used in modeling and prediction fields. These methods maintain their importance with applications in many fields. Predictive values obtained from mathematical models give very successful results. Among these methods, the Adaptive Neuro-Fuzzy Inference System (ANFIS) is one of the methods that achieves successful results, especially in modeling systems and obtaining predictions (Moralar, 2024).

ANFIS combines the principles of fuzzy logic and artificial neural networks, enabling it to be trained with known or target values and used to estimate unknown values. In recent years, it has become a popular tool for solving nonlinear problems, showing notable success in identifying relationships between input and output variables (Turan et al., 2015). ANFIS, short for Adaptive Neuro-Fuzzy Inference System, consists of software designed specifically to train and optimize input and output data. It uses a backpropagation gradient descent and least squares approach to ensure that the given inputs best match the corresponding outputs (Onur et al., 2016). The structure of ANFIS involves representing a network structure equipped with the neural learning capabilities of Sugeno-type fuzzy systems. ANFIS integrates both artificial neural networks and fuzzy logic into its framework (Köse et al., 2011).

This study aims to run simulations to reduce the time and energy costs of performing laboratory experiments. In this case, the optimum parameters for drying processes will be found by minimizing these costs.

Experimentally obtained wool yarn bobbin drying parameters were used in the creation of these models. The ANFIS method, one of the artificial intelligence methods, was used in the development of the model and the drying parameters were obtained as a result of this method. To achieve this, the estimated temperature values in certain areas of the drying system were determined.

ANFIS

One prominent soft computing technique for accurately modeling input-output matrix relationships is the ANFIS. Neuro-Fuzzy Systems combine Neural Networks and Fuzzy Logic. ANFIS, introduced by Jang in 1993, derives from neuro-fuzzy systems, which are a subset of fuzzy systems trained with learning algorithms. The term "adaptive" refers to its ability to update its parameters by processing data samples, thereby improving the representation of input data (Habashy and Lebda, 2022).

An adaptive network is a multilayer feed-forward network where nodes are connected by directed links, with each node performing a specific function on its incoming signals to generate a single output. Unlike conventional networks, the links in an adaptive network do not have associated weights. Instead, the node functions are parameterized and can be modified, allowing the adjustment of these parameters to alter the node functions and, consequently, the overall behavior of the network (Walia et al., 2015).

ANFIS is a type of neural network based on the Takagi-Sugeno fuzzy inference system, which is widely used in hydrological processes. Originally developed by Jang in 1993, ANFIS utilizes the first-order Sugeno fuzzy model. It typically employs either back-propagation or a

combination of back-propagation and least squares estimation to predict membership function parameters. The integration of neural networks with fuzzy systems enhances the learning capability of the network while benefiting the fuzzy system's flexibility. ANFIS uses the Takagi-Sugeno fuzzy inference system, where each rule's output can be either a constant or a linear combination of input variables plus a constant term. The final output is the weighted average of all rule outputs. The basic architecture of ANFIS, which includes two inputs (x, y) and one output (z), is illustrated in Figure 1 (Sonmez et al., 2018; Ali et al., 2019).

Rule 1: If x is A_1 and y is B_1 ; then $f=p_1x+q_1y+r_1$

Rule 2: If x is A_2 and y is B_2 ; then $f=p_2x+q_2y+r_2$

where A_1, A_2, B_1 and B_2 are nonlinear parameters while p_1, p_2, q_1, q_2, r_1 and r_2 are linear parameters.

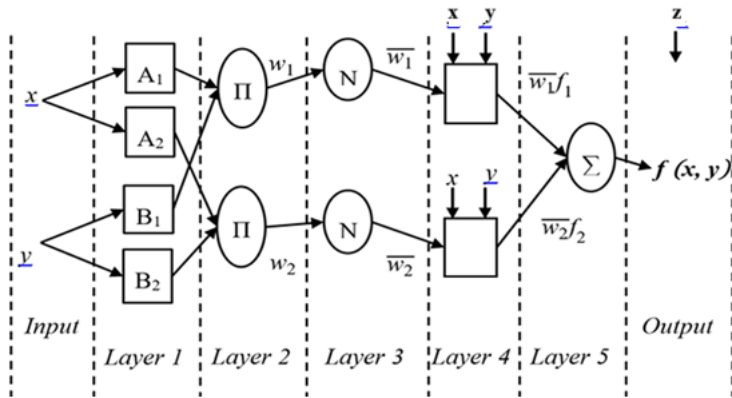


Figure 1. The architecture of ANFIS model

For simplicity, the fuzzy inference system considers two inputs, x and y , and one output, f . A brief overview of the five layers in the ANFIS algorithm is provided below. (Sonmez et al., 2018; Habashy and Lebda, 2022; Walia et al., 2015).

Layer 1 is known as the fuzzification layer, where input values are processed. In this layer, the input x is fed into nodes A_1 and B_1 , while the input y is provided to nodes A_2 and B_2 . In fuzzy theory, A_1 , A_2 , B_1 , and B_2 represent linguistic labels, which are used to assign appropriate membership functions to the inputs. These membership functions map the inputs to their respective fuzzy sets, initiating the process of converting crisp values into fuzzy values. The output of the i^{th} node in layer 1 is denoted by $O_{1,i}$. Each adaptive node is represented as a square node, where the function of the square is expressed by Eq. (1) and (2):

$$O_{1,i} = \mu_{1A_i}(x), \quad i=1,2 \quad (1)$$

$$O_{1,i} = \mu_{1B_i}(y), \quad i=3,4 \quad (2)$$

where $O_{1,i}$ and $O_{1,j}$ represent the output functions, and $\mu_{x,i}$ and $\mu_{y,j}$ refer to the membership functions. For example, if a triangular membership function is chosen, $\mu_{x,i}(x)$ is defined as:

Layer 2 is responsible for calculating the firing strengths of the rules, which is why it is referred to as the rule layer. This layer, also called the product layer, contains two fixed nodes labeled with Π . The outputs from this layer are w_1 and w_2 , which represent the weight functions of **Layer 3**, and the product of the input signals can be expressed as Eq. (3):

$$O_{2,i} = w_i = \mu_{A_i}(x) * \mu_{B_i}(y), \quad i=1,2 \quad (3)$$

The task of **Layer 3** is to normalize the firing strengths by dividing each value by the total firing strength. This layer, known as the normalized layer, contains two fixed nodes labeled with N . The outputs of this layer are \bar{w}_1 and \bar{w}_2 , representing the normalized firing strengths.

Hence, this layer is often referred to as the normalizing layer. The output of **Layer 3** can be expressed using Eq. (4).

$$O_{3,i} = \overline{w}_i = \frac{w_i}{w_1 + w_2}, \quad i=1,2 \quad (4)$$

Layer 4 is the defuzzification layer, consisting of two adaptive nodes. In this layer, the relationship between the inputs and the output is determined, and it can be represented by Eq. (5).

$$O_{4,i} = \overline{w}_i f_i = \overline{w}_i (p_i x + q_i y + r_i), \quad i=1,2 \quad (5)$$

where \overline{w}_i is the output of the third layer, and p_i , q_i and r_i are the consequent parameters.

The defuzzification values are returned by this layer, which is then passed on to the final layer, the summation layer, to generate the final output. Layer 5 is the output layer which includes a fixed node labeled with \sum . The real output of ANFIS is obtained by adding the outputs obtained for each rule in the defuzzification layer. The model's overall output is given by Eq. (6).

$$O_{4,i} = \sum_i \overline{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}, \quad i=1,2 \quad (6)$$

Modeling the Yarn Bobbin Drying Process

Experimental Setup

The experimental setup in Figure 1 was set up in Tekirdağ Namık Kemal University Mechanical Engineering Laboratory. With this setup, wool yarn bobbins were dried with hot air. In order to dry from inside to outside by creating a pressure difference, pressurized hot air was passed through the bobbins. Three different temperatures (80°C, 90°C and

100°C) and a pressure value (3 bar) were used in the experiments. All bobbins were selected as standard with an inner diameter of 35 mm and a length of 150 mm. Polyethylene bobbins designed with holes were used to allow air flow.



Figure 2. Experimental Setup (Toraman, 2011)

Thermocouples

Thermocouples are widely used devices in industry for measuring temperature. They are composed of two different metals welded together to form a temperature measurement element. The welded end, known as the hot junction, measures temperature, while the two other exposed ends serve as the cold junction. When the hot junction is exposed to heat, a voltage is generated due to the temperature difference between the hot and cold junctions. This voltage, typically in the millivolt range, is used to calculate the temperature. Thermocouples find broad application across various industrial sectors (Figure 3).



Figure 3. Thermocouples (Toraman, 2011)

The experiments were conducted using an experimental hot air bobbin dryer designed and produced based on hot air bobbin dryers used in the textile industry. In the experimental setup, the temperatures at various points of the bobbins were measured using thermocouples placed inside the bobbins (Cihat et al., 2011).

Statistical analysis

Once ANFIS is trained using a training algorithm to extract knowledge from the provided data, it can be employed to either predict unknown input variables or rank the input variables based on their influence on the output. To enhance the model's performance, various key parameters were tested through a trial-and-error method. The accuracy of the model was ultimately evaluated by selecting the output with the smallest estimation error, measured using the coefficient of determination (R^2), Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), and Mean Bias Error (MBE) (Eqs. 7-10) (Bakar et al., 2022; Buluş et al., 2023).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (0 \leq R^2 \leq 1) \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (0 \leq RMSE \leq +\infty) \quad (8)$$

$$MBE = 1/n \sum_{i=1}^n (y_i - \hat{y}_i) \quad (-1 \leq MBE \leq +1) \quad (9)$$

$$MAPE = \frac{100}{n} \sum_j^n \frac{|e_j|}{|A_j|} \quad (10)$$

ANFIS creates a model that must be tested to confirm it meets the desired criteria. This validation process assesses how effectively ANFIS has modeled the system by comparing outputs from the training data with those from a separate, non-training data set. The discrepancy between these outputs is quantified by the RMSE, which indicates the model's performance. A lower RMSE value reflects a more accurate model (Solichin et al., 2021).

ANFIS Model Analysis

The development, training, and testing of the ANFIS model were conducted using the MATLAB software package. MATLAB offers a robust simulation and testing platform for this purpose, enabling easy manipulation of the model's variables and parameters. As a result, it provides a comprehensive graphical representation of parameters and performance (Habashy and Lebda, 2022).

ANFIS training involves the use of both the gradient descent method and the least squares method. The training algorithms provided in the MATLAB fuzzy inference toolbox streamline data processing by offering training and forecasting functions. The main computational process of ANFIS consists of four stages. The first stage is data input,

while the second stage involves assigning fuzzy sets (Sonmez et al., 2018).

Figure 3 illustrates the following inputs and output:

- Input: Time (T)
- Input: Chamber Inlet Temperature (CIT)
- Input: Chamber Internal Temperature (CINT)
- Input: Chamber Outlet Temperature (COT)
- Input: Separator Outlet Temperature (SOT)
- Input: Fan Outlet Temperature (FOT)
- Output: Product Mass (PM).

The Takagi-Sugeno ANFIS model was also utilized to predict mass of yarn bobbin (M) using the Fuzzy Logic Toolbox in MATLAB (The MathWorks Inc., Natick, Massachusetts, USA).

Figure 3 displays the training and test data used in the ANFIS model for M. In these graphs, the data represented by circles correspond to the training data, while the data indicated by dots represent the test data.




Figure 4. Training and test dataset for M

An ANFIS model with 7 inputs and 1 output was trained over 100 iterations. Figure 4 displays the training and testing data, while Figure 4 illustrates the training error. This allows for an assessment of the proximity between the experimental and predicted values.

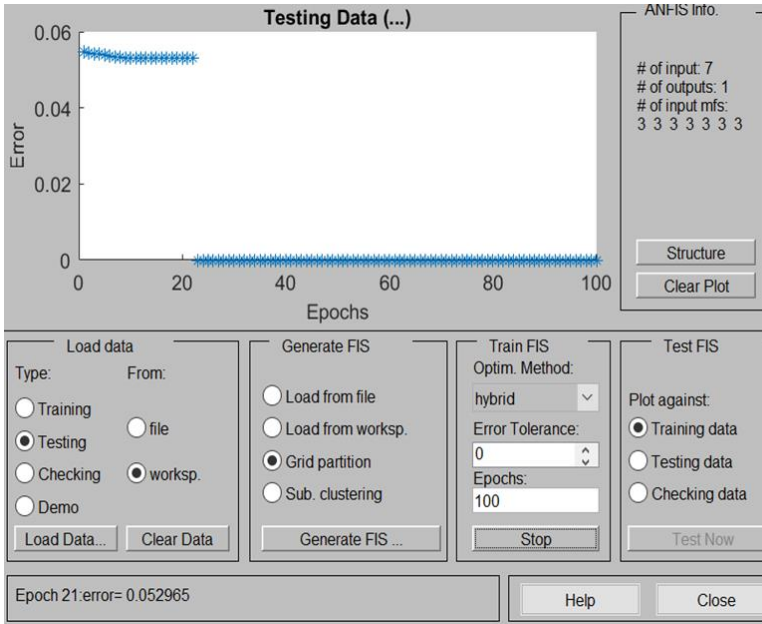


Figure 5. M prediction error rate for ANFIS

The number of rules to be created in an ANFIS system is found by the Eq. 11. Here NR: the number of rules, NI: the number of inputs and NMF: the number of membership functions used in the input layer.

$$NR = NMF^{NI} \quad (11)$$

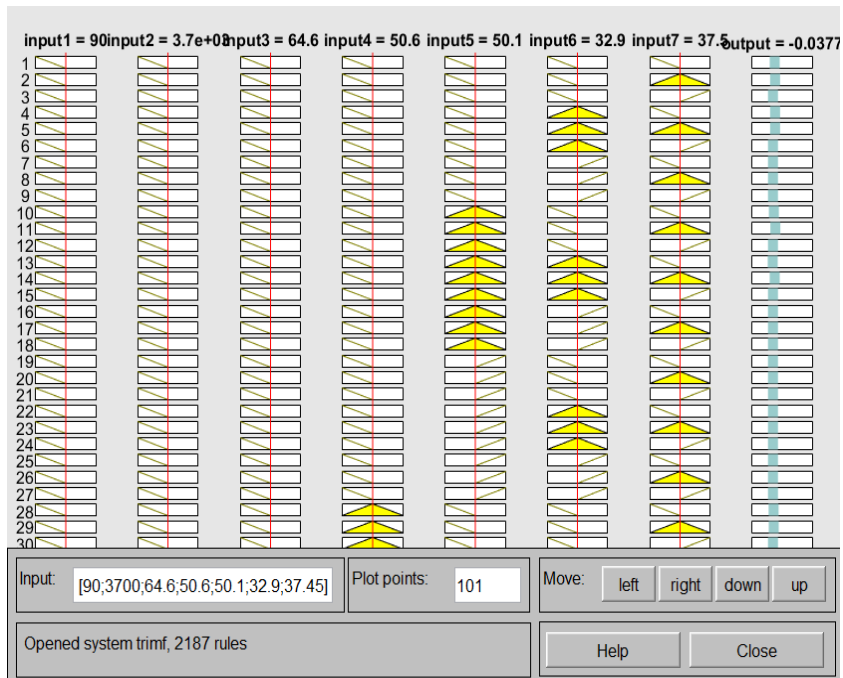


Figure 6. Rules created for model of M

Figure 6 shows part of the set of rules calculated according to equation 10. The part of 2187 rules of the developed models, intended for use in predictions, are displayed.

In the model, the triangular membership function was used as the input membership function. The model was trained with 2187 rules and the number of training epochs was determined as 100. As seen in Figure 6, after approximately 10 epochs, the error value produced by the network was fixed at 0.052965. No change in the error value was observed in the subsequent steps of the training.

The training data comprised 80% of the dataset (1576 data), while 20% (394 data) was allocated for testing in the ANFIS model. The relationships between input and output variables, defined by 2187 rules, are illustrated in Figure 5. The ANFIS model demonstrated a high

correlation coefficient, for training and testing. The performance of these models was evaluated for both training and testing phases. Table 1 presents metrics including the Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), Mean Bias Error (MBE) and Coefficient of Determination (R^2).

Table 1. Correlation values of training and test dataset

Training	RMSE	0,052989
	MAPE	0,460792
	R^2	0,999932
	MBE	-0,000557
Test	RMSE	0,048380
	MAPE	0,468077
	R^2	0,999943
	MBE	0,000369
All	RMSE	0,052100
	MAPE	0,462249
	R^2	0,999934
	MBE	-0,000372

Multiple adjustments were made with different parameters to optimize the ANFIS model for predicting M. The R^2 , MAPE, MBE and RMSE values have been calculated for these four outputs. Table 1 gives the calculations of R^2 , MBE, MAPE and RMSE values.

The goal is to achieve an R^2 value as close to 1 as possible, along with RMSE and MAPE values approaching zero. For R^2 , the values ranging from 0.999932 to 0.999943 for the ANN model indicates a very

high degree of correlation. A MAPE value of less than 0.10 denotes highly accurate predictions, between 0.10 and 0.20 reflects good predictions, between 0.20 and 0.50 suggests reasonable predictions, and a MAPE value greater than 0.50 indicates low accuracy (Kacar and Korkmaz, 2022; Buluş, 2024). As shown in Table 1, the MAPE values reflect both good and reasonable levels of prediction. Additionally, the RMSE values, which range between 0.048380 and 0.052989, being close to zero, further validate the accuracy of the models. Additionally, in an ideal situation, MBE should be close to zero. This indicates that there is no systematic bias in the model's predictions, and that the predictions are generally linear. If the MBE value is positive, the model is overestimating; if it is negative, the model is underpredicting.

CONCLUSIONS

In this study, we predicted certain temperatures within the system and the mass of the yarn bobbin during the drying process at 3 bar pressure and temperatures of 80°C, 90°C, and 100°C using an ANFIS model. The ANFIS model, which consists of 27 rules, provided accurate results using 2.187 data inputs, with 80% (1.576 data points) allocated for training and 20% (394 data points) for testing. The statistical results for RMSE, MAPE, R^2 , and MBE were 0.0048380, 0.468077, 0.999943, and 0.000369, respectively, indicating the accuracy of the test. The primary goal of these predictive models is to reduce the number of tests required in future drying processes. Additionally, it will facilitate the prediction of various other parameters within the drying system.

References

- Mahmudova, Nigar. (2018). A Study On Improving The Quality Of The Bobbin Dyeing And Reducing Yarn Waste, *Journal Of Awareness*, 3(3).
- Galoppi, G., Ferrari, L., Ferrara, G. and Carnevale, E.A. (2017). Experimental investigation on industrial drying process of cotton yarn bobbins: energy consumption and drying time, *Energy Procedia* 126 (201709) 361–368.
- Anonymous (2024). Accessed from: <http://m.tr.jshzdm.com/info/factors-affecting-drying-quality-bobbin-yarn-88711465.html>
- Ribeiro, J. and Ventura, J.M.P. (1995). Evaluation of textile bobbins drying processes: experimental and modeling studies. *Drying Technology*, 13(1-2), 239-265.
- Cihan, A., Kahveci, K., Akyol, U. and Akal, D. (2011). Drying Behavior of Polyester Based Yarn Bobbins in a Hot-Air Bobbin Dryer, *Defect and Diffusion Forum*, Vols: 312-315, 848-853.
- Akyol, U., Cihan, A., Shaliyev, R. (2010). Thermophysical parameter estimation of a wool bobbin during convective drying process. *Inverse Problems in Science and Engineering*, 18(2), 227-240.
- Akyol, E., Akyol, U., Hacıhafızoglu, O., Kahveci, K. and Cihan, A. (2011). Effect of drying air pressure on wool bobbin drying process”. Proceedings of the 9th IASME/WSEAS international conference on heat transfer, thermal engineering and environment, 444-447, Florence (Italy).
- Akyol, U., Kahveci, K. and Cihan, A. (2013). Determination of optimum operating conditions and simulation of drying in a textile drying process”. *Journal of The Textile Institute*, 2013, 104(2), 170-177.
- Akal, D., Kahveci, K., Akyol, U. and Cihan, A. (2017). Drying kinetics of cotton based yarn bobbins in a pressurized hot-air convective dryer. *Journal of Process Mechanical Engineering*, 231(2).
- Karakoca, A. (2017). Determination Of Temperature Field For Drying Process Of Yarn Bobbins Using Finite Difference Method, MSc. Thesis, Namık Kemal University.
- Toraman, S. (2010). Experimental Investigation Of Drying Behavior Of Wool Bobbins, MSc. Thesis, Namık Kemal University.

- Moralari, A. (2024). Modeling Drying Process Parameters for Petroleum Drilling Sludge with ANN and ANFIS, *Processes*, 12, 1948.
- Bulus, H.N. (2024). Adaptive Neuro-Fuzzy Inference System and Artificial Neural Network Models for Predicting Time-Dependent Moisture Levels in Hazelnut Shells (*Corylus avellana* L.) and Prina (*Olea europaea* L.), *Processes*, 12, 1703.
- Turan, E.; Gençođlu, M.T.; Karabiber, A. The calculation of surface leakage currents on the high voltage insulators by using ANFIS method. *Turk. J. Nat. Sci.* 2015, 4, 16–20.
- Onur, F., Ergun, B. and Şahin, C. (2016) Water level prediction with fuzzy logic in dam pond. VI. UZAL-CBS. 5-7 October, Adana, Türkiye.
- Köse, İ.İ., Şencan Şahin, A. and Selbaş, R. (2011) R 413A sođutucu akişkanin termofiziksel özelliklerinin (ANFIS) modeliyle belirlenmesi. National Air Conditioning Congress, November 18-20, Antalya, Türkiye (in Turkish).
- Walia, N., Singh, H. and Sharma, A. (2015). ANFIS: Adaptive Neuro-Fuzzy Inference System- A Survey, *International Journal of Computer Applications*, 123(13), 32-38.
- Jang, J-S.R. (1993). ANFIS Adaptive-Network-based Fuzzy Inference System, *IEEE Transactions on Systems Man and Cybernetics* 23(3):665 – 685.
- Buluş, H.N., Moralari, A. and Çelen, S. (2023). Modeling Of The Moisture Content And Drying Rate Of The Zucchini (*Cucurbita Pepo* L.) In A Solar Hybrid Dryer With Ann And Anfis Methods, *Philippine Agricultural Scientist (PAS)*, 106 (3), 293-305,
- Habashy, D.M. and Lebda, H.I. (2022). Comparison between Artificial Neural Network and Adaptive Neuro-Fuzzy Inference System For The Baryon-to-Meson Ratios in Proton-Proton Collisions.
- Sonmez, A.Y., Kale, S., Ozdemir, R.C. and Kadak, A.E. (2018). An Adaptive Neuro-Fuzzy Inference System (ANFIS) to Predict of Cadmium (Cd) Concentrations in the Filyos River, Turkey, *Turkish Journal of Fisheries and Aquatic Sciences* 18:1333-1343.
- Ali, N.S., Mohd-Yusof, K., Othman, M.F., Latip, R.A. and Ismail, M.S.N. (2019). Adaptive Neuro Fuzzy Inference System (ANFIS) modelling for quality

- estimation in palm oil refining process, *Journal of Mechanical Engineering*, 8(1), 36-47.
- Bakar, M.A.A., Ghani, A.T.A, Abdullah, M.L., Ismail, N. and Aziz, A.S. (2022). Adaptive Neuro-Fuzzy Inference system (ANFIS) Formulation to Predict Students' Neuroscience Mechanistic: A Concept of an Intelligent Model to Enhance Mathematics Learning Ability, *TEM Journal*, 11(4), 1942-1951.
- Solichin, A. and Saputri, F.H. (2021).An Adaptive Neuro-Fuzzy Inference System (ANFIS) Method for Recommending Employee Mutations in a Manufacturing Company, *J. Phys.: Conf. Ser.* 1908 012016.
- Kacar, İ. and Korkmaz, C. (2022). Prediction of agricultural drying using multi-layer perceptron network, long short-term memory network and regression methods, *GUJS* 12(4): 1188-1206.

CHAPTER 2

ANN-BASED PREY AND PREDATOR POPULATION PREDICTIONS FOR CANADIAN SNOWSHOE HARE AND LYNEX POPULATIONS

¹Assist. Prof. Dr. Rabia Korkmaz TAN

²Prof. Dr. Reşat MUTLU

¹Tekirdağ Namık Kemal University, Çorlu Engineering Faculty, Computer Engineering Department, Tekirdağ, Turkey, 0000-0002-3777-2536, rkorkmaz@nku.edu.tr

²Tekirdağ Namık Kemal University, Çorlu Engineering Faculty, Electronics and Communication Engineering Department, Tekirdağ, Turkey, 0000-0003-0030-7136, rmutlu@nku.edu.tr

1. Introduction

The Lotka-Volterra Model (Lotka, 1926) was the first model of a Predator-Prey Model. This model investigates the interaction of at least two living things in their shared environment. As a result of this interaction, the species known as the Predator survives by preying on other living things known as prey. The model has some parameters which govern the birth and death rates of these creatures. The model has been studied in a variety of areas, including complex system behavior, loss of stability over time, and limit cycles exhibiting structural stability (Gléria et al., 2001). There are some stability issues with the model (Gléria et al., 2001) since it is not a model that accurately reflects reality. The first Predator-Prey model was created using shark (predator) and fish (prey) species to calculate population densities (Volterra, 1926). Lotka-Volterra model has inspired many studies and serves as the foundation of the ecological process. Its characteristics such as limit cycles, Hopf bifurcations, and chaotic behavior have been observed (Han and Liu, 2011; Ruan, 2009). Kerner (Kerner, 1964) has demonstrated that the Lotka-Volterra model (LVM) accepts the Liouville theorem and a universal integral of motion. Goel, Maitra, and Montroll (Goel et al., 1971) investigated such interacting population models as an extension of Kerner's work. The parameters specifying the dynamic system in the Lotka-Volterra type model, on the other hand, are given on the basis of groups rather than individuals. Kimura (Kimura and Weiss, 1964) developed 'the stepping stone model' method in population genetics to investigate the reduction of genetic correlation with distance in a geographically structured population. While Boshan and Jiejie (Chen and

Chen, 2012) examined the structure of a rate-dependent dynamic predator-prey model discretized using the Euler method and the Central Multilayer Space Theorem for difference equations, Zhang and Boshan (Zhang et al., 2014) investigated the biological and economic systems of the discrete-time predator-prey model. Ghaziani, Govaerts, and Sonck (Ghaziani et al., 2012) discovered the conditions that must be met for a functional Holling-type discrete system to be stable at three equilibrium points. These studies have revealed that the discrete prey-prey system has more dynamic behaviors. The Hopf Bifurcation Theorem may be used for the periodic steady-state solution of the models (Xu et al., 2011). Tan and Bora (Korkmaz Tan and Bora, 2019) examined the dynamic behavior of discrete predator-prey systems and found the most appropriate behavior in their studies by performing parameter adjustment studies on the developed model. The ecological balance must ensure the continuation of the predator-prey system modeled by their research, as it is in reality, without extinction of the species. That's why accurate predator-prey models are needed.

Artificial Neural Networks is a parallel and distributed processors that's designed to imitate the working principles of a simple nervous system or the human brain. The learning process in artificial neural networks occurs with the adjustment of the weights of the synaptic connections between cells to achieve the desired goal (Luger, 2005). The use of Artificial Neural Networks is common in solving complex system problems that traditional algorithms or mathematical formulas are unable to calculate (Russell and Norvig, 1995). Information or algorithms are not precise in Artificial Neural Networks; experience is needed and used

to achieve the desired success. Various learning algorithms are used to provide the necessary experience.

Canada Lynex has dramatic fluctuations in population, following snowshoe hare populations to a peak, then crashing. Lynex Population in Canada is in decrease and it is under protection. That's why it has become a hot topic in the last decades (Stenseth et al., 1997; Tyson et al., 2010; Yan et al., 2013). Canadian Hares and Lynex Population data collected in from 1850 to 1950 is available on the net (Tan and Bora, 2020). The actual prey-predator system is more complex than the one predicted by the Lotka-Volterra model and better population models than the heuristic Lotka-Volterra model is needed such as agent-based models. However, such models are computationally intensive and time-consuming (Korkmaz Tan and Bora, 2019; Tan and Bora, 2017, 2020). An artificial neural network is either a circuit or a program inspired with biological neurons. They are able to learn, recognize patterns, classify, predict data (Haykin and Network, 2004; Liang and Bose, 1996). They are able to predict the behavior and output of dynamic models (Bandyopadhyay and Chattopadhyay, 2006; Martin et al., 1995; Pan and Duraisamy, 2018; Ramirez-Beltran and Montes, 2002; Xiao, 2017). They have been used successfully to predict population sizes (Benzer, 2014; Folorunso et al., 2010; Hamadneh, 2018; Lindström et al., 1998). They can also be used to predict prey and predator populations (Benzer, 2014; Folorunso et al., 2010; Hamadneh, 2018; Merilaita, 2007). Population cycles of mammals may be ratio dependent (Akçakaya, 1992) and an ANN can include such a dependency easily during training even though it is not expressed explicitly. Another advantage of an ANN model is that once

trained an ANN model runs quicker than an agent-based population model. In this study, first, it is shown that a Lotka-Volterra model is not sufficient to model the Canadian Hares and Lynex Population data collected from 1850 to 1950 and, then, ANN models are used to predict the data, and the ANN models for the populations are compared. The Artificial Neural Networks are trained with the Levenberg-Marquardt method using the MATLAB program and its Neural Net Fitting toolbox. The ANN models' inputs are chosen by taking inspiration from the Lotka-Volterra model.

The paper is arranged as follows. In the second section, the Lotka-Volterra equations in continuous time and discrete time are given. In the third section, Hares and Lynex Population data from 1850 to 1950 is presented. The data is used to find the parameters of Lotka-Volterra equations in discrete time using the least-squares method in the fourth section. An ANN model is suggested for each the population prediction in the fifth section and also selection of input and output variables for ANN, selection of number of ANN layers, ANN training and evaluation of prediction results are made. Its population prediction results are given and evaluated in the sixth section. The population predictions of the ANN models and the Lotka-Volterra model are also compared in the sixth section. The paper is concluded with the last section.

2. Material and Method

2.1. Lotka Volterra Equations

The structure of the Lotka-Volterra model, which has two populations, is such that the prey species survives by eating the predator species. Its model can be explained in this section. If no predator

population exists in the environment, the increase in prey population is calculated using the following equation:

$$\frac{dx}{dt} = ax, \text{ for } a > 0. \quad (1)$$

If there is no prey population in the environment, the predator population decline is calculated using the following equation:

$$\frac{dy}{dt} = -dy, \text{ for } d > 0. \quad (2)$$

If the species are in the same environment, they will encounter each other, and their growth and decline rates will change. The rates of increase and decrease vary depending on the x and y values. The number of prey decreases at a rate of bxy for b>0 and the predator population increases by cxy for c>0 in this case. Then, the set of equations, which are called Lotka-Volterra equations, for calculating the rate of change of the prey and predator numbers describing a Lotka-Volterra system in continuous time are given below.

$$\begin{aligned} \frac{dx}{dt} &= ax - bxy \\ \frac{dy}{dt} &= cxy - dy \end{aligned} \quad (3)$$

where x and y are the state variables presenting prey and predator populations respectively, t is time, and a, b, c, and d are Lotka-Volterra system parameters, which are positive real numbers describing interaction of the two species.

Ordinary differential equations, difference equations, and partial differential equations are used to create mathematical models. These equations, which are dynamic systems, are divided into two categories:

Discrete and continuous. When modeling continuous systems, differentiable equations are used. Discrete systems are modeled with difference equations. Lotka-Volterra model is a continuous system. Lotka-Volterra systems are used to study the dynamics of interacting populations. Some prey-predator systems can also be more complex than the described with the Lotka-Volterra system and agent-based models can be needed for modeling as done in (Korkmaz Tan and Bora, 2019; Tan and Bora, 2017, 2020). Just four parameters, a, b, c, and d, may not be sufficient to model a prey-predator system. The rates of change of both predator and prey populations can be considered as functions of both predator and prey populations.

$$\begin{aligned}x'(t) &= f_1(x(t), y(t)) \\ y'(t) &= f_2(x(t), y(t))\end{aligned}\tag{4}$$

For Lotka-Volterra equations, the functions of Eq. (4) are given as

$$\begin{aligned}f_1(x(t), y(t)) &= ax - bxy \\ f_2(x(t), y(t)) &= cxy - dy\end{aligned}\tag{5}$$

$f_1(x(t), y(t))$ and $f_2(x(t), y(t))$ might be more complex than the bilinear functions in Eq. (5) as in (Yan et al., 2013)].

Let

$$u = \frac{dx}{dt}\tag{6}$$

and

$$v = \frac{dy}{dt} \tag{7}$$

Then,

$$u = \frac{dx}{dt} = ax - bxy = ax - bz \tag{8}$$

$$v = \frac{dy}{dt} = cxy - dy = cz - dy$$

Lotka-Volterra system of two species in discrete time can be derived as the follows. The finite difference method can be used to obtain the rates of change of Lotka-Volterra equations approximately:

$$u[k] = \frac{x[k+1] - x[k]}{T_s} \cong ax[k] - bx[k]y[k] \tag{9}$$

$$v[k] = \frac{y[k+1] - y[k]}{T_s} \cong cx[k]y[k] - dy[k]$$

where k is an integer number showing the k^{th} data point and T_s is the sampling time.

A microcontroller-based emulator circuit of Prey-predator system of Lotka-Volterra equations has been made with ARM microcontroller education board in (Karakulak et al., 2021). Using Euler method and the Lotka-Volterra system parameters, the Lotka-Volterra equations in discrete time can be solved as done in (Karakulak et al., 2021) as:

$$x[k+1] \cong x[k] + T_s u[k] \tag{10}$$

$$y[k+1] \cong y[k] + T_s v[k]$$

$$x[k+1] \cong x[k] + T_s (ax[k] - bx[k]y[k]) \tag{11}$$

$$y[k+1] \cong y[k] + T_s (cx[k]y[k] - dy[k])$$

The prey and predator number of the Lotka-Volterra equations in the next step can be predicted as:

$$\begin{aligned}x[k+1] &\cong (1+aT_s)x[k]-bT_sx[k]y[k] \\y[k+1] &\cong cT_sx[k]y[k]+(1-dT_s)y[k]\end{aligned}\tag{12}$$

The discrete-time model is used in the fourth section for simulation of the Lotka-Volterra system.

2.2 Hares and Lynex Population of Showshoe Region From 1850 to 1950

Snowshoe Hares and Canadian Lynex Population from 1850 to 1950 is taken from (<https://www.chegg.com>) and it is shown in Figure 1. Lynex Population vs. Hares Population graphic plotted for the data shows that the system is not in steady-state or does not have a phase-portrait or a limit cycle. The phase-portrait of the data which is very complex and hard to describe is shown in Figure 2.




Figure 1. The data taken from (Stenseth et al., 1997).

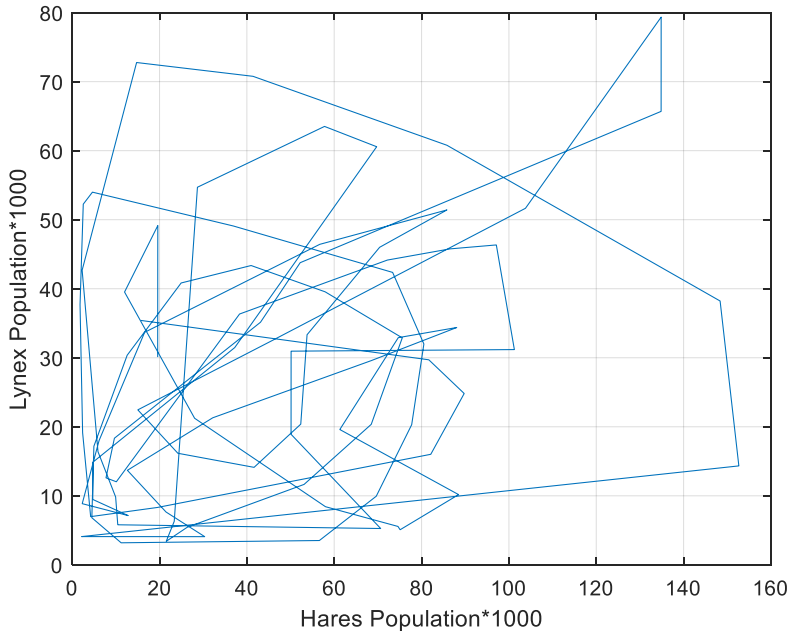


Figure 2. Lynex Population vs. Hares Population.

2.3 Curve Fitting of Hares and Lynex Population

In this section, the parameters of the Lotka-Volterra system are obtained with curve-fitting using the population data taken from (<https://www.chegg.com>). The following transformation of the variables are made. Let z and z_k defined as:

$$z = xy \tag{13}$$

and

$$z_k = x_k y_k \tag{14}$$

For the least squares curve-fitting method, the data points are traditionally written using sub-indexes. Therefore, the following equalities are true:

$$\begin{aligned}x[k] &= x_k \\y[k] &= y_k \\z[k] &= z_k\end{aligned}\tag{15}$$

There are two equations to be curve-fitted. Each equation has two parameters to be found. The sum of the squares of the error of the first equation of Eq. (8) is given as

$$S_{ab} = \sum_{k=1}^{k=N} (u_k - ax_k + bz_k)^2\tag{16}$$

To minimize the Eq. (16), its derivative by respect to a is calculated:

$$\frac{\partial S_{ab}}{\partial a} = \sum_{k=1}^{k=N} 2(-x_k)(u_k - ax_k + bz_k) = 0\tag{17}$$

By rearranging the Eq. (17), the following equation is obtained:

$$a \sum_{k=1}^{k=N} x_k^2 - b \sum_{k=1}^{k=N} (x_k z_k) = \sum_{k=1}^{k=N} (x_k u_k)\tag{18}$$

To minimize the Eq. (16), its derivative by respect to b is calculated:

$$\frac{\partial S_{ab}}{\partial b} = \sum_{k=1}^{k=N} 2(z_k)(u_k - ax_k + bz_k) = 0\tag{19}$$

By rearranging the Eq. (19), the following equation is obtained:

$$a \sum_{k=1}^{k=N} (x_k z_k) - b \sum_{k=1}^{k=N} z_k^2 = \sum_{k=1}^{k=N} (z_k u_k) \quad (20)$$

Eq. (17) and Eq. (19) can be written as a linear equation system:

$$\begin{bmatrix} \sum_{k=1}^{k=N} x_k^2 & \sum_{k=1}^{k=N} x_k z_k \\ \sum_{k=1}^{k=N} u_k z_k & \sum_{k=1}^{k=N} z_k^2 \end{bmatrix} \begin{bmatrix} a \\ -b \end{bmatrix} = \begin{bmatrix} \sum_{k=1}^{k=N} x_k u_k \\ \sum_{k=1}^{k=N} z_k u_k \end{bmatrix} \quad (21)$$

The following matrix multiplication is made to solve a and b:

$$\begin{bmatrix} a \\ -b \end{bmatrix} = \begin{bmatrix} \sum_{k=1}^{k=N} x_k^2 & \sum_{k=1}^{k=N} x_k z_k \\ \sum_{k=1}^{k=N} u_k z_k & \sum_{k=1}^{k=N} z_k^2 \end{bmatrix}^{-1} \begin{bmatrix} \sum_{k=1}^{k=N} x_k u_k \\ \sum_{k=1}^{k=N} z_k u_k \end{bmatrix} \quad (22)$$

The sum of the squares of the error of the second equation of Eq. (8) is given as

$$S_{cd} = \sum_{k=1}^{k=N} (v_k - cz_k + dy_k)^2 \quad (23)$$

To minimize the Eq. (23), its derivative by respect to c is calculated:

$$\frac{\partial S_{ab}}{\partial c} = \sum_{k=1}^{k=N} 2(-z_k)(v_k - cz_k + dy_k) = 0 \quad (24)$$

By rearranging the Eq. (24), the following equation is obtained:

$$c \sum_{k=1}^{k=N} z_k^2 - d \sum_{k=1}^{k=N} (y_k z_k) = \sum_{k=1}^{k=N} (z_k v_k) \quad (25)$$

To minimize the Eq. (23), its derivative by respect to d is calculated:

$$\frac{\partial S_{ab}}{\partial d} = 2 \sum_{k=1}^{k=N} (y_k)(v_k - cz_k + dy_k) = 0 \quad (26)$$

By rearranging the Eq. (20), the following equation is obtained:

$$c \sum_{k=1}^{k=N} y_k z_k - d \sum_{k=1}^{k=N} y_k^2 = \sum_{k=1}^{k=N} (y_k v_k) \quad (27)$$

Eq. (25) and Eq. (27) can be written as a linear equation system:

$$\begin{bmatrix} \sum_{k=1}^{k=N} y_k z_k & \sum_{k=1}^{k=N} y_k^2 \\ \sum_{k=1}^{k=N} z_k^2 & \sum_{k=1}^{k=N} z_k y_k \end{bmatrix} \begin{bmatrix} c \\ -d \end{bmatrix} = \begin{bmatrix} \sum_{k=1}^{k=N} y_k v_k \\ \sum_{k=1}^{k=N} z_k v_k \end{bmatrix} \quad (28)$$

The following matrix multiplication is made to obtain c and d:

$$\begin{bmatrix} c \\ -d \end{bmatrix} = \begin{bmatrix} \sum_{k=1}^{k=N} y_k z_k & \sum_{k=1}^{k=N} y_k^2 \\ \sum_{k=1}^{k=N} z_k^2 & \sum_{k=1}^{k=N} z_k y_k \end{bmatrix}^{-1} \begin{bmatrix} \sum_{k=1}^{k=N} y_k v_k \\ \sum_{k=1}^{k=N} z_k v_k \end{bmatrix} \quad (29)$$

The a, b, c, and d parameters of the Lotka-Volterra equations obtained using least-squares method are given in Table 1.

Table 1. The parameters of Hares and Canadian Lynex Lotka-Volterra system

a	0.0997
b	0.0027
c	8.4922e-04
d	0.0489

The Lotka-Volterra discrete time system derived in the second section is simulated in MATLABTM program using Euler method in discrete time domain. The parameters given in Table 1 are used for the simulations. The prey and predator populations obtained with the discrete-time simulation and the data given in (<https://www.chegg.com>) are shown together in Figures 3 and 4. The plots show that the prey and population data supplied in (<https://www.chegg.com>) deviates from the actual Lotka-Volterra model, i.e., the Lotka-Volterra model is unable to track the data given in (<https://www.chegg.com>) and misses the actual prey-predator dynamics. It has a lower frequency than the data in (<https://www.chegg.com>) for both prey and predator populations. LSM may be behaving as if a low pass filter due to the derivative part and that's why it is missing the high frequency dynamics. Lotka-Volterra model is not sufficient to accurately model the data. Perhaps, a modified Lotka-Volterra model may be needed. In the next section, an ANN model is made and used to model the data. The plot of the Lynex Population vs. the Hares Population obtained by the simulation is smoother than the one given by the data as seen in Figure 4. It can also be said that a limit cycle does exist for the simulations. However, the simulation results cannot predict the actual data accurately in both Figures 3 and 4.




Figure 3. a) $x(t)$ and b) $y(t)$ state variables with respect to time.

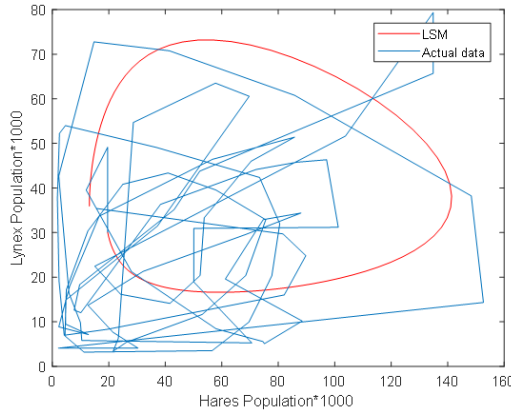


Figure 4. Lynex Population vs. Hares Population for the actual data in (<https://www.chegg.com>) shown in blue and the Lotka-Volterra model obtained for the parameters given in Table 1 shown in red.

3. Research Findings and Discussion

Considering the data in the previous section, it is hard to model such system. ANNs can be trained to predict the system behavior since ANNs can be used for curve-fitting successfully (Haykin and Network, 2004; Liang and Bose, 1996). In this section,

ANN models of the predator and prey system are developed. Since it is shown in the previous section that Lotka-Volterra equations are not

sufficient to model the system in discrete time, instead the Eq. (12), the following functions can be assumed:

$$\begin{aligned} x[k+1] &= f_1(x[k], y[k]) \\ y[k+1] &= f_2(x[k], y[k]) \end{aligned} \quad (30)$$

where $x[k]$ is the k^{th} data point of the predator (lynx) population and $y[k]$ is the k^{th} data point of the prey (hare) population.

Eq. (30) means the numbers of prey and predator in next step is dependent on the numbers of prey and predator in current step. A similar model is also used in (Stenseth et al., 1997). Figure 5 represents the predator-prey models examined in this study. First, the population of both the prey and the predator in the present time step is fed as inputs to the ANN system to obtain the populations of the prey and the predator in the next time step. When two ANNs for Eq. (30) shown in Figure 5.a, one for the prey and the other for the predator, are trained, they have not provided good results unfortunately. That's why another ANN model shown in Figure 5.b is considered. Reviewing the Eq. 10, it can be assumed that the population of the prey not only depends on the predator but also its derivative with respect to time or its difference in discrete time as

$$\begin{aligned} e_x[k] &= x[k+1] - x[k] \\ x[k+1] &= f_1(x[k], y[k], e_x[k]) \end{aligned} \quad (31)$$

Similarly, the following can be written for the predator model:

$$\begin{aligned} e_y[k] &= y[k+1] - y[k] \\ y[k+1] &= f_2(x[k], y[k], e_y[k]) \end{aligned} \quad (32)$$

Such a model has three inputs and one output for each ANN model. When the prey and the predator ANN models are developed further, the following model has also been obtained. The ANN models in Figure 5.b can be combined to have the same inputs and two outputs as shown in Figure 5.c and such an ANN model is described as

$$\begin{bmatrix} x[k+2] \\ y[k+2] \end{bmatrix} = f(x[k], y[k], x[k+1], y[k+1]) \quad (33)$$

However, the performance of the ANN given in Figure 5.b has a lower performance than the ANNs shown in Figure 5.c. That's why the results of the ANNs given in Figure 5.c is given in this study due to space considerations.

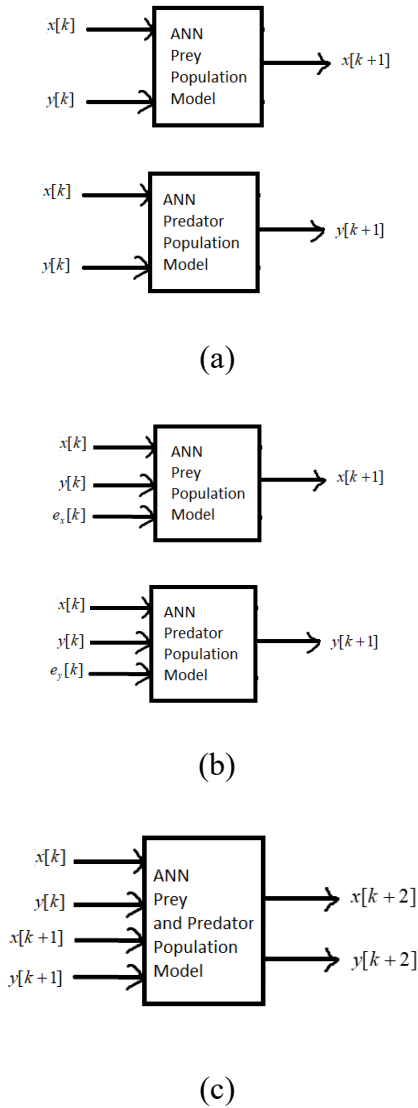


Figure 5. Conceptual ANN block diagrams of the Prey-Predator System.

There are many programs that can be used for artificial neural networks. The Neural Neural Network Toolbox (NNTool) is developed for the MATLAB™ program and offers algorithms, pre-trained models and applications to create, train, visualize and simulate shallow and deep

neural networks. NNTool toolbox of MATLAB is used to predict the Hare and Lynx populations in this study. Inputs and targets in the training data are defined in the Neural Net Fitting application available in NNTool as shown in Figure 6.

The ANN block diagram of the Prey-Predator System and the selection of the number of hidden layer neurons are shown in Figure 7. The ANN has only one hidden layer as shown in Figure 7. In order to reduce the error and obtain the best results, the number of neurons in the hidden layer is set to 10.

In the ANN, the sigmoid activation function is used in the hidden layer and the linear activation function is used in the output layer. In NNTool, Levenberg-Marquardt (LM) algorithm is chosen for calculating the weights. The fact that the training takes place in a fast and stable way compared to other algorithms has been the reason for choosing this algorithm. Then, information such as Input (input), Target (actual output), data acquisition method (matrix) is selected and it is determined what percentage of the collected data would be used for training, validation and testing as shown in Figure 8. During the study, these ratios has been changed to achieve better results.

In this study, a total of 6 columns and 88 rows of data taken from (<https://www.chegg.com>), 2 datasets are used for training of the ANN model in Figure 6. Therefore, the selected network has 4 inputs and 2 outputs. Each 2-column input dataset contains data of the same species for 2 consecutive years. The data has been divided into the training, test and validation sets as shown in Figure 8. 62 of the data (70%) are used for training, 13 of them (15%) are used for test and 13 of them (15%) are

used for validation. The datasets are given as inputs and the ANN is trained to obtain the predicted dataset as output. The selected ANN has been trained with the training dataset and, then, its performance is examined with validation and test datasets.

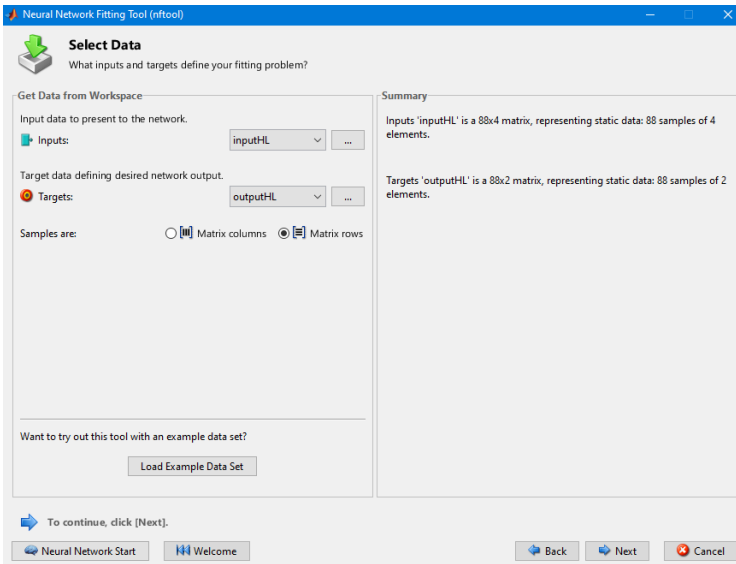


Figure 6. Input and target selection of the predator (lynx) and the prey (hare) model in NNTool.

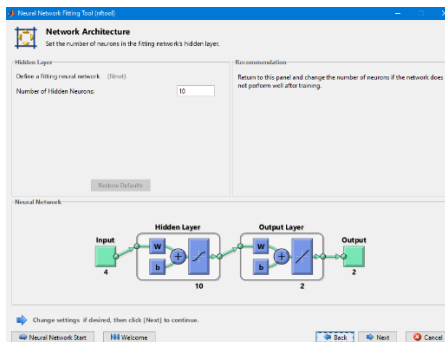


Figure 7. ANN block diagrams of the Prey-Predator System.

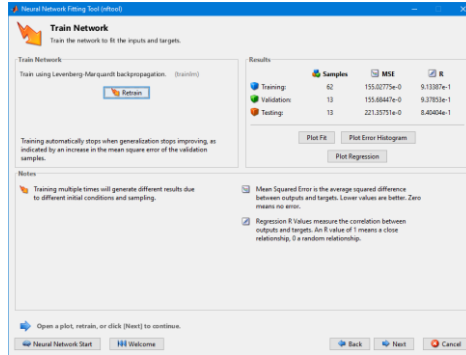


Figure 8. Training of the Predator and the Prey ANN Model in Neural Network Fitting Tool of Matlab.

Figure 9 shows that predicted prey and predator numbers obtained by the ANN, which has completed the training, reflect the real values. The predicted data is pretty close to the actual data taken from (<https://www.chegg.com>), Comparing Figures 3 and 9, it can be seen that the ANN models make better predictions than the Lotka-Volterra model.


MSE (Minimum Square Error) and R (Regression) results seen in Figure 9 are obtained. Table 1 shows the results of MSE and R in the prey-predator populations.

Table 1. MSE (Minimum Square Error) and R (Regression) results


	MSE	R
Training	155,02775e-0	9,13387e-1
Validation	155,68447e-0	9,37853e-1
Testing	221,35751e-0	8,40404e-1

In the data set used the variation of the interaction between populations over time is examined in prey-predator models. For example, an increase in the predator population leads to a decrease in the prey population. A decrease in the prey population will lead to a decrease in the predator population. Since the prey population will have difficulty in finding food. This situation is shown in Figure 1. The main purpose of the prey-predator models is to prevent extinction of their populations. The aim is to ensure the continuity of ecology. All predictions that prey and predator do not go extinct are assumed to be correct for ecology. The models given in Figure 5 are trained using the ANN algorithm, which is a deep learning method. The estimation results obtained by the models shown in Figures 5 (b) and 5 (c) are compatible with the actual data. In addition, the model that produces the closest result to the "Snowshoe Hares and Canadian Lynx Population" dataset, which consists of real data, is the one given in Figure 5 (c). Therefore, the data obtained from the model shown in Figure 5 (c) is used after that in this study. In Figure 9, the prediction data obtained by the ANN algorithm is shown separately for the prey and the predator in the Snowshoe Hares and Canadian Lynx Population Dataset. When Figure 9 is examined, it is seen that the prediction is very close to the real data.

The results of regression are analyzed in order to test the consistency of estimations, and as shown in the graphs for Hares and Lynx in Figure 10, a linear relationship has been observed between the predictions obtained and the actual values, which is 90.67% as shown in Figure 10. The ANN training results are also evaluated using regression and given in Table 2.



(a)



(b)

Figure 9. a) Lynex population data taken from (Yan et al., 2013) in blue and ANN population estimation of Lynex in red and b) Hare population data taken from (Yan et al., 2013) in blue and ANN population estimation of Hare in red.

Table 2. The ANN training results for the Lynex and Hares populations from 1850 to 1950.

