

# BİLGİSAYAR VE ELEKTRONİK BİLİMLERİNDE GÜNCEL GELİŞMELER 2

EDİTÖRLER

Dr. Öğr. Üyesi Emrehan YAVŞAN

Dr. Erhan KAHYA

Öğr. Gör. Mehmet Ali ŞİMŞEK



# BİLGİSAYAR VE ELEKTRONİK BİLİMLERİNDE GÜNCEL GELİŞMELER 2

## EDİTÖRLER

Dr. Öğr. Üyesi Emrehan YAVŞAN

Dr. Erhan KAHYA

Öğr. Gör. Mehmet Ali ŞİMŞEK

## YAZARLAR

Prof. Dr. Mehmet KARALI

Doç. Dr. Aytekin ERDEM

Doç. Dr. Gürcan UZAL

Doç. Dr. Soner ÇELEN

Dr. Öğr. Üyesi Aytaç MORALAR

Dr. Öğr. Üyesi Emrehan YAVŞAN

Dr. Öğr. Üyesi Ertuğrul KARAKULAK

Dr. Öğr. Üyesi Halil Nusret BULUŞ

Dr. Öğr. Üyesi Mehmet Ali YALÇINKAYA

Dr. Öğr. Üyesi Özgür DÜNDAR

Dr. Enes EFE

Dr. Erhan KAHYA

Dr. Fatma Funda ÖZDÜVEN

Öğr. Gör. Fatih ÖZEN

Öğr. Gör. Mehmet Ali ŞİMŞEK


Arş. Gör. Mümine YILDIZ

Dr. Çetin YAĞCILAR

Dr. Öğr. Üyesi Erdal KILIÇ

Kader SUTLU

Mert LEVENT



Copyright © 2023 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 – 2023©  
**ISBN: 978-625-367-494-6**  
Cover Design: İbrahim KAYA  
December / 2023  
Ankara / Türkiye  
Size = 16 x 24 cm

# İÇİNDEKİLER

ÖNSÖZ.....1

## CHAPTER 1

### MICROCONTROLLER-BASED FITZHUGH-NAGUMO NEURON MODEL EMULATOR CIRCUIT

Assoc. Prof. Dr. Gürcan UZAL

Lecturer Fatih ÖZEN

Assoc. Prof. Dr. Aytekin ERDEM

Assist. Prof. Dr. Ertuğrul KARAKULAK.....3

## BÖLÜM 2

### KURUTMA PARAMETRE TAHMİNİNDE YAPAY SİNİR AĞI MODELLERİNİN KARŞILAŞTIRILMASI

Mert LEVENT

Dr. Öğr. Üyesi Halil Nusret BULUŞ

Dr. Öğr. Üyesi Aytaç MORALAR

Doç. Dr. Soner ÇELEN.....19

## BÖLÜM 3

### SQL ENJEKSİYONU TÜRLERİ VE UYGULAMA GELİŞTİRME AŞAMASINDA ALINABİLECEK SAVUNMA ÖNERİLERİ

Dr. Öğr. Üyesi Mehmet Ali YALÇINKAYA.....43

## BÖLÜM 4

### ROBOT İŞLETİM SİSTEMİ VE HECTOR SLAM PAKETİNİN KULLANIMI

Arş. Gör. Mümine YILDIZ

Dr. Öğr. Üyesi Özgür DÜNDAR

Prof. Dr. Mehmet KARALI

Dr. Öğr. Üyesi Emrehan YAVŞAN.....61

## BÖLÜM 5

### TARIMSAL UYGULAMALARDA DERİN ÖĞRENME

Dr. Erhan KAHYA

Dr. Fatma Funda ÖZDÜVEN.....83

## **BÖLÜM 6**

### **GEN EKSPRESYONU VERİLERİNDEN YAPAY ZEKA TEKNİKLERİ İLE LÖSEMİ KANSER TEŞHİS SİSTEMİ**

Dr. Enes EFE

Dr. Öğr. Üyesi Emrehan YAVŞAN.....109

## **CHAPTER 7**

### **INTELLIGENT AQUAPONIC SYSTEMS WITH SENSORS SETTING UP**

Dr. Çetin YAĞCILAR.....121

## **BÖLÜM 8**

### **DEPOLANMIŞ HUBUBAT VE MAMULLERİNDE ZARARA NEDEN OLAN SEKONDER ZARARLILARIN YAPAY ZEKÂ VE GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK TEŞHİSİ**

Dr. Öğr. Üyesi Mehmet Ali YALÇINKAYA

Kader SUTLU.....133

## **BÖLÜM 9**

### **GEÇMİŞTEN GELECEĞE: WEB 1.0 – WEB 4.0**

Öğr. Gör. Mehmet Ali ŞİMŞEK

Dr. Öğr. Üyesi Erdal KILIÇ.....149

## ÖNSÖZ

Bu kitabın amacı, öğrencileri, akademisyenleri, uzmanları ve araştırmacıları Bilgisayar ve Elektronik Bilimlerindeki güncel yaklaşımlarla ve yeni gelişmelerle tanıştırmaktır. Kitabın içeriğinde çeşitli mühendislik alanlarında çalışan bilim insanlarının araştırmalarına İngilizce ve Türkçe olarak yer verilmiştir. Her bölümdeki konular teorik ve uygulama esasları ele alınarak açıklanmıştır. Birinci bölümde Elektronik Mühendisliğinin uygulama alanlarından birisi olan mikro-denetleyiciler konusunda gerçekleştirilen “Microcontroller-Based FitzHugh-Nagumo Neuron Model Emulator Circuit” başlıklı İngilizce bölüm sunulmuştur. İkinci bölümde yapay sinir ağları konusunda hazırlanmış “Kurutma Parametre Tahmininde Yapay Sinir Ağı Modellerinin Karşılaştırılması” adlı başlıklı çalışma sunulmuştur. Üçüncü bölümde “SQL Enjeksiyonu Türleri Vve Uygulama Geliştirme Aşamasında Alınabilecek Savunma Önerileri” başlıklı bölüm sunulmuştur. Dördüncü bölümde farklı mühendislik dallarından akademisyenlerin katkılarıyla oluşturulan “Robot İşletim Sistemi ve Hector Slam Paketinin Kullanımı” başlıklı multidisiplinler bir çalışma aktarılmıştır. Beşinci bölümde “Tarımsal Uygulamalarda Derin Öğrenme” başlıklı derleme çalışmasına yer verilmiştir. Altıncı bölümde günümüzün güncel çalışma konularından biri olan yapay zekanın çeşitli tekniklerini içeren “Gen Ekspresyonu Verilerinden Yapay Zeka Teknikleriyle Lösemi Kanseri Teşhis Sistemi” başlıklı çalışma aktarılmıştır. Yedinci bölümde sensör teknolojilerin kullanımının anlatıldığı “Intelligent Aquaponic Systems With Sensors Setting Up” başlıklı çalışma sunulmuştur. Sekizinci bölümde “Depolanmış Hububat ve Mamullerinde Zarara Neden Olan Sekonder Zararlıların Yapay Zekâ ve Görüntü İşleme Teknikleri Kullanılarak Teşhisi” başlıklı çalışma sunulmuştur. Dokuzuncu bölümde “Geçmişten Geleceğe: WEB 1.0 – WEB 4.0” başlıklı derleme çalışması yer almaktadır.

Kıymetli Bilimsel çalışmalarıyla kitabımıza katkı sunan tüm saygıdeğer yazarlarımıza ve Sayın. Doç. Dr. Seyithan SEYDOŞOĞLU’na teşekkür ederiz.

Dr. Öğr. Üyesi Emrehan YAVŞAN

Dr. Erhan KAHYA

Öğr. Gör. Mehmet Ali ŞİMŞEK



## CHAPTER 1

### MICROCONTROLLER-BASED FITZHUGH-NAGUMO NEURON MODEL EMULATOR CIRCUIT

Assist. Prof. Dr. Gürcan UZAL<sup>1</sup>

Lecturer Fatih ÖZEN<sup>2</sup>

Assoc. Prof. Dr. Aytekin ERDEM<sup>3</sup>

Assist. Prof. Dr. Ertuğrul KARAKULAK<sup>4</sup>

DOI: <https://dx.doi.org/10.5281/zenodo.10396091>

---

<sup>1</sup> Tekirdağ Namık Kemal University, Vocational School of Technical Sciences, Electronics and Automation Department, Tekirdağ, Turkey, [guzal@nku.edu.tr](mailto:guzal@nku.edu.tr), ORCID: 0000-0002-2029-8612

<sup>2</sup> Tekirdağ Namık Kemal University, Vocational School of Technical Sciences, Electronics and Automation Department, Tekirdağ, Turkey, [fozen@nku.edu.tr](mailto:fozen@nku.edu.tr), ORCID: 0000-0002-4232-5394

<sup>3</sup> Tekirdağ Namık Kemal University, Vocational School of Technical Sciences, Electronics and Automation Department, Tekirdağ, Turkey, [aerdem@nku.edu.tr](mailto:aerdem@nku.edu.tr), ORCID: 0000-0002-1760-4789

<sup>4</sup> Tekirdağ Namık Kemal Üniversitesi Teknik Bilimler Meslek Yüksekokulu Elektronik ve Otomasyon Bölümü, Tekirdağ, Türkiye, [ekarakulak@nku.edu.tr](mailto:ekarakulak@nku.edu.tr), ORCID: 0000-0001-5937-2114





## **1. Introduction**

Numerous biological neuron models have been suggested to simulate neuron behaviors. McCulloch and Pitts proposed the classical neuron model in 1943, some important physical assumptions are made for computational conveniences, such as that neuronal activity occurs according to the "all or nothing" principle and that only synaptic latency is in the nervous system (McCulloch & Pitts, 1943). The two main features expected from a neuron model are biological consistency and operational simplicity. The Hodgkin-Huxley (HH) neuron model, which is the most successful and widely used neuron model, entered the literature in 1952 (Hodgkin & Huxley, 1952). This model describes the ionic mechanism for the initiation and propagation of action potentials in the axon. Nobel laureate HH model has high biological consistency but it is computationally complex. Following the HH model, the FitzHugh-Nagumo (FHN) neuron model which is a 2-dimension version of the HH model and excited by an external current is proposed by Richard FitzHugh (FitzHugh, 1961). The FHN model consists of two differential equations. In 1962, Nagumo et al. proposed the electronic circuit of the FHN model (Jinici, Arimoto & Yoshizawa, 1962). The Wilson-Cowan model is proposed in 1972 (Wilson & Cowan, 1972). The model consists of two dimensionless differential equations representing the internal and external connections between neurons. In 1981, the Morris-Lecar neuron model is suggested, which also included two dimensionless equations, but is based on conductivity (Moris & Lecar). In 1984, the Hindmarsh-Rose (HR) neuron model is suggested, which can describe neuron behavior with three first-order differential equations (Hindmarsh & Rose, 1984). In addition to these models, there are Integrate and Fire-type models that describe only the electrical activity of neurons and not their electrophysiology (Teka, Marinov & Santamaria, 2014). The Izhikevich neuron model emerged in the literature in 2003 (Izhikevich, 2004). His model reproduces the spiking and bursting behavior of cortical neurons.

Most of neuron models have their emulator circuits. In 1964, Lewis proposed a transistor-based application to simulate neuron behavior (Lewis, 1964). The circuit which is proposed by Nagumo et al contains a tunnel diode and reproduces the FHN model output signal [4]. Microcontroller-based signal generators and emulators are proposed in many studies (Usta, Tepeyurt & Karakulak, 2021; Yener & Mutlu, 2018). Microcontroller-based neuron model

emulator circuits have also been proposed. Yener et al. has proposed Hindmarsh-Rose Neuron Model-based biological central pattern generator based on a microcontroller (Yener & Mutlu, 2019). Petrovas et al. proposed a microcontroller based FHN model circuit. Their circuit of the FHN model has a microcontroller and also contain an analog circuit. In their circuit, the microcontroller is used to obtain cubic nonlinearity (Petrovas, Lissauskas & Slepikas, 2012).

In the academic literature, a completely microcontroller-based emulator that generates FHN model signals has not been proposed yet. In this study, a circuit is proposed in which the analog output signal is obtained using the Pulse Width Modulation (PWM) port of the microcontroller. The excitation current parameter of the model is applied to the microcontroller using analog input of the microcontroller. This circuit can be used as a signal source in educational laboratories and scientific studies.

This study organized as follows; in the second section FHN model is briefly introduced and Simulink™ model of the FHN model has been given, microcontroller-based emulator circuit is explained in the third section, experimental results of the proposed circuit have been given in the fourth section, the paper is finished with the conclusion section.

## **2. Fitzhugh-Nagumo Neuron Model**

The FHN model is a relaxation oscillator consisting of two differential equations proposed by Richard FitzHugh in 1961 (FitzHugh, 1961; Jinichi, Arimoto & Yoshizawa, 1962). One of the differential equations ( $v$ ) is the membrane voltage of the neuron and the other is the recovery variable ( $w$ ) which provides negative feedback. The variable  $v$  has a cubic nonlinearity. The membrane potential equation of the neuron model is,

$$\frac{dv}{dt} = v - \frac{v^3}{3} - w + RI_{ext} \quad (1)$$

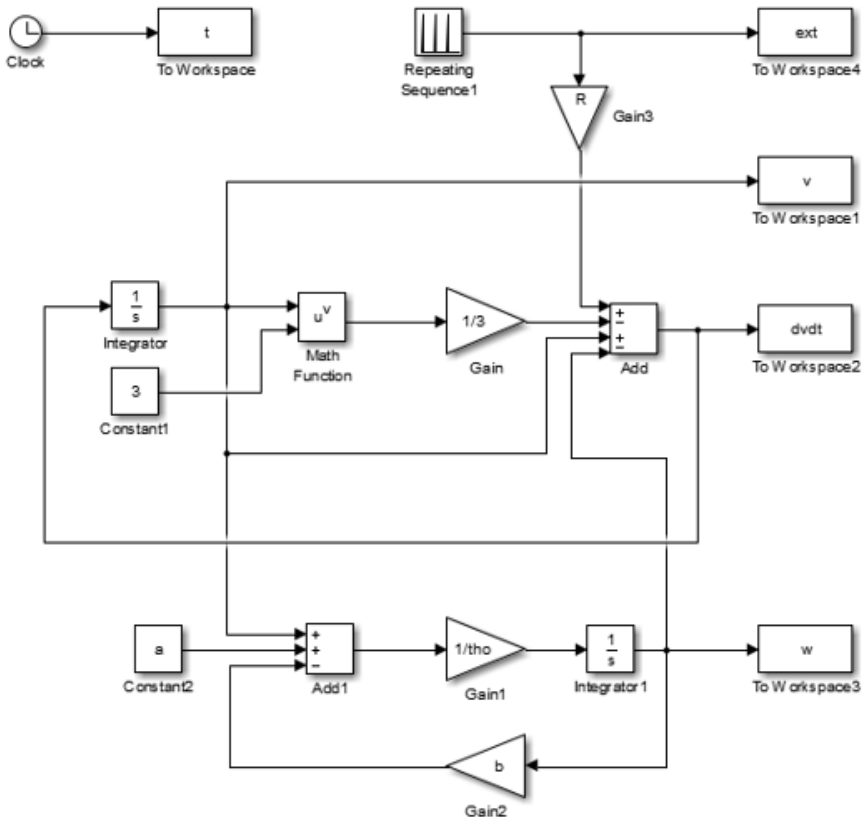
where  $v$  is the membrane potential voltage-like variable,  $w$  is the recovery variable of the model,  $I_{ext}$  is the external stimulus, and  $R$  is the external stimulus coefficient.

The equation representing the recovery variable is a linear dynamic equation. The recovery variable equation is,

$$\frac{dw}{dt} = \frac{v+a-bw}{\tau} \tag{2}$$

where  $a$ ,  $b$  and  $\tau$  are parameters that determine the duration and fixed point of the recovery.

In this study, the FHN neuron model is modeled with Matlab Simulink™. The block scheme of the Simulink model can be seen in Figure 1.




**Figure 1.** Simulink Model of FHN Model

The parameters which are used in the simulation of the model are shown in Table 1. These parameters are taken from reference (Scholarpedia, 2022).

**Table 1.** Parameters of Simulations (Scholarpedia, 2022)

Parameter	Value
a	0,7
b	0,8
R	0,5
$\tau$	12,5

The signals in Figure 2 are obtained by running the Simulink™ model shown in Figure 1.  $v$  and  $w$  signals are shown in blue and external excitations are shown in red. In the absence of excitation, model emits a  $v$  signal at resting potential at negative voltage levels. The frequency of the output signal is very low. A low-frequency output signal is one of the typical features of FHN model.

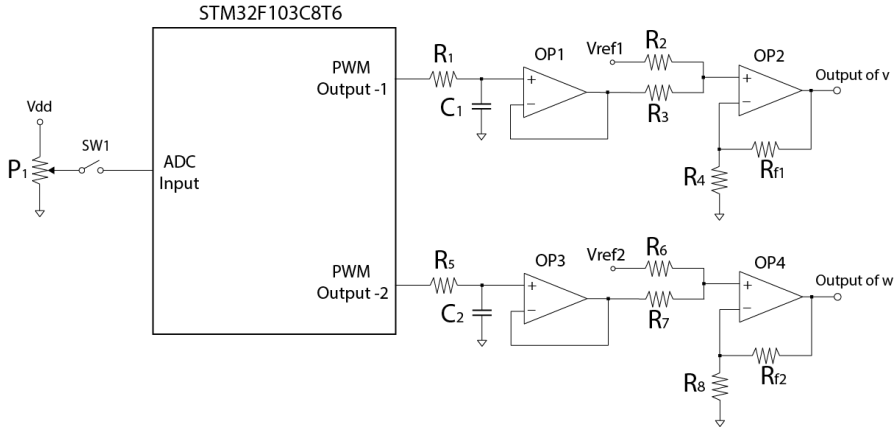


**Figure 2.** External current ( $I_{ext}$ ), membrane potential ( $v$ ), and recovery variable ( $w$ ) of FHN model

### 3. Microcontroller-Based Emulator Circuit

ARM architecture ST32F103C8T6 is the preferred microcontroller in the microcontroller-based FHN model simulator circuit (STM32F103C8, 2022). This microcontroller is preferred because of its stable structure and low cost. In addition, the debugging function is also very effective feature of this

microcontroller. Figure 3 shows the schematic of the microcontroller-based FHN model simulator circuit.



**Figure 3.** Microcontroller-based emulator circuit schematic

One of the analog inputs of the microcontroller is configured as an external excitation input, and two PWM output pins are configured as signal output pins. One of the output pins is used to generate the output signal of the model ( $v$ ) and the other to generate the recovered variable signal ( $w$ ). Although current is required for excitation in the FHN model, the external excitation is used as a voltage in this circuit to simplify the circuit structure. STM32F1 series microcontrollers do not have a built-in DAC (Digital to Analog Converter) terminal. In this case, an external DAC circuit must be used. In this study, an analog signal is obtained from a low-pass filter after the PWM output of the microcontroller (Usta, et al., 2012; Yener & Mutlu, 2018). Fewer electronic components are used to obtain the analog signal. After the microcontroller calculates the  $v$  and  $w$  signals, the duty cycle of the output PWM signals are calculated by Equation 3 and Equation 4.

$$D_v(t) = \frac{v(t)}{V_m} \tag{3}$$


$$D_w(t) = \frac{w(t)}{V_m} \tag{4}$$

where  $V_m$  is the maximum voltage level of the PWM port,  $D_v$  and  $D_w$  are the PWM duty cycles of the  $v$  and  $w$  signals, respectively.

Two passive low-pass filters ( $R_1, C_1, R_5, C_2$ ) are used in the circuit. The transfer function of the filters has been given in Equation 5.

$$T(s) = 1/(1 + sRC) \quad (5)$$

As shown in Figure 2, the output signal frequency of the FHN model is pretty low (about 0.03Hz). The frequency of the PWM output signal is configured as 1 kHz, which is relatively high. The values of the circuit elements used in the RC filter have been determined according to this information. In the circuit shown in Figure 3, OP1 and OP3 are used as voltage followers. Two operational amplifiers (OP2 and OP4) used as non-inverting voltage summer. According to the FHN model output in Figure 2, both the  $v$  variable and the  $w$  variable take negative values. PWM terminals cannot produce output signal at negative voltage level. Using a voltage summer circuit with Opamp, the signal is shifted to the negative voltage region to mimic the realistic signals. A photograph of the set-up circuit is shown in Figure 4.




**Figure 4.** Experimental setup

The circuit has been built on a breadboard. A microcontroller development board (STM32F103C8 BluePill) and a couple of Opamps ICs can be seen in Figure 4. Two of the three potentiometers are used to obtain the

voltage  $V_{ref1}$  and  $V_{ref2}$  of the voltage shifter circuits. External stimulation potentiometer is connected to the analog input of the microcontroller and provides the excitation parameter ( $I_{ext}$ ).

#### 4. Experimental Results

The parameters of the microcontroller-based FHN neuron model circuit are used as shown in Table 1. STM32F1 series microcontroller is preferred in the emulator circuit. One of the reasons for choosing this microcontroller is its debugging capabilities. With the help of debugging, the data processed by the microcontroller have been obtained during the operation of the microcontroller and the graphs of these data have been plotted. The signals are shown in Figure 5 are obtained from the microcontroller via the debug communication protocol (serial wire).

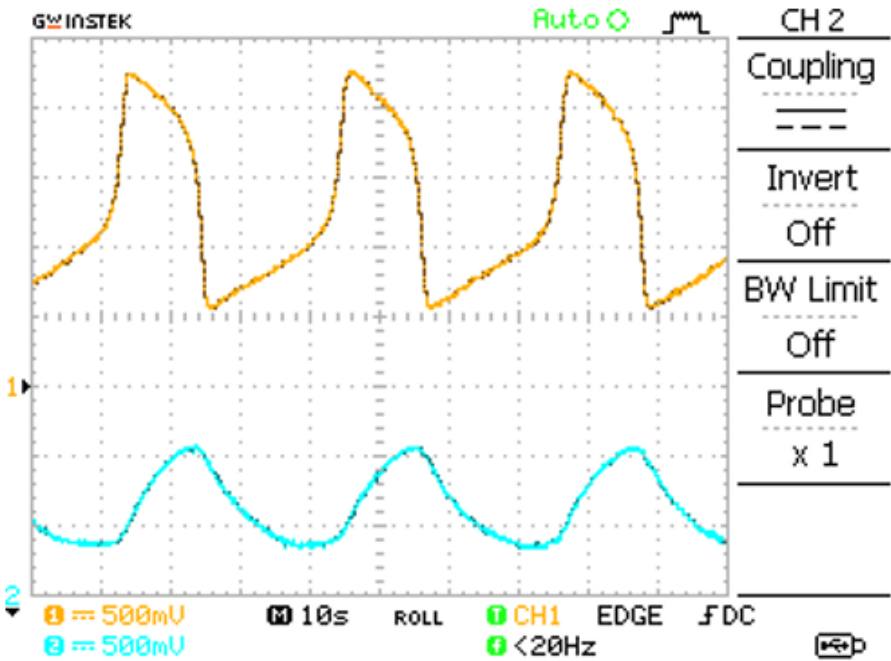


**Figure 5.** Outputs of The FHN Model Which is Taken by CubeMonitor Program


The data series obtained with debug protocol is plotted using the CubeMonitor program. Output signals which are taken from the circuit set up using an oscilloscope are shown in Figures 6-9. Figure 6 shows the signals  $v$




and  $w$ . These signals are the output of a low-pass RC filter. It is note worth that both signals are only in the positive voltage region. In Figure 7, both signals can be seen around baseline. Since these signals are taken from the output of the voltage shifter circuits, they are in the positive and negative voltage regions, similar to the signals in Figure 2. In the signals are shown in Figures 6 and 7, the external signal  $I_{ext}$  value is determined as 1. Therefore, the neuron model simulator constantly generates signals. In Figure 8, the excitation signal is set to 1 using potentiometer and switched with a button. The external excitation signal is shown in blue and output signal of the emulator is shown in yellow in Figure 8. It can be seen that the output voltage of the model remains at resting value when there is no excitation. With the excitation signal, the signal begins to be produced as a result of neuronal depolarization.



**Figure 6.** Membrane Voltage Output ( $v$ ) (yellow) and Recovery Variable Output ( $w$ ) (blue) of The RC Filters



**Figure 7.** Membrane voltage output ( $v$ ) (yellow) and recovery variable output ( $w$ ) (blue) of the voltage shifter circuits



**Figure 8.** Membrane voltage ( $v$ )(yellow) and external stimulation voltage ( $I_{ext}$ ) (blue) outputs of the voltage shifter circuits

Figure 9 shows the phase plane diagram of the model. In Figure 9, the  $w$  variable is on the y-axis and the  $v$  variable is on the x-axis

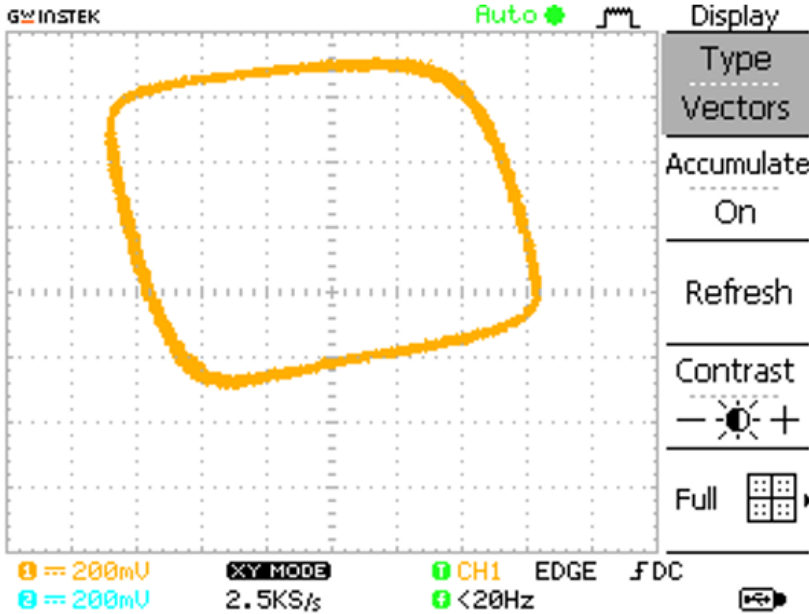


Figure 9. Phase plane plot of the FHN model emulator

## 5. Conclusions

In this study, the microcontroller-based FHN model emulator circuit is proposed. The emulator is implemented much simpler and with less component than expected from such a circuit. The circuit includes an ARM-based microcontroller, RC filters and Opamps for digital-analog converter circuits. The PWM outputs of the microcontroller are used to convert the digital signal into an analog signal. Almost all commercially available microcontrollers have PWM output terminals. After a passive low-pass RC filter, the analog signal can be obtained. With opamp voltage shifter circuits, the voltage level of the output signal is shifted to match the real signal, including negative voltage levels. The circuit also has a potentiometer and button for external excitation. The parameters of the model can be changed with the parameter changes in the software. By the addition of LCD screen and buttons to the emulator, the

parameters of the neuron model can be changed by the users. Thus, a setup which is similar to an experiment set can be built.

This emulator circuit can be used in laboratories for educational and research purposes. It can also be a signal source for other systems in research laboratories. Students who want to have this set can easily build their own emulator circuit on a breadboard. Since the circuit can be made with cheap and off the shelf electronic components (less than \$20). Other microcontroller-based neuron emulator circuits can be designed using PWM outputs as suggested in this study.

## References

- FitzHugh, R. (1961). Impulses and physiological states in theoretical models of nerve membrane. *Biophysical journal* 1(6) , 445-466.
- Hindmarsh, J.L., & Rose, R.M. (1984). A model of neuronal bursting using three couple first order differential equations. *Proc. R. Soc. Lond. Biol. Sci.*, 221(1222), 87-102.
- Hodgkin, A., & Huxley, A., (1952). A quantitative description of membrane current and its application to conduction and excitation in nerve. *Journal of Physiology*, 117, 500-544.
- Izhikevich, E.M., 2004. Simple model of spiking neurons. *IEEE Transactions on Neural Networks*, 14(6), 1569-1572.
- Jinichi, N., Arimoto, S. & Yoshizawa, S. (1962). An active pulse transmission line simulating nerve axon. *Proceedings of the IRE* 50.10, 2061-2070.
- Lewis, E.R. (1964). An electronic model of the neuron based on the dynamics of potassium and sodium ion fluxes,. In R.F. Reiss (Ed.), *Neural Theory and Modeling* (pp. 154-189), Stanford University Press, Stanford.
- McCulloch, W.S., & Pits, W.H. (1943). A logical calculus of ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115-133.
- Morris, C., & Lecar, H. (1981). Voltage oscillations in the barnacle giant muscle fiber. *Biophysical Journal*, 35, 193-213.
- Petrovas, A., Lisauskas, S., & A. Slepikas, A. (2012). Electronic model of fitzhugh-nagumo neuron. *Elektronika Ir Elektrotechnika*, 6(122), 117-120.
- Scholarpedia, Fitzhugh-Nagumo Neuron Model. (2022, February 10). [http://www.scholarpedia.org/article/FitzHugh-Nagumo\\_model](http://www.scholarpedia.org/article/FitzHugh-Nagumo_model)
- STM32F103C8 Mainstream Performance Line. (2022, February 10). <https://www.st.com/en/microcontrollers-microprocessors/stm32f103c8.html>
- Teka, W, Marinov, TM, & Santamaria, F. (2014). Neuronal spike timing adaptation described with a fractional leaky integrate-and-fire model. *PLoS computational biology* 10(3): e1003526.
- Usta, B.N., Tepeyurt, B. & Karakulak, E. (2021). Simple Synthetic ECG Generation via PWM output of microcontroller. *2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* ( pp. 27-30), Ankara.
- Wilson, H.R., & Cowan, J.D., (1972). Excitatory and inhibitory interactions in localized populations of model neurons. *Biophysical Journal*, 12(1), 1-24.
- Yener, S.C., & Resat Mutlu, R. (2018). A microcontroller-based ECG signal generator design utilizing microcontroller PWM output and experimental ECG data. *2018*

*Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)* (pp. 1-4), İstanbul.

Yener, Ş.Ç., & Mutlu, R. (2019). A Microcontroller implementation of Hindmarsh-Rose neuron model-based biological central pattern generator. *2019 1st International Informatics and Software Engineering Conference (UBMYK)* (pp. 1-4), Ankara.



## BÖLÜM 2

### KURUTMA PARAMETRE TAHMİNİNDE YAPAY SİNİR AĞI MODELLERİNİN KARŞILAŞTIRILMASI

<sup>1</sup>Mert LEVENT

<sup>2</sup>Dr. Öğr. Üyesi Halil Nusret BULUŞ

<sup>3</sup>Dr. Öğr. Üyesi Aytaç MORALAR

<sup>4</sup>Doç. Dr. Soner ÇELEN

DOI: <https://dx.doi.org/10.5281/zenodo.10396111>

---

<sup>1</sup> Tekirdağ Namık Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Tekirdağ, Türkiye, 0000-0002-5496-6439, email: 1188132107@nku.edu.tr

<sup>2</sup> Tekirdağ Namık Kemal Üniversitesi, Çorlu Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Tekirdağ, Türkiye, 0000-0003-1844-6484, e-mail: nbulus@nku.edu.tr

<sup>3</sup> Tekirdağ Namık Kemal Üniversitesi, Çorlu Mühendislik Fakültesi, Makine Mühendisliği Bölümü, Tekirdağ, Türkiye, 0000-0002-3964-4909, e-mail: amoral@nku.edu.tr

<sup>4</sup> Tekirdağ Namık Kemal Üniversitesi, Çorlu Mühendislik Fakültesi, Makine Mühendisliği Bölümü, Tekirdağ, Türkiye, 0000-0001-5254-4411, e-mail: scelen@nku.edu.tr





## 1.Giriş

Kurutma, eş zamanlı ısı ve kütle transferi ile kolaylaştırılan, ürünlerden nemin uzaklaştırılmasını gerektiren bir hasat sonrası işleme prosedürünü temsil eder. Bu termo-fiziksel süreç, nem içeriğini minimum eşiğe düşürmeyi ve tarımsal ürünlerdeki mikroorganizmaların büyümesini ve aktivitesini engellemeyi amaçlamaktadır (Elijah ve ark., 2020). Meyve, sebze ve bitkilerin korunmasında kullanılan tarihi bir yöntem, ürünlerin nem içeriğini azaltarak raf ömrünü uzatan ve dolayısıyla hacminin azalması nedeniyle rahat taşıma ve depolamayı kolaylaştıran kurutmadır (Yıldız ve ark., 2020).

Çağdaş toplumda bilgisayarların ve bilgisayar sistemlerinin her yerde bulunması, onları birçok alanda vazgeçilmez hale getirmiş (Ağyar, 2015), insan beyni ile teknolojik cihazlar arasında amansız bir karşılıklı bağımlılığa yol açmıştır. Sonuç olarak, bilgisayar sistemlerine ve yapay zekaya olan ilginin artması, ilgili araştırma çabalarında dikkate değer bir artışa neden olmuştur (Öztürk ve Şahin, 2018).

Çoğunlukla bir süreç veya sistemin davranışını açıklayan denklemlerin formülasyonunu gerektiren matematiksel modelleme, önemli avantajlar sağlar ve tarımda ve diğer çeşitli alanlarda geniş kapsamlı uygulama alanı bulur (Buluş ve ark., 2023).

YSA gibi yapay zeka teknikleri, varsayımlara veya basitleştirmelere olan ihtiyacı ortadan kaldırdığı için optimal koşulları tahmin etmek için etkili araçları temsil eder. Bu teknikler, önceden elde edilen bir dizi model girdisi ile bunlara karşılık gelen çıktılar arasındaki ilişkiyi kurarak insan beyninin kalıpları ayırt etme yeteneğini kopyalamayı amaçlamaktadır (Mousavifard ve ark., 2015). YSA'lar, insan beyninin işleyişini taklit ettikleri göz önüne alındığında, kuruma sürecini doğru bir şekilde tahmin etme konusunda uzmandır. Basitlikleri ve belirli bir görev için performansı kendi kendine ayarlama ve geliştirme kapasiteleri nedeniyle süreç değişkenlerini simüle etme konusunda umut vaat ediyorlar (Dülger, 2014).

Maliyetin en aza indirgenmesi için bir yol, kurutma işleminin ürün özellikleri de hesaba katılarak matematiksel modelinin oluşturulmasıdır. Yapay sinir ağları (YSA) oluşturulabilecek matematiksel modellerden biridir. Kurutma hızı ve verim gibi parametrelerin tahminini YSA'lar gibi yapay zeka teknikleri ile yapmak giderek popülerleşen bir konudur. Yapılan bu çalışmada farklı yapay sinir ağı (YSA) modellerin, fındık kabuğu kurutma işlemi

sonuçlarını tahmin etmesi ve deneysel sonuçlara yakınlığının hesaplanması amaçlanmıştır.

### **1.1.Önceki çalışmalar**

Dolatabadi ve arkadaşları, talaşın absorpsiyon potansiyelini tahmin etmek amacıyla YSA ve nöro-bulanık çıkarım sistemi (ANFIS) kullanmışlardır. Çalışmada elde ettikleri sonuçlar her iki modelin de geçerli sonuçlar ürettiğini göstermiştir. (Dolatabadi ve ark., 2018)

Victor H. Quej ve arkadaşları (2017), güneş ışınımını tahmin etmek amacıyla YSA modelleri kullanmışlardır. Yaptıkları çalışmada YSA'nın yanında Destek Vektör Makinesi (SVM) ve ANFIS modelleri ile de tahminlerde bulunmuşlardır. Tahminlerin sonucunun performans değerlendirmesi için kök ortalama kare hatası (RMSE), regresyon analizi ( $R^2$ ) ve ortalama mutlak hata (MAE) kullanmışlardır. (Quej ve ark., 2017)

YSA'ların kurutma işleminde kullanımını içeren bir çalışma Mohammad Kaveh ve ekibi (2018) tarafından gerçekleştirilmiştir. Çalışmada YSA'ların yanısıra ANFIS de kullanılmıştır. Kullanılan kurutucu ise konvektif sıcak hava kurutucusudur. (Kaveh ve ark., 2018)

Bahman Najafi ve ekibi (2018), biyogaz üretimi modellemesinde YSA ve ANFIS kullanmışlardır. Üretim modellemesinde araştırdıkları noktalardan biri de bağımsız değişkenlerin biyogaz üretimindeki etkisidir. (Najafi ve Ardabili, 2018)

ANFIS ve YSA modellerinin karşılaştırıldığı bir çalışmada (Rego ve ark., 2018), Alkalın Hidrojen Peroksit (AHP) kullanarak şeker kamışı delignifikasyon işleminin optimizasyonunu gerçekleştirmişlerdir. (Rego ve ark., 2018)

Bu çalışmada ANN ile fındık kabuğu kurutma işleminin modellemesi gerçekleştirilerek, mikrodalga düzeneği ile elde edilmiş deneysel sonuçlarla olan yakınlığı incelenmiştir. Bu incelemede farklı ANN modelleri oluşturularak, hangi modelin daha verimli sonuç verdiğinin hesaplanması amaçlanmıştır.

## 2. Materyal ve Metot


### 2.1. Yapay sinir ağları

YSA'lar insan beyni özelliklerini içeren sistemlerdir. Bu özelliklerin başında öğrenerek yeni bilgiler üretme gibi özellikler vardır. Bu yetenekleri matematiksel olarak ortaya koymaktadır. YSA'lar tecrübelerden öğrenir ve bu yeteneğini karar vermede kullanır (Erkaymaz, 2012).

YSA'lar insan sinir sistemine benzer şekilde nöronlardan oluşur. Bu nöronların birbirine bağlanması ile sinir ağları meydana gelir.

Son yıllarda YSA'lar farklı disiplinlerde farklı problemlerin çözümünde kullanılmışlardır. Bu problemlerin başlıcaları sınıflandırma, tahmin, örüntü tanıma ve kümeleme olarak belirtilebilir (Abioduna ve ark., 2018).

Yapay sinir ağları tek katmanlı ve çok katmanlı yapay sinir ağları olmak üzere iki şekilde sınıflandırılır. Çok katmanlı her YSA sistemi temel olarak girdi katmanı, gizli katman ve çıktı katmanı olmak üzere Şekil 1'de gösterildiği gibi üç katmanlı bir sistemden oluşur. (Tektaş ve Karataş, 2004; Buluş ve ark., 2023).



Şekil 1. Yapay sinir ağları genel mimarisi (Maladkar, 2018)

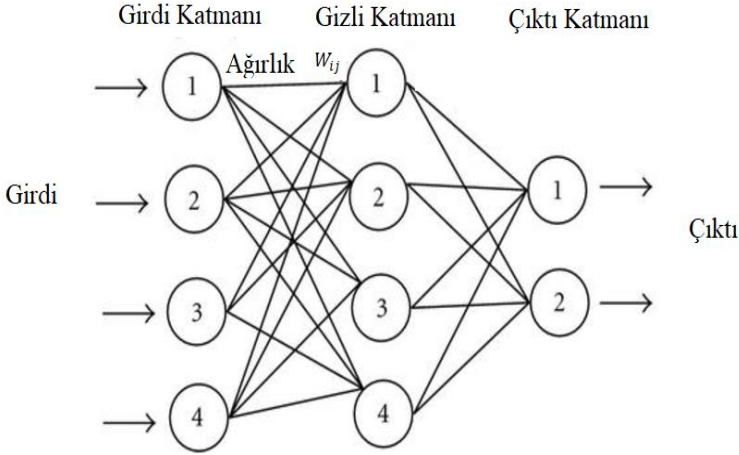
#### 2.1.1. Yapay sinir ağları topolojileri

Topolojilerine göre YSA'lar birkaç çeşide ayrılmaktadırlar.

##### 2.1.1.1. İleri beslemeli YSA

Bu YSA'lar genellikle örüntü oluşturma, örüntü tanıma ve sınıflandırmada kullanılırlar. Bilgi tek yönlü olarak yol alır. Bu YSA'da geri besleme döngüsü yer almaz. Girişler ve çıkışlar sabittir (Sight, 2018). Şekil 2'de tek gizli katmana sahip ileri beslemeli bir ağın mimarisini göstermektedir.


Ağırlık, gizli katmandaki girdi verilerinin dönüştürülmesi için kullanılan ve sinir ağı içinde yer alan parametrelerden biridir. Sinir ağlarını oluşturan düğümlerde ağırlık, sapma değeri ve girdi verileri bulunur. Bir sonraki katmana iletilmek üzere düğüme gelen girdi ağırlık ile çarpılır. Bu işlemler gizli katmanda yer almaktadır (Sight, 2018).



Şekil 2. İleri Beslemeli YSA (Raju ve ark., 2011)

### 2.1.1.2. Geri beslemeli YSA

İleri beslemeli YSA'larda bilgi tek yönde ilerlerken, buna ters olarak geri beslemeli YSA'da hareket iki yönlüdür (Şekil 3). Geri beslemeli YSA son derece güçlü ve karmaşık olabilir. Bu tür ağlar dinamik bir yapıya sahiptir. Bu tip bir ağdaki "durum" sürekli olarak değişir. Durumun değişmesi belirlenen bir denge noktasına ulaşıncaya kadar durmaktadır. Girdilerin değişmesi ile denge noktası değişir ve YSA denge noktasında kalmak için işlemler yapar. (Şengör ve Özdemir, 2017)




Şekil 3. Geri Beslemeli YSA (Şengör ve Özdemir, 2017)

### 2.1.1.3. Modüler sinir ağları

Modüler Sinir Ağları, (Şekil 4) birçok bağımsız ağdan oluşan bir ağ kümesidir. Modüler ağı oluşturan her ağın girdisi benzersizdir ve alt görevleri oluşturur. Sinir ağları birbirinden sinyal transferi yapmaz ve etkileşime girmez. Görevlerini birbirinden bağımsız olarak yerine getirirler (Goyal, 2019).

Bu modüler ağlar problemin karmaşıklığını azaltmak için büyük boyutlu hesaplama sürecini küçük süreçlere böler (Ahmadian, 2016).




Şekil 4. Modüler Sinir Ağları

### 2.1.1.4. Tekrarlayan sinir ağları (TSA)

Tekrarlayan Sinir Ağı (TSA) da geri besleme özelliğine sahip bir ağ topolojisidir. Katma çıktıları kaydedilir ve bir sonraki katmanda tahmin işlemini gerçekleştirmek için geri besleme özelliğini kullanır. Ağırlıklar ve

özellikler toplamının çarpımı birinci katmanı oluşturur. Bu işlem ileri beslemeli YSA'ya benzer. TSA özellikleri bundan sonra devreye girer. Bir nöronun bir sonraki adıma geçerken bir önceki adımda sahip olduğu bilgileri hatırlaması demektir. Bu özellik, TSA'ları zaman serileri, dil modelleme ve diğer zamanla değişen veri türlerinin işlenmesi için güçlü kılar. TSA'lar, geçmiş bilgiyi gelecekteki adımlara taşıma yeteneği ile öne çıkar ve bu özellik, çeşitli uygulamalarda kullanılmalarını sağlar. (Maladkar, 2018).


TSA, nöronların bellek hücreleri gibi davranmasını sağlar. Sinir ağının ön yayılım çalışmasına imkan tanınmalı ve daha sonra kullanılacak bilgileri hatırlamalıdır. Tahminin yanlış olması durumunda, öğrenme oranı veya hata düzeltme kullanılarak küçük değişiklikler yapılır. Bundaki amaç geri yayılım esnasında doğru tahmine kademeli olarak yaklaşmaktır. Bu adaptasyon süreci, ağın önceki hatalarından öğrenmesine ve gelecekte daha doğru tahminler yapmasına olanak tanır. (Maladkar, 2018).



Şekil 5. Tekrarlayan Sinir Ağı

### 2.1.1.5. Radyal tabanlı fonksiyon sinir ağı (RTF)


RTF'ler, genellikler fonksiyon yaklaşımı problemleri için kullanılmaktadır. RTF'lerin diğer ağlara göre avantajları, evrensel yaklaşımları ve daha hızlı öğrenme hızlarıdır. Bir RTF ağı, ileri beslemeli sinir ağlarından olmakla beraber, giriş, gizli ve çıkış katmanı olmak üzere 3 katmana sahiptir (Ahmadian, 2016).



Şekil 6. Radyal Tabanlı Fonksiyon Sinir Ağı

### 2.1.1.6. Evrişimsel sinir ağları (ESA)

Evrişimsel sinir ağları, yaygın olarak görüntü işleme problemlerinde kullanılan bir derin öğrenme algoritmasıdır. Girdi olarak görüntüyü alır ve görüntü içinde yer alan nesnelere ve görünüşleri birbirinden ayırt eder (Goyal, 2019).



Şekil 7. Evrişimsel Sinir Ağı

### 2.1.2. Eğitim algoritmaları

Bilinmeyen yeni veriler hakkında tahminde bulunmak için giriş verisi özniteliklerini hedefe eşleyen kalıpları bulmak eğitim algoritmalarının görevidir. Bu şekilde bir makine öğrenmesi modeli çıkarmaktadır. Bu modeller sayesinde mevcut bir eğitim seti modele verildikten sonra girdi – çıktı eşleşmesi gerçekleştirilmeyi öğrenir.

#### 2.1.2.1. Gradyan iniş algoritması (GİA)

Gradyan iniş (Gİ), uygulaması kolay ve makine öğrenmesi konusunun başlarında öğretilen bir yöntemdir. Verilen bir fonksiyonun yerel maks/min



noktalarını bulmak için kullanılır. Yinelemeli birinci dereceden bir optimizasyon algoritmasıdır. Derin öğrenme ve makine öğrenmesinde yaygın olarak kullanılmasının nedeni maliyet/kayıp işlevini en aza indirmektir (Cömert ve Kocamaz, 2017).

#### **2.1.2.2.Eşlenik gradyan algoritması (EGA)**

Karmaşık doğrusal denklem sistemlerinin çözümleri için kullanılan en uygun tekniklerden biri de Eşlenik Gradyan yöntemidir. Bu yöntem doğrusal olmayan optimizasyon problemleri için de uyarlanabilir özelliktedir. (Taş, 2005)

Bu yöntem 1950 yıllarında Hestenes ve Steifel tarafından pozitif tanımlı katsayı matrisli doğrusal sistemleri çözmek için geliştirilmiştir. İteratif bir metottur. (Taş, 2005).

#### **2.1.2.3.Quasi-Newton algoritması (QNA)**

Newton'un yöntemine alternatif olarak sıfırları veya kısmi maksimumları ve minimumları bulmak için kullanılmaktadır. Yinelemelerin maliyetli olduğu veya Jacobien veya Hessian yöntemlerinin kullanılmadığı durumlarda kullanılmaktadır. Jacobien yöntemini sıfırları atmak için, Hessian yöntemini de maksimum veya minimum noktasını bulmak için kullanılmaktadır (Gerbeau ve Vidrascu, 2005)

#### **2.1.2.4. Levenberg-Marquardt algoritması (LMA)**

Bu algoritma, özellikle doğrusal olmayan eğri uydurma problemlerinin ve optimizasyon sorunlarının çözümünde kullanılan iteratif optimizasyon algoritmasıdır. Son yıllarda ağ popüleritesinin artmasında önemli katkısı vardır (Binu ve Rajakumar, 2021).


Bu algoritma sinirsel komşuluk kavramını, bellek ve zaman kısıtlamalarının davranışını artırmak için kullanılır(Binu ve Rajakumar, 2021).

#### **2.1.3.Transfer fonksiyonları**

Giriş sinyallerini çıkış sinyallerine çevirmek için kullanılan fonksiyonlardır. Yaygın olarak kullanılan başlıca 4 tür transfer fonksiyonu vardır (Sharma ve ark., 2012).

### 2.1.3.1.Eşik transfer fonksiyonu

Çıktı değerinin, girdi değerlerinin belirlenmiş olan eşik değerinden büyük veya küçük olma durumuna göre iki seviyeden birine ayarlandığı fonksiyondur.




Şekil 8. Eşik Transfer Fonksiyonu

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (1)$$

### 2.1.3.2.Sigmoid transfer fonksiyonu

Sigmoid işlevi, 2 işlevden oluşmaktadır. Bunlar lojistik ve teğetsel olarak belirtilmektedir. Üretilen değer  $[-1, 1]$  aralığında olmasını sağlar.




Şekil 9.Sigmoid Transfer Fonksiyonu

$$f(x) = \frac{1}{1 + e^{-\beta x}} \quad (2)$$

### 2.1.3.3.Parçalı doğrusal transfer fonksiyonu

Çıktısının toplam ağırlıklı çıktı ile doğrusal orantılı olduğu bir fonksiyondur.




Şekil 10.Parçalı Doğrusal Transfer Fonksiyonu

$$f(x) = \begin{cases} 0, & x \leq x_{\min} \\ mx + b, & x_{\max} > x > x_{\min} \\ 1, & x \geq x_{\max} \end{cases} \quad (3)$$

#### 2.1.3.4. Gauss transfer fonksiyonu

Yüksek veya düşük düğüm çıktısının seçilen ortalama değere uzaklığına bağlı olarak sınıf üyeliği açısından yorumlandığı bir fonksiyondur.



Şekil 11.Gauss Transfer Fonksiyonu

$$f(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (4)$$

Burada:

$\mu$ : Ortalama değeri,

$\sigma$ : Standart sapmayı göstermektedir

### 2.1.4.Normalizasyon

Normalizasyon, verileri belirlenmiş olan bir ölçüğe getirmek için kullanılır. İki aşamalı bir işlemdir. Öncelikle girdi verilerinin istenen aralığa ölçeklendirme işlemi, sonrasında da kalıplama işlemi yapılır (Zhang ve Sun, 2009).

### 2.2.Performans ölçümleri

Performans ölçümleri, oluşturulan bir ağıın çıktılarının istenen değerlere ne kadar yaklaştığını gösteren fonksiyonlardır. Bu çalışmada kullanılan performans ölçüm yöntemleri RMSE, MAPE ve R<sup>2</sup> olmuştur.

#### 2.2.1.Kök ortalama kare hatası (RMSE)

Model tarafından yapılan tahminler ile gerçek değerler arasındaki farkların ortalama karesel kökünü hesaplar ve bu farkları ne kadar iyi thmin ettiğini gösterir. Daha düşük bir RMSE değeri, modelin daha iyi performans gösterdiği anlamına gelir (Tınmaz ve ark., 2019).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N |t_i - o_i|^2} \quad (5)$$

Burada:

$N$ : Veri sayısını,

$t_i$ : Deneysel veriyi,

$o_i$ : Tahmin değerini göstermektedir.

#### 2.2.2.Ortalama mutlak yüzde hatası (MAPE)

Tahmin değerleri ile gerçek değerler arasındaki farkların gerçek değerlere bölünmesiyle elde edilen sonuçların mutlak değerlerinin toplanarak gözlem sayısına bölünmesiyle elde edilir. Elde edilen değer 0'a yakın olması modelin doğruluğunu kuvvetlendirmektedir.

$$MAPE = \left( \frac{1}{N} \sum_{i=1}^N \left| \frac{t_i - o_i}{t_i} \right| \right) \quad (6)$$

$N$ : Veri sayısını,

$t_i$ : Deneysel veriyi,

$o_i$ : Tahmin değerini göstermektedir.

### 2.2.3. Korelasyon katsayısı ( $R^2$ )

Bu fonksiyon bağımlı değişkenin bağımsız değişkenler tarafından açıklanan varyansın oranını ifade eder. Modelin ne kadar iyi bağımlı değişkeni açıkladığını ve ne kadar iyi tahminler yaptığını değerlendirmek için kullanılır..

$$R^2 = 1 - \left( \frac{\sum_{i=1}^N (o_i - t_i)^2}{\sum_{i=q}^N (t_i)^2} \right) \quad (7)$$

$N$ : Veri sayısını,

$t_i$ : Deneysel veriyi,

$o_i$ : Tahmin değerini göstermektedir.

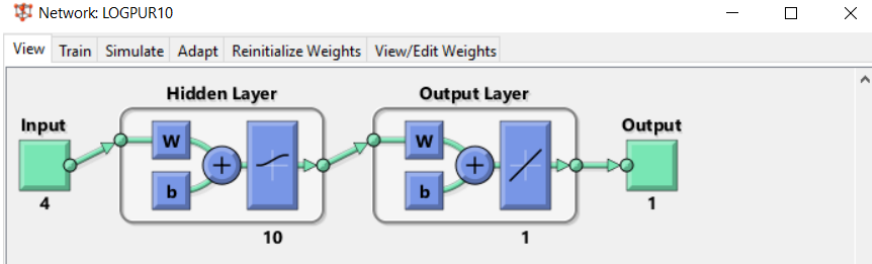
### 3. Araştırma Bulguları ve Tartışma

Bu çalışmada amaçlanan farklı transfer fonksiyonları ve nöron sayıları içeren YSA modellerinin karşılaştırılmasıdır. Bu modellerin eğitiminde deneysel olarak elde edilmiş veri kümesinin %80 oranındaki kısmı seçilmiştir.

Verilerin Tekirdağ Namık Kemal Üniversitesi Makine Mühendisliği Bölümü Laboratuvarında mevcut bulunan konveyör bantlı bir mikrodalga düzeneği kullanılmıştır (Moralar ve Çelen, 2022). Girdi, çıktı ve test verilerinin seçilmesi işlemi bu düzeneden elde edilen deneysel verilerden yapılmıştır. Girdi verisi olarak, zaman, kuru kütle, yaş kütle ve güç değerleri seçilmiş, çıktı verisi olarak da girdi verilerine bağlı olarak değişen nem oranı seçilmiştir. Sisteme eğitim aşamasında verilmemiş ve ağın tanımadığı %20'lik bölüm ise test verisi olarak alınmıştır.

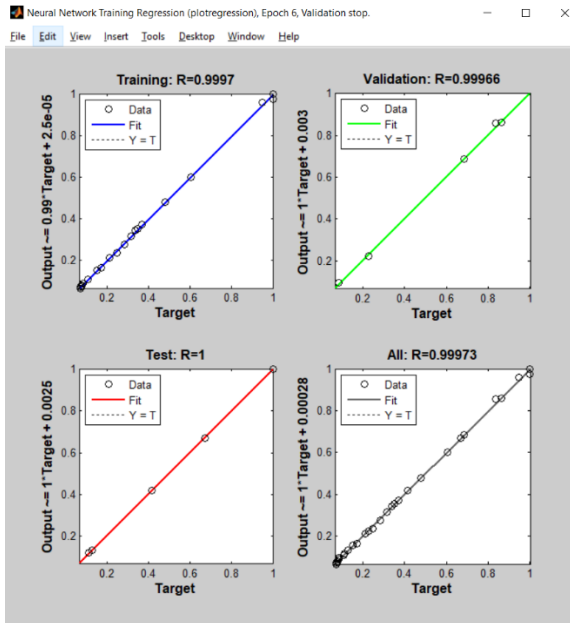
Verilerin ayrılmasından sonra YSA modelini oluşturmak için MATLAB yazılımı kullanılmıştır. Tek gizli katmanlı ileri beslemeli yapay sinir ağı mimarisi belirlendikten sonra, gizli katmandaki nöron sayıları 10, 20, 30 olarak değişen modeller üretilmiştir. Ayrıca farklı transfer fonksiyonları kullanılarak, YSA'ların nöron sayısı ve transfer fonksiyonu özelliklerine göre çıktı değerlerindeki deneysel değerlere yakınlığı incelenmiştir. Kurulan modellerde

eğitim fonksiyonu olarak Levenberg-Marquardt kullanılmıştır. Belirlenen özelliklere sahip YSA modeli mimarisi Şekil 12’de gösterilmiştir (Levent ve ark., 2023).




Şekil 12. YSA yapısı

YSA modelinin eğitimi gerçekleştirildikten sonra, %20’lik test verisini eğitilen ağa vererek çıktıları elde etmek amaçlanır. Bu elde edilen çıktılar kurutma sisteminin üreteceği kurutma parametrelerinin tahmin sonuçları olacaktır. Nöron sayısı ve transfer fonksiyonların kombinasyonları ile elde edilen 9 farklı model gerçekleştirilmiş, bir modele ait regresyon grafiği Şekil 13’te verilmiştir.



Şekil 13. Seçilen modele ait regresyon grafiği

Aynı modele ve aynı iterasyona ait olan validasyon performansına ait grafik de Şekil 14'te verilmiştir (Levent ve ark., 2023).



Şekil 14. YSA validasyon performansı

İleri Beslemeli Geriye Yayılım Sinir Ağı mimarisi altında nöron sayısı, çıktı fonksiyonu ve transfer fonksiyonlarının değiştirilerek oluşturulan 9 farklı modelin fındık kabuğu kurutma tahmin çıktıları Çizelge 1'de verilmiştir.





Çizelge 1’de elde edilen her modele ait sonuçların performans ölçümleri gerçekleştirilmiştir. Çizelge 2’de deneysel veriye en yakın modelin sonuçları sunulmuştur. Bu model İleri Beslemeli Geriye Yayılım Sinir Ağı mimarisinde tek gizli katmanlı, gizli katmanında 10 nörona sahip, transfer fonksiyonu olarak LOGSIG kullanan, çıktı katmanı fonksiyonu olarak PURELIN seçilmiş olan modeldir.

**Çizelge 2.** ANN En iyi Model Performans Ölçümü

	<b>Eğitim verisi</b>	<b>Test verisi</b>	<b>Tümü</b>
<b>RMSE</b>	0,007405453	0,006591519	0,009914074
<b>R<sup>2</sup></b>	0,999784562	0,998787963	0,999661542
<b>MAPE</b>	1,92757443	5,402078092	2,775014347

#### 4.Sonuçlar

Kurutma süreçlerinin zaman ve maddi maliyetini en aza indirmenin yollarından biri de matematiksel model oluşturarak, ürünün kuruma davranışlarını modellemektir. Bunun için bu çalışmada YSA kullanılarak fındık kabuğu ürünün kuruma parametreleri üzerinde tahminler gerçekleştirilmiştir. Ayrıca birden fazla model oluşturularak fındık kabuğu ürününün kuruma davranışlarına en yakın modelin tespiti yapılmıştır.

Bunu gerçekleştirmek için konveyör bantlı bir mikrodalga düzeneği aracılığı ile elde edilmiş deneysel kuruma parametrelerinin %80’lik kısmı YSA eğitimleri için kullanılarak, kalan %20’lik kısmın kuruma parametrelerinin tahmini hedeflenmiştir.

Kuruma parametrelerinin tahminin yapılması ile deneysel verilere en yakın modelin tespiti bu çalışmadaki önemli amaçlardan biridir. Gizli katmanda yer alan transfer fonksiyonu ve nöron sayısı ile çıkış fonksiyonunun kendi aralarında değiştirilerek kullanılmasıyla 9 farklı YSA modeli elde edilmiş ve fındık kabuğu kuruma parametreleri tahminlerinde birbirleri ile kıyaslanmıştır. Yapılan testler sonucunda en iyi modelin İleri Beslemeli Geriye Yayılım Sinir Ağı mimarisinde 10 nörona sahip, transfer fonksiyonu olarak Lojistik Sigmoid,

çıkış fonksiyonu olarak da Doğrusal Fonksiyon kullanan model olduğu tespit edilmiştir.

Bu modeller ve veriler ışığında fındık kabuğu için deney düzeneği kurmadan kurutma tahminleri yapılabilir hale gelmiştir. İleriki çalışmalarda mimarileri de işlemin içine katıp, gizli katman sayısının artırılması ile yeni modellerin oluşturularak, farklı ürünlerde de kurutma süreçlerinin modellenmesi hedeflenmektedir.

### **Ek Bilgi**

Bu çalışma, Tekirdağ Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı bünyesinde Haziran 2022’de tamamlanmış olan 1188132107 öğrenci numaralı Mert LEVENT’in “BULANIK MANTIK VE YAPAY SİNİR AĞI YÖNTEMLERİ İLE KURUTMA SÜRECİNİN MODELLENMESİ” isimli Yüksek Lisans Tezi’nden üretilmiş bir çalışmadır.

## Kaynakça

- Elijah, O.C., Philomena, K.I., Joseph, T.N., Charles, O.N. and Pascha, E.O. (2020). Valuation Of Optimization Techniques In Predicting Optimum Moisture Content Reduction In Drying Potato Slice, *Artificial Intelligence in Agriculture*, 4, 39–47.
- Yıldız, A.K., Taşova, M. and Polatci, H., (2020). The Use of Radial-Based Artificial Neural Networks in Modelling Drying Kinetics, *Turkish Journal of Agriculture - Food Science and Technology*, 8(2): 511-514.
- Ağyar, Z., (2015). Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama, *Mühendis ve Makine*, 56(662), 22-23.
- Öztürk, K. and Şahin, M. E., (2018). A General View of Artificial Neural Networks and Artificial Intelligence. *Takvim-i Vekayi*, 6(2), 25-36.
- Mousavifard, S.M., Attar, M.M., Ghanbari, A., Dadgar, M., (2015). Application Of Artificial Neural Network And Adaptive Neuro-Fuzzy Inference System To Investigate Corrosion Rate Of Zirconium-Based Nano-Ceramic Layer On Galvanized Steel In 3.5% Nacl Solution. *J. Alloys Compd.* 639, 315-324.
- Dülger, Ö., (2014). Predicting Mathematics 1 Course Success By Using Hierarchical Adaptive Network Based Fuzzy Inference System, *Pamukkale University Journal of Engineering Sciences*, 20(5), 166-173.
- Gerbeau, J.F., Vidrascu, M. (2005). A Quasi-Newton Algorithm Based on a Reduced Model for Fluid-Structure Interaction Problems in Blood Flows, *ESAIM Mathematical Modelling and Numerical Analysis*, 37(4).
- Taş, E. (2005). *Yapay Sinir Ağlarında Momentumlu Dik İniş ve Eşlenik Gradyan Eğitim Algoritmalarının Karşılaştırılması*, Yüksek Lisans Tezi, Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir.

- Zhang, Q., Sun, S. (2009). Weighted Data Normalization Based on Eigenvalues for Artificial Neural Network Classification, *International Conference on Neural Information Processing*, 7-8 December 2009.
- Tektaş, A., Karataş, A. (2010). Yapay sinir ağları ve finans alanına uygulaması: Hisse senedi fiyat tahminlemesi, *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(3-4): , 2004
- Raju, M.M., Srivastava, R.K., Bisht, D.S.C., Sharma, H. C., Kumar, A. (2011). Development of Artificial Neural-Network-Based Models for the Simulation of Spring Discharge, *Advances in Artificial Intelligence*, 2011.
- Erkaymaz, O. (2012). *İleri yönlü yapay sinir ağlarında küçük dünya ağ yaklaşımı ve uygulamaları* (Doktora Tezi) Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Sharma, V., Rai, S., Dev, A. (2012). A Comprehensive Study of Artificial Neural Networks, *International Journal of Advanced Research in Computer Science and Software Engineering*.
- Ahmadian, A.S., (2016). Numerical Models for Submerged Breakwaters. Elsevier.
- Cömert, Z., Kocamaz, A.F. (2017). A study of artificial neural network training algorithms for classification of cardiocography signals, *Journal of Science and Technology*, 7(2): 93-103.
- Goyal, K. (2017). The 7 Types of Artificial Neural Networks ML Engineers Need to Know, Erişim Adresi: <https://www.upgrad.com/blog/types-artificial-neural-networks-in-machine-language/>, (Erişim Tarihi:05.09.2023)
- Şengöz, N., Özdemir, G. (2017). Sınıflandırma Problemlerinin Karşılaştırılmasında ANFIS ve Basamak Korelasyon Sinir Ağının Kullanımı, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 21(1):125-130.
- Quej, V., Almorox, J., Arnaldo, J., Saito, L. (2017). ANFIS, SVM and ANN Soft-Computing Techniques to Estimate Daily Global

- Solar Radiation in a Warm Sub-Humid Environment, *Journal of Atmospheric and Solar–Terrestrial Physics*, 155: 62-70.
- Abioduna, O.I., Jantana, A., Omolara, A.E., Dada, K.V., Arshad, H., Mohamed, N.A. (2018). State-of-the-art in artificial neural network applications: A survey, *Heliyon*, 4(11).
- Dolatabadi, M., Mehrabpour, M., Esfandyari, M., Davoudi, M., Alidadi, H. (2018). Modeling of simultaneous adsorption of dye and metal ion by sawdust from aqueous solution using of ANN and ANFIS, *Chemometrics and Intelligent Laboratory Systems*, 181: 72-78.
- Kaveh, M., Sharabiani, V.R., Chayjan, R.A., Taghinezhad, E., Abbaspour-Gilandeh, Y., Golpour, I. (2018). ANFIS and ANNs Model for Prediction of Moisture Diffusivity and Specific Energy Consumption Potato Garlic and Cantaloupe Drying Under Convective Hot Air Dryer, *Information Processing in Agriculture*, 5(3): 372–387.
- Maladkar, K., (2018). Analyticsindiamag, Erişim Adresi:<https://analyticsindiamag.com/6-types-of-artificial-neural-networks-currently-being-used-in-todays-technology/>, (Erişim Tarihi: 20.09.2023)
- Najafi, B., Ardabili, S.F. (2018). Application of ANFIS, ANN, and Logistic Methods in Estimating Biogas Production from Spent Mushroom Compost (SMC), *Resources, Conservation & Recycling*, 133: 169–178.
- Rego, A.S., Valim, I.C., Vieira, A.A., Vilani, C., Santos, B.F. (2018). Optimization of sugarcane bagasse pretreatment using alkaline hydrogen peroxide through ANN and ANFIS modelling, *Bioresource Technology*, 267: 634–641.
- Sight, A. (2018). TechBlog, Erişim Adresi: <https://msatechnosoft.in/blog/artificial-neural-network-types-feed-forward-feedback-structure-perceptron-machine-learning-applications/>, (Erişim Tarihi: 15.09.2023)

- Tınmaz, E.K., Çelen, S., Çelik, S.Ö. (2019). Conventional and microwave drying of hydrocarbon cutting sludge, *Environmental Progress & Sustainable Energy*, 38(4): 1-7.
- Binu, D., Rajakumar, R.J., (2021). *Artificial Intelligence in Data Mining*, Academic Press.
- Moralars, A., Çelen, S. (2022). Evaluation of Thermal and Drying Characteristics of Dried Hazelnut (*Corylus avellana* L.) Shell Waste, *Philippine Agricultural Scientist*, 105(02).
- Buluş, H. N., Çelen, S., Moralars, A. (2023) Modeling the Moisture Content and Drying Rate of Zucchini (*Cucurbita pepo* L.) in a Solar Hybrid Dryer Using ANN and ANFIS Methods, *Philippine Agricultural Scientist*, 106:293-305.
- Levent, M., Buluş, H.N., Moralars, A. and Çelen, S. (2023). Comparison of Artificial Neural Networks and Fuzzy Logic Methods in the Hazelnut Shell Drying Process, *European Journal of Engineering and Applied Sciences*, 6(2), 50-55.



## **BÖLÜM 3**

### **SQL ENJEKSİYONU TÜRLERİ VE UYGULAMA GELİŞTİRME AŞAMASINDA ALINABİLECEK SAVUNMA ÖNERİLERİ**

<sup>1</sup>Mehmet Ali YALÇINKAYA

DOI: <https://dx.doi.org/10.5281/zenodo.10396142>

---

<sup>1</sup> Kırşehir Ahi Evran Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Kırşehir, Türkiye,  
ORCID: 0000-0002-7320-5643, [mehmetyalcinkaya@ahievran.edu.tr](mailto:mehmetyalcinkaya@ahievran.edu.tr)






## 1.GİRİŞ

Web uygulamaları, günümüzde işlemleri kolaylaştırmak ve kullanıcı deneyimini artırmak için yaygın bir şekilde kullanılmaktadır. Ancak, bu uygulamaların güvenliği büyük önem taşımaktadır. SQL enjeksiyonu, web uygulamalarını hedef alan yaygın ve ciddi bir güvenlik tehdididir. Bu tür bir saldırı, kötü niyetli kullanıcıların uygulama tarafından işlenen SQL sorgularını manipüle etmelerini sağlamak amacıyla kullanıcı giriş alanlarından alınan verileri kötüye kullanmalarıyla gerçekleşir. Temelde, saldırganlar, kullanıcı tarafından sağlanan verilerde beklenmeyen karakterleri veya kodları ekleyerek, veritabanı sorgularını istismar etmeye çalışırlar (OWASP,2023).

Tüm veritabanı türleri arasında rasyonel veritabanları çok popülerdir. MySQL, Oracle, MS SQL Server, MS Access, Postgres gibi ilişkisel veritabanı yönetim sistemlerinin çoğu dil olarak SQL kullanmaktadır. SQL'in esnekliği onu güçlü bir dil haline getirmiştir. Kullanıcının, bilginin nasıl getirileceği hakkında hiçbir bilgisi olmadan, hangi bilgiyi istediğini sorabilmesini sağlar. Ancak SQL tabanlı veritabanlarının geniş kullanımı onu bilgisayar korsanlarının ilgi odağı haline getirmiştir. Başarılı bir SQL enjeksiyon saldırısı, bilgisayar korsanına kritik gizli bilgileri açığa çıkartabilmektedir (Sadeghian, 2013)

SQL enjeksiyonu, genellikle web uygulamalarının kullanıcı giriş alanlarından gelen verilere güvenilmediğinde ortaya çıkar. Bu durum, saldırganların bu giriş alanlarından alınan verileri manipüle ederek veritabanı sorgularına istenmeyen kodları eklemelerine olanak tanır. (OWASP, 2022). Örneğin, kullanıcı adı ve şifre girişi, arama kutuları, online form alanları, hatta bazen URL parametreleri gibi alanlar, potansiyel SQL enjeksiyonu noktaları olabilmektedir. Bu alanlara yapılan girişlerin yeterince doğrulanmaması ve filtrelenmemesi durumunda, saldırganlar bu giriş alanlarına özel olarak oluşturulan SQL ifadelerini göndererek veritabanı sorgularını etkileyebilirler. Aşağıda SQL enjeksiyonu zafiyetinin ortaya çıktığı tipi senaryolar listelenmiştir;

- Kullanıcı Giriş Alanları: Web sayfalarındaki kullanıcı giriş alanları, genellikle SQL enjeksiyonu için bir saldırı noktası oluşturur. Örneğin, kullanıcı adı ve şifre gibi bilgileri kontrol etmek için yapılan sorgularda, saldırganlar bu alanlara özel olarak oluşturulan manipüle edilmiş girişleri ekleyerek veritabanı sorgularını etkileyebilirler.
- Arama Kutuları: Web sayfalarındaki arama kutuları, kullanıcının girdiği verilere dayalı olarak veritabanı sorgularını oluşturabilir. Saldırganlar, buradaki giriş alanlarına özel olarak tasarlanmış SQL ifadeleri ekleyerek, sorguları manipüle edebilir ve istenmeyen sonuçlar elde edebilirler.
- Form Alanları: Çeşitli form alanları, kullanıcıların çeşitli bilgileri girmelerini sağlar. Bu alanlara yapılan girişler, genellikle veritabanı sorgularını etkilemek için kullanılır. Saldırganlar, bu form alanlarına özel olarak hazırlanan verileri göndererek, veritabanı sorgularında istedikleri değişiklikleri gerçekleştirebilirler.
- Bu noktalarda alınacak önlemler, kullanıcı girişlerini doğrulamak, parametreize edilmiş sorgular kullanmak, giriş alanlarına sınırlamalar eklemek ve input validation (giriş doğrulama) gibi güvenlik önlemlerini içerir. Bu, SQL enjeksiyonu saldırılarına karşı korunmanın temelidir ve OWASP gibi güvenlik standartları bu konuda kapsamlı bilgi sağlar.



Şekil 1.1. OWASP Top 10 Saldırı Türleri İçerisinde SQL Enjeksiyonunun Yeri

SQL injection yöntemi ile bir web uygulamasının tüm verileri çalınabilmekte, küçük web sitelerinden, büyük firmalara ait web sitelerine kadar tüm uygulamalar söz konusu güvenlik açısından etkilenebilmektedirler (Çontar, 2013). Şekil 1' de OWASP tarafından belirlenen ve saldırganlar tarafından gerçekleştirilen saldırılar içerisinde SQL enjeksiyonunun sahip

olduğu sıralama gösterilmektedir. Şekilde görüldüğü gibi SQL enjeksiyon saldırıları günümüzde hala çok tehlikeli ve yaygın saldırılar arasındaki yerini korumaktadır.

Bu çalışmanın amacı, SQL enjeksiyonunun temelini anlamak, çeşitli SQL enjeksiyonu türlerini tanımlamak ve web uygulamalarında bu tür zafiyetlere karşı alınabilecek önlemleri listelemektir. Ayrıca, geliştiricilere ve güvenlik uzmanlarına bu tehdiye karşı farkındalık kazandırmak ve web uygulamalarını daha güvenli hale getirmek için kullanılabilecek en iyi uygulamaları sunmaktır.

## **2. SQL ENJEKSİYONU ZAFİYETİ ÇEŞİTLERİ**

Literatürde bilinen 4 tip SQL enjeksiyonu zafiyeti bulunmaktadır.

Bunlar;

- Hata tabanlı SQL enjeksiyonu ,
- Union tabanlı SQL enjeksiyonu,
- Zaman tabanlı SQL enjeksiyonudur.

### **2.1. Hata Tabanlı SQL Enjeksiyonu**

Hata tabanlı SQL enjeksiyonu, veritabanı sunucusundan alınan ve veritabanının yapısı hakkında bilgi içeren hata mesajlarına dayanan enjeksiyon türüdür (Voitovych, 2016). Diğer bir ifade ile, hata tabanlı SQL enjeksiyonunda, saldırgan bilgi çalmak için veri tabanı yönetim sisteminin (VTYS) ürettiği hata mesajlarından yararlanır. Bu tür bir saldırı, VTYS' ne gönderilen SQL sorgularının yapısını bozacak meta karakterlerin, sorgu içerisine eklenmesi ile gerçekleştirilir. İçerisinde meta karakterleri içeren sorgu VTYS tarafından çalıştırıldığında, bozuk syntax yapısı yüzünden hataya neden olacaktır. Bu durumda VTYS, web uygulamasına bir hata mesajı döndürecektir. Gerçekleştirdiği eylem sonrasında web sayfasında VTYS' nin hata mesajını gören saldırgan, sorguya eklediği ifadelerin herhangi bir filtrelemeden geçmediğini anlayacak ve bu zafiyet üzerinden sisteme yönelik saldırılar gerçekleştirecektir.

Hata tabanlı SQL enjeksiyonunda, her veritabanı yönetim sistemi farklı olduğu için döndürdüğü hatalar da farklı olacaktır. Yaygın veritabanı yönetim sistemlerinin döndürdüğü hatalardan bazıları aşağıda listelenmiştir;

1. MySQL Hataları:

a. MySQL Syntax Hatası:

- You have an error in your SQL syntax; check the manual that corresponds to your MySQL server version for the right syntax to use near '...' at line ...

b. MySQL Tablo Bulunamadı Hatası:

- Table '...' doesn't exist

2. PostgreSQL Hataları:

a. PostgreSQL Syntax Hatası:

- ERROR: syntax error at or near '...'

b. PostgreSQL Tablo Bulunamadı Hatası:

- ERROR: relation "..." does not exist

3. Microsoft SQL Server Hataları:

a. SQL Server Syntax Hatası:

- Incorrect syntax near '...'

b. SQL Server Tablo Bulunamadı Hatası:

- Invalid object name '...'

4. Oracle Hataları:

a. Oracle Syntax Hatası:

- ORA-00933: SQL command not properly ended

b. Oracle Tablo Bulunamadı Hatası:

- ORA-00942: table or view does not exist

5. SQLite Hataları:

a. SQLite Syntax Hatası:

- near '...' syntax error

b. SQLite Tablo Bulunamadı Hatası:

- no such table: '...'

Yukarıda listelenen hatalar, bir hata tabanlı SQL enjeksiyon saldırısı sırasında saldırganın hedef veritabanı yönetim sisteminden alabileceği şablonlardır. Ancak, bu hataların güvenlik duvarları veya diğer savunma mekanizmaları tarafından yakalanmış veya filtrelenmiş olabileceğini unutmamak önemlidir.