Training Data Distribution (%)	Validation Data Distribution (%)	Testing Data Distribution (%)	Hidden Neuron Numbers (%)	Training Regression R^2	Validation Regression R^2	Testing Regression R^2	Total Regression R^2
15	15	70	10	0,834276	0,879568	0,706228	2,63076

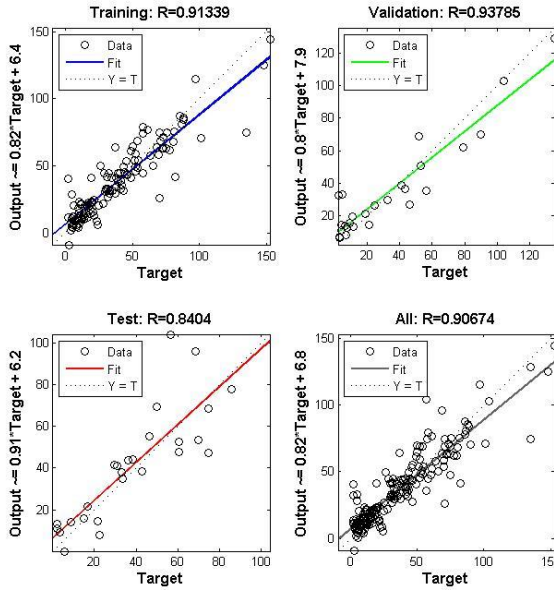


Figure 10. Relationship Between Estimated Values (Output) Obtained by the ANN and Actual Observation Values (Target)

The hare and lynx populations' MSE values obtained in each iteration during the training of the ANN are given in Figure 11 respectively. These curves in Figure 11 show that the training and validation error vectors follow a similar course throughout the training iterations. Thus, it can be concluded that there is no overfitting. As can be seen in the figure, the weight and threshold values that minimize the MSE for the validation set has been obtained in the 9th iteration and the best weight and threshold values were obtained.




Figure 11. Error Performances for Training and Validation Sets (a-lynx, b-hare)

The error histogram of the ANN architecture given in Figure 12 is obtained to examine the network performance. The training area is shown in blue, the validation area is shown in green, and the testing area is shown in red on the histogram. The histogram shows that most of the errors rise around 10%.




Figure 12. Histogram Chart of the Errors in the predictions obtained (a-lynx, b-hare)

To evaluate the accuracy of the ANN prediction results, the following formulas and their definitions are used;

MAPE (Mean absolute percentage error) is described as

$$MAPE = 100 \frac{\sum_{i=1}^{i=N} |T \text{ arg } et_i - Output_i|}{N} \quad (34)$$

where N is the number of the data points.

RMSE (Root-mean-square error) is described as

$$RMSE = \sqrt{\frac{\sum_{i=1}^{i=N} (T \text{ arg } et_i - Output_i)^2}{N}} \quad (35)$$

R^2 (The correlation) is the fitting coefficient used to measure the accuracy of the model. The correlation coefficient is equal to the square of R ;

$$R^2 = 1 - \frac{SSerror}{SStotal} \quad (36)$$

where

$$SSerror = \sum_{i=1}^{i=N} (T \text{ arg } et_i - Output_i)^2 \quad (37)$$

and

$$SStotal = \sum_{i=1}^{i=N} (T \text{ arg } et_i - T \text{ arg } et_{ort})^2 \quad (38)$$

Lewis classify ANN models as the follows in (Lewis, 1982):

- Models with a MAPE below 10% are 'very good'.
- Models with a MAPE between 10% and 20% are 'good'.
- Models with a MAPE between 20% and 50% are 'acceptable'.

- Models with a MAPE above 50% are 'very good'. classified as 'wrong and inaccurate.

A low MAPE value, 24.79%, for lynx is obtained and given in Table 3 indicate that the deviation between the actual data and the forecast data is small. However, MAPE value for hare is 65.63% and, according to Lewis, this value is inaccurate. The accuracy of the ANN prediction can be seen in Table 3.

Table 3. ANN performance for the data of Snowshoe Hares and Canadian Lynex Population from 1850 to 1950.

Model Output Parameter	The ANN Performance				
	MAD	MSE	MAPE	RMSE	R ²
Lynx	4,07611	36,41975	24,79%	6,034	0,9675985
Hare	9,07074	133,8824	65,63%	11,57	0,9212095

As a result of the predictions obtained from the ANN, the following comments can be made:

- In ANN models, the best prediction success was obtained for the Lynx population value, also the lowest prediction success was obtained for the Lynx population value.
- The ANN predicts the species' populations more accurately than the Lotka-Volterra model does.
- According to Lewis, the model must be improved more considering hares population.

4. CONCLUSIONS

In this study, first, a discrete model of the Lotka-Volterra equations has been derived and, then, a few ANN models of a prey-predator system are made considering a discrete phenomenological model and choosing

its system inputs. The ANN model, which gives the best results amongst them, is used for the prediction of the populations of the Hares and the Lynex species in Canada. A maximum % error of -1.67 has been obtained for the prey-predator with the ANN model. As a result, it can be said that ANN provides a powerful tool for the prediction of prey and predator populations.

It is shown in this study that the ANN can predict Lynx and Hares populations in Canadian Snowshoe region with less error than the Lotka-Volterra model gives. The ANN model predicts the trend of the species better than the Lotka-Volterra model. The ANN model predicts the maximum populations of both of the species well. However, it predicts the maximum populations with a very big error. Perhaps, using nonlinear ANN input functions the error can be decreased.

As future works, we make the following suggestions. The balance in population density between species of prey-predator model can be examined, the future populations of the species can be predicted, and the method given here can be extended to more than two coupled species with more complex relationships such as gross, sheep and wolf system as done in (Tan and Bora, 2017, 2020) or more complex systems using an ANN or ANNs. Such an ANN model perhaps can be improved for more accuracy for several interacting species by using other ANN topologies such as convolutional neural networks. The effect of the initial populations on the future species' populations can also be investigated easily with such an ANN model. Similar ANN models can also be used for education and studies such as extinction, over-population, steady-

state populations, etc. The effect of the number and the time delays of the ANN inputs on its performance may also be examined in the future.

Reference

- Akcakaya, H.R., 1992. Population cycles of mammals: evidence for a ratio-dependent predation hypothesis. *Ecological Monographs* 62, 119-142.
- Anonim (2003). Food and Agriculture Organization of the United Nations (FAO), Erişim Adresi: <https://www.chegg.com/homework-help/questions-and-answers/predator-prey-graph-snowshoe-hare-canadian-lynx-using-graph-approximate-carrying-capacitie-q583663>, (Erişim Tarihi: 20.08.2021)
- Bandyopadhyay, G., Chattopadhyay, S., 2006. An Artificial Neural Net approach to forecast the population of India. *arXiv preprint nlin/0607058*.
- Benzer, R., 2014. Population dynamics forecasting using artificial neural networks. *Fresenius Environmental Bulletin* 12, 14-26.
- Chen, B., Chen, J., 2012. Bifurcation and chaotic behavior of a discrete singular biological economic system. *Applied Mathematics and Computation* 219, 2371-2386.
- Folorunso, O., Akinwale, A., Asiribo, O., Adeyemo, T., 2010. Population prediction using artificial neural network. *African Journal of Mathematics and Computer Science Research* 3, 155-162.
- Ghaziani, R.K., Govaerts, W., Sonck, C., 2012. Resonance and bifurcation in a discrete-time predator-prey system with Holling functional response. *Nonlinear Analysis: Real World Applications* 13, 1451-1465.
- Glória, I., Figueiredo, A., Rocha Filho, T., 2001. Stability properties of a general class of nonlinear dynamical systems. *Journal of Physics A: Mathematical and General* 34, 3561.
- Goel, N.S., Maitra, S.C., Montroll, E.W., 1971. On the Volterra and other nonlinear models of interacting populations. *Reviews of modern physics* 43, 231.
- Hamadneh, N.N., 2018. A Comparison between Firefly and Prey-Predator Algorithms Based on Artificial Neural Networks. *Applied Mathematical Sciences* 12, 1157-1165.
- Han, W., Liu, M., 2011. Stability and bifurcation analysis for a discrete-time model of Lotka-Volterra type with delay. *Applied Mathematics and Computation* 217, 5449-5457.

- Haykin, S., Network, N., 2004. A comprehensive foundation. Neural networks 2, 41.
- Karakulak, E., Tan, R.K., Mutlu, R., 2021. STM32F429 Discovery Board-Based Emulator for Lotka-Volterra Equations. Journal of the Institute of Science and Technology 11, 1887-1895.
- Kerner, E.H., 1964. Dynamical aspects of kinetics. The bulletin of mathematical biophysics 26, 333-349.
- Kimura, M., Weiss, G.H., 1964. The stepping stone model of population structure and the decrease of genetic correlation with distance. Genetics 49, 561.
- Korkmaz Tan, R., Bora, Ş., 2019. Adaptive parameter tuning for agent-based modeling and simulation. Simulation 95, 771-796.
- Lewis, C.D., 1982. Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting. Butterworth-Heinemann.
- Liang, P., Bose, N., 1996. Neural network fundamentals with graphs, algorithms, and applications. Mac Graw-Hill.
- Lindström, J., Kokko, H., Ranta, E., Lindén, H., 1998. Predicting population fluctuations with artificial neural networks. Wildlife Biology 4, 47-53.
- Lotka, A.J., 1926. ELEMENTS OF PHYSICAL BIOLOGY. Science Progress in the Twentieth Century (1919-1933) 21, 341-343.
- Luger, G.F., 2005. Artificial intelligence: structures and strategies for complex problem solving. Pearson education.
- Martin, S., Kamwa, I., Marceau, R., 1995. Applications of artificial neural networks to the identification of dynamical systems, Proceedings 1995 Canadian Conference on Electrical and Computer Engineering. IEEE, pp. 606-612.
- Merilaita, S., 2007. Artificial neural networks and the study of evolution of prey coloration. Philosophical Transactions of the Royal Society B: Biological Sciences 362, 421-430.
- Pan, S., Duraisamy, K., 2018. Long-time predictive modeling of nonlinear dynamical systems using neural networks. Complexity 2018.
- Ramirez-Beltran, N.D., Montes, J.A., 2002. Neural networks to model dynamic systems with time delays. IIE Transactions 34, 313-327.
- Ruan, S., 2009. On nonlinear dynamics of predator-prey models with discrete delay. Mathematical Modelling of Natural Phenomena 4, 140-188.

- Russell, S., Norvig, P., 1995. Prentice Hall series in artificial intelligence. Prentice Hall Englewood Cliffs, NJ: .
- Stenseth, N.C., Falck, W., Bjørnstad, O.N., Krebs, C.J., 1997. Population regulation in snowshoe hare and Canadian lynx: asymmetric food web configurations between hare and lynx. *Proceedings of the National Academy of Sciences* 94, 5147-5152.
- Tan, R.K., Bora, Ş., 2017. Parameter tuning in modeling and simulations by using swarm intelligence optimization algorithms, 2017 9th International Conference on Computational Intelligence and Communication Networks (CICN). IEEE, pp. 148-152.
- Tan, R.K., Bora, Ş., 2020. Adaptive modified artificial bee colony algorithms (AMABC) for optimization of complex systems. *Turkish Journal of Electrical Engineering and Computer Sciences* 28, 2602-2629.
- Tyson, R., Haines, S., Hodges, K.E., 2010. Modelling the Canada lynx and snowshoe hare population cycle: the role of specialist predators. *Theoretical Ecology* 3, 97-111.
- Volterra, V., 1926. *Variazioni e fluttuazioni del numero d'individui in specie animali conviventi*. Società anonima tipografica" Leonardo da Vinci".
- Xiao, S., 2017. Research on Dynamic System Simulation Model and Algorithm Based on Artificial Neural Network, 2016 7th International Conference on Education, Management, Computer and Medicine (EMCM 2016). Atlantis Press.
- Xu, C., Liao, M., He, X., 2011. Stability and Hopf bifurcation analysis for a Lotka-Volterra predator-prey model with two delays.
- Yan, C., Stenseth, N.C., Krebs, C.J., Zhang, Z., 2013. Linking climate change to population cycles of hares and lynx. *Global change biology* 19, 3263-3271.
- Zhang, G., Shen, Y., Chen, B., 2014. Bifurcation analysis in a discrete differential-algebraic predator-prey system. *Applied Mathematical Modelling* 38, 4835-4848.

BÖLÜM 3

İSTANBUL'DA SU TÜKETİMİ VE YAĞIŞ TAHMİNİ: YAPAY ZEKA YAKLAŞIMI

Dr. Öğr. Üyesi Enes EFE¹

¹ Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Hitit Üniversitesi, Çorum,
Türkiye, 0000-0002-6136-6140, enesefe@hitit.edu.tr

1. Giriş

İstanbul günümüzde 15 milyonu aşan nüfusu ve hızla büyüyen kentsel yapısıyla, su yönetimi açısından büyük zorluklarla karşı karşıya kalan mega kentlerden biridir. Şehirdeki su arzı büyük ölçüde yüzey sularına dayanmakta ve yeraltı sularının katkısı ihmal edilecek kadar azdır (Akbaş, 2005). İstanbul'un su ihtiyacının yaklaşık %98'i göller ve barajlar gibi yüzeysel su kaynaklarından karşılanmaktadır, bu da şehrin su kaynaklarının yenilenme sürecinde doğrudan yağış miktarına bağımlı olmasına neden olmaktadır. Bu durum, su arzının sürdürülebilir yönetiminin kontrol altında tutulmasını daha da zorlaştırmakta ve olası su krizlerine açık hale getirmektedir (Turoğlu, 2019). Şehirdeki mevcut su altyapısının eski ve yetersiz olması, su kayıplarını artırarak yönetim stratejilerinin etkinliğini zorlaştırmaktadır. Su kaçağı oranlarının yüksek olması, özellikle suyun şehir geneline verimli bir şekilde ulaştırılmasında önemli zorluklar doğurmaktadır (Nalici ve Akbaş, 2022). Ayrıca, İstanbul'un su kaynaklarının bir kısmının şehir dışından getirilmesi (örneğin Melen Çayı Projesi) taşımacılıkla ilgili ek maliyetler ve teknik sorunlar oluşturmaktadır (Yılmaz ve ark., 2020).

Su yönetimi sorunlarının başında ise şehirdeki altyapı eksiklikleri ve su kaynaklarının sınırlı kapasitesi gösterilebilir. Özellikle 2007-2008 ve 2013-2014 yılları arasında yaşanan kuraklık dönemleri, su arzındaki kırılganlığı açıkça ortaya koymuş ve suyun yönetiminde daha yenilikçi ve sürdürülebilir yaklaşımların gerekliliğini gündeme getirmiştir (Yıldız, 2021). Ayrıca, nüfus artışı ve ekonomik büyümenin etkisiyle birlikte, su talebi hızla artmaktadır ve mevcut kaynakların bu talebi karşılaması zorlaşmaktadır. İstanbul düzenli su dağıtılan yaklaşık 7 milyon aboneye

sahip olup, suyun büyük bir kısmı yüzeysel kaynaklardan sağlanmaktadır. Ancak bu yüzeysel kaynaklar genellikle yağış rejimine bağlı olarak değişen kapasiteye sahip olduğu için, su yönetimi stratejilerinin çok boyutlu bir şekilde ele alınması gerekmektedir (Boudhaouia ve Wira, 2021).

İstanbul'un nüfusu, 2000'li yılların başından bu yana hızlı bir şekilde yükselmiş ve bu yükselişe paralel olarak su tüketimi de önemli ölçüde artmıştır. Türkiye İstatistik Kurumu (TÜİK) verilerine göre, İstanbul'un nüfusu her yıl ortalama %2 oranında artmakta, bu da su talebinin de sürekli olarak artmasına neden olmaktadır. Günlük su tüketimi, özellikle yaz aylarında sıcaklıkların artmasıyla birlikte yüksek seviyelere ulaşmaktadır (Turoğlu, 2019). Bunun yanı sıra sanayileşme ve kentsel yayılma gibi faktörlerinde su tüketim oranlarının artmasına yol açtığı söylenebilir. Ayrıca İstanbul'un su talebi yalnızca hanelerle sınırlı kalmayıp endüstriyel ve tarımsal faaliyetlerin de su kaynakları üzerindeki baskısını artırmaktadır (Saplıoğlu ve ark., 2017). Özellikle yaz aylarında artan turizm faaliyetleri de su tüketimini önemli ölçüde etkilemekte ve mevcut su kaynaklarının yönetimini daha da zorlaştırmaktadır.

İklim değişikliği, İstanbul'daki su yönetimi açısından önemli bir risk faktörüdür. Küresel ısınmanın etkisiyle yağışların miktarı ve dağılımında düzensizlikler meydana gelmekte, bu durum su rezervuarlarının yenilenme süreçlerini olumsuz yönde etkilemektedir (Wijesiri ve ark., 2020). Özellikle son yıllarda gözlemlenen aşırı sıcaklık artışları ve azalan yağış miktarları, şehrin su kaynaklarının gelecekte sürdürülebilir bir şekilde yönetilmesini tehlikeye sokmaktadır. 2014

yılında yaşanan şiddetli kuraklık, İstanbul'un su rezervuarlarındaki doluluk oranlarının %16'lara kadar düşmesine neden olmuş, bu da şehirde su kıtlığı riskinin ne kadar ciddi boyutlara ulaşabileceğini göstermiştir (Yıldız, 2021). Uzun vadeli iklim projeksiyonları gelecekte daha sık ve şiddetli kuraklık dönemlerinin yaşanabileceğini öngörmekte, bu da su yönetimi politikalarının yenilenmesini zorunlu kılmaktadır (Yılmaz ve ark., 2020).

Su yönetimi ve tahmin modelleri üzerine yapılan çalışmalarda, genellikle zaman serisi analizleri ve makine öğrenmesi yöntemleri kullanılarak su arzı ve talebi tahmin edilmeye çalışılmaktadır. (Nalici ve Akbaş, 2022), İstanbul'un baraj doluluk oranları için ARIMA ve Üssel Düzgünleştirme gibi zaman serisi modellerini kullanarak gelecekteki su arzını tahmin etmiş ve bu süreçte iklim değişikliğinin etkilerini dikkate almıştır. Benzer şekilde, (Yılmaz ve ark., 2020) çalışmasında, günlük su rezervuar seviyelerinin geçmiş verilerine dayanarak çeşitli tahmin modelleri geliştirilmiş ve kurak dönemlerin olası etkileri değerlendirilmiştir. Literatürde yapay sinir ağları (ANN), destek vektör makineleri (SVR) ve XGBoost gibi makine öğrenmesi algoritmalarının su tüketimi ve yağış tahminlerinde kullanımı da yaygındır (Firat ve ark., 2009; Kesorsit ve Sirisathitkul, 2022; Shan ve ark., 2023). Yapay zeka ve makine öğrenmesi yöntemleri yalnızca su yönetimi değil, aynı zamanda tıp (Efe ve Özşen, 2022; Efe ve Yavsan, 2024; Orhan ve YAVŞAN, 2023), sanayi (Efe ve ark., 2021) ve finans (Henrique ve ark., 2019) gibi birçok farklı alanda da yaygın olarak kullanılmaktadır. Bu modellerin, geleneksel istatistiksel yöntemlere kıyasla daha doğru ve

güvenilir sonuçlar sunduğu çeşitli çalışmalarda gösterilmiştir (El Bilali ve ark., 2023).

Mevcut çalışmalar genellikle su tüketimi ve yağış tahminlerini ayrı ayrı ele almış ve bu iki veri setinin birlikte değerlendirildiği araştırmalar ise sınırlı sayıdadır. Bu çalışmanın temel amacı İstanbul'un su tüketimi ve yağış verilerini kullanarak, gelecekteki su talebi ve su kaynaklarının durumu hakkında daha doğru ve kapsamlı tahminler sunmaktır. Bu doğrultuda su tüketimi ve yağış verileri birlikte analiz edilip, her iki veri setine dayalı tahmin modelleri oluşturulmuştur. Çalışmada Linear Regression, Support Vector Regression (SVR) ve XGBoost gibi makine öğrenmesi yöntemleri kullanılarak geçmiş verilerden faydalanılmış ve her iki değişkenin gelecekteki eğilimlerini öngörmek hedeflenmiştir.


2. Materyal ve Metod

2.1. Veri Seti


Veri seti, İstanbul Büyükşehir Belediyesi (İBB) Açık Veri Portalı'ndan elde edilmiştir ve İstanbul'un on büyük barajına düşen günlük yağış miktarları ile şehrin günlük su tüketim miktarını kapsamaktadır. Veriler, Şekil 1 ve Şekil 2'de gösterilmektedir. Barajlara düşen yağış verileri kilogram/metrekare (kg/m^2) cinsinden ölçülmüş olup Ömerli, Darlık, Elmalı, Terkos, Büyükçekmece, Sazlıdere, Alibey, Kazandere, Pabuçdere ve İstıncalar barajlarına ait ayrı ayrı verilere dayanmaktadır. Veri setinde ayrıca, İstanbul'un genel su tüketim miktarları da yer almakta olup, günlük bazda metreküp/gün ($\text{m}^3/\text{gün}$) cinsinden raporlanmıştır. Aşağıdaki Tablo 1 veri setindeki ilk 5 gözlemi sunarak yağış ve su tüketim verilerinin genel yapısını göstermektedir.

Tablo 1. Veri setindeki ilk beş gözlem: İstanbul'da günlük yağış ve su tüketimi

Tarih	Toplam Yağış (kg/m ²)	Tüketim (m ³ /gün)
01.01.2011	0	2096199
02.01.2011	8.4	2214668
03.01.2011	121.45	2092441
04.01.2011	38.24	2096199
05.01.2011	4.82	2214668



Şekil 1. Toplam yağış verisi (2011-2024)



Şekil 2. Tüketim verisi (2011-2024)

2.2. Zaman Serisi Ayrıştırma (Decomposition)

Zaman serisi ayrıştırma (decomposition), bir zaman serisinin daha basit bileşenlere ayrılarak analiz edilmesini sağlayan bir yöntemdir. Bu yöntemde bir zaman serisi genellikle üç ana bileşene ayrılır: trend, mevsimsellik (seasonality) ve artık (residual). Bu bileşenlerin ayrı ayrı incelenmesi, verideki farklı davranışların daha iyi anlaşılmasına ve modellerin performansının artırılmasına yardımcı olur (Ribeiro ve ark., 2021). Uygulanan yöntem doğrultusunda formül aşağıdaki gibi ifade edilebilir:

$$Y_t = T_t + S_t + R_t \quad (1)$$

Burada:

Y_t zaman serisinin belirli bir zamandaki (t) gözlemini temsil eder (örneğin, toplam yağış veya su tüketim miktarı).


Trend (T_t), zaman serisinin genel eğilimini temsil eder ve verideki uzun dönemli değişiklikleri gösterir. Trend, veri setinde belirgin bir artış veya azalış eğilimi varsa bu eğilimi ortaya koyar. Örneğin, bir şehirdeki su tüketimi yıllar içinde sürekli artış gösteriyorsa bu artış trend bileşeni olarak değerlendirilir.

Mevsimsellik (S_t), veride düzenli aralıklarla tekrar eden kısa dönemli dalgalanmaları ifade eder. Örneğin, yağış miktarlarının yılın belirli aylarında artış veya azalış göstermesi mevsimsel bir davranıştır. Mevsimsellik bileşeninin belirlenmesi, verideki bu döngüsel yapıları ortaya çıkararak tahmin modellerinin doğruluğunu artırabilir.


Artık bileşeni (R_t), zaman serisinde trend ve mevsimsellik bileşenlerinin çıkarılmasından sonra kalan ve rastgele dalgalanmaları ifade eden kısımdır. Bu bileşen, verideki gürültü veya beklenmedik olayların

etkilerini içerir. Artık bileşenin analiz edilmesi, modelin hata payını anlamak ve tahminlerin doğruluğunu değerlendirmek için önemlidir.

Bu çalışmada kullanılan Decomposition yöntemi yağış ve su tüketimi verilerinin trend, mevsimsellik ve artık bileşenlerine ayrılmasını sağlamış ve bu sayede verilerin daha ayrıntılı bir şekilde analiz edilmesine olanak tanımıştır. Yağış ve su tüketimi verilerinin ayrıştırılmış bileşenleri Şekil 3 ve Şekil 4'te gösterilmiştir.



Şekil 3. Toplam yağış verisinin trend bileşeni (2011-2024)



Şekil 4. Tüketim verisinin trend bileşeni (2011-2024)

2.3. Lineer Regresyon

Lineer regresyon, bağımlı bir değişkenin (hedef değişken) bağımsız bir veya daha fazla değişkene (girdi değişkenleri) doğrusal olarak nasıl bağlandığını belirlemek için kullanılan temel makine

öğrenmesi yöntemlerinden biridir. Bu model, girdi ve hedef değişkenler arasında bir doğrusal ilişki olduğunu varsayar ve en uygun doğrusal denklemi oluşturmak için en küçük kareler yöntemini kullanır. Amaç, hata terimini minimize ederek veri noktalarına en iyi şekilde uyan bir doğru çizmektir. Formül olarak hedef değişken y , girdiler x ve katsayılar β ile şu şekilde ifade edilir (Montgomery vd., 2021):

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_nx_n \quad (2)$$

Bu çalışmada, İstanbul'un günlük yağış ve su tüketimi verilerine dayalı ilk model olarak Lineer Regresyon modeli uygulanmıştır. Model, hem yağış hem de tüketim verilerinin zaman serisi analizini yapmak ve bu değişkenlerin gelecekteki eğilimlerini tahmin etmek için kullanılmıştır.

2.4. XGBoost (Extreme Gradient Boosting)

XGBoost, "Extreme Gradient Boosting" anlamına gelen ve karar ağaçları üzerine inşa edilmiş bir makine öğrenmesi algoritmasıdır. Bu yöntem, veri madenciliği ve tahmin problemlerinde yaygın olarak kullanılan ve performansı yüksek olan bir modelleme tekniğidir. XGBoost, gradyan artırma (gradient boosting) yönteminin optimize edilmiş bir versiyonu olup yüksek doğruluk ve hızlı işlem kapasitesi gibi önemli avantajları vardır. Bu algoritma, verisetindeki her bir gözlemin hatasını azaltmak amacıyla bir dizi zayıf öğreniciyi (basit karar ağaçları) ardışık olarak oluşturur ve bir önceki modelin hatalarını minimize ederek nihai bir tahmin modeli oluşturur. XGBoost'un hızlı hesaplama, düzenleme (regularization) ve paralel hesaplama gibi özellikleri onu

büyük veri setlerinde ve zaman serisi analizlerinde güçlü bir araç haline getirir.

Bu çalışmada, İstanbul'un günlük yağış ve su tüketim verileri üzerinde XGBoost kullanılarak tahmin modelleri geliştirilmiştir. Modelin performansını artırmak amacıyla hiperparametre optimizasyonu yapılmış ve "GridSearchCV" ile en uygun parametreler belirlenmiştir. Parametreler arasında "n_estimators" (ağaç sayısı), "max_depth" (ağaçların derinliği), "learning_rate" (öğrenme oranı), "subsample" (örnekleme oranı) ve "colsample_bytree" (ağaç başına kullanılan özellik oranı) yer almaktadır (Chen vd., 2019).

2.5. Değerlendirme Metrikleri ve Performans Kriterleri

Bu çalışmada, makine öğrenmesi modellerinin performansını değerlendirmek için iki temel hata metriği olan Ortalama Mutlak Hata (Mean Absolute Error - MAE) ve Kök Ortalama Kare Hatası (Root Mean Squared Error - RMSE) kullanılmıştır. Bu metrikler, tahmin edilen değerler ile gerçek değerler arasındaki farkların büyüklüğünü değerlendirerek modelin doğruluğunu belirlemeye yardımcı olur. Aşağıda bu metriklerin formülleri ve kullanım amaçları açıklanmıştır.

MAE, tahmin edilen \hat{y}_i ve gerçek y_i değerler arasındaki mutlak farkların ortalamasıdır ve hata büyüklüğünü gösterir. Daha düşük MAE değeri, modelin tahminlerinin gerçek değerlere daha yakın olduğunu ifade eder. MAE, aşağıdaki formül ile hesaplanır:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

Burada n , toplam veri sayısını ifade eder. MAE, hataların yönünü dikkate almaz ve tüm hataların eşit ağırlıkta olduğunu varsayar.

RMSE, tahmin hatalarının karesinin ortalamasının karekökü olarak hesaplanır ve büyük hatalara daha fazla ağırlık verir. Bu metrik, modelin büyük sapmalara duyarlılığını ölçmek için kullanılır ve hataların büyüklüğü hakkında daha geniş bilgi sunar. Daha düşük bir RMSE değeri, modelin daha iyi performans gösterdiği anlamına gelir. RMSE, şu şekilde hesaplanır:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

Bu formülde, hataların karesinin alınması büyük hataların daha fazla ceza almasına neden olur, böylece modelin büyük hatalar yapmasını engellemek için daha dikkatli olması sağlanır.

Bu çalışmada, modeller (Linear Regression, Support Vector Regression ve XGBoost) için hem su tüketimi hem de yağış tahminleri ayrı ayrı değerlendirilmiştir. Bu değerlendirme sürecinde her bir modelin tahmin ettiği değerler ile gerçek test verileri arasındaki MAE ve RMSE değerleri hesaplanarak, modellerin hangi koşullarda daha iyi performans gösterdiği belirlenmiştir.

3. Araştırma Bulguları ve Tartışma

Bu çalışmada, İstanbul'un günlük yağış ve su tüketimi verileri kullanılarak çeşitli yapay zeka modelleri yardımıyla geleceğe yönelik tahminler yapılmıştır. Bu modeller arasında Linear Regression, Support Vector Regression (SVR) ve XGBoost yer almaktadır. Veri ön işleme aşamasında zaman serisi analizine uygun olarak veri seti "trend", "mevsimsellik" ve "artık" bileşenlerine ayrılmıştır. Bu ayrıştırma işlemi, veri setindeki dönemsel değişiklikleri ve uzun vadeli eğilimleri daha iyi

analiz edebilmek için önemlidir. Ardından, modellerin eğitilmesi ve test edilmesi amacıyla veri seti eğitim ve test veri setlerine bölünmüştür. Verilerin ölçeklendirilmesi için MinMaxScaler kullanılarak, model performansının iyileştirilmesi amaçlanmıştır.

SVR ve XGBoost gibi daha karmaşık modellerde, hiperparametre optimizasyonu gerçekleştirilmiştir. Bu işlem, GridSearchCV (hiperparametre arama yöntemi) kullanılarak en uygun parametre kombinasyonlarının belirlenmesiyle yapılmıştır. GridSearchCV, belirlenen hiperparametre aralıklarını sistematik olarak tarar ve modelin en iyi performans gösterdiği parametreleri seçer. Ayrıca TimeSeriesSplit (zaman serisi için özel çapraz doğrulama yöntemi) ile veri seti zaman sırasına göre bölünmüş, böylece modelin geleceği tahmin etmek için geçmiş verileri kullanma kabiliyeti değerlendirilmiştir. Model performansını değerlendirmek amacıyla Mean Absolute Error (MAE) ve Root Mean Squared Error (RMSE) gibi metrikler kullanılmıştır. MAE tahmin edilen değerler ile gerçek değerler arasındaki ortalama mutlak hatayı ifade ederken, RMSE hataların karelerinin ortalamasının karekökü olarak hesaplanır ve büyük hatalara daha duyarlı bir değerlendirme sağlar. Bu metrikler, farklı modellerin aynı veri seti üzerindeki performanslarının karşılaştırılmasını ve hangi modelin daha güvenilir tahminler sunduğunun belirlenmesini mümkün kılmıştır. Son olarak, gelecekteki 20 yıl için hem yağış hem de su tüketimi tahminleri yapılmıştır. Bu tahminler, her modelin ürettiği sonuçlar doğrultusunda ayrı ayrı görselleştirilmiş ve analiz edilmiştir.

3.1. Modellerin Performans Karşılaştırması

Aşağıdaki Tablo 2, modellerin hem yağış hem de su tüketimi tahminleri için elde edilen MAE ve RMSE değerlerini özetlemektedir.

Tablo 2. Modellerin yağış ve su tüketimi tahminlerindeki MAE ve RMSE değerleri

Model	Hedef Değişken	MAE	RMSE
Lineer Regresyon	Yağış	1.6	2.7
Lineer Regresyon	Tüketim	3086.46	4096.18
SVR	Yağış	2.33	4.04
SVR	Tüketim	292141.93	347269.17
XGBoost	Yağış	2.31	3.97
XGBoost	Tüketim	22149.26	43631.82

Lineer regresyon modelinde yağış tahminleri için MAE 1.60 ve RMSE 2.70 olarak, tüketim tahminleri için ise MAE 3086.46 ve RMSE 4096.18 olarak hesaplanmıştır. Bu sonuçlar, lineer regresyonun yağış tahminlerinde nispeten düşük hata oranlarıyla daha iyi performans gösterdiğini, ancak su tüketimi tahminlerinde daha büyük sapmaların oluştuğunu göstermektedir. Özellikle tüketim tahmininde yüksek hata değerleri, lineer regresyonun doğrusal olmayan ilişkileri yakalamakta zorlandığını ve bu nedenle su tüketimi gibi daha karmaşık süreçleri tahmin etmede sınırlı kaldığını ortaya koymaktadır.

Support Vector Regression (SVR) modelinde yağış tahminleri için MAE 2.33 ve RMSE 4.04, tüketim tahminleri için ise MAE 292141.93 ve RMSE 347269.17 olarak hesaplanmıştır. Bu sonuçlar, SVR'nin yağış tahmininde lineer regresyona göre daha yüksek hata oranlarına sahip olduğunu, ancak su tüketimi tahmininde hataların çok daha büyük olduğunu göstermektedir. SVR modelinin doğrusal olmayan ilişkileri daha iyi yakalayabilme potansiyeli olmasına rağmen su tüketimi gibi değişkenlerde geniş hata aralıklarının olması, modelin verilerin

yapısındaki karmaşıklıkları yeterince iyi öğrenemediğine işaret etmektedir.

XGBoost modelinde yağış tahminleri için MAE 2.31 ve RMSE 3.97, su tüketimi tahminleri için ise MAE 22149.26 ve RMSE 43631.82 olarak elde edilmiştir. XGBoost, özellikle su tüketimi tahmininde diğer modellere kıyasla daha düşük hata değerleri göstererek daha iyi bir performans sergilemiştir. Bu modelin, gradyan artırma tekniği ve hiperparametre optimizasyonu ile daha karmaşık veri yapılarını öğrenebilmesi ve hata oranlarını düşürebilmesi dikkate değerdir. Ayrıca, XGBoost'un geniş verisetleri ve karmaşık ilişkileri daha iyi işleyebilmesi onu bu çalışmada en başarılı model haline getirmiştir.

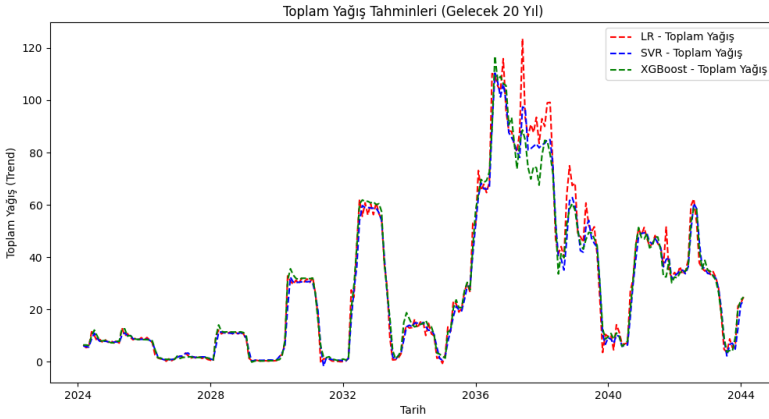
Modellerin performansları incelendiğinde, XGBoost'un hem yağış hem de su tüketimi tahminlerinde diğer iki modele göre daha başarılı olduğu görülmektedir. Yağış tahminlerinde tüm modeller nispeten düşük hatalarla benzer performanslar sergilerken, su tüketimi tahmininde XGBoost'un açık ara en düşük hata oranlarına sahip olduğu gözlemlenmiştir. SVR, doğrusal olmayan yapıları öğrenme yeteneği olmasına rağmen su tüketimi tahmininde beklenenden daha yüksek hatalar üretmiştir. Lineer regresyon ise özellikle su tüketimi gibi karmaşık ilişkiler içeren verilerde yetersiz kalmış ve hata oranları daha yüksek çıkmıştır.

Sonuç olarak, XGBoost'un gradyan artırma algoritmasının, daha karmaşık ve değişken veri yapılarında tahmin doğruluğunu artırdığı ve bu nedenle özellikle su yönetimi stratejilerinin belirlenmesinde daha uygun bir model sunduğu söylenebilir. Diğer modellerle karşılaştırıldığında, XGBoost'un esnekliği ve hiperparametre

optimizasyonu bu modelin farklı veri yapılarına uyum sağlamasını mümkün kılmış ve tahmin doğruluğunu artırmıştır. Bu bulgular, İstanbul'un su yönetimi stratejilerinde daha etkin kararlar almak için XGBoost gibi gelişmiş makine öğrenmesi algoritmalarının kullanılabilirliğini göstermektedir.

3.2. Su tüketimi ve yağış tahmin sonuçları

Çalışmada, Linear Regression, Support Vector Regression (SVR) ve XGBoost modelleri kullanılarak toplam yağış ve su tüketimi verileri ayrı ayrı modellenmiştir. Bu tahminler, Şekil 5 ve Şekil 6'da gösterilmektedir.




Şekil 5. Modellerin gelecek 20 yıl için toplam yağış tahminleri

Şekil 5'de, üç farklı model (Linear Regression, SVR ve XGBoost) kullanılarak yapılan yağış tahminleri yer almaktadır. Görsel incelendiğinde, modellerin gelecekteki yağış miktarlarında benzer eğilimler gösterdiği ancak tahminlerde bazı farklılıkların bulunduğu görülmektedir. Genel olarak modellerin eğilimleri benzer seyir izlerken, Linear Regression modelinin tahminleri diğer iki modele kıyasla daha dalgalı bir yapıya sahip görünmektedir. Bu dalgalanmalar, özellikle

belirli yıllarda daha yüksek tahmin değerlerinin ortaya çıkmasına neden olmaktadır.

XGBoost ve SVR modelleri ise daha dengeli ve düşük dalgalanma seviyelerine sahip tahminler üretmiştir. Bu durum, özellikle karmaşık veri yapılarında gradyan artırma algoritmalarının (XGBoost gibi) daha etkili sonuçlar üretebildiğini göstermektedir. Yağış tahminlerinde, üç modelin de gelecek yıllarda önemli değişim dönemlerine işaret eden benzer artış ve düşüş trendleri öngördüğü dikkat çekmektedir. Özellikle 2036 civarında belirgin bir yağış artışı, ardından ise azalan bir eğilim görülmektedir.



Şekil 6. Modellerin gelecek 20 yıl için tüketim tahminleri

Şekil 6'da, gelecekteki su tüketimi için yapılan tahminler görülmektedir. Linear Regression, SVR ve XGBoost modellerinin sonuçları karşılaştırıldığında tahminlerin belirgin şekilde farklılık gösterdiği anlaşılmaktadır. Özellikle SVR modelinin tahminleri, diğer modellere kıyasla çok daha düşük bir eğilim sergilemekte ve sürekli olarak belirli bir alt düzeyde kalmaktadır. Bu, SVR modelinin tüketim verilerini doğru şekilde öğrenememiş olabileceğini ve daha karmaşık veri yapılarına uygun olmayabileceğini göstermektedir.

Linear Regression ve XGBoost modelleri su tüketimi için daha benzer eğilimler ortaya koymakta, ancak Linear Regression modeli yine daha dalgalı bir yapı sergilemektedir. XGBoost modeli ise daha dengeli ve daha gerçekçi bir tahmin eğrisi üretmiş, gelecekteki tüketim değişimlerini daha iyi yansıtmıştır. Özellikle 2024 ve 2030 yılları arasında belirgin bir artış trendi gözlemlenmekte, ardından 2032 civarında bir tepe noktasına ulaşıldığı ve sonrasında düşüş trendinin başladığı görülmektedir.


3.3.Bulguların su yönetimi stratejilerine etkisi ve öneriler

Yapılan çalışmada, İstanbul'un su tüketimi ve yağış tahminleri için çeşitli yapay zeka modelleri kullanılarak gelecekteki eğilimler öngörülmüştür. Elde edilen bulgular, su yönetimi stratejilerinin şekillendirilmesi için önemli veriler sunmaktadır. Bu bulgulardan yağış tahminleri, belirli dönemlerde önemli değişimlerin olacağını ve bu değişimlerin su arzı üzerinde doğrudan etkili olacağını göstermektedir. Özellikle 2036 yılı civarındaki yağış artışları, su rezervuarlarının doluluk oranlarının artabileceği ve buna bağlı olarak su yönetimi önlemlerinin rahatlatılabileceği bir döneme işaret etmektedir. Ancak hemen ardından gelen azalan yağış eğilimleri, gelecekte yaşanabilecek su kıtlığı riskini azaltmak için erken planlama ve su tasarrufu önlemlerinin alınması gerektiğini göstermektedir.

Su tüketimi tahminlerine göre ise, 2024 ve 2030 yılları arasında önemli bir artış trendi öngörülmekte ardından 2032 civarında bir zirve noktasına ulaşılabileceği ve sonrasında düşüş eğilimine girileceği tahmin edilmektedir. Bu durum, kısa vadede su talebinin artmasıyla su arz ve talep dengesinin sağlanmasının zorlaşabileceğini ve daha etkili su

yönetimi stratejilerine ihtiyaç duyulacağını göstermektedir. Bu dönemde alınacak önlemlerle, su tüketimi azaltılabilir veya talep daha sürdürülebilir bir seviyede tutulabilir. Uzun vadede ise tüketim düşüşü öngörülse de, iklim değişikliği ve nüfus artışı gibi faktörler göz önünde bulundurularak esnek ve dinamik su yönetim politikalarının geliştirilmesi önemlidir.

Bu bağlamda, literatürde önerilen yenilikçi su yönetim ve üretim teknolojilerinin uygulanması önemli bir strateji olarak öne çıkmaktadır. Örneğin son yıllarda yapılan araştırmalar Şekil 7'de görüleceği üzere güneş enerjisiyle çalışan atmosferik su çıkarma sistemi (SAWE) gibi yeni teknolojilerin, su kıtlığı riski olan bölgeler için alternatif olarak oldukça ucuz maliyetli çözümler sunduğunu göstermektedir. SAWE sistemi (Yang vd., 2024), havadaki nemi emerek tatlı suya dönüştürmek için güneş enerjisini kullanır ve tamamen pasif bir şekilde çalışır. Sistem, cam elyaf membran (GFM) malzemesinden yapılan bir kütle taşıma köprüsü (MTB) yapısına sahiptir ve bu yapıya yerleştirilen higroskopik lityum klorür (LiCl) çözeltisi ile nemi yakalar. Güneş enerjisiyle çalışan bu sistem, ek enerji veya bakım gerektirmeden, düşük bağıl nem oranlarında bile su üretimini sürdürebilme kapasitesine sahiptir. Bu özellikleri sayesinde SAWE sisteminin, su kaynaklarının sınırlı olduğu İstanbul gibi büyük metropoller için önemli bir düşük maliyetli alternatif olabileceği öngörülmektedir.



Şekil 7. SAWE mimarisi ve tatlı su üretim süreci

Ayrıca diğer su üretim ve yönetim teknolojileri de dikkate alınmalıdır. Özellikle İstanbul gibi su kaynaklarının sınırlı olabileceği kıyı şehirlerinde, deniz suyunun arıtılması etkili bir çözüm olarak öne çıkmaktadır. Deniz suyu arıtma yöntemleri, tuz ve diğer mineralleri deniz suyundan uzaklaştırarak içilebilir su elde edilmesini sağlar. Ters ozmoz ve termal arıtma teknikleri gibi yöntemler, bu süreçte yaygın olarak kullanılmaktadır. Ters ozmoz, deniz suyunu yüksek basınç altında yarı geçirgen bir membran aracılığıyla filtreleyerek tuzun ve diğer çözünmüş maddelerin ayrılmasını sağlar, böylece içilebilir su elde edilir. Termal arıtma ise, deniz suyunu buharlaştırarak buharın yoğunlaştırılmasıyla tatlı su elde edilmesi sürecine dayanmaktadır. Bu teknikler, İstanbul'un su arzını artırmak ve su kıtlığı riskini azaltmak için alternatif ve sürdürülebilir çözümler sunabilir.

Yağmur suyu toplama sistemleri de su yönetimi stratejilerinde önemli bir yer tutmaktadır. İstanbul gibi yüksek nüfus yoğunluğuna sahip şehirlerde yağmur suyunun doğrudan çatılardan veya özel

yüzeylemlerden toplanarak depolanması, içme suyu, sulama veya günlük kullanım için uygun bir su kaynağı oluşturabilir. Bu yöntem düşük maliyetli ve kolay uygulanabilir olması sebebiyle, suyun temin edilmesinin zor olduğu bölgelerde özellikle etkilidir. Yağmur suyu toplama sistemleri, su talebini azaltarak mevcut su kaynaklarının korunmasına ve verimli bir şekilde kullanılmasına katkı sağlayabilir.

Yeraltı suyu kullanımı ise su rezervlerinin artırılması ve acil su ihtiyacının karşılanması için önemli bir yöntem olarak değerlendirilebilir. Yeraltı su kaynakları, doğal olarak yeraltında depolanan tatlı su rezervlerine ulaşılmasını sağlar. Ancak, bu kaynakların aşırı tüketilmesi durumunda yeraltı su seviyelerinin düşmesi ve bunun sonucunda çevresel sorunların ortaya çıkması gibi riskler bulunmaktadır. Bu nedenle, yeraltı sularının sürdürülebilir bir şekilde yönetilmesi ve aşırı kullanımın önlenmesi önemlidir.

4. Sonuçlar

Yapılan analizler İstanbul'daki su tüketimi ve yağış verilerinin geleceğe yönelik tahminlerinin hem kısa hem de uzun vadeli su yönetimi stratejilerinin belirlenmesinde önemli bir rol oynayabileceğini göstermektedir. Zaman serisi modellemeleri ve farklı yapay zeka teknikleri kullanılarak elde edilen bulgular, su arz ve talep dengelerinin daha etkin bir şekilde yönetilmesine olanak tanımaktadır.

Elde edilen sonuçlara göre gelecekteki su tüketiminde kısa vadede artış öngörülmekte ve bu artışın 2030'lara kadar devam edeceği, ardından düşüş eğilimine gireceği tahmin edilmektedir. Bu düşüş, son yıllarda yaşanan nüfus artış hızındaki yavaşlamanın etkisiyle ilişkili olabilir. Özellikle İstanbul gibi büyük şehirlerde nüfus artış hızının düşmesi, su

talebinin azalmasına veya daha stabil bir seyir izlemesine neden olabilir. Ancak yinede deneysel tahminler, özellikle kısa vadede su talebinin karşılanması için daha etkin su yönetimi politikalarının uygulanmasının gerekli olduğunu göstermektedir. Yağış tahminleri ise belirli dönemlerde artış ve azalış eğilimleri göstermekte olup, su rezervuarlarının dinamik bir şekilde yönetilmesi gerektiğini ortaya koymaktadır. Hem yağış hem de su tüketimi verilerindeki bu öngörüler, su kaynaklarının daha sürdürülebilir bir şekilde yönetilmesine olanak sağlayacak stratejik planlamalar yapılması gerektiğini vurgulamaktadır.

Modellerin performansının değerlendirilmesi için kullanılan MAE ve RMSE gibi metrikler Linear Regression modelinin daha basit eğilimleri yakalamakta başarılı olduğunu, ancak daha karmaşık ve büyük dalgalanmalar içeren verilerde SVR ve XGBoost'un daha yüksek doğruluk sunduğunu göstermiştir. Özellikle XGBoost modeli, hem yağış hem de tüketim tahminlerinde daha iyi sonuçlar sergilemiş ve bu modelin gelecekteki su yönetimi tahminlerinde daha etkin bir şekilde kullanılabileceğine işaret etmiştir.

İstanbul'un gelecekteki su arz ve talep dengelerinin daha etkin yönetilebilmesi için yenilikçi su üretim ve tasarruf teknolojilerinin uygulanması önemlidir. Güneş enerjisiyle çalışan atmosferik su çıkarma sistemi (SAWE) gibi yenilikçi teknolojiler, su kıtlığı riskini azaltmak ve su kaynaklarının sürdürülebilirliğini sağlamak açısından düşük maliyetli çözümler sunabilir. Ayrıca deniz suyu arıtma, yağmur suyu toplama ve yeraltı suyu yönetimi gibi alternatif su üretim yöntemlerinin entegre bir şekilde değerlendirilmesi gerekmektedir.

Sonuç olarak bu çalışma, İstanbul'un su yönetimi politikalarının gelecekteki iklim değişikliği, nüfus artışı ve su talebi gibi faktörlere uyum sağlayacak şekilde şekillendirilmesi gerektiğini göstermektedir. Elde edilen bulgular, hem kısa hem de uzun vadeli su yönetimi stratejilerinin belirlenmesine ışık tutmakta ve su kaynaklarının daha sürdürülebilir bir şekilde korunmasına yönelik önemli çıkarımlar sunmaktadır. Gelecekte yapılacak çalışmalarda, bu modellemelerin daha geniş verisetleri ve farklı bölgeler için uygulanarak doğrulanması ve bu sayede su yönetimi politikalarının daha da geliştirilmesi hedeflenmektedir.

Kaynaklar

- Akbaş, A. (2005). *İstanbul su kaynaklarının incelenmesi Yeşilçay ve Melen sistemlerinin ekonomik yönden değerlendirilmesi* (Yüksek Lisans Tezi) İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Boudhaouia, A. & Wira, P. (2021). A real-time data analysis platform for short-term water consumption forecasting with machine learning. *Forecasting*, 3(4): 682–694.
- Chen, T., He, T., Benesty, M. and Khotilovich, V. (2019). Package ‘xgboost’. *R version*, 90(1–66): 40.
- Efe, E., Özcan, M. and Haklı, H. (2021). Building and Cost Analysis of an Industrial Automation System using Industrial Robots and PLC Integration. *Avrupa Bilim ve Teknoloji Dergisi*, (28): 1–10.
- Efe, E. & Özşen, S. (2022). Comparison of Time-Frequency Analyzes for a Sleep Staging Application with CNN. *Journal of Biomimetics, Biomaterials and Biomedical Engineering*, 55: 109–130.
- Efe, E. & Yavsan, E. (2024). AttBiLFNet: A novel hybrid network for accurate and efficient arrhythmia detection in imbalanced ECG signals. *Mathematical Biosciences and Engineering*, 21(4): 5863–5880.
- El Bilali, A., Abdeslam, T., Ayoub, N., Lamane, H., Ezzaouini, M. A. and Elbeltagi, A. (2023). An interpretable machine learning approach based on DNN, SVR, Extra Tree, and XGBoost models for predicting daily pan evaporation. *Journal of Environmental Management*, 327: 116890.
- Firat, M., Yurdusev, M. A. and Turan, M. E. (2009). Evaluation of artificial neural network techniques for municipal water consumption modeling. *Water resources management*, 23: 617–632.
- Henrique, B. M., Sobreiro, V. A. and Kimura, H. (2019). Literature review: Machine learning techniques applied to financial market prediction. *Expert Systems with Applications*, 124: 226–251.
- Kesornsit, W. & Sirisathitkul, Y. (2022). Water consumption prediction based on machine learning methods and public data. *Advances in Computational Design*, 7(2): 113–128.

- Montgomery, D. C., Peck, E. A. and Vining, G. G. (2021). Introduction to linear regression analysis. *John Wiley & Sons*.
- Nalici, M. E. & Akbaş, A. (2022). Forecasting of Occupancy Rate of Dams in İstanbul. *Avrupa Bilim ve Teknoloji Dergisi*, (41): 229–239.
- Orhan, H. & YAVŞAN, E. (2023). Artificial intelligence-assisted detection model for melanoma diagnosis using deep learning techniques. *Mathematical Modelling and Numerical Simulation with Applications*, 3(2): 159–169.
- Ribeiro, M. H. D. M., Da Silva, R. G., Larcher, J. H. K., De Lima, J. D., Mariani, V. C. and Coelho, L. D. S. (2021). Seasonal-trend and multiobjective ensemble learning model for water consumption forecasting; IEEE. *International Joint Conference on Neural Networks*. (IJCNN). 18-22 July, P.1-8. Virtual Conference.
- Saphioğlu, K., Şenel, F. A. and Topçu, F. (2017). Yapay Arı Kolonisi ile Hazne Kapasitesinin Optimizasyonu: Köprüçay Örneği. *Harran Üniversitesi Mühendislik Dergisi*, 2(2): 101–108.
- Shan, S., Ni, H., Chen, G., Lin, X. and Li, J. (2023). A machine learning framework for enhancing short-term water demand forecasting using attention-biLSTM networks integrated with XGBoost residual correction. *Water*, 15(20): 3605.
- Turoğlu, H. (2019). İstanbul'un su yönetimi riskleri. *1st Istanbul International Geography Congress Proceedings Book*, Turkey.
- Wijesiri, B., Liu, A. and Goonetilleke, A. (2020). Impact of global warming on urban stormwater quality: From the perspective of an alternative water resource. *Journal of Cleaner Production*, 262: 121330.
- Yang, K., Pan, T., Ferhat, N., Felix, A. I., Waller, R. E., Hong, P.-Y., ... and Han, Y. (2024). A solar-driven atmospheric water extractor for off-grid freshwater generation and irrigation. *Nature Communications*, 15(1): 6260.
- Yilmaz, F., Ulusoy, I. and Toros, H. (2020). Temporal analysis of Istanbul Water Reservoir levels and suggestions for solution. *Journal of Research in Atmospheric Science*, 2(2): 51–55.
- Yıldız, D. (2021). İSTANBUL'UN 90 YILLIK YAĞIŞLARI VE MGM 'nin Türkiye Kuraklık Haritaları. *Water Policy Association*, Turkey.

BÖLÜM 4

KURUMSAL BİLGİ GÜVENLİĞİ İÇİN ÇOK KATMANLI BİR GÜVENLİK YAPISI TASARIMI

¹Dr. Öğr. Üyesi. Mehmet Ali YALÇINKAYA

¹ Kırşehir Ahi Evran Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar
Mühendisliği Bölümü, Kırşehir, Türkiye
ORCID: 0000-0002-7320-5643, mehmetyalcinkaya@ahievran.edu.tr

Giriş

Kurumsal bilgi güvenliği, günümüz dijital dünyasında kuruluşların varlıklarını korumak ve iş sürekliliğini sağlamak açısından kritik bir role sahiptir. Gelişen teknoloji ile birlikte artan veri akışı ve dijitalleşme süreçleri, siber tehditlerin daha karmaşık ve yaygın hale gelmesine neden olmuştur. Şirketler, müşteri bilgileri, finansal veriler, iş stratejileri ve diğer kritik bilgiler gibi varlıklarını koruma sorumluluğundadır. Bu varlıkların güvenliği ihlal edildiğinde, yalnızca finansal kayıplar değil, aynı zamanda itibar zedelenmesi, müşteri güveninin kaybı ve yasal yaptırımlar gibi ciddi sonuçlarla karşılaşılabilir (Schatz, Bashroush ve Wall, 2017).

Bilgi güvenliğinin temel amacı, verilerin gizliliğini, bütünlüğünü ve erişilebilirliğini sağlamak olarak tanımlanabilir. Ancak, bilgi güvenliği yalnızca teknik bir mesele değil, aynı zamanda organizasyonel bir sorumluluk olarak da ele alınmalıdır. Her ne kadar teknik çözümler bu alanda önemli rol oynasa da, insan faktörü, güvenlik politikaları ve farkındalık eğitimi gibi unsurların da aynı derecede önemi bulunmaktadır (Von Solms ve Van Niekerk, 2013).

Bu çalışmanın temel amacı, kurumsal bilgi güvenliğini sağlamak için çok katmanlı bir güvenlik yapısının nasıl tasarlanabileceğini incelemektir. Çok katmanlı bir güvenlik yapısı, farklı güvenlik önlemlerinin bir arada kullanılmasıyla güvenlik tehditlerine karşı daha güçlü bir savunma sağlar. Bu çalışmada, ISO 27001 standardı çerçevesinde bir Bilgi Güvenliği Yönetim Sistemi (BGYS) kurulumu, erişim kontrol sistemleri, ağ güvenliği ve farkındalık eğitimi gibi çeşitli güvenlik katmanları ele alınacaktır. Bu yaklaşımla amaç, kuruluşların

bilgi güvenliği tehditlerine karşı proaktif bir savunma mekanizması oluşturmasına katkı sağlamaktır.

Çalışmada ilk olarak, Bilgi Güvenliği Yönetim Sistemi (BGYS) Kurulumu başlığı altında, ISO 27001 standardının detayları ele alınacak ve risk yönetimi stratejilerinin nasıl uygulanacağı açıklanacaktır. Bu bölüm, kuruluşların güvenlik politikalarını nasıl oluşturabilecekleri ve mevcut riskleri nasıl değerlendirebileceklerine dair rehberlik sunacaktır. Erişim Kontrol Sistemleri başlığında, yetkilendirme ve kimlik doğrulama süreçleri üzerinde durulacak; çok faktörlü kimlik doğrulama (MFA) gibi güvenlik önlemlerinin uygulanması ve kritik verilerin şifrenmesi konuları tartışılacaktır. Üçüncü olarak, Ağ Güvenliği ve Segmentasyonu bölümünde, güvenlik duvarları, saldırı tespit ve önleme sistemleri (IDS/IPS) gibi teknolojiler ile ağ segmentasyonu kavramı incelenecek ve bu güvenlik katmanlarının ağ altyapısında nasıl uygulanabileceği açıklanacaktır. Güvenlik Farkındalık Eğitimi başlığı, insan faktörünün güvenlik açıklarına neden olma potansiyelini ele alarak, personel eğitiminin önemini vurgulayacaktır. Bu kapsamda sosyal mühendislik saldırıları ve phishing testlerinin etkili kullanımı örneklendirilecektir. Bir sonraki bölüm olan Olay Müdahale ve Yedekleme Planları, olası güvenlik ihlalleri durumunda hızlı müdahale edilmesini sağlayacak planların nasıl hazırlanacağını ve veri yedekleme süreçlerinin nasıl yönetileceğini anlatacaktır. Zararlı Yazılımlara Karşı Koruma bölümünde, güncel antivirüs ve anti-malware yazılımlarının kullanımı ile güvenlik yamalarının önemi tartışılacaktır. Bu bölüm, zararlı yazılımlara karşı korunmanın teknik detaylarına odaklanacaktır. Veri Kaybı Önleme (DLP) Sistemleri başlığında, hassas verilerin

sızmasını önlemek için kullanılacak teknolojik çözümler üzerinde durulacaktır. E-posta ve bulut tabanlı sistemlerde veri kaybını engelleyen stratejiler detaylandırılacaktır. Son olarak, Yasal Uyum ve Denetim bölümünde, kurumsal bilgi güvenliği politikalarının yerel ve uluslararası yasal mevzuatlara (örneğin KVKK ve GDPR) nasıl uyumlu hale getirileceği ve düzenli denetim süreçlerinin nasıl yürütüleceği ele alınacaktır. Bu yapı, kurumsal bilgi güvenliği için gereken tüm unsurları kapsamlı bir şekilde ele almakta ve çok katmanlı güvenlik yaklaşımının nasıl entegre bir çözüm sunduğunu detaylandırmaktadır.

1. Bilgi Güvenliği Yönetim Sistemi (BGYS) Kurulumu

Bilgi Güvenliği Yönetim Sistemi (BGYS), kuruluşların bilgi varlıklarını güvence altına almak için oluşturduğu, sistematik bir yaklaşıma dayanan yönetim çerçevesidir. Bu sistem, bilgi güvenliği süreçlerini belirleyerek, tehditlere karşı koruma sağlamak, riskleri minimize etmek ve yasal uyumluluğu sağlamak amacıyla oluşturulmuştur (Humphreys, 2008). BGYS'nin temel amacı, bilgi varlıklarının gizliliğini, bütünlüğünü ve erişilebilirliğini korumak ve bu doğrultuda politika ve prosedürlerin oluşturulmasını sağlamaktır (ISO/IEC 27001, 2013).

BGYS, yalnızca teknik çözümlerden ibaret değildir; organizasyon genelinde politikaların, süreçlerin ve farkındalık programlarının uygulanmasını da kapsar. Bu nedenle BGYS, yönetimden çalışanlara kadar tüm kurumun dahil olduğu bir yapı oluşturur. Yönetim seviyesinde karar alma mekanizmalarının bilgi güvenliğiyle entegre edilmesi, sistemin başarısı açısından hayati önemdedir. ISO 27001 standardı, BGYS kurulumunun en yaygın kabul gören uluslararası standardıdır ve

kurumların sistematik bir risk yönetimi yaklaşımı ile bilgi güvenliğini sağlamasına yardımcı olur (Calder & Watkins, 2015).

BGYS kurulumu sırasında, bilgi güvenliği politikalarının oluşturulması ve uygulanması kritik bir adımdır. Bu politikalar, kuruluşun bilgi güvenliği hedeflerini ve stratejilerini belirlerken, aynı zamanda uyulması gereken kuralları ve sorumlulukları tanımlar. Politika oluşturulurken risk analizi süreçleri temel alınmalı ve tehditlere karşı alınacak önlemler net bir şekilde belirlenmelidir (Stallings & Brown, 2018).

Ayrıca, BGYS kurulumu sırasında sürekli iyileştirme süreci de göz önünde bulundurulmalıdır. Bu sistem, yalnızca statik bir yapı değil, sürekli izleme, değerlendirme ve güncellemeyi gerektiren dinamik bir süreçtir. İç ve dış denetimlerle sistemin etkinliği düzenli olarak gözden geçirilmelidir (Polizzi ve Scanella, 2023). Bu yaklaşım, BGYS'nin sadece anlık çözümler sunmasını değil, sürekli gelişen tehdit ortamına karşı esnek ve sürdürülebilir olmasını sağlar. Bilgi güvenliği yönetim sistemi kurulumu kapsamında ISO 27001 standardının ve risk yönetim sürecinin benimsenmesi ve uygulanması gerekmektedir.

1.1. ISO 27001 Standardı

ISO 27001 standardı, bilgi güvenliği yönetim sistemlerinin (BGYS) kurulması ve işletilmesi için dünya çapında kabul gören uluslararası bir standarttır. Bu standart, kuruluşların bilgi varlıklarını koruma altına alarak risk yönetimi süreçlerini sistematik bir şekilde uygulamasını amaçlar (ISO/IEC 27001, 2013). ISO 27001, bilgi güvenliğinin sağlanması için gerekli olan politikaların, süreçlerin ve kontrollerin uygulanmasına rehberlik eder ve böylece kurumların bilgi

güvenliği tehditlerine karşı hazırlıklı olmasını sağlar (Humphreys, 2008).

ISO 27001 standardı, bilgi güvenliğinin üç temel unsurunu korumaya yönelik stratejiler sunar: gizlilik, bütünlük ve erişilebilirlik. Gizlilik, bilgilere yalnızca yetkili kişilerin erişmesini sağlar; bütünlük, bilgilerin doğruluğunu ve tamlığını korur; erişilebilirlik ise yetkili kişilerin bilgilere ihtiyaç duyduklarında ulaşabilmesini garanti eder (Calder & Watkins, 2015). Bu üç unsur, bilgi güvenliğinin her alanında standart kapsamında düzenlenir ve kontrol edilir.

ISO 27001, bir kurumun BGYS'sini etkin bir şekilde yönetebilmesi için "Planla-Uygula-Kontrol Et-Önlem A1" (PUKÖ) döngüsüne dayanır. Bu döngü, sürekli iyileştirmeyi hedefleyerek BGYS'nin güncel tehditlere karşı etkinliğini sürekli kılar (Stallings & Brown, 2018). İlk aşama olan "Planla", bilgi güvenliği hedeflerinin ve risk yönetimi stratejilerinin belirlenmesini içerir. "Uygula" aşaması, bu hedeflerin ve stratejilerin hayata geçirilmesini sağlarken, "Kontrol Et" aşaması, uygulamaların etkinliğinin ölçülmesi ve değerlendirilmesini kapsar. Son aşama olan "Önlem A1" ise tespit edilen eksikliklerin düzeltilmesini ve sistemin sürekli iyileştirilmesini sağlar (ISO/IEC 27001, 2013).

ISO 27001 standardının bir diğer önemli özelliği, risk bazlı bir yaklaşımı benimsemesidir. Bu, kurumların bilgi güvenliği risklerini tanımlamasını, bu riskleri önceliklendirmesini ve uygun güvenlik kontrollerini uygulamasını sağlar. ISO 27002 gibi ek rehber dokümanlar da bu süreçte hangi güvenlik kontrollerinin uygulanacağına dair ayrıntılı bilgi sağlar (ISO/IEC 27002, 2013).

ISO 27001'in uyum süreci, kuruluşlar için önemli avantajlar sunar. Standart, yalnızca yasal ve düzenleyici gereklilikleri karşılamakla kalmaz, aynı zamanda müşterilere ve paydaşlara bilgi güvenliği açısından güven verir. Standart, bilgi güvenliği yönetimini yapılandırırken, aynı zamanda uluslararası iş birliklerinde güven inşa edilmesine yardımcı olur (Calder & Watkins, 2015). Böylelikle, ISO 27001 uyumu, kuruluşların itibarını ve rekabet gücünü artıran bir unsura dönüşür.

1.2. Risk Yönetimi

Risk yönetimi, bilgi güvenliği yönetim sistemlerinin (BGYS) en kritik bileşenlerinden biridir ve kurumların karşı karşıya kaldığı bilgi güvenliği tehditlerini tanımlama, değerlendirme ve bu tehditlere karşı uygun stratejileri geliştirme sürecini kapsar (Calder & Watkins, 2015). Bu süreç, kurumların bilgi varlıklarını güvence altına almak için potansiyel tehditleri, zafiyetleri ve bu tehditlerin iş süreçlerine olan olası etkilerini belirlemesine olanak tanır (ISO/IEC 27005, 2018). Risk yönetimi, ISO 27001 standardının merkezi bir unsuru olarak, sistematik bir risk değerlendirmesi ve uygun kontrol önlemlerinin uygulanmasını gerektirir.

Risk yönetimi süreci genellikle beş ana aşamadan oluşur: risk tanımlama, risk analizi, risk değerlendirmesi, riskin kontrol altına alınması ve sürekli izleme. Risk tanımlama aşamasında, kuruluşun bilgi varlıkları ve bu varlıklara yönelik tehditler belirlenir. Bu tehditler hem iç hem de dış kaynaklı olabilir; örneğin, siber saldırılar, sosyal mühendislik veya doğal afetler gibi (Stallings & Brown, 2018). Risk analizi aşamasında, tanımlanan her bir tehdidin, bilgi varlıkları üzerindeki

potansiyel etkisi ve olasılığı değerlendirilir. Bu değerlendirme, riskin iş süreçlerine olan olumsuz etkisini ölçmeyi ve önceliklendirmeyi sağlar (Böhme & Schwartz, 2010).

Risk değerlendirmesi, analiz edilen risklerin kabul edilebilir olup olmadığına karar verilen aşamadır. ISO 27001'e göre, risklerin kabul edilebilir seviyede olup olmadığını belirlemek için kurumun risk iştahı göz önünde bulundurulur (ISO/IEC 27005, 2018). Risk iştahı, kurumun hangi düzeydeki riskleri kabul edebileceğini tanımlar ve bu doğrultuda kararlar alınır. Eğer bir risk kabul edilemez seviyede bulunursa, riskin kontrol altına alınması için stratejiler geliştirilir. Bu stratejiler arasında riskin azaltılması, riske karşı sigorta yapılması veya riskten tamamen kaçınma gibi önlemler bulunur (Humphreys, 2008).

ISO 27001 standardı, risklerin azaltılması için uygulanabilecek uygun güvenlik kontrollerinin seçilmesini de kapsar. ISO 27002 standardı, bu güvenlik kontrollerinin nasıl uygulanacağına dair ek rehberlik sağlar (ISO/IEC 27002, 2013). Kontrollerin belirlenmesi ve uygulanması aşamasında, tehditlerin ve zafiyetlerin büyüklüğüne göre doğru önlemler alınmalıdır. Örneğin, bir kuruluşun kritik verileri için şifreleme kullanmak, veri kaybı ve yetkisiz erişim risklerini minimize edebilir.

Risk yönetimi, bir defaya mahsus yapılan bir işlem değil, sürekli izlenmesi ve güncellenmesi gereken bir süreçtir. Tehdit ortamı sürekli değiştiği için, risklerin sürekli izlenmesi ve risk yönetim planlarının buna göre güncellenmesi gerekir (Peltier, 2016). Bu nedenle, BGYS'nin etkinliği düzenli iç ve dış denetimlerle gözden geçirilerek risklerin kontrol altında tutulması sağlanmalıdır (Malaescu ve Steve, 2015).

2. Erişim Kontrol Sistemleri

Erişim kontrol sistemleri, bir kuruluşun bilgi varlıklarına erişimin yönetilmesi ve korunmasında kritik bir rol oynar. Bilgi güvenliği yönetim sisteminin (BGYS) temel unsurlarından biri olan bu sistemler, yalnızca yetkili kişilerin belirli bilgilere ve sistemlere erişebilmesini sağlar (Stallings & Brown, 2018). Erişim kontrolü, bilginin gizliliğini, bütünlüğünü ve erişilebilirliğini koruma ilkelerini destekleyen önemli bir güvenlik katmanıdır (ISO/IEC 27002, 2013).

Erişim kontrol sistemlerinin temel amacı, kullanıcının kimliğini doğrulamak, yetkilendirme süreçlerini yönetmek ve kullanıcıların sadece yetkili oldukları bilgilere erişmelerini sağlamaktır (Bertino & Sandhu, 2005). Bu amaçla kullanılan kimlik doğrulama yöntemleri, kullanıcıların kimliklerini kanıtlamaları için çeşitli doğrulama faktörlerini içerir. Bu doğrulama faktörleri arasında şifreler, biyometrik veriler, akıllı kartlar ve iki faktörlü kimlik doğrulama (2FA) veya çok faktörlü kimlik doğrulama (MFA) gibi güvenlik yöntemleri yer alır (He ve Wang, 2014).

Erişim kontrol politikaları, kullanıcıların rollerine, sorumluluklarına ve iş ihtiyaçlarına göre yapılandırılmalıdır. Bu kapsamda, Role Dayalı Erişim Kontrolü (Role-Based Access Control - RBAC), geniş çapta kullanılan bir modeldir. RBAC, kullanıcılara belirli roller atayarak, bu rollerin sahip olduğu yetkiler dahilinde erişim hakları tanımlar. Bu model, büyük organizasyonlarda erişim haklarının merkezi bir şekilde yönetilmesini kolaylaştırır ve veri güvenliği risklerini azaltır (Ferraiolo & Kuhn, 1992).

Modern erişim kontrol sistemleri, siber güvenlik tehditlerinin gelişmesiyle birlikte sürekli olarak güncellenmekte ve daha karmaşık

hale gelmektedir. Özellikle bulut tabanlı sistemlerin yaygınlaşması, erişim kontrol teknolojilerinin daha dinamik ve esnek olmasını gerektirmiştir (Almorsy, Grundy, & Müller, 2016). Bulut sistemlerinde erişim kontrolleri hem kullanıcıların güvenliğini sağlamak hem de uzaktan erişim senaryolarını güvenli bir şekilde yönetmek için gelişmiş kimlik doğrulama mekanizmalarına dayanır.

Sonuç olarak, erişim kontrol sistemleri, bilgi varlıklarının güvenliğini sağlamak için kritik bir yapı taşıdır. Bu sistemler, yetkilendirme ve kimlik doğrulama süreçlerinin yanı sıra, kritik verilerin şifrelenmesi işlemini kapsar. Gelişen teknolojiyle birlikte, erişim kontrol sistemlerinin de evrilmesi ve yeni tehditlere karşı güçlü bir savunma mekanizması sunması gerekmektedir.

2.1. Kimlik Doğrulama ve Yetkilendirme

Kimlik doğrulama ve yetkilendirme, bilgi güvenliğinin temel yapı taşlarından biri olarak, bir kullanıcının kimliğini doğrulamak ve bu kullanıcının belirli kaynaklara erişim haklarını yönetmek için kritik süreçlerdir (Stallings & Brown, 2018). Kimlik doğrulama, bir kullanıcının sistemlere erişim talep ettiğinde kimliğini kanıtlaması sürecidir. Yetkilendirme ise doğrulanmış bir kimliğin hangi kaynaklara, verilere veya hizmetlere erişim yetkisine sahip olduğunu belirleyen mekanizmadır (Bertino & Sandhu, 2005).

Kimlik doğrulama, kullanıcının kimliğini belirlemek için genellikle birden fazla doğrulama faktörüne dayanır. Bu faktörler üç ana kategoride toplanır: bilinen bir şey (şifre veya PIN), sahip olunan bir şey (akıllı kart, güvenlik tokeni) ve biyometrik veri (parmak izi, retina taraması). Günümüzde en yaygın kullanılan yöntemler arasında çok

faktörlü kimlik doğrulama (MFA) ve iki faktörlü kimlik doğrulama (2FA) bulunmaktadır. MFA, bir kullanıcının birden fazla doğrulama faktörünü kullanarak kimliğini kanıtlamasını zorunlu kılar ve böylece kimlik doğrulama sürecini daha güvenli hale getirir (Song vd., 2018).

Kimlik doğrulamanın etkinliği, kullanılan faktörlerin karmaşıklığına ve güvenilirliğine bağlıdır. Şifreler yaygın olarak kullanılan bir kimlik doğrulama yöntemi, siber saldırılar ve şifre çalma girişimlerine karşı zayıf kalabilirler. Bu nedenle biyometrik veriler veya akıllı kartlar gibi fiziksel faktörlerin kullanımı, güvenlik risklerini azaltma açısından daha güvenilir bir çözüm sunar (Almorsy, Grundy & Müller, 2016).

Yetkilendirme süreci ise, bir kullanıcının hangi verilere ve kaynaklara erişebileceğini belirler. Bu süreçte genellikle Role-Based Access Control (RBAC) ve Attribute-Based Access Control (ABAC) gibi erişim kontrol modelleri kullanılır (Ferraiolo & Kuhn, 1992). RBAC, kullanıcılara belirli roller atayarak bu rollerin sahip olduğu yetkiler doğrultusunda erişim sağlar. ABAC ise daha esnek bir model olup, kullanıcının belirli özelliklerine, çevresel koşullara veya erişim taleplerine göre dinamik yetkilendirme sunar (Hu, Ferraiolo & Kuhn, 2015).

Yetkilendirme politikaları, bilgi güvenliğini sağlamak için kritik öneme sahiptir. Doğru bir yetkilendirme süreci, kullanıcıların yalnızca ihtiyaç duydukları bilgilere erişmesini sağlarken, yetkisiz erişimleri önler. Özellikle hassas verilerin korunmasında, kullanıcılara verilen erişim haklarının düzenli olarak gözden geçirilmesi ve denetlenmesi gerekmektedir (Stallings & Brown, 2018).

Özetlemek gerekirse, kimlik doğrulama ve yetkilendirme, bir kuruluşun bilgi varlıklarını korumak için güçlü ve entegre bir güvenlik mekanizması sağlar. Bu süreçlerin başarısı, doğru teknolojilerin, politikaların ve sürekli iyileştirme süreçlerinin uygulanmasına bağlıdır. Gelişen siber tehdit ortamı göz önüne alındığında, kimlik doğrulama ve yetkilendirme sistemlerinin düzenli olarak güncellenmesi ve güçlendirilmesi kritik önem taşımaktadır.

2.2. Kritik Verilerin Şifrelenmesi

Kritik verilerin şifrelenmesi, bilgi güvenliği stratejilerinin temel unsurlarından biridir ve verilerin gizliliğini korumak amacıyla kullanılan en etkili yöntemlerden biri olarak kabul edilir. Şifreleme, verilerin yetkisiz kişiler tarafından okunmasını önlemek için verileri okunamaz bir formata dönüştüren bir süreçtir (Stallings, 2017). Bu yöntem, özellikle hassas bilgilerin korunmasında, veri aktarımı ve depolama süreçlerinde kritik rol oynar.

Şifreleme, iki ana bileşenden oluşur: simetrik ve asimetrik şifreleme. Simetrik şifreleme yöntemlerinde hem şifreleme hem de şifre çözme işlemleri için aynı anahtar kullanılır. Bu yöntem hızlı ve basit olmasına rağmen, anahtarın güvenli bir şekilde iletilmesi zorluk yaratabilir. Buna karşın asimetrik şifreleme yöntemlerinde, bir çift anahtar kullanılır: birisi şifreleme için (genel anahtar), diğeri ise şifre çözme için (özel anahtar). Bu yöntem, anahtar yönetimi açısından daha güvenli olsa da simetrik şifrelemeye göre daha yavaş olabilir (Katz & Lindell, 2014).

Kritik verilerin şifrelenmesi, yalnızca veri ihlallerini önlemekle kalmaz, aynı zamanda yasal ve düzenleyici gereklilikleri yerine

getirmeye de yardımcı olur. Örneğin, Kişisel Verilerin Korunması Kanunu (KVKK) ve Genel Veri Koruma Yönetmeliği (GDPR) gibi yasal düzenlemeler, kişisel verilerin korunması için gerekli şifreleme yöntemlerinin kullanılmasını zorunlu kılar (Voigt & Von dem Bussche, 2017). Şifreleme, hem verilerin depolandığı sistemlerde (durumsal veri şifrelemesi) hem de veri aktarımı sırasında (iletim sırasındaki şifreleme) uygulanabilir.

Şifreleme teknolojilerinde kullanılan protokoller de güvenliği sağlama açısından büyük öneme sahiptir. Özellikle veri iletimi sırasında kullanılan Secure Sockets Layer (SSL) ve Transport Layer Security (TLS) protokolleri, verilerin güvenli bir şekilde aktarılmasını sağlar. Bu protokoller, şifreleme algoritmaları kullanarak ağ üzerindeki veri akışını koruma altına alır ve yetkisiz erişimlere karşı bir savunma mekanizması oluşturur (Rescorla, 2001).

Kritik verilerin korunmasında şifreleme politikalarının doğru bir şekilde uygulanması büyük önem taşır. Verilerin sınıflandırılması, hangi bilgilerin şifrelenmesi gerektiğini belirlemeye yardımcı olur. Hassas bilgiler (örneğin, finansal veriler, müşteri bilgileri, sağlık kayıtları) genellikle öncelikli olarak şifrelenmelidir. Ayrıca, şifreleme anahtarlarının yönetimi de güvenliğin devamlılığı açısından kritik bir süreçtir. Anahtarların güvenli bir şekilde saklanması ve düzenli olarak yenilenmesi, olası güvenlik açıklarını önlemeye katkıda bulunur (Kessler, 2019).

Kritik verilerin şifrelenmesi, modern bilgi güvenliği sistemlerinin ayrılmaz bir parçasıdır. Şifreleme teknolojileri, veri ihlallerine karşı güçlü bir savunma sağlarken, yasal uyum gereksinimlerini de karşılar.

Gelişen teknoloji ve artan siber tehditler göz önünde bulundurulduğunda, şifreleme politikalarının düzenli olarak gözden geçirilmesi ve güvenlik standartlarına uygun hale getirilmesi gerekmektedir.

3. Ağ Güvenliği ve Segmentasyonu

Ağ güvenliği, bir kuruluşun bilgi varlıklarını koruma stratejisinde en temel unsurlardan biridir. Dijitalleşme süreciyle birlikte kurumsal ağlar daha karmaşık hale gelmiş, bu da ağ güvenliğinin önemini artırmıştır. Ağ güvenliği, sistemlerin, cihazların ve verilerin siber tehditlere karşı korunmasını sağlayarak ağdaki iletişim kanallarını güvenli tutmayı amaçlar (Stallings & Brown, 2018). Modern siber tehditlerin artmasıyla birlikte, kurumsal ağların korunmasında yalnızca güvenlik duvarları veya saldırı tespit sistemleri (IDS/IPS) yeterli olmamaktadır; daha gelişmiş ve çok katmanlı güvenlik çözümleri gereklidir.

Ağ güvenliğinin temel amacı, kurum içi ve dışı tehditlerin belirlenmesi, bu tehditlere karşı önleyici tedbirler alınması ve saldırıların başarılı olması durumunda hızlı müdahale imkânı sağlamaktır (Hong-pin, 2009). Kurumsal ağlar, birden fazla bileşeni ve sistemi birbirine bağladığı için, saldırıya uğrama riski taşır. Özellikle ağ trafiğinin izlenmesi, şüpheli aktivitelerin tespit edilmesi ve ağ yapılandırmasının güvenlik risklerine göre optimize edilmesi, etkin bir ağ güvenliğinin temel unsurlarıdır (Ramaiah vd., 2018).

Bu kapsamda, ağ segmentasyonu, ağ güvenliğini güçlendirmek için sıkça kullanılan bir stratejidir. Ağ segmentasyonu, ağı daha küçük ve izole edilmiş bölümlere ayırarak, kritik sistemlerin ve hassas verilerin korunmasını sağlar. Segmentasyon, yalnızca belirli kullanıcıların ve

sistemlerin kritik ağ bölümlerine erişimine izin verir ve böylece bir saldırının ağın tamamına yayılmasını engeller (Lippmann ve ark., 2005). Özellikle, ağ segmentasyonu uygulamaları sayesinde, bir bölgedeki güvenlik ihlali, diğer ağ segmentlerini etkilemeden izole edilebilir ve müdahale süresi kısaltılır.

Bu bilgiler ışığında ilk olarak, kurumsal bilgi güvenliğini sağlamada kullanılan güvenlik duvarı ve saldırı tespit/önleme sistemleri, daha sonra da ağ segmentasyonu konusu ele alınacaktır.

3.1. Güvenlik Duvarı ve Saldırı Tespit/Önleme Sistemleri

Güvenlik duvarı ve saldırı tespit/önleme sistemleri (IDS/IPS), kurumsal ağ güvenliğinin kritik bileşenleri arasında yer alır. Güvenlik duvarları, ağ trafiğini izleyerek, belirlenen kurallara göre trafiğin hangi kısımlarının kabul edileceğine veya reddedileceğine karar verirken; saldırı tespit sistemleri (IDS) ve saldırı önleme sistemleri (IPS) ise şüpheli veya zararlı faaliyetleri tanımlar ve bunlara karşı proaktif önlemler alır (Stallings & Brown, 2018).

Güvenlik duvarları, hem dış tehditlere karşı bir bariyer oluşturur hem de iç ağın bölümlerini birbirinden izole ederek izinsiz erişimleri sınırlar. Güvenlik duvarları iki ana türde sınıflandırılabilir: donanım tabanlı ve yazılım tabanlı güvenlik duvarları. Donanım tabanlı güvenlik duvarları genellikle daha yüksek performans sunarken, yazılım tabanlı güvenlik duvarları, esnekliği ve kolay yönetilebilirliği ile tercih edilir (Konikiewicz ve Markowski, 2017). Güvenlik duvarları, ağ trafiğini kontrol etmek için çeşitli yöntemler kullanır; bunlar arasında durumsal filtreleme (stateful filtering) ve proxy tabanlı filtreleme yer alır. Durumsal filtreleme, paketlerin kaynağını ve hedefini izlerken, proxy

tabanlı filtreleme ise gelen trafiği ayrıntılı analiz ederek güvenli olup olmadığını değerlendirir (Youssef ve Bouhoula, 2011).

Ancak güvenlik duvarları, genellikle yalnızca trafiğin dışarıdan içeriye doğru olan kısmını kontrol eder. Bu nedenle, saldırı tespit sistemleri (IDS), ağda meydana gelen şüpheli faaliyetleri algılayarak güvenlik duvarlarının eksikliklerini tamamlar. IDS'ler, ağ üzerindeki trafiği sürekli izler ve olası saldırılara karşı bir alarm mekanizması sağlar (Wang vd., 2023). Saldırı tespit sistemleri genellikle iki türdür: imza tabanlı ve anomali tabanlı IDS'ler. İmza tabanlı sistemler, bilinen saldırı modellerine dayalı olarak şüpheli aktiviteleri tanımlar; anomali tabanlı sistemler ise normal ağ davranışından sapmaları tespit ederek potansiyel saldırıları belirler (Stallings & Brown, 2018).

Saldırı önleme sistemleri (IPS), IDS'lerin aksine, yalnızca saldırıları tespit etmekle kalmaz, aynı zamanda saldırı girişimlerini engellemek için aktif önlemler alır. IPS'ler, ağ trafiğini analiz eder ve zararlı trafiği tespit ettiklerinde bu trafiği otomatik olarak durdurur veya engeller (Pratama vd., 2018). Bu sistemler hem iç hem de dış tehditlere karşı ağın daha güvenli olmasını sağlar. IPS'ler genellikle güvenlik duvarlarıyla birlikte çalışarak, güvenlik politikalarının ihlali durumunda saldırıların yayılmasını engeller ve tehditlere karşı daha hızlı tepki verilmesini sağlar (Wang ve Li, 2013).

Güvenlik duvarları ve IDS/IPS sistemlerinin entegrasyonu, kurumsal ağların çok katmanlı bir güvenlik stratejisiyle korunmasına olanak tanır. Bu sistemler birlikte kullanıldığında, ağ güvenliği hem dış tehditlere karşı hem de iç tehditlere karşı daha dirençli hale gelir. Ayrıca, bu sistemlerin düzenli olarak güncellenmesi ve tehdit istihbaratı

verileriyle beslenmesi, modern siber saldırı tekniklerine karşı savunmanın etkinliğini artırır (Akujuobi ve Ampah, 2007).

Sonuç olarak, güvenlik duvarları ve saldırı tespit/önleme sistemleri, bir kurumun bilgi varlıklarını koruma açısından hayati öneme sahiptir. Gelişen tehdit ortamı göz önünde bulundurulduğunda, bu sistemlerin düzenli olarak izlenmesi, güncellenmesi ve tehditlere hızlı tepki verebilecek kapasiteye sahip olması gerekmektedir.

3.2. Ağ Segmentasyonu

Ağ segmentasyonu, kurumsal ağ güvenliğini güçlendirmek amacıyla kullanılan kritik bir stratejidir. Segmentasyon, büyük bir ağı daha küçük, izole bölümlere ayırarak, güvenliği artırmak ve yönetimi kolaylaştırmak için uygulanır. Ağ segmentasyonu, saldırılara karşı direnci artırırken, ağ içindeki farklı sistemler ve cihazlar arasındaki trafiğin kontrol edilmesini sağlar (Lippmann ve ark., 2005). Bu yöntem, özellikle kritik verilerin ve sistemlerin korunması için hayati bir önlem olarak kabul edilir.

Ağ segmentasyonu, ağdaki farklı bölümler arasında bir izolasyon oluşturarak, saldırıların bir bölümden diğerine yayılmasını önler. Bu sayede, herhangi bir güvenlik ihlali meydana geldiğinde, yalnızca ihlal edilen segment etkilenir ve diğer segmentler korunmuş olur (Stallings & Brown, 2018). Örneğin, bir kuruluşta finansal verilerin bulunduğu segment, genel kullanıcı verilerinin bulunduğu segmentten izole edilerek, yetkisiz erişimlerin önüne geçilebilir. Aynı şekilde, operasyonel sistemler ile yönetim sistemlerinin ayrılması da güvenlik risklerini minimize eder.

Ağ segmentasyonu genellikle Virtual Local Area Networks (VLAN) gibi teknolojiler kullanılarak gerçekleştirilir. VLAN'lar, fiziksel olarak aynı ağ üzerinde bulunan cihazların mantıksal olarak farklı ağ segmentlerine ayrılmasını sağlar. Bu mantıksal ayırım, güvenlik politikalarının her segment için ayrı olarak uygulanmasına olanak tanır. VLAN'lar ayrıca, ağ performansını artırmak ve yönetimi kolaylaştırmak için de kullanılır (Anyasi vd., 2018). Örneğin, bir kuruluş, çalışanların kişisel cihazlarını içeren bir VLAN ile kritik verilerin işlendiği kurumsal cihazların bulunduğu başka bir VLAN oluşturabilir. Böylelikle, bir segmentte yaşanan bir ihlal diğer segmentleri etkilemez.

Bir başka segmentasyon yöntemi ise mikro segmentasyon olarak bilinir. Mikro segmentasyon, geleneksel segmentasyon yöntemlerinden daha ayrıntılı bir güvenlik sağlamak için kullanılır. Her bir uygulama, cihaz veya hizmet için ayrı güvenlik politikaları uygulanarak, ağın en küçük bileşenlerine kadar güvenlik kontrolü sağlanır. Mikro segmentasyon, özellikle bulut bilişim ortamlarında ve veri merkezlerinde yaygın olarak kullanılmaktadır. Bu yöntem, ağ trafiğinin daha ayrıntılı izlenmesine olanak tanır ve her bir segmentin güvenliği ayrı ayrı optimize edilebilir (O'Connor ve ark., 2018).

Ağ segmentasyonu, ağ güvenliğini artırmanın yanı sıra yönetim kolaylığı da sağlar. Farklı segmentlere uygulanan güvenlik politikaları, ağdaki trafiğin izlenmesi ve yönetilmesi sürecini kolaylaştırır. Ayrıca, ağ segmentleri arasındaki veri trafiği, güvenlik gereksinimlerine göre optimize edilebilir, bu da ağ performansını artırır. Ancak segmentasyonun etkin bir şekilde uygulanabilmesi için, segmentler arası trafiğin güvenliğini sağlamak amacıyla güvenlik duvarları, erişim

kontrol sistemleri ve şifreleme gibi ek güvenlik çözümlerinin de kullanılması gerekir (Stallings & Brown, 2018).

Sonuç olarak, ağ segmentasyonu, kurumsal ağların güvenliğini artırmak ve yönetim süreçlerini optimize etmek için güçlü bir stratejidir. Segmentasyon sayesinde, ağ üzerindeki kritik sistemler izole edilerek, güvenlik açıkları minimuma indirgenir. Gelişen siber tehdit ortamında, ağ segmentasyonu stratejilerinin düzenli olarak gözden geçirilmesi ve güncellenmesi, güvenliğin sürdürülebilirliği açısından hayati önem taşımaktadır.

4. Kurum Personellerinin Siber Güvenlik Farkındalık Seviyelerinin Arttırılması

Kurum ve kuruluşlar tarafından alınmış, teknolojik güvenlik önlemleri ne kadar gelişmiş olursa olsun, insan hatası genellikle güvenlik ihlallerinin ana nedeni olarak karşımıza çıkmaktadır (Hadlington, 2017). Bu nedenle kurum çalışanların siber tehditler ve güvenlik politikaları hakkında bilinçlenmeleri ve kurumun bilgi güvenliği stratejisinde proaktif bir rol oynamaları büyük önem taşımaktadır.

Güvenlik farkındalığı, sadece çalışanların şifre yönetimi, kimlik doğrulama gibi teknik güvenlik önlemlerini nasıl kullanacaklarını bilmekten ibaret değildir. Aynı zamanda sosyal mühendislik saldırıları, kimlik avı (phishing) girişimleri, kötü niyetli yazılımlar ve diğer siber tehditler hakkında da bilgi sahibi olmalarını gerektirir. Özellikle sosyal mühendislik saldırıları, kurumsal güvenlik tehditlerinin büyük bir kısmını oluşturmaktadır ve çalışanların bu tür saldırılara karşı korunması, etkili bir güvenlik farkındalık eğitimi ve düzenli sosyal mühendislik testleri ile mümkündür (Mitnick & Simon, 2011).

4.1. Siber Güvenlik Farkındalık Eğitimleri

Siber güvenlik farkındalık eğitimleri, kurumsal bilgi güvenliği stratejisinin en önemli unsurlarından biridir ve çalışanların bilgi güvenliği farkındalığını artırarak, siber tehditlere karşı daha dirençli bir kurum kültürü oluşturmayı hedefler. Çoğu güvenlik ihlalinin temelinde insan hatası yer aldığından, teknik önlemler kadar etkili bir personel eğitimi de hayati önem taşır (Hadlington, 2017). Çalışanlar, siber tehditlerin sadece teknik değil, sosyal mühendislik gibi insan odaklı yönleriyle de mücadele edebilmelidir.

Bu eğitimlerde öncelik, çalışanların güvenlik politikalarına uygun davranmalarını sağlamaktır. Bu bağlamda, çalışanların güçlü şifre oluşturma ve yönetme, kimlik doğrulama yöntemlerini doğru kullanma ve güvenli cihaz kullanımı gibi temel güvenlik becerilerini öğrenmesi gerekir (Sommestad ve ark., 2014). Ayrıca, çalışanların siber tehditleri tanıma ve bu tehditlere karşı nasıl tepki verecekleri konusunda bilgi sahibi olmaları kritik öneme sahiptir. Örneğin, phishing e-postalarını ayırt etme, şüpheli bağlantılardan kaçınma ve sosyal mühendislik girişimlerine karşı dikkatli olma, personel eğitimlerinin odak noktaları arasında yer almalıdır.

Etkili bir personel eğitimi programı, yalnızca bir defaya mahsus gerçekleştirilen bir etkinlik olmamalıdır. Siber tehditler sürekli değiştiği için, güvenlik farkındalık eğitimlerinin düzenli olarak tekrarlanması ve güncellenmesi gerekmektedir (Alshaiikh, 2020). Eğitimler, çalışanların günlük iş süreçlerinde karşılaşılabilecekleri gerçekçi senaryolar üzerinden yürütülmeli ve her seviyeden çalışana hitap edecek şekilde uyarlanmalıdır. Üst yönetimden operasyonel çalışanlara kadar tüm

personelin bu eğitimlere katılması, bilgi güvenliğinin kurumsal bir sorumluluk olarak benimsenmesine yardımcı olur (Tsohou ve ark., 2015).

Simülasyonlar ve pratik testler, personel eğitiminin etkinliğini artıran unsurlardan biridir. Örneğin, düzenli olarak gerçekleştirilen kimlik avı (phishing) testleri, çalışanların bu tür saldırılara nasıl tepki verdiklerini ölçer ve eksik oldukları alanlarda ek eğitim sağlayarak güvenlik farkındalığını pekiştirir (Warkentin & Willison, 2009). Aynı şekilde, saldırı senaryoları ve güvenlik ihlali simülasyonları da çalışanların siber tehditlere karşı nasıl daha etkin bir şekilde tepki verebileceklerini öğretir.

Sürekli eğitim ve bilinçlendirme, personelin güvenlik tehditlerine karşı farkındalık seviyesini artırırken, aynı zamanda güvenlik kültürünün güçlenmesine katkı sağlar. Eğitim programları, çalışanların bilgi güvenliği konusundaki bilgi ve becerilerini sürekli olarak güncellemek için dijital araçlar, interaktif eğitim modülleri ve çevrimiçi kurslar gibi yenilikçi yöntemlerle desteklenmelidir (Herath & Rao, 2009). Bu sayede, çalışanlar siber tehditlere karşı her zaman tetikte kalacak ve güvenlik açıklarını en aza indirmek için bilinçli hareket edecektir.

Sonuç olarak, siber güvenlik farkındalık eğitimleri, kurumsal bilgi güvenliğinin başarısı için kritik bir unsurdur. Etkili bir eğitim programı, sadece teknik becerilerin geliştirilmesiyle sınırlı kalmamalı, aynı zamanda çalışanların güvenlik bilincini artırarak siber tehditlere karşı proaktif bir savunma mekanizması oluşturmalarını sağlamalıdır. Bu doğrultuda, sürekli güncellenen ve gerçekçi senaryolara dayalı eğitimler,

kurumların bilgi güvenliği risklerini minimize etmesine yardımcı olacaktır.

4.2. Phishing Testleri

Phishing (kimlik avı) saldırıları, günümüzde en yaygın kullanılan sosyal mühendislik saldırı yöntemlerinden biridir ve kuruluşların bilgi güvenliği tehditleri arasında önemli bir yer tutar. Bu saldırılar, kullanıcıları yanıltarak hassas bilgileri (şifreler, kredi kartı numaraları vb.) ele geçirmeyi hedefler. Phishing saldırılarının bu denli etkili olmasının temel sebebi, insan davranışlarını manipüle ederek güvenlik açığı yaratmasıdır (Sheng ve ark., 2010). Bu nedenle, phishing testleri, güvenlik farkındalık eğitimlerinin önemli bir parçası olarak kurumlarda düzenli olarak uygulanmalı ve çalışanların bu tür saldırılara karşı nasıl tepki verdikleri ölçülmelidir.

Phishing testleri, bir kurumun çalışanlarının kimlik avı saldırılarına karşı farkındalık seviyesini test etmek ve olası zayıf noktaları belirlemek için kullanılan etkili bir yöntemdir. Bu testler, çalışanlara sahte ama gerçekçi e-postalar gönderilerek kimlik avı girişimlerine nasıl tepki verdiklerini gözlemlemeyi amaçlar (Caputo ve ark., 2014). Gerçekçi senaryolar üzerinden gerçekleştirilen bu testler, çalışanların phishing saldırılarına karşı güvenlik bilinç düzeylerini artırır ve eksik oldukları konuları belirleyerek gerekli eğitimlerin verilmesine olanak tanır.

Phishing testlerinin amacı, çalışanların bu tür saldırıları tanıyabilme yeteneklerini geliştirmek ve yanlışlıkla hassas bilgileri ifşa etmelerinin önüne geçmektir. Çalışanlar, genellikle phishing e-postalarını güvenilir kaynaklardan gelen mesajlar olarak algıladıkları

için bu testler, gerçek saldırı senaryolarına karşı pratik yapma imkânı sunar (Parsons ve ark., 2015). Testlerde başarısız olan çalışanlar, hangi sinyalleri gözden kaçırdıklarını öğrenir ve gelecekte daha dikkatli olmaları sağlanır. Bu süreç, kurumların güvenlik açıklarını gidermek için etkili bir yol sunar.

Phishing testleri, aynı zamanda çalışanların kişisel sorumluluklarını anlamalarına da yardımcı olur. Kurum içi farkındalığın artması ve güvenlik kültürünün yaygınlaşması için bu testler düzenli olarak yapılmalıdır. Çalışanların bu tür testlerde başarılı olmaları, sadece kendi güvenlikleri için değil, aynı zamanda kurumsal bilgi varlıklarının korunması açısından da kritik öneme sahiptir (Alshaikh, 2020). Üstelik test sonuçları, üst yönetim ve güvenlik ekiplerine, bilgi güvenliği politikalarının ne kadar etkili olduğunu değerlendirme fırsatı sunar.

Ancak phishing testleri, yalnızca sonuçlara dayalı bir cezalandırma aracı olarak kullanılmamalıdır. Çalışanları motive etmek ve daha bilinçli bir güvenlik kültürü oluşturmak için bu testler, eğitim programlarının bir parçası olarak yapılandırılmalıdır (Jakobsson & Myers, 2006). Yanlış davranışları cezalandırmak yerine, çalışanlara doğru bilgi ve farkındalık sağlanmalı, böylece bu tür saldırılara karşı daha dirençli bir savunma hattı oluşturulmalıdır.

Sonuç olarak, phishing testleri, çalışanların siber tehditlere karşı farkındalığını artırmak ve güvenlik açıklarını tespit etmek için vazgeçilmez bir araçtır. Düzenli ve kapsamlı phishing testleri, kurumların güvenlik stratejilerini güçlendirmelerine ve çalışanların bu tür tehditlere karşı daha bilinçli bir şekilde hareket etmelerine yardımcı

olur. Bu nedenle, phishing testlerinin etkin bir güvenlik farkındalık programının temel bir unsuru olması gerekmektedir.

5. Olay Müdahale ve Yedekleme Planları

Olay müdahale ve yedekleme planları, kurumsal bilgi güvenliği yönetiminin kritik unsurlarındandır. Her ne kadar siber tehditlere karşı gelişmiş güvenlik önlemleri alınsa da, olası bir güvenlik ihlali durumunda etkin bir olay müdahale planına sahip olmak, zararların minimuma indirilmesi ve operasyonların hızlı bir şekilde normale döndürülmesi için gereklidir (Kävrestad, 2018). Aynı şekilde, düzenli ve güvenli bir yedekleme planı oluşturmak, veri kaybı riskine karşı güçlü bir savunma sağlar. Bu iki unsur, bilgi güvenliği yönetiminin proaktif ve reaktif yönlerini dengeleyen hayati araçlardır. Kurumların bu süreçleri etkin bir şekilde uygulamaları, veri kaybını ve operasyonel kesintileri minimuma indirerek bilgi güvenliği risklerini azaltır. Düzenli eğitimler, testler ve güncellemeler sayesinde, kurumlar bu planları sürekli geliştirebilir ve olası siber saldırılara karşı daha dayanıklı hale gelebilir.

5.1. Olay Müdahale Planı

Olay müdahale planı, bir güvenlik ihlali veya siber saldırı durumunda kurumların hızlı ve organize bir şekilde tepki vermesini sağlayan bir çerçevedir. Etkili bir olay müdahale planı, kurumun bilgi varlıklarını korumak, güvenlik ihlallerinin etkisini sınırlamak ve olay sonrasında operasyonların en kısa sürede normale dönmesini sağlamak için hayati öneme sahiptir (Lamis, 2010). Bu plan, güvenlik ihlallerinin sadece tespit edilmesini değil, aynı zamanda bu ihallere karşı proaktif ve stratejik adımlar atılmasını sağlar.

Olay müdahale süreci genellikle altı aşamadan oluşur: hazırlık, tespit, sınırlama, yok etme, kurtarma ve inceleme (SANS Institute, 2019). Hazırlık aşaması, olay müdahale ekiplerinin eğitilmesini, gerekli araç ve yazılımların hazırlanmasını ve olay anında nasıl hareket edileceğine dair prosedürlerin oluşturulmasını kapsar. Bu aşama, herhangi bir ihlal gerçekleşmeden önce yapılacak hazırlıkları ve senaryoların önceden belirlenmesini içerir. Hazırlık aşaması ne kadar kapsamlı olursa, olay anında müdahale o kadar hızlı ve etkili olur.

Tespit aşaması, olası bir güvenlik ihlalinin fark edilmesiyle başlar. Bu aşamada, saldırının veya anormal faaliyetin izlenmesi ve kimliklendirilmesi amaçlanır. Tespit sürecinde, saldırının hangi sistemler üzerinde gerçekleştiği ve hangi verilerin risk altında olduğu belirlenir. Güvenlik duvarları, saldırı tespit/önleme sistemleri (IDS/IPS) ve SIEM (Security Information and Event Management) sistemleri bu aşamada kritik bir rol oynar (Stallings & Brown, 2018).

Sınırlama aşaması, güvenlik ihlalinin yayılmasını önlemek amacıyla saldırının izole edilmesini hedefler. Bu aşamada, saldırının etkisini sınırlamak için sistemlere erişim kısıtlanır ve saldırının diğer sistemlere yayılması engellenir. Hızlı sınırlama, olay müdahalesinin başarısında kritik bir faktördür çünkü saldırının büyümesi engellenerek daha büyük zararın önüne geçilir (Kraemer ve ark., 2009).

Yok etme aşaması, saldırının kaynağının ortadan kaldırılması sürecidir. Bu aşamada, zararlı yazılım veya saldırı öğeleri sistemden temizlenir ve saldırının daha fazla zarar vermesi engellenir. Aynı zamanda, bu aşamada saldırının tekrar yaşanmaması için gerekli

güvenlik önlemleri de devreye alınır. Saldırı kaynağı sistemden tamamen temizlenmeden kurtarma aşamasına geçilmemelidir.

Kurtarma aşaması, sistemlerin normal operasyonlarına döndürülmesini içerir. Bu aşamada, sistemler yeniden yapılandırılır ve saldırı sırasında zarar görmüş veriler, yedeklerden geri yüklenir. Kurtarma aşaması, sistemlerin güvenli bir şekilde yeniden çalışır hale getirilmesi için dikkatli planlanmalıdır. Herhangi bir açık bırakılmaması adına, yeniden yapılandırılan sistemlerin güvenlik testlerine tabi tutulması önemlidir (Nelson ve ark., 2019).

Son aşama olan inceleme aşaması, saldırının neden ve nasıl gerçekleştiğinin analiz edilmesini içerir. Bu aşamada, olay müdahale sürecindeki eksiklikler değerlendirilir ve gelecekte benzer saldırıların önlenmesi için yeni güvenlik politikaları ve prosedürler geliştirilir. Ayrıca, olaydan elde edilen dersler, olay müdahale planlarının güncellenmesi ve iyileştirilmesi için kullanılmalıdır (SANS Institute, 2019).

Olay müdahale planının başarısı, sadece IT ekiplerinin müdahale hızıyla değil, tüm kurum genelinde benimsenmiş olan güvenlik farkındalığı ile de doğrudan ilişkilidir. Tüm çalışanlar, olay müdahale planlarının önemini kavramalı ve bu planlara uygun hareket etmelidir. Ayrıca, olay müdahale planlarının düzenli olarak gözden geçirilmesi, test edilmesi ve değişen tehdit ortamına göre güncellenmesi, planın etkinliğini artıracaktır (Thompson, 2018).

Sonuç olarak, olay müdahale planı, bilgi güvenliğinin korunması için kritik bir savunma mekanizmasıdır. Etkin bir olay müdahale planı, siber saldırılara karşı kurumun hızlı ve organize bir şekilde tepki

vermesini sağlar. Bu planların düzenli olarak test edilmesi, güvenlik ihlallerinin etkilerini minimize etmek ve kurumun güvenlik stratejilerini sürekli iyileştirmek için hayati öneme sahiptir.

5.2. Veri Yedekleme

Veri yedekleme, kurumsal bilgi güvenliği stratejisinin temel unsurlarından biridir ve kritik verilerin kaybına karşı en etkili savunma mekanizmalarından birini oluşturur. Veri kayıpları; donanım arızaları, siber saldırılar, insan hataları veya doğal felaketler gibi birçok sebepten kaynaklanabilir. Bu nedenle, her kurumun sistematik ve güvenli bir yedekleme planı oluşturması hayati önem taşır (Nelson ve ark., 2019). Etkili bir yedekleme stratejisi, verilerin hızlı ve güvenli bir şekilde geri yüklenmesini sağlayarak operasyonel sürekliliği teminat altına alır.

Veri yedekleme yöntemleri, genellikle üç ana kategoriye ayrılır: tam yedekleme, artımlı yedekleme ve fark yedekleme. Tam yedekleme, tüm sistemin veya veritabanının tamamen yedeklenmesini içerir. Bu yöntem, en kapsamlı veri yedekleme şeklidir, ancak zaman alıcı olabilir ve büyük miktarda depolama alanı gerektirir (Nakamura vd., 2017). Artımlı yedekleme, yalnızca son yedeklemeden bu yana değişen verileri yedekler. Bu yöntem, daha az depolama alanı kullanırken yedekleme süresini de kısaltır. Fark yedekleme ise, son tam yedeklemeden bu yana değişen tüm verileri yedekler, böylece artımlı yedeklemenin avantajlarını sunarken, veri geri yükleme sürecini hızlandırır (Nelson ve ark., 2019).

Güvenilir bir yedekleme planı oluşturmanın temel unsurlarından biri, yedeklerin güvenli bir şekilde saklanması ve düzenli olarak test edilmesidir. Verilerin şifrelenmiş bir ortamda saklanması, yedeklerin

fiziksel çalınma veya yetkisiz erişime karşı korunmasını sağlar. Özellikle bulut tabanlı yedekleme hizmetleri, verilerin güvenli bir şekilde uzak sunucularda depolanmasını ve ihtiyaç duyulduğunda erişilebilmesini mümkün kılar (Guo vd., 2023). Bunun yanı sıra, yedekleme planlarının düzenli olarak test edilmesi, yedeklerin gerçekten işe yarayıp yaramadığını doğrulamak açısından kritik bir süreçtir. Test edilmeyen bir yedekleme planı, acil bir durumda geri yükleme başarısızlığıyla sonuçlanabilir ve veri kaybını önleyemez (Stallings & Brown, 2018).

Yedekleme sıklığı, verilerin önem derecesine ve değişim hızına bağlı olarak belirlenmelidir. Kurumlar, kritik verileri günlük olarak yedeklerken, daha az önemli veriler haftalık veya aylık olarak yedeklenebilir. Bu, yedekleme süresini ve depolama gereksinimlerini optimize ederken, veri güvenliğini sağlamaya yardımcı olur. Özellikle finansal veriler veya müşteri bilgileri gibi hassas veriler için daha sık yedekleme yapılması önerilir (Nelson ve ark., 2019).

Yedekleme planlarının bir diğer önemli unsuru, verilerin coğrafi olarak farklı bölgelerde saklanmasıdır. Özellikle doğal afetler veya bölgesel elektrik kesintileri gibi durumlar göz önüne alındığında, verilerin fiziksel olarak farklı yerlerde saklanması, olası riskleri minimize eder. Bu nedenle, birçok kurum, yerel yedeklemenin yanı sıra uzak sunucular veya bulut tabanlı yedekleme çözümlerini de kullanır (Ma ve Yang, 2018).

Sonuç olarak, veri yedekleme, kurumların bilgi güvenliği stratejilerinin olmazsa olmaz bir parçasıdır. Verilerin düzenli olarak yedeklenmesi ve bu yedeklerin güvenli bir şekilde saklanması, olası veri kayıplarının önüne geçer. Yedekleme planlarının düzenli olarak test

edilmesi ve coğrafi olarak farklı bölgelerde yedeklerin saklanması, kurumların veri güvenliğini sağlaması ve operasyonel sürekliliği koruması açısından hayati öneme sahiptir.