VTYS' leri tarafından döndürülen hata mesaj örnekleri gösterildikten sonra sıra, hata tabanlı SQL enjeksiyonu örneğinin incelenmesine gelmektedir. Örnek bir senaryo düşünelim: Bir web uygulaması, kullanıcının giriş yaptığı bir kullanıcı adı ve şifre alanı içermektedir. Web uygulama sayfası içerisinde yer alan username ve password alanına girilen veriler, aşağıdaki SQL sorgusu içerisine gömülerek VTYS' nde çalıştırılmak üzere gönderilmektedir.

- `SELECT id, username, email FROM users WHERE username = 'input_username' AND password = 'input_password';`

Saldırgan, bu sorguyu kötüye kullanmak için kullanıcı adı alanına aşağıdaki gibi bir giriş yapabilir:

- `' OR 1=1; --`

Bu giriş, orijinal sorgu içerisine gömüldüğünde aşağıdaki SQL sorgusu ortaya çıkacaktır;

- `SELECT id, username, email FROM users WHERE username = " OR 1=1; -- ' AND password = 'input_password';`

Yukarıdaki SQL sorgusu dikkatle incelendiğinde, `' OR 1=1; --` ifadesinin başında yer alan tırnak meta karakteri fazlalık oluşturmakta ve SQL sorgusunun yapısını bozmaktadır. Bu durum sonrasında eğer veri tabanından yukarıda listelenen bir hata mesajı dönerse, saldırgan input alanına girdiği ifadelerin herhangi bir filtrelemeden geçmeden VTYS' nde çalıştırıldığını görecektir ve saldırılarını ona göre şekillendirecektir.

- `AND 1=CONVERT(int, (SELECT @@version)); --`

Yukarıdaki ifade saldırgan tarafından kullanıcı adı alanına girildiğinde, ilk olarak sorgu içerisine gömülecek, daha sonra da VTYS tarafından çalıştırılacaktır. Bu giriş, veritabanının sürüm numarasını çekmeye çalışır. Eğer

hata mesajı ekrana basılıyorsa, saldırgan VTYS' nin sürümü hakkında bilgi edinecektir.

## 2.2. Union Tabanlı (Union Based) SQL Enjeksiyonu

Union tabanlı SQL enjeksiyonu, kötü niyetli kullanıcıların bir web uygulamasına zarar vermek veya hassas bilgileri çalmak için UNION SQL operatörünü kullanarak veritabanına istenmeyen erişim sağlamaya çalıştığı bir tür SQL enjeksiyonudur. Bu tür bir saldırı, web uygulamasının kullanıcı giriş alanlarına müdahale ederek, SQL sorgularını manipüle etme esasına dayanır.

SQL Union operatörü birden fazla Result-Set' i birleştirmek için kullanılmaktadır. Union operatörü olarak gerçekleştirilen sorgularda dikkat edilmesi gereken nokta, iki tablodan çekilen kolonların veri tiplerinin aynı olması zorunluluğudur. Bir uygulamada, Union operatörü kullanılarak gerçekleştirilen sorgularda, eğer sorgu sonrasında web uygulamasına hata dönüyor ve hata içerisinde kullanıcıya veri tabanından çekilen veri gösteriliyor ise, bu noktada Union SQL enjeksiyonu zafiyeti bulunmaktadır. Örnek bir Union denemesinde, farklı tipte veri tabanlarından alınan hata mesajları Tablo 2.1' de gösterilmektedir (Yalçınkaya, 2020).

Tablo 2.1. VTYS' lerine göre Union sorgu hata mesajları

Veri Tabanı	Hata Mesajı
MSSQL	All queries combined using a UNION, INTERSECT or EXCEPT operatör must have an equal number of expressions in their target lists.
Oracle	ORA-01789: query block has incorrect number of result columns.
MySQL	The used SELECT statements have a different number of columns.
MS Access	The number of columns in the two selected tables or queries of a union query do not match.

Union tabanlı SQL enjeksiyonu saldırılarını örneklemek için, kullanıcı adı ve parola bilgilerinin alındığı ve veri tabanına giriş doğrulama için

gönderildiği bir web uygulaması düşünelim. Web uygulaması içerisinde yer alan input alanlarına normal değerler girildiğinde oluşacak sorgu aşağıdaki gibidir;

- `SELECT id, username, email FROM users WHERE username = 'input_username' AND password = 'input_password';`

Saldırganın kullanıcı adı alanına aşağıdaki Union sorgusunun girildiğini düşünülün;

- `' UNION SELECT table_name, null, null FROM information schema.tables –`

Bu sorgu incelendiğinde, `information_schema.tables` tablosundan tablo adlarının alınmaya çalışıldığı ve null değerlerinin, orijinal sorgunun sütun sayısını eşleştirmek için kullanıldığı görülmektedir. Bu durumda VTYS' ne gönderilecek sorgu aşağıdaki gibi olacaktır;

- `SELECT id, username, email FROM users WHERE username = " UNION SELECT table_name, null, null FROM information_schema.tables --' AND password = 'input_password';`

`INFORMATION_SCHEMA.TABLES` tablosu, VTYS üzerinde yer alan tüm tablolar hakkında bilgilerin yer aldığı bir tablodur. Bu tablo içerisindeki `TABLE_NAME` sütunu ise veri tabanında yer alan tüm tabloların isimlerini içermektedir. Bu sorgu çalıştırıldığında `Table_Name` sütunundaki ilk tablo ismi döndürülecektir. Union komutu, ikinci sorgudan dönen `nvarchar` türündeki tablo ismini, integer tipinde olan `id` değeri ile birleştirmek için, `integer` a çevirmeye çalışacaktır. `Nvarchar` bir değer `integer`'a çevrilemediği için hata oluşacak ve dönen hata web uygulaması tarafından ekrana basılacaktır. Oluşacak hata metni aşağıdaki gibi olacaktır;

- Microsoft OLE DB Provider for ODBC Drivers error '80040e07' [Microsoft][ODBC SQL Server Driver][SQL Server]Syntax error converting the nvarchar value '**tablo1**' to a column of data type int./index.asp, line 5



Elde edilen hata mesajında nvarchar türündeki değerin integer' a çevrilemediği uyarısı verilmektedir. Bunun yanında hata çıktısı incelendiğinde Table\_Name alanında yer alan ilk tablo isminin 'tablo1' olduğu görülmektedir.

### 2.3. Zaman Tabanlı SQL Enjeksiyonu

Zaman tabanlı SQL enjeksiyonu, veritabanının belirli bir süre duraklatılmasına ve ardından başarılı bir SQL sorgusu yürütülmesini gösteren sonuçların döndürülmesine dayanır. Bu saldırı türünde, saldırgan, SQL sorgularının yanıt süresini kullanarak veritabanı üzerindeki bilgileri çalmaya çalışır (Rai vd, 2021). Zaman tabanlı SQL enjeksiyonu için kullanılacak SQL komutları, kullanılan veritabanı yönetim sistemine göre değişiklik gösterebilir. Aşağıda farklı VTYS' leri üzerinde zaman tabanlı SQL enjeksiyonu zafiyetini tetiklemek için kullanılacak SQL komutları listelenmektedir;

1. MySQL:
  - a. SLEEP(seconds)
2. PostgreSQL:
  - a. pg\_sleep(seconds)
3. Microsoft SQL Server:
  - a. WAITFOR DELAY '0:0:5'
4. Oracle:
  - a. DBMS\_LOCK.SLEEP(seconds)

Aşağıdaki örnekte, bir web uygulamasındaki bir kullanıcı giriş alanı üzerinden gerçekleştirilen zaman tabanlı bir SQL enjeksiyonu ele alınmıştır. Öncelikle, saldırının hedefine yönelik bir SQL sorgusunu belirlenmesi gerekmektedir. Web uygulamasında kullanıcı adı ve şifre doğrulama işlemi aşağıdaki gibi bir SQL sorgusu ile gerçekleştirildiği varsayılmaktadır;

- SELECT \* FROM Users WHERE Username = 'input\_username' AND Password = 'input\_password';

Saldırgan tarafından parola alanına aşağıdaki sorgunun girilmektedir;

- ' OR IF(1=1, WAITFOR DELAY '0:0:5', 0) –

Bu SQL ifadesinde WAITFOR DELAY '0:0:5' komutu, SQL Server'ın belirli bir süre boyunca (bu örnekte 5 saniye) beklemesini sağlamaktadır. Saldırgan parola alanına yukarıda verilen SQL komutunu yazıp, login butonuna tıkladığında, VTYS' ne gönderilen SQL sorgusu aşağıdaki gibi olacaktır;

- `SELECT * FROM Users WHERE Username = " OR IF(1=1, WAITFOR DELAY '0:0:5', 0) --' AND Password = 'input_password';`

Yukarıdaki sorgu incelendiğinde, 1 her zaman 1' e eşit olduğundan dolayı eğer dönen sayfa 5 saniye gecikmeli görüntülenecek olursa, zaman tabanlı SQL enjeksiyonu tespit edilmiş olacaktır.

### **3. SQL ENJEKSİYONU Tekniklerine yönelik çözüm önerileri**

SQL enjeksiyonu saldırıları, siber saldırganlar tarafından web uygulamalarını istismar etmek ve kurum/kuruluşlara ait kritik verilerin elde etmek amacıyla yaygın olarak gerçekleştirilmektedir. SQL enjeksiyonlarına karşı etkili savunma hem uygulama geliştiricileri hem de sistem yöneticileri tarafından bir dizi önlem almayı içerir. Söz konusu saldırıya karşı, kayıt türlerinin kontrol edilmesi, beyaz liste kullanılması, zaman gecikmelerinin izlenmesi, log kayıtlarının düzenli olarak takip edilmesi gibi önlemler alınabilmektedir. Bu çalışmada ise daha çok uygulama geliştirme aşamasında alınabilecek önlemler detaylandırılmıştır.

#### **3.1. Parametreize Sorgular Kullanma**

"Parametreize Sorgular Kullanma", SQL enjeksiyonlarına karşı alınabilecek en etkili önlemlerden biridir. Bu yöntem, dinamik SQL sorgularında kullanılan kullanıcı girişlerini veya dış etkileşimli unsurları sorguya gömmek yerine, bu unsurları sorgu parametreleri olarak işlemenizi sağlar. Bu sayede, kullanıcı girişleri direkt olarak SQL sorgusuna gömülmediği için SQL enjeksiyon saldırıları engellenmiş olur.

Aşağıda "Parametreize Sorgular Kullanma" işleminin adım adım nasıl uygulanabileceği detaylı olarak örneklendirilmiştir.

- `SELECT * FROM Users WHERE Username = 'input_username' AND Password = 'input_password';`

Yukarıdaki örnekte bir web sayfasından alınan kullanıcı adı ve parola bilgilerinin, VTYS' nde çalıştırılmak üzere sorgu içerisine eklendiği klasik yöntem gösterilmektedir. Bu yöntem doğrudan SQL enjeksiyonu zafiyetine neden olmaktadır. Aşağıda ise SQL Enjeksiyonu riskini azaltan, kullanıcıdan

alınan verilerin istenen formatta olup olmadığını kontrol eden Python kodu gösterilmektedir.

```
def sanitize_input(user_input):
    # Girişin beklenen formatta olup olmadığını kontrol et
    # Gerekirse temizleme işlemlerini uygula
    sanitized_input = user_input.strip() # Örnek: Boşlukları temizle
    return sanitized_input

# Kullanıcı girişlerini al
input_username = sanitize_input("example_username")
input_password = sanitize_input("example_password")
```

Gerekli kontrollerden geçirilen kullanıcı girdileri daha sonra aşağıdaki şekilde sorgu içerisine gömülebilmektedir;

```
# Parametreize sorgu
sql = "SELECT * FROM Users WHERE Username = %s AND
Password = %s"

# Veritabanı bağlantısı
conn = psycopg2.connect("your_connection_string")
cursor = conn.cursor()

# Parametreleri ekleyerek sorguyu çalıştır
cursor.execute(sql, (input_username, input_password))

# Sonuçları al
results = cursor.fetchall()

# Bağlantıyı kapat
cursor.close()
conn.close()
```

Yukarıda örnek uygulaması gösterilen yöntem ile, kullanıcı tarafından girilen veriler, doğrudan sorgu içine gömülme yerine, ek kontrollerden geçirilmekte, daha sonra sorgu içerisine eklenmektedir. Bu sayede input verileri içerisinde yer alabilecek olası zararlı komutlar filtrelenecektir.

### 3.2. Input Validasyonu

Web Uygulamalarında yer alan kullanıcı girişlerini doğrulanmalıdır. Geliştiriciler tarafından, kullanıcıların girdiği verilerin özel karakterleri veya SQL ifade bileşenlerini içermemeleri sağlanarak güvenliği artırılmalıdır. Bu sayede kullanıcıların sadece belirli karakterleri içeren ve belirli uzuntuktaki girdileri kabul edilecektir. Örneğin, bir kullanıcı adının sadece harf ve rakamları içermesi gerektiğini düşünelim. Bu durumu kontrol etmek için Python dilinde yazılmış basit bir doğrulama işlemi aşağıda gösterilmektedir;

```
def is_valid_username(username):  
    return username.isalnum() # Sadece harf ve rakamlardan oluşmalı  
  
# Kullanıcı adını kontrol et  
if is_valid_username(input_username):  
    # Kullanıcı adı geçerli, devam et  
else:  
    # Kullanıcı adı geçerli değil, hata mesajı göster veya işlemi durdur
```

### 3.3. Stored Procedures Kullanma

"Stored Procedures Kullanma," SQL enjeksiyonlarına karşı alınabilecek etkili bir önlemdir. Stored Procedure (Depolanan Prosedür), bir veritabanı yönetim sistemi tarafından derlenmiş ve depolanmış bir SQL sorgusudur. Bu sorgular, genellikle iş mantığı veya veritabanı işlemlerini gerçekleştirmek için kullanılır. SQL enjeksiyonlarından korunmak için stored procedures kullanmak, kullanıcı girişlerini doğrudan SQL sorgularına gömmeye ihtiyacı azaltır ve güvenlik sağlar.

Stored Procedure oluşturmak için kullanılan syntax veritabanı yönetim sistemine (örneğin, MySQL, SQL Server, PostgreSQL) bağlıdır. Aşağıda SQL Server ve Python dili kullanılarak gerçekleştirilen bir Stored Procedure örneği gösterilmektedir.

```
CREATE PROCEDURE VerifyUser
    @input_username NVARCHAR(50),
    @input_password NVARCHAR(50)
AS
BEGIN
    SELECT * FROM Users WHERE Username = @input_username
    AND Password = @input_password;
END;
```

Yukarıda tanımlanan Stored Procedure içerisinde yer alan parametreler, dış kaynaklardan alınan kullanıcı girişlerini doğrudan sorgulara gömmek yerine kullanılır. Aşağıda ise, Python dilinde yazılmış örnek bir stored procedure çağrı örneği gösterilmektedir.

```
import pyodbc

# Veritabanı bağlantısı
conn_str = "Driver = { SQL Server } ;
Server=your_server;Database=your_database; User Id =
your_username; Password = your_password;"
conn = pyodbc.connect(conn_str)
cursor = conn.cursor()

try:
    # Stored procedure çağrısı
    cursor.execute("{CALL VerifyUser(?, ?)}", (input_username,
input_password))
```

```
# Sonuçları al
rows = cursor.fetchall()

# Sonuçları işleme
for row in rows:
    print(row)

finally:
    # Bağlantıyı kapat
    cursor.close()
    conn.close()
```

Bu örnekte pyodbc kütüphanesini kullanarak SQL Server veritabanına bağlanılmaktadır. Ardından execute fonksiyonuyla stored procedure'ı çağırılmaktadır. Stored procedure'ın adını ve parametrelerini belirtirken dikkat edilmelidir. Bu örnekte, ? işaretleri yerine parametrelerin sırasıyla yerleştirildiğini görülmektedir. Son olarak, fetchall fonksiyonu ile stored procedure'ın döndürdüğü sonuçlar alınabilmekte ve işlenebilmektedir.

### 3.4. Least Privilege İlkesi

"Least Privilege" (En Az Yetki) ilkesi, bir kullanıcının veya bir sistemin ihtiyacı olan minimum yetkileri alması gerekliliğini savunan bir güvenlik prensibidir. SQL enjeksiyonlarına karşı alınabilecek önlemlerden biri olarak, Least Privilege ilkesi uygulandığında, kullanıcılara veya uygulamalara sadece gerekli olan en düşük düzeyde yetkiler verilir. Bu şekilde, eğer bir saldırı gerçekleşirse veya bir hata oluşursa, zararın etkisi minimize edilmiş olur.

Aşağıda "Least Privilege" ilkesi doğrultusunda yazılan SQL komutları verilmiştir. Komutlar incelendiğinde, ilk olarak kullanıcılara veya uygulamalara atanabilecek önceden tanımlanmış rolleri belirlenmiştir. Bu roller genellikle belirli bir işlevi yerine getirmek için gerekli olan yetkileri içermektedir (örneğin, "read-only", "data modification", "admin" rolleri).

-- Örnek: "read-only" ve "data modification" rolleri

```
CREATE ROLE ReadOnly;
```

```
GRANT SELECT ON ALL TABLES IN SCHEMA public TO  
ReadOnly;
```

```
CREATE ROLE DataModification;
```

```
GRANT INSERT, UPDATE, DELETE ON ALL TABLES IN  
SCHEMA public TO DataModification;
```

Roller tanımlandıktan sonra, her kullanıcıya veya uygulamaya, ihtiyacına uygun olan rolleri atanmalıdır. Kullanıcılar sadece belirli görevleri yerine getirmek için gerekli olan yetkilere sahip olmalıdır. Aşağıda söz konusu işleme ait örnek gösterilmektedir.

-- Örnek: Kullanıcıya rolleri atama

```
CREATE USER web_app WITH PASSWORD 'password';
```

```
GRANT ReadOnly TO web_app;
```

Kullanıcılara rollerin atanmasının yanında, sadece işlerini yapabilmeleri için gerekli olan tablo ve işlemlere yetki verilmelidir. Örneğin, bir web uygulamasının sadece belirli bir tabloyu sorgulaması gerekiyorsa, sadece söz konusu tabloya erişim sağlanmalı, veri tabanında yer alan başka tablolara erişimi yasaklanmalıdır. Aşağıda söz konusu işleme ait örnek gösterilmektedir.

-- Örnek: Sadece belirli bir tabloya yetki verme

```
GRANT SELECT ON Users TO web_app;
```

“Least Privilege” ilkesi doğrultusunda alınabilecek bir diğer önlem ise, stored procedure’lara erişimin kısıtlanmasıdır. Stored procedure’lar, belirli görevleri gerçekleştirmek için kullanılacak önceden tanımlanmış ve kontrol edilmiş işlemleri içerebilir. Kullanıcılara stored procedure’ları doğrudan çağırma yetkisi verilirken, tablolara doğrudan erişim vermekten kaçınılabilir. Aşağıda söz konusu işleme ait örnek gösterilmektedir.

-- Örnek: Stored procedure için yetki verme

```
GRANT EXECUTE ON VerifyUserProcedure TO web_app;
```

#### 4. SONUÇLAR

SQL enjeksiyonları, kullanıcı girişlerinin kontrolsüz bir şekilde SQL sorgularına gömülmesi nedeniyle ortaya çıkan güvenlik açıklarıdır. Bu tür saldırılar, saldırganın kötü niyetli SQL ifadelerini enjekte ederek uygulama üzerinde istenmeyen etkiler yaratmasına olanak tanır. Bu etkiler arasında veritabanı içeriğinin görüntülenmesi, değiştirilmesi veya silinmesi bulunabilir. Dolayısıyla, SQL enjeksiyonlarına karşı korunmak, kullanıcıların girişlerini güvenli bir şekilde işlemek ve veritabanı güvenliğini sağlamak açısından kritik öneme sahiptir. Bu nedenle, uygulama geliştirme aşamasında alınan önlemler büyük önem taşımaktadır. Bu makalede incelenen önlemler, SQL enjeksiyonlarına karşı etkili bir savunma sağlamak amacıyla uygulama geliştiricileri tarafından benimsenebilir.

Bu makalede, SQL enjeksiyonu türleri üzerinde detaylı bir inceleme yapılmış ve bu tür saldırılara karşı alınabilecek dört önemli önlem detaylı bir şekilde açıklanmıştır. Açıklanan önlemler olan; parametreize sorgular kullanmak, input validasyonu ve filtreleme, stored procedures kullanmak ve Least Privilege ilkesini uygulamak, uygulama geliştiricilerine ve sistem yöneticilerine güçlü bir güvenlik stratejisi sağlamaktadır. Bu önlemler, siber saldırılara karşı daha dirençli ve güvenli web uygulamalarının geliştirilmesine katkıda bulunmaktadır. Fakat unutulmamalıdır ki, güvenlik, sürekli bir çaba gerektirmektedir. Bu nedenle uygulama güvenliği sürekli olarak izlenmeli ve güncellenmelidir.



## **KAYNAKLAR**

- Çontar, F., 2013. Ağ ve Yazılım Güvenliği, Kodlab Yayıncılık, 264s, İstanbul.
- OWASP, 2023. "SQL Injection Prevention Cheat Sheet." Erişim Tarihi: 10.10.2023.  
[https://cheatsheetsseries.owasp.org/cheatsheets/SQL\\_Injection\\_Prevention\\_Cheat\\_Sheet.html](https://cheatsheetsseries.owasp.org/cheatsheets/SQL_Injection_Prevention_Cheat_Sheet.html)
- Rai, A., Miraz, M. M. I., Das, D., & Kaur, H. (2021, April). SQL Injection: Classification and Prevention. In 2021 2nd International conference on Intelligent Engineering and Management (ICIEM) (pp. 367-372). IEEE.
- Sadeghian, A., Zamani, M., & Abdullah, S. M. (2013, September). A taxonomy of SQL injection attacks. In 2013 International Conference on Informatics and Creative Multimedia (pp. 269-273). IEEE.
- Voitovych, O. P., Yuvkovetskyi, O. S., & Kupershtein, L. M. (2016, September). SQL injection prevention system. In 2016 International Conference Radio Electronics & Info Communications (UkrMiCo) (pp. 1-4). IEEE.
- Yalçınkaya, M.A. (2020). Yapay zeka ve dinamik analiz tabanlı web uygulama zafiyet tarayıcısı. (Yayınlanmamış Doktora Tezi). Süleyman Demirel Üniversitesi, Isparta.

## **BÖLÜM 4**

### **ROBOT İŞLETİM SİSTEMİ VE HECTOR SLAM PAKETİNİN KULLANIMI**

<sup>1</sup>Arş. Gör. Mümine YILDIZ

<sup>2</sup>Dr. Öğr. Üyesi Özgür DÜNDAR

<sup>3</sup>Prof. Dr. Mehmet KARALI

<sup>4</sup>Dr. Öğr. Üyesi Emrehan YAVŞAN

DOI: <https://dx.doi.org/10.5281/zenodo.10396166>

---

<sup>1</sup> Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Konya, Türkiye, ORCID: 0000-0001-8177-622X, [mumineyildiz@erbakan.edu.tr](mailto:mumineyildiz@erbakan.edu.tr)

<sup>2</sup> Necmettin Erbakan Üniversitesi, Havacılık ve Uzay Bilimleri Fakültesi, Havacılık ve Uzay Mühendisliği Bölümü, Konya, Türkiye, ORCID: 0000-0002-4142-4446, [ozdundar@erbakan.edu.tr](mailto:ozdundar@erbakan.edu.tr)

<sup>3</sup> Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Konya, Türkiye, ORCID: 0000-0002-2380-0575, [mkarali@erbakan.edu.tr](mailto:mkarali@erbakan.edu.tr)


<sup>4</sup> Tekirdağ Namık Kemal Üniversitesi, Elektronik ve Otomasyon Bölümü, Tekirdağ, Türkiye, ORCID: 0000-0001-9521-4500, [eyavsan@nku.edu.tr](mailto:eyavsan@nku.edu.tr)



## 1. Giriş

Robot İşletim Sistemi (ROS), robotikte geniş bir şekilde kullanılan kapsamlı bir çerçevedir. Robotik uygulamaların çeşitli gereksinimlerini karşılamak üzere tasarlanmış olan ROS, geniş bir araç yelpazesi, kütüphane ve yazılım geliştirme konusunda kolaylık sağlar. Felsefe, kodda küçük değişiklikler yaparak başka robotlarda çalışabilecek bir yazılım parçası yapmaktır. Bu doğrultuda, çeşitli robotlar için iş yükünü azaltarak paylaşılabilir ve kullanılabilir fonksiyonlar yaratmak amaçlanmaktadır (Joseph, 2017). ROS, robotlar için modüler ve yeniden kullanılabilir yazılım bileşenleri oluşturmanın yanı sıra, donanım soyutlaması, düşük seviye cihaz kontrolü, iletişimler arasında geçiş, mesaj geçişi, paket yönetimi ve daha birçok özelliğiyle de öne çıkar. Bu platform, robotik araştırmacıların ve geliştiricilerin, çeşitli robot platformlarına uygulanabilir, etkili ve güvenilir robot yazılımları geliştirmelerine olanak tanır. ROS, özellikle akademik çevrelerde robotik araştırmaları yapmak ve yeni robotik teknolojileri geliştirmek için kullanılır, fakat aynı zamanda endüstriyel uygulamalarda da giderek daha yaygın hale gelmektedir.

ROS, donanım soyutlaması, düşük seviye cihaz kontrolü, yaygın kullanılan fonksiyonların uygulanması (implementasyonu), süreçler arası mesaj geçişi ve paket yönetimi gibi standart işletim sistemi olanakları sağlar. Açık kaynak olarak yayınlanan hazır paketlerin kullanımı ile hızlı bir şekilde adaptasyon sağlanabilir. Örneğin eş zamanlı lokalizasyon ve haritalama (SLAM) algoritmalarına dair paketler kullanılabilir veya sensör ve aktüatörlerin cihaz sürücüleri kullanılabilir. Ayrıca ROS, hata ayıklama, görselleştirme ve simülasyon yapmak için araçlar sunar. Rviz, Gazebo ve rqt\_gui gibi araçlar; hata ayıklama, görselleştirme ve simülasyon için güçlü açık kaynak araçlardır.



Şekil 1. ROS ana çalışma mimarisi

ROS, merkezi bir topolojiye sahip grafik mimarisine dayanmaktadır ve işlem, kontrol, durum, planlama, aktüatör vb. gibi posta alabilir veya gönderebilir olan düğümlerde gerçekleşir (Open Robotics, 2022). Bu düğümler, ROS istemci kütüphanelerine sahip herhangi bir dilde programlanabilir. Yüksek performanslı düğümleri C++ veya C'de ve diğer düğümleri Python veya Java'da yazılabilir. Bu tür bir esneklik Player, YARP, Orocos, MRPT vb. gibi diğer robotik platformlarda mevcut değildir (Quigley ve diğerleri, 2009). ROS, robotik uygulama geliştirmede pek çok avantaj sağlar. Bu avantajlardan bazıları aşağıda altbaşlıklar halinde açıklanmıştır.

**Modülerlik:** Çoğu bağımsız robotik uygulamada meydana gelebilecek sorunlardan biri, eğer ana kodun herhangi bir iş parçacığı çökerse, tüm robot uygulamasının durabilmesidir. ROS'ta durum farklıdır; her bir işlem için farklı düğümler yazılmakta ve eğer bir düğüm çökerse, sistem çalışmaya devam edebilmektedir. Ayrıca, ROS, herhangi bir sensör veya motor arızalanırsa operasyonları sürdürme konusunda sağlam yöntemler sunar.

**Eş zamanlı kaynak yönetimi:** Bir donanım kaynağını iki işlem üzerinden yönetmek her zaman zor bir işlemdir. Bir kameradan gelen bir görüntüyü yüz tanıma ve hareket algılama için işlemek istediğimizi düşünün; ya her ikisini de yapabilen tek bir birlik olarak kodu yazabiliriz, ya da eş zamanlılık için tek iş parçacıklı kod yazabiliriz. Eğer iş parçacıklarında iki özellikten fazlasını eklemek istiyorsak, uygulama davranışı karmaşık hale

gelecek ve hata ayıklaması zor olacaktır. Fakat ROS'ta, ROS sürücülerinden ROS konularını kullanarak cihazlara erişebiliriz. ROS kamerası sürücüsünden gelen görüntü mesajına herhangi bir sayıda ROS düğümü abone olabilir, ve her düğüm farklı işlevselliği gerçekleştirebilir. Bu, hesaplamada karmaşıklığı azaltabilir ve tüm sistemin hata ayıklama kabiliyetini artırabilir.

**Geniş kütüphane ve araç desteği:** ROS, robotik uygulamaların geliştirilmesi için geniş bir kütüphane ve araç setine sahiptir. Sensör entegrasyonu, hareket planlaması, görüntü işleme ve yapay zeka gibi çeşitli konularda geliştiricilere yardımcı olan bu kütüphaneler, projelerin daha hızlı ve etkili bir şekilde ilerlemesini sağlar. ROS'un sunduğu bu araçlar, geliştiricilere farklı uygulamalar ve özellikler üzerinde çalışma esnekliği tanır.

**Çoklu dil desteği:** ROS, çeşitli programlama dillerini destekleyen bir yapıya sahiptir. Bu sayede geliştiriciler, C++, Python, Lisp gibi dillere aşina oldukları için konfor alanlarında çalışabilirler. Bu çok dilli destek, topluluğun çeşitlenmesine ve farklı bilgi birikimleriyle katkıda bulunmasına olanak tanır.

**Donanım soyutlaması:** ROS, farklı robot donanımları arasında bir soyutlama katmanı sunar. Bu, geliştiricilere farklı donanım platformlarına uyumlu uygulamalar geliştirme esnekliği tanır. Bu soyutlama, kodun farklı robot platformları arasında kolayca paylaşılmasını ve uyarlanmasını kolaylaştırır.

**Akademik ve endüstriyel kullanım:** ROS, robotik alanında akademik araştırmaların yanı sıra endüstriyel uygulamalar için de popüler bir platformdur. Akademik çevrelerde, ROS genellikle yeni robotik algoritmaların ve teknolojilerinin araştırılmasında kullanılır. Endüstriyel alanda, ROS bazen ticari/endüstriyel robotların (Efe, Özcan ve Haklı, 2021) ve onların ürünlerinin geliştirilmesi süreçlerinde tercih edilir, bu da endüstrinin inovasyon kapasitesini artırabilir.

**Simülasyon ortamları:** ROS, geliştiricilere yazılımlarını gerçek donanım olmadan test etme fırsatı sunan simülasyon araçlarıyla entegre bir şekilde gelir. Özellikle Gazebo, ROS ile entegre çalışabilen güçlü bir robot simülasyon aracıdır. Bu simülasyon ortamı, robotlar için gerçek dünya

koşullarını taklit edebilir ve geliştirme sürecini hızlandırabilir, maliyetleri azaltabilir ve daha güvenilir robotik sistemlerin oluşturulmasını destekler.

**Aktif topluluk:** Bir kütüphane veya yazılım çerçevesi seçerken, özellikle bir açık kaynak topluluğundan, kullanmadan önce kontrol edilmesi gereken ana faktörlerden biri yazılım desteği ve geliştirici topluluğudur. Açık kaynaklı bir araçtan destek garantisi yoktur. Bazı araçlar iyi destek sağlar, bazıları sağlamaz. ROS'ta, destek topluluğu aktiftir. Kullanıcılardan destek sorgularını ele almak için bir web portalı da vardır (Anonim, 2023a). Bu portaldan da anlaşılacağı gibi ROS topluluğunun dünya çapında geliştiricilerde istikrarlı bir büyüme gösterdiği görülmektedir.

Bu maddelerin yanı sıra, geniş kütüphane ve araç desteği, çoklu dil desteği, donanım soyutlaması, akademik ve endüstriyel kullanım ve simülasyon ortamları avantaj sağlamaktadır.

ROS'un yukarıdaki avantajlarının yanında kullanımında ortaya çıkan birtakım dezavantajları da vardır. Bunlar aşağıki bölümlerde ele alınmıştır.

**Öğrenme zorluğu:** ROS öğrenmesi zor olabilir. Keskin bir öğrenme eğrisi vardır ve geliştiriciler, ROS çerçevesinden fayda sağlamak için birçok yeni kavramı öğrenmelidir.

**Simülasyona başlama zorlukları:** ROS'taki ana simülatör Gazebo'dur. Gazebo stabil çalışmasına rağmen, kullanımı başlangıçta kolay olmayabilir. Simülatörün, programlamak için dahili özellikleri yoktur. Tam simülasyon sadece ROS'ta kodlama yoluyla yapılır. Gazebo'yu V-REP ve Webots gibi diğer simülatörlerle karşılaştırdığımızda, bu simülatörler robotu prototiplemek ve programlamak için dahili işlevselliklere sahiptir. Aynı zamanda, geniş bir robot çeşitliliğini destekleyen zengin bir grafik kullanıcı arayüzü (GUI) araç setine ve ROS arayüzlerine de sahiptirler. Bu araçlar özel olup düzgün bir iş çıkarabilir. Gazebo ve ROS kullanarak simülasyon öğrenme zorluğu, projelerde kullanılmama sebeplerinin başında gelmektedir.

**Robot modelleme zorlukları:** ROS'ta robot modelleme, XML tabanlı bir robot açıklaması olan URDF kullanılarak gerçekleştirilir. Kısacası, robot modelini URDF etiketlerini kullanarak bir açıklama olarak yazmamız gerekir. V-REP'te GUI'de doğrudan 3D robot modelini oluşturabiliriz ya da örgüyü içe aktarabiliriz. ROS'ta, robot model tanımlarını URDF etiketlerini kullanarak

yazmalıyız. SolidWorks'ten URDF'ye bir 3D modeli dönüştürmek için bir eklenti vardır, ama eğer başka 3D CAD araçları kullanıyorsak hiçbir seçenek yoktur. ROS'ta bir robotu modellemeyi öğrenmek çok zaman alır ve URDF etiketleri kullanarak oluşturmak da diğer simülatlara göre zaman alıcıdır.

**Performans:** ROS, genellikle yüksek düzeyde soyutlama sağlar, bu da performansı olumsuz etkileyebilir. Yüksek performans gerektiren uygulamalar için bu durum bir problem oluşturabilir.

**Gerçek zamanlı işlemler:** ROS, gerçek zamanlı işlemler ve kontrol sistemleri için tam optimize edilmemiştir. Bu, özellikle gerçek zamanlı gereksinimleri olan robotik uygulamalar için bir dezavantajdır.

**Güvenlik:** ROS'un eski sürümleri, güvenlik konusunda yetersiz kalabilirler. Özellikle internet üzerinden iletişimde, güvenlik açıkları ve siber saldırılara karşı hassasiyet söz konusu olabilir.

**Windows desteği:** ROS, başlangıçta Linux işletim sistemi için tasarlandığından, Windows üzerinde çalıştırmak bazı zorluklara neden olabilir. Bu durum, Windows kullanıcıları için ekstra bir yük oluşturabilir.

**Donanım desteği:** Bazı donanım bileşenleri ve robot modelleri, ROS ile doğrudan uyumlu olmayabilir ve bu da ekstra entegrasyon çabası gerektirebilir.

**Bellek ve işlemci kullanımı:** Bazı durumlarda, ROS'un bellek ve işlemci kullanımı optimal olmayabilir, bu da kaynakların etkili kullanımını sınırlar.

**Ticari robot ürünlerinde ROS:** ROS'u bir ticari üründe kullanırken dikkat edilmesi gerekenlerden biri kod kalitesidir. ROS kodu, standart bir kodlama tarzını takip eder ve kodun bakımı için en iyi uygulamalara sahiptir. Ayrıca ürün için gerekli kalite seviyesinin karşılanıp karşılanmadığı kontrol edilmelidir. Kodun kalitesini artırmak için ekstra çalışmalar gerekebilir. ROS platformundaki kodun çoğuna, üniversitelerden araştırmacılar tarafından katkıda bulunulmuştur, bu yüzden ROS kod kalitesinden memnun değilsek,



kendi kodumuzu yazmak daha iyidir, bu robota özgüdür ve gerekirse sadece ROS'un çekirdek işlevselliği kullanılabilir (Fernandez, Crespo, Mahtani ve Martinez, 2015).

ROS'un ilk sürümündeki çeşitli zorlukları ve sınırlamaları çözmek için ROS2 (Robot Operating System 2) sürümü geliştirilmiştir. Özellikle gerçek zamanlı sistemler (RTS); güvenlik, uyumluluk ve performans gibi alanlarda önemli iyileştirmeler getirmektedir. ROS2, geliştiricilere optimize tepki süreleri ile gerçek zamanlı uygulamalar oluşturma olanağı tanırken, gelişmiş performans, daha iyi güvenlik özellikleri, daha esnek iletişim protokolleri ve daha geniş platform desteği sunar (Open Robotics, 2023). Fakat ROS2'nin getirdiği bu avantajlar, kullanıcıların yeni paradigmalara ve araçlara adapte olmasını gerektiren bir öğrenme ve adaptasyon eğrisi ile birlikte gelir. Mevcut ROS paketleri ve araçları ROS2 ile doğrudan uyumlu olmayabilir ve geçiş süreci bazı zorlukları beraberinde getirebilir. Ayrıca, ROS2 nispeten yeni ve gelişmekte olan bir teknolojidir. Bu da, bazı özelliklerin ve araçların hala geliştirilme aşamasında olabileceği ve topluluk desteğinin ve dokümantasyonun ROS kadar kapsamlı olmayabileceği anlamına gelir. Bu durum, geliştiricilerin yeni teknolojiyi öğrenmeye ve mevcut sistemleri yeni platforma taşımaya yönelik yaklaşımlarını etkileyebilir.

## **2. Otonom Sistemlerde ROS Kullanımı**

ROS otonom sistemlerin geliştirilmesi konusunda bir devrim niteliğindedir. Otonom sistemler; çevresel veriyi toplayabilen, analiz edebilen ve bu verilere dayanarak bağımsız kararlar alabilen sistemlerdir. ROS'un bu sistemler üzerindeki etkisi, çeşitli araçlar, kütüphaneler ve özelliklerle açığa çıkmaktadır, bu da otonom sistemlerin daha etkili ve verimli bir şekilde geliştirilmesine olanak tanımaktadır.