6. Zararlı Yazılımlara Karşı Koruma

Zararlı yazılımlar, kurumların bilgi güvenliği açısından karşı karşıya kaldığı en büyük tehditlerden biridir. Bu yazılımlar, sistemlere izinsiz erişim sağlamak, verileri şifrelemek, silmek veya çalmak gibi çeşitli zararlı aktiviteler gerçekleştirmek amacıyla kullanılır (Stallings & Brown, 2018). Kurumlar, giderek karmaşıklaşan bu tehditlere karşı etkili bir koruma sağlamak için zararlı yazılımlara karşı koruma yöntemlerini çok katmanlı bir güvenlik stratejisine entegre etmelidir.

Zararlı yazılım türleri arasında virüsler, solucanlar, trojanlar, fidye yazılımları (ransomware), casus yazılımlar (spyware) ve rootkitler gibi birçok farklı tehdit bulunur. Özellikle fidye yazılımları, verileri şifreleyerek kurumlardan fidye talep eden saldırılar olarak günümüzde büyük bir risk teşkil etmektedir (Symantec, 2019). Bu tür saldırılara karşı koruma sağlamak için, sürekli olarak güncellenen antivirüs ve anti-malware yazılımları kullanmak zorunlu hale gelmiştir.

Zararlı yazılımlara karşı korunmada sıfırıncı gün saldırıları (zero-day attacks) da dikkate alınması gereken bir tehdittir. Bu saldırılar, henüz keşfedilmemiş veya düzeltme yapılmamış güvenlik açıklarını hedef alır. Bu tür saldırılara karşı korunmanın en etkili yolu, güvenlik açıklarının düzenli olarak taranması ve sistem güncellemelerinin anında uygulanmasıdır (Al-Rushdan vd., 2019). Kurumlar, işletim sistemleri ve uygulamaları için sürekli olarak güvenlik yamaları ve güncellemeler uygulamalıdır.

6.1. Antivirüs ve Anti-malware Yazılımlarının Kullanılması

Antivirüs ve anti-malware yazılımları, zararlı yazılımlara karşı koruma sağlamak için temel güvenlik araçlarıdır ve kurumsal bilgi güvenliği stratejisinin önemli bir bileşenini oluşturur. Bu yazılımlar, sistemlerde zararlı yazılım tespiti, kaldırılması ve tehditlerin engellenmesi süreçlerini yönetir. Zararlı yazılımlar, veri ihlali, kimlik hırsızlığı ve sistem performansının bozulması gibi ciddi sonuçlara yol açabilir. Bu nedenle, kurumsal ağlar ve cihazlar üzerinde antivirüs ve anti-malware çözümlerinin etkin bir şekilde kullanılması kritik öneme sahiptir (Stallings & Brown, 2018).

Antivirüs yazılımları, virüsler, solucanlar, truva atları gibi bilinen tehditleri tespit etmek ve engellemek için zararlı yazılım imzalarına dayanır. Bu yazılımlar, veritabanlarında bulunan zararlı yazılım imzalarını ağ ve cihazlardaki dosyalarla karşılaştırarak şüpheli aktiviteleri tespit eder (Rahumed vd., 2011). Anti-malware yazılımları ise sadece virüslerle değil, aynı zamanda fidye yazılımları (ransomware), casus yazılımlar (spyware) ve reklam yazılımları (adware) gibi daha geniş bir tehdit yelpazesine karşı koruma sağlar. Her iki yazılım türü de sistem güvenliğini sağlamada önemli roller oynar, ancak yeni tehditlerin sürekli olarak ortaya çıkması, bu yazılımların düzenli olarak güncellenmesini zorunlu kılar.

Güncellemeler ve yeni tehditlere karşı adaptasyon, antivirüs ve anti-malware yazılımlarının etkinliğini koruyabilmesi için çok önemlidir. Yeni tehditler ortaya çıktıkça, yazılımların zararlı yazılım imzaları ve tehdit algılama algoritmaları sürekli olarak güncellenmelidir. Bu güncellemeler, özellikle sıfırinci gün saldırıları (zero-day attacks)

gibi henüz bilinmeyen açıkların hedeflendiği durumlarda, tehditlerin önlenmesinde büyük rol oynar (Yogi, 2023). Güncellenmeyen yazılımlar, yeni tehditlere karşı savunmasız hale gelir ve kurumların bilgi güvenliğini ciddi şekilde tehlikeye atabilir.

Antivirüs ve anti-malware yazılımlarının performansı, sadece tehdit imzalarına dayalı olarak değil, aynı zamanda davranışsal analiz ve makine öğrenmesi gibi ileri düzey tehdit algılama tekniklerine dayalı olarak da artırılmaktadır. Davranışsal analiz, sistemdeki olağan dışı hareketleri ve şüpheli aktiviteleri izleyerek zararlı yazılımların daha hızlı tespit edilmesini sağlar. Makine öğrenmesi tabanlı çözümler ise tehditleri önceden tanımlanmış imzalar olmadan, geçmiş veri ve modellemeler kullanarak tanıyabilir. Bu tür çözümler, özellikle yeni ortaya çıkan ve henüz tanımlanmamış tehditler için etkili bir savunma mekanizması sunar (Rieck, 2011).

Çok katmanlı güvenlik stratejisinin bir parçası olarak antivirüs ve anti-malware yazılımları, ağ güvenliği duvarları (firewall), saldırı tespit sistemleri (IDS/IPS) ve kimlik doğrulama mekanizmalarıyla entegre edilmelidir. Bu entegrasyon, sadece yazılımların değil, genel güvenlik mimarisinin etkinliğini artırır. Özellikle büyük kurumsal ağlarda, antivirüs yazılımlarının tek başına yeterli koruma sağlamadığı bilinmektedir. Bu nedenle, antivirüs çözümlerinin diğer güvenlik katmanlarıyla birlikte çalışarak sistemdeki tehditlerin bütünsel bir şekilde ele alınması sağlanmalıdır (Stallings & Brown, 2018).

Sonuç olarak, antivirüs ve anti-malware yazılımları, zararlı yazılımlara karşı savunmanın temelini oluşturan kritik güvenlik araçlarıdır. Bu yazılımların etkin kullanımı ve düzenli güncellenmesi,

siber saldırılara karşı koruma sağlarken, sistemlerin güvenliğini ve performansını da optimize eder. Ancak bu yazılımların tek başına yeterli olmadığı unutulmamalı, çok katmanlı bir güvenlik stratejisi içinde sürekli izleme ve gelişmiş tehdit algılama teknikleri ile desteklenmelidir.

6.2. Güvenlik Güncellemeleri

Güvenlik güncellemeleri, kurumsal bilgi güvenliği stratejisinin en temel unsurlarından biridir ve yazılım ve donanımlarda ortaya çıkan güvenlik açıklarının kapatılması için kritik bir rol oynar. Güvenlik açıkları, siber saldırganlar tarafından sistemlere izinsiz giriş yapmak, verileri ele geçirmek veya zarar vermek amacıyla kullanılır. Bu tür saldırılara karşı korunmanın en etkili yollarından biri, yazılım ve sistemlerin düzenli olarak güncellenmesi ve güvenlik yamalarının uygulanmasıdır (Stallings & Brown, 2018).

Güvenlik güncellemeleri, yazılım sağlayıcıları tarafından tespit edilen güvenlik açıklarına yönelik yayınlanan yamalardır. Birçok siber saldırı, bilinen güvenlik açıklarını hedef alır, bu nedenle bu yamaların uygulanmaması sistemleri ciddi şekilde savunmasız hale getirebilir. Özellikle sıfırncı gün saldırıları (zero-day attacks), sistemlerin daha önce bilinmeyen açıklarını hedef alarak gerçekleştirildiği için, güvenlik güncellemelerinin düzenli uygulanması bu tür saldırıların etkisini azaltabilir (Symantec, 2019). Herhangi bir açık tespit edildiğinde, bu açığı kapatmak için geliştirilen güvenlik yamalarının hızla uygulanması gereklidir.

Otomatik güvenlik güncelleme sistemleri, kurumlar için kritik bir önlem olarak kullanılabilir. Bu sistemler, manuel güncelleme işlemlerinde oluşabilecek gecikmeleri ortadan kaldırarak, güvenlik

yamalarının hızlı ve etkin bir şekilde uygulanmasını sağlar. Ancak, otomatik güncellemeler uygulanmadan önce detaylı bir test süreci yürütülmesi önemlidir, zira bazı güncellemeler, yazılım veya sistem işlevlerinde uyumsuzluklara neden olabilir (Sawadogo, 2020). Bu tür sorunlar, sistem kararlılığını etkileyebileceği için her yamanın ilgili sistemlerde test edilmesi ve uygulanması tavsiye edilir.

Güvenlik güncellemelerinin başarısı, sadece işletim sistemleri için değil, aynı zamanda kullanılan uygulamalar, ağ cihazları, güvenlik duvarları ve yönlendiriciler gibi donanım ve yazılımlar için de geçerlidir. Birçok kurum, sistem güncellemelerini sadece masaüstü ve sunucu düzeyinde uygularken, ağ cihazları ve diğer altyapı unsurlarını göz ardı edebilir. Oysaki, bu cihazlardaki güvenlik açıkları da siber saldırılara karşı önemli bir tehdit oluşturur (Kraemer ve ark., 2009). Bu nedenle, tüm sistem bileşenlerinin güncellemelerinin düzenli olarak kontrol edilmesi ve uygulanması, sistem güvenliği açısından kritik öneme sahiptir.

Yedekleme ve test süreçleri, güvenlik güncellemelerinin uygulanmasında dikkat edilmesi gereken diğer önemli faktörlerdir. Bir güncelleme uygulamadan önce, ilgili sistemlerin yedeklenmesi, olası bir uyumsuzluk veya sorun durumunda sistemlerin geri yüklenebilmesini sağlar. Ayrıca, uygulanan güncellemelerin sistem üzerindeki etkileri test edilmeli ve güncellemelerin sistem performansı ve güvenliği üzerindeki etkileri değerlendirilmelidir (Nelson ve ark., 2019).

Güvenlik güncellemelerinin zamanında uygulanmaması, siber saldırılara açık bir sistem yaratabilir ve veri kaybı, hizmet kesintisi veya itibar zedelenmesi gibi ciddi sonuçlara yol açabilir. WannaCry fidye

yazılımı saldırısı, bilinen bir güvenlik açığını hedef alarak 2017'de küresel ölçekte binlerce işletme ve kurumu etkilemiş, bu da güvenlik güncellemelerinin ihmal edilmesinin nasıl yıkıcı etkiler yaratabileceğini göstermiştir (Symantec, 2019). Bu olay, güvenlik güncellemelerinin zamanında uygulanmasının önemini bir kez daha vurgulamaktadır.

Sonuç olarak, güvenlik güncellemeleri, sistemlerin siber tehditlere karşı korunması ve güvenlik açıklarının minimize edilmesi için hayati bir öneme sahiptir. Güvenlik yamalarının düzenli olarak uygulanması, otomatik güncelleme sistemlerinin kullanılması ve güncellemelerin test edilmesi, güvenlik güncellemelerinin etkinliğini artırmak ve kurumların bilgi güvenliği stratejisini güçlendirmek için gerekli adımlardır.

7. Veri Kaybı Önleme (DLP) Sistemleri

Veri Kaybı Önleme (Data Loss Prevention - DLP) sistemleri, hassas verilerin yetkisiz kişilere sızmasını engellemek ve veri güvenliğini sağlamak amacıyla geliştirilmiş güvenlik çözümleridir. Kurumların dijital varlıkları, özellikle müşteri bilgileri, finansal veriler ve fikri mülkiyet gibi kritik bilgiler, günümüzün karmaşık siber tehdit ortamında korunması gereken en önemli varlıklar arasındadır. DLP sistemleri, bu tür hassas verilerin yanlışlıkla ya da kasıtlı olarak dışarıya sızdırılmasını önlemeye yönelik olarak kullanılır (Stallings & Brown, 2018).

DLP sistemlerinin temel işlevi, hassas bilgilerin tanımlanması, izlenmesi ve korunmasıdır. DLP teknolojileri, hem veri depolama ortamında (at-rest) hem de veri aktarımı sırasında (in-transit) verilerin güvenliğini sağlamak amacıyla kullanılır. Verilerin nereye gönderildiğini, kim tarafından erişildiğini ve nasıl işlendiğini izleyerek,

herhangi bir veri ihlali veya sızıntı girişiminde anında müdahale edilmesine olanak tanır (Wang, 2017). DLP çözümleri, özellikle e-posta sistemleri, bulut hizmetleri ve taşınabilir cihazlar üzerinden veri sızıntısını engelleme konusunda kritik bir rol oynar.

DLP sistemleri, veri sınıflandırması ve veri akışının izlenmesi gibi tekniklerle çalışır. Kurumlar, öncelikle hangi verilerin kritik olduğunu tanımlamalı ve bu verilere uygun güvenlik politikaları geliştirmelidir. Veri sınıflandırması, verilerin önemine göre kategorize edilmesi ve her kategorinin farklı güvenlik politikalarıyla korunması anlamına gelir. DLP teknolojisi, bu sınıflandırılmış verileri sürekli izleyerek, herhangi bir kural ihlali veya anormal aktivite tespit ettiğinde müdahale eder (Symantec, 2019). Örneğin, bir çalışanın kritik müşteri bilgilerini kurumsal e-posta yerine kişisel bir e-posta adresine göndermeye çalışması, DLP sistemi tarafından tespit edilip engellenebilir.

E-posta ve bulut tabanlı sistemlerde veri sızıntısı en yaygın veri kaybı tehditlerinden biridir. E-posta aracılığıyla yanlışlıkla hassas bilgilerin paylaşılması, veri ihlallerinin en sık karşılaşılan sebeplerinden biridir. DLP çözümleri, e-posta içeriklerini tarayarak ve belirli anahtar kelimeleri, veri kalıplarını ya da şifrelenmiş bilgileri analiz ederek hassas verilerin yetkisiz kişilere iletilmesini engeller (Faiz vd., 2020). Aynı şekilde, bulut hizmetlerinde kullanılan DLP çözümleri, verilerin güvenli bir şekilde saklanmasını sağlar ve verilerin yetkisiz bulut depolama hizmetlerine aktarılmasını önler.

DLP sistemlerinin en önemli avantajlarından biri de kullanıcı davranışlarını izleme ve analiz etme yeteneğidir. Bu, olası veri ihlallerini önlemek için hem içeriden gelen tehditlere karşı bir güvenlik katmanı

oluşturur hem de çalışanların farkında olmadan yaptıkları hataları azaltmaya yardımcı olur. Örneğin, bir kullanıcı büyük miktarda veri kopyalamaya çalıştığında veya dışarıya dosya transferi yaptığında, DLP sistemi bu davranışı izler ve gerektiğinde otomatik müdahalede bulunur (Nelson ve ark., 2019).

DLP sistemleri ayrıca yasal uyum gereksinimlerini karşılamada da önemli bir rol oynar. Kişisel Verilerin Korunması Kanunu (KVKK), Genel Veri Koruma Yönetmeliği (GDPR) ve diğer ulusal ve uluslararası veri koruma yasaları, kurumların hassas verileri korumasını zorunlu kılmaktadır. DLP çözümleri, bu yasal düzenlemelere uyum sağlamaya yardımcı olur ve olası veri ihlallerinde kurumların yasal sorumluluklarını yerine getirmesini sağlar (Voigt & Von dem Bussche, 2017).

Sonuç olarak, DLP sistemleri, kurumların hassas verilerini koruma altına almak ve veri sızıntılarını önlemek için vazgeçilmez bir araçtır. E-posta ve bulut tabanlı sistemlerde veri kaybını engelleyen bu çözümler, aynı zamanda kullanıcı davranışlarını izleyerek iç tehditlere karşı da güçlü bir savunma sunar. Gelişen tehdit ortamında, DLP sistemlerinin etkin kullanımı, veri ihlallerini önlemek ve yasal uyumluluğu sağlamak açısından kritik öneme sahiptir.

Sonuçlar

Bu çalışma, kurumsal bilgi güvenliğinin sağlanmasına yönelik çok katmanlı bir güvenlik yapısının önemini ve bu yapının nasıl etkin bir şekilde uygulanabileceğini ortaya koymuştur. Dijitalleşmenin hız kazanması ve siber tehditlerin her geçen gün daha karmaşık hale gelmesi, kurumların sadece teknik önlemlerle değil, aynı zamanda insan faktörüne yönelik stratejilerle de güvenliği sağlamalarını zorunlu

kılmaktadır. Güvenlik duvarları, saldırı tespit/önleme sistemleri (IDS/IPS), ağ segmentasyonu, kimlik doğrulama ve yetkilendirme süreçleri, zararlı yazılımlara karşı koruma ve veri kaybı önleme (DLP) sistemleri gibi güvenlik katmanlarının entegrasyonu, bilgi güvenliği stratejisinin temel taşlarını oluşturmaktadır.

Çalışma boyunca, her bir güvenlik katmanının işlevi ve kurum içindeki kritik önemi detaylandırılmıştır. Özellikle ISO 27001 standardı çerçevesinde kurumsal bilgi güvenliği yönetim sistemlerinin (BGYS) nasıl yapılandırılması gerektiği ve risk yönetimi süreçlerinin etkin bir şekilde nasıl uygulanabileceği açıklanmıştır. Bu bağlamda, erişim kontrol sistemlerinin veri güvenliğinde oynadığı kilit rol, ağ güvenliği çözümlerinin siber tehditlere karşı sağladığı koruma ve farkındalık eğitimlerinin insan hatalarını minimize etmedeki önemi vurgulanmıştır.

Zararlı yazılımlara karşı koruma ve güvenlik güncellemelerinin düzenli bir şekilde uygulanması, sürekli gelişen tehdit ortamına karşı en etkili savunma yöntemleri arasında yer almıştır. Antivirüs ve anti-malware yazılımlarıyla desteklenen güvenlik çözümleri, sistemlerin güvenliğini sağlarken, çok katmanlı güvenlik stratejisi ile tüm kurumsal yapının bütüncül bir şekilde korunması mümkün hale gelmiştir. Veri kaybı önleme (DLP) sistemlerinin kullanımı ise, hassas verilerin yetkisiz erişimlerden korunması ve veri ihlallerinin önlenmesi açısından kritik bir önlem olarak sunulmuştur.

Bu bağlamda, bilgi güvenliğine yönelik tehditlerin giderek daha karmaşık ve zorlayıcı hale geldiği günümüzde, kurumların sadece teknolojik çözümlerle yetinmeyip, aynı zamanda güvenlik politikalarını düzenli olarak gözden geçirmeleri ve güncellemeleri gerekmektedir.

Olay müdahale planlarının oluşturulması ve veri yedekleme stratejilerinin uygulanması, olası veri kayıplarına karşı operasyonel sürekliliği sağlamak açısından büyük önem taşımaktadır.

Sonuç olarak, bu çalışma, kurumsal bilgi güvenliğini sağlamak için sadece teknolojik önlemlerle değil, aynı zamanda bütüncül bir güvenlik anlayışıyla hareket edilmesi gerektiğini göstermiştir. Güvenlik farkındalık eğitimlerinin, güvenlik güncellemelerinin ve yedekleme planlarının düzenli olarak uygulanması, bilgi güvenliği stratejisinin sürdürülebilirliği açısından büyük önem arz etmektedir. Bu yaklaşım, kurumsal ağların ve verilerin korunmasını sağlarken, kurumların bilgi güvenliği risklerine karşı daha dayanıklı hale gelmesini sağlayacaktır.

Kaynaklar

- Al-Rushdan, H., Shurman, M., Alnabelsi, S. H., & Althebyan, Q. (2019, December). Zero-day attack detection and prevention in software-defined networks. In 2019 international arab conference on information technology (acit) (pp. 278-282). IEEE.
- Akujuobi, C. M., & Ampah, N. K. (2007, May). Enterprise network intrusion detection and prevention system (ENIDPS). In Sensors, and Command, Control, Communications, and Intelligence (C3I) Technologies for Homeland Security and Homeland Defense VI (Vol. 6538, pp. 28-39). SPIE.
- Alshaikh, M. (2020). Developing cybersecurity culture to influence employee behavior: A practice perspective. *Computers & Security*, 98, 102003.
- Almorsy, M., Grundy, J., & Müller, I. (2016). An analysis of the cloud computing security problem. arXiv preprint arXiv:1609.01107.
- Anyasi, F. I., Uzairue, S. I., Enehizena, O. N., Matthews, V. O., Amaize, P., & Nkordeh, N. (2018). Design and analysis of a broadcast network using logical segmentation, *Telkomnika*, 2018.
- Ben Youssef, N., & Bouhoula, A. (2011, June). Dealing with stateful firewall checking. In *International Conference on Digital Information and Communication Technology and Its Applications* (pp. 493-507). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Bertino, E., & Sandhu, R. (2005). Database security—Concepts, approaches, and challenges. *IEEE Transactions on Dependable and Secure Computing*, 2(1), 2-19.
- Böhme, R., & Schwartz, G. (2010). Modeling cyber-insurance: Towards a unifying framework. In *Workshop on the Economics of Information Security (WEIS)*.
- Calder, A., & Watkins, S. (2015). *IT Governance: An International Guide to Data Security and ISO27001/ISO27002*. Kogan Page Publishers.
- Caputo, D. D., Pfleeger, S. L., Freeman, J. D., & Johnson, M. E. (2014). Going spear phishing: Exploring embedded training and awareness. *IEEE Security & Privacy*, 12(1), 28-38.
- Faiz, M., Arshad, J., Alazab, M., & Shalaginov, A. (2020). Predicting likelihood of legitimate data loss in email DLP. *Future Gener. Comput. Syst.*, 110, 744-757.
- Ferraiolo, D. F., & Kuhn, D. R. (1992). Role-based access controls. *National Computer Security Conference*.
- Guo, C., Su, M., & Cui, F. (2023, July). Research on Data Storage Security in Cloud Computing Environment. In *2023 4th International Conference on Information Science, Parallel and Distributed Systems (ISPDS)* (pp. 475-479). IEEE.

- Hadlington, L. (2017). Human factors in cybersecurity; examining the link between Internet addiction, impulsivity, attitudes towards cybersecurity, and risky online behaviors. *Heliyon*, 3(7), e00346.
- He, D., & Wang, D. (2014). Robust biometrics-based authentication scheme for multiserver environment. *IEEE Systems Journal*, 9(3), 816-823.
- Herath, T., & Rao, H. R. (2009). Protection motivation and deterrence: a framework for security policy compliance in organisations. *European Journal of Information Systems*, 18(2), 106-125.
- Hong-pin, W. (2009). Construction of the Secure Enterprise Network Based on Multi-layer Protection. *Microcomputer Information*.
- Hu, V. C., Ferraiolo, D., & Kuhn, D. R. (2015). Assessment of Access Control Systems. NIST.
- Humphreys, E. (2008). Information security management standards: Compliance, governance and risk management. Information Security Technical Report, 13(4), 247-255.
- ISO/IEC 27001. (2013). Information technology – Security techniques – Information security management systems – Requirements. ISO/IEC 27001:2013.
- ISO/IEC 27002. (2013). Information technology – Security techniques – Code of practice for information security controls. ISO/IEC 27002:2013.
- ISO/IEC 27005. (2018). Information technology – Security techniques – Information security risk management. ISO/IEC 27005:2018.
- Jakobsson, M., & Myers, S. (2006). Phishing and countermeasures: Understanding the increasing problem of electronic identity theft. John Wiley & Sons.
- Katz, J., & Lindell, Y. (2014). Introduction to Modern Cryptography: Principles and Protocols. CRC Press.
- Kävrestad, J. (2018). Incident Response. Privacy, Regulations, and Cybersecurity.
- Kraemer, S., Carayon, P., & Clem, J. (2009). Human and organizational factors in computer and information security: Pathways to vulnerabilities. *Information Technology & People*, 22(1), 7-35.
- Kessler, G. C. (2019). An overview of cryptography. *Handbook of Computer Networks and Cyber Security*, 213-248.
- Konikiewicz, W., & Markowski, M. (2017). Analysis of performance and efficiency of hardware and software firewalls. *Journal of Applied Computer Science Methods*, 9, 49-63.
- Lamis, T. (2010, October). A forensic approach to incident response. In 2010 Information Security Curriculum Development Conference (pp. 177-185).
- Lippmann, R. P., Ingols, K. W., Scott, C., Piwowarski, K., Kratkiewicz, K., Artz, M., & Cunningham, R. (2005). Evaluating and strengthening enterprise network security using attack graphs. Project Report IA-2, MIT Lincoln Laboratory.

- Ma, L., & Yang, B. (2018, October). Data backup against progressive disasters in geodistributed data center networks. In 2018 international conference on networking and network applications (NaNA) (pp. 223-226). IEEE.
- Malaescu, I., & Sutton, S. G. (2015). The reliance of external auditors on internal audit's use of continuous audit. *Journal of information systems*, 29(1), 95-114.
- Mitnick, K. D., & Simon, W. L. (2011). *The art of deception: Controlling the human element of security*. John Wiley & Sons.
- Nakamura, S., Zhao, X., & Nakagawa, T. (2017). Constant and random full backup models with incremental and differential backup schemes. *International Journal of Reliability, Quality and Safety Engineering*, 24(03), 1750015.
- Nelson, B., Phillips, A., & Steuart, C. (2019). *Guide to Computer Forensics and Investigations*. Cengage Learning.
- Parsons, K., McCormac, A., Butavicius, M., Pattinson, M., & Jerram, C. (2015). The design of phishing studies: Challenges for researchers. *Computers & Security*, 52, 194-206.
- Peltier, T. R. (2016). *Information Security Policies, Procedures, and Standards: guidelines for effective information security management*. CRC press.
- Polizzi, S., & Scannella, E. (2023). Continuous auditing in public sector and central banks: a framework to tackle implementation challenges. *Journal of Financial Regulation and Compliance*, 31(1), 40-59.
- Pratama, R. F., Suwastika, N. A., & Nugroho, M. A. (2018, May). Design and implementation adaptive Intrusion Prevention System (IPS) for attack prevention in software-defined network (SDN) architecture. In 2018 6th International Conference on Information and Communication Technology (ICoICT) (pp. 299-304). IEEE.
- Rahumed, A., Chen, H. C., Tang, Y., Lee, P. P., & Lui, J. C. (2011, September). A secure cloud backup system with assured deletion and version control. In 2011 40th International Conference on Parallel Processing Workshops (pp. 160-167). IEEE.
- Rescorla, E. (2001). *SSL and TLS: Designing and building secure systems*. Addison-Wesley Professional.
- Rieck, K., Trinius, P., Willems, C., & Holz, T. (2011). Automatic analysis of malware behavior using machine learning. *Journal of computer security*, 19(4), 639-668.
- SANS Institute. (2019). *Incident handling: Six phases of incident response*. SANS Reading Room.
- Sawadogo, A. D., Bissyandé, T. F., Moha, N., Allix, K., Klein, J., Li, L., & Traon, Y. L. (2020). Learning to catch security patches. arXiv preprint arXiv:2001.09148.
- Schatz, D., Bashroush, R., & Wall, J. (2017). Towards a more representative definition of cyber security. *Journal of Digital Forensics, Security and Law*, 12(2), 53-74.

- Sheng, S., Holbrook, M., Kumaraguru, P., Cranor, L. F., & Downs, J. (2010). Who falls for phish? A demographic analysis of phishing susceptibility and effectiveness of interventions. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, 373-382.
- Sommestad, T., Hallberg, J., Lundholm, K., & Bengtsson, J. (2014). Variables influencing information security policy compliance: A systematic review of quantitative studies. *Information Management & Computer Security*.
- Song, J., Xu, B. R., Zhang, G. C., Li, G. S., Ma, C. G., & Ge, A. J. (2018, June). Improved Two-Factor Authentication Protocol Based on Biometric Feature and Password for Cloud Service. In *International Conference on Cloud Computing and Security* (pp. 90-100). Cham: Springer International Publishing.
- Stallings, W., & Brown, L. (2018). *Computer Security: Principles and Practice*. Pearson.
- Symantec. (2019). *Internet Security Threat Report 2019*.
- Thompson, E. C. (2018). The incident response strategy. *Cybersecurity Incident Response: How to Contain, Eradicate, and Recover from Incidents*, 65-70.
- Tsohou, A., Karyda, M., Kokolakis, S., & Kiountouzis, E. (2015). Managing the introduction of information security awareness programmes in organizations. *European Journal of Information Systems*, 24(1), 38-58.
- Voigt, P., & Von dem Bussche, A. (2017). *The EU General Data Protection Regulation (GDPR)*. Springer.
- Von Solms, R., & Van Niekerk, J. (2013). From information security to cyber security. *Computers & Security*, 38, 97-102.
- Wang, R. X., Wang, Y., & Dai, L. (2023, March). Intrusion detection in network security. In *Second Guangdong-Hong Kong-Macao Greater Bay Area Artificial Intelligence and Big Data Forum (AIBDF 2022)* (Vol. 12593, pp. 366-371). SPIE.
- Wang, Z., & Li, X. (2013). Intrusion prevention system design. In *Proceedings of the International Conference on Information Engineering and Applications (IEA) 2012: Volume 3* (pp. 375-382). Springer London.
- Wang, C. (2017). *Data Loss Prevention System Based on Big Data*. DEStech Transactions on Computer Science and Engineering.
- Warkentin, M., & Willison, R. (2009). Behavioral and policy issues in information systems security: the insider threat. *European Journal of Information Systems*, 18(2), 101-105.
- Ramaiah, C. H., Charan, D. A., Akhil, R. S., & Kumar, P. P. (2018). Secure automated threat detection and prevention (SATDP). *Int J Eng Technol*, 7, 86-9.
- Yogi, M. K. (2023). A Comprehensive Study of Zero-Day Attacks. *Journal of Information Technology and Digital World*, 5(3), 253-273.

BÖLÜM 5

DERİN ÖĞRENME VE TARIMSAL UYGULAMALAR

Dr .Erhan KAHYA¹

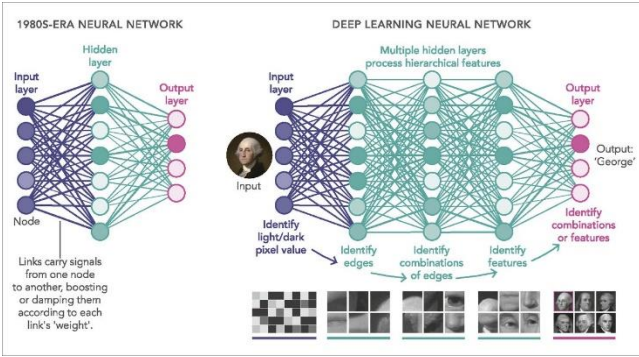
Dr. Fatma Funda ÖZDÜVEN²

¹ Tekirdağ Namık Kemal Üniversitesi,Teknik Bilimler Meslek Yüksekokulu , Elektronik ve Otomasyon Bölümü,Kontrol ve Otomasyon Teknolojisi Programı, Tekirdağ ,Türkiye.
ekahya@nku.edu.tr,05067188820, Orcid ID: 0000-0001-7768-9190

² Tekirdağ Namık Kemal Üniversitesi,Teknik Bilimler Meslek Yüksekokulu Bitkisel ve Hayvansal Üretim Bölümü ,Seracılık Programı,Tekirdağ ,Türkiye
fozduven@nku.edu.tr,05325768446,Orcid ID: 0000-0003-4286-8943

1. Derin Öğrenme Nedir?

Derin öğrenme, yapay sinir ağlarının bir alt dalı olarak, büyük veri setlerinden öğrenme yeteneği ile dikkat çekmektedir. Derin öğrenme, makine öğrenmesinin bir alt dalıdır ve yapay sinir ağları kullanarak verilerden öğrenme sürecini ifade eder. Derin öğrenme, özellikle büyük veri setleri üzerinde karmaşık modeller oluşturmak için kullanılır. Bu yöntem, çok katmanlı sinir ağları (derin sinir ağları) aracılığıyla verilerin özelliklerini otomatik olarak öğrenir ve bu sayede görüntü tanıma, doğal dil işleme, ses tanıma gibi birçok alanda yüksek başarımlar elde eder. Şekil 1 'de derin öğrenmenin blok diyagramı gösterilmiştir.



Şekil. Derin öğrenme blok diyagramı(Anonim)

Derin öğrenmenin temel bileşenleri şunlardır:

1. **Sinir Ağları:** Yapay sinir ağları, birbirine bağlı düğümlerden oluşur. Her düğüm, gelen bilgiyi işler ve sonuçları bir sonraki katmana iletir. Derin öğrenme ağları, çok katmanlı (derin) sinir ağlarıyla çalışır.
2. **Katmanlar (Layers):** Bir derin öğrenme modelinde giriş katmanı, gizli katmanlar ve çıkış katmanı bulunur. Giriş

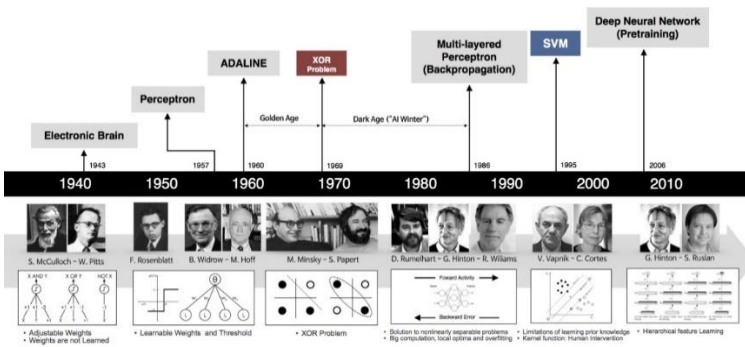
katmanı veriyi alırken, çıkış katmanı sonucu verir. Gizli katmanlar ise veriyi işleyerek anlamlı temsil düzeylerine ulaşılmasını sağlar.

3. **Aktivasyon Fonksiyonları:** Bu fonksiyonlar, sinir ağının katmanlar arasında öğrenebilmesini sağlar. En çok kullanılan aktivasyon fonksiyonları ReLU, Sigmoid ve Tanh'tir.
4. **Geri Yayılım (Backpropagation):** Eğitim sırasında modelin hatalarını analiz edip ağırlıklarının güncellemesini sağlayan yöntemdir.
5. **Optimizasyon Algoritmaları:** Modelin öğrenme sürecinde hata oranını azaltmak için kullanılan algoritmalarıdır. En popüler optimizasyon algoritmaları arasında Stochastic Gradient Descent (SGD) ve Adam bulunur.

Derin öğrenme modelleri, büyük veri setleri ve güçlü donanımlar (örneğin, GPU'lar) ile daha verimli çalışır ve öğrenme sürecinde verinin karmaşık yapısını yakalayabilir.

2.Derin Öğrenmenin Tarihsel Gelişimi

Derin öğrenmenin tarihsel gelişiminin adımları Şekil 2'de gösterilmiştir.



Şekil 2. Tarihsel gelişimi (Anonim 2)

2.1. Erken Dönemler (1940-1980)

Derin öğrenmenin temelleri, 1940'larda Warren McCulloch ve Walter Pitts'in yapay sinir ağları üzerine yaptığı çalışmalarla atılmıştır (McCulloch ve Pitts, 1943). 1958'de Frank Rosenblatt, "Perceptron" adı verilen ilk yapay sinir ağını geliştirmiştir (Rosenblatt, 1958). Ancak, bu erken dönemlerdeki çalışmalar sınırlı veri ve hesaplama gücü nedeniyle beklenen başarıyı elde edememiştir.

2.2. İlk Teorik Temeller

1943 yılında Warren McCulloch ve Walter Pitts, sinir hücrelerinin matematiksel bir modelini geliştirmiştir. Bu model, sinir hücrelerinin (nöronların) belirli bir şekilde birbirleriyle etkileşimde bulunarak bilgi işlediğini öne sürmüştür (McCulloch ve Pitts, 1943). Bu çalışma, yapay sinir ağlarının teorik temellerini atmış ve daha sonraki araştırmalara ilham vermiştir.

2.3. Perceptron'un Gelişimi

1958 yılında Frank Rosenblatt, "Perceptron" adı verilen ilk yapay sinir ağını tanıtmıştır. Perceptron, iki katmanlı bir yapıya sahip olup, giriş katmanındaki verileri işleyerek çıkış katmanına ileten basit bir modeldir (Rosenblatt, 1958). Rosenblatt, bu modelin öğrenme yeteneğine sahip olduğunu ve belirli görevleri yerine getirebileceğini göstermiştir. Ancak, Perceptron'un sınırlamaları, özellikle doğrusal olarak ayrılabilir olmayan verilerle başa çıkma yeteneği eksikliği, bu dönemde derin öğrenme alanındaki ilerlemeleri sınırlamıştır (Minsky ve Papert, 1969).

2.4. İlk Eleştiriler ve Sınırlamalar

1969 yılında Marvin Minsky ve Seymour Papert, "Perceptrons" adlı kitaplarında, Perceptron'un sınırlamalarını ele almışlardır. Bu kitap,

yapay sinir ağları üzerine yapılan araştırmalara büyük bir darbe vurmuş ve birçok araştırmacının bu alandan uzaklaşmasına neden olmuştur (Minsky ve Papert, 1969). Bu dönemde, yapay zeka ve makine öğrenimi alanında yaşanan bu duraklama, "AI kışı" olarak adlandırılan bir döneme yol açmıştır.

2.5. Yeniden Canlanma Çabaları

1980'lerin başında, yapay sinir ağlarına olan ilgi yeniden canlanmaya başlamıştır. Bu dönemde, geri yayılım algoritması (backpropagation) gibi yeni tekniklerin geliştirilmesi, sinir ağlarının daha karmaşık yapılar haline gelmesine olanak tanımıştır (Rumelhart ve ark., 1986). Bu gelişmeler, derin öğrenmenin temellerini atmış ve sonraki yıllarda daha karmaşık modellerin ortaya çıkmasına zemin hazırlamıştır.

2.6. Yeniden Canlanma (1980-2000)

1980'lerde, Geoffrey Hinton ve arkadaşları, geri yayılım algoritmasını (backpropagation) geliştirerek sinir ağlarının eğitiminde önemli bir adım atmışlardır (Rumelhart ve ark., 1986). Bu dönemde, sinir ağları daha karmaşık yapılar haline gelmeye başlamış ve daha fazla katman eklenmiştir. Ancak, bu dönemde de derin öğrenme, sınırlı uygulama alanları ile sınırlı kalmıştır.

2.6.1. Geri Yayılım Algoritması

1986 yılında, David Rumelhart, Geoffrey Hinton ve Ronald Williams, geri yayılım algoritmasını tanıtmıştır. Bu algoritma, çok katmanlı sinir ağlarının eğitiminde etkin bir şekilde kullanılabilen bir yöntemdir (Rumelhart ve ark., 1986). Geri yayılım, sinyallerin ağ içindeki nöronlardan geçerek çıktı ve hata hesaplaması ile geri döndürülmesini sağlamakta, böylece ağın ağırlıklarının güncellenmesine

olanak vermektedir. Bu teknik, derin öğrenmenin yeniden canlanması kilit bir parçası olmuştur.

2.6.2. Çok Katmanlı Ağlar ve Derin Öğrenme

1980'lerde, sinir ağları daha karmaşık ve çok katmanlı yapılar haline gelmeye başlamıştır. Bu dönem boyunca, çok katmanlı algılayıcılar (multi-layer perceptrons) ile birlikte daha derin ağlar üzerinde çalışmalar artmıştır (Hinton ve ark., 2006). Hinton ve arkadaşları, derin ağların daha derin katmanlara sahip olmasının, daha karmaşık verileri ve kavramları öğrenme yeteneğini artırdığını göstermiştir.

2.6.3. Gelişen Uygulama Alanları

1980'lerin sonlarına doğru, yapay sinir ağları, birkaç farklı alanda uygulamaya girmeye başlamıştır. Özellikle, yüz tanıma, ses tanıma ve el yazısı tanıma gibi alanlarda ilk başarılı uygulamalar gerçekleştirilmiştir (LeCun ve ark., 1989). Bu dönemde, yapay sinir ağları, diğer makine öğrenmesi tekniklerine göre daha iyi performans gösterdiği alanlarda tanınmıştır.

2.6.4. İlk Derin Öğrenme Modelleri

1990'larda, daha karmaşık ve derin sinir ağları üzerinde çalışmalar hız kazanmıştır. Bu dönemde, "Convolutional Neural Networks" (CNN) gibi özel ağ mimarileri geliştirilmiştir. Yüz tanıma alanında yapılan çalışmalar, CNN'lerin etkili performansını ortaya koymuştur (LeCun ve ark., 1998). Bu tür ağlar, görüntü işleme alanında önemli ilerlemelere zemin hazırlamıştır.

2.6.5. Yöntemlerin Sınırlamaları ve Düşüş

Ancak, 1990'ların ortalarında, derin öğrenme alanındaki ilgi yine de sınırlamalarla karşılaşmıştır. Sinir ağlarının eğitimi, büyük veri setlerine ve yüksek hesaplama gücüne ihtiyaç duymakta, bu yüzden bazı araştırmacılar alternatif yöntemlere yönelmiştir (Schmidhuber, 2015). Bu süreç, ilgi azalmasına yol açmış ve "AI kışı" benzeri bir duruma neden olmuştur.

2.7. Büyük Veri ve Hesaplama Gücü (2000-2010)

2000'lerin başında, internetin yaygınlaşması ve büyük veri setlerinin ortaya çıkması, derin öğrenmenin gelişimini hızlandırmıştır (Dean ve ark., 2012). Ayrıca, grafik işleme birimleri (GPU'lar) sayesinde hesaplama gücündeki artış, daha karmaşık modellerin eğitilmesine olanak tanımıştır. 2012'de Hinton ve ekibi, ImageNet yarışmasında derin öğrenme ile büyük bir başarı elde ederek bu alandaki ilginin artmasına yol açmıştır (Krizhevsky, Sutskever, & Hinton, 2012).

2.7.1. Büyük Veri Fenomeni

2000'lerin başında, internet ve dijital teknolojilerin yaygınlaşması, büyük veri olarak adlandırılan devasa veri setlerinin oluşmasına sebep olmuştur. Çeşitli kaynaklardan (sosyal medya, sensör verileri, ticaret verileri) elde edilen bu veriler, derin öğrenme algoritmalarının eğitilmesi için zengin bir kaynak sunmuştur (Zikopoulos ve Eaton, 2011). Büyük veri, modelin doğruluğunu ve genel performansını artırarak uygulama alanlarını genişletmiştir.

2.7.2. Hesaplama Gücündeki Artış

Grafik İşlem Birimleri (GPU'lar), derin öğrenme süreçlerinde büyük bir etki yaratmıştır. NVIDIA gibi firmalar, yüksek paralel

hesaplama yetenekleri olan GPU'ları geliştirmiştir. Bu grafik işlemcileri, büyük veri setleri üzerinde derin sinir ağlarının daha hızlı ve verimli bir şekilde eğitilmesine olanak tanımıştır (Krähenbühl ve ark., 2016). Bu gelişme, özellikle derin öğrenme alanında devrim yaratmıştır.

2.7.3. Hinton ve Ekibinin Başarısı

2012 yılında, Geoffrey Hinton ve ekibi, ImageNet yarışmasında derin öğrenme yöntemleriyle büyük bir başarı elde etmiştir (Krizhevsky, Sutskever, & Hinton, 2012). Hinton'un ekibi, derin konvolüsyonel sinir ağı (CNN) kullanarak görüntü tanıma alanında önemli bir sıçrama yapmış ve bu başarı, derin öğrenmeye olan ilgiyi büyük ölçüde artırmıştır. Bu dönemde üretilen sonuçlar, derin öğrenmenin gerçek dünya uygulamalarındaki potansiyelini gözler önüne sermiştir.

2.7.4. Derin Öğrenme Uygulamaları

2000-2010 yılları arasında derin öğrenme, çeşitli uygulama alanlarında fark edilmeye başlamıştır. Bunun yanı sıra, ses tanıma, doğal dil işleme (NLP), görüntü analizi ve oyun programlama gibi birçok alanda önemli gelişmeler kaydedilmiştir (Bengio, Lecun, & Haffner, 2007). Örneğin, Google ve Apple gibi büyük teknoloji şirketleri, sesli asistanlar ve görüntü tanıma hizmetleri gibi uygulamalarla bu teknolojileri benimsemişlerdir.

2.7.5. Hedeflemeler ve Araçlar

Bu dönemde, derin öğrenme alanında pek çok yeni araç ve kütüphane geliştirilmeye başlamış, TensorFlow, PyTorch ve Caffe gibi framework'ler, araştırmacılara ve geliştiricilere büyük kolaylık sağlamıştır (Abadi ve ark., 2016; Paszke ve ark., 2019). Bu çerçeveler,

derin öğrenme uygulamalarının daha erişilebilir ve verimli olmasını sağlamış, araştırma ve uygulama süreçlerini hızlandırmıştır.

2.8. Günümüzde Derin Öğrenme (2010-Günümüz)

Son yıllarda, derin öğrenme, görüntü işleme, doğal dil işleme ve oyun gibi birçok alanda devrim yaratmıştır (LeCun, Bengio, & Haffner, 2005). Google'ın AlphaGo projesi, derin öğrenmenin karmaşık stratejik oyunlarda nasıl kullanılabileceğini göstermiştir (Silver ve ark., 2016). Ayrıca, otomatik sürüş, sağlık hizmetleri ve finans gibi sektörlerde de derin öğrenme uygulamaları hızla yaygınlaşmaktadır.

2.8.1. Derin Öğrenme Algoritmalarındaki Gelişmeler

2010 sonrası dönemde, derin öğrenme ile ilgili birçok yeni mimari geliştirilmiştir. Özellikle derin konvolüsyonel sinir ağları (CNN) ve tekrar eden sinir ağları (RNN) gibi yapılar, görüntü ve dil işleme alanlarında önemli ilerlemelere olanak tanımıştır (LeCun, Yoshua, & Bengio, 2015). Örneğin, GoogLeNet ve ResNet gibi mimariler, daha derin ve daha verimli ağlar oluşturmak için geliştirilmiştir (Szegedy ve ark., 2015; He ve ark., 2016).

2.8.2. Uygulama Alanları

Derin öğrenme, birçok sektörde devrim yaratmıştır. Öne çıkan alanlar arasında:

- **Görüntü Tanıma:** 2015 yılında, ResNet yapısı, ImageNet yarışmasını kazanarak görüntü tanıma alanında büyük bir başarı elde etmiştir (He ve ark., 2016).
- **Doğal Dil İşleme:** BERT (Bidirectional Encoder Representations from Transformers) gibi modeller, dil

anlayışını geliştirmiş ve çok sayıda doğal dil işleme görevinde en iyi sonuçları elde etmiştir (Devlin ve ark., 2019).

- **Otomatik Sürüş:** Tesla ve Waymo gibi şirketler, derin öğrenme sayesinde otonom araç teknolojilerini geliştirmiştir (Bojarski ve ark., 2016).
- **Sağlık Hizmetleri:** Derin öğrenme, tıbbi görüntülemelerde hastalık teşhisini ve sağlık takibini kolaylaştırmıştır (Esteva ve ark., 2017).

2.8.3. Etik ve Güvenlik Konuları

Derin öğrenmenin yaygınlaşmasına paralel olarak, etik ve güvenlik endişeleri de artmıştır. Veri gizliliği, algoritmaların önyargıları, ve karar alma süreçlerinin şeffaflığı gibi konular, araştırmaların ve uygulamaların önemli bir parçası haline gelmiştir (O'Neil, 2016). AI sistemlerinin güvenilirliği ve adilliği konusundaki tartışmalar, araştırmacılar ve uygulayıcılar arasında yoğunlaşmıştır.

2.8.4. Araştırma ve Ticarileşme

2010'dan bu yana derin öğrenme, sadece akademik bir alan olmanın ötesine geçerek ticarileşmeye başlamıştır. Çeşitli teknoloji firmaları, derin öğrenme tabanlı ürün ve hizmetler geliştirmekte olup, bu da sektördeki yenilikleri hızlandırmaktadır (Jordan ve Mitchell, 2015). Özellikle bulut bilişim hizmetleri, küçük ve orta ölçekli işletmelerin derin öğrenme tekniklerini benimsemesine yardımcı olmuştur.

2.8.5. Gelecek Perspektifi

Gelecekte, derin öğrenmenin gelişimi devam edecektir. Zayıf ve güçlü yapay zeka arasındaki sınırlar daha da bulanık hale gelecektir. Yeni algoritmalar, veri setleri ve hesaplama teknikleri ile derin öğrenme

uygulamalarının daha verimli ve etkili hale getirilmesi beklenmektedir (Goodfellow, Bengio, & Courville, 2016).

2.9. Gelecek Perspektifi

Derin öğrenmenin geleceği, daha verimli algoritmalar, daha büyük veri setleri ve daha güçlü hesaplama kaynakları ile şekillenecektir. Ayrıca, etik ve güvenlik konuları da derin öğrenme uygulamalarının gelişiminde önemli bir rol oynamaktadır (O'Neil, 2016).

2.9.1. Model Gelişiminde Yeni Yöntemler

Gelecekte, derin öğrenme alanında daha verimli ve etkili algoritmaların geliştirilmesi öngörülmektedir. Örneğin, "Transformers" modelinin başarısı, doğal dil işleme dışındaki alanlarda da benzer yapıların kullanılmasına yol açabilir (Vaswani ve ark., 2017). Ayrıca, daha az veri ile daha iyi sonuçlar elde etmeyi hedefleyen "few-shot" ve "zero-shot" öğrenme yaklaşımları da gelişim aşamasındadır (Lake ve ark., 2015).

2.9.2. Hesaplama Gücünün ve Altyapının Gelişimi

Hesaplama gücündeki artış, derin öğrenme uygulamalarını daha erişilebilir ve etkili hale getirmeye devam edecek. Bulut bilişim hizmetleri, özellikle küçük ve orta ölçekli işletmelerin büyük veri setlerini analiz etmesine olanak tanıyacaktır. Bunun yanı sıra, kuantum hesaplama gibi yeni teknolojiler, karmaşık modelleme ve optimizasyon sorunlarının çözümünde devrim yaratma potansiyeline sahiptir (Farhi ve ark., 2017).

2.9.3. Etik ve Sosyal Sorumluluk

Yapay zeka ve derin öğrenme uygulamaları ile ilişkili etik ve sosyal sorumluluk konuları, giderek daha fazla önem kazanmaktadır. Veri gizliliği, önyargı ve adalet gibi konular, kamuoyunun dikkatini çekmektedir (O'Neil, 2016). Gelecekte, bu sorunlara yanıt vermek için daha sağlam düzenlemelerin ve şeffaflık mekanizmalarının oluşturulması önem arz edecektir.

2.9.4. Interdisipliner Çalışmalar

Derin öğrenme, yalnızca bilgisayar bilimi alanında değil, aynı zamanda sağlık, finans, mühendislik ve sosyal bilimler gibi birçok disiplinde uygulanmaktadır. Gelecekte, interdisipliner işbirliklerinin artması, derin öğrenme tekniklerinin daha geniş kapsamlı ve etkili bir şekilde kullanılmasına olanak tanıyacaktır (Gil ve ark., 2019). Örneğin, yapay zeka destekli sağlık hizmetleri, kişiselleştirilmiş tıp uygulamalarında önemli bir rol oynayabilir.

2.9.5. İnsan-Makine İşbirliği

Gelecek perspektifinde, derin öğrenmenin insan-makine etkileşimlerini geliştirme potansiyeli bulunmaktadır. Otomasyonun artması, insanların yaratıcı ve stratejik düşünme becerilerinin daha fazla vurgulandığı bir çalışma ortamı oluşturabilir (Brynjolfsson ve McAfee, 2014). Bu durum, iş gücü dinamiklerini değiştirebilir ve yeni iş alanları oluşturabilir.

Derin öğrenme, yapay zeka alanında önemli bir dönüm noktasıdır ve tarihsel gelişimi, bu teknolojinin potansiyelini ve gelecekteki yönelimlerini anlamak için kritik öneme sahiptir. Gelecekte, derin öğrenmenin daha fazla alanda devrim yaratması beklenmektedir.

3. Tarımda Derin Öğrenme

Derin öğrenme, tarımda çeşitli tarımsal süreçleri geliştiren ve sektördeki uzun süredir devam eden zorlukları ele alan gelişmiş hesaplama teknikleri sunarak devrim niteliğinde bir etki yaratmaktadır. Uygulamaları, bitki gelişiminden hastalık tespitine, yabancı ot ve zararlı yönetimine kadar geniş bir yelpazeye yayılmakta ve kaynak kullanımını optimize ederken sürdürülebilir uygulamaları teşvik etmektedir. Tarımsal alan, nüfus artışı ve iklim değişikliği nedeniyle artan taleplerle karşı karşıya kaldıkça, derin öğrenme teknolojileri verimliliği ve üretkenliği artırmak için kritik bir rol oynamakta ve modern tarım stratejilerinin ayrılmaz bileşenleri haline gelmektedir. Derin öğrenme algoritmalarının, özellikle Konvolüsyonel Sinir Ağları (CNN'ler) gibi tekniklerin kullanımı, hassas bitki tanımlama ve sınıflandırma imkanı sunarak farklı bitki çeşitlerinin daha iyi izlenmesini ve yönetilmesini sağlamaktadır. Ayrıca, bu modeller çevresel verileri, hava durumu desenleri ve toprak koşulları gibi verileri analiz ederek çiftçilerin ürün verimlerini tahmin etmelerine olanak tanıyan öngörücü analizlere katkıda bulunmaktadır. Derin öğrenmenin Nesnelerin İnterneti (IoT) teknolojileri ile entegrasyonu, gerçek zamanlı karar verme yeteneklerini daha da artırarak çiftçilerin sulama, zararlı yönetimi ve hastalıkları zamanında müdahalelerle yönetmelerine yardımcı olmaktadır. Ancak, tarımda derin öğrenme kullanımında bazı zorluklar vardır. Veri yönetimi, algoritma performansı ve altyapı bağlantısı ile ilgili sorunlar, bu teknolojilerin birçok kırsal alanda uygulanmasını karmaşık hale getirmektedir. Ayrıca, dijital araçlara olan bağımlılık, özellikle bu yenilikleri etkili bir şekilde kullanma kaynakları ve bilgisi olmayan küçük çiftçiler arasında mevcut eşitsizlikleri artırabilir. Tarım sektörü

gelişmeye devam ederken, bu zorlukların üstesinden gelmek, derin öğrenmenin potansiyelinden tam anlamıyla yararlanmak ve gelecekte sürdürülebilir tarım uygulamalarını sağlamak için kritik öneme sahip olacaktır.

3.1.Derin Öğrenmenin Tarımda Uygulamaları

Derin öğrenme, tarımda devrim niteliğinde bir teknoloji olarak ortaya çıkmış ve çeşitli süreçleri önemli ölçüde geliştirmiştir. Uygulamaları geniş ve çeşitlidir ve tarım sektörünün karşılaştığı birçok zorluğu ele almaktadır.

3.1.1.Bitki Yönetimi

Derin öğrenmenin tarımda birincil uygulamalarından biri bitki yönetimidir. Konvolüsyonel Sinir Ağları (CNN'ler) gibi teknikler, bitki tanımlama ve sınıflandırma için kullanılmakta, farklı bitki çeşitlerinin daha verimli izlenmesini ve yönetilmesini sağlamaktadır (Altalak ve ark.,2022;Wang ve ark.,2023). Ayrıca, derin öğrenme modelleri hava durumu desenleri ve toprak koşulları gibi çeşitli kaynaklardan veri analiz ederek ürün verimini tahmin edebilir (Araújo ve ark.,2023).

3.1.2.Hastalık Tespiti

Derin öğrenme, tarım sektöründe bitki hastalıklarının tespitinde önemli bir rol oynamaktadır. Son yıllarda, yapay zeka algoritmalarının, özellikle derin öğrenme (DL) ve makine öğrenimi (ML) tekniklerinin, bitki hastalıklarının tanımlanmasında ve sınıflandırılmasında kullanımı artmıştır. Bu bağlamda, derin öğrenme yöntemleri, geleneksel el ile yapılan gözlemlerden daha hızlı ve doğru sonuçlar sunarak, tarım üretkenliğini artırma potansiyeline sahiptir (Li ve Zhang, 2021). Bitki hastalıklarının tespitinde kullanılan derin öğrenme teknikleri arasında,

konvolüsyonel sinir ağları (CNN) öne çıkmaktadır. CNN'ler, görüntü işleme alanında oldukça etkili olup, bitki yapraklarındaki hastalıkların belirtilerini tanımada yüksek doğruluk oranları sağlamaktadır. Örneğin, Naranjo-Torres ve arkadaşları, konvolüsyonel sinir ağları kullanarak ahududu hastalıklarını tespit eden bir sistem geliştirmiştir (Naranjo-Torres ve ark., 2021). Ayrıca, Roy ve diğerleri, domates yaprak hastalıklarını belirleyebilmek için yenilikçi bir PCA DeepNet modeli kullanmışlardır (Roy ve ark., 2023). Bu tür çalışmalar, derin öğrenme tekniklerinin bitki hastalıklarının tespitinde ne kadar etkili olduğunu göstermektedir. Derin öğrenme uygulamaları, bitki hastalıklarının erken tespiti için büyük veri setleri kullanmaktadır. Örneğin, Pandian ve arkadaşları, 147,500 görüntü içeren bir veri seti ile derin konvolüsyonel sinir ağı (DCNN) modelini eğitmişlerdir (Pandian ve ark., 2022). Bu tür büyük veri setleri, modelin genel performansını artırmakta ve farklı hastalık türlerini daha iyi ayırt etmesine olanak tanımaktadır. Ayrıca, Mavridou ve diğerleri, makine görme sistemlerinin tarımda nasıl kullanılabileceğini ve bu sistemlerin bitki hastalıklarının tespitindeki rolünü incelemişlerdir (Mavridou ve ark., 2019). Bitki hastalıklarının tespitinde kullanılan diğer bir önemli yöntem ise görüntü artırma teknikleridir. Bu teknikler, modelin eğitim sürecinde veri setinin çeşitliliğini artırarak, modelin genelleme yeteneğini güçlendirmektedir (Pandian ve ark., 2022). Bitki yaprak hastalıklarının tespitinde CNN'lerin kullanımını incelemiş ve bu yöntemlerin gelecekteki tarım uygulamaları için büyük bir potansiyele sahip olduğunu belirtmiştir (Saini, 2019).

CNN'ler, görüntü işleme alanında yüksek başarı oranları ile tanınmakta ve bitki yapraklarındaki hastalık belirtilerini etkili bir şekilde sınıflandırmaktadır (Yan ve ark., 2020; Li ve Zhang, 2021). Bitki

hastalıklarının tespitinde derin öğrenme uygulamaları, büyük veri setleri kullanarak modelin eğitimini gerçekleştirmektedir. Chen ve ark., (2021) yalnızca 25 etiketli örnekle daha önce görülmemiş bitki hastalıklarını tespit eden bir meta-öğrenme yöntemi geliştirmiştir. Bu yöntem, %93.9'luk bir doğruluk oranı elde etmiştir. Bu tür çalışmalar, derin öğrenme tekniklerinin sınırlı veri ile bile etkili sonuçlar elde edebileceğini göstermektedir. Transfer öğrenme yönteminin tarımda hastalık ve zararlı tanımda yüksek doğruluk sağladığını belirtmektedir. Araştırmalarında, sınırlı sayıda hastalık ve zararlı görüntüsü ile %97.49'a kadar tanıma doğruluğu elde edilmiştir (Yin ve ark., 2020). Bu durum, transfer öğrenmenin tarım uygulamalarında nasıl etkili bir şekilde kullanılabileceğini ortaya koymaktadır. Ayrıca, derin öğrenme ile bitki hastalıklarının tespitinde görüntü artırma teknikleri de önemli bir rol oynamaktadır. Bu teknikler, eğitim sürecinde veri setinin çeşitliliğini artırarak modelin genelleme yeteneğini güçlendirmektedir (Sun ve ark., 2023). K-means kümeleme ile görüntü özelliklerini çıkararak CNN kullanarak bitki hastalıklarını tanımlamışlardır (Sultana ve ark., 2020). Konvolüsyonel Sinir Ağları (CNN) gibi teknikler, görüntü sınıflandırması ve nesne tespiti gibi çeşitli bilgisayarla görme görevlerine başarıyla uygulanmıştır. Bu yöntemler, görsel verilerin analizi yoluyla bitki hastalıklarını tanımda özellikle etkilidir. Ancak, derin öğrenme modelleri genellikle büyük veri setlerine ihtiyaç duyar; bu da mobil tarım uygulamaları için dağıtımda zorluklar yaratabilir. Devam eden araştırmalar, coğrafi bilgi ve tarihsel hastalık insidansı gibi çeşitli veri kaynaklarını entegre eden hafif modeller geliştirmeye odaklanmaktadır (Anonim 3; Yousaf ve ark.,2023).

Derin öğrenmenin Nesnelerin İnterneti (IoT) ile entegrasyonu, hassas tarım uygulamalarını dönüştürmektedir. Drone'lar, akıllı sensörler ve otomatik makineler gibi yeni teknolojiler, tarımsal operasyonları optimize etmek için gelişmiş algoritmalarla birleştirilmektedir. Bu yenilikler, kaynak tahsisi, zararlı yönetimi ve bitki izleme ile ilgili karar verme süreçlerini geliştiren gerçek zamanlı veri toplama ve analizine olanak tanımaktadır. Örneğin, araştırmacılar, çeşitli IoT cihazlarından elde edilen verileri analiz edebilen derin öğrenme mimarilerini araştırmaktadır; bu da tarımsal uygulamaların hassasiyetini ve verimliliğini artırmaktadır (Lian ve ark.,2024 ;Anonim 6). Hidayah ve ark. (2022) yılında 4 grup ürün üzerinde derin öğrenme ile hastalık tespiti üzerine yaptıkları çalışmada domates, patates, patlıcan ve biberi kullanmışlardır. Toplam 16580 görüntüden oluşan veri kümesini 100 epoch ve 16 batch boyutu ile eğitmişlerdir. Derin öğrenme modelleri karşılaştırması sonucunda en iyi sonucu YOLOv5 modelinde tespit ettiklerini vurgulamışlardır. YOLOv5 modelinin ortalama hassasiyetin %94,2 olarak bulmuşlardır. Haque ve ark. (2022) yılında oluşturdukları patlıcan için hastalık tespiti sistemlerinde derin öğrenmenin çeşitli modelleri ile çalışma yapmışlardır. Kullandıkları derin öğrenme modellerinde VGG16, Inception V3, VGG 19, MobileNet, NasNetMobile ve ResNet50'dir. Eğitim setini patlıcan için 9 hastalık türünden oluşturmuşlardır. Test seti sonuçlarına göre %99 yakın bir oranda başarı elde ettiklerini vurgulamışlardır.

Wang ve ark.(2022) hıyar için hastalık tespiti için YOLOv5s derin modeline dayalı bir hıyar kök-ur nematodu tespit modeli geliştirmişlerdir. Bu modelin salatalık kök-nematodu tespitinde iyi bir performans elde ettiğini vurgulamışlardır.

Fu ve ark. (2022) yılında soya fasulyesi fenotipi tanımlanması üzerine YOLO-v5 ağına dayanan algılama sistemi üzerine yaptıkları çalışmada hassasiyeti yaklaşık %6 artarak soya fasulyesi popülasyonunda 200 bitki içindeki tespiti %88,14 hassasiyet bulmuşlardır.

Çeltik yapraklarındaki hastalıkların erken teşhisi için derin öğrenme modellerinin kullanımı incelenmiştir. Bu çalışma, derin öğrenme tabanlı sistemlerin tarımda nasıl bir rol oynayabileceğini göstermektedir (Özdemir, 2023). Çeltik bitkisi hastalıklarının tespitinde evrişimli sinir ağlarının (CNN) etkinliğini vurgulamış, bu tür sistemlerin otomatik teşhis süreçlerine katkı sağladığını belirtmiştir (Ökten ve Yüzgeç, 2022). Derin öğrenme ve makine öğrenmesi yöntemlerinin bitki yapraklarındaki hastalıkların tespitinde nasıl kullanılabileceğini açıklamışlardır, bu da tarımda otomasyonun önemini pekiştirmektedir (Yaman ve Tuncer, 2022). Sonuç olarak, derin öğrenme teknikleri, bitki hastalıklarının tespitinde devrim niteliğinde bir değişim yaratmaktadır. Bu yöntemler, hem doğruluk oranlarını artırmakta hem de tarım uygulamalarını daha verimli hale getirmektedir. Gelecekte, bu teknolojilerin daha fazla entegrasyonu ile tarım sektöründe hastalık yönetimi ve üretkenlik artırılabilir.

3.1.3.Yabani Ot ve Zararlı Yönetimi

Bir diğer önemli derin öğrenme uygulaması, yabancı ot ve zararlıların tanımlanmasıdır. Derin öğrenme teknolojileri, bitkiler ile çeşitli yabancı ot türleri arasında ayırım yapmayı kolaylaştırarak herbisit uygulamalarını optimize eder ve kaynak kullanım verimliliğini artırır (Anonim 6 ;Jafar ve ark.,2024). Bu yetenek, kimyasal kullanımını en aza

indirerek sürdürülebilir uygulamaları destekler. Yabancı ot tespiti ve sınıflandırması için kullanılabilirdiğinden, hedefe yönelik ve hassas yabancı ot kontrol önlemleri alınabilir (Cicco ve ark., 2017).

Zhang ve ark.(2022) SE-YOLOv5x derin öğrenme modeli kullanarak tarlada yabancı ot-ürün sınıflandırması yapmışlardır. Çalışmada SE-YOLOv5x modeli kullanılarak, sırasıyla %97,6, %95,6, %97,1 ve %97,3 hassasiyet, geri çağırma, ortalama hassasiyet (mAP) ve F1-skor değerleri ile yabancı ot ve marul bitki tanımlaması sonucuna ulaşılmıştır. SE-YOLOv5x modeli ile marul gövdesinin tarladaki çıkış noktalarının yerini %97,14 doğrulukla bulunmuştur.

López-Correa ve ark.(2022) domates mahsullerinde oluşan yabancı ot türlerini otomatik olarak tespit etmek ve sınıflandırmak için derin öğrenme tabanlı yöntem geliştirmişlerdir. Derin öğrenme modelleri olarak YOLOv7 ve Faster-RCNN kullanmışlardır.

Zhang ve Wang (2019), bitki hastalıklarının tespitinde derin öğrenme yöntemlerinin etkinliğini vurgulamaktadır. Konvolüsyonel Sinir Ağları (CNN) gibi modeller, tarım alanlarındaki görüntüleri analiz ederek yabancı otları ve zararlıları tanımlamak için kullanılabilir. Bu sayede, çiftçiler erken müdahale fırsatı bulabilirler. Kumar ve Singh (2021), tarımda derin öğrenmenin uygulamalarını ve potansiyelini ele alarak, bu teknolojilerin veri analizi süreçlerini nasıl dönüştürdüğünü göstermektedir.

Ferentinos (2018), zararlıların ve yabancı otların tespit edilmesiyle otomatik ilaçlama sistemlerinin nasıl çalıştığını açıklamaktadır. Bu sistemler, yalnızca ihtiyaç duyulan alanlara ilaç uygulayarak kaynakları daha verimli kullanma imkanı sunmaktadır. Derin öğrenme, tarımda su, gübre ve pestisit kullanımını optimize ederek sürdürülebilir tarım

uygulamalarını destekler. Liu ve Zhang (2020), bu teknolojilerin çevresel etkileri azaltma ve maliyetleri düşürme potansiyelini vurgulamaktadır. Bu sayede, çiftçiler daha bilinçli kararlar alabilir ve kaynaklarını daha etkili bir şekilde yönetebilir.

3.1.4.Su Stresi Tespiti

Derin öğrenme teknikleri, bitkilerde su stresini değerlendirme yeteneğini artırmaktadır. İHA'lar ve çok spektral kameralar gibi veri kaynaklarını kullanarak, bu algoritmalar bitki sağlığını izleyebilir ve çevresel koşullara dayalı sulama ihtiyaçlarını tahmin edebilir (Araújo ve ark.,2023;Lian ve ark.,2024). Bu tür bilgiler, çiftçilerin sulama uygulamalarını optimize etmelerine olanak tanır ve su kaynaklarını korurken ürün verimliliğini sürdürmelerine yardımcı olur. Liu ve Zhang (2020), derin öğrenmenin su yönetimi süreçlerini nasıl dönüştürdüğünü vurgulamaktadır. Bu sayede, çiftçiler su kaynaklarını daha verimli kullanabilir ve çevresel etkileri azaltabilir. Dronlar ve uzaktan algılama teknolojileri, tarım alanlarının izlenmesine olanak tanır. Bu teknolojiler, bitki sağlığını ve su stresini değerlendirmek için yüksek çözünürlüklü görüntüler sağlar (Mohanty ve ark., 2016). Sürdürülebilir su yönetimi stratejileri, su kaynaklarının korunmasını ve verimli kullanılmasını sağlar. Bu stratejiler arasında yağmur suyu hasadı, sulama döngülerinin optimize edilmesi ve su tasarruflu tarım tekniklerinin uygulanması yer alır (Zhang ve Wang, 2019).

3.1.5.Hava Tahmini ve Çevresel İzleme

Derin öğrenme, tarımsal planlama için hayati öneme sahip hava tahmininde de rol oynamaktadır. Tarihsel hava verilerini ve mevcut çevresel koşulları analiz ederek, derin öğrenme modelleri çiftçilerin

ekim ve hasat zamanlarıyla ilgili bilinçli kararlar almalarına yardımcı olan doğru tahminler sağlayabilir(Altalak ve ark.,2022;Wang ve ark.,2023). Derin öğrenme modelleri uydu görüntüleri, hava durumu verileri ve toprak sensörleri gibi çeşitli kaynaklardan gelen verileri analiz ederek mahsul yönetimi uygulamalarını optimize etmeye yönelik içgörüler ve öneriler sağlayabilir. Bu, verim tahmini, sulama planlaması ve besin yönetimi gibi görevleri içerir (Ampatzidis, 2018; Jin ve ark., 2020).

3.1.6.Akıllı İzleme Sistemleri

Derin öğrenmenin akıllı izleme sistemlerine entegrasyonu, bitkilerin gerçek zamanlı gözlemlenmesine olanak tanır. Tarlalarda konuşlandırılan sensörler, toprak nemi, besin seviyeleri ve bitki sağlığı hakkında veri iletebilir ve bu veriler derin öğrenme algoritmaları tarafından işlenerek hassas tarım stratejilerini bilgilendirebilir (Lian ve ark.,2024). Bu entegrasyon, daha iyi kaynak yönetimini teşvik eder ve ürün verimliliğini maksimize eder. Tarımda derin öğrenmenin bir diğer kullanımı sınıflandırmadır. Modelleri otomatik meyve ve sebze sınıflandırması için kullanılmış, kalite ve olgunluğa göre daha hızlı ve daha doğru sınıflandırmaya olanak sağlamaktadır (Aji ve ark., 2019). Sa ve ark. (2023) yılında derin öğrenme modeli ile yaptıkları meyve tespit sistemi çalışmalarında R-CNN modelini kullanmışlardır. Rahnemoonfar ve ark. (2023) yılında yaptıkları derin öğrenme modeli ile cherry domatesinin dal üzerinde sayımını %93 doğruluk ile tahmin etmişlerdir. Wang ve ark. (2019) yılında mango meyvesinin ağaç üzerinde sayımı çalışmalarında eğitim modeli olarak YOLO kullanarak denemeler yapmışlardır. Lee ve ark.(2022) yılında domates için çiçeklenme

dönemini baz alarak hasat tahmin sistemi çalışmalarında YOLOv2 ve YOLOv3 modellerini kullanmışlardır. Liu ve ark (2022) yılında otomatik kuşkonmaz hasat sistemi çalışmalarında DA-Mask RCNN derin öğrenme modelinin kullanarak precision, recall ve F1-score değerlerini 0.993,0.971,0.982 olarak tespit etmişlerdir. Bu değerlere göre modelin uygunluğunu doğrulamışlardır. Abeyrathna ve ark.(2023) robotik hasat sistemleri için hangi derin öğrenme modelinin uygulunu incelemişlerdir. Karşılaştırılan modeller YOLOv4, YOLOv5 ve YOLOv7 derin öğrenme modelleridir. Bu tür sistemlerde kullanılacak modellerin YOLOv5 ve YOLOv7 modeli olduğunu vurgulamışlardır. (Wu ark.,2022) yılında boynuz mantarlarının otomatik sınıflandırılması üzerine bir çalışma yapmışlardır. Çalışmalarında YOLOv5'in tek aşamalı nesne tespiti ile PSPNet'in semantik segmentasyonunu entegre etmişlerdir. Çalışma sonucunda entegre sistemin gerçek zamanlı sınıflandırma yaptığını tespit etmişlerdir. Rong ve ark.(2022) robotik karpuz hasadı için kavrayıcı ve kesme cihazından oluşan özel bir uç tasarlamışlardır. Geliştirdikleri YOLOv5s-CBAM modeli ile yapılan test sonucunda karpuz meyvelerini %89,8 doğrulukla bulmuşlardır. Hasat başarı oranı, konumlandırma hatası ile %85,0 olarak tespit etmişlerdir.

3.1.7.Otomasyon ve Robotik

Tarımda otomasyon ve robotik entegrasyonu, tarım uygulamalarında önemli bir dönüşümü temsil etmektedir. Birçok araştırma projesi, tarımsal verimliliği ve etkinliği artırmak için robotik platformların kullanımını araştırmıştır. Teknolojideki ilerlemeler, bazı robotik tarım faaliyetlerinin ticari olarak uygulanabilir hale gelmesini sağlamıştır. İnsansız kara araçları ve insansız hava araçları, hassas bitki

koruma alanında ön planda yer almakta ve gerçek zamanlı olarak yabancı otları tespit etme ve ele alma yeteneğine sahiptir(Albahar ve ark.,2023).

3.1.8.Tarımda İşbirlikçi Robotlar

İşbirlikçi robotlar veya cobot'lar, Ag5.0'ın geliştirilmesinde kritik bir rol oynaması beklenmektedir. Bu robotlar, ergonomiyi geliştirmek ve insan operatörlerle çalışma alanını paylaşmak üzere tasarlanmıştır. Özellikle organik gıda üretiminde, kimyasal olmayan zararlı kontrol yöntemleri ve verimli hasat sistemleri kullanarak gelişmiş uygulamalara sahiptirler. İnsansız kara araçları ve insansız hava araçları teknolojilerinin birleşimi, tarım görevlerinde verimliliği ve operasyonel sinerjiyi artıran Çoklu Robot Filosu Sistemleri (MFS) oluşturması beklenmektedir(Albahar ve ark.,2023).

3.1.9.Akıllı Teknolojilerin Etkisi

Akıllı sensörlerin, IoT ekosistemlerinin ve makine öğrenimi (ML) algoritmalarının ortaya çıkışı, tarımsal disiplinleri daha da dijitalleştirmektedir. Bu yenilikler, geleneksel tarımsal sensörlerin gerçek zamanlı veri işleme ve analiz yapabilen AI destekli akıllı sensörlere dönüşmesini sağlamaktadır. Öne çıkan örnekler arasında Sony'nin IMX500 ve IMX501 görüntü tabanlı AI sensörleri bulunmaktadır; bu sensörler hızlı veri edinimi ve işleme imkanı sunarak karar verme süreçlerini ve operasyonel verimliliği artırmaktadır(Albahar ve ark.,2023).

3.1.10.Gerçek Zamanlı Kinematik (RTK) Teknolojisi

Tarım otomasyonundaki bir diğer önemli yenilik, tarımsal makineler için santimetre düzeyinde hassasiyet sağlayan Gerçek Zamanlı Kinematik (RTK) teknolojisidir. Bu teknoloji, çiftçilerin

tarlalarını doğru bir şekilde haritalandırmalarına ve araçlarını kalıcı trafik yollarına yönlendirmelerine olanak tanır, bu da toprak hasarını azaltır ve daha iyi toprak sağlığı yönetimi ile verimliliği artırır (Salman ve ark.,2023). Doğru konumlandırma ve otomasyonun birleşimi, kaynak kullanımını optimize ederken insan hatalarını en aza indirir.

3.1.11.Otonom Tarım Makineleri

Otonom tarım makinelerinin, John Deere'in AI destekli traktörleri gibi, ortaya çıkışı, sektörün robotik tarıma doğru kaydığını göstermektedir. Bu makineler, yakıt tüketimini optimize etmenin yanı sıra, ekimden hasada kadar çeşitli görevleri yüksek hassasiyetle ve minimum insan müdahalesi ile gerçekleştirebilmektedir. Bu teknolojik evrim, iş gücü eksikliklerini ve kaynak kısıtlamalarını ele alırken, genişleyen küresel nüfus için gıda güvenliğini sağlamak amacıyla robotik tarım pazarında yenilik yapan birçok girişimci tarafından desteklenmektedir(Anonim 7).

3.1.12.Gelecek Beklentileri

Derin öğrenmenin tarıma entegrasyonunun, teknoloji alanındaki ilerlemeler ve tarımsal zorlukların artan karmaşıklığı ile birlikte önümüzdeki yıllarda önemli ölçüde evrilmesi beklenmektedir. Anahtar eğilimlerden biri, hassas tarım uygulamalarını geliştirmek için Konvolüsyonel Sinir Ağları (CNN'ler) ve Tekrarlayan Sinir Ağları (RNN'ler) gibi derin öğrenme modellerinin uygulanmasıdır. Bu modeller, bitki sınıflandırması, verim tahmini ve zararlı tespiti gibi görevlerde özellikle etkilidir ve çiftçilerin kaynak kullanımını optimize eden ve ürün verimliliğini artıran veri odaklı kararlar almalarına olanak tanır (Araújo ve ark.,2023).

3.1.13.Akıllı Tarım ve IoT Entegrasyonu

Derin öğrenmenin Nesnelerin İnterneti (IoT) teknolojileri ile birleşimi, tarımsal uygulamaları devrim niteliğinde değiştirmesi beklenmektedir. AI işleme yeteneklerine sahip akıllı sensörler, gerçek zamanlı veri toplama ve analizine olanak tanıyacaktır. Bu, çevresel değişikliklere uyum sağlayan otonom sistemlerin geliştirilmesine yol açabilir ve optimal tarım koşullarını sağlamaktadır (Albahar ve ark.,2023). İşbirlikçi robotlar (cobot'lar), çeşitli tarım görevlerinde yardımcı olmak üzere tasarlanmakta ve ergonomiyi geliştirerek verimliliği artırmaktadır.

3.1.14.İklim Değişikliği ile Mücadele

Araştırmacılar, derin öğrenmenin tarımı iklim değişikliğine uyarlamadaki rolüne de odaklanmaktadır. Derin öğrenme algoritmalarını kullanan Karar Destek Sistemleri (DSS), çiftçilerin gerçek zamanlı hava durumu ve toprak verilerine dayalı olarak sulama programlaması ve bitki yönetimi ile ilgili bilinçli seçimler yapmalarına yardımcı olabilir (Mesías-Ruiz ve ark.,2023). Bu tür sistemler, değişen iklim koşullarının getirdiği zorluklara yanıt veren sürdürülebilir tarım uygulamalarının geliştirilmesi için gereklidir.

3.1.15.Gelecek Araştırma Yönleri

Mevcut ilerlemelere rağmen, uzmanlar akıllı tarım alanının hala emekleme aşamasında olduğunu ve derin öğrenmenin operasyonel araştırma teorileri ile entegrasyonu için daha fazla araştırma yapılması gerektiğini savunmaktadır(Mesías-Ruiz ve ark.,2023). Gelecek çalışmalar, tarımsal verimliliği optimize etmek için insansız hava araçları ile daha sofistike makine öğrenimi algoritmalarının ve bunların

kombinasyonlarının araştırılmasını beklemektedir. Bu, yenilikçi tarım çözümleri aracılığıyla gıda güvenliğini artırmayı hedefleyen Tarım 4.0 hedeflerine ulaşmak için büyük veri setlerinin analizini içermektedir(Mesías-Ruiz ve ark.,2023;Yousaf ve ark.,2023).

3.1.16.Tarımsal Karar Destek Sistemleri

Derin öğrenmenin tarımda dikkate değer bir uygulaması, çiftçilerin bilinçli kararlar almasına yardımcı olmak için tasarlanmış Karar Destek Sistemleri (DSS) geliştirilmesidir. Recio ve ark. (2003) tarafından kullanılan AgriSupport II sistemi, işletme maliyetleri, kârlılık analizi, programlama ve kaynak tahsisi için çözümler sunarak tarımsal üretim süreçlerini geliştirmektedir. Sistem, çeşitli tarımsal görevler için en düşük maliyetli seçeneği önermek amacıyla tüm uygulanabilir operasyonel modları hesaplamak ve analiz etmek için CPLEX optimizasyonunu kullanmaktadır. Bu tür gelişmiş araçların uygulanması, çiftçilerin yatırım maliyetlerini en aza indirirken daha büyük verimlilik elde etmelerini sağlamaktadır (Mesías-Ruiz ve ark.,2023).

3.1.17.Küçük Çiftçilerin Ekonomik Güçlendirilmesi

Ayrıca, tarımda derin öğrenmenin başarılı uygulamaları, küçük çiftçilerin ekonomik olarak güçlendirilmesi için hayati öneme sahiptir. Finansal kaynaklara erişimi farklı yöntemlerle (kooperatif vb.) artırarak, küçük çiftçiler kaliteli girdilere ve modern tarım uygulamalarına yatırım yapabilirler. Bu finansal destek, küçük işletmelerin tarımda uygulanabilir operasyonlara geçişini destekler; bu da gelişen ekonomilerde verimlilik ve sürdürülebilirlik üzerinde önemli bir etki yaratabilir. Derin öğrenmeyi kullanan çiftçiler; riskleri daha iyi yöneterek piyasa fırsatlarından daha fazla faydalanabilirler (Lian ve ark.,2024; Anonim 7).

4.Sonuç

Derin öğrenme, tarım sektöründe devrim niteliğinde bir etki yaratarak, çeşitli tarımsal süreçlerin geliştirilmesine olanak tanımaktadır. Bu çalışma, derin öğrenmenin tarımda nasıl uygulandığını ve sağladığı faydaları kapsamlı bir şekilde ele almıştır. Özellikle, bitki yönetimi, hastalık tespiti, yabancı ot ve zararlı yönetimi, su stresi tespiti, hava tahmini ve çevresel izleme gibi alanlarda derin öğrenme tekniklerinin kullanımı, tarımsal verimliliği artırmakta ve kaynak kullanımını optimize etmektedir.

Derin öğrenme algoritmalarının, özellikle Konvolüsyonel Sinir Ağları (CNN'ler) gibi tekniklerin, bitki hastalıklarının erken tespiti ve zararlıların yönetimi konusundaki etkinliği, tarımda otomasyon ve robotik uygulamaları ile birleştiğinde, çiftçilere daha bilinçli kararlar alma imkanı sunmaktadır. Ayrıca, bu teknolojilerin Nesnelerin İnterneti (IoT) ile entegrasyonu, gerçek zamanlı veri toplama ve analiz yaparak tarımsal operasyonların optimize edilmesine katkıda bulunmaktadır.

Ancak, derin öğrenmenin tarımda uygulanması bazı zorluklarla karşı karşıyadır. Veri yönetimi, algoritma performansı ve altyapı bağlantısı gibi sorunlar, bu teknolojilerin kırsal alanlarda benimsenmesini karmaşık hale getirebilir. Ayrıca, dijital araçlara olan bağımlılık, küçük çiftçiler arasında mevcut eşitsizlikleri artırabilir. Bu nedenle, tarım sektörünün gelişimi için bu zorlukların üstesinden gelinmesi kritik bir öneme sahiptir.

Sonuç olarak, derin öğrenme, tarımda sürdürülebilir uygulamaların sağlanması ve verimliliğin artırılması açısından büyük bir potansiyele sahiptir. Gelecekte, bu teknolojilerin daha fazla entegrasyonu ile tarım sektöründe hastalık yönetimi ve üretkenlik artırılabilir. Ayrıca, küçük

çiftçilerin ekonomik güçlendirilmesi için derin öğrenme tabanlı çözümler geliştirilmesi, tarımsal üretkenliği ve sürdürülebilirliği artırma açısından önemli bir adım olacaktır.

Kaynaklar

- Abadi, M., Barham, P., Chen, J., & Chen, Z. (2016). TensorFlow: A System for Large-Scale Machine Learning. Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation.
- Abeyrathna RMRD, Nakaguchi VM, Minn A, Ahamed T. Recognition and Counting of Apples in a Dynamic State Using a 3D Camera and Deep Learning Algorithms for Robotic Harvesting Systems. Sensors. 2023; 23(8):3810. <https://doi.org/10.3390/s23083810>
- Aji, W. S. ve Hawari, K. (2019). A study of deep learning method opportunity on palm oil ffb (fresh fruit bunch) grading methods. Proceedings of the 2019 Ahmad Dahlan International Conference Series on Engineering and Science (ADICS-ES 2019). <https://doi.org/10.2991/adics-es-19.2019.9>
- Albahar M. A Survey on Deep Learning and Its Impact on Agriculture: Challenges and Opportunities. Agriculture. 2023; 13(3):540. <https://doi.org/10.3390/agriculture13030540>
- Altalak M, Ammad uddin M, Alajmi A, Rizg A. Smart Agriculture Applications Using Deep Learning Technologies: A Survey. Applied Sciences. 2022; 12(12):5919. <https://doi.org/10.3390/app12125919>
- Ampatzidis, Y. (2018). Applications of artificial intelligence for precision agriculture. Edis, 2018(6). <https://doi.org/10.32473/edis-ae529-2018>
- Anonim1,<https://www.umutozel.com/deep-learning-nlp>
Erişim tarihi:20.11.2025
- Anonim2,<https://bilisim.io/2017/11/17/yapay-zekanin-kisa-bir-tarihcesi/> Erişim tarihi:20.11.2025
- Anonim3,<https://masschallenge.org/articles/agriculture-innovation/>
Erişim tarihi:19.11.2025
- Anonim4,<https://www.thinkwithniche.com/blogs/details/top-ai-innovations-transforming-agriculture-in-2024-the-future-of-farming-is-here>
Erişim tarihi:18.11.2025
- Anonim5,<https://www.cropin.com/blogs/new-technologies-in-agriculture> Erişim tarihi:20.11.2025
- Anonim 6,<https://www.technologyreview.com/2022/11/16/1063268/feeding-the-world-by-ai-machine-learning-and-the-cloud/>
Erişim tarihi:20.11.2025
- Anonim7,<https://www.agritechtomorrow.com/story/2022/12/agro-informatics-trends-transforming-the-industry-in-2023/14268/>
- Araújo SO, Peres RS, Ramalho JC, Lidon F, Barata J. Machine Learning Applications in Agriculture: Current Trends, Challenges, and Future Perspectives. Agronomy. 2023; 13(12):2976. <https://doi.org/10.3390/agronomy13122976>

- Bengio, Y., LeCun, Y., & Haffner, P. (2007). Gradient-Based Learning Applied to Document Recognition. *Proceedings of the IEEE*.
- Bojarski, M., Choromanska, A., & Ferzensztein, R. (2016). End to end Learning for Self-Driving Cars. *arXiv preprint arXiv:1604.07316*.
- Brynjolfsson, E., & McAfee, A. (2014). *The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies*. W. W. Norton & Company.
- Chen, L., Cui, X., & Li, W. (2021). Meta-learning for few-shot plant disease detection. *Foods*, 10(10), 2441. <https://doi.org/10.3390/foods10102441>
- Cicco, M. D., Potena, C., Grisetti, G., & Pretto, A. (2017). Automatic model based dataset generation for fast and accurate crop and weeds detection. 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). <https://doi.org/10.1109/iros.2017.8206408>
- Dean, J., Corrado, G. S., Monga, R., & Yang, K. (2012). Large Scale Distributed Deep Networks. *Advances in Neural Information Processing Systems*.
- Devlin, J., Chang, M. W., & Lee, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *arXiv preprint arXiv:1810.04805*.
- Esteva, A., Kuprel, B., & Bashir, M. (2017). Dermatologist-Level Classification of Skin Cancer with Deep Neural Networks. *Nature*.
- Farhi, E., Goldstone, J., Gutmann, S., & Neven, H. (2017). Quantum Algorithms for Fixed Qubit Architectures. *arXiv: Quantum Physics*.
- Ferentinos, K. P. (2018). "Deep Learning Models for Plant Disease Detection and Diagnosis." *Computers and Electronics in Agriculture*, 145, 311-318.
- Fu, Xiaoming, Aokang Li, Zhijun Meng, Xiaohui Yin, Chi Zhang, Wei Zhang, and Liqiang Qi. 2022. "A Dynamic Detection Method for Phenotyping Pods in a Soybean Population Based on an Improved YOLO-v5 Network" *Agronomy* 12, no. 12: 3209. <https://doi.org/10.3390/agronomy12123209>
- Gil, J., Alvarez, C., & López-Jiménez, D. (2019). Interdisciplinary Collaboration in Artificial Intelligence Research: A Social Network Analysis. *AI & Society*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Haque MR, Sohel F. Deep Network with Score Level Fusion and Inference-Based Transfer Learning to Recognize Leaf Blight and Fruit Rot Diseases of Eggplant. *Agriculture*. 2022; 12(8):1160. <https://doi.org/10.3390/agriculture12081160>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- Hidayah, A., Radzi, S. A., Razak, N. A., Saad, W. H. M., Wong, Y. C., Naja, A. (2022). Disease detection of solanaceous crops using deep learning for robot vision. *Journal of Robotics and Control (JRC)*, 3(6), 790-799. <https://doi.org/10.18196/jrc.v3i6.15948>

- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*.
- Jafar, A., Bibi, N., Naqvi, R. A., Sadeghi-Niaraki, A., & Jeong, D. (2024). Revolutionizing agriculture with artificial intelligence: plant disease detection methods, applications, and their limitations. *Frontiers in Plant Science*, 15. <https://doi.org/10.3389/fpls.2024.1356260>
- Jin, X., Yu, X. H., Wang, X. Y., Bai, Y. T., Su, T., & Kong, J. (2020). Deep learning predictor for sustainable precision agriculture based on internet of things system. *Sustainability*, 12(4), 1433. <https://doi.org/10.3390/su12041433>
- Jordan, M. I., & Mitchell, T. M. (2015). *Machine Learning: Trends, Perspectives, and Prospects*. Science.
- Krähenbühl, P., & Koltun, V. (2016). Efficient Inference in Fully Connected Conditional Random Fields with Graph Cuts. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*.
- Kumar, A., & Singh, R. (2021). "Application of Deep Learning in Agriculture: A Review." *Artificial Intelligence in Agriculture*, 5, 1-10.
- Lake, B. M., Salakhutdinov, R., & Tenenbaum, J. B. (2015). Human-Level Concept Learning through Probabilistic Program Induction. *Science*.
- LeCun, Y., & Bengio, Y. (1989). Convolutional Networks for Images, Speech, and Time-Series. *The Handbook of Brain Theory and Neural Networks*.
- LeCun, Y., Bengio, Y., & Haffner, P. (2005). Gradient-Based Learning Applied to Document Recognition. *Proceedings of the IEEE*.
- LeCun, Y., Bengio, Y., & Haffner, P. (2015). *Deep Learning*. Nature.
- Lee U, Islam MP, Kochi N, Tokuda K, Nakano Y, Naito H, Kawasaki Y, Ota T, Sugiyama T, Ahn D-H. An Automated, Clip-Type, Small Internet of Things Camera-Based Tomato Flower and Fruit Monitoring and Harvest Prediction System. *Sensors*. 2022; 22(7):2456. <https://doi.org/10.3390/s22072456>
- Li, L. ve Zhang, S. (2021). Plant disease detection and classification by deep learning—a review. *IEEE Access*, 9, 56683-56698. <https://doi.org/10.1109/access.2021.3069646>
- Lian, J. ve Dias Pereira, J. (2024). Editorial: iot, uav, bei empowered deep learning models in precision agriculture. *Frontiers in Plant Science*, 15. <https://doi.org/10.3389/fpls.2024.1399753>
- Liu X, Wang D, Li Y, Guan X, Qin C. Detection of Green Asparagus Using Improved Mask R-CNN for Automatic Harvesting. *Sensors (Basel)*. 2022 Nov 28;22(23):9270. doi: 10.3390/s22239270. PMID: 36501972; PMCID: PMC9741112.

- Liu, Y., & Zhang, Y. (2020). "A Review of Deep Learning in Agriculture: Applications and Challenges." *Computers and Electronics in Agriculture*, 175, 105586.
- López-Correa, Juan Manuel, Hugo Moreno, Angela Ribeiro, Dionisio Andújar. 2022. "Intelligent Weed Management Based on Object Detection Neural Networks in Tomato Crops" *Agronomy* 12, no. 12: 2953. <https://doi.org/10.3390/agronomy12122953>
- Mavridou, E., Vrochidou, E., Papakostas, G. A., Pachidis, T., & Kaburlasos, V. G. (2019). Machine vision systems in precision agriculture for crop farming. *Journal of Imaging*, 5(12), 89. <https://doi.org/10.3390/jimaging5120089>
- McCulloch, W. S., & Pitts, W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *The Bulletin of Mathematical Biophysics*.
- Mesías-Ruiz, G. A., Pérez-Ortiz, M., Dorado, J., Castro, A. I. d., & Peña, J. M. (2023). Boosting precision crop protection towards agriculture 5.0 via machine learning and emerging technologies: a contextual review. *Frontiers in Plant Science*, 14. <https://doi.org/10.3389/fpls.2023.1143326>
- Minsky, M., & Papert, S. (1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). "Using Deep Learning for Image-Based Plant Disease Detection." *Frontiers in Plant Science*, 7, 1419.
- Naranjo-Torres, J., Mora, M., Fredes, C., & Valenzuela, A. M. (2021). Disease and defect detection system for raspberries based on convolutional neural networks. *Applied Sciences*, 11(24), 11868. <https://doi.org/10.3390/app112411868>
- O'Neil, C. (2016). *Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy*. Crown Publishing Group.
- ÖKTEN, İ. ve Yüzgeç, U. (2022). Evrişimli sinir ağı ile çeltik bitkisi hastalığının tespiti. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 11(1), 203-217. <https://doi.org/10.17798/bitlisfen.1014393>
- ÖZDEMİR, C. (2023). Early diagnosis of paddy leaf diseases using deep learning models and data preprocessing techniques. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 38(3), 807-817. <https://doi.org/10.21605/cukurovaumfd.1377763>
- Pandian, J. A., Kumar, D., Geman, O., Hnatiuc, M., Arif, M., & Kanchanadevi, K. (2022). Plant disease detection using deep convolutional neural network. *Applied Sciences*, 12(14), 6982. <https://doi.org/10.3390/app12146982>
- Paszke, A., Gross, S., Wang, P., & Chanan, G. (2019). *PyTorch: An Imperative Style, High-Performance Deep Learning Library*. *Advances in Neural Information Processing Systems*.
- Rahnemoonfar M, Sheppard C. Deep Count: Fruit Counting Based on Deep Simulated Learning. *Sensors*. 2017; 17(4):905. <https://doi.org/10.3390/s17040905>

- Rong, Jiacheng, Jun Fu, Zhiqin Zhang, Jinliang Yin, Yuzhi Tan, Ting Yuan, ve Pengbo Wang. 2022. "Development and Evaluation of a Watermelon-Harvesting Robot Prototype: Vision System and End-Effector" *Agronomy* 12, no. 11: 2836. <https://doi.org/10.3390/agronomy12112836>
- Rosenblatt, F. (1958). *The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain*. *Psychological Review*.
- Roy, K., Chaudhuri, S. S., Frnda, J., Bandopadhyay, S., Ray, I. J., Banerjee, S., ... & Nedoma, J. (2023). Detection of tomato leaf diseases for agro-based industries using novel pca deepnet. *IEEE Access*, 11, 14983-15001. <https://doi.org/10.1109/access.2023.3244499>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning Representations by Back-Propagating Errors. *Nature*.
- Sa I, Ge Z, Dayoub F, Upcroft B, Perez T, McCool C. DeepFruits: A Fruit Detection System Using Deep Neural Networks. *Sensors*. 2016; 16(8):1222. <https://doi.org/10.3390/s16081222>
- Saini, G. (2019). Disease detection in plant leaves using convolutional neural networks: a futuristic approach to agriculture. *The Pharma Innovation*, 8(1), 707-713. <https://doi.org/10.22271/tpi.2019.v8.i11.25406>
- Salman, Z., Muhammad, A., Piran, M. J., & Han, D. (2023). Crop-saving with ai: latest trends in deep learning techniques for plant pathology. *Frontiers in Plant Science*, 14. <https://doi.org/10.3389/fpls.2023.1224709>
- Schmidhuber, J. (2015). *Deep Learning in Neural Networks: An Overview*. *Neural Networks*.
- Silver, D., Huang, A., Maddison, C. J., & Guez, A. (2016). Mastering the Game of Go with Deep Neural Networks and Tree Search. *Nature*.
- Sultana, N., Rahman, M. M., Parven, N., Rashiduzzaman, M., & Jabiullah, M. I. (2020). Computer vision based plant leaf disease recognition using deep learning. *International Journal of Innovative Technology and Exploring Engineering*, 9(5), 622-626. <https://doi.org/10.35940/ijitee.e2486.039520>
- Sun, J., Cao, W., Fu, X., Ochi, S., & Yamanaka, T. (2023). Few-shot learning for plant disease recognition: a review. *Agronomy Journal*, 116(3), 1204-1216. <https://doi.org/10.1002/agj2.21285>
- Szegedy, C., Vanhoucke, V., & Ioffe, S. (2015). Going Deeper with Convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- Vaswani, A., et al. (2017). Attention is All You Need. *Advances in Neural Information Processing Systems*.
- Wang Z, Walsh K, Koirala A. Mango Fruit Load Estimation Using a Video Based MangoYOLO—Kalman Filter—Hungarian Algorithm Method. *Sensors*. 2019; 19(12):2742. <https://doi.org/10.3390/s19122742>

- Wang, Chunshan, Shedong Sun, Chunjiang Zhao, Zhenchuan Mao, Huarui Wu, Guifa Teng. 2022. "A Detection Model for Cucumber Root-Knot Nematodes Based on Modified YOLOv5-CMS" *Agronomy* 12, no. 10: 2555.
<https://doi.org/10.3390/agronomy12102555>
- Wang, X., Zeng, H., Lin, L., Huang, Y., Lin, H., & Que, Y. (2023). Deep learning-empowered crop breeding: intelligent, efficient and promising. *Frontiers in Plant Science*, 14. <https://doi.org/10.3389/fpls.2023.1260089>
- Wu, Yanqiang, Yongbo Sun, Shuoqin Zhang, Xia Liu, Kai Zhou, Jialin Hou. 2022. "A Size-Grading Method of Antler Mushrooms Using YOLOv5 and PSPNet" *Agronomy* 12, no. 11: 2601.
<https://doi.org/10.3390/agronomy12112601>
- Yaman, O. ve Tuncer, T. (2022). Bitkilerdeki yaprak hastalığı tespiti için derin özellik çıkarma ve makine öğrenmesi yöntemi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 123-132. <https://doi.org/10.35234/fumbd.982348>
- Yan, Q., Yang, B., Wang, W., Wang, B., Zhang, Y., & Zhang, J. (2020). Apple leaf diseases recognition based on an improved convolutional neural network. *Sensors*, 20(12), 3535. <https://doi.org/10.3390/s20123535>
- Yousaf, A., Kayvanfar, V., Mazzoni, A., & Elomri, A. (2023). Artificial intelligence-based decision support systems in smart agriculture: bibliometric analysis for operational insights and future directions. *Frontiers in Sustainable Food Systems*, 6.
<https://doi.org/10.3389/fsufs.2022.1053921>
- Zhang, Jian-Lin, Wen-Hao Su, He-Yi Zhang, Yankun Peng. 2022. "SE-YOLOv5x: An Optimized Model Based on Transfer Learning and Visual Attention Mechanism for Identifying and Localizing Weeds and Vegetables" *Agronomy* 12, no. 9: 2061. <https://doi.org/10.3390/agronomy12092061>
- Zhang, Y., & Wang, Y. (2019). "Deep Learning for Plant Disease Detection: A Review." *Computers and Electronics in Agriculture*, 162, 1-10.
- Zikopoulos, P., & Eaton, C. (2011). *Understanding Big Data: Analytics for Enterprise Class Hadoop and Streaming Data*. McGraw-Hill.

BÖLÜM 6

MİKRODENETLEYİCİ TABANLI OTOMOBİL ENJEKTÖRÜ AÇIK KALMA SÜRESİ ÖLÇME SİSTEMİ

Dr. Öğr. Üyesi Erdal KILIÇ¹

Öğr. Gör. Ersoy MEVSİM²

Doç. Dr. Ertuğrul KARAKULAK³

Sorumlu Yazar: Erdal KILIÇ

¹ Agricultural Machinery Program, Vocational School of Technical Sciences, Namık Kemal University Tekirdag, Turkey, e-mail: ekilic@nku.edu.tr, 0000-0001-8212-5533


² Computer Programming Dept., Vocational school of Technical Sciences, Namık Kemal University, Tekirdag, Turkey, e-mail: emevsim@nku.edu.tr, 0000-0002-0879-6424

³ Electronics Department, Vocational school of Technical Sciences, Namık Kemal University, Tekirdag, Turkey, e-mail: ekarakulak@nku.edu.tr, 0000-0001-5937-2114

1. Giriş

Termik motorlarda enjektörler yanma odası içerisine yakıt karışımını püskürtme donanımlarıdır. Bir benzin enjektörü aslında bir selenoid valftir. Enerjilendirildiğinde açılarak yakıtı yanma odasına püskürtür. Enjektörlerin çalışma voltajı aralığı 0- 12 volt arasındadır. Motorda en az silindir sayısı kadar enjektör bulunur. Enjektörün açık kaldığı süre oldukça kısadır ve milisaniye mertebesinde ölçülebilir (H. N. Gupta, 2012; S. Gupta & Patidar, 2020).

Püskürtme 3 farklı şekilde olabilir. Bunlardan biri olan “eş zamanlı püskürtme” sisteminde sadece bir transistör tüm enjektörlerin şasi hattını kontrol eder ve tüm enjektörler aynı anda püskürtme gerçekleştirir. İkinci püskürtme tipi olan “ikiz püskürtme” veya “yarı sıralı püskürtme” sisteminde kumanda 2 transistör ile gerçekleşir. 1. ve 3. silindirlerin enjektörleri aynı anda püskürtme yaparken 2. ve 4. silindirlerin enjektörlerinde püskürtme aynı anda gerçekleşir. “Sıralı püskürtmeli” enjektör sistemlerinde ise her bir silindirin enjektörü için bağımsız bir transistör bulunmaktadır ve her enjektör ayrı bir transistör ile kontrol edilir. Dört silindirli bir motorda sıralı püskürtme 1-3-4-2 şeklinde silindir sırasıyla gerçekleşir. Günümüzde yaygın olarak kullanılan direkt enjeksiyonlu püskürtme sistemlerinde sıralı püskürtme yöntemi geçerlidir. Enjektörler yakıtı püskürttükleri yere göre de ikiye ayrılırlar. Bunlardan birisinde yakıt yanma odası içerisine püskürtülürken bir diğesinde ise yakıt yanma odasının portuna püskürtülür (Duronio et al., 2020; Joe Chintagunti & Kumar Agarwal, 2024). Şekil 1’de bir benzin enjektörüne ait kesit çizimi verilmiştir.



Şekil 1. Enjektör kesit görüntüsü (medcom.id, 2024)

Enjektörde bağlantı portu iki uçlu bir soketten oluşmaktadır ve elektriksel bağlantılar enjektör solenoid valfini enerjilemektedir. Enerjilenen solenoid valfte piston hareket etmekte ve enjektör iğnesinden yakıt çıkışı sağlanmaktadır.

Enjektörden püskürtülen yakıtın miktarı 3 farklı faktöre bağlı olarak değişir. Bunlar sırasıyla yakıt basıncı, enjektör delik çapı ve son olarak da enjektör iğnesinin açık kaldığı süredir. Yakıt basıncı ve enjektör delik çapı motor üretici firma tarafından belirlenir ve motor ömrü süresince değişmezler. Motor silindrine uygulanacak yakıt miktarı için değişken tek parametre enjektörün açık kalma süresidir (Erkuş ve ark., 2015; Joe Chintagunti & Kumar Agarwal, 2024).

Enjektörün açılma periyodu ve açık kalma süresi Electronic Control Unit (ECU) tarafından belirlenmektedir. Enjektörlerin açık kalma süreleri motorun yapısına, ECU ayarlarına ve motorun sensörleri tarafından ECU'ya iletilen verilere bağlı olarak değişebilir (Otiaba et al., 2011). Motor devri ve enjektör açık kalma süresindeki değişimler ECU'nun sağlıklı çalışmasına dair önemli bilgiler içermesi bakımından arıza tespitinde kullanılabilir. Termik motorlarda enjektör açık kalma


süresini hesaplamak, motorun performansını ve yakıt verimliliğini optimize etmek için önemlidir. Bunun için enjektörün uçlarından elektriksel sinyali ölçerek motor devrini ve enjektör açık kalma süresini ölçen elektriksel donanım önemli bir ihtiyaca yanıt verebilir.

Otomobillerde yapılacak elektriksel ölçmeler ile arıza tespitine dayanan ölçme sistemleri literatürde sıklıkla incelenmiş ve önerilmiştir (Kılıç & Mevsim, 2024). Özellikle enjektöre dair elektriksel ve optik ölçmelere dair sistemler de literatürde yer almıştır. Soid ve Zainal içten yanmalı motorda enjektörden çıkan yakıt spreyinin yapısının ölçülmesi için optic bir yöntem önerdiler (Soid & Zainal, 2011). Wieclawski ve arkadaşları Hall Effect akım ölçme donanımı kullanarak enjektör akımını ölçtüler ve bu işaret üzerinden arıza analizi önerdiler (Wieclawski et al., 2020, 2022). Gailis ve Pirs enjektör hata tespiti için enjektörün sesinin ve enjektörden akan elektrik akımının ölçülmesini ve analizini önerdiler. Onların sisteminde ses ölçmek için bir kristal mikrofon ve akım ölçmek için enjektöre seri bağlı bir direnç ve ölçme yükselteci devresi bulunmaktadır (Gailis & Pirs, 2013). Chen ve Zendong da enjektör akımını seri bir direnç üzerinden ölçmeyi önermişlerdir. Onların sisteminde enjektör akım işareti opamp'li filtre ve yükselteç serisinin ardından bir mikrodenetleyicinin kesme terminaline uygulanmaktadır (Chen & Zhang, 2011). Enjektör gerilimi ölçerek motorun devrini ve enjektör açık kalma süresini ölçen bir sistem daha önce önerilmemiştir. Bu çalışmada mikrodenetleyici tabanlı bir motor devri ve enjektör açık kalma süresi ölçer sistem önerilmektedir.

Bu çalışmanın ikinci bölümünde önerilmekte olan sistem tanımlanmış, üçüncü bölümde deneysel sonuçlar verilmiş ve irdelenmiş, çalışma sonuç bölümü ile tamamlanmıştır.

2. Enjektör Açık Kalma Süresi Ölçme Sistemi

Modern motorlarda yer alan elektronik ateşleme sistemleri sayesinde enjektörler endüktif yapılı ve elektronik kontrollü vanalar şeklinde işlev görürler (H. N. Gupta, 2012). Enjektörlerin dakikadaki açılma sayısı motor devri ile uyumlu şekilde değişirken aynı zamanda motorun performansı enjektörlerin açıldıklarında açık kalma sürelerine de bağlıdır. ECU hem enjektörün doğru anda açılmasını hem de uygun süre boyunca açık kalmasını belirler ve uygular (Otiaba ve ark, 2011). Şekil 1’de görüldüğü gibi bir enjektör endüktif içeriğe sahip bir solenoid valf şeklinde bir donanıma sahiptir. Her bir enjektör iki uçlu elektriksel kontrol girişine sahiptir ve bu uçlardan uygulanan gerilim ile valf açılır ve enjektör yakıtı silindire veya silindir portuna püskürtür. Şekil 2’de enjektörlerden birisinin uçlarından dijital osiloskop ile yapılmış ölçümle alınmış gerilim değişimi görülebilir.

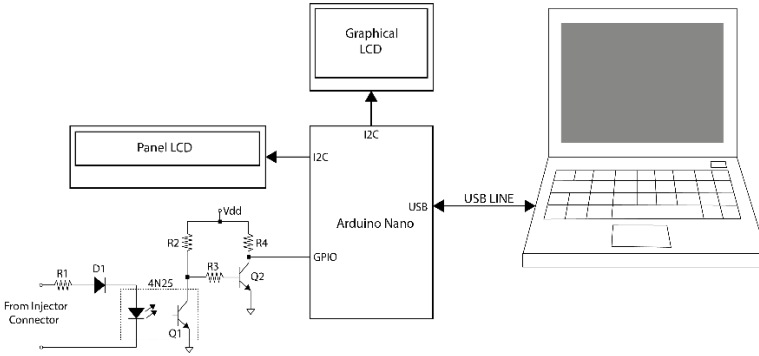


Şekil 2. Enjektör uçlarından ölçülen işaret

Şekil 2’de görülen eğride enjektörün yaklaşık 4 ms süreyle açık kaldığı anlaşılmaktadır. Bu açık kalma süresi motorun devrine, motor sıcaklığı, gaz pedalı seviyesi ve motor üzerindeki yük gibi bir dizi

değişkene bağlı olarak ECU tarafından belirlenmektedir. Ayrıca enjektörün kapanmasının ardından enjektör endüktif yapısı kaynaklı ters yönlü gerilim dikmesi görülebilmektedir. Enjektör uçlarındaki gerilimin -12 V ile +50 V arasında değiştiği dikkat çekmiştir.