ROS, çoklu sensör entegrasyonu sayesinde otonom sistemlere çevrelerini daha doğru bir şekilde algılama yeteneği kazandırmaktadır. Lazer tarama cihazları, kameralar ve ultrasonik sensörler, sistemlere çevresel bilgi toplama imkanı sunar. Bu, ROS'un gelişmiş veri işleme yetenekleriyle birleşerek, sistemlere çevrelerini daha iyi anlama ve bu bilgilere dayalı kararlar alma kapasitesi kazandırmaktadır. Ayrıca, ROS otonom sistemlere, güzergah planlama ve navigasyon konusunda da destek vermektedir, bu da sistemlerin çevrelerinde daha güvenli bir şekilde hareket etmelerini sağlamaktadır.

Modülerlik ve yeniden kullanılabilirlik açısından, ROS'un modüler yapısı, geliştiricilere otonom sistemlerin bileşenlerini kolayca değiştirme ve yeniden kullanma imkanı tanır. Bu özellik, otonom sistemlerin farklı görevlere ve uygulamalara kolayca adapte olabilmesine yardımcı olur. Simülasyon ortamları sayesinde, otonom sistemler gerçek dünyaya çıkmadan önce sanal bir ortamda test edilebilir, bu da geliştirme süreçlerini hızlandırabilir ve maliyetleri azaltabilir. Ayrıca, ROS'un çoklu platform desteği, farklı robotik platformlar ve işletim sistemleri üzerinde çalışabilme esnekliği sağlar, bu da farklı robot türlerinin aynı ROS çerçevesini kullanarak entegre edilebilmesine olanak tanır.

ROS'un açık kaynak kodlu olması, kullanıcıların mevcut kodları incelemelerine, değiştirmelerine ve yeni fonksiyonlar eklemelerine imkan verir. Bu, hızlı prototipleme yapılabilirliğini artırır ve geliştiricilere fikirlerini pratikte daha kolay test etme ve uygulama imkanı tanır. Topluluk ve kaynaklar açısından, ROS'un büyük ve aktif topluluğu, geliştiricilere destek, öğrenme materyalleri ve dokümantasyon sağlamaktadır.

## **2.1. Otonomi bileşenleri**

Otonom robotların etkili bir şekilde çalışabilmesi için bir dizi işlem basamaklarının uygulanması gerekir. Bu işlem basamakları otonom robotların etkili bir şekilde çalışabilmesi için bir araya getirilmeli ve entegre edilmelidir. Bu basamaklar, birbirleriyle sürekli olarak iletişim halindedir ve birlikte çalıştığında, robotun çevresini anlamasını, bu çevredeki engellere uyum sağlamasını, hedefine ulaşmasını ve belirli görevleri yerine getirmesini sağlar. Bu basamaklar aşağıda sırasıyla verilmiştir.

### **Algılama (Sensing) basamağı**

Otonom robotlar, çevreleri hakkında bilgi toplamak için bir dizi sensör kullanır. LIDAR, RADAR, kameralar, ultrasonik sensörler ve IMU'lar gibi sensörler, robotun çevresel bilgi toplamasını sağlar.

### **Haritalama (Mapping) basamağı**

Robotun çevresini anlaması için, sensör verileri kullanılarak bir harita oluşturulur. SLAM teknolojisi, robotun haritasını oluştururken aynı zamanda konumunu da belirlemesine olanak tanır.

### **Lokalizasyon (Localization) basamağı**

Robotun, kendisi ve çevresi hakkında bilgi edinmesi gereklidir. Lokalizasyon, robotun dünya üzerindeki kesin konumunu belirleme sürecidir. Bu, genellikle GPS, odometri ve çevresel özelliklerin eşleştirilmesiyle gerçekleştirilir.

### **Yol Planlama (Path Planning) basamağı**

Yol planlama, robotun bir başlangıç noktasından bir hedef noktasına en uygun yolu bulma sürecidir. Bu süreç, Dijkstra ve A\* gibi en kısa yolu arama/bulma algoritmalarını içerebilir. Genellikle haritalama ve lokalizasyon ile yakından ilişkilidir.

### **Navigasyon (Navigation) basamağı**

Yol planlama ile bulunan yol üzerinden robotun güvenli veya sağlıklı bir şekilde hareket etmesi navigasyon sürecidir. Navigasyon, çarpışma önleme ve çevre izleme gibi alt bileşenleri içerir. Robot, dinamik engelleri aşabilmesi için sürekli olarak sensör verilerini izlemeli ve yolunu güncellemelidir.

### **Kontrol (Control) basamağı**

Kontrol süreci, robotun hareketini yönetir. Bu; motorların hızını, yönlendirme açısını, frenleme gibi içerikleri kapsar. Kontrol sistemleri genellikle PID denetleyiciler veya daha gelişmiş kontrol teorisi yöntemleri kullanır.

### **Görev Yönetimi (Task Management) basamağı**

Robotlar genellikle çoklu görevleri yerine getirebilir. Görev yönetimi süreci, belirli bir görevi gerçekleştirecek kaynakların atanmasını, görevin durumunun izlenmesini ve görevler arası geçişleri yönetir.

## **3. SLAM: Eş zamanlı Yer Belirleme ve Haritalama**

SLAM (Simultaneous Localization and Mapping) algoritmaları, robotların veya otonom araçların bilinmeyen bir çevrede aynı anda konumlarını belirlemelerine ve çevrelerini haritalamalarına olanak tanır. Temel amaç, bir robotun, çevresi hakkında önceden bilgi sahibi olmadan, gezinirken haritalama yapabilmesi ve kendi konumunu bu harita üzerinde belirleyebilmesidir. SLAM, otonom robotların ve araçların çevrelerini daha iyi anlamalarını ve bu çevre içinde daha etkili bir şekilde hareket etmelerini sağlar.

SLAM algoritmalarının çalışma mantığı, genellikle robotun sahip olduğu sensör verilerini kullanmaktır. Bir robot; LIDAR, RADAR ve çeşitli kameralar gibi sensörler aracılığıyla çevresinden veri toplar. Bu veriler, robotun çevresindeki nesnelere ve özelliklerin bir haritasını oluşturmak için kullanılır. Aynı zamanda, robot bu harita üzerinde kendi konumunu ve yönelimini sürekli olarak tahmin eder. Algoritma, sensör verileri ve hareket verilerini bir araya getirerek, robotun konumunu ve haritanın güncel bir modelini elde etmek için bu verileri sürekli olarak günceller. Yani, SLAM, robotun konumunu ve çevresini aynı anda tahmin etme ve güncelleme sürecidir. Bu özelliği sayesinde, SLAM algoritmaları, otonom robotik sistemlerin temel taşlarından biri haline gelmiştir (Filipenko ve On, 2018).

ROS çerçevesi, SLAM teknolojisini uygulamak için bir dizi paket ve araç sunar. Gmapping, genellikle lazer tarama verilerini kullanarak grid map tabanlı SLAM çözümleri için tercih edilirken (Abdelrasoul, Saman ve Sebastian, 2017), Google'ın geliştirdiği Cartographer, 2D ve 3D haritalama kabiliyetine sahiptir ve IMU (Inertial Measurement Unit) sensör verileri ile lazer tarama verilerini entegre edebilir (Hess, Kohler, Rapp ve Andor, 2016). RTAB-Map ise, büyük ölçekli ve döngü kapatma (loop closure) kapasitesine odaklanmış, RGB-D, stereo ve monoküler kamera destekli bir pakettir (Labbé ve Michaud, 2019). HECTOR SLAM, özellikle uçan araçlar gibi hareketli platformlarda odometri bilgisi olmadan etkili 2D haritalama yapabilir (Park, Kim ve Sohn, 2020). ORB-SLAM, görüntü tabanlı çözümler için uygun, monoküler ve stereo kamera ile RGB-D sensörleri destekleyen bir sistemdir (Mur-Artal ve Tardos, 2016). Karto SLAM, 2D lazer tarama verileri üzerinden etkili haritalama gerçekleştirebilir (Anonim, 2019). Son olarak, SLAM Toolbox, çevrimiçi ve çevrimdışı haritalama, döngü kapatma ve özelleştirme imkanları sunar (Macenski ve Jambrecic, 2021). Tüm bu paketler, çeşitli sensör yapılandırmaları ve çevresel koşullar için çözüm sağlar, ve kullanıcıların projelerinin belirli gereksinimlerine bağlı olarak farklı seçenekler arasında tercih yapmalarına olanak tanır.

HECTOR SLAM bölümünde robotik topluluğu tarafından çokça kullanılan bu paketin örnek bir uygulaması gerçekleştirilmiştir. Bu uygulama, HECTOR SLAM pakedinin kendi oluşturduğumuz sistem üzerinde kullanımını açıklamaktadır.

HECTOR SLAM, özellikle hareketli platformlar ve uçan araçlar gibi odometri bilgisi olmayan sistemler için tasarlanmış bir SLAM (Simultaneous Localization and Mapping) metodudur. Çalışma mantığı, 2D lazer tarayıcı verilerini kullanarak robotun konumunu ve haritasını aynı anda oluşturmaktır. HECTOR SLAM, karmaşık ve detaylı ortamlarda bile hızlı ve etkili bir şekilde çalışabilir. Bu metodun avantajları arasında, düşük maliyetli platformlarda bile yüksek performanslı haritalama yeteneği, hassasiyet, ve hız bulunmaktadır. HECTOR SLAM, çeşitli uygulamalar için topluluk tarafından sıklıkla tercih edilmekte ve uygulanmaktadır, çünkü bu yöntem, odometriye bağımlı olmadan yüksek kaliteli 2D haritalar üretebilir. Ayrıca, topluluk tarafından geliştirilen çeşitli güncellemeler ve iyileştirmeler ile HECTOR SLAM, geniş bir kullanım yelpazesi ve çeşitli robotik projeler için uyumluluk sunmaktadır. Paketin kullanımı için gerekli işlem adımları:

### **A1. ROS kurulumu**

Eğer sisteminizde ROS kurulu değilse, öncelikle ROS'u kurulması gerekmektedir. ROS'un kurulum talimatları için ROS'un resmi web sitesi (Anonim, 2020) ziyaret edilmelidir.

### **A2. Çalışma alanının oluşturulması**

ROS paketleri geliştirmek ve ROS ile çalışmak için, catkin çalışma alanını (workspace) oluşturması gerekir. Bu çalışma alanını oluşturmak için takip edilmesi gereken adımlar:

```
mkdir -p ~/catkin_ws/src
```

```
cd ~/catkin_ws/
```

```
catkin_make
```

```
echo "source ~/catkin_ws/devel/setup.bash" >> ~/.bashrc
```

```
source ~/.bashrc
```

### **A3. HECTOR SLAM paketinin kurulumu**

ROS'un kurulumu tamamlandıktan sonra, HECTOR SLAM paketinin indirilip kurulması gerekmektedir. Bu işlem aşağıdaki gibi gerçekleştirilir:

```
cd ~/catkin_ws/src
```

```
git clone https://github.com/tu-darmstadt-ros-pkg/hector\_slam.git
```

```
cd ~/catkin_ws
```

```
catkin_make
```

Bu işlemlerle paket kopyalanmış ve derlenmiş olacaktır.

#### **A4. Lazer tarayıcı sürücülerinin kurulması**

Projemizde SLAMTEC RPLidar A2M8 lidar sensörü kullanılmıştır (Anonim, 2023b). Lidarın kullanımı için

```
cd ~/catkin_ws/src
```

```
git clone https://github.com/Slamtec/rplidar\_ros.git
```

```
cd ~/catkin_ws
```

```
catkin_make
```

işlemleri ile RPLidar paketi kurulup derlenecektir.

RPLidar sensörlerinin çalışması için bağlandığı porta izin verilmesi gerekmektedir. Bunun için

ls /dev/tty\* kodu ile port bilgisi kontrol edilir.

/dev/ttyUSB0 portuna

sudo chmod 777 /dev/ttyUSB0 kodu ile izin verilir ve sonrasında paketin çalıştırılması için launch dosyası çalıştırılır.

```
launch>
```

```
<node name="rplidarNode"      pkg="rplidar_ros"
type="rplidarNode" output="screen">
```

```
<param name="serial_port"    type="string"
value="/dev/ttyUSB0"/>
```

```
<param name="serial_baudrate" type="int" value="115200"/><!--
A1/A2 -->
```

```

<param name="frame_id"      type="string" value="laser_link"/>
<param name="inverted"      type="bool"  value="false"/>
<param name="angle_compensate" type="bool"  value="true"/>
<param name="motor_pwm" value="100"/>
</node>

```

Launch içerisinde port bilgisi ve lidarın robot üzerinde konumun bilgilerini taşıyan frame\_id parametreleri düzenlenmiştir.

```

<node name="rplidarNodeClient" pkg="rplidar_ros"
type="rplidarNodeClient" output="screen">
</node>

```

rplidarNodeClient düğümü ile lidarın okuduğu anlık bilginin terminale basılması sağlanır.

```

<node      pkg="tf"      type="static_transform_publisher"
name="laser_link_to_base_link" args="0 0.13 0.05 0 0 0 base_link
laser_link 100"/>

```

tf düğümü ile base\_link çerçevesinden laser\_link çerçevesine sabit bir dönüşüm yayınlanır. laser\_link çerçevesi base\_link çerçevesine göre args: x, y, z, roll, pitch, yaw translasyon ve rotasyon bilgileri metre cinsinden yerleştirilir. Son değer 100 ise, dönüşümün yayınlanma frekansını belirtir ve Hz cinsinden ifade edilir. Yani, bu durumda dönüşüm saniyede 100 defa yayınlanacaktır.

```

</launch>

```

RPLidar başlatma işleminden sonra HECTOR SLAM paketi kurularak (Anonim, 2022) launch dosyası düzenlenir ve çalıştırılır.

```

<?xml version="1.0"?>
<launch>
  <!--<arg      name="tf_map_scanmatch_transform_frame_name"
default="scanmatcher_frame"/>-->

```

Odometri bilgisi için kullanılan eşleştirme çerçevesinin ismi belirlenir. `pub_map_scanmatch_transform` parametresi ile bu çerçeveye ait dönüşümlerin yayınlanıp yayınlanmayacağı belirlenir.

```
<arg name="base_frame" default="base_link"/>
<arg name="odom_frame" default="odom"/>
```

Çerçeve isimleri belirlenir.

```
<arg name="pub_map_odom_transform" default="true"/>
```

Harita odometri dönüşümünün yayınlanıp yayınlanmayacağı belirlenir.

```
<arg name="scan_subscriber_queue_size" default="50"/>
```

Abone olunan Lidar konusu için mesaj kuyruğunun boyutu belirlenir.

```
<arg name="scan_topic" default="scan"/>
```

Lidar taramalarının alınacağı konu (topic) ismi belirtilir.

```
<arg name="map_size" default="2048"/>
```

Hector SLAM paketi için haritanın boyutunu belirtir. Buradaki 2048 değeri, haritanın boyutunu ızgaralarla (cells) ifade eder. Yani, bu örnekte harita, 2048 x 2048 hücreden (cell) oluşur.

Hector SLAM'de her bir hücre, belirli bir gerçek dünya alanını temsil eder ve bu alan `map_resolution` parametresi ile belirlenir. Örneğin, `<param name="map_resolution" value="0.050"/>` ifadesi, her bir hücrenin 0.05 metre x 0.05 metre (5 cm x 5 cm) boyutlarında bir alanı temsil ettiğini belirtir.

Bu durumda, toplam harita boyutu şöyle hesaplanabilir:

Toplam Harita Boyutu = hücre sayısı × her hücredeki gerçek alanı,

Toplam Harita Boyutu = 2048 hücre × 0.05 metre/hücre = 102.4 metre

Bu örnekte, toplam harita boyutu 102.4 metre x 102.4 metre olur.

```
<node pkg="hector_mapping" type="hector_mapping"
name="hector_mapping" output="screen">
```

HECTOR Mapping düğümü başlatılır.

```
<!-- Frame names -->
```

```
<param name="map_frame" value="map" />
```

```
<param name="base_frame" value="$(arg base_frame)" />
```



```

<param name="odom_frame" value="\$(arg odom_frame)" />
<!-- Tf use -->
<param name="use_tf_scan_transformation" value="true"/>
<param name="pub_map_scanmatch_transform" value="false"/>
<param name="use_tf_pose_start_estimate" value="false"/>
<param name="pub_map_odom_transform" value="\$(arg
pub_map_odom_transform)"/>
  <!-- Map size / start point -->
<param name="map_resolution" value="0.050"/>
<param name="map_size" value="\$(arg map_size)"/>
<param name="map_start_x" value="0.5"/>
<param name="map_start_y" value="0.5" />
<param name="map_multi_res_levels" value="2" />
  <!-- Map update parameters -->
<param name="update_factor_free" value="0.4"/>
<param name="update_factor_occupied" value="0.9" />
<param name="map_update_distance_thresh" value="0.4"/>
<param name="map_update_angle_thresh" value="0.06" />
<param name="laser_z_min_value" value = "-1.0" />
<param name="laser_z_max_value" value = "1.0" />
<param name="laser_max_dist " value= "15"/>

<!-- Advertising config -->
<param name="advertise_map_service" value="true"/>
  <param name="scan_subscriber_queue_size" value="\$(arg
scan_subscriber_queue_size)"/>
<param name="scan_topic" value="\$(arg scan_topic)"/>
  <!-- Debug parameters -->
<!--
  <param name="output_timing" value="false"/>
  <param name="pub_drawings" value="true"/>
  <param name="pub_debug_output" value="true"/>

```

```

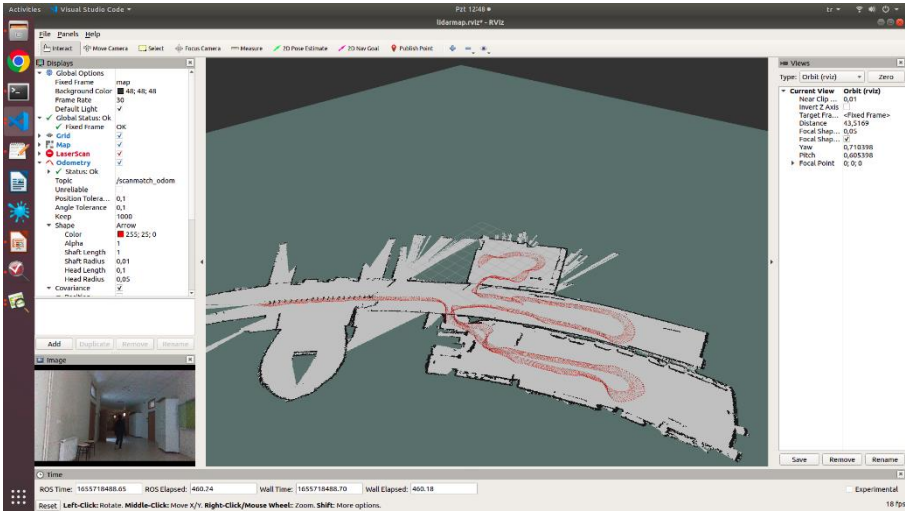
-->
<!--<param    name="tf_map_scanmatch_transform_frame_name"
value="$$(arg tf_map_scanmatch_transform_frame_name)" />-->
</node>
<!--<node    pkg="tf"        type="static_transform_publisher"
name="odom_to_map" args="0 0 0 0 0 0 map odom 10"/>
<node    pkg="tf"        type="static_transform_publisher"
name="base_link_to_odom" args="0 0 0 0 0 odom base_link 10"/>-->
-->
</launch>

```

Launch dosyası `hector_map.launch` olarak kaydedilir ve launch dosyası RPLidar çalıştırıldıktan sonra HECTOR launch dosyası çalıştırılır.

```
roslaunch hector_mapping hector_map.launch
```

Paketler çalıştırıldıktan sonra bir başka terminalde `rviz` çalıştırılır (Open Robotics, 2018). Harita odometri ve lazer taramaları eklenerek gerçek zamanlı olarak kontroller sağlanabilir.




Şekil 2. Rviz üzerinde haritanın oluşturulması ve odometri bilgisi

Hector Mapping paketinde harita oluşturduktan sonra, haritayı kaydetmek için `map_saver` node'u kullanılır. Bu node, `map_server` paketinin

bir parçasıdır ve oluşturulan haritayı bir PGM dosyası (Portable Graymap Format) olarak kaydeder.

```
roslun map_server map_saver -f~/home/catkin_ws/map
```



Şekil 3. Mapserver vasıtasıyla kaydedilen haritalar

Harita kaydedildikten sonra, belirtilen dizine gidilir ve haritanın doğru bir şekilde kaydedilip kaydedilmediğini kontrol edilir. Harita, .pgm ve .yaml formatlarında kaydedilecektir. .pgm dosyası haritanın görsel temsidir ve .yaml dosyası harita metadata'sını içerir.

## Kaynakça

- Abdelrasoul, Y., Saman, A. B. S. H. ve Sebastian, P. (2017). A quantitative study of tuning ROS gmapping parameters and their effect on performing indoor 2D SLAM. *2nd IEEE International Symposium on Robotics and Manufacturing Automation* içinde . Institute of Electrical and Electronics Engineers Inc. doi:10.1109/ROMA.2016.7847825
- Anonim. (2019). slam\_karto - ROS Wiki. 4 Ekim 2023 tarihinde [http://wiki.ros.org/slam\\_karto](http://wiki.ros.org/slam_karto) adresinden erişildi.
- Anonim. (2020). ROS/Installation - ROS Wiki. 4 Ekim 2023 tarihinde <http://wiki.ros.org/ROS/Installation> adresinden erişildi.
- Anonim. (2022). GitHub - tu-darmstadt-ros-pkg/hector\_slam: hector\_slam contains ROS packages related to performing SLAM in unstructured environments like those encountered in the Urban Search and Rescue (USAR) scenarios of the RoboCup Rescue competition. 5 Ekim 2023 tarihinde [https://github.com/tu-darmstadt-ros-pkg/hector\\_slam](https://github.com/tu-darmstadt-ros-pkg/hector_slam) adresinden erişildi.
- Anonim. (2023a). Questions - ROS Answers: Open Source Q&A Forum. 3 Ekim 2023 tarihinde <https://answers.ros.org/questions/> adresinden erişildi.
- Anonim. (2023b). GitHub - Slamtec/rplidar\_ros. 5 Ekim 2023 tarihinde [https://github.com/Slamtec/rplidar\\_ros](https://github.com/Slamtec/rplidar_ros) adresinden erişildi.
- Efe, E., Özcan, M. ve Haklı, H. (2021). Building and Cost Analysis of an Industrial Automation System using Industrial Robots and PLC Integration. *European Journal of Science and Technology*, 1–10. doi:10.31590/ejosat.972290
- Fernandez, E., Crespo, L., Mahtani, A. ve Martinez, A. (2015). *Learning ROS for robotics programming*. Packt Publishing. [https://www.google.com/books?hl=tr&lr=&id=n11CgAAQBAJ&oi=fnd&pg=PP1&dq=Fernandez,+E.,+Crespo,+L.+S.,+Mahtani,+A.,+%26+Martinez,+A.+%282015%29.+Learning+ROS+for+robotics+programming.+Packt+Publishing+Ltd.%5D.&ots=zYz\\_y1kVBP&sig=er\\_Yi3Dxm8pk3mlqBbaOMa-vCt8](https://www.google.com/books?hl=tr&lr=&id=n11CgAAQBAJ&oi=fnd&pg=PP1&dq=Fernandez,+E.,+Crespo,+L.+S.,+Mahtani,+A.,+%26+Martinez,+A.+%282015%29.+Learning+ROS+for+robotics+programming.+Packt+Publishing+Ltd.%5D.&ots=zYz_y1kVBP&sig=er_Yi3Dxm8pk3mlqBbaOMa-vCt8) adresinden erişildi.
- Filipenko, M. ve On, I. A. (2018). Comparison of various slam systems for mobile robot in an indoor environment. *International Conference on*

- Intelligent Systems (IS)*.  
<https://ieeexplore.ieee.org/abstract/document/8710464/> adresinden erişildi.
- Hess, W., Kohler, D., Rapp, H. ve Andor, D. (2016). Real-Time Loop Closure in 2D LIDAR SLAM. *IEEE international conference on robotics and automation (ICRA)* içinde .
- Joseph, L. (2017). *ROS robotics projects : build a variety of awesome robots that can see, sense, move, and do a lot more using the powerful Robot Operating System*. Packt Publishing.  
[https://books.google.com/books/about/Mastering\\_ROS\\_for\\_Robotics\\_Programming.html?hl=tr&id=MulODwAAQBAJ](https://books.google.com/books/about/Mastering_ROS_for_Robotics_Programming.html?hl=tr&id=MulODwAAQBAJ) adresinden erişildi.
- Labbé, M. ve Michaud, F. (2019). RTAB-Map as an open-source lidar and visual simultaneous localization and mapping library for large-scale and long-term online operation. *Journal of Field Robotics*, 36(2), 416–446. doi:10.1002/ROB.21831
- Macenski, S. ve Jambrecic, I. (2021). SLAM Toolbox: SLAM for the dynamic world. *Journal of Open Source Software*, 6(61), 2783. doi:10.21105/JOSS.02783
- Mur-Artal, R. ve Tardos, J. D. (2016). ORB-SLAM2: an Open-Source SLAM System for Monocular, Stereo and RGB-D Cameras. *IEEE Transactions on Robotics*, 33(5), 1255–1262. doi:10.1109/TRO.2017.2705103
- Open Robotics. (2018). rviz - ROS Wiki. 5 Ekim 2023 tarihinde <http://wiki.ros.org/rviz> adresinden erişildi.
- Open Robotics. (2022). Documentation - ROS Wiki. 3 Ekim 2023 tarihinde <https://wiki.ros.org/Documentation> adresinden erişildi.
- Open Robotics. (2023). ROS 2 Documentation: Rolling documentation. 3 Ekim 2023 tarihinde <https://docs.ros.org/en/rolling/index.html> adresinden erişildi.
- Park, K., Kim, S. ve Sohn, K. (2020). High-Precision Depth Estimation Using Uncalibrated LiDAR and Stereo Fusion. *IEEE Transactions on Intelligent Transportation Systems*, 21(1), 321–335. doi:10.1109/TITS.2019.2891788
- Quigley, M., Gerkey, B., Conley, K., Faust, J., Foote, T., Leibs, J., ... Ng, A. (2009). ROS: an open-source Robot Operating System. *ICRA workshop on open source software* içinde . <http://lars.mec.ua.pt/public/LAR>

Projects/BinPicking/2016\_RodrigoSalgueiro/LIB/ROS/icraoss09-ROS.pdf adresinden erişildi.



## **BÖLÜM 5**

### **TARIMSAL UYGULAMALARDA DERİN ÖĞRENME**

<sup>1</sup>Dr. Erhan KAHYA

<sup>2</sup>Dr. Fatma Funda ÖZDÜVEN

DOI: <https://dx.doi.org/10.5281/zenodo.10396188>

---

<sup>1</sup> Tekirdağ Namık Kemal Üniversitesi, Elektronik ve Otomasyon Bölümü, Kontrol Sistemleri Programı, Tekirdağ, Türkiye,  
ORCID:0000-0001-7768-9190 , ekahya@nku.edu.tr

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






## **Giriş**

Makine öğrenmesinin bir alt alanı olan derin öğrenme, verilerden temsilleri otomatik olarak öğrenme yeteneği nedeniyle son yıllarda büyük ilgi görmüştür. Derin öğrenme yöntemleri, birden fazla soyutlama seviyesine sahip veri temsillerini otomatik olarak öğrenme yetenekleri nedeniyle büyük ilgi gören makine öğrenimi tekniklerinin bir alt kümesidir. Bu yaklaşım bilgisayarla görme, doğal dil işleme ve tıbbi görüntüleme gibi çeşitli alanlarda kayda değer bir başarı göstermiştir. Derin öğrenme algoritmaları ve mimarileri sürekli olarak geliştirilerek yapay zeka alanında hızlı bir ilerleme kaydedilmiştir (LeCun ve ark., 2015). Bu ilerlemeler, tıbbi görüntü analizi gibi görevlere uygulandığı tıbbi görüntüleme teknolojilerinde hızla yaygınlaşmıştır. Derin öğrenmenin tıbbi görüntülemedeki potansiyeli Google, Facebook ve Microsoft gibi büyük şirketlerin ilgisini çekmiştir (Lee ve ark., 2017). Derin öğrenmenin geliştirilmesi ve uygulanması, derin öğrenme araştırmalarını ve uygulamalarını kolaylaştırmada önemli bir rol oynayan Keras, PyTorch, TensorFlow ve Microsoft Cognitive Toolkit gibi çeşitli yazılım araçlarının ortaya çıkmasına da yol açmıştır. Bu araçlar, derin yapıların optimize edilmesindeki zorlukların azaltılmasına katkıda bulunmuş ve böylece araştırmacıların derin öğrenmeye olan ilgisini ve odağını artırmıştır (Meshram, 2022). Derin öğrenme yöntemlerinin sağlık sistemleri, ilaç keşfi, biyotıp ve tıbbi görüntü analizinde yaygın olarak kullanıldığını belirtmek gerekir (Qureshi ve ark., 2021). Sadece tıbbi alanda değil çevre yönetimi, tarım ve ticari faaliyetler gibi çeşitli diğer alanlarda da derin öğrenmenin kullanıldığını görmekteyiz. Derin öğrenmenin bu farklı alanlarda kullanımı, çok yönlülüğünü ve karmaşık gerçek dünya sorunlarını ele alma potansiyelini yansıtmaktadır. Ayrıca, derin öğrenme, yüksek teşhis doğruluğu ve düşük hata oranları elde ederek arıza teşhisinde üstün performans göstermiştir (Jin ve ark., 2021). Derin öğrenme yöntemlerinin en önemli avantajlarından biri, manuel özellik mühendisliğine ihtiyaç duymadan orijinal verilerden karmaşık doğrusal olmayan ilişkileri ve temsili özellikleri otomatik olarak öğrenme yetenekleridir (Wei ve ark., 2020). Bu özellik, derin öğrenmeyi özellikle görüntü segmentasyonu, nesne çıkarımı ve multimedya verilerinde kenar tespiti gibi görevler için uygun hale getirmektedir (Li ve ark., 2023). Bununla birlikte, derin öğrenme yöntemlerinin veriye aç olduğunu ve yüksek model performansı elde etmek için büyük miktarda açıklanmalı eğitim verisi gerektirdiğini kabul etmek önemlidir (Shrestha ve ark.,

2022). Derin öğrenmenin umut verici beklentilerine rağmen, ele alınması gereken zorluklar vardır. Bu zorluklardan biri, etkili kullanım için hem bilgisayar bilimi hem de biyoloji alanında uzmanlık gerektiren model mimarilerini seçmek için standart yöntemlerin olmamasıdır. Ayrıca, klinik analizde derin öğrenmenin uygulanması, gelecekteki araştırma yönlerinde hassas tıbbın önemini vurgulayarak dikkatle değerlendirilmesi gereken zorluklar ortaya çıkarmaktadır (Ravi ve ark, 2017).

Derin öğrenme, bir dizi çeşitli model ve mimari içerir. Derin öğrenmede kullanılan bazı önemli modeller:


**Yapay Sinir Ağları (Artificial Neural Network-ANN):** Yapay sinir ağları, insan beyninin çalışma şeklini taklit eden bir yapısı olan matematiksel modellerdir. Genellikle giriş katmanı, gizli katmanlar ve çıkış katmanından oluşurlar. Şekil 1’de blok şeması gösterilmiştir.



Şekil 1. Yapay Sinir Ağları (Artificial Neural Network-ANN) blok şeması(Anonim 1)

**Evrişimli Sinir Ağları (Convolutional Neural Networks-CNN):** Özellikle görüntü işleme görevlerinde kullanılan CNN'ler, evrişim katmanları ile özellik haritalarını öğrenme yeteneğine sahiptir. Bu sayede özellikle resim sınıflandırma gibi görevlerde etkilidirler. Şekil 2’de blok şeması gösterilmiştir.


## CNN Mimarisi



Şekil 2. Evrişimli Sinir Ağları(Convolutional Neural Networks-CNN) blok şeması(Anonim 2)

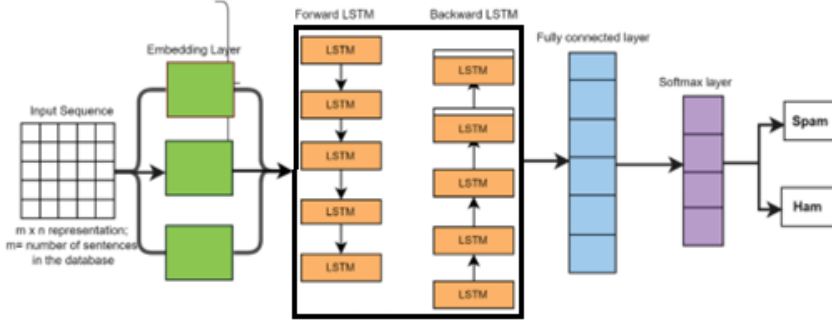
### Rekurrent Sinir Ağları (Rekurrant Neural Network-RNN):

RNN'ler, sıralı veri üzerinde çalışan modellerdir. Bu, zaman serisi verileri veya doğal dil işleme görevleri gibi sıralı veri problemleri için uygundur. Ancak, uzun vadeli bağımlılık sorunlarına duyarlı olabilirler. Şekil 3'de blok şeması gösterilmiştir.



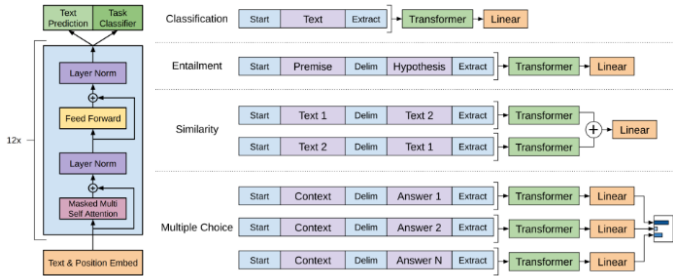
Şekil 3. Rekurrent Sinir Ağları(Rekurrant Neural Network-RNN) blok şeması(Anonim 3)

**Uzun Kısa Vadeli Hafıza Ağları (Long-Short-Term Memory-LSTM):** LSTM'ler, RNN'lerin uzun vadeli bağımlılık sorunlarını çözmek için geliştirilmiş bir türüdür. Bellek hücreleri aracılığıyla uzun vadeli bağımlılıkları daha etkili bir şekilde ele alabilirler. Şekil 4'de blok şeması gösterilmiştir.



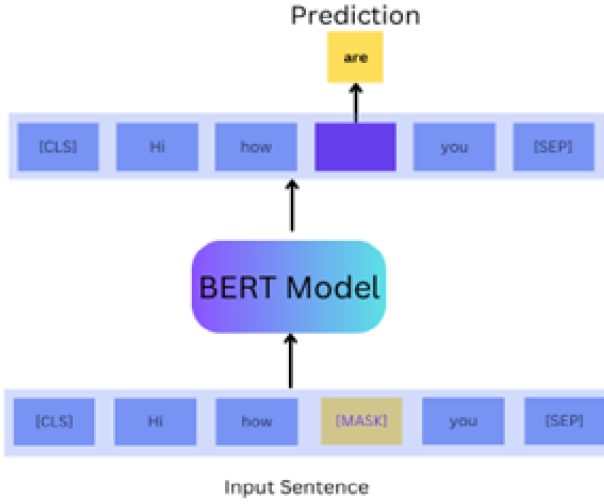
Şekil 4. Uzun Kısa Vadeli Hafıza Ağları (Long-Short-Term Memory-LSTM) (Anonim 4)

**GPT (Generative Pre-Trained Transformer):** Büyük dil modelleri olarak bilinen GPT gibi modeller, genellikle doğal dil işleme görevlerinde kullanılır. Transformer mimarisi, büyük veri setlerinde önceden eğitildikten sonra çeşitli görevlerde ince ayar yapılabilir. Şekil 5'de blok şeması gösterilmiştir.



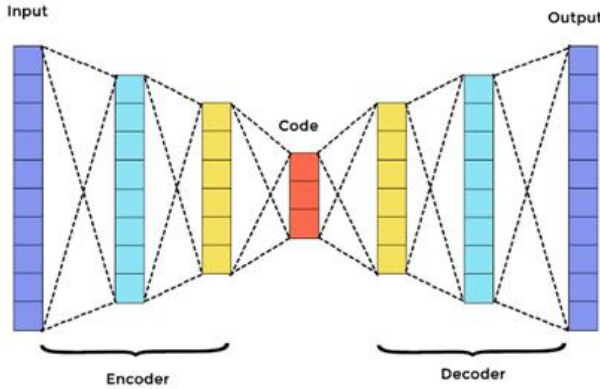
Şekil 5. GPT (Generative Pre-Trained Transformer) blok şeması (Anonim 5)

**BERT (Bidirectional Encoder Representations from Transformers):** BERT, doğal dil işleme görevlerinde kullanılan bir başka büyük dil modelidir. Transformer tabanlı bir mimari kullanır ve özellikle metin anlama görevlerinde başarılıdır. Şekil 6'de blok şeması gösterilmiştir.



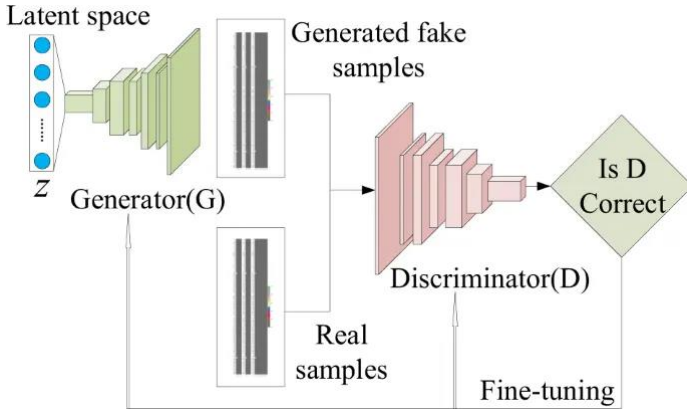
Şekil 6. BERT(Bidirectional Encoder Representations from Transformers) blok şeması(Anonim 6)

**Autoencoders:** Bu modeller, veri setinin temsilini öğrenmeye çalışan unsupervised öğrenme algoritmalarıdır. Encoder ve decoder olmak üzere iki ana bileşeni içerirler ve genellikle veri sıkıştırma veya özellik mühendisliği gibi görevlerde kullanılır. Şekil 7’de blok şeması gösterilmiştir.