Şekil 3'te bu çalışmada önerilmekte olan mikrodenetleyici tabanlı enjektör açık kalma süresi ve devir ölçme sistemine ait şema görülmektedir.




Şekil 3. Mikrodenetleyici tabanlı enjektör açık kalma süresi ölçme sistemi şeması

Ölçme sistemi mikrodenetleyici tabanlıdır ve mikrodenetleyici geliştirme kartı olarak Arduino Nano seçilmiştir (arduino.cc, 2024). Bu geliştirme kartının tercih edilme sebebi ise bu donanımın ucuz ve güvenilir olmasının yanında Arduino kullanarak tasarım yapmanın kolay ve yaygın olmasıdır. Ölçme sistemi enjektör girişlerine iki uçlu bir konnektör ile kolayca bağlanabilmektedir. Arduino ve diğer tüm mikrodenetleyicilerin terminallerinin 0 V - 5 V gerilim aralığında çalışmaları sebebiyle analog bir devre ile enjektör uçlarındaki gerilim aralığı mikrodenetleyiciye uygun gerilim seviyelerine getirilmektedir. Ayrıca mikrodenetleyici endüktif yüklerin yarattığı elektriksel gürültülerden olumsuz etkilenmektedir. Bunu engellemek ve motor ile

elektronik devreyi elektriksel yalıtım maksadıyla 4N25 optokuplörü kullanılmıştır (Semiconductors, 2002). Optokuplöre bağlı transistörlü devre ile işaretin gerilim aralığı mikrodenetleyici için uygun gerilim aralığına getirilmektedir. Bu analog devrenin bağlantısı mikrodenetleyicinin genel maksatlı giriş/çıkış terminallerinden ((General Purpose Input Output (GPIO)) birine yapılmaktadır (arduino.cc, 2024).

Önerilen ölçme sisteminde kullanılan panel LCD üzerinde motorun devri ve enjektörün açık kalma süresi kullanıcıya bildirilmektedir. Ayrıca bir grafik LCD üzerinde motor devri ve enjektör açık kalma süresi zaman ekseninde birlikte çizdirilmektedir. Bilgisayar ile olan USB bağlantısı kullanılarak mikrodenetleyici motor devri ve enjektör açık kalma sürelerini bilgisayara transfer etmektedir. Kullanılan yazılım (Arduino IDE-Serial Plotter Tool (Documentation, 2024)) ile ilgili veriler bilgisayar ekranında da grafik hale getirilebilmektedir. Bu çalışmada önerilmekte olan ölçme sistemi ProtoBoard üzerine kurulmuştur. Kurulu ölçme sistemine ait fotoğraf Şekil 4’te görülebilir.



Şekil 4: Enjektör açık kalma süresi ve devir ölçme sistemine ait fotoğraf

Şekil 4’de Arduino Nano mikrodenetleyici geliştirme kartının bilgisayar ile USB bağlantısı görülmektedir. Bu bağlantı ile ölçme sistemi ölçme verilerini bilgisayara transfer etmektedir. Grafik LCD üzerinde görülen motor devri ve enjektör açık kalma süresi eğrileri eş zamanlı olarak bilgisayar ekranında da izlenebilmektedir. Şekil 4’de görülen panel LCD üzerinde ise söz konusu bilgiler takip edilebilmektedir.


3. Deneysel Sonuçlar

Bu bölümde bu çalışmada önerilmekte olan ölçme sistemine ait deneysel sonuçlar verilmektedir. Deneysel sonuçlar dijital osiloskop ile alınmış sonuçlar ve ölçme sisteminden USB yoluyla alınmış ve bilgisayar ekranında görüntülenmiş enjektör açık kalma süresi ve motor devir eğrileri şeklindedir. Deneysel çalışma esnasında ölçmeler Hyundai Sonata (2009) marka ve model aracın motoru üzerinde gerçekleştirilmiştir. İlgili araca ait donanım bilgileri Tablo 1’de ayrıntılı olarak verilmiştir.


Tablo 1. Ölçmelerin üzerinde gerçekleştirildiği motor teknik özellikleri (H.Company, 2009)

Motor tipi	V-tipi, DOHC
Silindir adedi	6
Silindir Çapı	84 mm
Strok	75 mm
Toplam silindir hacmi	2.493 cc
Sıkıştırma oranı	10.0
Ateşleme sırası	1-2-3-4-5-6
Rölanti dev./dak.	700 ± 100
Enjektör	Elektromanyetik tip
Enjektör direnci	20°C’de 13 - 16Ω
Yakıt basıncı kPa (psi)	270 (38)

Deneysel ölçme sistemi Şekil 4'te görüldüğü gibi protoboard üzerine kurulmuş ve sonuçlar bu şekilde alınmıştır. Şekil 5'te Mikrodenetleyici geliştirme kartının GPIO pininden alınan enjektör elektriksel eğrileri görülmektedir.



(a)



(b)

Şekil 5. Enjektör giriş işaretleri a) Motor rölanti durumdayken, b) Motor devri artırılırken

Şekil 5'te alınan eğriler doğrudan enjektör uçlarından alınmamıştır. Şekil 2'de görüldüğü gibi enjektör uçlarındaki gerilimin

aralığı mikrodnetleyicinin giriş gerilim aralığı olan 0 V - 5 V aralığının oldukça dışındadır. Ayrıca önerilmekte olan ölçme sisteminin motorun elektriksel gürültülerinden etkilenmesi riskleri de bulunmaktadır. Bu sebeple optokuplör tabanlı bir analog devre tasarlanmış ve kullanılmıştır. Bu sayede mikrodnetleyicili ölçme devresi ile motorun elektriksel altyapısı birbirinden elektriksel olarak yalıtılmış, ayrıca ölçülen gerilim mikrodnetleyici çalışma gerilim aralığına getirilmiştir. Şekil 5'teki eğriler bu analog devrenin çıkışından yani mikrodnetleyici GPIO pininden alınmıştır. Şekil 5.a'da motorun rölanti devrindeyken enjektörden alınan işaret görülmektedir. Bu şekilde enjektörün açılmasına dair periyot bilgisi tespit edilebilir. Dört zamanlı termik motorlarda 720° dönüş esnasında dört zaman gerçekleşmektedir ve bu durum bir çevrim olarak tanımlanmaktadır. Her bir çevrim sırasında her enjektör bir kez tetiklenmektedir. Motor bir çevrim esnasında iki devir yapmaktadır (Cammalleri et al., 2013). Buna göre enjektör periyodu ile motor devri arasındaki matematiksel ilişki Denklem 1'de verilmiştir.


$$\text{min}^{-1} = 2 \times 60 / T_i \quad (1)$$

Burada min^{-1} motor devri ve T_i enjektör açılma periyodudur. Şekil 5.a'da görülen işarete yaklaşık enjektör açılma periyodu 180 ms civarındadır. Denklem 1'e göre motorun devrinin 666,6 RPM (Revolutions per Minute) olduğu anlaşılmaktadır. Bu devirde saniyede motor 11,11 devir ile dönmektedir. Dört zaman için geçen süre ise 180 ms'dir.

Şekil 5.b'de motor öncelikli olarak rölanti devrindeyken gaz pedalına basılarak devir arttırılmaktadır. Bu duruma dair şekilde enjektör

açılma periyodunda azalma dikkat çekmektedir. Gaz pedalın basılması ile motor yönetim sisteminin motorun devrini arttırması enjektör açılma periyodunun azalması ile sonuçlanmaktadır.

Önerilmekte olan enjektör açık kalma süresi ölçer Arduino mikrodnetleyicisi tabanlıdır. Arduino kodlarının yazılması ve derlenmesi için Arduino IDE kullanılmıştır. Kullanılan IDE içerisinde çeşitli tasarım süresince kullanılabilir modüller bulunmaktadır. Bu toolboxlar mikrodnetleyicinin kodu koşturduğu esnada mikrodnetleyiciden veri çekilmesi ve işlenmesine de izin vermektedir. USB yolu ile gerçek zamanlı olarak bilgisayara taşınan veriler Arduino IDE içerisindeki Arduino IDE Serial Plotter Tool Modülü ile grafiklenmiştir. Hem motor devir sayısı hem de enjektörün açık kalma süresi zaman ekseninde çizdirilmiştir. Motor devri ve enjektör açık kalma süresine dair grafik Şekil 6'da görülebilir.



Şekil 6. Motor devri ve enjektör açık kalma süresi değişkenlerinin Arduino IDE Serial Plotter Tool programı ile alınmış eğrileri

Şekil 6’da mavi ile görülen eğri motor devrini, kırmızı ile görülen eğri ise enjektör açık kalma süresini ifade etmektedir. Motor devri Şekil 6’da görülen eğrinin alınması esnasında 3 defa arttırılmış ve her seferinde yeniden rölanti devri seviyesine düşmesi beklenmiştir. Devir artışlarının başlangıcında yer alan dikmelerin gaz pedalına basılması esnasında ortaya çıkan elektriksel gürültüler kaynaklı olduğu değerlendirilmektedir. Motor devrinin artışa geçişi esnasında enjektörün açık kalma süresinin de hızlıca arttığı kırmızı renkli enjektör açık kalma süresi eğrisinden görülmektedir. Bunun sebebi motorun yük altında ihtiyacı olan yakıt karışımı miktarının artması olarak açıklanabilir. Motorun istenen devre gelip plato yapması ile enjektör açık kalma süresi de azalmaktadır. Ayrıca motor devri azalırken de enjektör açık kalma süresi azalmaktadır. Bahsi geçen tüm süreç ECU tarafından işletilmekte ve gözetilmektedir.

4. Tartışma ve Sonuç

Bu çalışmada enjektörün uçlarındaki elektriksel işareti ölçerek motorun devrini ve enjektörün açık kalma süresini ölçen, grafikleyen ve kaydedilmesini sağlayan bir donanım önerilmiştir. Önerilen donanım Arduino mikrodenetleyici tabanlıdır ve analog ve sayısal sistemleri bir arada barındırmaktadır. Ölçme sistemi belirtilen değişkenleri kantitatif olarak ölçerken aynı zamanda zaman ekseninde karşılaştırmalı grafiklerini de verebilmektedir. Bilgisayara da transfer edilebilen datalar sayesinde değişkenlere ait grafikler bilgisayar ortamında görüntülenebilir, kaydedilebilir ve transfer edilebilir.

Enjektörlerin açık kalma süreleri ve her bir enjektörün açılma periyodu ECU sistemi tarafından belirlenmekte ve değiştirilmektedir. Bu

parametreler motorun devri, gaz pedalına basılma düzeyi ve motor üzerindeki yük ile ilişkili olarak motor yönetim sistemi tarafından belirlenmektedir. Bu çalışmada önerilmekte olan sistem ile motor yönetim sisteminin donanım ve yazılımının arızaları tespit edilebilir. Bunun yanında otomotiv alanında eğitim ve uygulama yaptırılan atölyelerde motor yönetim sisteminin çalışması ile ilgili eğitim materyali olarak da kullanılabilir. Kolaylıkla bulunabilir malzemeler içermesi sebebiyle öğrenciler veya arıza tespit sistemine ihtiyacı olan işletmeler tarafından kolaylıkla oluşturulabilir. Malzemelerin toplam maliyetinin oldukça düşük olması (25\$'dan az) sebebiyle herkes tarafından çok sayıda yapılabilmektedir.

Kaynaklar

- arduino.cc. (2024). Nano Arduino Documentation. <https://docs.arduino.cc/hardware/nano/>
- Cammalleri, M., Pipitone, E., Beccari, S., & Genchi, G. (2013). A mathematical model for the prediction of the injected mass diagram of a S.I. engine gas injector. *Journal of Mechanical Science and Technology*, 27(11), 3253–3265. <https://doi.org/10.1007/s12206-013-0848-6>
- Chen, L., & Zhang, Z. (2011). Study on the measurement of dynamic characteristics for automotive electronic fuel injector. *Proceedings 2011 International Conference on Transportation, Mechanical, and Electrical Engineering, TMEE 2011*, 511–514. <https://doi.org/10.1109/TMEE.2011.6199253>
- Company, H. M. (2009). Owner ' S Manual Operation Maintenance Contents. Hyundai Motor Company Owner's Manual.
- Documentation, A. (2024). Using the serial plotter tool. <https://docs.arduino.cc/software/ide-v2/tutorials/ide-v2-serial-plotter/>
- Duronio, F., De Vita, A., Montanaro, A., & Villante, C. (2020). Gasoline direct injection engines – A review of latest technologies and trends. Part 2. *Fuel*, 265(December 2019), 116947. <https://doi.org/10.1016/j.fuel.2019.116947>
- ERKUŞ, B., KARAMANGİL, M. İ., & SÜRMEYEN, A. (2015). Designing a Prototype LPG Injection Electronic Control Unit for a Carburetted Gasoline Engine. *Uludağ University Journal of The Faculty of Engineering*, 20(2), 141. <https://doi.org/10.17482/uujfe.33667>
- Gailis, M., & Pirs, V. (2013). Experimental study in gasoline engine injector performance. *Engineering for Rural Development*, 364–368.
- Gupta, H. N. (2012). FUNDAMENTALS OF INTERNAL COMBUSTION ENGINES (Google eBook). PHI Learning Pvt. Ltd. <http://books.google.com/books?id=s9QNRTeYIXsC&pgis=1>
- Gupta, S., & Patidar, A. (2020). A Review on Fuel Injection System. *International Research Journal of Engineering and Technology*, 07, 358–361. www.irjet.net
- Joe Chintagunti, S., & Kumar Agarwal, A. (2024). Effects of fuel injection pressure and quantity on low octane gasoline sprays in a simulated high-pressure ambient environment of a gasoline compression ignition engine. *Fuel*, 363(X), 130793. <https://doi.org/10.1016/j.fuel.2023.130793>
- KILIÇ, E., & MEVSİM, E. (2024). Design and Application of Low-Cost Fuse Current Tester in Cars. *International Journal of Engineering and Innovative Research*, 6(1), 29–39. <https://doi.org/10.47933/ijeir.1292924>
- medcom.id. (2024). Kenali Komponen Penting Motor. <https://www.medcom.id/otomotif/tips/ybJeA4nN-kenali-komponen-penting-motor-injeksi>

- Otiaba, K. C., Ekere, N. N., Bhatti, R. S., Mallik, S., Alam, M. O., & Amalu, E. H. (2011). Thermal interface materials for automotive electronic control unit: Trends, technology and R&D challenges. *Microelectronics Reliability*, 51(12), 2031–2043. <https://doi.org/10.1016/j.microrel.2011.05.001>
- Semiconductors, V. (2002). Vishay Semiconductors Optocoupler with Base Connection. <https://www.vishay.com/docs/83725/4n25.pdf>
- Soid, S. N., & Zainal, Z. A. (2011). Spray and combustion characterization for internal combustion engines using optical measuring techniques - A review. *Energy*, 36(2), 724–741. <https://doi.org/10.1016/j.energy.2010.11.022>
- Więclawski, K., Figlus, T., Maćzak, J., & Szczurowski, K. (2022). Method of Fuel Injector Diagnosis Based on Analysis of Current Quantities. *Sensors*, 22(18). <https://doi.org/10.3390/s22186735>
- Więclawski, K., Maćzak, J., & Szczurowski, K. (2020). Electric current waveform of the injector as a source of diagnostic information. *Sensors (Switzerland)*, 20(15), 1–15. <https://doi.org/10.3390/s20154151>

CHAPTER 7

BÜYÜK DİL MODELLERİNİN MÜHENDİSLİKTEKİ ROLÜ

Dr. Öğr. Üyesi Murat IŞIK¹

¹ Kırşehir Ahi Evran Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Kırşehir, Türkiye
ORCID: 0000-0003-3200-1609, muratisik@ahievran.edu.tr

Giriş

Son yıllarda Yapay Zekâ alanında kaydedilen ilerlemelerin en dikkat çekici örneklerinden biri, büyük dil modellerinin (BDM) gelişimidir. Bu modeller, dil işleme süreçlerini sadece daha akıllı ve etkili hale getirmekle kalmamış, aynı zamanda mühendislik, sağlık, hukuk ve finans gibi çok çeşitli alanlarda devrim niteliğinde yenilikler getirmiştir (Kaddour et al. 2023). BDM'ler, doğal dil işleme (NLP) görevlerinde sağladıkları üstün performansla dikkat çekerken, mühendislik gibi daha teknik disiplinlerde de kullanılmaya başlanmıştır. Bu bölümde, büyük dil modellerinin mühendislik disiplinlerindeki mevcut ve potansiyel uygulamaları, oluşturdukları fırsatlar ve beraberinde getirdikleri teknik ve etik zorluklar ele alınacaktır. Ayrıca hazır bir BDM modelinin elimizde bulunan bir eğitim setine göre eğitilip kullanılması süreci anlatılacaktır.

Detaylara girmeden önce Büyük Dil Modellerinin mühendislik alanında kullanımına genel olarak bakılması gerekmektedir. BDM'ler, devasa miktarlarda veri ile eğitilen ve doğal dilin karmaşıklıklarını anlamak ve yeniden üretmek için geliştirilen yapay zekâ modelleridir. Bu modeller, dilin öngörülebilir yapısını kullanarak yalnızca dil işlemede değil, aynı zamanda kod üretimi, tasarım optimizasyonu, veri işleme gibi mühendislik uygulamalarında da başarı sağlamaktadır (Hou et al. 2023).

Mühendislik uygulamalarında BDM'lerin kullanım potansiyeli, özellikle karmaşık problemlerin çözümünde ortaya çıkmaktadır. Hatta BDM'ler mühendislik tasarım süreçlerinin olmazsa olmazı bir araç haline gelmiştir demek çok abartılı olmayacaktır. Tasarımda olağanüstü çözümler üretme, alternatifler geliştirme ve performans tahmini gibi süreçlerde dil modelleri, mühendislik ekiplerine değerli katkılar

sunmaktadır. BDM'ler, tasarım parametrelerinin metin tabanlı açıklamalarını işleyerek otomatikleştirilmiş tasarım ve üretim çözümleri sunabilmektedir (Göpfert et al. 2024).

BDM'lerin başarısının ardındaki temel faktörlerden biri, büyük veri kümeleri üzerinde eğitilmeleridir. Bu modeller, devasa miktarlardaki metin veri setleri üzerinden öğrenme süreçlerini optimize eder. Özellikle mühendislik gibi verinin yoğun bulunduğu alanlarda, BDM'lerin eğitimi sırasında dikkat edilmesi gereken faktörler, veri kalitesi ve çeşitliliği olarak öne çıkmaktadır (An 2023). Modelin, veri içerisindeki desenleri öğrenebilmesi ve bu bilgiyi mühendislik çözümlerine uygulayabilmesi, eğitimin başarısındaki kritik unsurlardan biridir. BDM'nin mühendislikte kullanım alanlarından bazılarını aşağıdaki gibi sıralanması mümkündür:

- Yazılım mühendisliği alanı (Wu et al. 2023).
- Veri madenciliği ve analitik süreçler (Zhang et al. 2023).
- Otonom Sistemlerde Dil Modelleri (Tagliabue et al. 2023).
- Bilimsel Araştırmalarda Otonom Sistemler (Boiko et al. 2023).
- Mühendislik Tasarım ve Simülasyon Uygulamaları (Zheng et al. 2023).
- Diğer alanlar.

BDM'lerin verimli bir şekilde kullanılabilmesi için doğru şekilde yönlendirilmeleri gerekmektedir. Bu noktada "prompt mühendisliği" adı verilen süreç devreye girer. Ancak doğru yapılandırılmış komutlarla dil modellerinden istenilen sonuçlar elde edilebilir. Bu, mühendislik uygulamalarında dil modellerinin daha verimli ve isabetli çalışmasını sağlar (Aljanabi et al. 2023).

Her ne kadar büyük dil modelleri mühendislik süreçlerinde önemli katkılar sunsa da bazı sınırlamaları bulunmaktadır. Özellikle çok büyük veri kümeleri ile eğitilmeleri gerektiği için yüksek hesaplama gücü ve kaynak gereksinimi, bu modellerin yaygın kullanımını kısıtlayan faktörler arasındadır. Ayrıca, modellerin bazen yanlış ya da hatalı sonuçlar üretebilmesi, dikkatli bir şekilde denetlenmelerini gerektirmektedir (Chowdhery et al. 2023).

Sonuç olarak, büyük dil modelleri mühendislik alanında devrim yaratabilecek bir potansiyele sahiptir. Tasarımdan veri analizine kadar geniş bir yelpazede kullanılabilen bu modeller, mühendislik ekiplerinin iş süreçlerini optimize etmelerine ve yenilikçi çözümler üretmelerine olanak tanımaktadır. Ancak, bu teknolojinin tam potansiyelinin ortaya çıkabilmesi için karşılaşılan sınırlamaların aşılması gerekmektedir.

Dil Modellerine Genel Bakış

Büyük dil modelleri (BDM), doğal dil işleme (NLP) alanında kullanılan temel yapılardır ve çeşitli dil görevlerini yerine getirmek için geliştirilmişlerdir. İlk dil modelleri, dilin istatistiksel özelliklerini kullanarak kelime dizilerinin olasılıklarını hesaplayan n-gram modelleri ve Markov zincirlerine dayanıyordu. Bu modeller, bir metindeki kelimelerin sıklıklarını inceleyerek, belirli bir kelimenin öncesindeki ya da sonrasındaki kelimeleri tahmin etmeye çalışıyordu (Douglas 2023). Ancak, bu yaklaşımlar sınırlı bellek kapasitesine sahip olduklarından, uzun bağlamli ilişkileri ve dilin karmaşık yapısını anlamakta yetersiz kalıyorlardı.

Bu eksiklikleri aşmak için geliştirilen derin öğrenmeye dayalı modeller, dilin daha derin yapılarını öğrenmeye başladı. İlk başta, RNN

(Recurrent Neural Networks) ve LSTM (Long Short-Term Memory) gibi yapılar kullanılarak daha karmaşık dil modelleri geliştirildi. Bu modeller, zaman içinde dilin dinamik yapısını anlamaya yönelik daha iyi performans sergiledi; ancak dilin karmaşıklığını tam olarak çözmek için yetersiz kaldılar. Transformer mimarisi ise bu sorunu büyük ölçüde çözdü ve büyük dil modellerinin temelini oluşturdu (Kaddour et al. 2023).

BDM'lerin evrimi, derin öğrenme ve Yapay Zekâ teknolojilerinin gelişimine paralel olarak hız kazanmıştır. Google tarafından geliştirilen BERT (Bidirectional Encoder Representations from Transformers) ve OpenAI'nin GPT (Generative Pretrained Transformer) serisi, BDM'lerin en bilinen örnekleri arasında yer alır. BERT, dilin iki yönlü anlamını öğrenmeye yönelik bir yaklaşım sunarken, GPT, dil modelleme görevlerini jeneratif bir şekilde ele almıştır (Devlin 2018).

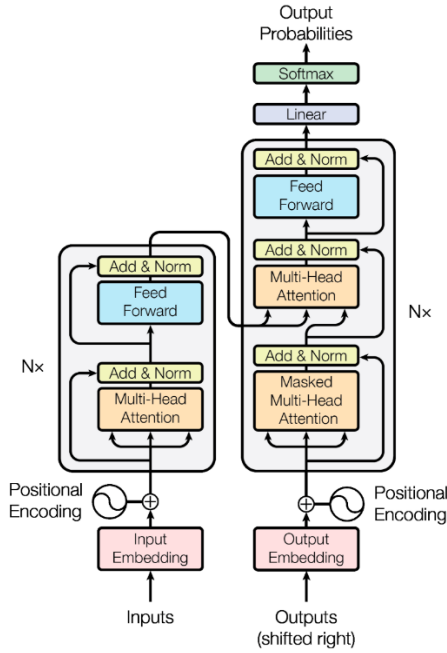
Transformer mimarisi, özellikle dikkat mekanizması (attention mechanism) ile öne çıkmaktadır. Birazdan detayları verilecek olan bu mekanizma, metindeki her kelimenin diğer kelimelerle olan ilişkisini dinamik olarak öğrenme yeteneği sağlar. Bu sayede, dil modelleri hem kısa hem de uzun bağlamları dikkate alarak daha doğru tahminlerde bulunabilir. Bu özellik, BERT ve GPT modellerinin özellikle büyük veri setleri üzerinde eğitildiğinde yüksek performans göstermesinin ana nedenidir (Chowdhery ve ark. 2023).

Büyük Dil Modellerinin Teknik Mimarisi

BDM'lerin başarısının arkasında yatan ana yapı, vektörleştirme süreçlerinden başlar. Vektörleştirme, dilin sayısal temsillerini oluşturmak için kullanılır ve dildeki her bir kelimenin veya karakterin,

belirli bir matematiksel uzayda temsil edilmesini sağlar. Bu sayede, dilin sözdizimsel ve anlamsal yapıları sayısal verilere dönüştürülebilir ve dil modelleri tarafından işlenebilir hale gelir. Word2Vec ve GloVe gibi yöntemler, dilin bu matematiksel temsillerini elde etmek için yaygın olarak kullanılan yaklaşımlardır (Douglas 2023). BDM'lerin başarısının arkasında yatan diğer bir ana yapı ise Transformer mimarisidir. Bu mimari, büyük dil modellerinin temelini oluşturan en önemli yapılardan biridir. Transformer, özellikle dikkat (attention) mekanizmasını kullanarak metin içerisindeki kelimeler arasındaki ilişkileri dinamik bir şekilde öğrenir ve bağlamları dikkate alarak metin işlemlerini gerçekleştirir. Bu dikkat mekanizması, her kelimenin diğer kelimelerle olan ilişkisini öğrenir ve modelin daha geniş bağlamlarda daha doğru tahminler yapmasını sağlar (Kaddour ve ark. 2023). Transformer mimarisi sayesinde, büyük veri setleri üzerinde çalışabilen dil modelleri oluşturulmuş ve bu sayede büyük dil modellerinin performansı önemli ölçüde artmıştır.

Transformer, doğal dil işleme (NLP) ve diğer dil görevlerinde yeni bir çığır açarak, dil modellerinin başarısında önemli bir rol oynamıştır (Luo ve ark. 2023). Transformer, büyük dil modellerinin omurgasıdır. Özellikle dikkat mekanizması (self-attention) sayesinde dilin bağlamlarını etkili bir şekilde işleyebilir. Şekil-1'de bir Transformer modelinin mimarisi görülmektedir. Şekil üzerinden modelinin temel bileşenleri olan encoder ve decoder yapısı, ayrıca self-attention ve multi-head attention mekanizmalarını görülebilir.



Şekil 1: The Transformer - model architecture (Vaswani 2017)

Transformer'ların çalışmasını anlamak için Şekil-1'de sunulan her bir mekanizmanın incelenmesi gerekmektedir.

Encoder-Decoder Genel Yapısı

Transformer mimarisinde, model iki temel bileşenden oluşur. Bunlar Encoder ve Decoder bileşenleridir. Encoder, giriş verisini alır ve dilin temsili olan bir dizi vektör oluşturur. Bu vektörler, metindeki kelimelerin anlamlarını ve bağlamlarını taşır. Decoder ise bu vektörleri kullanarak yeni bir metin üretir ya da mevcut metni işler (Zhu & Soricut 2021).

Encoder (sol taraf): Girdi dizisini işler ve girdinin anlamını temsil eden gizli bir temsiliyet seti üretir. Bu temsiliyet daha sonra decoder tarafından kullanılır.

Decoder (sağ taraf): Decoder, encoder'dan gelen temsiliyetlerle birlikte önceki çıktıları kullanarak bir sonraki kelimeyi (veya token'ı) tahmin eder. Bu işlem tekrarlanarak tüm çıktı dizisi üretilene kadar devam eder.

Her encoder ve decoder bloğu, N defa tekrar edilir (üst üste katmanlar) ve bu, modelin daha derin öğrenme yapmasına olanak tanır.

Konumsal Kodlama (Positional Encoding)

Girdi Gömmesi + Konumsal Kodlama (Sol alt): Transformer modeli, geleneksel RNN'ler (Recurrent Neural Networks) gibi ardışık yapılar kullanmadığından, token'ların sırasını doğal olarak anlayamaz. Bu sorunu çözmek için, dizideki kelimelerin sırasını anlamak amacıyla konumsal kodlamalar girdi gömmelerine eklenir. Bu kodlamalar, her kelimenin konumsal bilgisini modelin öğrenmesini sağlar ve girdi gömmeleriyle toplanarak sıranın korunmasını sağlar.

Çıktı Gömmesi + Konumsal Kodlama (Sağ alt): Benzer şekilde, decoder içinde de çıktı gömmeleri, sıralama bilgilerini modelin anlaması için konumsal kodlamalarla birleştirilir.

Multi-Head Attention

Transformer'ın temelini oluşturan dikkat mekanizması, zamanla geliştirilmiş ve optimize edilmiştir. Örneğin, temporal attention mekanizması, metinlerdeki zamansal bilgileri dikkate alarak dikkat mekanizmasını daha da güçlendirir. Bu mekanizma, metinlerde zaman damgası bulunan bilgileri işleyerek dilin zaman içerisindeki değişimini anlamaya yardımcı olur (Rosin & Radinsky 2022). Transformer mimarisinde en dikkat çekici özellik, self-attention mekanizmasıdır. Bu

mekanizma, her kelimenin metnin diğer tüm kelimeleri ile olan bağına inceleyerek kelimenin anlamını daha iyi kavramasını sağlar. Her bir kelime, diğer kelimelerle olan bağına göre bir "dikkat" değeri alır ve bu değerler üzerinden modelin kararları şekillenir. Self-attention'ın en büyük avantajı, hem kısa hem de uzun metinlerdeki karmaşık ilişkileri öğrenebilmesidir (Wang ve ark. 2020). Bununla birlikte, self-attention mekanizmasının hesaplama maliyeti oldukça yüksektir. Özellikle uzun metinlerde dikkat mekanizmasının çok fazla işlem yapması gerektiğinden, işlem süresi ve bellek kullanımı artar. Bu sorunu çözmek için çeşitli yöntemler geliştirilmiştir. Örneğin, Linformer modeli, self-attention mekanizmasının karmaşıklığını azaltarak daha verimli bir hesaplama süreci sunar (Wang ve ark. 2020).

- **Self-Attention:** Encoder içinde, self-attention mekanizması, girdi dizisindeki her kelimenin diğer tüm kelimelerle olan ilişkisini dikkate alır. Bu, modelin cümle veya dizideki uzak kelimeler arasındaki ilişkileri öğrenmesine yardımcı olur.
- **Multi-Head Attention:** Tek bir dikkat mekanizması yerine, birden fazla dikkat başlığı kullanılır. Her dikkat başlığı girdiyi farklı bir şekilde işler ve kelimeler arasındaki farklı ilişkileri öğrenir. Tüm başlıkların sonuçları birleştirilerek modelin girdi dizisini daha iyi anlaması sağlanır. Multi-head adının sebebi, birden fazla dikkat mekanizması (head) aynı anda paralel olarak çalışır ve böylece model, cümledeki farklı bölgelere dikkat edebilir.

Self-attention, her bir kelimenin diğer tüm kelimelerle olan ilişkisini öğrenir, multi-head attention ise bu dikkat mekanizmasını paralel bir şekilde işleterek dilin çok boyutlu yapısını anlamaya çalışır

(Manning ve ark. 2020). Bu yapı kullanılarak; BDM'ler, dilin çeşitli özelliklerini çıkararak öğrenme süreçlerini optimize eder. Özellik çıkarımı, dilin yapısal ve anlamsal bileşenlerini ayrıştırarak daha anlamlı bir şekilde işlenmesini sağlar. Büyük veri setleri ile yapılan eğitimlerde, model bu özellikleri öğrenerek dilin daha derin yapısını kavrar ve dilin karmaşık ilişkilerini daha iyi anlamaya başlar. Bu süreç, modelin hem dil anlama hem de dil üretme görevlerinde başarılı olmasını sağlar (Zhou ve ark. 2022).

Decoder içinde iki tür multi-head attention vardır:

- **Masked Multi-Head Attention:** Eğitim sırasında gelecekteki token'ları görmesini engellemek için, decoder'ın dikkat mekanizması maskelenir. Bu, modelin yalnızca önceden üretilen token'lara bakarak sıradaki kelimeyi tahmin etmesini sağlar.
- **Encoder-Decoder Attention:** Decoder, encoder'dan gelen temsiliyeti kullanarak girdi dizisinin ilgili kısımlarına odaklanır.

Add & Norm (Toplama ve Normalizasyon)

Her bir alt katmandan sonra (attention ya da feed-forward katmanı gibi), Transformer, rezidüel bağlantılar kullanır. Bu, alt katmana giren girdinin çıktıyla toplanmasını sağlar. Daha sonra, sonuç bir normalizasyon adımına tabi tutulur. Bu işlem, modelin eğitim sürecini stabilize eder ve derin ağların eğitiminde karşılaşılan vanishing gradient problemini önler.

Örneğin, self-attention katmanından sonra, "Add & Norm" adımı, dikkat hesaplamasının sonucuna orijinal girdiyi ekler ve sonra bu çıktı normalleştirilir.

Feed-Forward Katmanları

Multi-head attention katmanlarından sonra, her token bir ileri beslemeli sinir ağına (feed-forward neural network) ayrı ayrı gönderilir. Genellikle, iki katmanlı bir tam bağlantılı sinir ağı kullanılır. Basit olmasına rağmen, bu katman modelin daha karmaşık temsiliyeti öğrenmesine yardımcı olur. Bu katman her token için ayrı ayrı uygulanır ve modele daha fazla esneklik ve doğrusal olmayanlık katar.

Decoder'deki Maskelenmiş Multi-Head Attention

Decoder, kelimeleri sırayla üretir. Gelecekteki token'ları görmesini önlemek için dikkat mekanizması "maskelenir". Bu, modelin sadece önceki token'lara bakarak tahmin yapmasını sağlar. Bu mekanizma, otoregresif modelin yapısını korur: model sadece önceki token'lara dayanarak sıradaki kelimeyi tahmin edebilir.

Çıktı Olasılıkları (Output Probabilities)

Encoder ve decoder katmanlarından geçtikten sonra, decoder'dan gelen son çıktı, bir doğrusal katmandan geçer ve ardından softmax fonksiyonuna gönderilir. Softmax fonksiyonu, sonraki token'lar için bir olasılık dağılımı üretir. Softmax katmanı, olasılıklar üretir ve modelin sıradaki kelimeyi tahmin etmesini sağlar.

Transformer modelleri, yüksek işlem gücü ve bellek kullanımı gerektirdiğinden, bu modellerin daha verimli hale getirilmesi için çeşitli yöntemler geliştirilmiştir. Örneğin, H-Transformer modeli, dikkat hesaplamalarını hiyerarşik bir şekilde yaparak daha verimli bir işlem süreci sunar ve bellek kullanımını azaltır (Zhu & Soricut 2021). Temelde Transformer'ın Adım Adım İşleyişi aşağıdaki adımlarla gerçekleşmektedir:

1. Girdi Kodlaması (Sol Alt): Girdi token'ları (kelimeler veya alt kelimeler) önce yoğun vektörlere (embedding) dönüştürülür ve konumsal kodlamalar bu vektörlere eklenir. Bu, modelin kelimelerin dizilim sırasını anlamasına olanak tanır.
2. Encoder: Bu gömmeleri alır ve multi-head attention kullanarak her kelimenin diğer kelimelerle olan ilişkisini öğrenir. Sonuçlar bir ileri beslemeli sinir ağına gönderilir. Bu işlemler, N kez tekrar edilir, böylece model girdinin daha karmaşık temsillerini öğrenir.
3. Decoder: Çıktıyı adım adım üretir. Masked multi-head attention mekanizması, gelecekteki token'lara bakmayı engeller. Ayrıca, encoder-decoder attention ile encoder'dan gelen temsiliyetlere odaklanarak doğru çıktılar üretilir. Sonuç, softmax fonksiyonu ile işlenerek sonraki token tahmin edilir.
4. Son Çıktı: Model, olasılıkları kullanarak bir sonraki token'ı tahmin eder ve bu süreç çıktı dizisinin sonuna kadar devam eder.

Özetle, transformer mimarisi, kelimeler arasındaki bağımsız ilişkilere odaklanmak için self-attention mekanizmasını kullanarak dildeki bağlamı anlar. Multi-head attention mekanizması, modelin aynı girdiye farklı açılardan dikkat etmesine olanak tanır, böylece hem kısa hem de uzun mesafeli bağlamlar öğrenilebilir. Encoder ve decoder, birlikte çalışarak girdileri işler ve çıktı dizisini üretir. Bu yapı, dil işleme görevlerinde mükemmel performans göstermesini sağlar.

Büyük Dil Modellerinin Uygulamalar ve Gerçek Dünya Kullanım Alanları

Büyük dil modelleri (BDM), özellikle mühendislik ve yazılım geliştirme gibi teknik alanlarda büyük bir dönüşüm yaratmıştır. Bu bölümde, BDM'lerin mühendislikte ve gerçek dünyadaki çeşitli uygulamaları ele alınacaktır.

Yazılım Mühendisliğinde Büyük Dil Modelleri: Yazılım mühendisliği, BDM'lerin en başarılı uygulama alanlarından biri olmuştur. Özellikle kod üretimi, hata ayıklama ve yazılım test süreçlerinde BDM'ler oldukça etkili hale gelmiştir. Araştırmalara göre, BDM'ler yazılım mühendisliği görevlerinde birçok başarı elde etmiştir. Bu görevler arasında kod tamamlama, hata tespiti ve otomatik kod düzeltme yer alır. Bu süreçlerde BDM'ler, insan geliştiricilere yardımcı olmak için büyük ölçüde kullanılmakta ve yazılım geliştirme süreçlerini hızlandırmaktadır (Hou ve ark. 2023). ChatGPT ve Copilot gibi modeller, yazılım geliştiricilerine yardımcı olma konusunda oldukça başarılı örneklerdir. Bu modeller, geliştiricilere kod önerileri sunar ve kod yazma süreçlerinde karşılaşılan hataları otomatik olarak düzeltebilir. Ayrıca, bu modeller, geliştiricilere daha iyi tasarım ve optimizasyon önerileri sunarak yazılım projelerinin kalitesini artırır (Fan ve ark. 2023).

Otonom Sistemlerde Dil Modelleri: BDM'lerin kullanıldığı bir diğer önemli alan, otonom sistemlerdir. Otonom robotlar ve insansız hava araçları gibi sistemler, BDM'ler kullanılarak daha akıllı hale getirilmiştir. Özellikle görev planlama ve kontrol sistemlerinde BDM'ler, otonom sistemlerin daha verimli ve doğru kararlar almasını sağlar. Gerçek dünyada yapılan deneylerde, bu modellerin robotların çevreyi

algılaması ve kontrol girişlerine yanıt vermesi konusunda başarı sağladığı gösterilmiştir (Tagliabue ve ark. 2023).

Veri Analizi ve Ön İşleme: Veri bilimi ve mühendislik uygulamalarında da BDM'ler kritik bir rol oynamaktadır. Veri analitiği süreçlerinde, hatalı veri tespiti, eksik veri doldurma ve veri eşleştirme gibi görevlerde BDM'ler yüksek performans göstermektedir. GPT-4 gibi modeller, bu süreçlerdeki verimliliği artırarak, büyük veri kümelerini etkili bir şekilde işleyebilir. BDM'lerin veri işleme kapasitesi, mühendislik projelerinin başarıya ulaşmasında önemli bir katkı sağlar (Zhang ve ark. 2023).

Bilimsel Araştırmalarda Otonom Sistemler: BDM'ler, bilimsel araştırmalarda da otonom sistemlerin geliştirilmesinde kullanılmıştır. Özellikle karmaşık deneylerin tasarımı, planlanması ve yürütülmesinde dil modelleri, bilim insanlarına yardımcı olmuştur. Bu otonom sistemler, bilimsel deneyleri kendi başlarına gerçekleştirebilmekte ve başarılı sonuçlar elde edebilmektedir (Boiko ve ark. 2023).

Mühendislik Tasarım ve Simülasyon Uygulamaları: BDM'ler, mühendislik tasarım süreçlerinde de inovasyon sağlamaktadır. Mühendislik projelerinde kullanılan BDM'ler, tasarım sürecinde alternatif çözümler sunarak ve tasarım parametrelerini optimize ederek süreçlerin hızlanmasına katkıda bulunmaktadır. Örneğin, BDM'ler, karmaşık simülasyon görevlerinde mühendislik ekiplerine destek sağlayarak tasarımın başarıyla tamamlanmasına yardımcı olur (Zheng ve ark. 2023).

Diğer Uygulama Alanları: Büyük dil modellerinin uygulamaları bununla sınırlı değildir. BDM'ler tıbbi görüntüleme, hukuk, biyoteknoloji gibi birçok sektörde kullanılarak bu alanlarda yeni

çözümler sunmaktadır. Özellikle karmaşık metin analizi ve veri işleme süreçlerinde BDM'lerin etkinliği, bu teknolojinin geniş bir kullanım alanına yayılmasını sağlamaktadır. Örneğin, tıbbi uygulamalarda BDM'ler, klinik verilerin analiz edilmesinde ve teşhis süreçlerinde önemli roller üstlenmektedir (Yang ve ark. 2023).

Büyük Dil Modellerinin Sınırlamaları ve Zorlukları

Büyük dil modelleri (BDM), büyük başarılar ve geniş uygulama alanlarıyla tanınmakta olsa da, bazı önemli sınırlamalar ve zorluklarla karşı karşıyadır. Bu bölümde, BDM'lerin sınırlamaları özellikle mühendislik, veri işleme ve gerçek dünya uygulamaları bağlamında ele alınacaktır.

Veri ve Hesaplama Gücü: BDM'lerin eğitimi, çok büyük veri setleri ve yüksek hesaplama gücü gerektirir. Bu, özellikle düşük kaynaklı veya sınırlı donanımlara sahip projeler için büyük bir engel oluşturmaktadır. Büyük dil modelleri, büyük verileri işleyebilmek için devasa işlem gücüne ihtiyaç duyar ve bu da enerji tüketimi açısından oldukça maliyetli olabilir. Ayrıca, yüksek donanım ve enerji gereksinimi, bu modellerin geniş ölçekli uygulanabilirliğini kısıtlayan önemli bir faktördür (Hou ve ark. 2023).

BDM'lerin Zayıf Gerçek Dünya Uyumu: BDM'ler, gerçek dünya uygulamalarında karşılaşılan karmaşık veri yapıları ve görevler karşısında zorluklarla karşılaşabilirler. Özellikle karmaşık talimatların veya uzun metinlerin işlenmesinde dil modelleri bazen semantik kısıtlamaları göz ardı edebilir ve hatalı sonuçlar üretebilir. Bu modeller, uzun ve heterojen veri setlerini işlerken, girdilerin bağlamını tam olarak anlayamayabilir ve yanlış sonuçlara ulaşabilir (He ve ark. 2024).

Model Boyutu ve Maliyet Sorunları: Büyük dil modelleri, genellikle çok büyük boyutlardadır ve bu da depolama ve bellek kullanımı açısından sorun yaratır. Özellikle düşük maliyetli sistemlerde, bu modellerin çalıştırılması güç olabilir. Ayrıca, bu modellerin geliştirilmesi ve eğitilmesi büyük maliyetler gerektirir. Daha küçük ve hafif modeller geliştirmek için sıkıştırma ve bilgi damıtma teknikleri kullanılsa da, bu teknikler bazen modelin performansını olumsuz etkileyebilir (Liang ve ark. 2020).

Yanlılık (Bias) ve Etik Sorunlar: BDM'ler, eğitildikleri veri setlerindeki yanlılıklardan etkilenebilirler. Özellikle toplumsal, ırksal veya cinsiyet yanlılıkları gibi etik sorunlar, dil modellerinin çıktılarında ortaya çıkabilir. Bu, modelin adil ve tarafsız sonuçlar üretme kapasitesini kısıtlar ve toplumsal etkiler açısından sorunlar yaratabilir. Yanlılık ve etik sorunlar, BDM'lerin geniş çapta kullanıldığı mühendislik projelerinde ciddi sonuçlar doğurabilir (Kaddour ve ark. 2023).

Veri Güvenliği ve Gizlilik: BDM'lerin bir diğer önemli sınırlaması, veri güvenliği ve gizliliği ile ilgilidir. Bu modeller, büyük miktarlarda veri ile eğitildiğinden, kullanıcıların gizliliğini ve verilerini koruma sorunu doğar. Özellikle sağlık, finans ve hukuk gibi hassas alanlarda BDM'lerin kullanımı, güvenlik açıkları ve veri ihlalleri açısından dikkat gerektirir. Veri güvenliği, BDM'lerin gerçek dünya uygulamalarında yaygın olarak kullanılmasını kısıtlayan önemli bir zordur (Lee ve ark. 2023).

Karmaşık Görevlerde Yetersizlik: BDM'ler, karmaşık görevlerin yerine getirilmesinde bazen yetersiz kalabilirler. Örneğin, dil modelleri, karmaşık matematiksel problemleri çözerken veya teknik metinleri analiz ederken başarılı olamayabilir. Bu, özellikle mühendislik gibi

teknik alanlarda BDM'lerin başarısını sınırlandırır. Karmaşık ve spesifik mühendislik problemlerinde BDM'lerin performansı, geleneksel yaklaşımların gerisinde kalabilir (Meadows ve ark. 2023).

Büyük Dil Modellerinin Gelecek Yönelimleri

Büyük dil modellerinin (BDM) gelecekte mühendislik ve diğer teknik alanlarda nasıl evrileceği, bu teknolojilerin bugünkü başarıları ve sınırlamaları dikkate alındığında oldukça ilgi çekicidir. BDM'lerin sürekli gelişimi, daha verimli, güçlü ve uygulamaya yönelik çözümler sunmalarını sağlıyor. Bu bölümde, BDM'lerin gelecekteki potansiyel yönelimleri ve mühendislik uygulamaları üzerindeki etkileri incelenecektir.

Daha Verimli Modeller ve Enerji Tüketimi: BDM'lerin enerji tüketimi ve yüksek hesaplama gücü gereksinimi, gelecekte çözülmesi gereken önemli zorluklar arasında yer almaktadır. Bu soruna yönelik olarak, gelecekte daha kompakt ve verimli dil modellerinin geliştirilmesi beklenmektedir. Model sıkıştırma ve bilginin daha etkili damıtılması gibi yöntemlerle BDM'lerin donanım ve enerji maliyetlerini azaltmak üzerine çalışmalar devam etmektedir (Liang ve ark. 2020).

İnsan-Bilgisayar Etkileşiminde Yeni Uygulamalar: BDM'lerin insan-bilgisayar etkileşimini geliştirme potansiyeli oldukça yüksektir. Bu modeller, mühendislik ve tasarım süreçlerinde daha fazla insan girdisi almadan otonom sistemlerle etkileşime girebilir. Örneğin, gelecekte BDM'ler mühendislik tasarımlarında yaratıcı önerilerde bulunarak, tasarım süreçlerinin hızlandırılmasına katkı sağlayabilirler. Bu, özellikle otonom sistemlerde ve robotikte önemli fırsatlar sunabilir (Göpfert ve ark. 2024).

Disiplinler Arası Uygulamalar: BDM'lerin gelecekte mühendislik dışındaki disiplinlerde de geniş uygulama alanları bulması beklenmektedir. Özellikle biyoteknoloji, kimya, malzeme bilimi gibi alanlarda BDM'lerin kullanımı artmaktadır. Bu modeller, veri analizinde, yeni bileşiklerin keşfinde ve bilimsel deneylerde kullanılabilir. Ayrıca, çok modaliteyi destekleyen modellerin gelişimiyle, metin ve görsel veriler arasında daha derin bağlar kurularak disiplinler arası çalışmalarda daha fazla katkı sunabilirler (Jablonka ve ark. 2023).

Kişiselleştirilmiş Çözümler ve Otonomi: BDM'lerin gelecekte daha kişiselleştirilmiş çözümler sunması beklenmektedir. Bu modeller, kullanıcının ihtiyaçlarına göre kişiselleştirilmiş öneriler sunabilir ve belirli problemlere odaklanarak daha özelleşmiş çözümler üretebilir. Ayrıca, otonom sistemlerin daha fazla yaygınlaşmasıyla birlikte, BDM'ler daha fazla otonom karar verme süreçlerine entegre edilebilir. Örneğin, bilimsel araştırmalarda kullanılan otonom sistemler, dil modelleriyle entegre edilerek kendi başlarına deneyler planlayabilir ve yürütebilir (Boiko ve ark. 2023).

Daha İyi Verimlilik ve İnce Ayar Stratejileri: BDM'ler, gelecekte mühendislik görevlerine özgü ince ayar stratejileriyle daha verimli hale getirilebilir. Örneğin, yazılım mühendisliğinde kod üretimi ve hata ayıklama görevlerinde kullanılan modeller, ince ayar süreçleriyle mühendislik görevlerine daha spesifik çözümler üretebilir. Ayrıca, veri ön işleme ve model optimizasyonu gibi süreçlerde daha iyi sonuçlar elde edilmesi için yeni stratejiler geliştirilmektedir (Hou ve ark. 2023).

Çok Dilli ve Evrensel Modeller: Gelecekte çok dilli dil modellerinin daha da geliştirilmesi beklenmektedir. Çok dilli modeller, çeşitli dillerde ve kültürel bağlamlarda etkili bir şekilde çalışabilmekte

ve bu sayede dil bariyerlerini aşarak küresel mühendislik projelerine katkı sağlayabilmektedir. Bu modeller, mühendislik süreçlerinde dil kaynaklı sorunları çözerek küresel işbirliğini artırabilir. Çok modalite destekli dil modelleri, metin dışındaki verilerle de etkileşime girebilir, örneğin görseller, grafikler ve ses verileri ile anlamlı analizler yapabilir (Pan ve ark. 2024).

Mühendislik Alanındaki Yeni Uygulamalar: BDM'lerin mühendislik projelerinde otomasyon, tasarım optimizasyonu ve veri analitiği gibi alanlarda daha da yaygınlaşması beklenmektedir. Özellikle büyük veri kümeleri üzerinde daha derin analizler yapabilen ve bu verileri işleyebilen dil modelleri, mühendislik süreçlerinde yenilikçi çözümler sunacaktır. Örneğin, mühendislik tasarımlarında dil modelleri, alternatif tasarım çözümleri sunarak süreçleri hızlandırabilir ve daha yaratıcı sonuçlar elde edilmesine katkıda bulunabilir (Zheng ve ark. 2023).

Sonuç

Büyük dil modelleri (BDM), yapay zeka dünyasında derin bir etki yaratarak birçok farklı alanda devrim niteliğinde yenilikler getirmiştir. Özellikle mühendislik, bilimsel araştırmalar ve veri analitiği gibi teknik alanlarda büyük başarılar elde eden bu modeller, dil işleme yeteneklerini kullanarak karmaşık görevlerin üstesinden gelmektedir. BDM'lerin, mühendislik süreçlerini otomatikleştirme ve hızlandırma yetenekleri, verimliliği artırarak daha yenilikçi çözümler sunmalarını sağlamaktadır.

Ancak bu modellerin gelişimine rağmen bazı sınırlamalar devam etmektedir. Hesaplama maliyetleri, enerji tüketimi, veri güvenliği ve etik sorunlar, BDM'lerin geniş çapta uygulanmasının önündeki en büyük

engeller olarak öne çıkmaktadır. Yüksek hesaplama gücü ve büyük veri setlerine olan bağımlılık, bu modellerin özellikle kaynak sınırlaması olan projelerde kullanılmasını zorlaştırmaktadır. Buna ek olarak, yanlışlık ve doğruluk sorunları, BDM'lerin güvenilirliğini sorgulayan bir faktör olarak karşımıza çıkmaktadır.

Geleceğe baktığımızda, büyük dil modellerinin daha verimli, kişiselleştirilebilir ve disiplinler arası uygulamalara entegre edilmiş çözümler sunacağı öngörülmektedir. Özellikle mühendislik alanında, otomasyon ve tasarım süreçlerinde BDM'lerin katkısının artması beklenmektedir. Aynı zamanda, çok dilli ve çok modaliteli modellerin gelişimiyle, dil bariyerlerini aşan ve çeşitli veri türleriyle etkileşime giren daha güçlü modellerin ortaya çıkacağı düşünülmektedir. BDM'lerin potansiyelinin tam olarak hayata geçebilmesi için, bu modellerin verimliliğini artıran ve etik sorunlarını çözmeye odaklanan araştırmaların hızla devam etmesi gerekmektedir.

Örnek bir BDM eğitimi, ince ayar süreci ve hiperparametrelerin ayarlanması

Büyük dil modelleri genellikle devasa veri kümeleri üzerinde önceden eğitilmiştir (pre-trained). Bu ön eğitim aşaması, modelin temel dil bilgisi ve bağlam farkındalığı kazanmasını sağlar. Ancak, belirli bir görevde en iyi sonuçları almak için ince ayar yapılması (fine-tuning) gerekir. İnce ayar işlemi, modelin daha küçük ve görevle alakalı bir veri kümesi üzerinde eğitilerek görev özelinde optimize edilmesini içerir. Süreci daha iyi kavramak için gelişmiş bir model örneği olan GPT-3 gibi büyük bir dil modelinin ince ayar (fine-tuning) sürecine göz atabiliriz. GPT-3 ve benzeri büyük dil modelleri hem geniş ölçekli veri hem de

güçlü donanım gerektiren modellerdir. Aşağıda, OpenAI'nin GPT-3 modelini fine-tuning yaparak bir görev için optimize etmeye yönelik bir örnek sunulacaktır. Hugging Face gibi kütüphaneler şu anda GPT-3'ü doğrudan ince ayar yapmak için kullanılsa da OpenAI'nin sağladığı API üzerinden bu işlemi gerçekleştirmek mümkündür.

Verilecek örnekte, GPT-3'ü bir metin sınıflandırma veya özel metin üretimi görevi için optimize edilmektedir. Bu ince ayar, OpenAI API'si üzerinden yapılabilecektir.

Adım 1: OpenAI API'sine Erişim

Öncelikle, OpenAI'nin GPT-3 modelini kullanmak için “**openai**” kütüphanesi kurulması gerekmektedir. Aşağıdaki kod bloğu ile bu kütüphane elde edilir.

```
pip install openai # OpenAI kütüphanesi yüklenir.
```

Adım 2: Veri Seti Hazırlığı

GPT-3'ü ince ayar yapmak için kullanılan veri seti, modelin görevi anlaması ve daha spesifik sonuçlar üretmesi için uygun formatta olmalıdır. OpenAI API, JSONL (JSON Lines) formatını kabul eder. Örneğin, bir müşteri desteği chatbotu için GPT-3'ü eğitmek istediğimizi varsayalım. Veri setimiz şu formatta olabilir:

```
{"prompt": "Müşteri: Ürünüm kargoda kayboldu. Ne yapmalıyım?  
Yanıt:", "completion": "Müşteri hizmetleri: Ürün kaybolduysa öncelikle kargo şirketiyle iletişime geçmenizi öneririz. Ayrıca, biz de süreci hızlandırmak için size yardımcı olabiliriz."}  
  
{"prompt": "Müşteri: Ürünü iade etmek istiyorum. Prosedür nedir?  
Yanıt:", "completion": "Müşteri hizmetleri: İade sürecimiz oldukça basit. Ürünü aldığınız tarihten itibaren 30 gün içinde iade edebilirsiniz. İade formunu doldurun ve ürünü bize gönderin."}
```

Bu veri seti, müşteri hizmetleri chatbotunun cevap vermesini sağlayacak şekilde GPT-3'e özel olarak optimize edilir.

Adım 3: Modelin Fine-Tuning Süreci

GPT-3 modeline ince ayar yapmak için aşağıdaki Python kodu kullanılabilir. Bu kodda, OpenAI'nin GPT-3 ince ayar (fine-tuning) süreci başlatılır.

```
import openai  
  
openai.api_key = 'API_ANAHTARINIZ' # Bu alana OpenAI anahtarınız girilir.  
  
# Eğitim dosyası OpenAI sunucusuna yüklenir  
response = openai.File.create(  
    file=open("train_data.json"), # JSONL formatındaki eğitim veri setiniz  
    purpose='fine-tune'  
)  
  
file_id = response['id'] # Yüklenen dosya için bir kimlik alınır.  
  
# İnce ayar işlemi başlatılır  
fine_tune_response = openai.FineTune.create(  
    training_file=file_id,  
    model="davinci" # GPT-3'ün davinci versiyonu  
    kullanılıyor  
)  
  
# Sürecinin durumunu takip edilebilir.  
fine_tune_id = fine_tune_response['id']  
status = openai.FineTune.retrieve(id=fine_tune_id)  
  
print("Fine-tuning durumu:", status['status'])
```

Adım 4: Eğitilen Modeli Kullanma

Model ince ayar sürecini tamamladıktan sonra, bu modele sorgular gönderebilir ve görev spesifik sonuçlar alınabilir.

```
# İnce ayarlanmış modeli kullanarak tahmin yapma

response = openai.Completion.create(
    model="fine-tuned-model-id", # İnce ayarlanan model kimliği burada kullanılır
    prompt="Müşteri: Siparişim gecikti. Ne yapmalıyım?\n\nYanıt:",
    max_tokens=50
)

print(response.choices[0].text.strip())
```

Hiperparametreler ve Ayarları

1. Model Seçimi:

- OpenAI'nin GPT-3 modelleri arasında **davinci**, en güçlü modeldir ve en karmaşık görevlerde kullanılır. Daha düşük hesaplama gücü ve maliyet gerektiren görevler için **curie**, **babbage** ve **ada** modelleri de kullanılabilir.
- Tavsiye edilen: Başlangıçta **davinci** kullanımındır, ancak maliyet açısından diğer modelleri de değerlendirilebilir.

2. Learning Rate (Öğrenme Oranı):

- GPT-3 API'si, öğrenme oranını otomatik olarak optimize eder, ancak ince ayar sürecinde kullanılan veri setinin boyutuna ve karmaşıklığına göre bu ayar değişiklik gösterebilir. Genellikle API üzerinden bu parametreye doğrudan müdahale etmeye gerek kalmaz.

3. Batch Size (Toplu İşlem Boyutu):

- OpenAI, veri setine göre batch size'ı otomatik olarak ayarlasa da daha büyük veri setlerinde işlem süresi ve

verimlilik açısından batch size önemli bir faktördür. GPT-3 modelleri için batch size varsayılan olarak yüksek tutulur.

4. Epoch Sayısı:

- GPT-3 modellerinde genellikle varsayılan olarak birkaç epoch yeterlidir. OpenAI API, bu süreci otomatik olarak optimize eder, ancak veriye bağlı olarak daha fazla epoch gerektiğinde API'de bu parametre değiştirilebilir.

5. Prompt Tasarımı:

- GPT-3 modellerinde başarılı sonuçlar elde etmek için prompt (verilen giriş komutu) tasarımı çok önemlidir. Doğru yapılandırılmış bir prompt, modelin doğru sonuçlar üretmesini sağlar. Her bir görev için farklı prompt yapıları test edilmelidir.

Kaynaklar

- Aljanabi M, Yaseen MG, Ali AH, and Mohammed MA. 2023. Prompt engineering: Guiding the way to effective large language models. *Iraqi Journal For Computer Science and Mathematics* 4:151-155.
- An H. 2023. Research on the development and risks of large language models. *Theoretical and Natural Science* 25:261-265.
- Boiko DA, MacKnight R, and Gomes G. 2023. Emergent autonomous scientific research capabilities of large language models. arXiv preprint arXiv:230405332.
- Chowdhery A, Narang S, Devlin J, Bosma M, Mishra G, Roberts A, Barham P, Chung HW, Sutton C, and Gehrmann S. 2023. Palm: Scaling language modeling with pathways. *Journal of machine learning research* 24:1-113.
- Devlin J. 2018. Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:181004805.
- Douglas MR. 2023. Large language models. arXiv preprint arXiv:230705782.
- Fan A, Gokkaya B, Harman M, Lyubarskiy M, Sengupta S, Yoo S, and Zhang JM. 2023. Large language models for software engineering: Survey and open problems. 2023 IEEE/ACM International Conference on Software Engineering: Future of Software Engineering (ICSE-FoSE): IEEE. p 31-53.
- Göpfert J, Weinand JM, Kuckertz P, and Stolten D. 2024. Opportunities for large language models and discourse in engineering design. *Energy and AI*:100383.
- He Q, Zeng J, Huang W, Chen L, Xiao J, He Q, Zhou X, Liang J, and Xiao Y. 2024. Can Large Language Models Understand Real-World Complex Instructions? *Proceedings of the AAAI Conference on Artificial Intelligence*. p 18188-18196.
- Hou X, Zhao Y, Liu Y, Yang Z, Wang K, Li L, Luo X, Lo D, Grundy J, and Wang H. 2023. Large language models for software engineering: A systematic literature review. *ACM Transactions on Software Engineering and Methodology*.
- Jablonka KM, Ai Q, Al-Feghali A, Badhwar S, Bocarsly JD, Bran AM, Bringuier S, Brinson LC, Choudhary K, and Circi D. 2023. 14 examples of how LLMs can transform materials science and chemistry: a reflection on a large language model hackathon. *Digital Discovery* 2:1233-1250.
- Kaddour J, Harris J, Mozes M, Bradley H, Raileanu R, and McHardy R. 2023. Challenges and applications of large language models. arXiv preprint arXiv:230710169.
- Lee D-H, Pujara J, Sewak M, White RW, and Jauhar SK. 2023. Making large language models better data creators. arXiv preprint arXiv:231020111.
- Liang KJ, Hao W, Shen D, Zhou Y, Chen W, Chen C, and Carin L. 2020. Mixkd: Towards efficient distillation of large-scale language models. arXiv preprint arXiv:201100593.

- Luo Q, Zeng W, Chen M, Peng G, Yuan X, and Yin Q. 2023. Self-Attention and Transformers: Driving the Evolution of Large Language Models. 2023 IEEE 6th International Conference on Electronic Information and Communication Technology (ICEICT): IEEE. p 401-405.
- Manning CD, Clark K, Hewitt J, Khandelwal U, and Levy O. 2020. Emergent linguistic structure in artificial neural networks trained by self-supervision. *Proceedings of the National Academy of Sciences* 117:30046-30054.
- Meadows J, Valentino M, and Freitas A. 2023. Generating mathematical derivations with large language models. arXiv preprint arXiv:230709998.
- Pan S, Zheng Y, and Liu Y. 2024. Integrating graphs with large language models: Methods and prospects. *IEEE Intelligent Systems* 39:64-68.
- Rosin GD, and Radinsky K. 2022. Temporal attention for language models. arXiv preprint arXiv:220202093.
- Tagliabue A, Kondo K, Zhao T, Peterson M, Tewari CT, and How JP. 2023. Real: Resilience and adaptation using large language models on autonomous aerial robots. arXiv preprint arXiv:231101403.
- Vaswani A. 2017. Attention is all you need. *Advances in neural information processing systems*.
- Wang S, Li BZ, Khabsa M, Fang H, and Ma H. 2020. Linformer: Self-attention with linear complexity. arXiv preprint arXiv:200604768.
- Wu Y, Li Z, Zhang JM, Papadakis M, Harman M, and Liu Y. 2023. Large language models in fault localisation. arXiv preprint arXiv:230815276.
- Yang A, Xiao B, Wang B, Zhang B, Bian C, Yin C, Lv C, Pan D, Wang D, and Yan D. 2023. Baichuan 2: Open large-scale language models. arXiv preprint arXiv:230910305.
- Zhang H, Dong Y, Xiao C, and Oyamada M. 2023. Large language models as data preprocessors. arXiv preprint arXiv:230816361.
- Zheng Z, Ning K, Chen J, Wang Y, Chen W, Guo L, and Wang W. 2023. Towards an understanding of large language models in software engineering tasks. arXiv preprint arXiv:230811396.
- Zhou Y, Muresanu AI, Han Z, Paster K, Pitis S, Chan H, and Ba J. 2022. Large language models are human-level prompt engineers. arXiv preprint arXiv:221101910.
- Zhu Z, and Soricut R. 2021. H-transformer-1d: Fast one-dimensional hierarchical attention for sequences. arXiv preprint arXiv:210711906.

BÖLÜM 8

AÇIKLANABİLİR AI (XAI): GÜVEN, HESAP VEREBİLİRLİK VE ETİK YAKLAŞIMLAR

Öğr. Gör. Dr. Nadir SUBAŞI¹

¹ Kırklareli Üniversitesi, Teknik Bilimler Meslek Yükseokulu, Kırklareli, Türkiye, ORCID ID: 0000-0002-5657-9002, nadir.subasi@klu.edu.tr

Giriş

Son yıllarda, yapay zekanın (AI) hızlı ilerlemesi, çeşitli endüstrileri dönüştürerek makinelerin karmaşık görevleri dikkate değer bir verimlilikle gerçekleştirmesini sağladı. Bununla birlikte, AI sistemleri giderek daha karmaşık hale geldikçe, karar verme süreçlerini anlamak kritik bir endişe olarak ortaya çıkmıştır (Belle ve Papantonis, 2021).

Açıklanabilir AI (XAI) devreye girdiği yer burasıdır. XAI, AI sistemlerinin davranışını kullanıcılar için şeffaf ve anlaşılır hale getiren modeller ve teknikler geliştirmeye odaklanan bir AI alt alanıdır. Kararların nasıl alındığına dair içgörüler sağlayarak XAI, yapay zeka uygulamalarında güven, hesap verebilirlik ve etik hususları teşvik eder. Açıklanabilir AI'nın inceliklerini araştırırken, önemini, metodolojilerini ve insan anlayışı ile makine zekası arasındaki boşluğu doldurmada karşılaştığı zorlukları keşfedeceğiz.

XAI alanını daha derine inerken, çeşitli sektörler içindeki entegrasyonunun sadece teknolojik bir ilerleme değil, aynı zamanda etik bir zorunluluk olduğu ortaya çıkıyor. Örneğin, teşhis ve tedavi kararlarına yardımcı olmak için yapay zeka sistemlerinin giderek daha fazla kullanıldığı sağlık hizmetlerinde, şeffaflık ihtiyacı çok önemlidir; tıp uzmanları, hasta güvenliğini ve güvenini sağlamak için bu sistemlerin sonuçlarına nasıl ulaştıklarını anlamalıdır (Hao, 2023).

Dahası, zorluk, gelişmiş algoritmaların karmaşıklığını, kullanıcıları bunaltmadan karmaşık akıl yürütme süreçlerini iletebilen kullanıcı dostu arayüzlerin gerekliliği ile dengelemekte yatmaktadır. Teknoloji ve etiğin bu kesişimi, özellikle yapay zeka sistemleri hata yaptığında veya önyargılı sonuçlar ürettiğinde, hesap verebilirlik

hakkında kritik soruları gündeme getiriyor ve XAI'nin çeşitli endüstrilerde dağıtımını yöneten sağlam çerçeveler geliştirilmesinin önemini vurguluyor (Reddy ve Kumar, 2023).

Yapay Zeka Sistemlerinde Şeffaflığın Önemi

Yapay zeka sistemlerinde şeffaflık talebi arttıkça, etik uygulamaların desteklenmesini sağlayan düzenleyici çerçevelerin gerekliliği de artıyor. Kararların hasta sonuçlarını önemli ölçüde etkileyebileceği sağlık hizmetleri gibi sektörlerde, açıklanabilir yapay zekanın entegrasyonu sadece faydalı değil, aynı zamanda yasal ve etik standartlara uyum için de gerekli hale gelir (Feng, 2018).

Ayrıca, XAI aracılığıyla bir hesap verebilirlik kültürünü teşvik ederek, kuruluşlar, farklı demografik gruplar arasındaki sağlık eşitsizliklerini şiddetlendirdiği gösterilen algoritmik önyargılarla ilişkili riskleri azaltabilir (Noor, 2020).

Bu, teknoloji ve sosyal eşitlik arasındaki kritik bir kesişimi vurgular; Yapay zeka gelişmeye devam ederken, paydaşların model geliştirmede kapsayıcılığı önceliklendirmesi ve farklı bakış açılarının hayatımızı giderek daha fazla belirleyen algoritmaları bilgilendirmesini sağlaması zorunludur. Bu nedenle, AI'nın gelecekteki manzarası muhtemelen inovasyonu sorumlulukla birleştirme yeteneğine bağlı olacak ve hem yetenek açısından gelişmiş hem de etik düşüncelere dayanan sistemler yaratacaktır.

Açıklanabilir Yapay Zeka (XAI) Temel Kavramları

1. Açıklanabilirlik (Explainability)

Yapay zeka sistemlerinin karar verme süreçlerinin şeffaf ve anlaşılır bir şekilde sunulmasıdır. Kullanıcıların, sistemin nasıl çalıştığını ve kararlarını nasıl aldığını anlamalarını sağlar.

Açıklanabilirliğe ek olarak, XAI'nin bir diğer önemli yönü, çeşitli alanlardaki uyarlanabilirliğidir ve bu da bu sistemlerin şeffaflığı korurken belirli endüstri ihtiyaçlarını karşılamak için nasıl uyarlanabileceği sorusunu gündeme getiriyor. Örneğin, yapay zekâ odaklı teşhislerin yaygınlaştığı sağlık hizmetlerinde, algoritmaların yalnızca doğru tahminler sağlamakla kalmayıp aynı zamanda akıl yürütmelerini de etkili bir şekilde iletmelerini sağlamak hem pratisyenler hem de hastalar için çok önemli hale gelir (Petrauskas vd., 2020).

Ayrıca, AI teknolojileri geliştikçe, performanslarını değerlendirmek için kullanılan metodolojiler de öyle olmalıdır; bu, önyargıları en aza indirmek ve sonuçlardaki adaleti artırmak için çeşitli veri kümelerini entegre etmeyi içerir, böylece algoritmik hesap verebilirliği çevreleyen etik endişeleri ele alır (Kim, 2021).

Zorluk, teknik karmaşıklığı kullanıcı merkezli tasarımla dengeleyen sağlam bir çerçeve geliştirmekte ve nihayetinde paydaşların teknolojiden bunalmış olmaktan ziyade kendilerini güçlendirdikleri bir ortamı teşvik etmekte yatmaktadır.

2.Şeffaflık (Transparency)

AI sistemlerinin iç işleyişinin açık bir şekilde gösterilmesi. Bu, kullanıcıların sistemin mantığını ve verilerin nasıl kullanıldığını görmelerine olanak tanır. Bu bağlamda, kullanıcıların algoritmaların

karar alma süreçlerini daha iyi anlamalarını sağlamak için şeffaflık ve açıklık ilkeleri ön planda tutulmalıdır.

Ayrıca, Açıklanabilir Yapay Zekanın (XAI) çeşitli sektörlere entegrasyonu, kullanıcı katılımı ve güveni ile ilgili önemli hususları gündeme getiriyor. Bu sistemler, kararların bireylerin yaşamları üzerinde derin etkileri olabileceği finans ve ceza adaleti gibi alanlarda giderek yaygınlaştıkça, bir şeffaflık kültürünü teşvik etmek daha da kritik hale geliyor. Örneğin, finansal kurumlar kredi puanlaması için algoritmalar kullanıyorsa, tüketicilerin sadece puanlarının nasıl hesaplandığını değil, aynı zamanda bu hesaplamaları etkileyen faktörleri de anlamaları zorunludur (Chen vd., 2023).

Bu gereklilik, veri kaynaklarında bulunan potansiyel önyargıları ele alırken kullanıcının anlamasını öncelikli hale getiren XAI çerçeveleri geliştirmenin önemini vurgulamaktadır. Bunu yaparak, kuruluşlar hesap verebilirliği artırabilir ve algoritmik ayrımcılıkla ilişkili riskleri azaltabilir ve sonuçta çeşitli popülasyonlar arasında daha adil sonuçlara yol açabilir (Brandon, 2021).

Bu nedenle, zorluk sadece sofistike yapay zeka modelleri oluşturmakta değil, aynı zamanda netliği ve kapsayıcılığı destekleyen etik bir ortam içinde çalışmalarını sağlamada yatmaktadır.

3.Hesap Verebilirlik (Accountability)

AI sistemlerinin sonuçlarından sorumlu tutulabilmesi. Bu, özellikle sağlık hizmetleri gibi kritik alanlarda, kararların sonuçlarının izlenmesi ve gerektiğinde düzeltilmesi açısından önemlidir.

Açıklanabilir AI (XAI) entegrasyonu gelişmeye devam ettikçe, bu sistemlerde şeffaflığı ve hesap verebilirliği artırmada disiplinler arası iş

birliđinin rolünü dikkate almak giderek daha önemli hale geliyor. Etik, hukuk ve sosyal bilimler gibi çeşitli alanlardan uzmanları teknoloji uzmanlarının yanı sıra dahil ederek, kuruluşlar yapay zeka kararlarının toplumsal etkileri hakkında daha bütünsel bir anlayış geliştirebilirler. Örneđin, sađlık hizmetlerinde, bu işbirlikçi yaklaşım, tanı algoritmalarındaki marjinalleştirilmiş toplulukları orantısız bir şekilde etkileyebilecek potansiyel önyargıları belirlemeye yardımcı olabilir ve böylece adaletin önceliklendirildiđi bir ortamı teşvik edebilir (Petrauskas vd., 2020).

Ayrıca, XAI'nin etik kullanımı için açık yönergeler oluşturmak sadece mevzuata uygunluđa yardımcı olmakla kalmaz, aynı zamanda bu teknolojilerin yaygın olarak benimsenmesi için gerekli olan kamu güvenini de teşvik eder (Forzley vd., 2013).

Nihayetinde, teknik gelişmeler ve insani değerler arasındaki boşluđu kapatmak, yapay zekanın mevcut eşitsizlikleri şiddetlendirmek yerine eşitlik için bir araç olarak hizmet etmesini sađlamak için çok önemli olacaktır.

4.Algoritmik Önyargı (Algorithmic Bias)

AI sistemlerinin, eğitim verilerindeki önyargılardan etkilenerek haksız veya yanlı sonuçlar üretmesi. Bu durum, sađlık eşitsizliklerini artırabilir ve etik sorunlar yaratabilir.

Açıklanabilir Yapay Zeka (XAI) çevreleyen söylem geliştikçe, bu sistemlerin zaman içinde nasıl denetlenip geliştirilebileceđini ele almak giderek daha kritik hale geliyor. Yapay zeka karar verme süreçlerinin sürekli izlenmesi, yalnızca algoritmik önyargıları belirlemeye yardımcı olmakla kalmaz, aynı zamanda kullanıcıların kendilerini olumsuz

etkileyebilecek sonuçları sorgulama ve meydan okuma konusunda kendilerini yetkili hissettikleri bir ortamı teşvik eder. Örneğin, sağlık profesyonellerinin ve hastaların yapay zeka önerileriyle ilgili tutarsızlıkları veya endişeleri bildirebilecekleri geri bildirim döngülerini entegre etmek hem hesap verebilirliği hem de güveni önemli ölçüde artırabilir (Drea vd., 2014).

Ayrıca, çeşitli sektörlerde AI sistemlerinin adaletini ve şeffaflığını değerlendirmek için standartlaştırılmış ölçümler oluşturmak, teknolojik ilerlemelerin yanı sıra etik hususlara öncelik veren daha adil bir çerçeve oluşturmaya yardımcı olacaktır (Nordling, 2019).

Bunu yaparak kuruluşlar, yapay zekâ uygulamalarının toplum içindeki mevcut eşitsizlikleri sürdürmek yerine güçlendirme araçları olarak hizmet etmesini sağlayabilir.

Bu tür bir yaklaşım, yapay zeka sistemlerinin tasarımında ve uygulanmasında toplumsal faydayı ön planda tutarak, kullanıcıların ihtiyaçlarına daha duyarlı çözümler geliştirilmesine olanak tanır.

5.Kullanıcı Dostu Arayüzler (User-Friendly Interfaces)

Karmaşık AI süreçlerini kullanıcıların anlayabileceği şekilde sunan tasarımlar. Bu arayüzler, kullanıcıların sistemle etkileşimde bulunurken zorlanmamalarını sağlar.

Açıklanabilir Yapay Zeka (XAI) entegrasyonu gelişmeye devam ettikçe, kullanıcı katılımı ve güveniyle ilgili potansiyel zorlukları ele almak giderek daha hayati hale geliyor. Örneğin, kullanıcı dostu arayüzler karmaşık süreçleri basitleştirmek için tasarlansa da, karar vermenin kritik yönlerini aşırı basitleştirmeden gerekli bilgi derinliğini iletme için yeterince sağlam olmalıdırlar (Hammond, 2020).

Bu denge, yapay zeka önerilerinin yanlış yorumlanmasının hem bireyler hem de topluluklar için önemli sonuçlara yol açabileceği finans ve sağlık hizmetleri gibi sektörlerde özellikle çok önemlidir. Ayrıca, bir şeffaflık kültürünü teşvik etmek yalnızca kullanıcı anlayışını geliştirmekle kalmaz, aynı zamanda geri bildirim döngüsüne aktif katılımı teşvik ederek paydaşların kusurlu veri girdilerinden veya sistemik eşitsizliklerden kaynaklanabilecek algoritmik önyargılar hakkındaki endişelerini dile getirmelerini sağlar (Shin ve Shin, 2023).

Bu nedenle, kuruluşlar etik yapay zeka sistemleri geliştirmeye çalışırken, bu teknolojilerin mevcut eşitsizlikleri sürdürmek yerine güçlendirme araçları olarak hizmet etmesini sağlamak için hem erişilebilirliğe hem de hesap verebilirliğe öncelik vermek çok önemli olacaktır.

6.Etik İlkeler (Ethical Principles)

Yapay zeka sistemlerinin geliştirilmesinde ve uygulanmasında dikkate alınması gereken değerler. Bu ilkeler, adalet, şeffaflık ve hesap verebilirlik gibi unsurları içerir.

Açıklanabilir Yapay Zeka (XAI) çevreleyen diyalog gelişmeye devam ettikçe, etik bir AI geliştirme kültürünü teşvik etmenin sadece akademik bir alıştırma değil, pratik bir gereklilik olduğu giderek daha belirgin hale geliyor. Bu, kuruluşların hem geliştiriciler hem de paydaşlar için kapsamlı eğitim programları uygulamalarını ve yapay zeka sistemleriyle ilişkili hem teknik yönler hem de etik hususlar konusunda bilgili olmalarını gerektirir (Balasubramaniam vd., 2020).

Ayrıca, kapsayıcı uygulamaların çeşitli demografik gruplar arasında daha adil sonuçlara yol açtığı gösterildiğinden, tasarım

aşamasında çeşitli bakış açılarını dahil etmek algoritmik yanlılığı azaltmaya yardımcı olabilir (McCraden vd.,2020).

Sosyoloji, etik ve hukuk gibi alanlardan içgörüler alarak disiplinler arası iş birliğinin önemini vurgulayarak kuruluşlar, yapay zeka uygulamalarında kullanıcı güvenini ve hesap verebilirliğini artırırken adalete öncelik veren çerçeveler oluşturabilirler (Andrews vd., 2022).

Bilgilerle, bu yaklaşım sadece mevcut eşitsizlikleri ele almakla kalmaz, aynı zamanda kullanıcıları yaşamlarını etkileyen yapay zeka odaklı kararları eleştirel bir şekilde değerlendirmek için gerekli bilgilerle donatarak güçlendirir.

7.Model Geliştirme (Model Development)

Yapay zeka sistemlerinin tasarlanması ve eğitilmesi süreci. Bu süreçte, farklı bakış açılarını ve demografik grupları dikkate almak, daha adil ve etkili sistemler oluşturulmasına yardımcı olur.

Açıklanabilir Yapay Zeka (XAI) entegrasyonu ilerledikçe, kullanıcıların yapay zeka tarafından oluşturulan sonuçlarla ilgili tutarsızlıkları veya endişeleri bildirmelerine olanak tanıyan sağlam geri bildirim mekanizmaları oluşturmak giderek daha hayati hale geliyor. Bu katılımcı yaklaşım sadece hesap verebilirliği geliştirmekle kalmaz, aynı zamanda yapay zeka sistemlerinde sürekli bir iyileştirme kültürünü teşvik ederek geliştiricilerin gerçek dünya deneyimlerine ve çeşitli kullanıcı gruplarından gelen içgörülere dayalı algoritmaları iyileştirmelerini sağlar (Raji vd., 2020).

Ayrıca, model geliştirme sırasında disiplinler arası bakış açılarını dahil etmek hem teknik performansı hem de etik hususları ele alan daha

kapsamlı çözümlere yol açabilir ve sonuçta toplumsal değerlerle daha iyi uyumlu sistemlerle sonuçlanabilir (Shults vd., 2018).

Örneğin, sağlık profesyonellerini ve hastaları tasarım sürecine aktif olarak dahil ederek, yapay zeka araçları, marjinalleştirilmiş toplulukları olumsuz etkileyebilecek önyargıları en aza indirirken hasta bakımının nüanslarını yansıtacak şekilde uyarlanabilir. Bu nedenle, XAI'yi çevreleyen diyalog, yalnızca uyumun ötesine ve teknolojinin çeşitli sektörlerde eşitlik ve güçlendirme için bir katalizör görevi gördüğü bir ortam geliştirmeye doğru gelişmelidir.

Bu temel kavramlar, açıklanabilir yapay zekanın önemini ve uygulama alanlarını anlamada kritik bir rol oynamaktadır. XAI, AI sistemlerinin kullanıcılar tarafından daha iyi anlaşılmasını sağlayarak, güven ve etik standartların geliştirilmesine katkıda bulunur.

Yöntem ve Teknikler

Yapay zeka açıklanabilirliği için geliştirilen yöntem ve teknikler çeşitlilik gösterir. Modele özgü teknikler, karar ağaçları ve doğrusal modeller gibi belirli algoritmaların içsel özelliklerinden yararlanarak şeffaflık sağlar. Post-hoc açıklama teknikleri ise LIME ve SHAP gibi yöntemlerle karmaşık modellerin karar mekanizmalarını çözümlenmeye odaklanır. Bu yaklaşımlar, yapay zeka modellerinin "kara kutu" özelliğini aşarak, alınan kararların arkasındaki mantığı görünür kılmayı amaçlar.

Görselleştirmeler, modellerin davranışlarını ve tahminlerini grafik ve şemalarla anlaşılır kılarak, kullanıcıların karmaşık yapay zeka sistemlerini daha kolay yorumlamasına yardımcı olur. Bu teknikler,

modellerin şeffaflığını artırarak güven inşa etmeye ve karar süreçlerini daha anlaşılır kılmaya katkıda bulunur.

1.Yorumlanabilir Model Mimarileri (IMA'lar)

Yorumlanabilir Model Mimarileri (IMA'lar), yapay zeka sistemlerinin şeffaflığını ve anlaşılabilirliğini artırmak için özel olarak tasarlanmış model yapılarıdır. Karar ağaçları ve doğrusal modeller gibi mimariler, kullanıcıların karar verme süreçlerini net ve açık bir şekilde kavrayabilmelerini sağlar. Bu yaklaşım, özellikle sağlık ve finans gibi hassas alanlarda kritik öneme sahiptir, çünkü modellerin kararlarının izlenebilir ve anlaşılabilir olması güven inşa etmek için temel bir gerekliliktir.

IMA'ların en belirgin avantajı, basit ve yorumlanabilir olmalarıdır. Karmaşık matematiksel hesaplamalara gerek kalmadan, modellerin nasıl sonuca ulaştığını görselleştirmek mümkün olur. Bu özellik, yapay zeka sistemlerinin etik ve şeffaf bir şekilde dağıtılmasına olanak sağlar, böylece kullanıcılar ve karar vericiler modellerin içyüzünü daha iyi anlayabilirler (Prasath ve Priya, 2024).

2.Model-Agnostik Teknikler

Model-agnostik teknikler, yapay zeka modellerinin açıklanabilirliğini artırmak için geliştirilmiş esnek yaklaşımlardır. LIME (Yerel Yorumlanabilir Model-Agnostik Açıklamalar) ve SHAP (Shapley Additive Açıklamalar) gibi yöntemler, temel modelin mimarisinden bağımsız olarak çalışarak geniş bir uygulama yelpazesine olanak tanır. Bu teknikler, farklı türdeki modellerin karar mekanizmalarını yorumlamak için kullanılabilir, bu da onları yapay zeka uygulamalarında son derece değerli kılar.

Bu tekniklerin ayırt edici özelliği, yorumlayıcı netlik ve hesaplama verimliliği açısından farklılık göstermeleridir. LIME, örneğin, modelin belirli bir tahmini için yerel bir açıklama sağlarken, SHAP tüm özellikler için global bir önem sıralaması sunar. Bu çeşitlilik, araştırmacılara ve veri bilimcilerine farklı veri karmaşıklıkları ve model türleri için en uygun açıklama tekniğini seçme esnekliği sağlar.

Model-agnostik tekniklerin temel amacı, yapay zeka sistemlerinin "kara kutu" doğasını aşmak ve karar süreçlerinin şeffaflığını artırmaktır. Kullanıcılara modellerin nasıl ve neden belirli tahminler yaptığını anlamalarına yardımcı olarak, yapay zeka teknolojisine olan güveni pekiştirir (Wang, 2024).

3.Özellik İlişkilendirme ve Görselleştirme

Yapay zeka sistemlerinin açıklanabilirliğinde özellik ilişkilendirme ve görselleştirme teknikleri kritik bir rol oynar. Özellik ilişkilendirme yöntemleri, modellerin tahminlerinde etkili olan temel özellikleri belirleyerek, karar mekanizmalarının anlaşılmasına katkıda bulunur. Bu yaklaşım, hangi girdi özelliklerinin modelin sonuçları üzerinde daha fazla etkiye sahip olduğunu ortaya çıkarır ve karar süreçlerinin şeffaflığını artırır.

Görselleştirme stratejileri ise bu karmaşık analiz sonuçlarının kullanıcılar tarafından kolay anlaşılmasını sağlar. Grafikler, ısı haritaları, etkileşimli tablolar gibi görsel araçlar, teknik bilgiye hakim olmayan kullanıcıların bile yapay zeka modellerinin nasıl çalıştığını kavramalarına yardımcı olur. İlaç keşfi gibi kritik alanlarda, bu yaklaşım hayati kararların arkasındaki mantığın net bir şekilde anlaşılmasını sağlar.

Bu entegre yaklaşım, yapay zeka sistemlerinin şeffaflığını ve güvenilirliğini artırırken, aynı zamanda farklı disiplinlerden kullanıcıların modellerin işleyişini anlamalarına olanak tanır. Özellikle ilişkilendirme ve görselleştirme teknikleri, karmaşık yapay zeka modellerinin "kara kutu" doğasını aşarak, karar süreçlerinin daha demokratik ve anlaşılabilir olmasına katkıda bulunur (Ponzoni vd., 2023) (Schwalbe ve Finzel, 2024).

Bununla birlikte, bu alanda hala önemli zorluklar bulunmaktadır. Yorumlanabilirlik terminolojisinin standartlaştırılması ve çeşitli alanlarda tutarlı uygulamaların geliştirilmesi devam eden bir süreçtir. Açıklanabilir Yapay Zeka (XAI) alanındaki araştırma ve geliştirme çalışmaları, modellerin daha şeffaf, güvenilir ve etik bir şekilde tasarlanması için kritik öneme sahiptir. Bu sürekli gelişim, yapay zeka teknolojilerinin toplumsal kabulünü ve güvenilirliğini artırmaya yönelik önemli bir çaba olarak görülmelidir (Graziani vd., 2023).

Uygulamalar

Yapay zeka açıklanabilirliği, günümüzde birçok kritik sektörde yaşamsal öneme sahiptir. Sağlık alanında, AI destekli teşhis sistemleri doktorlara hastaların durumları hakkında detaylı ve yorumlanabilir içgörüler sağlar. Hastanın tıbbi geçmişi, semptomları ve risk faktörleri ışığında yapılan tahminlerin açıklanabilir olması, tıbbi karar destek sistemlerinin güvenilirliğini artırır.

Finans sektöründe ise kredi puanlaması ve risk değerlendirme mekanizmaları için şeffaflık zorunludur. Müşterilerin kredi başvurularının neden reddedildiğini veya onaylandığını anlamaları, adil ve şeffaf bir karar sürecinin temel gerekleridir. Otonom sistemlerde ise

açıklanabilirlik, güvenlik ve güvenilirliğin sağlanmasında kritik rol oynar. Otonom araçların veya robotik sistemlerin aldığı kararların izlenebilir ve anlaşılabilir olması, potansiyel risklerin önceden tespit edilmesine olanak sağlar.

Gelecekteki Etkileri

XAI ilkeleri, yapay zeka teknolojilerinin geleceğini şekillendirmede ve insani değerlerle ve toplumsal normlarla uyumlu olmalarını sağlamada çok önemli bir rol oynayacaktır.

XAI uygulamalarının geliştirilmesi ve benimsenmesi, çeşitli alanlarda AI çözümlerinin güvenini ve kabulünü artıracaktır.

XAI'nin sağladığı bu avantajlar, yapay zeka sistemlerinin daha şeffaf ve erişilebilir olmasına yardımcı olarak hem kullanıcıların hem de geliştiricilerin teknolojiyi daha etkin bir şekilde benimsemelerini sağlayacaktır.

Çalışma, çok disiplinli bir ortamda yapay zeka gelişiminin geleceğini tartışmak için sağlam bir temel oluşturmak amacıyla hukukçular, filozoflar, geliştiriciler, doktorlar ve sosyologlar tarafından kullanılan terminolojiyi uyumlu hale getirmeyi amaçlamaktadır.

Çalışmada, AI sistemlerinin yorumlanabilirliğini artıran çeşitli metodolojileri ve çerçeveleri kapsar. Bu kategoriler, Yorumlanabilir Model Mimarileri (IMA'lar), modelden bağımsız teknikler, özellik ilişkilendirme yöntemleri ve görselleştirme stratejilerini içerir. Her kategori, yapay zeka kararlarını kullanıcılar için daha şeffaf ve anlaşılır hale getirmede çok önemli bir rol oynar.

Önerilen terminolojinin birden fazla alanda nasıl kullanıldığını ve ayrıca sosyal ve teknik tartışmalarda çok yönlülüğünü gösteriyoruz. Bu

noktaları tıbbi alanın somut uygulaması üzerinde tartışarak, ortak bir terminolojiye duyulan ihtiyacın gerçek olduğunu ve insan-makine iş birliğinin nasıl etkili bir şekilde kurulabileceğini tanımlamak için daha fazla düşünülmesi gerektiğini gösteriyoruz. Sosyal bilimlerin yardımı olmadan sürdürülebilir bir insan-makine ortaklığı elde etmek mümkün olmayacaktır ve sosyal ve teknik bilimlerin sınırında daha fazla araştırma yapılması gerekmektedir. Bu çalışma, bilim insanları ve hümanistlerin bu tür konularda iş birliği ve etkileşim içinde olmaları için güçlü bir temel oluşturabilir.

Kaynaklar

- Andrews, P., de Sousa, T., Haefele, B., Beard, M., Wigan, M., Palia, A., & Jacquet, A. (2022). A Trust Framework for Government Use of Artificial Intelligence and Automated Decision Making. arXiv preprint arXiv:2208.10087.
- Balasubramaniam, N., Kauppinen, M., Kujala, S., & Hiekkänen, K. (2020). Ethical guidelines for solving ethical issues and developing AI systems. In *Product-Focused Software Process Improvement: 21st International Conference, PROFES 2020, Turin, Italy, November 25–27, 2020, Proceedings 21* (pp. 331-346). Springer International Publishing.
- Belle, V., & Papantonis, I. (2021). Principles and practice of explainable machine learning. *Frontiers in big Data*, 4, 688969.
- Brandon, J. (2021). Using unethical data to build a more ethical world: How CallMiner handles imperfections in speech recognition. *AI and Ethics*, 1(2), 101-108.
- Chen, X. Q., Ma, C. Q., Ren, Y. S., Lei, Y. T., Huynh, N. Q. A., & Narayan, S. (2023). Explainable artificial intelligence in finance: A bibliometric review. *Finance Research Letters*, 104145.
- Drea, C., Lumsden, V., & Bourne, J. (2014). Using practitioners' feedback to contribute to organisational development in health visiting. *Community Practitioner*, 87(12), 30-33.
- Feng, Z. (2018). Does AI Share Same Ethic with Human Being? From the Perspective of Virtue Ethics. In *Intelligence Science II: Third IFIP TC 12 International Conference, ICIS 2018, Beijing, China, November 2-5, 2018, Proceedings 2* (pp. 465-472). Springer International Publishing.
- Forzley, M., Robertson, J., & Smith, A. (2013). Legislation an essential tool for ensuring access to medicines policy goals. *WHO South-East Asia Journal of Public Health*, 2(1), 69-71.
- Graziani, M., Dutkiewicz, L., Calvaresi, D., Amorim, J. P., Yordanova, K., Vered, M., ... & Müller, H. (2023). A global taxonomy of interpretable AI: unifying the terminology for the technical and social sciences. *Artificial intelligence review*, 56(4), 3473-3504.
- Hammond, M. I., Browne, K. M., Estee, M., & Kliman-Silver, C. (2020). U.S. Patent No. 10,664,766. Washington, DC: U.S. Patent and Trademark Office.
- Hao, J. (2023, June). Towards reliable medical image analysis based on deep learning with XAI. In *International Conference on Image, Signal Processing, and Pattern Recognition (ISPP 2023)* (Vol. 12707, pp. 1281-1286). SPIE.
- Kim, H. (2021). Suggestion of Building the AI Code of Ethics through Deep Learning and Big Data Based AI. *Robotics & AI Ethics*, 6(1), 29-34.
- McCadden, M., Mazwi, M., Joshi, S., & Anderson, J. A. (2020, February). When your only tool is a hammer: ethical limitations of algorithmic fairness solutions in

- healthcare machine learning. In Proceedings of the AAAI/ACM Conference on AI, Ethics, and Society (pp. 109-109).
- Noor, P. (2020). Can we trust AI not to further embed racial bias and prejudice?. *BMJ*, 368.
- Nordling, L. (2019). A fairer way forward for AI in health care. *Nature*, 573(7775), S103-S103.
- Petrauskas, V., Damuleviciene, G., Dobrovolskis, A., Dovydaitis, J., Janaviciute, A., Jasinevicius, R., ... & Meskauskas, Z. (2020). XAI-based medical decision support system model. *IJSRP*, 10, 598-607.
- Ponzoni, I., Páez Prosper, J. A., & Campillo, N. E. (2023). Explainable artificial intelligence: A taxonomy and guidelines for its application to drug discovery. *Wiley Interdisciplinary Reviews: Computational Molecular Science*, 13(6), e1681.
- Prasath.B.R & Priya.V,"Explainable AI (XAI): Interpretable Model Architectures", *Recent Trends in Data Analysis and Data Visualization ,IIP Series, Volume 3, May, 2024, Page no.72-79, e-ISBN: 978-93-6252-474-4, DOI/Link: <https://www.doi.org/10.58532/nbennurch207>*
- Raji, I. D., Smart, A., White, R. N., Mitchell, M., Gebru, T., Hutchinson, B., & Barnes, P. (2020, January). Closing the AI accountability gap: Defining an end-to-end framework for internal algorithmic auditing. In Proceedings of the 2020 conference on fairness, accountability, and transparency (pp. 33-44).
- Reddy, G. P., & Kumar, Y. P. (2023, April). Explainable ai (xai): Explained. In 2023 IEEE Open Conference of Electrical, Electronic and Information Sciences (eStream) (pp. 1-6). IEEE.
- Schwalbe, G., & Finzel, B. (2024). A comprehensive taxonomy for explainable artificial intelligence: a systematic survey of surveys on methods and concepts. *Data Mining and Knowledge Discovery*, 38(5), 3043-3101.
- Shin, D., & Shin, E. Y. (2023). Data's impact on algorithmic bias. *Computer*, 56(6), 90-94.
- Shults, F. L., Wildman, W. J., & Dignum, V. (2018, December). The ethics of computer modeling and simulation. In 2018 Winter simulation conference (WSC) (pp. 4069-4083). IEEE.
- Wang, Y. (2024). A comparative analysis of model agnostic techniques for explainable artificial intelligence. *Research Reports on Computer Science*, 25-33.

BÖLÜM 9

ÇOKLU SENSÖR ODOMETRİ VERİSİNİN FÜZYONU: GENİŞLETİLMİŞ KALMAN FİLTRESİ İLE FÜZYON VE PERFORMANS KARŞILAŞTIRMASI

Hasan KARAKAYA¹

Dr. Mümine YILDIZ²

¹ Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Konya, Türkiye, Karayaka34@outlook.com

² Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Konya, Türkiye, ORCID: 0000-0001-8177-622X, mumineyildiz@erbakan.edu.tr

1. Giriş

Odometri, otonom robotların, konumlarını belirlemesi, çevresindeki engellerle etkileşime geçmesi, harita oluşturması ve belirlenen hedef nokta için yol planlamasının yapılmasında kilit bir rol oynamaktadır. Odometri verisinin doğruluğu zincirleme şeklinde tüm süreci etkilemektedir. Otonom robot çalışmalarının başangıcında, odometri verisinin hesaplamaları tekerlek kodlayıcılarına dayanırken ilerleyen yıllarda GPS, IMU, Kameralar ve LIDAR, sensörlerine dayanan farklı odometri hesaplanma teknikleri geliştirilmiştir. Son çalışmalarda ise sensörlerin dezavantaja düştüğü noktalarda sağlamlığı artırmak ve daha doğru sonuçlara erişmek için füzyon teknikleri kullanılmaktadır (Nguyen ve ark.,2022).

Tekerlek kodlayıcısı (enkoder) kullanılarak, tekerleğin dönüş miktarını ölçerek robota ne kadar yol aldığı hesaplamada yardımcı olur. Kodlayıcıdan alınan verilerle tekerleklerin dönme açısı bulunur; bu açı, tekerlek yarıçapıyla çarpılarak alınan yol hesaplanır. Robotun yön ve pozisyon bilgisi, iki tekerlek arasındaki farklar göz önünde bulundurulur ve böylece robotun başlangıç konumuna göre hangi yönde ne kadar hareket ettiği hesaplanır.

GPS ile odometri hesaplamasında, robotun konumunu belirlemek için GPS'ten alınan enlem, boylam ve yükseklik verilerini kullanır. GPS verileri zamana göre işlenerek robotun hareket yönü, hızı ve toplam yol bilgisi hesaplanır. Robotun konumu bu şekilde sürekli güncellenir; ancak GPS, yalnızca açık alanlarda ve belirli bir doğrulukla çalıştığı için genellikle başka sensör verileriyle (örneğin, IMU veya tekerlek kodlayıcıları) desteklenir.

IMU ile odometri hesaplamasında, robotun ivme ve açısal hız verileri kullanarak konum ve yönelim tahmini yapılır. İvme verileri hız ve konum hesaplamak için, açısal hız verileri ise robotun dönüş açısını belirlemek için kullanılır. Zamanla yapılan bu hesaplamalar robotun hareketini izlemeye olanak tanır; ancak küçük hatalar birikerek doğruluğu azaltabileceği için IMU genellikle diğer sensörlerle desteklenir.

Lidar ile odometri hesaplaması, ardışık lazer taramaları arasındaki konum değişikliklerini analiz ederek robotun hareketini tahmin eder. Her taramada çevredeki nesnelerin mesafeleri ölçülür; bu taramalar karşılaştırılarak robotun ilerlediği mesafe ve yön belirlenir. Lidar odometrisi, özellikle yüksek doğruluk gerektiren ve detaylı çevre bilgisi isteyen kapalı alanlarda avantajlıdır. Ancak düz koridorlar gibi mesafenin değişmediği ortamlarda sapmalar görülmektedir.

Kameraların kullanıldığı, görsel odometri (Visual Odometry - VO) adı verilen teknikte ise, robotun hareketini izlemek için çevresel görüntüler analiz edilir. Görsel odometri, robotun hareket ettikçe aldığı ardışık görüntü kareleri arasındaki özellikleri karşılaştırarak konum ve yön değişikliklerini hesaplar. Bu işlem sırasında, robotun çevresindeki nesnelerin konumları ve hareketleri dikkate alınır; böylece robotun hareket yoluna göre kaydettiği mesafe ve açısal değişimler hesaplanabilir (Campos ve ark.,2021). Ancak görsel odometri ortam aydınlatma şartları, görsel özelliklerin çıkarılamadığı özniteliksiz ortamlar gibi durumlarda hatalı sonuç verebilmektedir.

Kamera ve LIDAR, tekerlek kodlayıcıları ve IMU gibi sensörlerin birlikte kullanılması ile sistemlerin eksikliklerini gidermek için füzyon çalışmaları yapılmaktadır. Füzyon çalışmaları daha sağlam sistemler

oluşturarak robotun karmaşık ve dinamik ortamlarda etkili bir şekilde görev yapmasına katkı sağlar (Coyte ve ark.,2014). Bu çalışmada, otonom robotların daha hassas bir konumlandırma ve yön bulma yapmasını sağlamak için farklı sensörlerden elde edilen odometri verilerinin Genişletilmiş Kalman Filtresi (EKF) ile füzyonu sağlanmış ve sonuçlar karşılaştırmalı olarak incelenmiştir. EKF ile LIDAR'dan alınan konum ve konum değişiminden hesaplanan hız verileri, kameradan elde edilen konum, hız ve ivme verileri ile IMU'dan alınan açısal ve lineer hız verileri füzyon edilmiştir. Çalışmanın devamında Kalman filtresi, ROS (Robot Operating System) üzerinde projenin uygulama adımları ve sonuçlar yer almaktadır.

2. ROS İle Füzyon İşlemleri

Kalman filtresi, ilk kez 1960'larda R.E. Kalman tarafından geliştirilmiştir (Kalman, 1960). Bu filtre, bir sistemin durumunu zaman içinde tahmin etmek ve gözlemlerle güncellemek için matematiksel bir çerçeve sunar; ancak yalnızca doğrusal sistemler için geçerlidir. Gerçek dünya problemleri genellikle doğrusal olmayan sistemler içerdiğinden, klasik Kalman filtresi bu durumlarda yetersiz kalır. 1970'lerde, doğrusal olmayan sistemlerin analizi ihtiyacından doğan EKF, Kalman filtresinin bu sistemlere uyarlanması olarak ortaya çıkmıştır. EKF, doğrusal olmayan bir sistemde, sistemi küçük doğrusal parçalar halinde ele alarak bu parçaları lineerleştirir (Taylor serisi kullanarak). Böylece, doğrusal bir filtre ile işlem yapılabilir hale gelir. EKF, özellikle robotik, otomotiv, havacılık ve uzay gibi alanlarda, konum tahmini, navigasyon ve kontrol sistemleri gibi karmaşık uygulamalarda kullanılarak modern robotik ve kontrol sistemlerinin temel bileşenlerinden biri haline gelmiştir.

ROS (Robot Operating System), robotik uygulamalarda sensör, kamera, motor gibi bileşenlerin iletişim kurmasını ve uyum içinde çalışmasını sağlamak için kullanılan bir yazılım çerçevesidir. ROS, robot programcılarının kod yazmasını kolaylaştıran araçlar ve kütüphaneler sunmaktadır (Yıldız, ve ark. 2023).

ROS paketleri ise, belirli bir işlevi gerçekleştiren ve bir projede modüler olarak kullanılabilen yazılım birimleridir. Her paket, belirli bir görev için gereken kod, bağımlılıklar ve yapılandırma dosyalarını içerir. Örneğin, bir kamera paketi görüntü verilerini işlerken ([da Silva, ve ark. 2017]), bir Lidar paketi mesafe ölçümleri yapabilir; bu paketler bir araya getirilerek robotun tüm işlevleri yönetilebilir.

Çalışmada, robotun konum ve hız gibi dinamiklerini daha güvenilir bir şekilde tahmin etmek için sensör verilerinin etkin bir füzyonu sağlayan ROS *robot_localization* kullanılmıştır. ROS ortamında dağıtımına sunulmuş olan *robot_localization* paketi, EKF algoritmasını kullanan, robotun konumunu (nerede olduğu) ve yönünü (hangi yöne baktığı) daha doğru bir şekilde belirlemeye yardımcı olan güçlü bir yazılım aracıdır. Bir robotun, karmaşık ortamlarda etkili bir şekilde navigasyon yapabilmesi için konumunu doğru bir şekilde bilmesi kritik bir öneme sahiptir [Google Cartographer ROS Documentation]. Bununla birlikte, bir robota bağlı sensörler (örneğin GPS, IMU, tekerlek hız ölçer) her biri kendine özgü hatalar barındırdığından, sadece bir sensör verisi kullanılarak konumun kesin olarak belirlenmesi genellikle zorlayıcıdır. *robot_localization* paketi, bu zorlukları aşmak amacıyla geliştirilmiştir. Farklı sensörlerden gelen bilgileri bir araya getirerek, robotun bulunduğu konumu ve yönü daha iyi tahmin eder. Bu süreç,

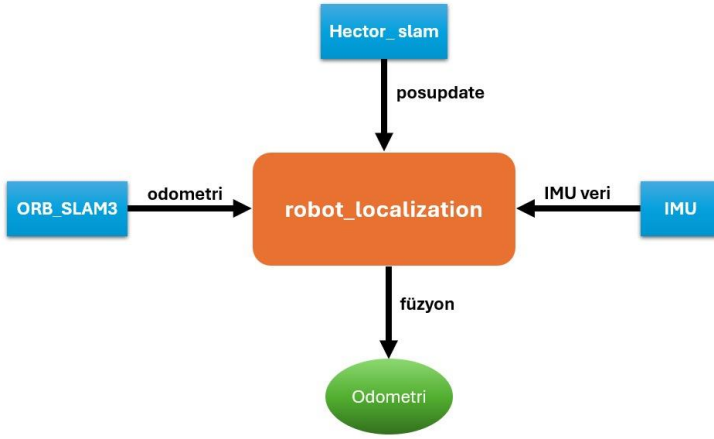
birden fazla kaynaktan alınan verilerin birleşimini içerdiğinden, robotun çevresini daha iyi algılayabilmesini sağlar.

EKF algoritması ile robotun odometrisini hesaplamak için üç veri kaynağı kullanılmıştır: *Hector_SLAM* ile elde edilen poseupdate verisi, *ORB-SLAM3* ile hesaplanan odometri bilgisi ve IMU verileri. Her bir veri kaynağının sağladığı bilgilerin öne çıkan özellikleri ve projede nasıl kullanıldıkları önemlidir.

• **Hector_SLAM:** Odometri verisini tahmin etmek için yalnızca Lidar verisini kullanır, genellikle IMU veya tekerlek kodlayıcılarına ihtiyaç duymadan konum ve yönelim bilgilerini çıkarır. Bu işlem, harita üzerinden tarama eşleştirme (scan-matching) algoritmalarıyla yapılır. Yeni ve önceki taramalar arasındaki en iyi uyum bulunarak robotun pozisyon değişikliği, yani anlık pozisyonunu (x, y) ve yönelimini (yaw) içeren poseupdate verisi hesaplanır. Bu işlem sırasında pozisyon doğruluğunu artırmak için optimizasyon uygulanır. Böylece, robotun konum ve yön bilgisi sürekli güncellenir ve harita ile uyumlu hale getirilir. Hector SLAM, genellikle yüksek frekansta güncel konum bilgisi sağladığından, özellikle iç mekan ortamlarında güvenilir bir pozisyon bilgisi sağlamaktadır, hız ve ivme verilerini sağlar.

• **ORB-SLAM3:** Görsel odometri ve SLAM (Simultaneous Localization and Mapping) için kullanılan, kamera ve IMU verilerini birleştirerek hem görsel hem de görsel-inertial odometri sağlayabilen bir algoritmadır. Bu algoritma, özellik tabanlı bir yöntemle çalışır ve özellikle kapalı alanlarda yüksek doğruluk sunar. ORB-SLAM3, odometri verisi ile pozisyon, hız ve ivme verilerini sağlar (Ibragimov, ve Afanasyev, 2017, October).

• **IMU:** Robotun açısal ve doğrusal hız bilgilerini sağlayan önemli bir sensördür. IMU verisi, ivmeölçer ve jiroskop ölçümlerini içerir ve robotun anlık hareketlerini algılar. Robotun hızlanması, yavaşlaması veya yön değiştirmesi gibi durumları hassas bir şekilde ölçerek konum hesaplamalarında güvenilir bir bilgi sağlar. IMU verisi, özellikle yüksek frekanslı hızlanma ve dönme verilerini sunduğundan, robotun hareket dinamiklerini daha doğru bir şekilde izlemek için kullanılmıştır.



Şekil 1. Sistem mimarisi

Robot Localization Paketinin Kullanımı

Robot Localization, genellikle iki ana filtreye çalışır: **Extended Kalman Filter (EKF)** ve **Unscented Kalman Filter (UKF)**. Bu filtreler, sensör verilerini kullanarak hem 2D hem de 3D odometri füzyonu gerçekleştirebilir. Bu projede EKF kullanılmıştır. *robot_lacalization* paketi, odometri verisi (tekerlek kodlayıcıları, Lidar veya görsel odometri gibi kaynaklardan gelen hız ve pozisyon bilgileri), IMU verisi (hızlanma ve açısal hız bilgileri), GPS verisi (lat-long veya UTM koordinatlarıyla küresel pozisyon) ve bazı durumlarda manyetometre gibi diğer sensörlerden alınan bilgiler kullanılır. Paket

yapılan konfigürasyonlar ile farklı veri kaynaklarını istenilen sayı ve şekilde kullanma esnekliği sağlamaktadır (Rahman, 2020).