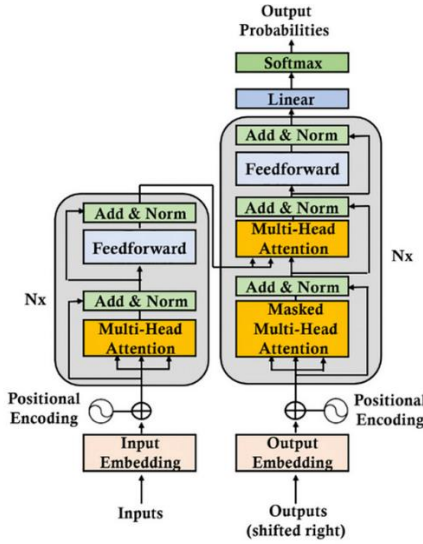
Şekil 7. Autoencoders blok şeması(Anonim 7)

**Generative Adversarial Network(GANs):** Yaratıcı içerik üretimi için kullanılır. Resimler, müzikler,metinler gibi çeşitli alanlarda kullanılmaktadır. Şekil 8’de blok şeması gösterilmiştir.




Şekil 8. Generative Adversarial Network(GANs) blok şeması(Anonim 8)

**Transformer Models:** Doğal dil işleme (NLP) alanında büyük bir etki yaratmıştır. Çeviri,metin sınıflandırma,dil modelleme gibi alanlarda kullanılmaktadır. Şekil 9’da blok şeması gösterilmiştir.




Şekil 9. Transformer Models blok şeması(Anonim 9)

**R-CNN (Bölge Tabanlı Evrimsel Sınır Ağı):** Bilgisayarla görme ve derin öğrenme alanını önemli ölçüde geliştiren öncü bir nesne algılama çerçevesidir. Ross Girshick ve arkadaşları tarafından 2014 yılında tanıtılan R-CNN, derin öğrenme tekniklerini sürece entegre ederek nesne tespitinde bir atılımı temsil etmektedir. Şekil 10’da blok şeması gösterilmiştir.



Şekil 10. R-CNN (Bölge Tabanlı Evrişimsel Sinir Ağı) blok şeması(Anonim 10)

**Inception:** Bilgisayarla görme ve görüntü tanıma alanında önemli bir etkiye sahip olmuştur. Çok ölçekli özellikleri yakalama yeteneği, farklı uygulamalara uyarlanabilirliği ile birleştiğinde, onu bilgisayarla görme, yapay zeka ve ötesi alanlardaki araştırmacılar ve uygulayıcılar için değerli bir araç haline getirmektedir. Inception modelinin sürekli olarak geliştirilmesi ve uyarlanması, görüntü tanıma ve sınıflandırma alanında temel bir çerçeve olarak konumunu daha da sağlamlaştırmaktadır. Şekil 11 'de blok şeması gösterilmiştir.




Şekil 11. Inception blok şeması(Singh, T ve ark.,2020)

**YOLO (You Only Look Once) :** Bilgisayarla görme ve yapay zeka alanında büyük ilgi gören gerçek zamanlı bir nesne algılama sistemidir. YOLO,



görüntülerdeki veya video karelerindeki nesneleri olağanüstü hız ve doğrulukla tespit etme ve sınıflandırma becerisiyle bilinir. Şekil 12 'de blok şeması gösterilmiştir.



Şekil 12. YOLO (You Only Look Once) blok şeması (Anonim 11)

Derin öğrenme yöntemleri, verilerdeki karmaşık örüntüleri otomatik olarak öğrenmek ve temsil etmek için sinir ağlarından yararlanarak makinelerin öğrenilen bilgiye dayalı tahminler ve kararlar almasını sağlar. Bu özelliklerinden dolayı günümüzde birçok alanda uygulamalarını görmekteyiz. Tarımsal alanda kullanılmaya başlayan derin öğrenme uygulamalarını şu şekilde sıralayabiliriz:

### Hasat Sistemleri

Derin öğrenme tekniklerinin entegrasyonu, tarımsal uygulamalardan biri olan hasat sistemi teknolojilerinde önemli ilerlemeler sağlamaktadır. Mahsul tespiti, verim tahmini, meyve hasat robotları ve hassas tarım günümüzde pek çok uygulaması bulunmaktadır. Derin öğrenme, doğal ortamlarda bitki tanımlamaya uygulanarak biyoçeşitliliğin korunmasına ve akıllı ormancılık uygulamalarına katkıda bulunmaktadır (Sun ve ark.,2017). Ayrıca, çalışmalar, tanıma ve yerleştirme yöntemleri için derin öğrenmeden yararlanarak görme tabanlı meyve toplama robotlarının geliştirilmesine odaklanmaktadır. (Tang ve ark., 2020). Lin ve ark. (2022) derin öğrenme takviyeli bir muz hasat robotu için ters kinematik çözümü geliştirmiştir. Darwin ve ark. (2021) akıllı tarım uygulamaları için mahsul görüntülerinde çiçeklenme ve verimi tanımayla

yönelik derin öğrenme modellerini incelemişler ve sonucunda ürünün hasat olgunluğunu doğru tanımlamak adına yüksek oranda doğruluk elde etmişlerdir. Jun ve ark. (2021) derin öğrenme kullanarak hasat robotları geliştirmişlerdir. Son efektör manipülasyonu için 3B algılama ve derin öğrenmeyi kullanan bir domates hasat robotunu tasarlamışlardır. Elavarasan ve ark. (2020), hasat sistemlerini optimize etmek için mahsul verim tahmini için derin bir takviye öğrenme modeli geliştirmişlerdir (Ni ve ark., (2020). Yaban mersini meyvelerinin görüntü segmentasyonu ve özellik çıkarımı için derin öğrenmeyi kullanmışlardır. Dias ve ark.(2018) geliştirilmiş semantik segmentasyon ağı kullanılarak çok türlü meyve çiçeği tespiti sistemi yapmışlardır. Hu ve ark. (2019), domates hasat süreçlerinin otomatikleştirilmesinde derin öğrenmenin potansiyelini ortaya koyan Faster R-CNN ve sezgisel bulanık kümeyi birleştirerek bitkilerdeki tek olgun domateslerin otomatik olarak tespiti yapmışlardır. Ko ve ark.(2021), tarımsal ayıklama sistemlerinde domates olgunluğunun tespiti için evrişimli sinir ağlarının stokastik bir karar füzyonunu geliştirerek hasat edilen domateslerin verimli bir şekilde sınıflandırılması ve derecelendirilmesi potansiyelini ortaya koymuşlardır. Magalhães ve ark. (2021) bir seradaki domateslerin tespiti için Tek Atışlı Çoklu Kutu Dedektörü ve YOLO derin öğrenme modellerini değerlendirerek sera tabanlı domates hasadı uygulamalarında derin öğrenmenin potansiyelini vurgulamışlardır. Luna ve ark. (2019) eşikleme, makine öğrenimi ve derin öğrenme tekniklerini kullanarak domates meyvesinin boyut sınıflandırmasını araştırmışlardır. Derin öğrenmenin domates meyvesini boyut ve olgunluğa göre doğru bir şekilde sınıflandırma potansiyelini tespit etmişlerdir. Domates hasadında derin öğrenme yöntemlerinin kullanımı son araştırmalarda önemli bir ilgi görmüştür. Makine öğreniminin bir alt kümesi olan derin öğrenme, büyük miktarda heterojen veriyi özümleme ve karmaşık ve belirsiz olgular için güvenilir tahminler sağlama konusundaki çok yönlülüğünü kanıtlamıştır (Singh ve ark.,2018). Meyve tanıma ve lokalizasyonu alanında, derin öğrenme tabanlı algoritmaları, domates hasadı ve meyve tespiti bağlamında uygulanabilirliklerini gösteren ana yöntemlerden biri olarak incelenmişlerdir (Tang vd., 2020). Domateslerin olgunluk tespiti için derin öğrenme kullanılmış ve hasat için en uygun zamanın belirlenmesinde çok önemli bir faktör olan domates olgunluğunun değerlendirilmesini otomatikleştirme potansiyelini vurgulamışlardır (Mutha ve ark., 2021). Ayrıca, domates meyvelerinin tespiti

için YOLOv5 derin öğrenme modellerinin değerlendirilmesi, hasat robotu geliştirme için gerekli olan gerçek zamanlı görsel domates tespitinde derin öğrenmenin rolünü vurgulayarak mahsul verimi tahmini için önermişlerdir (Bini ve ark., 2022). Valdez (2020), hasat sonrası daha iyi işleme için derin öğrenme tabanlı nesne algılama kullanarak elma kusurlarının tespitine odaklanmış ve derin öğrenmenin hasat sonrası süreçleri ve kalite kontrolünü iyileştirme potansiyelini göstermiştir. Wu ve ark. (2012) meyve ve sebze hasat robotlarında sinir ağlarının uygulama araştırmasını yapmış ve robotik hasat için kamera kalibrasyonu, görüntü segmentasyonu, sınıflandırma ve engellerden kaçınmada derin öğrenmenin kullanımını göstermişlerdir. Yapılan çalışmalar, derin öğrenmenin tarımsal hasat uygulamalarında devrim yaratmadaki önemli etkisini ortaya koymaktadır. İleride tarım uygulamalarındaki gelişmelere katkıda bulunarak tarım teknolojisi alanında daha fazla yeniliğin önünü açacağı görülmektedir.

### **Yabancı ot ve Bitki Hastalıkları, Zararlıları Tespiti**

Derin öğrenme kullanılarak bitki hastalıklarının tespiti, bitkileri etkileyen hastalıkları doğru bir şekilde tanımlamak ve sınıflandırmak için gelişmiş hesaplama tekniklerinin uygulanmasını içeren bir yöntemdir. Bu amaçla derin öğrenme modellerinin kullanımını araştıran çeşitli çalışmalar yapılmaktadır. Yapılan çalışmalar derin öğrenmenin bitki hastalıklarını doğru bir şekilde tespit etme ve sınıflandırma potansiyelini toplu olarak vurgulamaktadır. Hastalıkların mahsul verimi ve genel tarımsal üretkenlik üzerindeki etkisini azaltmak için zamanında müdahalelere olanak sağlamaktadır. Derin öğrenme teknikleri bitki hastalıklarının tespitinde önemli bir rol oynamaktadır. Bazı çalışmalarda, mısır yapraklarındaki bazı hastalık belirtilerinin tespitinde olumlu sonuçlar vermiştir (Paliwal & Joshi, 2022). Bidve ve ark (2023) görüntü işleme ve derin öğrenme kullanarak yabancı ot tespit sistemi geliştirmişlerdir. Derin öğrenme modelleri ahududularda hastalık ve zararlı tespitinde etkili olmuş, ürün sağlığı yönetimini geliştirmek için donanım ve yazılımı etkili bir şekilde entegre etmişlerdir (Naranjo-Torres ve ark., 2021). Mahsul türleri arasında transfer öğrenimi, hassas tarımda mahsullerin yabancı otlara karşı semantik segmentasyonunu sağlayarak tarımsal otomasyonda derin öğrenmenin potansiyelini ortaya koymuşlardır (Bosilj ve ark., 2019). Derin öğrenme domates bitkisi hastalıklarının teşhisi için

kullanılmış ve domates bitkilerini etkileyen hastalıkları tanımlama ve yönetme potansiyelini vurgulamışlardır (Gerdan ve ark., 2022). Bitki tanımlama bağlamında, derin öğrenme modelleri doğal ortamlarda büyük ölçekli bitki sınıflandırması için tasarlanmış ve domates de dahil olmak üzere farklı bitki türlerini tanımlama ve ayırt etme potansiyellerini göstermişlerdir (Sun ve ark., 2017). Paliwal ve ark. (2022) mısır mahsullerinde yaprak hastalıklarının tespiti için derin öğrenme modellerine genel bir bakış sunmuşlardır. Mohanty ve ark. (2016), görüntü tabanlı bitki hastalığı tespiti için derin öğrenme kullanmanın fizibilitesini göstermişler ve dışarıda tutulan bir test setinde %99,35'lik bir doğruluk elde etmişlerdir. Benzer şekilde, Sladojević ve ark. (2016) derin evrişimli ağlar kullanarak yaprak görüntüsü sınıflandırmasına dayalı bir bitki hastalığı tanıma modeli geliştirmişlerdir. Çalışmalarında yaprak görüntülerine dayalı doğru hastalık tanıma için derin sinir ağlarından yararlanmışlardır. Jiang ve ark. (2019), evrişimli sinir ağlarına (CNN'ler) dayalı geliştirilmiş bir derin öğrenme yaklaşımı kullanarak elma yaprağı hastalıkları için gerçek zamanlı bir tespit sistemi kurmuşlardır. Geliştirdikleri modelle, elma hastalıklarında verimli ve gerçek zamanlı tespitini yapmışlardır. Roy ve ark. (2021), bilgisayarla görme ve derin öğrenmeye dayalı çok sınıflı bir bitki hastalığı tespit modeli geliştirmişler, yüksek ortalama hassasiyet (mAP) ve F1-skoru elde ederek yaklaşımlarının etkinliğini vurgulamışlardır. Fuentes ve ark. (2017) domates bitki hastalıklarının ve zararlılarının gerçek zamanlı tanınması için bir derin öğrenme tabanlı dedektör geliştirmişlerdir. Hassan ve ark. (2022) yeni bir CNN modeli kullanarak bitki hastalığı tanımlamada yüksek doğruluk elde etmişlerdir. Yao ve ark. (2021) mevcut derin ağların sınırlamalarını ele almak için şeftali hastalıklarının sınıflandırılmasında geliştirilmiş bir ağ olan L2MXception'ı önermişlerdir. Derin öğrenme teknikleri bitki hastalıkları, zararlıları ve yabancı ot tespiti için önemli bir potansiyel oluşturmaktadır. Bu gelişmeler, hastalık ve zararlı yönetimi uygulamalarında devrim yaratma, hastalıkların erken ve doğru bir şekilde tanımlanmasını sağlama ve nihayetinde sürdürülebilir tarım uygulamalarına ve gıda güvenliğine katkıda bulunma konusunda umut vaat etmektedir.

## **Tarımsal Ürün Sınıflandırma**

Hasat sırasında tarımsal ürün sınıflandırması, makine öğrenimi ve derin öğrenme tekniklerinin entegrasyonu ile önemli ilerlemeler kaydetmiştir. Bu

teknolojiler hasat edilen ürünlerin boyut, şekil, kalite ve olgunluk gibi özelliklerine göre sınıflandırılmasında kullanılmaktadır. Bilgisayarla görme yaklaşımları, yüksek çözünürlüklü görüntüler kullanarak bahçe bitkilerinin boyut ve şekil fenotiplerini karakterize etmek için kullanılmış ve ürünlerin önceden tanımlanmış kriterlere göre kutulara ve konteynerlere ayrılmasını sağlamıştır (Haque ve ark.,2021). Makine öğrenimi ve derin öğrenme tekniklerinin IoT teknolojisi ile entegrasyonu, tarımsal bilgilerin sınıflandırılması konusunda etkili ve doğru karar verilmesini kolaylaştırarak tarımsal üretim ve ekonomik kalkınma için bir odak noktasıdır (Gao, 2022). Tarımsal ürünlerin sınıflandırılmasında makine öğrenimi ve derin öğrenmenin uygulanması, uygun olmayan ürünleri farklı sınıflara ayırma yeteneğini göstererek hasat sonrası işleme ve kalite kontrolünün verimli olmasına katkıda bulunmuştur (Medojević ve ark., 2022). Hassas tarım çerçevesinde makine öğrenimi ve derin öğrenmenin kullanılması, mahsullerin sınıflandırılmasını, hastalık ve zararlı tahminini ve akıllı yabancı ot kontrolünü mümkün kılarak tarımsal yönetim ve karar alma süreçlerini geliştirmiştir (Zhang ve ark., 2021). Bu teknolojiler ayrıca tarımsal üretimin tahmin edilmesinde, mahsul veriminin öngörülmesinde, toprak ve su yönetiminde etkili olmuş ve sürdürülebilir tarım uygulamalarına katkıda bulunmuştur (Awe ve ark., 2022). Zheng ve ark.(2019) yaptıkları çalışmada, CropDeep veri kümesi temsili ek açıklamalar sağlamada etkili olduğunu tespit etmişler, böylece hassas tarımda derin öğrenme tabanlı sınıflandırma ve algılama için daha güçlü bir ölçütü vurgulamışlardır. Çeşitli meyve ve sebzeleri kapsayan bitki görüntülerinde çiçeklenme/verimin tanınması için derin öğrenme modelleri kullanılmış ve bu da mahsul sınıflandırmasında derin öğrenmenin çok yönlülüğünü göstermiştir (Darwin ve ark., 2021). Hassas tarımda derin öğrenmenin uygulanması, yabancı ot sınıflandırması, yapraklarda hastalık tespiti, verim tahmini ve İHA görüntü analizini kapsayarak, derin öğrenme tekniklerinin tarımsal ürün sınıflandırmasındaki geniş kapsamlı etkisini vurgulamaktadır (Preethi ve ark., 2021). Buna ek olarak, ürün verim tahmini için derin öğrenme modellerinin kullanımı önemli bir araştırma alanı olmuştur; YieldNet modeli, uzaktan algılama verilerine dayalı olarak eş zamanlı mısır ve soya fasulyesi verim tahminine olanak tanıyarak paydaşlara verim potansiyelini en üst düzeye çıkarmak için gerçek zamanlı karar verme yetenekleri sağlar (Khaki ve ark., 2020). Derin öğrenme ürün, gübre ve sulama tavsiyelerinde kullanabilinirken,

tarım verilerini modernize etme ve makine öğrenimi teknikleri aracılığıyla çiftçiler için erişilebilir hale getirme ihtiyacını vurgulamıştır (Ajmera ve ark., 2022). Makine öğrenimi ve derin öğrenme tekniklerinin entegrasyonu, hasat sırasında tarımsal ürün sınıflandırmasında devrim yaratarak tarımsal süreçlerde verimliliğin, doğruluğun ve karar alma süreçlerinin iyileştirilmesine yol açmıştır.

### **Hasat Verim Tahmini**

Tarımsal hasatta verim tahmini için derin öğrenmeyi uygulamak amacıyla, çeşitli çalışmalar derin öğrenme tekniklerinin bu alandaki etkinliğini göstermiştir. Derin öğrenme uygulamalarında, mahsul verimini tahmin etmek ve tarımsal zorlukları ele almak için CNN, LSTM, SNN ve RNN dahil olmak üzere çeşitli derin öğrenme modellerinin kullanılmaktadır. Derin öğrenme tabanlı semantik segmentasyon teknikleri kullanarak meyve verimi tahmininin üstün performansını vurgulamış ve gelişmiş verim tahmini uygulamaları için çalışmalar devam etmektedir (Maheswari ve ark., 2021). Tao ve ark. (2023), Gauss süreç regresyon modelinin verim tahmini ve su-azot yönetimi için uygunluğunu vurgulayarak tarımsal verim tahmininde makine öğrenimi modellerinin potansiyelini vurgulamışlardır. Bhimavarapu ve ark. (2023), yağış, rüzgar, sıcaklık ve güneş radyasyonu gibi çeşitli hava durumu parametrelerini dikkate alarak ürün verimini tahmin etmek için derin öğrenme algoritmalarının, özellikle de Uzun Kısa Süreli Bellek (LSTM) algoritmasının kullanımını tespit etmişlerdir. Karuna ve ark. (2021) ve Kim ve ark. (2021) tarafından gösterildiği gibi ürün verimi tahmini için Evrimsel Sinir Ağı (CNN) ve Spiking Sinir Ağı (SNN) modelleri de dahil olmak üzere derin öğrenme tabanlı modelleri kullanmışlardır. Bu çalışmalar, derin öğrenme modellerinin tarımda, özellikle de verim tahmini bağlamında uygulanabilirliğini ve etkinliğini göstermiştir. Kamilaris ve ark. (2018) tarımda derin öğrenmenin kullanımı üzerine kapsamlı bir araştırma yapmış ve derin öğrenmenin verim tahmini ve diğer tarımsal uygulamalar için potansiyelini vurgulamışlardır. Umar ve ark. (2022), tarımda makine öğrenimi ve yeni ortaya çıkan derin öğrenme teknolojilerinin uygulanmasına genel bir bakış sunarak, bunların tarım ekosisteminde benimsenmesiyle ilgili fırsatları ve zorlukları tespit etmişlerdir. Guillén-Navarro ve arkadaşları (2020), tarımdaki düşük sıcaklıkları tahmin etmek için bir derin öğrenme modeli, özellikle de Uzun Kısa

Sürekli Bellek (LSTM) sinir ağı önermiş ve tarımsal tahminlerde derin öğrenme tekniklerinin çok yönlülüğünü göstermişlerdir. Rashid ve ark. (2021), optimum mahsul verimi tahmini için makine öğrenimi ve sinyal işleme tekniklerini birleştiren algılama teknolojilerinin ve hibrit sistemlerin kullanılmasını önermiştir. Karuna ve ark. (2021) mısır verimini değerlendirmek için Evrimsel Sinir Ağları (CNN), Spiking Sinir Ağları (SNN) ve Tekrarlayan Sinir Ağları (RNN) kullanarak tarımda verim tahmini için kullanılan derin öğrenme modellerinin çeşitliliğini vurgulamışlardır.

### **Akıllı sulama sistemleri**

Akıllı sulama sistemleri, su kullanımını verimli hale getirmek ve tasarruf etmek, mahsul verimini artırmak ve çevresel etkiyi en aza indirmek için gelişmiş teknolojilerden yararlanır. Yapay zekanın bir alt kümesi olan derin öğrenme, tarımda akıllı sulama sistemlerinin verimliliğini ve etkinliğini artırmak için yenilikçi çözümler sunmaktadır. Çeşitli çalışmalar, akıllı sulama sistemlerinde derin öğrenmenin potansiyelini ortaya koymaktadır. Zhang ve ark.(2018) Landsat görüntülerinden center pivot sulama sistemlerinin otomatik olarak tanımlanması için derin öğrenme tabanlı bir model geliştirerek derin öğrenmenin sulama altyapısı tanımadaki potansiyelini ortaya koymuşlardır. Amin ve ark. (2022) evrimsel algoritma güdümlü derin öğrenmeye dayalı IoT özellikli bir akıllı sulama sistemi önermiş ve derin öğrenmenin sulama uygulamalarını optimize etmedeki rolünü vurgulamışlardır. Kamarudin ve ark. (2021) bitki su stresi değerlendirmesinde derin öğrenme sensör füzyonu üzerine kapsamlı bir inceleme yapmışlar ve akıllı sulama sistemlerinde bitki su durumunu izleme ve yönetmede derin öğrenmenin potansiyelini göstermişlerdir. Akıllı sulama sistemlerinde derin öğrenmenin uygulanması; veri entegrasyonu, modelin yorumlanabilirliği ve gerçek zamanlı karar verme gibi zorlukları beraberinde getirmektedir. Ancak araştırmacılar bu zorlukların üstesinden gelme konusunda önemli adımlar atmıştır. Zhang ve ark. (2021) tarımsal yönetimde uygulanan makine öğrenimi yaklaşımlarının bir bilgi haritasını çıkararak akıllı tarımda derin öğrenme uygulamalarının mevcut durumu ve gelecekteki yönelimleri hakkında bilgi vermişlerdir. Alibabaei ve ark. (2022) sulama verimliliği çalışmalarında derin öğrenmeyi Q-ağıyla karşılaştırarak akıllı sulama parametrelerini ortaya koymuşlardır. Akıllı sulama sistemleri için derin öğrenme alanı, açıklanabilir yapay zeka modellerinin geliştirilmesine,

gerçek zamanlı sulama kontrolü için uç hesaplamaya ve hassas sulama için büyük veri analitiğinin entegrasyonuna odaklanan devam eden araştırmalarla gelişmeye devam etmektedir. Ryo ve ark. (2022), derin öğrenme tabanlı akıllı sulama sistemlerinin geliştirilmesi ve uygulanmasında ekolojik hususlar ve üreticinin katılımında ihtiyaç olduğu belirtilmiştir. Derin öğrenmenin Nesnelerin İnterneti (IoT) teknolojileriyle birlikte uygulanması, akıllı toprak ve hava koşullarının izlenmesini kolaylaştırarak akıllı şehirlerde hassas tarımın ilerlemesine katkıda bulunmaktadır (Qazi ve ark., 2022). Derin öğrenme modellerinin tarımda kullanılması, bu modeller tarafından üretilen büyük ağırlık matrislerini yönetmek için veri sıkıştırma tekniklerinin dikkate alınmasını gerektirmektedir (Fountsop ve ark., 2020). Diğer taraftan derin öğrenmenin sensör destekli sulama yönetimi ile entegrasyonu, akıllı sulama sistemlerini optimize etmek için hibrit derin inanca ağlarının geliştirilmesini gerektirmektedir (Yonbawi ve ark., 2023). Derin öğrenme yöntemlerinin tarımsal sulamaya entegrasyonu, su yönetimini geliştirmek, sulama uygulamalarını optimize etmek ve genel tarımsal sürdürülebilirliği iyileştirmek için önemli bir potansiyele sahiptir. Bununla birlikte, veri yönetimi ve model optimizasyonu gibi ilgili zorlukların ele alınması, tarımsal sulamada derin öğrenmenin başarılı bir şekilde uygulanması için çok önemlidir.

## **Sonuç**

Derin öğrenme, tarımsal uygulamalarda çeşitli alanlarda önemli bir etki yaratmaktadır. Hasat sistemleri, bitki hastalıklarının tespiti, tarımsal ürün sınıflandırması, hasat verim tahmini ve akıllı sulama sistemleri gibi alanlarda derin öğrenme tekniklerinin kullanımı, tarımsal süreçlerde verimliliği, doğruluğu ve karar alma süreçlerini iyileştirmektedir. Derin öğrenme, hasat sistemleri alanında meyve tespiti, verim tahmini, meyve hasat robotları ve hassas tarım gibi uygulamalarda önemli bir rol oynamaktadır. Derin öğrenme modelleri, ürün tespiti ve hasat olgunluğu gibi kritik faktörleri doğru bir şekilde tanımlayarak tarımsal verimliliği artırmaktadır. Bitki hastalıklarının tespiti ve sınıflandırılmasında da etkili olmaktadır. Bitki hastalıklarının erken tespiti, ürün verimi ve genel tarımsal üretkenlik üzerinde olumlu bir etki yaratmaktadır. Tarımsal ürün sınıflandırmasında da kullanılmakta olup, hasat sonrası işleme ve kalite kontrolünün verimli olmasına katkıda bulunmaktadır. Hasat verim tahmini ve akıllı sulama sistemleri gibi alanlarda da etkili bir şekilde



kullanılmaktadır. Bu teknikler, tarımsal süreçlerde verimliliği artırmak ve doğruluğu iyileştirmek için önemli bir potansiyele sahiptir. Derin öğrenme tekniklerinin tarımsal uygulamalarda kullanılması, tarım sektöründe sürdürülebilirlik, verimlilik ve karar alma süreçlerinde önemli gelişmeler sağlamaktadır. Bu teknikler, tarımsal süreçlerde verimliliği artırmak, doğruluğu iyileştirmek ve çevresel etkiyi en aza indirmek için önemli bir potansiyele sahiptir. Derin öğrenme, tarımsal uygulamalarda devrim yaratma, hastalıkların erken ve doğru bir şekilde tanımlanmasını sağlama ve nihayetinde sürdürülebilir tarım uygulamalarına ve gıda güvenliğine katkıda bulunma konusunda umut vaat etmektedir. Araştırmalar göstermektedir ki önümüzdeki yıllarda makine öğrenmesi ve derin öğrenme yöntemleri tüm bilim dallarında olduğu gibi tarımda da öne çıkan konular arasında yer alacaktır. Tarımsal girdilerde ve işgücünde her geçen gün yaşanan problemler, tarımda yeni bakış açıları oluşturmamız yönünde yol açmaktadır. Derin öğrenme yöntemleri, tarımsal verileri değerlendirmede, sürdürülebilirlik, işgücü ve enerji tasarrufu açısından hizmet etmektedir.

## Kaynaklar

- Ajmera, A., Bhandari, M., Jain, H. K., & Agarwal, S. (2022). Crop, fertilizer, & irrigation recommendation using machine learning techniques. *International Journal for Research in Applied Science and Engineering Technology*, 10(12), 29-35.
- Alibabaei, K., Gaspar, P. D., Assunção, E., Alirezazadeh, S., Lima, T. M., Soares, V. N. G. J., ... & Caldeira, J. M. L. P. (2022). Comparison of on-policy deep reinforcement learning a2c with off-policy dqn in irrigation optimization: a case study at a site in portugal. *Computers*, 11(7), 104.
- Amin, J., Anjum, M. A., Sharif, A., Raza, M., Kadry, S., & Nam, Y. (2022). Iot with evolutionary algorithm based deep learning for smart irrigation system. *Computers, Materials & Continua*, 71(1), 1713-1728.
- Anonim 1. <https://aylablgn.medium.com/yapay-sinir-a%C4%9Flar%C4%B1-artificial-neural-network-ann-f875dfaa6476>
- Anonim 2. <https://www.youtube.com/watch?v=Lr7HXeSnzrU>
- Anonim 3. <https://medium.com/@batincangurbuz/tekrarlayan-sinir-a%C4%9F%C4%B1-recurrent-neural-networks-rnn-17b517dd0b3e>
- Anonim 4. <https://datakapital.com/blog/yinelenen-sinir-aglari-nedir/>
- Anonim 5. <https://www.analyticsvidhya.com/blog/2022/10/generative-pre-training-gpt-for-natural-language-understanding/>
- Anonim 6. <https://learnopencv.com/bert-bidirectional-encoder-representations-from-transformers/>
- Anonim 7. <https://www.educba.com/autoencoders/>
- Anonim 8. <https://www.labellerr.com/blog/what-is-gan-how-does-it-work/>
- Anonim 9. <https://pub.aimind.so/transformer-model-and-variants-of-transformer-chatgpt-3d423676e29c>
- Anonim 10. <https://merveelifsarac.medium.com/cnn-r-cnn-fast-r-cnn-mask-r-cnn-c90a1a4d76fb>
- Anonim 11. <https://www.geeksforgeeks.org/yolo-you-only-look-once-real-time-object-detection/>
- Awe, O. O. and Dias, R. (2022). Comparative analysis of arima and artificial neural network techniques for forecasting non-stationary agricultural

- output time series. *Agris on-Line Papers in Economics and Informatics*, 14(4), 3-9. <https://doi.org/10.7160/aol.2022.140401>
- Bhimavarapu, U., Battineni, G., & Chintalapudi, N. (2023). Improved optimization algorithm in lstm to predict crop yield. *Computers*, 12(1), 10.
- Bidve, V. S., Mane, S., Tamkhade, P. K., & Pakle, G. (2023). Weed detection by using image processing. *Indonesian Journal of Electrical Engineering and Computer Science*, 30(1), 341.
- Bini, D. A., Pamela, D., & Hemanth, D. J. (2022). Evaluating yolov5 deep learning models for the detection of tomato berries for crop yield estimation. *Frontiers in Artificial Intelligence and Applications*.
- Bosilj, P., Aptoula, E., Duckett, T., & Cielniak, G. (2019). Transfer learning between crop types for semantic segmentation of crops versus weeds in precision agriculture. *Journal of Field Robotics*, 37(1), 7-19.
- Darwin, B., Dharmaraj, P., Prince, S., Popescu, D., & Hemanth, D. J. (2021). Recognition of bloom/yield in crop images using deep learning models for smart agriculture: a review. *Agronomy*, 11(4), 646.
- Dias, P. A., Tabb, A., & Medeiros, H. (2018). Multispecies fruit flower detection using a refined semantic segmentation network. *IEEE Robotics and Automation Letters*, 3(4), 3003-3010.
- Elavarasan, D.; and Vincent, P. D. (2020). Crop yield prediction using deep reinforcement learning model for sustainable agrarian applications. *IEEE access*, 8: 86886–86901.
- Fountsop, A. N., Fendji, J. L. E. K., & Atemkeng, M. (2020). Deep learning models compression for agricultural plants. *Applied Sciences*, 10(19), 6866.
- Fuentes, A., Yoon, S., Kim, S. C., & Park, D. S. (2017). A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors*, 17(9), 2022.
- Gao, S. (2022). The application of information classification in agricultural production based on internet of things and deep learning. *IEEE Access*, 10, 22622-22630.
- Gerdan, D., Koç, C., & Vatandaş, M. (2022). Diagnosis of tomato plant diseases using pre-trained architectures and a proposed convolutional neural network model. *Tarım Bilimleri Dergisi*.

- Guillén-Navarro, M. A., Martínez-España, R., Llanes, A., Bueno-Crespo, A., & Cecilia, J. M. (2020). A deep learning model to predict lower temperatures in agriculture. *Journal of Ambient Intelligence and Smart Environments*, 12(1), 21-34.
- Haque, S., Lobatón, E., Nelson, N., Yencho, G. C., Pecota, K. V., Mierop, R., ... & Williams, C. M. (2021). Computer vision approach to characterize size and shape phenotypes of horticultural crops using high-throughput imagery. *Computers and Electronics in Agriculture*, 182, 106011.
- Hassan, S. M. and Maji, A. K. (2022). Plant disease identification using a novel convolutional neural network. *IEEE Access*, 10, 5390-5401.
- Hu, C., Liu, X., Zhou, P., & Li, P. (2019). Automatic detection of single ripe tomato on plant combining faster r-cnn and intuitionistic fuzzy set. *IEEE Access*, 7, 154683-154696.
- Jiang, P., Chen, Y., Liu, B., He, D., & Liang, C. (2019). Real-time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks. *IEEE Access*, 7, 59069-59080.
- Jin, Y., Ying, Y., Li, J., & Zhou, H. (2021). Gas path fault diagnosis of gas turbine engine based on knowledge data-driven artificial intelligence algorithm. *IEEE Access*, 9, 108932-108941.
- Jun, J., Kim, J., Seol, J., & Son, H. I. (2021). Towards an efficient tomato harvesting robot: 3d perception, manipulation, and end-effector. *IEEE Access*, 9, 17631-17640.
- Kamarudin, M. H., Ismail, Z. H., & Saidi, N. B. (2021). Deep learning sensor fusion in plant water stress assessment: a comprehensive review. *Applied Sciences*, 11(4), 1403.
- Kamilaris, A. and Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: a survey. *Computers and Electronics in Agriculture*, 147, 70-90.
- Karuna, G., Pravallika, K., Anuradha, K., & Srilakshmi, V. (2021). Convolutional and spiking neural network models for crop yield forecasting. *E3S Web of Conferences*, 309, 01162.
- Khaki, S., Pham, H., & Wang, L. (2020). Yieldnet: a convolutional neural network for simultaneous corn and soybean yield prediction based on remote sensing data..

- Kim, W., Lee, D., Kim, T., Kim, H., Sim, T., & Kim, Y. J. (2021). Weakly supervised crop area segmentation for an autonomous combine harvester. *Sensors*, 21(14), 4801.
- Ko, K., Jang, I., Choi, J. H., Lim, J., & Lee, D. U. (2021). Stochastic decision fusion of convolutional neural networks for tomato ripeness detection in agricultural sorting systems. *Sensors*, 21(3), 917.
- LeCun, Y., Bengio, Y., & Hinton, G. E. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Lee, J., Jun, S., Cho, Y., Lee, H., Kim, G. B., Seo, J. B., ... & Kim, N. (2017). Deep learning in medical imaging: general overview. *Korean Journal of Radiology*, 18(4), 570.
- Li, G. and Liu, W. (2023). Multimedia data processing technology and application based on deep learning. *Advances in Multimedia*, 2023, 1-15.
- Lin G, Huang P, Wang M, Xu Y, Zhang R, Zhu L. An Inverse Kinematics Solution for a Series-Parallel Hybrid Banana-Harvesting Robot Based on Deep Reinforcement Learning. *Agronomy*. 2022; 12(9):2157.
- Luna, R. G. d., Dadios, E. P., & Vicerra, R. R. P. (2019). Size classification of tomato fruit using thresholding, machine learning, and deep learning techniques. *AGRIVITA Journal of Agricultural Science*, 41(3).
- Magalhães, S. A., Castro, L., Moreira, G., Santos, F. N. d., Cunha, M., Dias, J., ... & Moreira, A. P. (2021). Evaluating the single-shot multibox detector and yolo deep learning models for the detection of tomatoes in a greenhouse. *Sensors*, 21(10), 3569.
- Maheswari, P., Raja, P. V., Apolo-Apolo, O., & Pérez-Ruiz, M. (2021). Intelligent fruit yield estimation for orchards using deep learning based semantic segmentation techniques—a review. *Frontiers in Plant Science*, 12.
- Medojević, I., Veg, A., Joksimović, A., & Ilić, J. (2022). Promotion of color sorting in industrial systems using a deep learning algorithm. *Applied Sciences*, 12(24), 12817.
- Meshram, A. A. (2022). Review on different software tools for deep learning. *International Journal for Research in Applied Science and Engineering Technology*, 10(1), 565-571.

- Mohanty, S. P., Hughes, D., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7.
- Mutha, S. A., Shah, A. M., & Ahmed, M. Z. (2021). Maturity detection of tomatoes using deep learning. *SN Computer Science*, 2(6).
- 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.
- Ni, X., Li, C., Jiang, H., & Takeda, F. (2020). Deep learning image segmentation and extraction of blueberry fruit traits associated with harvestability and yield. *Horticulture Research*, 7(1).
- Paliwal, J. and Joshi, S. (2022). An overview of deep learning models for foliar disease detection in maize crop. *Journal of Artificial Intelligence and Systems*, 4(1), 1-21.
- Preethi, C. R., Nc, B., & Ck, Y. (2021). An comprehensive survey on applications of precision agriculture in the context of weed classification, leave disease detection, yield prediction and uav image analysis. *Advances in Parallel Computing Technologies and Applications*.
- Qazi, S., Khawaja, B. A., & Farooq, Q. U. (2022). Iot-equipped and ai-enabled next generation smart agriculture: a critical review, current challenges and future trends. *IEEE Access*, 10, 21219-21235.
- Qureshi, K. N., Alhudhaif, A., Ali, M., Qureshi, M. A., & Jeon, G. (2021). Self-assessment and deep learning-based coronavirus detection and medical diagnosis systems for healthcare. *Multimedia Systems*, 28(4), 1439-1448.
- Rashid, M., Bari, B. S., Yusup, Y., Kamaruddin, M. A., & Khan, N. (2021). A comprehensive review of crop yield prediction using machine learning approaches with special emphasis on palm oil yield prediction. *IEEE Access*, 9, 63406-63439.
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Pérez, J., Lo, B., ... & Yang, G. (2017). Deep learning for health informatics. *IEEE Journal of Biomedical and Health Informatics*, 21(1), 4-21.
- Roy, A. M. and Bhaduri, J. (2021). A deep learning enabled multi-class plant disease detection model based on computer vision. *Ai*, 2(3), 413-428.