Konfigürasyonlar

robot_localization paketi farklı mesaj tipleri ile verileri almaktadır. Verilerin doğru olarak değerlendirilebilmesi için konfigürasyonların doğru yapılması gerekmektedir. Kabul edilen mesaj tipleri:

, sensor_msgs/Imu, sensor_msgs/NavSatFix

• **nav_msgs/Odometry**: Odometri verilerini taşır ve robotun konum (pozisyon ve yönelim) ve hız bilgilerini sağlar. **pose.pose**: Robotun konum ve yönelimini içerir. **twist.twist**: Robotun doğrusal ve açısal hız bilgilerini içerir.

• **sensor_msgs/Imu**: IMU verilerini taşır ve robotun açısal hız, doğrusal ivme ve yönelim bilgisini içerir. **orientation**; robotun dünya çerçevesindeki yönelimini temsil eder (quaternion formatında). **angular_velocity**; robotun x, y, z eksenlerindeki açısal hız bilgisini sağlar. **linear_acceleration**; robotun x, y, z eksenlerindeki doğrusal ivme bilgisini sağlar.

• **sensor_msgs/NavSatFix**: GPS verisini taşır ve robotun dünya üzerindeki konumunu belirlemek için kullanılır. **latitude**; enlem bilgisi. **longitude**; boylam bilgisi. **altitude**; yükseklik bilgisi.

• **geometry_msgs/PoseWithCovarianceStamped**: Konum ve yönelim bilgisini taşır ve genellikle başlangıç pozisyonu olarak kullanılır. **pose.pose**; robotun konum ve yönelim bilgilerini içerir. **pose.covariance**; verinin doğruluğunu gösteren kovaryans matrisi.

• **geometry_msgs/TwistWithCovarianceStamped**: Robotun doğrusal ve açısal hız verilerini taşır. **twist.twist**; doğrusal ve açısal hız

bilgilerini içerir. **twist.covariance**; kovaryans matrisi, hız verisinin doğruluğunu belirtir.

Temel Parametreler

• **frequency**: Filtre çıkış frekansıdır (Hz cinsinden). Filtre, en az bir giriş mesajı alana kadar hesaplamaya başlamayacaktır. Varsayılan değer 30'dur.

• **sensor_timeout**: Sensör verilerinin zaman aşımına uğrayacağı süreyi tanımlar (saniye cinsinden). Zaman aşımı durumunda filtre, düzeltme yapmaksızın yalnızca bir tahmin döngüsü gerçekleştirir. Varsayılan değer olarak $1/\text{frequency}$ alınır, yani her bir döngü süresiyle ilişkilidir.

• **two_d_mode**: Sistem 3D bilgiler yerine yalnızca iki boyutlu verilere ihtiyaç duyduğunda kullanılır. Eğer filtre, düz zemin üzerinde ve iki boyutlu bir ortamda çalışacaksa, bu parametre true yapılarak 3D bilgiler devre dışı bırakılır. Varsayılan değer false'tur.

• **transform_time_offset**: İlgili transformu öne almak ya da geciktirmek amacıyla kullanılan bir ofset değeri sağlar. Bu özellik, diğer paketlerle uyumlu çalışmayı kolaylaştırır. Belirtilmezse, varsayılan olarak 0.0 değerini alır.

• **transform_timeout**: tf (transform) dinleyicisinin, gerekli bir transformun kullanılabilir hale gelmesi için bekleyeceği süreyi belirler. Bu süre belirtilmezse varsayılan değer 0.0 olarak kabul edilir.

• **publish_tf**: tf başlığına transform yayınlanıp yayınlanmayacağını belirler. Çoğu durumda transform bilgisinin yayımlanması önemlidir; bu nedenle varsayılan değer true olarak belirlenmiştir.

• **publish_acceleration**: Filtrenin ivme değerlerini yayınlayıp yayınlamayacağını belirtir. Varsayılan değer false olup, ivme değerlerinin yayımlanması yalnızca gerekli olduğu durumlarda önerilir.

• **map_frame**: Dünya çerçevesini temsil eden çerçeve adıdır. GPS tabanlı veya harita tabanlı pozisyon güncellemeleri gibi keskin sıçramaların meydana gelebileceği sistemlerde kullanılır. Varsayılan olarak "map" çerçevesidir.

• **odom_frame**: Kısa süreli doğruluğa sahip, yerel hareket planlaması için ideal olan odometri çerçevesini temsil eder. Zamanla küçük sapmalar gösterebilir; bu nedenle kısa süreli görevler için uygundur. Varsayılan olarak "odom" çerçevesi kabul edilir.

• **base_link_frame**: Robota fiziksel olarak bağlı çerçeveyi ifade eden base_link çerçevesidir. Bu çerçeve, robotun konumunu belirlemede temel çerçeve olarak kabul edilir. Varsayılan olarak base_link çerçevesidir.

• **world_frame**: odom_frame veya map_frame çerçevesinden biri olarak seçilir ve varsayılan olarak odom_frame'dir.

• **use_control**: Filtreleme sürecinde kontrol girdisinin kullanılmasını sağlayan parametre. Varsayılan değeri false olarak belirlenmiştir; bu, varsayılan olarak sistemin kontrol girdisini tahmin aşamasında göz ardı ettiği anlamına gelir. Ancak, kontrol girdisinin robot hareketlerini tahmin etmeye katkı sağlayabileceği durumlarda bu parametre true olarak ayarlanarak etkinleştirilebilir.

• **stamped_control**: Kullanılacak kontrol girdisinin türünü belirtir. Bu parametre, sistemin geometry_msgs'de Twist veya TwistStamped türünde bir kontrol girdisi ile çalışmasını sağlar. Bu farklı mesaj türleri,

robotun durum verisinin zamana bağlı ya da bağımsız olarak işlendiği durumlara göre seçilir.

- **control_timeout**: Son gönderilen kontrol komutunun geçerlilik süresini belirler. Bu süre, tahmin sırasında kullanılan kontrol verisinin güncelliğini koruyup korumadığını belirler ve varsayılan değeri 0.2 saniyedir. Bu parametre, sistemin beklenen tepki süresi veya hızına göre ayarlanabilir.

- **control_config**: Hangi hız bileşenlerinin kontrol edileceğini tanımlar. Bu bileşenler sırasıyla vx, vy, vz, vroll, vpitch ve vyaw hızlarını temsil eder. Parametre, sistemin belirli yönlerdeki hızların kontrol edilmesini sağlayarak hareket tahminlerinin daha doğru olmasını sağlar.

- **acceleration_limits**: Robotun kinematiğine göre tanımlanması gereken ivme sınırlarını belirler. Bu parametre, sistemin tahminlerde aşırı hızlanmayı önlemesini sağlar ve filtre tarafından hesaplanan hızın gerçekçi sınırlar dahilinde olmasını güvence altına alır.

- **deceleration_limits**: Yavaşlama sınırlarını belirler. Bu parametre, robotun ani durmalardan kaçınmasını sağlar ve yavaşlama durumunda kinematik sınırlamaların aşılmasını engeller.

- **acceleration_gains**: İvme sınırına ulaşamadığında izin verilen değişim miktarını tanımlar. Sistem bu parametreyi kullanarak ivmelenme sırasında daha yumuşak geçişler sağlayabilir.

Veri Giriş Konfigürasyonları

Sisteme girdi olarak verilen odometri, IMU gibi verilerin kullanımına dair konfigürasyonları içerir. Verilen her bir veri ve mesaj türüne ait odom0, pose0 gibi başlıkla aşağıdaki gibi konfigürasyon blokları bulunmaktadır.

```
odom0: /orb_slam3/body_odom    "Mesaj tipi: Dinlenen topic ismi"
odom0_config: [false, false, false, [x_konum, y_konum, z_konum,
                                     false, false, false, roll, pitch, yaw,
                                     true, true, false, x_hız, y-hız, z_hız,
                                     false, false, true roll_hız, pitch_hız, yaw_hız,
                                     false, false, false] x_ivme, y_ivme, z_ivme]

odom0_queue_size: 10
odom0_nodelay: false
odom0_differential: false
odom0_relative: true
odom0_pose_rejection_threshold: 2
odom0_twist_rejection_threshold: 2
```

Burada konfigürasyon matrisi içerisinde true, false ile kullanılacak konum, hız, ve ivme parametreleri belirlenir. Parametre seçimlerinin kullandığımız kaynak ve filtreye etki etmesini istediğimiz parametreler doğrultusunda yapılması oldukça önemlidir. Filtreye dail edilen parametreler filtre çıkışında elde edilecek olan odometri verisini kalitesini doğrudan etkilemektedir.

- **_queue_size:** İlgili kaynağın kuyruk kapasitesini tanımlar. Bu, veri kaynağının güncellemeleri tamponlama kapasitesini gösterir ve varsayılan değer 2'dir.

- **_nodelay:** İlgili kaynakta Nagle algoritmasını devre dışı bırakmak için kullanılır. Nagle algoritması, ağ üzerinden gönderilen küçük veri paketlerini birleştirerek daha büyük bir paket halinde gönderilmesini sağlar. Bu işlem veri iletimini yavaşlatabilir, ancak bant genişliğinden tasarruf sağlar. Bu parametre **true** olarak ayarlandığında Nagle algoritması devre dışı bırakılır, böylece odometri verileri anında ve daha hızlı iletilir. Gerçek zamanlı uygulamalarda veya hızlı veri akışı gereken durumlarda bu özellik faydalı olabilir, çünkü veri iletim

gecikmesini azaltır. Varsayılan değeri *false*'tur; yani, algoritma etkin durumdadır ve küçük veri paketleri birleşerek gönderilir.

- **_differential:** İlgili kaynak için diferansiyel modun etkin olup olmadığını belirtir. Diferansiyel mod, sürekli güncellemeler yerine sadece farkların hesaplanmasıyla sistemdeki veri miktarını azaltır. Varsayılan olarak *false*'tur.

- **_relative:** İlgili kaynağın başlangıç noktasını sıfır olarak belirler. Bu sayede odometri verisi, mevcut duruma göre görece bir pozisyon bilgisi sağlar. Varsayılan olarak *false*'tur.

- **_pose_rejection_threshold ve _twist_rejection_threshold:** Bu parametreler, veri içinde aykırı (outlier) değerlerin varlığında kullanılır ve Mahalanobis mesafesi ile ölçülen bir güven sınırı belirler. `_pose_rejection_threshold`, pozisyon verisi için belirlenen güven sınırını ifade ederken; `_twist_rejection_threshold` hız verisi için belirlenir. Eğer bir ölçüm bu mesafeyi aşarsa, sensör verisinin mevcut durumdan çok uzak olduğu varsayılır ve filtreleme sürecine dahil edilmez. Bu parametrelerin uygun şekilde ayarlanması, sistemin veri güvenilirliğini artırabilir ve yanlış ölçümlerden kaynaklanan ani durum değişikliklerini önleyebilir.

Gürültü Kovaryans Matrisi (process_noise_covariance): Bu matris, her tahmin adımından sonra toplam hataya eklenen gürültüyü ifade eder. Sistem modeliniz hareketi ne kadar doğru yansıtıyorsa, bu matrisin köşegenindeki değerler de o kadar küçük tutulabilir. Gürültü matrisi, sistemin hareket modelinin doğruluğuna göre ayarlanabilir ve her uygulamada farklılık gösterebilir. Matrisin değerleri **x, y, z** (konum), **roll, pitch, yaw** (dönüş açıları), **vx, vy, vz** (hız bileşenleri), **vroll, vpitch,**

vyaw (açısal hız bileşenleri), **ax, ay, az** (ivme bileşenleri) sırasına göre dizilmiştir.

Eğer bir değişkenin filtrede daha yavaş bir hızda yakınsadığı görülürse, bu değişkenle ilişkili diyagonal değer artırılabilir. Bu, filtrenin ilgili değişken için hata tahminini büyüterek, düzeltme adımında gelen ölçümlere daha fazla güvenmesini sağlar. Örneğin, **x** bileşeni için köşegen değeri artırmak, **x** eksenindeki tahmini hata miktarını büyütecek ve bu yöndeki ölçümlerin güvenilirliğini artıracaktır.

Bu matrisin köşegenindeki değerler arttırıldığında: Filtre, ilgili değişkenin tahmin hatasında daha fazla "gürültü" öngörür. Dolayısıyla ölçümler düzeltme adımında daha fazla dikkate alınır. Bu da sistemin ölçümlere daha fazla bağlı hale gelmesini sağlar ve hızlı değişimlere daha çabuk yanıt verir. Örneğin: **Düşük bir köşegen değeri**;sistem, model tahminlerine güvenecektir. Ancak, değişkenin hızlı yakınsamayabileceği durumlarda düşük köşegen değerleri filtre için zorlayıcı olabilir. **Yüksek bir köşegen değeri**; filtre, model tahmin hatasının büyük olduğunu kabul eder ve ölçümlere daha fazla güvenerek tahmini hızlandırır.

Başlangıç Tahmin Hata Kovaryans Matrisi (initial_estimate_covariance): Bu matris, sistemin başlangıç durumundaki hata kovaryansını tanımlar. Diyagonal değeri yüksek olan değişkenler, ilgili ölçüm geldiğinde hızlıca yakınsar. Bu matristeki değerler gürültü kovaryans matrisi ile aynı sırada dizilmiştir.

Bu matristeki diyagonal değerler arttırıldığında: Başlangıçta bu değişkenler için daha yüksek hata varsayılır. Filtre, bu değişkenlerde hızlı bir şekilde yakınsama sağlayarak ölçümleri daha çabuk dikkate alır. Ancak ölçümler eksik veya doğrudan ölçülemeyen bir değişkene büyük

bir değer atanması, tahminlerin doğruluğunu olumsuz etkileyebilir. Örneğin; x bileşeni için başlangıç diyagonal değeri yüksekse, x konumu ölçümle hızlıca düzeltilir. **Yüksek diyagonal değerler**; filtrenin ölçümlerle daha hızlı yakınsamayı sağlamasına yol açar. **Düşük diyagonal değerler**; filtrenin ölçümleri dikkate alarak yakınsaması daha uzun sürer ve modelin güvenilirliğine daha fazla güvenildiğini gösterir.

Bu iki matris birlikte, sistemin hata ve gürültü tahminlerinin ince ayarını yapmaya yardımcı olur ve farklı senaryolarda tahmin doğruluğunu optimize etmek için ayarlanabilir.

Tüm konfigürasyon ayarlamaları yapıldıktan sonra .yaml uzantılı olarak kaydedilir. EKF düğümü çalıştırılırken ayarlanan konfigürasyonların yüklenmesi için dosya belirtilir.

```
<node pkg="robot_localization" type="ekf_localization_node"
name="ekf_odom" clear_params="true">
<rosparam command="load" file="$(find
"paket_adi")/config/ekf_localization.yaml" />
```

3. Proje Uygulama Adımları

Bu uygulamada, ekibimiz tarafından toplanan çoklu sensör füzyonuna uygun Konya-Datasets kullanılmıştır[Konya Dataset. GitHub]. Veri seti kullanılarak, Hector-SLAM algoritması ile elde edilen poseupdate verisi, ORB-SLAM3 algoritması ile elde edilen odometri verisi ve IMU verileri EKF algoritması ile füzyon edilmiştir. Uygulamamızda tekerlek kodlayıcılar kullanılmamıştır (Pajaziti, 2014). Füzyon odometri verileri referans olarak kabul edilen Cartographer algoritması sonuçları ile karşılaştırılmıştır. Cartographer algoritması LIDAR ve IMU verilerini kullanarak ve optimizasyon tekniklerini


uygulayarak çalıştığı için oldukça hassas sonuçlar verdiği için referans olarak kabul edilmiştir.

➤ ORB_SLAM3, Hector_SLAM, EKF ve Cartographer paketlerinin aynı anda aynı veri seti ile çalıştırılması.

➤ Çalıştırılan paketlerden elde edilen odometri, poseupdate verilerinin ayrı ayrı *bag dosyalarına kaydedilmesi*.

➤ bag dosyalarının kapatılması sırasında transform adında hazırlanan python kodu ile cartographer paketinin yayınladığı robotun oluşturulan SLAM ortamındaki yörüngesini veren /trajectory konusu tf üzerinden odometriye dönüştürülür.

➤ Cartographer SLAM algoritmasından elde edilen harita rosrun map_server kodu ile kaydedilir.



Şekil 2. Cartographer algoritması ile elde edilen harita

➤ Elde edilen tüm bag dosyaları timestamp adı verilen python kodu ile birlikte aynı anda çalıştırılarak tek bir dosyada aynı zaman damgalı olacak şekilde kaydedilir.

➤ Karşılaştırma işlemleri için MichaelGrupp/evo paketi kullanılmıştır. Paket içerisinde evo_rpe, evo_ape, evo_traj komutları kullanılmıştır.

```
evo_traj bag merged.bag /ekf --ref /cartographer -p --plot_mode=xy -as  
--ros_map_yaml home2.yaml
```

➤ Ayrıca elde ettiğimiz odometrelerin harita üzerinde çizilmesi için kendi python kodumuz yazılmıştır.

EKF Yaml Dosyasının Hazırlanması: Konfigürasyonlar her üç mesaj türünün veya ikisinin yapıldığı farklı kombinasyonlarda kullanılmıştır. robot_localization veri girişleri için kullanılan konfigürasyon matrisleri ve açıklamaları aşağıda verilmiştir.

```
odom0: /orb_slam3/body_odom
```

```
odom0_config: [ture, true, false,  
               false, false, false,  
               false, false, false,  
               false, false, true,  
               false, false, false]
```

Pozisyon Bileşenlerinden; robotun pozisyonunun x bileşeni, (robotun sağa/sola hareketi), y bileşeni, (robotun ileri/geri hareketi) kullanılacaktır.

Robotun pozisyonunun z bileşeni (yukarı/aşağı hareketi) kullanılmayacak. Açısal Bileşenlerinden; Roll, Pitch, Yaw kullanılmayacaktır. Hız Bileşenlerinden; yalnızca Yaw hızı (dönme hızı) kullanılacaktır. İvme bileşenlerinden hiç biri kullanılmayacaktır.

pose0: /poseupdate

pose0_config: [ture, true, false,
false, false, true,
false, false, false,
false, false, false,
false, false, false]

Pozisyon Bileşenlerinden; robotun pozisyonununun x ve y bileşeni, kullanılacaktır. Açısal Bileşenlerinden; Yaw bileşeni kullanılacaktır.

imu0: cameraimu

imu0_config: [false, false, false,
false, false, false,
false, false, false,
false, false, true,
true, false, false]

Hız Bileşenlerinden; yalnızca Yaw hızı (dönme hızı) kullanılacaktır. İvme bileşenlerinden ise x bileşeni kullanılacaktır.


Odometri, pose ve imu konfüğürasyonlarının her biri için relative parametresi true ayarlanmış diğer parametreler *false* ayarlanmıştır.

4. Sonuçlar

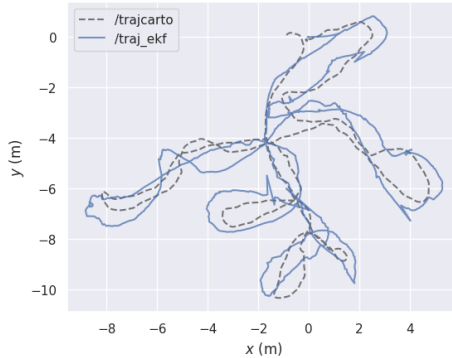
Bu çalışmada farklı sensör verileri kombinasyonları ve konfüğürasyonları ile kullanılan EKF çıktıları Cartographer ve ORB-SLAM3 çıktıları ile karşılaştırılmıştır. robot_localization paketiyle sunulan EKF algoritmasında sistem modeli her ne kadar odometri verilerinin işlenmesi için ayarlanmış ve güçlü bir araç olarak öne çıksada kofigürasyonlar büyük önem taşımaktadır. Farklı konfüğürasyonlar altında bozuk veriler elde edilebilirken, iyi ayarlamalar sonucunda ise

doğru veri elde edilmiştir. Nihai sonuçların doğruluğu, çevresel koşullar, yazılımsal yapılandırmalar ve donanımsal özellikler, elde edilen sonuçların doğruluğunu doğrudan etkilemektedir.


Özellikle EKF'nin çeşitli alanlardaki potansiyel kullanımını değerlendirirken, filtreyi farklı platformlar için uygun hale getirmek kritik bir önem taşımaktadır. Bu bağlamda, İHA'lar, kara araçları veya deniz araçları gibi farklı platformlar için özelleştirilmiş senaryolar oluşturulması gerekmektedir (Nguyen, ve ark. 2022). Bu tür özelleştirmeler, EKF'nin performansını artıracak ve uygulama alanında daha etkili sonuçlar elde edilmesini sağlayacaktır.



Şekil 3. İyi ayarlanmamış EKF çıktısı



Şekil 4. EKF ile Cartographer Odometreleri karşılaştırması



Şekil 5. x, y, z eksenler,nde kıyaslama sonuçları

Çalışmalarımız sonucunda, EKF'nin etkin kullanımı ile farklı sensörlerden gelen verilerin birleştirilmesi ve doğruluğu artırma yönünde katkı sağladığı görülmüştür. Fakat özniteliksiz ortamlar, farklı aydınlatma şartları ve hareket bozulmaları gibi farklı zorlu şartlar altında robotların güvenilirliğini artırmak için daha fazla çalışmaya ihtiyaç vardır. Bu noktada, çalışmamız, EKF'nin potansiyelini göstermekte ve gelecekteki çalışmalar için önemli bir referans oluşturmaktadır.

Kaynaklar

- Campos, C., Elvira, R., Rodríguez, J. J. G., Montiel, J. M., ve Tardós, J. D. (2021). Orb-slam3: An accurate open-source library for visual, visual-inertial, and multi-map slam. *IEEE Transactions on Robotics*, 37(6):1874–1890.
- Coyte, J. L., Li, B., Du, H., Li, W., Stirling, D., & Ros, M. (2014, July). Decision tree assisted EKF for vehicle slip angle estimation using inertial motion sensors. In 2014 International Joint Conference on Neural Networks (IJCNN) (pp. 940-946). IEEE.
- Da Silva, B. M., Xavier, R. S., do Nascimento, T. P., & Gonçalves, L. M. (2017, November). Experimental evaluation of ROS compatible SLAM algorithms for RGB-D sensors. In 2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR) (pp.1-6). IEEE.
- Google Cartographer ROS Documentation <https://google-cartographer-ros.readthedocs.io/en/latest/index.html> 2 Kasım 2024 tarihinde erişildi.
- Ibragimov, I. Z., & Afanasyev, I. M. (2017, October). Comparison of ROS-based visual SLAM methods in homogeneous indoor environment. In 2017 14th Workshop on Positioning, Navigation and Communications (WPNC) (pp. 1-6). IEEE.
- Kalman, R. E. (1960). A new approach to linear filtering and prediction problems.
- Kohlbrecher, S., Von Stryk, O., Meyer, J., & Klingauf, U. (2011, November). A flexible and scalable SLAM system with full 3D motion estimation. In 2011 IEEE international symposium on safety, security, and rescue robotics (pp. 155-160). IEEE.
- Konya Dataset. GitHub. <https://github.com/Konya-Dataset/Konya-Dataset> 2 Kasım 2024 tarihinde erişildi.
- Le, X. S., Fabresse, L., Bouraqadi, N., & Lozenguez, G. (2018). Evaluation of out-of-the-box ros2d slams for autonomous exploration of unknown indoor environments. In *Intelligent Robotics and Applications: 11th International Conference, ICIRA 2018, Newcastle, NSW, Australia, August 9–11, 2018, Proceedings, Part II 11* (pp. 283-296). Springer International Publishing.
- Moore, T., & Stouch, D. (2016). A generalized extended kalman filter implementation for the robot operating system. In *Intelligent Autonomous Systems 13: Proceedings of the 13th International Conference IAS-13* (pp. 335-348). Springer International Publishing.
- Nguyen, A. M., Nguyen, D. T., Pham, V. Q., Nguyen, H. T., Tran, D. T., Lee, J. H., & Nguyen, A. Q. (2022, November). Real-time ROS Implementation of Conventional Feature-based and Deep-learning-based Monocular Visual Odometry for UAV. In *2022 11th International Conference on Control, Automation and Information Sciences (ICCAIS)* (pp. 436-441). IEEE.

- Nguyen, Q. H., Johnson, P., & Latham, D. (2022). Performance evaluation of ROS-based SLAM algorithms for handheld indoor mapping and tracking systems. *IEEE Sensors Journal*, 23(1), 706-714.
- Pajaziti, A. (2014). Slam-map building and navigation via ros. *International Journal of Intelligent Systems and Applications in Engineering*, 2(4), 71-75.
- Rahman, Z. (2020). How to use the ROS robot localization package. Medium. <https://medium.com/@zillur-rahman/how-to-use-the-ros-robot-localization-package-534fe04014d3>
- Robot Operating System Documentation. <https://wiki.ros.org/Documentation>
- Yıldız, M., Dündar, Ö., Karalı, M. & Yavşan, E. (2023). Robot İşletim Sistemi ve Hector SLAM Paketinin Kullanımı. *Bilgisayar ve Elektronik Bilimlerinde Güncel Gelişmeler*, Iksad Publications 2, 61-81.

BÖLÜM 10

MİKROALG ÜRETİMİNDE SÜRDÜRÜLEBİLİR ENDÜSTRİYEL UYGULAMALARIN İNCELENMESİ

¹Dr. Çetin YAĞCILAR

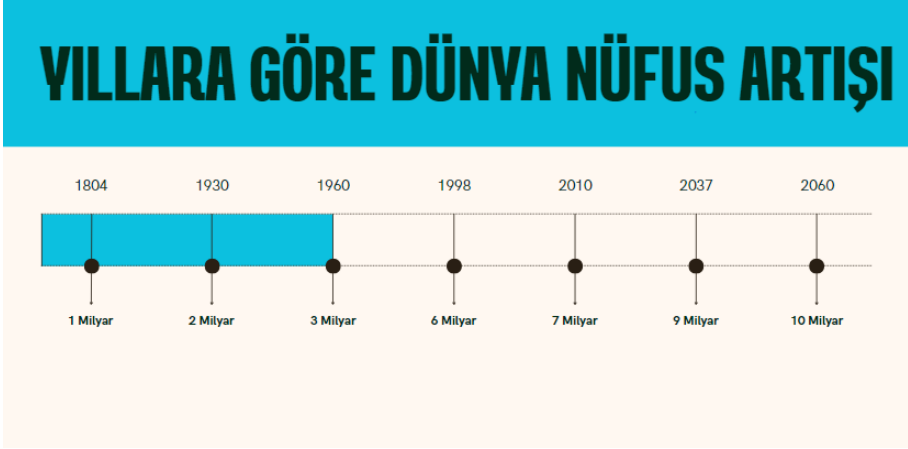
²Dr. Öğr. Üyesi Cemal POLAT

¹ Tekirdağ Namık Kemal Üniversitesi, Fen Edebiyat Fakültesi, Biyoloji Bölümü, Tekirdağ, Türkiye, ORCID ID: 0000-0002-4683-820X, cyagcilar@nku.edu.tr

² Tekirdağ Namık Kemal Üniversitesi, Ziraat Fakültesi, Zootekni Bölümü, Tekirdağ, Türkiye, ORCID ID: 0000-0002-7419-2864, cpolat@nku.edu.tr

Giriş

Mevcut verilere göre 2024 yılı Dünya nüfusu Birleşmiş Milletler verileri göz önüne alındığında ortalama olarak 8,189,000,000 kişi olduğu ve bu rakamın 2060 yılına gelindiğinde yaklaşık olarak 10 milyar olacağı tahmin edilmektedir ("Worldometer," 2024) (Şekil 1).




Şekil 1. Ön Görülen Dünya Nüfusu 2060 Yılı [Bu görüntü Canva ile oluşturuldu: https://www.canva.com/design/DAGXNRaGYCA/eRastsON--4_u3OHGHZCrg/edit?utm_content=DAGXNRaGYCA&utm_campaign=designshare&utm_medium=link2&utm_source=sharebutton]

Giderek artan Dünya nüfusu, tarımsal ürünlere olan talebin de paralel olarak artmasına yol açmakta ancak, çeşitli sosyo-ekonomik ve çevresel faktörler nedeniyle tarımsal üretimin azalması, gıda kaynaklarının yetersiz hale gelmesine neden olmaktadır (Junaid ve Gokce, 2024). Bu artan nüfusun sağlıklı beslenmesi için bitkisel ve hayvansal ürünlerin aynı zamanda fosil yakıt olarak bilinen petrol ürünlerinin de talebin karşılanması için üretim miktarının artırılması yeterli değildir (Fabris vd., 2020). Tarım kaynaklarının sürdürülebilir şekilde devam ettirilebilmesi gelecek yıllarda gıda güvenliğinin oluşturulması, yoksulluğun, açılığın ve yetersiz beslenmeye bağlı birçok

olumsuz etkinin giderilmesi için önemle üstünde durulması gereken bir zorunluluktur (Ahmed vd., 2022). Gerek yeterli ve güvenli gıda gerekse alternatif yakıt için, yükselen taleplerin karşılaması için yeni sürdürülebilir kaynak ve çözümlerin geliştirilmesi gerekmektedir.

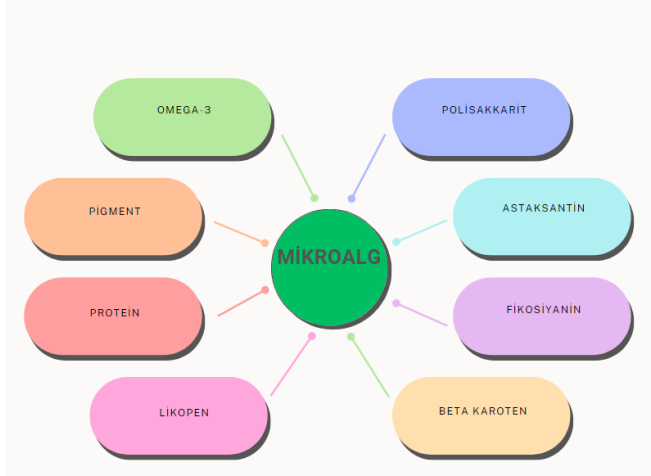
Mikroalgler ökaryotik ve prokaryotik siyanobakterileri içeren çeşitli ortam koşullarında büyüme özelliğine sahip 3 ila 30 µm arasında farklı boyut ve şekillere sahip fotosentetik tek hücreli organizmalar olarak tanımlanmaktadır (Lehmuskero, Chauton ve Boström, 2018; Aizpuru ve González-Sánchez, 2024; Jadhav ve Rao, 2024). Mikroalg olarak tanımlanan fotosentetik organizmalar farklı teknolojik alanlarda kullanılabilir özellikleri bulunabilen değerli ürünlerdir. Bu ürünler ya doğal güneş ışığını ya da yapay ışık kaynağı ile karbondioksiti ve besin ortamlarını kullanarak faydalı biyokütle üretebilen organizmalardır (Bora vd., 2024; Ramandani vd., 2024) (Şekil 2).



Şekil 2. Mikroalg Büyümesi

50000 den fazla tür çeşitliliği olan mikroalgler yüksek protein, omega-3 yağ asitleri ve renk maddeleri gibi yüksek değerli ürünler

içermektedirler (Abou-Shanab, Hwang, Cho, Y., Min ve Jeon, 2011; Yang, Fan, Cao, Wang, Mou ve Sun, 2024) (Şekil 3).



Şekil 3. Mikroalglerden Elde Edilen Ürünler [Bu görüntü Canva ile oluşturuldu]

Günümüzde mikroalgler gıda sektöründe, hayvan yemlerinde, su ürünleri yetiştiriciliğinde, kozmetik ve yakıt endüstrisi gibi pek çok farklı ticari alanda kullanım bulabilmektedir (Priyadarshani ve Rath, 2012; Olaizola ve Grewe, 2019). Bu nedenle birçok sektör alanında kullanılması bu ürünlerin gelecek için önemli olduğunu göstermektedir.

Mikroalg Yetiştiriciliği

Mikroalgler dış ortamda ötrofik koşullar altında yüksek biyokütle oranlarına ulaşabilmekte ancak elde edilecek oranlara bakıldığında yeterli olamamakta böylelikle son yıllarda yapay büyüme ortamları geliştirerek elde edilecek biyokütle konsantrasyonlarının artırılması için birçok çalışmaya odaklanılmıştır (Fabris vd., 2020). Tatlı su, tuzlu su ve atık su gibi çeşitli yetiştirme koşulları ve farklı besin ortamlarında

mikroalg hücrelerinin büyüme hızı ve hücre içeriği farklılık gösterebilmektedir (Chew vd., 2018).


Mikroalg hücre büyümesi için birçok faktör belirleyici etki etmekte ve bu etki ile mikroalgin besin içeriği ve miktarı değişmektedir (Koller vd., 2012). Bu etkiler, abiyotik, biyotik ve kültürün büyüme süreci ile ilgili olarak ışık yoğunluğu, pH değeri, kültürün havalandırılması, sıcaklık gibi parametreler ile kültüre ilave edilen karbon (C), azot (N), fosfor (P), kükürt (S), potasyum (K), demir (Fe) gibi besin elementleri önemli rol oynamaktadır (Koller vd., 2012; Markou, Vandamme ve Muylaert, 2014; Okoro, Azimov, Munoz, Hernandez ve Phan, 2019) (Şekil 4). Bu faktörlerin optimal düzeyde tutulması, kültür ortamının verimliliğini ve sürdürülebilirliğini artırmak için gereklidir.



Şekil 4. Mikroalgin Büyüme ve Gelişimini Etkileyen Faktörler [Bu görüntü Canva ile oluşturuldu] (Okoro VD., 2019; Chowdury, Nahar ve Deb, 2020)

Alg yetiştiriciliği fikri, 1952 yılında Washington' da bulunan Carnegie Enstitüsü tarafından ortaya atılmış, 1960 yılında “Japonya


Beslenme Derneği”, bu fikri büyük çaplı açık sirkülasyon sistemlerinde denemeye başlamış ve 1970' lerin sonlarına doğru ise Japonya, Avrupa ve İsrail' de ticari alg üretimi hayata geçirilmiştir (Gupta, Lee ve Choi, 2015). Günümüzde uygulanan yetiştirme sistemlerinin görselleri Şekil 5' te gösterilmiştir.



Şekil 5. Mikroalg Yetiştirme Sistemleri: (a) Açık kanal yarış tipi havuz sistemleri (b) Yuvarlak tank sistemleri; (c) Düz havuz sistemleri; (d) Sarmal boru şeklindeki fotobiyoreaktör; (e) Kolon şeklinde fotobiyoreaktör (f) Halka şeklinde fotobiyoreaktör

Günümüzde teknolojinin gelişmesiyle birlikte mikroalg yetiştiriciliği daha kapsamlı olarak açık veya kapalı yetiştirme sistemleri tasarlanarak üretilmeye başlanmıştır (Chew vd., 2018; Fabris vd., 2020; Pinto, Ferreira ve Tasic, 2021). Açık havuz sistemleri, düşük inşaat maliyeti, bakım ve işletme giderleri nedeniyle büyük ölçekli mikroalg yetiştiriciliğinde en yaygın kullanılan sistemler arasında ancak kapalı

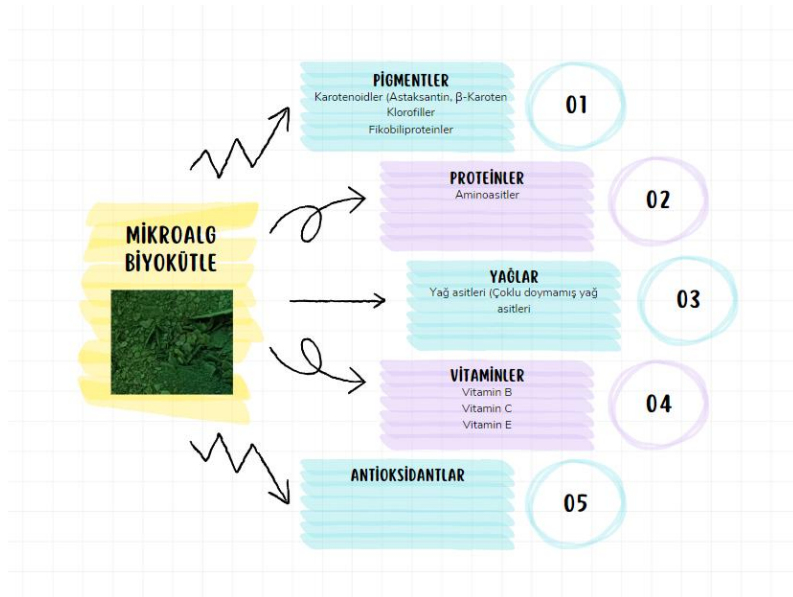
fotobiyoreaktör sistemleri yüksek fotosentetik verime ve biyokütle verimliliğine sahip olduğundan daha fazla tercih sebebi olmaktadır (Costa ve de Morais, 2014). "Mikroalg yetiştirme sistemlerinden sonra diğer önemli bir aşama, hasat işlemi; bu işlem, ürünün büyüme ortamından ayrılmasını kapsamakta ve alg hasadı mekanik, kimyasal, biyolojik ve elektrik bazlı yöntemleri içermektedir (Barros, Gonçalves, Simões ve Pires, 2015; Singh ve Patidar, 2018). Bu yöntemler arasında yerçekimi sedimantasyonu, flokülasyon, yüzdürme, santrifüjleme, membran ayırma veya bunların bir kombinasyonları bulunmakta ancak, mikroalg hasadı için tek bir yöntemin belirlenmesi zordur, çünkü mikroalg hücrelerinin morfoloji, yoğunluk ve boyut gibi özellikleri farklılık göstermektedir (Esteves, Almeida, Gonçalves ve Pires, 2020) (Şekil 6).




Şekil 6. Mikroalgin Hasadı (*Arthrospira platensis*) [Bu görüntü Tekirdağ Namık Kemal Üniversitesi Fen Edebiyat Fakültesi Biyoloji Bölümü Sucul Omurgalı Deney Ünitesinde fotoğraflanmıştır.]

Endüstriyel Uygulamalar

Mikroalgler, gıda ve hayvansal yem ürünleri, bitki gübrelere, biyoyakıt alanında ve çeşitli yüksek katma değerli ürünler gibi birçok farklı endüstriyel alanda kullanımı olan umut verici sürdürülebilir bir hammadde olarak kabul edilmektedir (Kumar, Sun, Rathour, Pandey, Thakur ve Tsang, 2020; Tang vd., 2020). Mikroalglerden elde edilen protein, çoklu doymamış yağ asitleri ve vitaminler gibi birincil ürünlerin yanı sıra sağlık açısından ele alındığında elde edilen ikincil ürünler (Astaksantin, fikosiyenin, pigmentler, karotenoidler, vb) daha fazla önem sağlamaktadır (Ampofo ve Abbey, 2022) (Şekil 7-8).



Şekil 7. Mikroalglerde biyo-aktif bileşikler (Koyande vd., 2019)



Şekil 8 Fikosiyanin - Karotenoid (*Arthrospira platensis* – *Chlorella sorokiniana*) [Bu görüntü Tekirdağ Namık Kemal Üniversitesi Fen Edebiyat Fakültesi Biyoloji Bölümü Sucul Omurgalı Deneysel Ünitesinde fotoğraflanmıştır.]

Mikroalg biyokütlesinden elde edilen bu bileşenler ve ürünler gıda endüstrisi pazarında giderek talep artışı kazanmaktadırlar (Fabris vb., 2020). Mikroalgler öncelikli olarak insan beslenmesinde örneğin unlu mamullerde, makarnalarda, atıştırmalıklarda, şekerlemelerde, sakızlarda, içeceklerde ve hatta bebek mamalarında besin takviyesi ve doğal gıda renklendirici olarak kullanılabilirler (Sidari ve Tofalo, 2019; Raymundo, Fradinho ve Nunes, 2023). Bu kullanım çeşitliliği içerdikleri biyoaktif bileşenlerin sağlıklı gıda olarak kabul edilmesi (Eze vd., 2023) hem de bazı mikroalg türlerinin insan sağlığı ve refahını iyileştirici ve koruyucu etki göstermesi açısından önemlidir (Koyande vd., 2019).

Su ürünleri yetiştiriciliğinde balık yemlerinde kullanılan balık unu yüksek protein kaynağı olmasına karşın pahalı ve sürdürülebilirliği kısıtlı olup buna karşın mikroalglerin besin içerikleri, su ürünleri yetiştiriciliği ve diğer hayvan yemlerindeki bileşenlerin yerini alabilecek sürdürülebilir bir ürün olarak hızla önem kazanmaktadır (Yaakob, Ali, Zainal, Mohamad ve Takriff, 2014). Çiftlik hayvanlarının diyet takviyesi

için çeşitli mikroalg türleri kullanılmaya başlanmıştır (Kusmayadi, Leong, Yen, Huang ve Chang, 2021).

Spirulina platensis, *Chlorella vulgaris* ve *Nannochloropsis gaditana* karışımı soya fasulyesine alternatif olarak sığırlarda yemin lezzetini arttırdığı ve süt kalitesine olumlu etki yaptığını göstermiştir (Lamminen, Halmemies-Beauchet-Filleau, Kokkonen, Jaakkola ve Vanhatalo, 2019). Şam keçilerinin diyetlerine günlük olarak 5 veya 10 g *Chlorella vulgaris* ilave edilmesinin süt verimini arttırdığı ve süt yağ asidi profilini pozitif yönde değiştirdiği sonucuna varılmıştır (Kholif vd., 2017). Araştırmalar ayrıca kümes hayvanların yemlerinde bulunabilen aflatoksin B1 (AFB1), bu hayvanların besin emilimini ve metabolizmasını bozarak büyüme ve yem verimliliğinin azalmasına yol açabileceği ve mikroalglerin kanatlı yemlerine ilavesi bu bileşiğin zararlı etkilerini ve bu etkileri azaltmadaki umut verici rolünü vurgulamaktadır (Abdelnour, Mahasneh, Barakat, Alkahtani ve Madkour, 2024).

Bitkilerin ihtiyaç duyduğu besinlerin sağlamak ve gelişimleri sırasında çeşitli zararlılardan ve hastalıklardan korunması amacıyla ilave edilen gübreler tarımda kullanımı arttıkça birtakım çevre ve insan üzerinde potansiyel tehlikeler oluşturmaktadır (El-Moustaqim, Sbai, El Yousfi, Mabrouki ve Hmouni, 2024). Mikroalglerin bitkiler için biyogübre olarak kullanımı bitki büyümesini, verim düzeyini, bitki kalitesini ve stres faktörlerini azaltmada yardımcı olduğu bildirilmektedir (Cordeiro vd., 2022; Dineshkumar, Subramanian, Arumugam, Ahamed Rasheeq ve Sampathkumar, 2020; Gonçalves, Freitas, Fernandes ve Silva, 2023).

Karada yetiştirilen bitkilere kıyasla mikroalgler, daha küçük alanlarda daha kolay üretilmeleri gibi önemli avantajları nedeniyle

biyoyakıt üretimi için sürdürülebilir ve uygun bir hammadde olarak kabul edilmektedir (Abdullah vd., 2024). B15 olarak tanımlanan % 15 spirulina biyoyakıt + % 85 dizel katkılı biyodizelin eklendiği yakıt nanopartiküllerin zararlı gaz emisyonunu azalttığı ve yanma kalitesini olumlu bir artışa sebep olduğu bildirilmiştir (Gev d., 2022). %20, 40, 60 ve 80 oranlarında spirulina mikroalgi içeren biyodizel karışımlarının doğal emişli dizel motorda daha düşük bir fren termal verimliliği, egzoz sıcaklığı ve CO₂ ürettiği bulunmuştur (Rajak, Nashine ve Verma, 2020).

Sonuç

Mikroalglerden elde edilen ürünler endüstriyel uygulamalarda kullanım için hala gelişim aşamasındadır. Elde edilen katma değeri yüksek ürünlerin pazar payı yüksek olmasına rağmen, üretim maliyetlerinin düşürülmesi ve hasat işlemlerinin daha etkin bir şekilde gerçekleştirilmesi gerekmektedir. Mikroalglerin gelecek yıllarda daha düşük maliyetli üretim süreçleri için kültür ve yetiştirme süreçlerinin optimize edilmesi, araştırma fonları ve politika desteği açısından büyük önem taşımaktadır. Mikroalglerle ilgili araştırma projeleri için finansal destek sağlayan ulusal ve uluslararası fonların oluşturulması gereklidir. Ayrıca üniversiteler ve araştırma kuruluşları, mikroalglerle ilgili çalışmaları desteklemek için bütçe kullanımını artırmaları gereklidir. Bu da mikroalglerin gelecekte daha geniş bir kapsamda kullanılabilmesi için önemli adımları oluşturmaktadır.


Kaynaklar

- Abdelnour, S. A., Mahasneh, Z. M., Barakat, R. A., Alkahtani, A. M., ve Madkour, M. (2024). Microalgae: A promising strategy for aflatoxin control in poultry feeds. *Toxicon*, 244, 107770.
- Abdullah, M., Ali, Z., Yasin, M. T., Amanat, K., Sarwar, F., Khan, J., ve Ahmad, K. (2024). Advancements in sustainable production of biofuel by Microalgae: Recent insights and future directions. *Environmental Research*, 119902.
- Abou-Shanab, R. A., Hwang, J. H., Cho, Y., Min, B., ve Jeon, B. H. (2011). Characterization of microalgal species isolated from fresh water bodies as a potential source for biodiesel production. *Applied energy*, 88(10), 3300-3306.
- Ahmed, M., Hayat, R., Ahmad, M., Ul-Hassan, M., Kheir, A. M., Ul-Hassan, F., ... ve Ahmad, S. (2022). Impact of climate change on dryland agricultural systems: a review of current status, potentials, and further work need. *International Journal of Plant Production*, 16(3), 341-363.
- Aizpuru, A., ve González-Sánchez, A. (2024). Traditional and new trend strategies to enhance pigment contents in microalgae. *World Journal of Microbiology and Biotechnology*, 40(9), 272.
- Ampofo, J., ve Abbey, L. (2022). Microalgae: Bioactive composition, health benefits, safety and prospects as potential high-value ingredients for the functional food industry. *Foods*, 11(12), 1744.
- Barros, A. I., Gonçalves, A. L., Simões, M., ve Pires, J. C. (2015). Harvesting techniques applied to microalgae: a review. *Renewable and sustainable energy reviews*, 41, 1489-1500.
- Bora, A., Rajan, A. S. T., Kumar, P., Muthusamy, G., ve Alagarsamy, A. (2024). Microalgae to bioenergy production: Recent advances, influencing parameters, utilization of wastewater—A critical review. *Science of The Total Environment*, 174230.
- Chew, K. W., Chia, S. R., Show, P. L., Yap, Y. J., Ling, T. C., ve Chang, J. S. (2018). Effects of water culture medium, cultivation systems and growth modes for microalgae cultivation: A review. *Journal of the Taiwan Institute of Chemical Engineers*, 91, 332-344.
- Chowdury, K. H., Nahar, N., ve Deb, U. K. (2020). The growth factors involved in microalgae cultivation for biofuel production: a review. *Computational Water, Energy, and Environmental Engineering*, 9(4), 185-215.
- Cordeiro, E. C. N., Mógor, Á. F., Amatuzzi, J. O., Mógor, G., Marques, H. M. C., ve de Lara, G. B. (2022). Microalga biofertilizer improves potato growth and yield, stimulating amino acid metabolism. *Journal of Applied Phycology*, 34(1), 385-394.
- Costa, J. A. V., ve de Moraes, M. G. (2014). An open pond system for microalgal cultivation. In *Biofuels from algae* (pp. 1-22). Elsevier.

- Dineshkumar, R., Subramanian, J., Arumugam, A., Ahamed Rasheeq, A., ve Sampathkumar, P. (2020). Exploring the microalgae biofertilizer effect on onion cultivation by field experiment. *Waste and Biomass Valorization*, 11, 77-87.
- El-Moustaqim, K., Sbai, S. E., El Yousfi, Y., Mabrouki, J., ve Hmouni, D. (2024). New strategy for the advancement of modern agriculture through the use of microalgae as biofertilizers. *Euro-Mediterranean Journal for Environmental Integration*, 1-15.
- Esteves, A. F., Almeida, C. J., Gonçalves, A. L., ve Pires, J. C. (2020). Microalgae harvesting techniques. In *Handbook of microalgae-based processes and products* (pp. 225-281). Academic Press.
- Eze, C. N., Onyejiaka, C. K., Ihim, S. A., Ayoka, T. O., Aduba, C. C., Nwaiwu, O., ve Onyeaka, H. (2023). Bioactive compounds by microalgae and potentials for the management of some human disease conditions. *AIMS microbiology*, 9(1), 55.
- Fabris, M., Abbriano, R. M., Pernice, M., Sutherland, D. L., Commault, A. S., Hall, C. C., ... ve Ralph, P. J. (2020). Emerging technologies in algal biotechnology: toward the establishment of a sustainable, algae-based bioeconomy. *Frontiers in plant science*, 11, 279.
- Ge, S., Brindhadevi, K., Xia, C., Khalifa, A. S., Elfakhany, A., Unpaprom, Y., ve Van Doan, H. (2022). Enhancement of the combustion, performance and emission characteristics of spirulina microalgae biodiesel blends using nanoparticles. *Fuel*, 308, 121822.
- Gonçalves, J., Freitas, J., Fernandes, I., ve Silva, P. (2023). Microalgae as biofertilizers: a sustainable way to improve soil fertility and plant growth. *Sustainability*, 15(16), 12413.
- Gupta, P. L., Lee, S. M., ve Choi, H. J. (2015). A mini review: photobioreactors for large scale algal cultivation. *World Journal of Microbiology and Biotechnology*, 31, 1409-1417.
- Jadhav, S. K., ve Rao, K. K. (2024). What are microalgae?. *Agritech*, 1, 8-10.
- Junaid, M. D., ve Gokce, A. F. (2024). Global agricultural losses and their causes. *Bulletin of Biological and Allied Sciences Research*, 2024(1), 66-66.
- Kholif, A. E., Morsy, T. A., Matloup, O. H., Anele, U. Y., Mohamed, A. G., ve El-Sayed, A. B. (2017). Dietary *Chlorella vulgaris* microalgae improves feed utilization, milk production and concentrations of conjugated linoleic acids in the milk of Damascus goats. *The Journal of Agricultural Science*, 155(3), 508-518.
- Koller, M., Salerno, A., Tuffner, P., Koinigg, M., Böchzelt, H., Schober, S., ... ve Braunegg, G. (2012). Characteristics and potential of micro algal cultivation strategies: a review. *Journal of Cleaner Production*, 37, 377-388.

- Koyande, A. K., Chew, K. W., Rambabu, K., Tao, Y., Chu, D. T., ve Show, P. L. (2019). Microalgae: A potential alternative to health supplementation for humans. *Food Science and Human Wellness*, 8(1), 16-24.
- Kumar, M., Sun, Y., Rathour, R., Pandey, A., Thakur, I. S., ve Tsang, D. C. (2020). Algae as potential feedstock for the production of biofuels and value-added products: Opportunities and challenges. *Science of the Total Environment*, 716, 137116.
- Kusmayadi, A., Leong, Y. K., Yen, H. W., Huang, C. Y., ve Chang, J. S. (2021). Microalgae as sustainable food and feed sources for animals and humans—biotechnological and environmental aspects. *Chemosphere*, 271, 129800.
- Lamminen, M., Halmemies-Beauchet-Filleau, A., Kokkonen, T., Jaakkola, S., ve Vanhatalo, A. (2019). Different microalgae species as a substitutive protein feed for soya bean meal in grass silage based dairy cow diets. *Animal Feed Science and Technology*, 247, 112-126.
- Lehmuskero, A., Chauton, M. S., ve Boström, T. (2018). Light and photosynthetic microalgae: A review of cellular-and molecular-scale optical processes. *Progress in oceanography*, 168, 43-56.
- Markou, G., Vandamme, D., ve Muylaert, K. (2014). Microalgal and cyanobacterial cultivation: The supply of nutrients. *Water research*, 65, 186-202.
- Okoro, V., Azimov, U., Munoz, J., Hernandez, H. H., ve Phan, A. N. (2019). Microalgae cultivation and harvesting: Growth performance and use of flocculants-A review. *Renewable and Sustainable Energy Reviews*, 115, 109364.
- Olaizola, M., ve Grewe, C. (2019). Commercial microalgal cultivation systems. *Grand challenges in algae biotechnology*, 3-34.
- Pinto, L. F. R., Ferreira, G. F., ve Tasic, M. (2021). Cultivation techniques. In *Microalgae* (pp. 1-33). Academic Press.
- Priyadarshani, I., ve Rath, B. (2012). Commercial and industrial applications of microalgae—A review. *Journal of Algal Biomass Utilization*, 3(4), 89-100.
- Rajak, U., Nashine, P., ve Verma, T. N. (2020). Effect of spirulina microalgae biodiesel enriched with diesel fuel on performance and emission characteristics of CI engine. *Fuel*, 268, 117305.
- Ramandani, A. A., Sun, Y. M., Lan, J. C. W., Chen, W. H., Chang, J. S., Rachmadona, N., ... ve Khoo, K. S. (2024). Upcycling nutrients derived from food waste via microalgae cultivation: A review on impacts on cellular compounds, economy and environment analyses for achieving circular bioeconomy. *Biochemical Engineering Journal*, 109454.
- Raymundo, A., Fradinho, P., ve Nunes, M. C. (2023). Application of microalgae in baked goods and pasta. In *Handbook of Food and Feed from Microalgae* (pp. 317-334). Academic Press.

- Sidari, R., ve Tofalo, R. (2019). A comprehensive overview on microalgal-fortified/based food and beverages. *Food Reviews International*, 35(8), 778-805.
- Singh, G., ve Patidar, S. K. (2018). Microalgae harvesting techniques: A review. *Journal of environmental management*, 217, 499-508.
- Tang, D. Y. Y., Yew, G. Y., Koyande, A. K., Chew, K. W., Vo, D. V. N., ve Show, P. L. (2020). Green technology for the industrial production of biofuels and bioproducts from microalgae: a review. *Environmental Chemistry Letters*, 18, 1967-1985.
- Worldometer, Current World Population. (2024, 11 Kasım). Erişim adresi [http://
https://www.worldometers.info/world-population/](http://https://www.worldometers.info/world-population/)
- Yaakob, Z., Ali, E., Zainal, A., Mohamad, M., ve Takriff, M. S. (2014). An overview: biomolecules from microalgae for animal feed and aquaculture. *Journal of Biological Research-Thessaloniki*, 21, 1-10.
- Yang, S., Fan, Y., Cao, Y., Wang, Y., Mou, H., ve Sun, H. (2024). Technological readiness of commercial microalgae species for foods. *Critical Reviews in Food Science and Nutrition*, 64(22)



ISBN: 978-625-367-960-6