- Ryo, M., Schiller, J., Stiller, S., Palacio, J. C. R., Mengsuwan, K., Safonova, A., Wei, Y. (2022). Deep learning for sustainable agriculture needs ecology and human involvement. *Journal of Sustainable Agriculture and Environment*, 2(1), 40-44.
- S. Yonbawi, S. Alahmari, B. R. S. S. Raju, C. H. G. Rao, M. K. Ishak et al.(2023). "Modeling of sensor enabled irrigation management for intelligent agriculture using hybrid deep belief network," *Computer Systems Science and Engineering*, vol. 46, no.2, pp. 2319–2335.
- Shrestha, P., Kuang, N., & J, Y. (2022). Efficient end-to-end learning for cell segmentation with machine generated incomplete annotations.
- Singh, A. K., Ganapathysubramanian, B., & Sarkar, S. (2018). Deep learning for plant stress phenotyping: trends and future perspectives. *Trends in Plant Science*, 23(10), 883-898.
- Singh, T. , Vishwakarma, D. K. (2020). A deeply coupled convnet for human activity recognition using dynamic and rgb images. *Neural Computing and Applications*, 33(1), 469-485.
- Sladojević, S., Arsenović, M., Anderla, A., Čulibrk, D., & Stefanović, D. (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*, 2016, 1-11.
- Sun, Y., Liu, Y., Wang, G., & Zhang, H. (2017). Deep learning for plant identification in natural environment. *Computational Intelligence and Neuroscience*, 2017, 1-6.
- Tang, Y., Chen, M., Chen, Z., Luo, L., Li, J., Lian, G., ... & Zou, X. (2020). Recognition and localization methods for vision-based fruit picking robots: a review. *Frontiers in Plant Science*, 11.
- Tao, W., Zeng, S., Su, L., Sun, Y., Shao, F., & Wang, Q. (2023). Yield prediction and water-nitrogen management of chinese jujube based on machine learning. *Irrigation and Drainage*, 72(2), 439-450.
- Umar, M. A., Sani, B. M., & Suleiman, U. (2022). An overview of machine and deep learning technologies application in agriculture: opportunities and challenges in nigeria. *SLU Journal of Science and Technology*, 4(1&2), 84-96.
- Valdez, P. (2020). Apple defect detection using deep learning based object detection for better post harvest handling.

- Wei, Y. and Weng, Z. (2020). Research on the process fault diagnosis method based on dbn and dropout. *The Canadian Journal of Chemical Engineering*, 98(6), 1293-1306.
- Wu, W., Shenping, D., & Lv, J. (2012). Application research of neural networks in fruit and vegetable harvesting robot. *Proceedings of the 10th World Congress on Intelligent Control and Automation*.
- Yao, N., Ni, F., Wang, Z., Luo, J., Sung, W., Luo, C., Li, G. (2021). L2mxception: an improved xception network for classification of peach diseases. *Plant Methods*, 17(1).
- Zhang, C., Yue, P., Di, L., & Wu, Z. (2018). Automatic identification of center pivot irrigation systems from landsat images using convolutional neural networks. *Agriculture*, 8(10), 147.
- Zhang, J., Liu, J., Chen, Y., Feng, X., & Sun, Z. (2021). Knowledge mapping of machine learning approaches applied in agricultural management—a scientometric review with citespace. *Sustainability*, 13(14), 7662.
- Zheng, Y., Kong, J., Jin, X., Wang, X., & Zuo, M. (2019). Cropdeep: the crop vision dataset for deep-learning-based classification and detection in precision agriculture. *Sensors*, 19(5), 1058.





## BÖLÜM 6

### GEN EKSPRESYONU VERİLERİNDEN YAPAY ZEKA TEKNİKLERİ İLE LÖSEMİ KANSER TEŞHİS SİSTEMİ

<sup>1</sup>Dr. Enes EFE

<sup>2</sup>Dr. Öğr. Üyesi Emrehan YAVŞAN

DOI: <https://dx.doi.org/10.5281/zenodo.10396204>

---

<sup>1</sup> Hitit Üniversitesi Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Çorum, Türkiye, ORCID: 0000-0002-6136-6140, enesefe@hitit.edu.tr

<sup>2</sup> Tekirdağ Namık Kemal Üniversitesi, Elektronik ve Otomasyon Bölümü, Tekirdağ, Türkiye, ORCID: 0000-0001-9521-4500, eyavsan@nku.edu.tr



## 1. Giriş

Lösemi, dünya genelinde en yaygın ölüm nedenlerinden biri olarak gösterilen kritik bir sağlık sorunudur. Kanser araştırmaları, bu ölümcül hastalığın teşhisi, tedavisi ve önlenmesi için yenilikçi yöntemler geliştirmeye çalışmaktadır. Bu kapsamda, mikrodizi verileri, kanser araştırmalarında hayati bir rol oynamaktadır. Mikrodizi verileri, gen ekspresyonundaki genetik değişiklikleri binlerce hücre düzeyinde eş zamanlı olarak inceleme olanağı sağlayan yüksek boyutlu veri kümelerini ifade eder. Bu kapsamlı boyutluluk, kanser araştırmacılarına, hastalığın moleküler temellerini daha derinlemesine anlama ve detaylı analizler yapma imkanı sunar. Kısacası mikrodizi verileri; kanserin teşhisi, tedavisi ve hastalığın genel olarak kavranmasında önemli ilerlemelere öncülük etmiştir. Özellikle, bu verilerin kullanımı sayesinde kanserin erken teşhis edilmesi ve hastaların daha etkili tedavilere erişimi konusunda önemli adımlar atılmıştır. Bununla birlikte, mikrodizi verilerinin analizi ve yorumlanması bir takım zorlukları da beraberinde getirmektedir. Bu dizilerden doğru ve güvenilir sonuçlara ulaşabilmek için özel veri madenciliği ve istatistik tekniklerin başarılı bir şekilde uygulanması gerekmektedir. Ancak bu teknik zorlukların üstesinden gelindiğinde mikrodizi verileri, kanser araştırmalarında önemli bir kılavuz olabilir, yeni tedavilerin geliştirilmesine katkı sağlayabilir ve hastaların yaşam kalitesini artırabilir (Fajila, 2019; Klein vd., 2009; Lowenberg vd., 1999). Aksi halde bu avantajlara ulaşılması mümkün değildir.

Kanser çalışmalarını yürüten araştırmacılar, veri kümelerinin yüksek boyutluluğu, kanser türlerine özgü genlerin eksikliği ve genler arasındaki karmaşık etkileşimler gibi birçok zorlukla karşı karşıyadır. Bu zorlukların üstesinden gelmek için araştırmacılar yeni ve gelişmiş algoritmalar ortaya çıkarmalı, kanser türlerine özgü genleri tanımlamalı ve gen etkileşimlerini daha iyi anlamalıdır. Bu sayede kanser araştırmalarında daha fazla ilerleme kaydedilebilir ve kanser tedavileri daha etkili hale getirilebilir.

Yapılacak araştırmalarda verileri analiz etmek, kanserin temel mekanizmalarını ve dinamiklerini anlamamızla birlikte kanser türlerini tanımlamamıza yardımcı olur. Kanser araştırmalarında kullanılan veri setleri karmaşık ve yüksek boyutlu olduğundan geleneksel yöntemler yetersiz kalabilir. Bu nedenle, ileri istatistiksel yöntemler, makine öğrenmesi algoritmaları ve ağ analizi tekniklerinin birlikte kullanılması önemlidir (Orhan

vd., 2023). Bu yöntemler, kanserin erken teşhisine ve kişilere özgü tedavilerin geliştirilmesine yardımcı olabilir (Sönmez vd., 2021).

Literatürde yer alan pek çok çalışma, en uygun özellikleri seçerek gen ifade düzeylerini içeren veri setlerini sınıflandırmayı amaçlamaktadır. Bu çalışmalarda özellik seçimi için filtre, wrapper, gömülü ve hibrit yöntemler gibi çeşitli yöntemler kullanılmıştır (Kar vd., 2015). Yapılan bu çalışmada ise gen ekspresyon verilerini düşük boyutlu bir uzayda temsil etme, gürültüyü azaltma ve özellikler arasındaki ilişkileri vurgulama amacıyla Zaman-Frekans Dönüşüm yöntemlerinden yararlanılarak özellikler seçilmiş ve seçilen özellikler makine öğrenmesi algoritmaları kullanılarak sınıflandırılmıştır. Böylece daha etkin bir özellik seçimi süreci geçirilerek işlem yükü hafifletilmiştir. Düşük boyutlu bir arama uzayında yüksek performanslı bir yapay zeka modeli sunulmaya çalışılmıştır. Kısacası gen ekspresyon seviyelerinin sınıflandırılmasında özellik seçim süreci optimize edilerek modelin performansının yükseltilmesi hedeflenmiştir.

## **2. Materyal ve Metot**

### **2.1. Veriseti**

Bu çalışmada, literatürde en sık kullanılan veri kümeleri arasında yer alan lösemi gen mikrodizisi veri kümesini (Golub vd., 1999) kullanarak sınıflandırma başarısını ölçebilmek amacıyla deneysel çalışmalar yürütülmüştür. Tablo 1’de kullanılan hazır veri setinin özellikleri verilmektedir.

Tablo 1. Lösemi veriseti için gen, örnek ve sınıf sayısı.

<b>Veriseti</b>	<b>Gen</b>	<b>Örnek</b>	<b>Sınıf</b>
Lösemi	7129	72	2

Lösemi veri seti, lösemi teşhisi konulan bireylerden elde edilen 72 kemik iliği ve periferik kan örneğini içerir. Bu veri seti, Akut Miyeloid Lösemi (AML) ve Akut Lenfositik Lösemi (ALL) olmak üzere iki farklı alt kanser tipi arasında ayırım yapma hedefiyle oluşturulmuştur. Bu örneklerden 25’i AML, 47’si ise ALL olarak sınıflandırılmıştır. Yüksek yoğunluklu oligonükleotid mikrodizileri kullanılarak yapılan çalışmada, bu iki kanser alt tipindeki gen ekspresyon kalıpları araştırılmış ve toplam 7129 adet gen analiz edilmiştir.

## 2.2. Ayrık Kosinüs Dönüşümü

Ayrık kosinüs dönüşümü (AKD), bir dizideki frekans bileşenlerini çıkarmak için kullanılan bir matematiksel işlemidir. Fourier dönüşümünün (FD) bir özel durumudur ve FD'ye göre daha hızlı ve daha az bellek gerektirir (Efe vd., 2022; Khayam, 2003).  $N$  elemanlı bir  $x(n)$  sinyalinin ayrık kosinüs dönüşümü şu formülle ifade edilir:

$$X(k) = \sqrt{\frac{2}{N}} C(k) \sum_{n=0}^{N-1} x(n) \cdot \cos\left(\frac{(2\pi + 1) \cdot k\pi}{2N}\right) \quad (1)$$

Burada:

- $X(k)$ , AKD'nin  $k$ . bileşeni,
- $x(n)$ , orijinal sinyalin  $n$ . örneği,
- $C(k)$ , AKD matrisinin  $k$ . satırındaki eleman.

## 2.3. Hızlı Fourier Dönüşümü

Hızlı Fourier Dönüşümü (HFD), zaman alanındaki bir sinyali frekans alanına dönüştürmek için kullanılan bir algoritmadır. HFD özellikle bilgisayarlar üzerinde, hızlı bir şekilde büyük veri setlerine uygulanabilen bir yöntemdir. HFD'nin temel matematiksel formülü şu şekildedir:

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot e^{-j\frac{2\pi}{N}kn} \quad (2)$$

Bu formülde:

- $X(k)$ , frekans alanında ki sinyalin  $k$ -inci bileşenini temsil eder.
- $x(n)$ , zaman alanında ki orijinal sinyalin  $n$ -inci örneğini temsil eder.
- $N$ , örnek sayısını temsil eder.

HFD algoritması genellikle Cooley ve Tukey tarafından geliştirilen bir böl ve yönet stratejisine dayanır. HFD'nin bu hızlı versiyonu, rekürsif bir şekilde alt sinyalleri işleyerek genel dönüşümü daha hızlı bir şekilde hesaplar.

HFD algoritmasının ana fikri, veri setini bir dizi alt probleme bölmek ve ardından bu alt problemleri çözmek ve sonuçları birleştirmek suretiyle toplam işlem maliyetini azaltmaktır. HFD'nin temel formülü üzerine bu bölme ve birleştirme adımları eklenir (Nussbaumer vd., 1982).

#### 2.4. Ayrık Dalgacık Dönüşümü

Ayrık dalgacık dönüşümü (ADD), bir sinyali belirli bir ölçek ve konum parametrelerine sahip dalgacık fonksiyonları ile temsil etme işlemidir (Shensa, 1992). Genel formülü şu şekildedir:

$$X(a, b) = \sum_{n=0}^{N-1} x(n) \cdot \psi_{a, b}(n) \quad (3)$$

Burada:

- $X(a, b)$ , ayrık dalgacık katsayılarını temsil eder.
- $x(n)$ , giriş sinyalini temsil eder.
- $\psi_{a, b}(n)$ , ölçek ( $a$ ) ve konum ( $b$ ) parametrelerine bağlı olarak değişen ana dalgacık fonksiyonunu temsil eder.

ADD uygulanırken tüm deneyler, yaygın olarak kullanılan pencere fonksiyonlarından Daubechies (db) ile gerçekleştirilmiştir.

#### 2.5. K-En Yakın Komşu ve Rastgele Orman Algoritmaları

K-En Yakın Komşu (KYK) ve Rastgele Orman (RO) algoritmaları, makine öğrenimi alanında sıkça kullanılan yöntemlerdir. KYK, bir sınıflandırma veya regresyon problemi çözmek için kullanılan basit ve etkili bir algoritmadır. Temel fikir yeni bir veri noktasını, çevresindeki en yakın  $k$  komşu noktanın etkisiyle sınıflandırmaktır. Bu, veri noktalarının benzerlik ölçüsüne dayalı olarak gruplandığı bir yaklaşımdır. KYK'nın avantajları arasında basit uygulanabilirlik, eğitim sürecinin olmaması ve genelde iyi sonuçlar elde etme yeteneği bulunmaktadır. Ancak bu algoritma kullanılırken büyük veri setleriyle çalışmak, oldukça uzun süreler gerektirebilir.

RO, birçok karar ağacının bir araya getirilmesiyle oluşturulan bir ensemble (topluluk) öğrenme yöntemidir. Her bir karar ağacı, rastgele seçilen alt veri setleri üzerinde eğitilir ve genellikle birbirinden bağımsızdır. Bu, modelin daha genel ve dayanıklı olmasını sağlar. RO'nun temel avantajlarından

biri, aşırı öğrenmeye (overfitting) karşı dayanıklılığı ve yüksek boyutlu veri setlerinde etkili performansdır. Aynı zamanda, aykırı veya eksik verilere karşı dayanıklıdır. RO geniş uygulama alanlarına sahip olan güçlü bir öğrenme algoritmasıdır.

## 2.6. Temel Bileşenler Analizi

Temel Bileşenler Analizi (TBA) çok boyutlu veri setlerini daha az boyutta ifade etmek amacıyla kullanılan istatistiksel bir yöntemdir. Bu yöntem, veri setindeki değişkenlik miktarını azaltarak, verinin temel özelliklerini ve yapılarını daha iyi anlamamıza olanak tanır. TBA'nın temel amacı, veri setindeki değişkenlik içindeki temel desenleri ve ilişkileri ortaya çıkarmaktır. Bu, veriyi daha az boyutlu bir uzayda temsil etmek suretiyle gerçekleştirilir. TBA, genellikle veri setindeki korelasyonları azaltmak ve analiz sürecini daha yönetilebilir hale getirmek amacıyla kullanılır. TBA'nın avantajları şunlardır:

- Veri setindeki gürültüyü azaltır.
- Değişken içindeki temel desenleri anlamamıza yardımcı olur.
- Boyut azaltma sağlar, bu da daha az sayıda değişkenle çalışmayı ve modelleme yapmayı kolaylaştırır.

## 3. Araştırma Bulguları ve Tartışma

Bu çalışma için tercih edilen veri kümesi, 10 kat-çapraz doğrulama kullanılarak eğitim ve test kümelerine ayrılmıştır. Bu süreç, performanslarını değerlendirmek için kullanılan her modele ayrı ayrı uygulanmıştır. Daha sonra ortalama deneysel sonuçlar, sırasıyla denklem (5), (6), (7) ve (8)'de tanımlanan doğruluk, duyarlılık, özgüllük ve Makro F1 puanı için hesaplanmıştır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + FN + TN} \times 100 \quad (4)$$

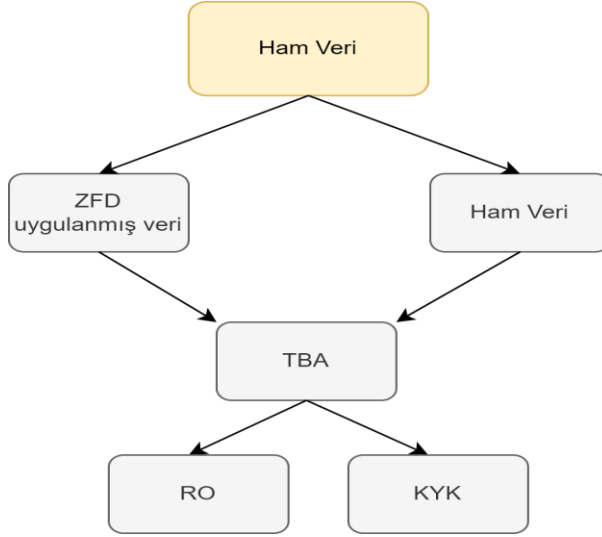
$$\text{Duyarlılık} = \frac{TP}{TP + FN} \times 100 \quad (5)$$

$$\text{Özgüllük} = \frac{TN}{FP + TN} \times 100 \quad (6)$$

$$\text{Makro F1} = \frac{2 \times \text{Makro Kesinlik} \times \text{Makro Duyarlılık}}{\text{Makro Kesinlik} + \text{Makro Duyarlılık}} \quad (7)$$



Şekil 1’de, Zaman-Frekans Dönüşümü uygulanmış veriler ve uygulanmamış veriler üzerinde TBA sonucu yapılan sınıflandırma işlemlerinin çalışma prosedürünü gösteren akış diyagramı sunulmuştur.



Şekil 1. Önerilen sistemin akış diyagramı

Yapılan işlemler sonucu elde edilen performans bilgileri aşağıdaki Tablo 2’de gösterilmiştir.

Tablo 2. 10-kat çapraz doğrulama yöntemini kullanan RO ve KYK sınıflandırıcılı mikrodizi veri kümesinin deneysel sonuçları.

Veriseti	Sınıflandırıcı	Duyarlılık	Özgüllük	Doğruluk	MF1
Ham veri	KYK	98.00	53.33	83.21	59.67
	RO	100	88.33	95.71	91.67
AKD’li veri	KYK	100	70.00	90.00	80.67
	RO	100	91.67	97.14	94.67
HFD’lü veri	KYK	100	73.33	91.43	82.67
	RO	100	83.33	94.29	88.33
ADD’lü veri	KYK	98.00	68.33	88.75	70.67
	RO	100	93.33	97.14	95.00

Tablo 2 incelendiğinde 2 farklı sınıflandırıcı arasında RO'nun KYK'ya göre çok daha başarılı olduğu gözlenebilir. Ayrıca Zaman-Frekans Dönüşüm (ZFD) yöntemleri uygulanmış veriler, ham verilere göre daha üstün bir performans sergilemişlerdir. Bunun olası nedenleri için frekans alanındaki özellik çıkarımının yararları da göz önüne alındığında aşağıdakiler sıralanabilir.

- Model, mikrodizi veri kümesine ZFD uygulayarak verilerdeki frekansla ilgili desenleri ve varyasyonları yakalayabilir. Bu, modelin, mikrodizi verilerinde mevcut olan ve yalnızca zaman alanında tanımlanması zor olabilecek periyodik veya tekrarlayan desenleri tespit etmesini sağlar.
- Verinin ZFD aracılığıyla frekans alanına dönüştürülmesi, zaman alanında var olan gürültünün veya ilgisiz özelliklerin etkisinin azaltılmasına yardımcı olabilir. Gürültü bileşenleri tipik olarak yüksek frekanslı bölgelerde ortaya çıkar ve örneğin AKD, sinyal enerjisini daha az sayıda katsayıya yoğunlaştırarak gürültüyle ilgili bileşenleri etkili bir şekilde azaltabilir.
- ZFD sayesinde boyutsallığın azaltılması kolaylaşır ve yüksek boyutluluk yükü azalır.

#### 4. Sonuçlar

Mikrodizi verileri, lösemi araştırmalarında kanserin teşhisi, tedavisi ve önlenmesi için önemli araçlardan biridir. Bu veriler, gen ekspresyonundaki genetik değişiklikleri binlerce hücre düzeyinde eş zamanlı olarak inceleme olanağı sunar. Ancak, mikrodizi verilerinin analizi ve yorumlanması bir takım zorlukları da beraberinde getirmektedir. Bu çalışmada, gen ekspresyon verilerinden önemli olan özellikleri seçebilmek için Zaman-Frekans Dönüşüm yöntemlerinden faydalanılmasının etkinliği araştırılmıştır. Bu yöntemler sayesinde gen ekspresyon verilerini düşük boyutlu bir uzayda temsil etme, gürültüyü azaltma ve özellikler arasındaki ilişkileri vurgulama gibi avantajlar incelenmiştir.

Sunulan çalışmayla Zaman-Frekans Dönüşüm yöntemleri kullanılarak gen ekspresyon verilerinden seçilen özelliklerin, makine öğrenmesi algoritmalarının performansını önemli ölçüde artırdığı tespit edilmiştir. Bu çalışma, lösemi araştırmalarında mikrodizi verilerinin analizinde Zaman-Frekans Dönüşüm yöntemlerinin etkin bir şekilde kullanılabileceğini

göstermektedir. Gelecekte diğer kanser türleri üzerinde Zaman-Frekans Dönüşüm yöntemlerinin etkinliği araştırılabilir. Bu yöntemler, farklı kanser türlerinin erken teşhisi, tedavisi ve önlenmesi için yeni yöntemler geliştirilmesine yardımcı olabilir.

## Kaynakça

- 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.
- Fajila, M. N. F. (2019). Gene subset selection for leukemia classification using microarray data. *Current Bioinformatics*, 14(4), 353–358.
- Golub, T. R., Slonim, D. K., Tamayo, P., Huard, C., Gaasenbeek, M., Mesirov, J. P., Coller, H., Loh, M. L., Downing, J. R., & Caligiuri, M. A. (1999). Molecular classification of cancer: class discovery and class prediction by gene expression monitoring. *science*, 286(5439), 531–537.
- Kar, S., Sharma, K. Das, & Maitra, M. (2015). Gene selection from microarray gene expression data for classification of cancer subgroups employing PSO and adaptive K-nearest neighborhood technique. *Expert Systems with Applications*, 42(1), 612–627.
- Khayam, S. A. (2003). The discrete cosine transform (DCT): theory and application. *Michigan State University*, 114(1), 31.
- Klein, H.-U., Ruckert, C., Kohlmann, A., Bullinger, L., Thiede, C., Haferlach, T., & Dugas, M. (2009). Quantitative comparison of microarray experiments with published leukemia related gene expression signatures. *BMC bioinformatics*, 10, 1–11.
- Lowenberg, B., Downing, J. R., & Burnett, A. (1999). Acute myeloid leukemia. *New England Journal of Medicine*, 341(14), 1051–1062.
- Nussbaumer, H. J., & Nussbaumer, H. J. (1982). *The fast Fourier transform*. Springer.
- 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.
- Shensa, M. J. (1992). The discrete wavelet transform: wedding the a trous and Mallat algorithms. *IEEE Transactions on signal processing*, 40(10), 2464–2482.
- Sönmez, Ö. S., DAĞTEKİN, M., & Ensari, T. (2021). Gene expression data classification using genetic algorithm-based feature selection. *Turkish Journal of Electrical Engineering and Computer Sciences*, 29(7), 3165–3179.



**CHAPTER 7**  
**INTELLIGENT AQUAPONIC SYSTEMS WITH SENSORS**  
**SETTING UP**

<sup>1</sup>Çetin YAĞCILAR

DOI: <https://dx.doi.org/10.5281/zenodo.10396229>

---

<sup>1</sup> Tekirdağ Namık Kemal University, Faculty of Arts and Sciences, Department of Biology, Süleymanpaşa, Tekirdağ, TURKEY, ORCID: 0000-0002-4683-820X



## **INTRODUCTION**

According to the 2021 Global Food Crises Report (GRFC) study, 53 countries and about 193 million people in these countries are reported to suffer from acute food shortages, and this rate will increase in 2022, and 258 million people in 58 countries and these regions will suffer from food shortages (Parantez Medya, 2023). Food crisis: Due to rapid population growth and the decline in arable land per capita and freshwater resources used for irrigation, food production must double by 2050 to ensure human nutrition (Sahu & Liu, 2023).

Aquaponic systems are presented as an alternative solution to the world's food and environmental problems and as a new approach to agriculture (Yanes, Matrinez & Ahmad, 2020). The aquaponics system is based on a system of continuously circulating aquaculture in a closed circuit and soilless plant cultivation in water supplemented with an enriched nutrient solution, known as hydroponics (Goddek et al., 2015; Rakocy, 2012). The reason why aquaponic systems are preferred is that they offer the possibility of producing food closer to the city center (Love et al., 2015). At the same time, it is a great advantage to recycle the waste water produced in aquaculture facilities in closed circuits and use it for growing plants. This wastewater contains large amounts of nitrogen, and the source of this nitrogen is protein-rich fish feed (Hu et al., 2015). In aquaculture, the most important factor in bringing fish to the desired size is the quality of the water environment in which the fish are kept. This is achieved by replacing the water in the system daily with clean water (Hu et al., 2015; Martins, Ochola, Ende, Eding, & Verreth, 2009). These water changes can lead to both an increased workload in closed aquaculture and a global environmental crisis by promoting eutrophication and cyanobacterial blooms of nitrogen-rich water released into nature (Wang & Wang, 2009) (Figure 1).





Figure 1. Eutrophication is a global environmental crisis (Designed with artificial intelligence using Image Creator by Designer)

In this context, interest in scientific studies on the aquaponics system has greatly increased and many meetings and training courses on this system have been organized in recent years (Colt, Schuur, Weaver & Semmens, 2022). When "aquaponic systems" was entered into the academic search engine Google, a total of 20063 publications were found between 2015 and 2023 (Figure 2).




Figure 2. Number of publications on the topic "Aquaponic Systems" in Google Scholar between 2010 and 2023

## AQUAPONIC SYSTEMS

These systems are now considered one of the most efficient and sustainable methods in terms of environmental impact (Okomoda et al., 2023). The general explanation of the system is that the filtered water is transferred from the fish tank to the plant tank using a pump and the water is then returned to the fish tank (FAO, 2014) (Figure 3).



Figure 3. Aquaponic system design (designed with artificial intelligence using Designer's Image Creator)

Nitrifying bacteria in the filters convert the ammonia in the environment into nitrite and then the nitrite into nitrate, making it usable for plants (Kushwaha et al., 2023; Robles-Porchas et al., 2020; Thakur et al., 2023) (Figure 4).




Figure 4. Nitrification cycle in an aquaponic system

In aquaponic systems, the monitoring of many parameters related to the water and the environment is necessary for the healthy growth of fish and plants (Gayam et al., 2022). Many parameters can be evaluated automatically when controlling this system. Among these parameters, the values for pH, temperature, water level, oxygen, nitrate and dissolved solids are important for both the health of the fish and the productivity of the plants. These sensors to be used allow us to obtain information about these values by connecting them to Arduino (Rao et al., 2021).

## SENSORS

They are used to collect data from fish and plant tanks and to evaluate environmental conditions.

### pH

In aquaponic systems, the pH should be maintained between 7 and 8.5 to ensure that microbial nitrification takes place under ideal conditions by

converting ammonia to nitrite and nitrite to nitrate (Wang, Yang & Kim, 2023). the pH value must be controlled and maintained at the desired values for both fish and plant cultures (Goddek, Joyce, Kotzen & Burnell, 2019).

### **TEMPERATURE**

Monitoring water temperature in aquaponic systems is a necessary parameter not only for fish farming but also for plant growth (Sallenave, 2016). For the fish to grow as desired and be healthy, the temperature in the fish and plant tanks must be between 24 and 30 °C, and a water heater must be used to maintain this temperature at the desired level (Saaïd, Fadhil, Ali, & Noor, 2013).

### **WATER LEVEL**

In aquaponics systems, the water level is controlled to prevent the water in the fish and plant tanks from rising too high and, above all, to prevent the water in the fish tanks from falling below the water level that the fish need to feed and live (Cruz-Anchiraico, Mantari-Ramos, Cangalaya & Huamanchahua, 2022).

### **OXYGEN**

Ensuring the continuity of nitrifying bacteria depends on sufficient oxygen levels in the water, and this level should be between 4-8 mg/litre in aquaponic systems (FAO, 2014). In aquaculture, low oxygen levels can lead to rapid deterioration of water quality due to pollution from fish feces and inedible feed in the aquatic environment, which affects fish health and even leads to fish mortality (Ren, Zhang, Wei & Li, 2018).

### **NITRATE**

In aquaponic systems, most of the ammonia is produced by the fish, and if the number of fish and the filtration system are balanced, the ammonia in the environment is quickly converted to nitrate (FAO, 2014; Yavuzcan Yıldız et al., 2017).

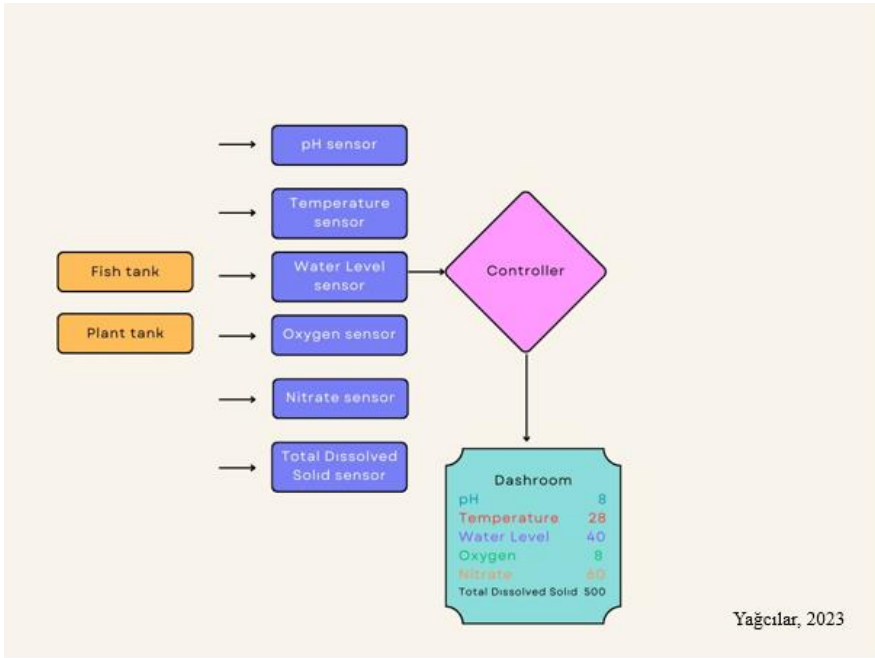


Figure 5: Example of a block diagram of automation in aquaponics systems

## CONCLUSION

Food security and sustainability are a major issue today due to rapid population growth, water scarcity and the decrease in sufficient agricultural land. Aquaponic systems can prevent this problem through fish farming and plant culture. However, for a healthy growing environment for both fish and plants, this system must be traceable. In this context, the sensors to be used for the system will be able to notify the user in the event of a negative development so that the problem can be solved immediately.

## REFERENCES

- Colt, J., Schuur, A. M., Weaver, D., & Semmens, K. (2022). Engineering design of aquaponics systems. *Reviews in Fisheries Science & Aquaculture*, 30(1), 33-80.
- Cruz-Anchiraico, J. A., Mantari-Ramos, L. N., Cangalaya, J. D. A., & Huamanchahua, D. (2022, October). Design of an Automated System of pH and Water Level for an Aquaponic Module. In *2022 IEEE 13th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)* (pp. 0603-0608). IEEE.
- FAO (2014). *Small-scale aquaponic food production. Integrate fish and plant farming. FAO fisheries and aquaculture technical paper No. 589* (p. 262). Food and Agriculture Organization of the United Nations.
- Gayam, K. K., Jain, A., Gehlot, A., Singh, R., Akram, S. V., Singh, A., ... & Noya, I. D. (2022). Imperative Role of Automation and Wireless Technologies in Aquaponics Farming. *Wireless Communications and Mobile Computing*, 2022.
- Goddek, S., Delaide, B., Mankasingh, U., Ragnarsdottir, K. V., Jijakli, H., & Thorarinsdottir, R. (2015). Challenges of sustainable and commercial aquaponics. *Sustainability*, 7(4), 4199-4224.
- Goddek, S., Joyce, A., Kotzen, B., & Burnell, G. M. (2019). *Aquaponics food production systems: combined aquaculture and hydroponic production technologies for the future* (p. 619). Springer Nature.
- Hu, Z., Lee, J. W., Chandran, K., Kim, S., Brotto, A. C., & Khanal, S. K. (2015). Effect of plant species on nitrogen recovery in aquaponics. *Bioresource technology*, 188, 92-98.
- Kushwaha, J., Priyadarsini, M., Rani, J., Pandey, K. P., & Dhoble, A. S. (2023). Aquaponic trends, configurations, operational parameters, and microbial dynamics: A concise review. *Environment, Development and Sustainability*, 1-34.
- Love, D. C., Fry, J. P., Li, X., Hill, E. S., Genello, L., Semmens, K., & Thompson, R. E. (2015). Commercial aquaponics production and profitability: Findings from an international survey. *Aquaculture*, 435, 67-74.

- Martins, C. I., Ochola, D., Ende, S. S., Eding, E. H., & Verreth, J. A. (2009). Is growth retardation present in Nile tilapia *Oreochromis niloticus* cultured in low water exchange recirculating aquaculture systems?. *Aquaculture*, 298(1-2), 43-50.
- Okomoda, V. T., Oladimeji, S. A., Solomon, S. G., Olufeagba, S. O., Ogah, S. I., & Ikhwanuddin, M. (2023). Aquaponics production system: A review of historical perspective, opportunities, and challenges of its adoption. *Food science & nutrition*, 11(3), 1157-1165.
- Parantez Medya. (07.Haziran.2023). Küresel Gıda Krizleri Raporu: 58 ülkede 258 milyon insan şiddetli açlıkla karşı karşıya. Magazinebbm. Küresel Gıda Krizleri Raporu: 58 ülkede 258 milyon insan şiddetli açlıkla karşı karşıya | BBM Magazine (magazinebbm.com)
- Rakocy, J. E. (2012). Aquaponics—integrating fish and plant culture. *Aquaculture production systems*, 344-386.
- Rao, K. R., Ahammad, S. H., Rajesh, V., Chandana, M. S., Tejaswi, P. S., Lakshmi, P. S., & Priya, B. P. (2021). Design and Implementation of an Automated Aquaponics System using Internet of Things. *Nveo-Natural Volatiles & Essential Oils Journal NVEO*, 5125-5139.
- Ren, Q., Zhang, L., Wei, Y., & Li, D. (2018). A method for predicting dissolved oxygen in aquaculture water in an aquaponics system. *Computers and electronics in agriculture*, 151, 384-391.
- Robles-Porchas, G. R., Gollas-Galván, T., Martínez-Porchas, M., Martínez-Cordova, L. R., Miranda-Baeza, A., & Vargas-Albores, F. (2020). The nitrification process for nitrogen removal in biofloc system aquaculture. *Reviews in Aquaculture*, 12(4), 2228-2249.
- Saaïd, M. F., Fadhil, N. S. M., Ali, M. M., & Noor, M. Z. H. (2013, August). Automated indoor Aquaponic cultivation technique. In *2013 IEEE 3rd international conference on system engineering and technology* (pp. 285-289). IEEE.
- Sahu, S. K., & Liu, H. (2023). A genetic solution for the global food security crisis. *Journal of Integrative Plant Biology*, 65(6), 1359-1361.
- Sallenave, R. (2016). *Important water quality parameters in aquaponics systems*. College of Agricultural, Consumer and Environmental Sciences.

- Thakur, K., Kuthiala, T., Singh, G., Arya, S. K., Iwai, C. B., Ravindran, B., ... & Awasthi, M. K. (2023). An alternative approach towards nitrification and bioremediation of wastewater from aquaponics using biofilm-based bioreactors: A review. *Chemosphere*, 137849.
- Wang, H., & Wang, H. (2009). Mitigation of lake eutrophication: Loosen nitrogen control and focus on phosphorus abatement. *Progress in Natural Science*, 19(10), 1445-1451.
- Wang, Y. J., Yang, T., & Kim, H. J. (2023). pH Dynamics in Aquaponic Systems: Implications for Plant and Fish Crop Productivity and Yield. *Sustainability*, 15(9), 7137.
- Yanes, A. R., Martinez, P., & Ahmad, R. (2020). Towards automated aquaponics: A review on monitoring, IoT, and smart systems. *Journal of Cleaner Production*, 263, 121571.
- Yavuzcan Yıldız, H., Robaina, L., Pirhonen, J., Mente, E., Domínguez, D., & Parisi, G. (2017). Fish welfare in aquaponic systems: its relation to water quality with an emphasis on feed and faeces—a review. *Water*, 9(1), 13.





## BÖLÜM 8

### DEPOLANMIŞ HUBUBAT VE MAMULLERİNDE ZARARA NEDEN OLAN SEKONDER ZARARLILARIN YAPAY ZEKÂ VE GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK TEŞHİSİ

<sup>1</sup>Mehmet Ali YALÇINKAYA,

<sup>2</sup>Kader SUTLU

DOI: <https://dx.doi.org/10.5281/zenodo.10396241>

---

<sup>1</sup> Kırşehir Ahi Evran Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Kırşehir, Türkiye,

ORCID: 0000-0002-7320-5643, mehmetyalcinkaya@ahievran.edu.tr

<sup>2</sup> Kırşehir Ahi Evran Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Kırşehir, Türkiye,

ORCID:0009-0002-5173-3186, sutlu.kader@ogr.ahievran.edu.tr



## 1.GİRİŞ

Depolanmış hububat ve hububattan imal edilen mamuller hem dünya hem de ülkemiz için sürdürülebilir gıda güvenliği için stratejik öneme sahiptir. Depolanmış hububat ve mamullerin depolama sırasında toplam ürün miktarının ve kalite özelliklerinin değişmeden hedeflenen veya belirlenen süre kadar depolanması global ve ülkesel düzeyde bir güvenlik sorunudur. Bu nedenle depolama sırasında hububatın özelliklerini yitirmeden depolanması kritik öneme sahiptir. Hububatların depolanması sürecince kayıplara neden olan abiyotik ve biyotik stres faktörlerinin şiddetine ve süresine bağlı olarak değişen düzeylerde önemli miktar ve kalite kayıpları yaşanabilmektedir. Bu duruma bağlı olarak global veya ülkesel düzeyde ve değişen seviyelerde gıda güvenliği sorunları oluşabilmektedir.

Depolanmış hububatlarda biyotik streslere bağlı olarak oluşan kayıpların %20 düzeyinde olduğu ve zararlılar (böcek vb organizmalar) kaynaklı kayıpların ise %10 düzeyde olduğu kabul edilmektedir (Emekçi ve ark., 2015; Güz ve ark., 2015). Bu zarar oranı bulaşma düzeyi veya depolama alanında bulunan zararlı yoğunluğuna bağlı olarak oluşabilecek kayıplar katlanarak daha da artabilmektedir. Zararlılar tarafından depolanmış ürün veya bitkisel mamullerde oluşabilecek nicel ve kalite kayıplarına ek olarak zararlıların ürünlere doğrudan veya dolaylı olarak bulaştırdıkları pislikleri, eğer zararlılar herhangi bir salgı salgılıyorsa, salgılamış oldukları ağ ya da benzeri maddeler ile vücut kalıntıları ürünün ekonomik değerini değişen düzeylerde olumsuz etkileyen öne çıkan önemli unsurlardır. Oluşabilen ağımsı yapılar işletmelerde bulunan mekanik aksamalarda ağ yapıları nedeniyle sorunlara yol açabilmektedir. Tüm bunlara ek olarak artan zararlı düzeyine bağlı olarak üründe küflenme, kızışma ve kokuşma oluşabilmektedir. Bilerek veya bilmeyerek zararlılarla bulaşık gıda maddelerinin tüketilmesi, insan ve hayvan sağlığına değişen düzeylerde risk oluşturabilmektedir.

Konunun çözümünde günümüz teknolojisini kullanarak, yapay zekâ ve görüntü işleme tekniklerinin kullanımı, problemin belirlenmesi ve zamanında müdahale için farklı fırsatlar sağlayabilmektedir.

Yapay zekâ en kısa açıklama ile “insan beyninin ve düşünme sisteminin kopya edilmesi” olarak tanımlanabilir. Tanımı biraz daha sade bir şekilde yapmak gerekirse; “bir bilgisayar programını insan gibi düşünebilecek hâle getirme” cümlesi kullanılabilir. Yapay zekâ sistemi, her başarılı veri işleme turu

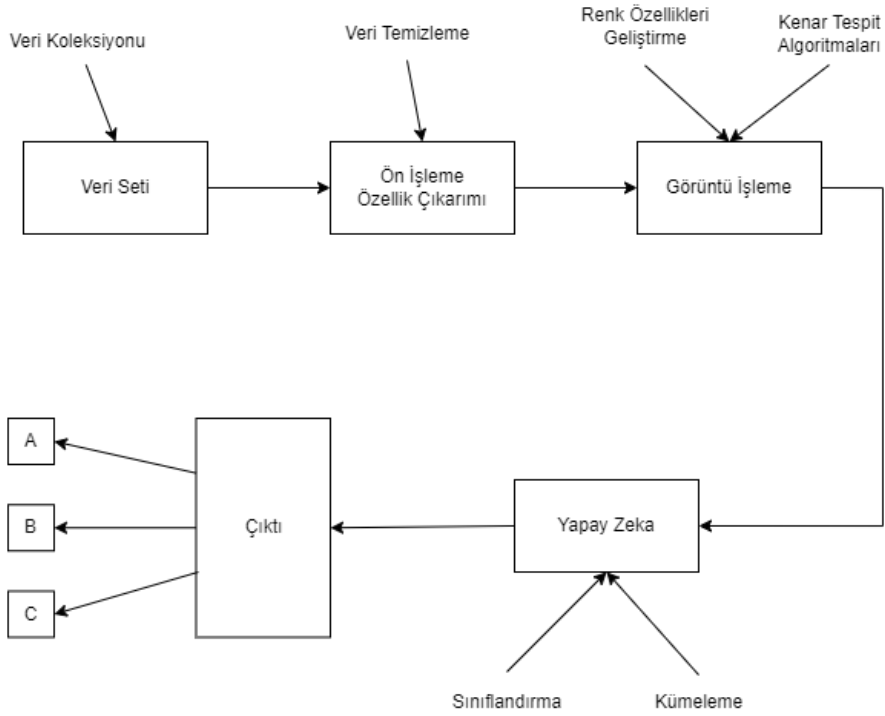
sonrasında daha akıllı hale gelmektedir. Bunun nedeni her etkileşim, sistemin çözümleri test etmesine, ölçmesine ve başarmak üzere ayarlandığı görevde uzmanlık geliştirmesine imkân tanımaktadır. Yapay zekâ sistemleri, bir insanın benzer işleri yapabileceği orandan çok daha hızlı bir şekilde tamamlayabileceğinden insanlardan çok daha hızlı uzman hale gelebilir. Bu durum yapay zekâyı akıllı karar verme gerektiren herhangi bir süreç için inanılmaz derecede etkili hale getirmektedir. Sonuç olarak tüm bunlar, yapay zekâyı inanılmaz derecede güçlü ve son derece değerli bir teknoloji yapmaktadır.

Gelişen teknolojiyle birlikte yapay zekanın çalışma alanı da genişlemiştir. Yapay zekâ sadece bununla sınırlı kalmayıp kendi kendine öğrenebilen ve kendini geliştiren sistemler, insan zekasından bağımsız gelişebilecek bir kavrama doğru ilerlemektedir.

Yapay zekânın alt dallarından biri olan derin öğrenme, oluşturulan veri setlerinden sonuçlar üreterek tahminde bulunan birden çok katmandan meydana gelen makine öğrenme yöntemidir. Bu çalışmada da yapay zekâ teknikleri kullanılarak, yukarıda bahsedilmiş zararlıların tespit edilmesine çalışılmış ve oldukça başarılı sonuçlar elde edilmiştir.

## **2. MATERYAL ve YÖNTEM**

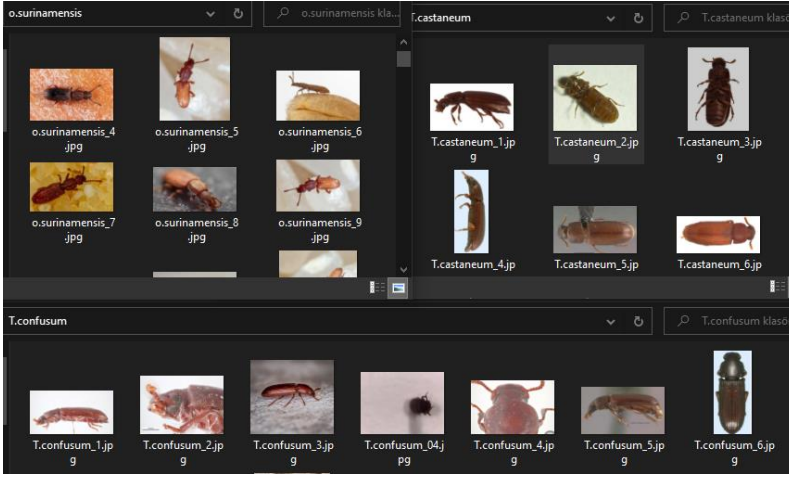
Bu başlık altında veri seti, yazılım, donanım ve değerlendirme ölçümleri açısından yapılan işlemleri açıklar. Gerçekleştirilen çalışmaya ait izlenen yol Şekil 1’ de gösterilmiştir;



Şekil 1: Çalışmada izlenen adımlar

## 2.1. Veri Seti

Veri seti, depolanmış hububat ve mamullerinde zarara neden olan sekonder zararlıların görüntülerini içermektedir. Bu görüntüler, Kırşehir Ahi Evran Üniversitesi Ziraat Fakültesi Bitki Koruma bölümünün saha çalışmaları ve laboratuvar imkanlarıyla elde edilmiştir. Veri seti oluşturulurken, "daha fazla veri, daha güçlü model" felsefesi benimsenmiştir (Cambron, 2011). Şekil 2' de veri seti içerisinde yer alan örneklerden bazıları görülmektedir.



Şekil 2: Veri Seti İçerisinde Yer Alan Bazı Örnekler

Veri set oluşturulurken, her bir zararlı için en az 200 adet görüntü toplanması hedeflenmiştir. Görüntüler, önceden belirlenmiş böcek türlerini temsil eden zararlılar üzerinde çekilmiştir. Görüntüler, uygun ışıklandırma ve perspektif sağlamak için standartize edilmiştir.

Veri seti için toplanan görüntülerin etiketleme işlemi makesense.ai sitesi kullanılarak gerçekleştirilmiştir. Etiketleme işlemi, rectangular bounding box (dikdörtgen kutu sınırlandırma) tekniği kullanılarak Şekil 3.3'teki gibi yapılmıştır. Görüntülerdeki böcekler, çizilen sınırlarla sınırlandırılmış ve ilgili sınıf isimleri olan "oryzaphilus\_surinamensis", "tribolium\_castaneum", "tribolium\_confusum" gibi etiketlerle sınıflandırılmıştır.



Şekil 3: Veri setindeki etiketli resimlere bir örnek

Etiketlenen görüntüler, Şekil 4'teki gibi YOLOv5 formatında kaydedilmiştir. Bu format, görüntülerin etiketlenmiş sınırlarını ve ilgili sınıf bilgilerini içeren bir yapı sağlar.



1.txt - Not Deferi

Dosya Düzen Biçim Görünüm Yardım

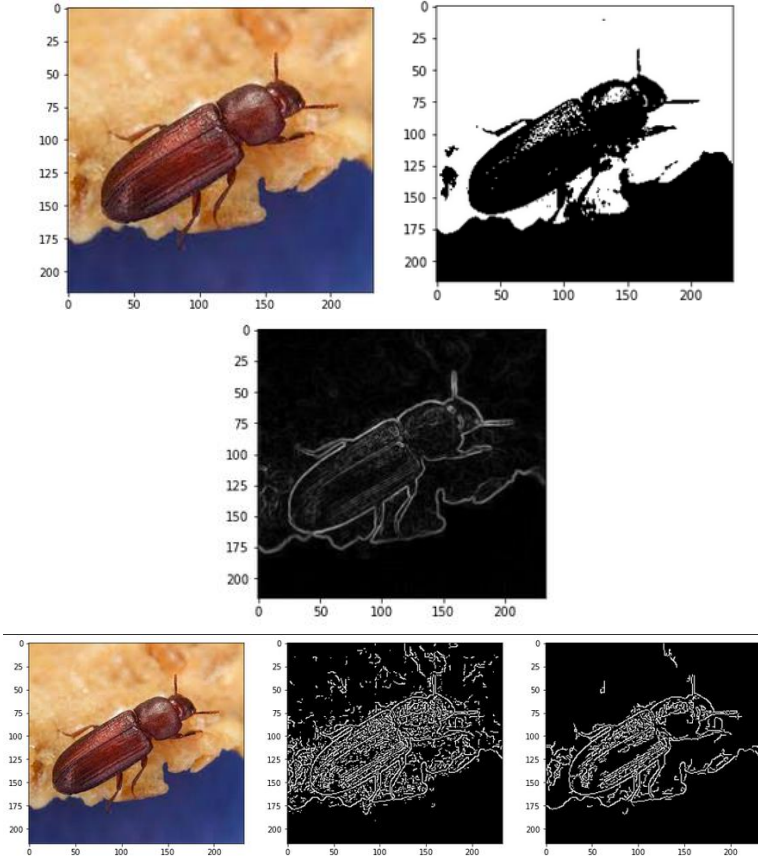
0 0.464602 0.520171 0.914454 0.946464

Şekil 4: Etiketlenmiş Verinin YOLO formatında koordinatları

### 3.2. Görüntü İşleme Modeli

Veri seti oluşturma işleminin tamamlanmasından sonra, sekonder zararlıların sınıflandırılması için bir yapay zekâ ve görüntü işleme modeli geliştirilmiştir. Geliştirilen model, toplanan veri setini kullanarak zararlıları otomatik olarak sınıflandırmak için eğitilmiştir. Şekil 5' te toplanan görüntüler üzerinde yapılan ön işleme örneği gösterilmektedir.





Şekil 5. Ön İşleme

Veri setindeki görüntüler, modelin işleyebileceği uygun boyutlara getirilmiştir. Bu adım, görüntülerin boyutlarının aynı olmasını sağlar ve modelin tutarlı bir şekilde çalışmasına yardımcı olur. Örneğin, görüntüler 416x416 piksel boyutuna ayarlanmıştır.

Görüntülerin renk kalitesi ve kontrastı, eğitim sürecindeki tutarlılık için düzeltilmiştir. Renk düzeltme işlemi, görüntülerin doğal renklerine yakın hale getirilmesini sağlar. Ayrıca, görüntülerin piksel değerleri normalizasyon işlemine tabi tutulmuştur. Bu adım, görüntülerin piksel değerlerini belirli bir aralığa sıkıştırarak işleme kolaylığı sağlamaktadır.

Görüntülerde bulunan parazitler, modelin doğru sınıflandırma yapabilmesi için temizlenmiştir. Bu adım, görüntülerin üzerindeki gürültüyü azaltarak modelin daha keskin ve doğru sonuçlar üretmesini sağlar. Gürültü azaltma teknikleri, parazitlerin filtrelenmesi veya giderilmesi işlemlerini içerir.

Gerçekleştirilen işlemlere veri augmentasyonu ile devam edilmiştir. Veri augmentasyonu, görüntü veri setine çeşitlilik kazandırmak için veri augmentasyon teknikleri uygulanmıştır. Örneğin, görüntüler üzerinde döndürme, yatay veya dikey simetri, zoom, kesme gibi işlemler uygulanarak veri seti genişletilmiştir.

Veri augmentasyonundan sonra veri normalizasyonu işlemine geçilmiştir. Veri normalizasyonu, görüntülerdeki piksel değerlerini belirli bir aralığa getirmek için yapılan bir işlemdir. Bu adım, modelin daha iyi bir şekilde öğrenme yapmasını ve daha hızlı bir şekilde konverjans elde etmesini sağlar. Örneğin, piksel değerleri  $[0, 1]$  aralığına normalize edilmiştir.

### 3.3. Öznitelik Çıkarımı

Veri setindeki görüntülerden elde edilen öznitelikler, görüntü işleme barındıran yazılım uygulamaları için büyük önem taşımaktadır (Coşkun ve Demirhan, 2022). Bu amaçla, görüntüler üzerinde çeşitli görüntü ön işleme teknikleri uygulanmaktadır, örneğin renk uzayı dönüşümleri, boyutlandırma ve filtreleme gibi işlemler gerçekleştirilmektedir. Bu ön işleme adımları, görüntülerin daha uygun hale getirilmesini sağlar. Görüntü tespiti ve sınıflandırması için ise öznitelik çıkarma teknikleri veya algoritmaları kullanılmaktadır (Tiobe, 2022), (Şehirli, 2018). Öznitelik çıkarma, görüntüler hakkında bilgileri temsil edebilecek özelliklerin elde edilmesini sağlar. Özellik çıkarma, medikal görüntü işleme uygulamalarında da büyük fayda sağlar. Bu teknikler, görüntülerin istenilen özelliklerini daha düşük boyutlu bir uzayda temsil ederek, depolama alanını optimize eder ve algoritmanın işlem süresini azaltır (Coşkun ve Demirhan, 2022). Öznitelik çıkarma yöntemlerinin temel amacı, orijinal verilerden elde edilen en uygun bilgiyi daha düşük boyutlu bir uzayda temsil etmektir (Coşkun ve Demirhan, 2022). Büyük veri kümeleriyle çalışıldığında, girdi verileri çok büyük olduğu için öznitelik çıkarma yöntemleri kullanılmaktadır. Bu yöntemler, girdi verilerini daha sıkıştırılmış bir formda temsil ederek, işlem süresini optimize etmeye yardımcı olur. Öznitelik çıkarma yöntemleri arasında yaygın olarak kullanılanlar şablon eşleştirme, deforme edilebilir şablonlar, kontur profilleri, spline eğri yaklaşımı ve gabor gibi yöntemlerdir (Coşkun ve Demirhan, 2022).

### 3.4. Model Eğitimi

#### 3.4.1. Roboflow ile Veri Setinin Hazırlanması

Gerçekleştirilen çalışmada, veri setinde yer alan görüntüler ve ilgili etiketler, modelin girdi ve çıktılarını belirlemek için kullanılmıştır. Model, derin öğrenme algoritmaları ve konvolüsyonel sinir ağları gibi yapay zekâ tekniklerini kullanarak eğitilmiştir.

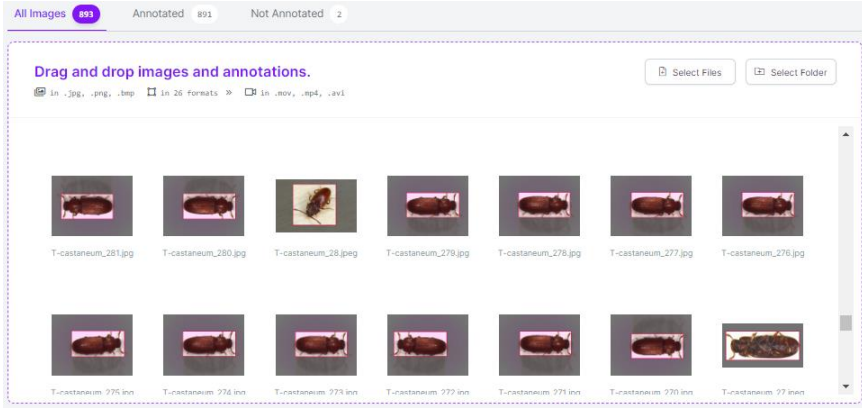
Bu çalışmadaki veri seti, eğitim seti, doğrulama seti ve test seti olarak 3 gruba ayrılmıştır. Eğitim seti geliştirilirken kullanılan ortam değişkenleri Tablo 1’de gösterildiği gibidir.

RAM	8 GB
CPU	Intel(R) Core(TM) i5-8265U CPU @ 1.60GHz 1.80 GHz
Geliştirme Ortamı	Google Colab, Jupyter Notebook
Programlama Dili	Python
Model	YOLOv5

Tablo 1: Ortam Değişkenleri

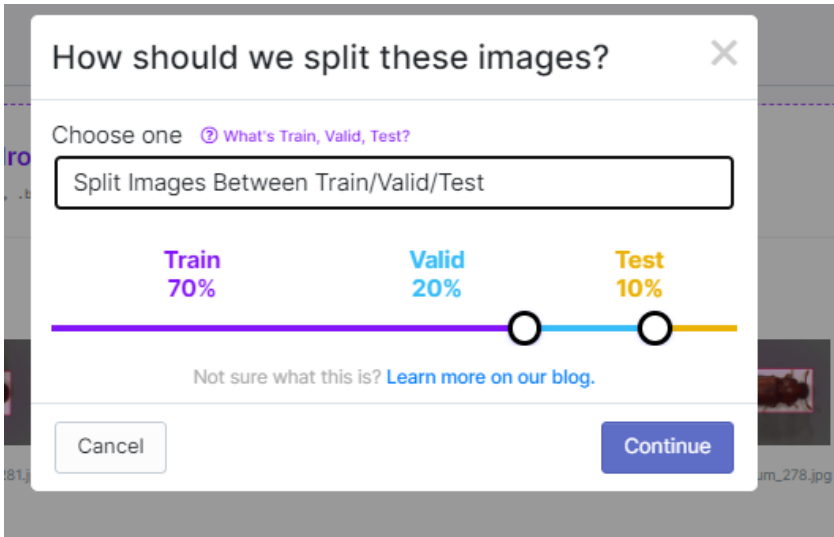
Model eğitime işleminde ayrıca Roboflow platformu kullanılmıştır. Roboflow, bilgisayarlı görü (computer vision) projeleri için kullanılan bir platformdur. Geliştiricilere, görüntüleri işlemek, etiketlemek ve model eğitimi yapmak için kullanabilecekleri araçlar sunar. Roboflow, görüntü veri setlerini işlemenin ve kullanmanın karmaşıklığını azaltmayı hedefler ve görüntü tabanlı projelerin geliştirme sürecini hızlandırmayı amaçlar.

Makesense.ai’de etiketlediğimiz verileri YOLOv5 formatında indirdikten sonra, Roboflow hesabına yükleyerek tekrardan etiketleme işlemine gerek kalmadan kullanılabilir. Bu, görüntü veri setlerinin düzenlenmesini, veri artırma tekniklerinin uygulanmasını, etiketlerin kontrol edilmesini ve eğitim için kullanıma hazır hale getirilmesini sağlar. Şekil 6’ da Etiketlenen verilerin Roboflow’ a yüklenmesi gösterilmektedir.



Şekil 6. Etiketlenen Verilerin Roboflow'a Yüklenmesi

Görüntülerin yüklenmesinden sonra, otomatik ayrıştırma yöntemi kullanılmış ve verilerin %70'i eğitim, %20'si doğrulama ve %10'u test verisi olarak ayrıştırılmıştır. Şekil 7' de söz konusu işleme ait ekran görüntüsü gösterilmektedir.



Şekil 7. Verisetinin Train/Test/Valid Ayrılması

Veri seti oluşturulduktan sonra bazı ön işleme teknikleri uygulanarak görseller üzerinde bazı işlemler gerçekleştirilmiştir. Bütün resimlerin boyutu 416x416 olarak değiştirildi. Parlaklık, doygunluk, pozlama değerleri verilerek

resimlerin daha belirginleştirilmesi amaçlanmıştır. Bu işlemlerden sonra veri seti model eğitiminde hazır hale gelmiştir. Modeli eğitirken kullanılacak yöntem seçilerek Roboflow'un sağladığı colab dosyasıyla veriseti kolayca eğitilebilmektedir.

### 3.4.2. Google Colab ile Modelin Eğitimi

Roboflow'da hazırlanan colab dosyası, Colab Notebook üzerine indirilir. Bu adımda, veri setinin dosyaları da wget veya requests gibi araçlar kullanılarak indirilir ve Colab Notebook'a aktarılır. Daha sonra YOLOv5s modeli, veri kümesi üzerinde eğitilir. Görüntü boyutu 416x416 olarak, batch boyutu 16 olarak ayarlanır. Sonuç klasörünün adı 'yolov5s\_results' olarak belirlenip, önbellek kullanılarak eğitim hızlandırılır. Daha sonra TensorFlow kullanılarak YOLOv5 performansı ölçülür. Bunun için TensorFlow'un görselleştirme aracı olan TensorBoard'dan yararlanır. Şekil 8' de başarılı bir şekilde geliştirilen modelin test edilmesine ait ekran görüntüsü gösterilmektedir.



Şekil 8: Geliştirilen modelin test edilmesi

### 3. ARAŞTIRMA BULGULARI

Bu bölümde, gerçekleştirilen çalışmadan elde edilen bulgular ve bu bulguların analizini ayrıntılı bir şekilde sunulacaktır. Ayrıca, algoritmalar arasındaki karşılaştırmalar yapılacak, sonuçların değerlendirilecek ve gelecekteki çalışmalar için öneriler sunulacaktır. Tablo 1' de farklı sınıflandırma algoritmalarından elde edilen başarı oranları gösterilmektedir.

	1	2	3	4	5	Ortalama
K-Nearest Neighbors (KNN)	0.86	0.81	0.87	0.82	0.83	0.84
Decision Tree Classifier (DTC)	0.78	0.78	0.81	0.81	0.79	0.8
Support Vector Machine (SVM)	0.86	0.78	0.83	0.82	0.78	0.82
Random Forest Classifier (RFC)	0.86	0.85	0.89	0.85	0.84	0.86

Tablo 2: Farklı sınıflandırma algoritmaları sonuçları

Bu çalışmada, KNN, DTC, SVM ve RFC algoritmalarının performansını değerlendirmek için doğruluk oranı, hassasiyet, özgünlük ve duyarlılık gibi performans metrikleri kullanılmıştır. Tablo 2'de söz konusu algoritmalarından elde edilen 5 farklı sınıflandırma işlemi sonuçları ve bu sonuçların ortalamaları gösterilmektedir.

Doğruluk oranı metriği, bir algoritmanın doğru sınıflandırılan örneklerin oranını ölçmektedir. RFC en yüksek doğruluk ortalamasına sahiptir (%0,86) ve diğer algoritmaların önünde yer almaktadır. KNN (%0,83), SVM (%0,82) ve DTC (%0,8) algoritmaları da orta düzeyde performans göstermiştir. Linear Regression (LR) algoritmasının ise bu metrik için verilerin yetersizliği nedeniyle sonuçları hesaplanamamıştır.

Hassasiyet ve özgünlük metrikleri, sınıflandırma modelinin doğru pozitif ve doğru negatif sonuçları ne kadar iyi ayırt ettiğini ölçer. RFC, KNN ve SVM algoritmaları bu metriklerde benzer bir performans sergilemiştir, ancak RFC daha yüksek hassasiyet ve özgünlük değerlerine sahiptir. DTC algoritması ise diğer algoritmalara göre daha düşük bir performans göstermiştir.

Duyarlılık metriği, bir sınıflandırma modelinin doğru pozitif sonuçları ne kadar iyi yakaladığını ölçer. RFC en yüksek duyarlılık değerine (%0,89) sahipken, diğer algoritmalar daha düşük duyarlılık değerlerine sahiptir. Bu sonuç, RFC'nin pozitif sınıfları daha etkili bir şekilde sınıflandırabildiğini göstermektedir.

Elde edilen bulgulara göre, RFC'nin en yüksek doğruluk, hassasiyet, özgünlük ve duyarlılık değerlerine sahip olduğu görülmüştür. Bu sonuçlar, RFC algoritmasının veri setindeki sınıflandırma görevini en iyi şekilde gerçekleştirebildiğini ve diğer algoritmalarından daha iyi tahminler yapabildiğini göstermektedir. KNN ve SVM algoritmaları, orta düzeyde performans göstermelerine rağmen, RFC'nin gerisinde kalmışlardır. KNN algoritması, komşuların etkileşimi kullanarak sınıflandırma yapar ve bu durum bazı durumlarda doğru sonuçları etkileyebilir. SVM algoritması ise, sınıflandırma işlemini gerçekleştirmek için bir hiper düzlem oluşturur ve bazen verilerin karmaşıklığına uyum sağlamada zorluklar yaşayabilir. DTC algoritması, diğer algoritmalara göre daha düşük performans göstermiştir. Bu durum, ağaç tabanlı algoritmanın sınıflandırma işleminde daha az esneklik gösterdiğini ve veri setindeki özellikler arasındaki ilişkileri tam olarak yakalayamadığını gösterebilir.

#### **4. SONUÇLAR**

Bu çalışma, depolanmış hububat ve mamullerinde meydana gelen zararlara yönelik yapay zekâ ve görüntü işleme tekniklerinin kullanımını ele almaktadır. Veri seti oluşturma aşamasında kendi imkanlarımızla elde ettiğimiz görüntüler üzerinde gerçekleştirilen sınıflandırma süreci, KNN, SVM, DTC ve RFC algoritmalarını içermektedir. Elde edilen sonuçlar incelendiğinde, en yüksek doğruluk oranının %86 ile Random Forest sınıflandırıcısından (RFC) geldiği görülmüştür. Bu sonuçlar, depolanan hububat ve mamullerinde zararlıların teşhisi için yapay zekâ tabanlı yöntemlerin etkili bir şekilde kullanılabileceğini göstermektedir. Gerçekleştirilen çalışma ayrıca, tarım ve gıda endüstrilerinde zararlı kontrolüne yönelik yeni perspektifler sunarak, yapay zekâ ve görüntü işleme tekniklerinin uygulama potansiyelini vurgulamaktadır.

## KAYNAKLAR

- Cambron, N.C., Cad System For Lung Nodule Analysis, B.S., University Of Louisville, Yüksek Lisans Tezi, 2011.
- Coşkun, U. A., & Demirhan, A. (2022). Farklı Çiçek Türlerini Derin Öğrenme Yöntemi İle Tanıma. Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 24(70), 55-64.
- "Internet: Tiobe (Programlama Topluluğu Endeksi)", <https://www.tiobe.com> (2022).
- Şehirli, E., 2018., "A Fully Automated Application For Analysis And Quantification Of Dna Damage On Comet Assay Images", Karabük Üniversitesi, Bilgisayar Mühendisliği Doktora Tezi.





## BÖLÜM 9

### GEÇMİŞTEN GELECEĞE: WEB 1.0 – WEB 4.0

<sup>1</sup>Mehmet Ali ŞİMŞEK

<sup>2</sup>Erdal KILIÇ

DOI: <https://dx.doi.org/10.5281/zenodo.10396257>

---

<sup>1</sup> Tekirdağ Namık Kemal Üniversitesi, TBMYO, Bilgisayar Teknolojileri Bölümü, Tekirdağ, TÜRKİYE. ORCID: 0000-0002-6127-2195

<sup>2</sup> Tekirdağ Namık Kemal Üniversitesi, TBMYO, Makine ve Metal Teknolojileri Bölümü, Tekirdağ, TÜRKİYE. ORCID: 0000-0001-8212-5533



## 1.GİRİŞ

Teknolojinin logaritmik olarak artış göstermesi bilgi miktarındaki hızlı büyüme, bilgi erişimiyle ilgili sorunların artmasına ve çeşitlenmesine yol açmaktadır. Kullanıcıların istedikleri bilgiye erişmeleri, büyük bilgi yığınları içinde giderek zorlaşmaktadır. Bilgi erişimi, kapsamlı veri kümelerinden elde etme, organize etme, kataloglama, kaydetme, inceleme, sorgulama ve istenen bilgiyi üretme veya sunma sürecidir (Aldemir & Oğuz, 2006). Bu sürecin sağlıklı bir şekilde işlemesi önemlidir. Bu sürece katkı sağlamak için arama motorları gibi çeşitli araçlar tasarlanmaktadır. Ancak, mevcut sistemlerin ve tasarlanan araçların yeterli olmadığı gözlemlenmektedir.

Günümüze kadar gelen web teknolojileri; web 1.0, web 2.0 ve web 3.0 olarak isimlendirilmektedir. Web 3.0 aynı zamanda Semantik web olarak da isimlendirilmektedir. Henüz literatüre yeni yeni girmeye başlayan dördüncü nesil web teknolojileri olarak web 4.0 bulunmaktadır.

Web 1.0, internetin ilk yıllarında kullanılan, statik web veya birinci kuşak web olarak da bilinen bir terimdir. Bu dönemde, ziyaret edilen web sayfalarından sadece bilgi edinilebilirdi. Web sayfasını tasarlayan kişiler, ziyaretçilerin sadece belirlenen içerikleri okuyabildiği statik bir yapı oluştururdu. İnternet ortamında yayımlanan içeriklerin dinamik olarak bulunmaz ve içerik sunucuları, içeriklerini kendi istedikleri gibi sunarlardı. Kullanıcı istekleri gün geçtikçe arttığından web 2.0'a geçiş başladı.

Web 2.0 döneminde, insanlar sadece kullanıcı olmanın ötesine geçerek paylaşım yapabilir, yorumlayabilir ve değerlendirebilir hale geldiler. Web 2.0 teknolojilerinin gelişmesine sosyal ağlar, YouTube, Wikipedia gibi sitelerin öncülük ettiği söylenebilir. Bu dönemde, internet içeriği artık sadece site yöneticileri tarafından değil, aynı zamanda kullanıcılar tarafından içerik oluşturma, güncelleme, yorumlama ve değerlendirme yapılabiliyordu. Günümüzde bile hala varlığını sürdüren bir teknoloji trendidir.

Anlamsal ağ, Web 3.0 ile yazılımların istenilen yüksek kaliteli içeriğe daha hızlı ulaşmasını ve bu içeriği öne çıkarmasını ifade eder. Bu durum, semantik web tarzına uygun yazılmış içeriklerin diğer içeriklere göre bir adım öne çıkmasına olanak tanır.

İstenilen kaliteli içeriğin oluşmasında anlamsal ağın temelini oluşturan ontoloji kavramı yatmaktadır. Ontoloji, varlık bilimi ve aralarındaki ilişkilerin tanımlanması anlamına gelmektedir. Semantik alanda ontoloji ise site

içerisindeki tüm anahtar kelimelerin birbirlerine anlamları ile birlikte ilişkilendirilmesidir. Bu ilişki sonucu daha net sorgular sorgulanabileceğinden dolayı istenilen bilgi karşımıza gelebilmektedir.

Anlamsal ağ teknolojisi bir web teknolojisi gibi görünmüş olmasına rağmen web teknolojilerinden farklı kullanım alanlarında vardır.

Web 4.0, web teknolojilerindeki evrimin devamı olarak değerlendirilebilir; ancak bu terim henüz net bir tanıma sahip değildir (Ersöz, 2020). İlerleyen süreçte web teknolojilerine katkısını hep birlikte göreceğiz.

## **2. WORLD WIDE WEB**

İnternet, dünya çapında bağlantılı bilgisayarlarla oluşturulan bir ağıdır ve kullanıcılara TPC/IP protokol kümesi üzerinden çeşitli uygulamalar sunmaktadır.

İnternette en çok kullanılan arayüz olan World Wide Web (WWW) veya kısaca Web, tarayıcı programlar aracılığıyla kullanıcılara metinlerin yanı sıra görüntü, ses ve video gibi çoklu ortam içeriklerine erişim imkanı sunar. Bir başka deyişle; video, film, animasyon yazı gibi verileri bir bilgisayardan başka bir bilgisayara çağrılmasıdır. İnternet ile web aynı şeyler değildir. Web internet üzerinde çalışan bir servistir.

Farklı türden verileri aynı yapı içerisinde son kullanıcıya sunan bilgisayar programlarına Web Browser ya da Web tarayıcılar denir. Web ortamı kamuya açık olup, web tarayıcı gibi farklı yazılımlara bağlı değildir. Bu nedenle birçok web tarayıcısı mevcuttur.

İnsanlık tarihinin en önemli başarılarından biri, her yerde yaygın hale gelen World Wide Web(www) denilebilir. Günümüzde tüm insanlık bilgi arama ve paylaşımı için WWW'yi kullanmaktadır. Web'in bu kadar etkileyici olmasında, verilerin dağınık yapıda bulunması, dinamik olması, çok büyük verileri barındırması, kamuya açık olması gibi nedenler yatmaktadır (Kurtel, 2008):

World Wide Web, 1991 yılındaki başlangıcından bu yana yaygın olarak kullanılmakta ve internette hızla yayılmaktadır. Bu hızlı genişleme, bilgi paylaşımı gereksinimine, web sayfaları oluşturma ve yayınlama kolaylığına ve bu sayfalara hızlı ve uygun maliyetle erişilebilmesine bağlanabilir (Karademirci,2008).

Web ortamında bilgi yoğun bir şekilde üretilmekte ve erişilmektedir. Gün geçtikçe internete erişimin ve kullanımın artması içerik üreticilerin de artmasına sebep olmuştur. Dört bir yanındaki bilgi üreticileri sayesinde, milyonlarca sayfalık çeşitli biçimlerde, dillerde ve içeriklerde dokümanlar internette mevcuttur. Bu dokümanlar kullanıcılar tarafından kullanılmayı beklemektedir. Bilginin önemi ve miktarı bu süreçte artmaktadır (Kurtel, 2008).

Web sayfaları zamanla eskir ve değiştirilmesi gerekebilir. İçeriklerin sık sık değiştirilmesi gerektiğinde ortaya çıkan yönetim zorlukları, web yapısının daha da geliştirilmesine yol açmıştır.

Web teknolojisi üzerinde yaşanan başka bir sıkıntı ise, web üzerinde artan bilgilerin bilgisayar tarafından yorumlanması isteğiydi. Artan bilgiler, oluşturulan sayfaların zamanla değiştirilme isteği, var olan bilgilerin bilgisayar tarafından değiştirilmesi isteği web' in gelişimine zemin hazırlamıştır.

Web'in tarihçesi, Web 1.0, Web 2.0 ve Web 3.0'ın yapı ve teknolojik gelişimini içerir. Günümüzde yeni bir paradigma olarak Web 4.0'dan söz edilmeye başlanmıştır. Bu numaralandırma, resmi bir temele dayanmasa da web kavramının evrimini anlatmak için kullanılır ve anlatımı somutlaştırmak için uygun olabilir.

Web 1.0 olarak bilinen ilk kuşak web, bilgilerin World Wide Web üzerinde takip edilmesi için genellikle el ile HTML sayfaları oluşturuluyordu. İkinci kuşak web, HTML sayfaları bilgisayarlar tarafından otomatik olarak oluşturulmaya başlandı. Bu noktada, birçok kişi için bu durum yeterli kabul edilirken web'in olgunluk dönemi olarak kabul edilmektedir. Web 3.0 olarak adlandırılan teknoloji, Semantik web veya anlamsal ağ olarak bilinir ve etkin kullanımı daha da artacağı düşünülmektedir.

## **2.1. Web 1.0 (Statik Web)**

Web 1.0, web teknolojilerinin başlangıç aşamasını temsil eder. İnternet kullanıcılarının, bilgiye doğrudan kaynaklardan erişebildiği bir dönemi ifade eder. Herkesin istediği zaman internet üzerinden bilgi arayıp okuyabileceği, sadece okunabilir bir web sistemi olarak adlandırılan yapı Web 1.0 olarak bilinir(Özden, 2022).

Web 1.0, genellikle statik web veya birinci kuşak web olarak da adlandırılır ve internetin ilk yıllarında kullanılmıştır. Bu dönemde, ziyaret edilen sitelerden sadece bilgi alınabilir ve siteyi tasarlayan kişilerin yerleştiği

içerikler ziyaretçiler tarafından okunabilirdi. Web'in dinamik bir yapısı bulunmuyordu ve içerik sunucular, içeriklerini kendi istedikleri gibi sunulmaktaydı.

Web 1.0, statik içerikli sayfalar, animasyonlu imgeler, çerçeve kümeleri veya frameset'ler ve misafir defterleri içerir. Kullanıcıların sahip oldukları kaynaklar ve bilgiler başkaları tarafından değiştirilebilir özellikte değildir. Sadece web ortamında paylaşılabilir. Şekil 2.1'de görülen sayfanın değiştirilebilir bir özelliği yoktur; sadece görsel paylaşım özelliğine sahiptir (Kazandır, 2011).



Şekil 2.1. Web 1.0 örneği.

Web 1.0, insanlara bilgi sunmuştur. Siteyi tasarlayan kullanıcının oluşturduğu sayfalar arasında gezinmesiyle sınırlıdır. Kullanıcının site içerisine katkıda bulunamazdı.

Süreç içerisinde internet ve web kullanımının artması, kullanıcı isteklerinin tam anlamıyla karşılanamamasına sebep olmuştur. Sunulan içeriğin yetersizliği, kullanıcılarında web üzerinde statik yapıdan kurtulup paylaşım yapma isteği Web 2.0'ı doğurmuştur.

## 2.2. Web 2.0 (Dinamik Web)

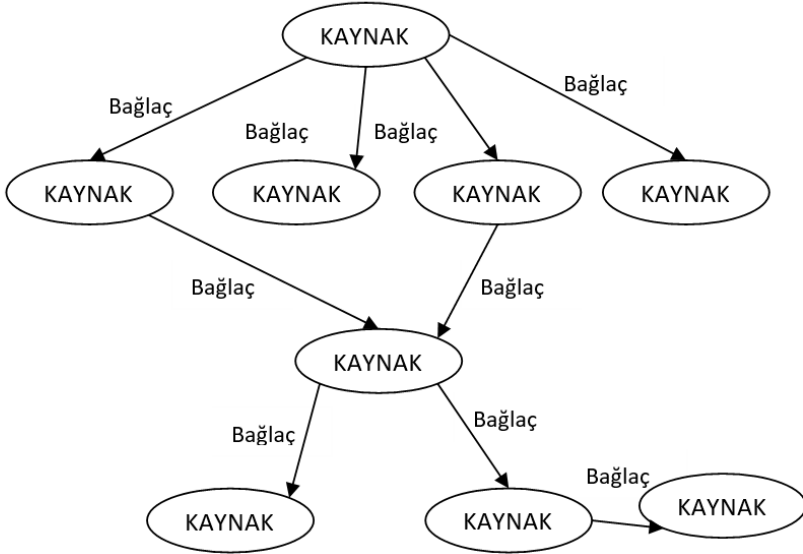
2004 yılında Dale Dougherty web 2.0'ı 1990'larda geliştirilen Web 1.0 versiyonunun evrimi olarak tanıtmıştır. Web 2.0, daha dinamik ve interaktif web deneyimleri sunan WWW'nin ikinci neslidir(Permatasari et al., 2020). Bu süreç içerisinde insanlar sadece kullanıcı olarak değil, aynı zamanda yorumcu, değerlendirici ve web içeriğine katkı sağlayıcı olarak da aktif hale gelmiştir. Sosyal ağlar, video paylaşım sistemleri gibi siteler Web 2.0'in öncülerinden olmuştur. Web 2.0 döneminde, site kullanıcıları artık web yöneticilerinin yerine içeriği oluşturmaya, değerlendirmeye ve yorumlamaya başladılar. Ek olarak, Web 2.0 dönemi, içeriğin çeşitli platformlara dağıtıldığı bir çağa da tanıklık etti. Sadece masaüstü bilgisayarlar değil, akıllı cihazlar ile de internete erişim sağlamaya başlandı.

Web 2.0 teknolojisini Web 1.0 teknolojisinden ayıran en önemli nokta kullanıcıların katılımıdır. Kullanıcı Web 2.0 da olduğu gibi sadece içeriği okuyabilen kullanıcılar değil, içeriğe katkı sağlayan bilen, geliştiren bilen aktif bir katılımcıdır. Bu yüzden Web 2.0'in diğer bir adı da dinamik web'tir.

Web 2.0 daha güzel tasarımlı siteleri de beraberinde getirdi. Artık sabit görünümün yanı sıra kullanıcıya göre değişebilen, içerisinde pek çok multimedya bileşenlerinin de barındırıldığı sistemleri görmek mümkündür. İçerik göstermenin yanı sıra programlamanın da yapılabildiği sitelerdir. Sosyal medya ortamları, web güncelleri(bloglar), video izleme siteleri, fotoğraf paylaşım siteleri Web 2.0'in doğuşuyla ortaya çıkmıştır.

Web 2.0'da veriler büyük veri tabanları içinde sunucularda saklanır. Sunucular üzerinde çalışan programlar, çevrim içi dokümanlara yapılan sorguları görsel olarak geri döndürerek sadece "insan anlamlandırmasına" yönelik olan çevrim içi dokümanları görsel olarak geri döndürürler. Kullanıcı, sorgu sonucunda "bilgi" yerine "doküman kümesi" alır ve aradığı probleme ait cevabın doküman kümesi içerisinde olup olmadığını bilmeden anlama ve analiz sürecine girer. Şekil 2.2, Web 2.0 kaynaklarının birbirleriyle olan ilişkilerini anlama yeteneğini göstermektedir.(Kazandır, 2011).





Şekil 2.2. Web 2.0 kaynaklarının birbirleriyle olan ilişkileri.

Arama motorları kullanılarak yapılan anahtar kelimeye dayalı sorgulamalarda, milyonlarca web sayfası arasında aranılan bilgiyle ilgili çok sayıda eşleşme ortaya çıkabilir. Bu durum, arama sonuçları içerisinde hangilerinin kullanıcının ihtiyaçlarına uygun olduğunu belirlemeyi zorlaştırır. Eksik tanımlanan arama kriterleriyle yapılan sorgulamalarda bilgiye erişim mümkün olmayabilir gelen bilginin ne olduğu anlaşılmaz. Sorgulama fazla arama kriterleriyle daraltıldığında ise kişi karşısına herhangi bir bilgi kümesi çıkmayabilir. Diğer bir husus ise bulunan bilgilerin doğruluğudur (Kurtel, 2008). Aranılan bilgi kaynakları arasındaki bağlaçların sayısı kadar geriye bilgi kümesi olarak gelmektedir. Web 2.0'ın yetersiz kaldığı yerlerden birisidir.

Çevrim için alışveriş işlemlerinde yaşanan sorunlarda örnek olarak verilebilir. Web üzerinde alışveriş yapan bir kişi, alacağı ürünün kodunu, fiyatını ve ürünün resmini görebilir, deneyimi ve bilgisi sayesinde birden fazla bilgiyi doğal bir şekilde eşleştirebilir ve bu bilgilerden hızla yeni bilgiler çıkarabilir. Ancak bilgisayar benzer eşleştirmeyi ve çıkarsamayı gerçekleştiremez. Bunun nedeni, bu bilgilerin HTML açısından metin ve resim dosyalarından oluşması ve aralarında anlamsal bağların bulunmamasıdır (Kurtel, 2008).

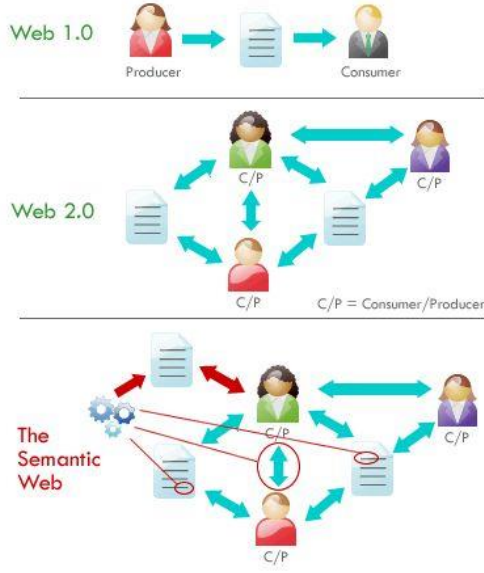
Web 2.0 teknolojisinde eksik kaldığı yerler çoğaltılabilmektedir. Web 3.0 kavramı Web 2.0'nin eksikliğinden orta çıkmış ve web teknolojisinin daha ileriye götüreceği çalışmalar bütünüdür.

### 2.3. Web 3.0 (Semantik Web)

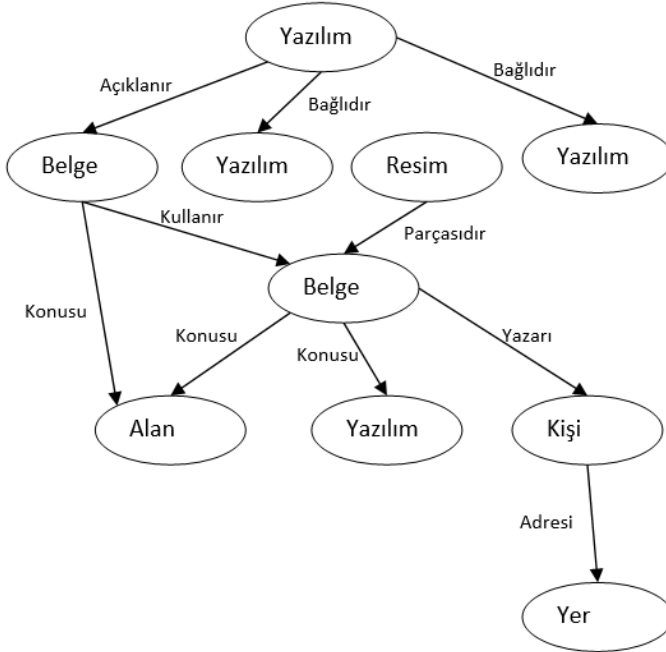
Anlamsal Web veya Web 3.0 olarak da bilinen Anlamsal Web, kullanıcının kontrolü dışında meydana gelen bilgisayarlar arasında bilgi iletişimini sağlamak için kullanılan teknolojilerden oluşur. İnsan merkezli-sosyal bir Web, bilgi yönetimini geliştirir (Kazandır vd., 2009). Anlamsal ağ, bir sayfanın tüm metnini paylaşmak yerine ihtiyaç duyulan bilgileri ve gerçekleri paylaşmayı ifade eder. Sir Tim Berners-Lee, 2001 yılında semantik web fikrini ortaya atmıştır (Berners-Lee et al., 2001; Patel & Jain, 2021).

Anlamsal Ağ kavramı, Web 3.0'un simgesi olarak ortaya çıkmıştır ve bu dönemde işlenen verinin bilgisayarlar tarafından daha iyi yorumlanabilmesi için yapılandırıldığı bir webi temsil etmektedir. Semantik web'in ortaya çıkmasına kadar olan süreçte, bilgisayarlar için web sadece dokümanlar, bu dokümanlardaki bağlantılar ve bu bağlantıların ucundaki diğer dokümanlardan oluşan bir zincirden ibaretti. Anlamsal Ağ fikri, verinin makineler tarafından daha kolay yorumlanabileceği bir biçimde depolanıp işlenerek, verinin daha hızlı ve erişilebilir hale geleceği tezini öne sürdü. Anlamsal Ağ'ın ortaya çıkışıyla birlikte, web artık sadece bir dokümanlar ağı (web of documents) olmaktan çıkarak gerçek bir veri ağı (web of data) haline geldi. Veri hakkında metadata kullanımı sayesinde bilgisayarlar, işledikleri verinin ne anlama geldiğini, başka hangi verilerle ne tür bağlantılara sahip olduğunu takip edebilir, mantıksal olarak yorumlayabilir ve yeni bağlantılar ile verilere ulaşabilir hale geldi(Battal, 2009).

Şekil 2.3, Web 1.0, Web 2.0 ve Web 3.0'ın aralarındaki karşılaştırmayı anlatılmıştır. Anlamsal ağ bilgi odaklı çalışmaktadır. Aranan bilgi neyse geriye o bilgi getirilmektedir. Şekil 2.4'te gösterildiği gibi Web 3.0 kaynakları birbirini tanıyabilmekte ve aralarındaki ilişkiyi anlayabilmektedir. (Kazandır, 2011).



Şekil 2.3. Web teknolojilerinin anlamsal kıyaslaması.



Şekil 2.4. Web 3.0 kaynaklarının birbirleriyle olan ilişkileri.

## 2.4. Web 4.0

Yeni bir paradigma olarak Web 4.0 ya da diğer adıyla Simbiyotik Web, makinelerin ve insanların etkileşim kuracağı, makinelerin internet üzerindeki içeriği anlamlandırma düzeyinde zeka geliştireceği web teknolojilerinin yeni nesline verilmesi düşünülen isimdir. Bu gelişim, performans ve hız açısından insanlara en üst düzeyde bilgiye erişim imkânı sunmayı amaçlamaktadır. Endüstri 4.0 alt teknolojilerinin Web 4.0 ile bağlantılarının gelişeceği düşünülmektedir(Choudhury, n.d.; Ersöz, 2020).

## 3. ANLAMSAL AĞ

Web veri tabanının genişlemesi ve karmaşıklığı hem bilgisayarların hem de insanların bilgiyi anlaması ve yorumlaması gerektiğini göstermiştir. Bilginin insanlar, bilgisayarlar ve çeşitli elektronik cihazlar tarafından anlaşılabilmesi için bütünlük bir yapının oluşturulması gerekmektedir.

Anlamsal ağın temel felsefesi, iyi tanımlanmış ve ilişkilendirilmiş bilgi ve hizmetlerin bilgisayarlar tarafından okunabilir ve anlaşılabilir olmasını sağlayan standartların ve teknolojilerin geliştirilmesidir. Anlamsal ağ yalnızca web sayfalarını kullanan bir insan-bilgisayar etkileşimi olmaktan öte, verinin bulunduğu diğer ortamları da içerir. Bu ortamlar, veri tabanları, hizmetler, programlar, çeşitli sensörler, kişisel cihazlar ve hatta ev içi uygulamalar gibi karmaşık bir yapıya sahiptir. (Süzen & Taşdelen, 2016; Tonta & Madran, 2009).

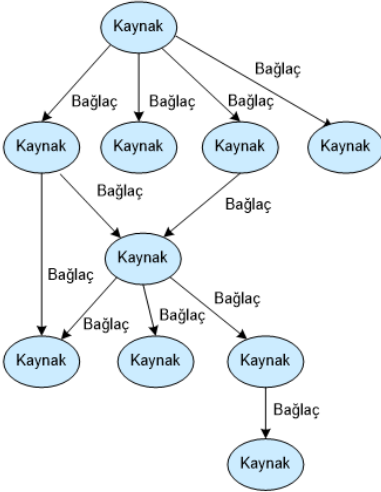
Oluşturulması planlanan yapı anlamsal ağ olarak adlandırılır. Anlamsal Ağ, web sayfalarının anlamlı içeriğini yapılandırmayı amaçlar. Bu yapılar, sayfalarca doküman üzerinde gezerek temsil ettikleri kullanıcıların yerine sofistike işlemler gerçekleştirebilen özerk yapıların en güçlü aday yazılım bileşenleridir. Anlamsal Ağ, Web 2'den tamamen farklı olmayıp, onun bir uzantısı olarak görülür. Bu yapıda bilginin düzgün bir şekilde tanımlanmış anlama sahip olduğu ve insanlar ile bilgisayarların birlikte çalışabildiği bir web ortamı hedeflenmektedir(Kardaş, 2008).

Anlamsal Ağ teknolojisinin temel amacı, makinelerin, insanlar gibi, Web üzerinde gösterilen bilgiyi okuma ve anlama yeteneği kazanmasını sağlamaktır. Anlamsal Ağ, anlamlı ve makineler tarafından anlaşılabilir bilgi kaynaklarına sahip olması nedeniyle hem otomatize edilmiş araçlar hem de insanlar


tarafından kullanıcıların paylaşım ve işleme ihtiyacını karşılamaktadır (Kazandır, 2011).

Web'in evrensel yapısı ve kaynaklar arasındaki bağlantı gücü, "her şeyin her şeyle bağlantılı olabileceği" temeline dayanır. Bu durumda, web teknolojisi, tamamlanmamış taslaklarla işlenmiş ve son hali verilmiş belgeleri, ticari bilgileri akademik bilgilerden ayırt edemez. Anlamsal web, bu ayrımları yapabilme yeteneği ile Web 2 ortamından ayrılır. Bu ayrım, web'deki verinin anlamsal yapılarının kullanılmasıyla sağlanır. Bu nedenle daha karmaşık ve daha iyi sonuçlar üreten sorgular yapılabilir ve insanlar kendi durumlarına ve ihtiyaçlarına en uygun verilere erişebilir. Özelleşmiş otomatik ajanlar, bu verileri ve bilgileri işleyecektir.

Şekil 3.1'de görünen günümüz web'in gereksinimleri yeni ihtiyaçları doğdurmuştur. Tim Berners-Lee bu ihtiyaçlara yönelik iki ana vizyon cümlesiyle şekillendirilmiştir; Şekil 3.2' de görüldüğü gibi "İlk olarak web, daha fazla birlikteliğin sağlanacağı bir ortam haline gelecektir, ikinci olarak da işlemlerin bilgisayarlar tarafından yürütülmesi ile web daha anlaşılır olacaktır"(Kurtel, 2008). Şekil 3.1 ve Şekil 3.2 incelendiğinde; günümüz web teknolojisindeki kaynaklar birbirlerine bağlı ama bu bağlantılar arasındaki ilişki türü belli değildir. Anlamsal ağ ile kaynaklar aralarındaki ilişki türüne göre birbirine bağlanmıştır. Bu da bilgisayarların kaynakları anlayıp ayırt edebileceği bir forma dönüştürmüştür. Şekil 3.2'de kaynaklar birbirlerine bu anlamlı bağ ile ilişkilendirildiği görülmektedir. Web 2.0 teknolojileri kullanılarak yapılan web aramaları ile, aranan konu ile ilgili sonuçları ve birbiriyle ilgisi olmayan sonuçları da görüntülerken, anlamsal ağ teknolojileri kullanılarak yapılan aramalar, aranan konu ile ilgili sonuçları görüntüler.



Şekil 3.1. Bugünkü ağ



Şekil 3.2. Anlamsal ağ

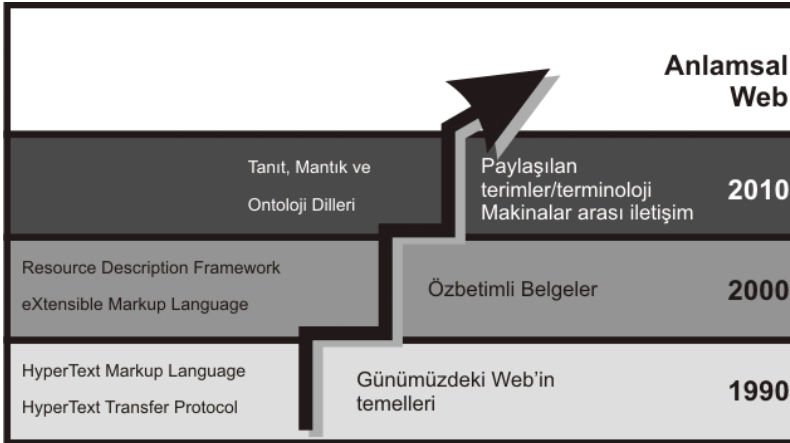
Anlamsal ağın uygulanabilmesi için verilerin birbirleri ile ilişkilendirilmesi gerekmektedir. Bunun için Ontoloji yapısı kullanılmaktadır. Anlamsal ağın uygulanabilmesi için verilerin birbirleriyle ilişkilendirilmesi gereklidir ve bu amaçla Ontoloji yapısı kullanılır. Ontoloji, belirli bir ilgi alanına ait terimlerin ve ilişkilerin açık ve formal tanımlamalarını içerir. Bu tanımlamalar, kavram ve kavram ilişkilerinin bilgisayarlar tarafından yorumlanabilir bir formda oluşturulması anlamına gelir(Dağ & Erkan, 2007).

Günümüzde, geleneksel yöntemlerle geliştirilen uygulamalarda sıklıkla karşılaşılan bir sorun, arama motorları üzerinden yapılan bir sorgulamada kullanıcının aradığı konu ile ilgili olmayan oldukça fazla sonuç gelmektedir. Anlamsal ağ ontolojileri kullanılarak oluşturulmuş arama motorlarında ise bu tür gereksiz bilgiler kullanıcının karısına gelmez. Kullanılan ontolojiler, kullanıcının bağlamına en uygun verilere odaklanmayı amaçlar. Örneğin, bir kullanıcı "ağaç" sorgusu yaptığında, bilgisayar bilimleri alanındaki "ikili ağaç veri yapıları" ile ilgili sonuçlarla biyoloji alanındaki ağaçlarla ilgili sonuçların bir araya gelmesi muhtemeldir. Ancak, kullanıcı eğer biyoloji ile ilgileniyorsa, "ağaç, biyoloji" şeklinde bir sorgu yaparak daha çok ve öncelikli olarak biyoloji alanıyla ilgili sonuçlarla karşılaşmalıdır(Türksoy, 2007).

### 3.1. Anlamsal Ağın Gelişimi

1990'ların başlarından itibaren web teknolojileri hızla gelişmeye devam ederek günlük yaşantımızı kolaylaştıran birçok yeniliği insanlığın hizmetine sunmuştur. Bu yenilikler arasında elektronik iletişim, bankacılık ve internet üzerinden yapılan alışveriş işlemleri öne çıkmaktadır. Bu işlemler sayesinde zaman alan günlük görevlerimiz daha hızlı ve kolay bir şekilde gerçekleştirilebilmektedir. Bu örneklerle sınırlı kalmayacağı açık olan bu gelişmeler, web teknolojilerinin gelecekte daha anlamlı hale getirilmesi için bir dizi yenilikçi çalışmayı tetiklemiştir (Yaşar, 2007).

Anlamsal ağın evrimi, adım adım ilerleyerek her aşamada bir öncekini güçlendirmektedir (Güney, 2009). Bu ağ, Şu Anda kullanılan web mimarisini geliştirmeyi hedefleyen ve World Wide Web Konsorsiyumu (W3C) tarafından yönetilen bir çabadır. Anlamsal web fikrini ilk ortaya atan makale, Berners-Lee tarafından 2001 yılında Scientific American dergisinde yayınlanmıştır. Bu çalışma, anlamsal ağın mevcut web'den ayrı bir oluşum olmadığını, ancak onun bir uzantısı olarak tanımlar. Anlamsal ağın mevcut web ortamını geliştirmeye yönelik ilk aşamasının, web ortamındaki veri ve dokümanların makineler tarafından "anlaşılabilir" hale getirilmesi olduğu belirtilmiştir (Kazandır, 2011). Şekil 3.3 de web teknolojilerinin tarihi gelişimi görülmektedir.



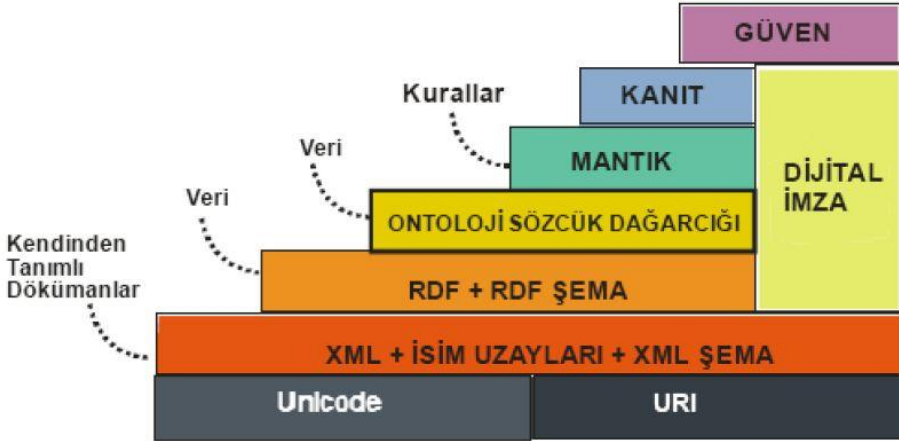
Şekil 3.3. Anlamsal Ağ'ın Gelişimi (Berners-Lee, 2001)

### 3.2. Anlamsal Ağ Mimarisi ve Bileşenleri

Anlamsal ağ, temel olarak felsefe, tasarım prensipleri, etkileşimli çalışma grupları ve yardımcı teknolojilerden oluşmaktadır. Bu unsurların, belirli bir problem uzayındaki kavramları, terimleri ve bağlantıları resmi bir biçimde ifade etmeleri beklenir. Anlamsal ağın temelini oluşturan unsurlar, bir nesneyi sınıflandırmayı ve ona doğru şekilde değer atamayı gerektirir. Semantik Web, W3C, Massachusetts Institute of Technology, Hewlett-Packard ve web topluluklarının belirlediği standartlara dayanmaktadır. Bu çerçevede, Resource Description Framework (RDF) kullanılarak XML sözdizimi ve URL'lerle birleştirilen birçok uygulama entegre edilmektedir (Eminoğlu, 2009).

Anlamsal Ağ'ın evrimi aşama aşama ilerlemektedir; her aşama, bir öncekine ek bir katman inşa etmektedir. Anlamsal Web'in kurucusu olarak kabul edilen Tim Berners-Lee tarafından sunulan katmanlı mimari, Şekil 3.4'te gösterilmektedir (Güney, 2009).

Son üç katman, RDF, OWL, SPARQL ve GRDDL gibi somut çıktıları içerecektir. "W3C" tarafından oluşturulan çalışma grupları tarafından bu konular üzerinde çalışmalar devam etmektedir (Eminoğlu, 2009).



Şekil 3.4. Anlamsal ağ katmanları (Güney, 2009)

Ontoloji katmanı, sözlüklerin kolay değişimini sağlar ve farklı kavramlar arasındaki ilişkileri tanımlar. Bu ontolojiler, birlikte çalışan uygulamalar için



paylaşılan ortak bir terminoloji sunar. Ontolojiler, veri yapıları, karmaşık ilişkiler ve bunların anlamlarını ortaya çıkarmak amacıyla kullanılır.

Dokümanlardaki değişiklikler, sayısal imza katmanı ile belirlenir ve bu katmanlar, W3C çalışma grupları tarafından standartlaştırılır.

Sekil 3.4'teki yapıda ontoloji katmanından bir üst seviyeye çıktığımızda mantık katmanı ile karşılaşırız. Bu katman, çıkarımların gerçekleştirilebilmesi için kuralların yazılmasını sağlar. Mantık katmanı, ontolojilere mantıksal kurallar ekleyerek, modelleme verileri arasındaki var olan ancak doğrudan anlaşılabilen ilişkilerin çıkarım motorları aracılığıyla ortaya çıkarılmasını sağlar.

Kanıt katmanı, kuralları uygular ve Güven katmanının mekanizması ile sağlanan kanıtların güvenilirliğini değerlendirir.

Bu teknolojinin tüm basamakları birbiriyle ilişkilidir. XML dışında, her birinin kendi içinde bir sınıf modeli bulunmaktadır. RDF (Kaynak Açıklama Çerçevesi), Anlamsal Ağ için temel veri modelidir. Bu model, farklı değişim formatları olan RDF/XML, N-Triples, N3 ve Turtle için temel teşkil etmektedir. Anlamsal Ağ'ın merkezinde Ontolojiler yer almaktadır. Bu nedenle OWL (Web Ontoloji Dili), tanımlamalar ve veriler arasındaki ilişkilerin kurulması için kullanılmaktadır.

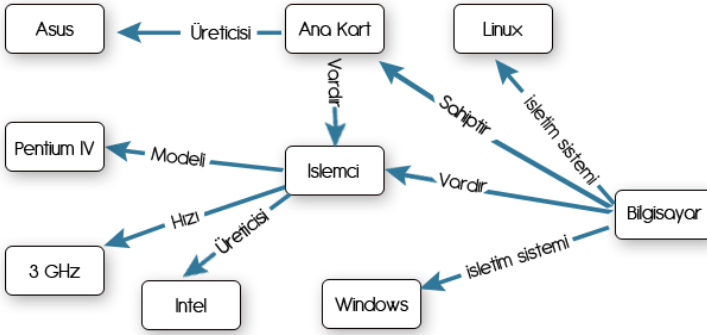
### **3.2.1. Ontoloji**

Anlamsal Ağ, ontolojilerin kullanılmasıyla gerçekleştirilebilir. Ontoloji terimi felsefede varlık bilimi olarak tanımlanmaktadır. Yirminci yüzyılın sonlarında ontoloji, yapay zekanın bir parçası olarak yaygın bir şekilde kullanılmıştır. Ontoloji, belli bir alandaki bilgilerin paylaşımını ve yeniden kullanılmasını sağlayan "kavramlaştırmaların biçimsel ve açık tanımlanması"dır. Ontolojilerin zeki sistemlerde kullanılması elektronik ticaret, doğal dil işleme ve bilgi yönetimi gibi konularda ontolojiler son zamanlarda popüler hale getirmiştir.

Ontolojinin bilgisayar bilimindeki en çok kabul gören Gruber'e (1993) ait olan tanımı; "kavramsallaştırmanın açıkça belirtilmesidir" şeklinde ifade edilmesidir. Kavramsallaştırma, belli bir tasarım aşamasında soyut model oluşturma anlamına gelir. Maedche ve Staab (Maedche & Staab, 2001)'e göre bu modelin, tasarım aşamasında bilinen tüm bilgilerinin geride hiçbir soru bırakmayacak şekilde açıkça tanımlanması gerekir.

Ontoloji, otomobil, sağlık, eğitim, ticaret gibi belirli bir konu hakkında bilgileri tanımlamak ve açıklamak için gerekli terimleri belirler. İnsanların, veri tabanlarının ve uygulamaların oluşturdukları alanlar hakkında bilgi paylaşmasını sağlar. Bu ontolojiler, alanları birbirinden ayıran bilgileri ayrıştırır.

Bir ontoloji, çalıştığı alanda varlıkların birbirleriyle nasıl ilişkili olduğunu tanımlar ve isimlendirir. Ontoloji, bir konuyla ilgili bilgiyi, o konuyla ilgili ilişkileri ve kullanıcılar arasında iletişimi sağlamak için bir sözlük oluşturur. Ontoloji, veri tabanları, dosya sistemleri, veri dosyaları ve diğer yapısal veya yarı-yapısal veri türlerinin mantıksal gösterimini sağlar. Ontoloji, bir fikri sözdizimi olarak tanımlamak yerine, onu ifade ettiği anlam balgamında açıklar. Bu ayrım, çeşitli veri kümeleri arasındaki net farklılıkları ortaya koymak için kullanılabilir. Bu nedenle, birbirine çok benzer veya kelime olarak aynı olan veriler birbirinden ayrıştırılır.(Karademirci, 2008).Ontolojileri geliştirmek için OntoEdit, Protege, RDFDB, OpenKnoME gibi araçlardan yararlanılmaktadır. Bilgisayar donanımı alanında oluşturulmuş basit ontoloji yapısı Şekil 3.5’de görülmektedir. Ontoloji oluşturmak için OWL, RDF, SWRL, SPARQL, vb. sorgulama dillerine ihtiyaç duyur(Rhayem et al., 2020).



Şekil 3.5. Bilgisayar donanımı alanında örnek bir ontoloji

RDF (Resource Description Framework): RDF, W3C tarafından geliştirilen bir dil olarak, meta veri tanımlamalarının ve kullanımlarının standartlaştırılması için XML yapısının üzerine inşa edilmiştir. Bu dille web kaynaklarının tanımlanması, bilgisayarlar tarafından anlaşılabilir bir şekilde meta veri standartları içeren bir veri modeli oluşturulmaktadır. RDF, XML

uygulamaları için standartlar oluşturarak entegrasyon ve haberleşme süreçlerini kolaylaştırmaktadır (Karademirci, 2008).

**RDF schema(RDFS):** RDF Schema, genellikle RDF için bir tür sistemini sağlar. RDF Schema sayesinde kaynaklar; sınıflar, özellikler ve değerler ile tanımlanabilir. RDF Schema'daki sınıf özellikleri, nesneye yönelik programlama dillerinde olduğu gibi işlev gösterir. Bir sınıf, benzer varlıkların yapısal oluşumunu temsil eder ve bu oluşum miras özelliklerine izin verir.

**OWL (Web Ontology Language):** Web Ontology Language (OWL), ontolojileri tanımlamak ve çeşitlendirmek için kullanılan bir dildir. OWL, bilginin içeriğini sadece insanlara göstermekle kalmayıp aynı zamanda bilgisayarlar tarafından işlenebilmesi için tasarlanmıştır. Bu dil, XML, RDF ve RDF Schema (RDF-S) tarafından desteklenen web içeriğinin bilgisayarlar tarafından daha iyi yorumlanabilmesini amaçlamaktadır. OWL, OIL ve DAML+OIL gibi dillerden esinlenmiştir ve şu anda W3C tarafından önerilen bir dildir. OWL, DAML+OIL web ontoloji dilinin araştırma tabanlı bir versiyonudur.

#### **4. TARTIŞMA ve SONUÇ**

Web teknolojilerinin gelişimi, akıllı web'e doğru geçişi ve sürekli gelişime isteği bugünlerde teknolojinin her alanında gözlemlenmektedir. İnsanoğlu makinelerin her geçen gün daha da akıllı olmasını istemektedir. Özellikle yapay zeka, nesnelerin interneti, akıllı ajanlar, doğal dil işleme sosyal medya, sosyal ağlar gibi teknolojilerin varlığı ve web'e bıraktıkları bilgiler bu sürecin hızlanmasına katkı sağlamaktadır. Son yıllarda yeni bir paradigma olarak Web 4.0'a dair çeşitli tanımların literatürde yapılmaya başladığı web teknolojilerinin gelişim gösterdiğinin bir kanıtıdır. Ancak, Web 1.0, Web 2.0 ve Web 3.0'ın önceki kesin tanımlamalarına kıyasla, Web 4.0 için henüz net bir tanım bulunmamaktadır.

Bu bölümde web teknolojileri üzerinde durulmuş, geçmişte günümüze ve geleceğe ışık tutulmaya çalışılmıştır. Anlamsal ağ teknolojilerinden bahsedilmiştir. Ortaya atıldığı yıllardan bu yana pek çok çalışma yapılmış olmasına rağmen, halen daha varılması beklenen seviyenin çok uzağında olduğunu göstermektedir. Gün geçtikçe gelişimini hızlandıracağı görülen bu teknolojilerin Endüstri 4.0'ın alt dalları ile çok daha ileri noktalara gideceği ön görülmektedir.

## KAYNAKLAR

- Aldemir, A., & Oğuz, E. S. (2006). Sayısal Dijital Kültürün Korunması: Web Arşivleme. *Turkish Librarianship*, 20(3), 283–312.
- Battal, A. (2009). *Semantik Web İle Geliştirilen Bir Televizyon Program Öneri Sistemi* [Yüksel Lisans Tezi]. TOBB Ekonomi ve Teknoloji Üniversitesi.
- Berners-Lee, T., Hendler, J., & Lassila, O. (2001). The semantic web. *Scientific American*, 284(5), 34–43.
- Choudhury, N. (n.d.). *World wide web and its journey from web 1.0 to web 4.0*.
- Dağ, F., & Erkan, K. (2007). E-öğrenme ve anlamsal web. *Teknik Eğitimde Web Tabanlı Bir Eğitim Uygulaması, Ulusal Teknik Eğitim, Mühendislik ve Eğitim Bilimleri Genç Araştırmacılar Sempozyumu (UMES-2007), Haziran, 3*, 146–150.
- Eminoğlu, B. G. (2009). Semantic web (anlamsal ağ) yapıları ve yansımalar. *Akademik Bilişim 2009*, 151–155.
- Ersöz, B. (2020). Yeni Nesil Web Paradigması: Web 4.0. *Bilgisayar Bilimleri ve Teknolojileri Dergisi*, 1(2), 58–65.
- Guber, T. (1993). A translational approach to portable ontologies. *Knowledge Acquisition*, 5(2), 199–229.
- Güney, K. (2009). *Anlamsal web ve etmen teknolojileri Kullanarak sağlık bilgi sistemi Geliştirme* [Yüksel Lisans Tezi]. Ege Üniversitesi.
- Karademirci, O. (2008). *Anlamsal Web Teknikleri Kullanılarak GPS Tabanlı Bağlam Bilinçli Mobil Uygulama* [Yüksek Lisans Tezi]. Gazi Üniversitesi.
- Kardaş, G. (2008). Anlamsal web ortamında çalışan çok etmenli sistemlerin model güdümlü geliştirilmesi. In *Ege Üniversitesi Fen Bilimleri Enstitüsü Uluslararası Bilgisayar AD Doktora Tezi*, \Izmir.
- Kazandır, Z. B. (2011). *Anlamsal web tabanlı kütüphane bilgi sistemi*. Gazi Üniversitesi.
- Kurtel, K. (2008). WEB'in Geleceği: Anlamsal WEB. *Ege Academic Review*, 8, 205–213.
- Maedche, A., & Staab, S. (2001). *Comparing ontologies-similarity measures and a comparison study* (Vol. 6). AIFB.


- Özden, A. T. (2022). 1.0'dan 5.0'a Dünya: Web, Pazarlama, Endüstri ve Toplum. *Journal of Business in The Digital Age*.  
<https://doi.org/10.46238/jobda.1003371>
- Patel, A., & Jain, S. (2021). Present and future of semantic web technologies: a research statement. *International Journal of Computers and Applications*, 43(5), 413–422.  
<https://doi.org/10.1080/1206212X.2019.1570666>
- Permatasari, P. A., Qohar, A. A., & Rachman, A. F. (2020). From web 1.0 to web 4.0: the digital heritage platforms for UNESCO's heritage properties in Indonesia. *Virtual Archaeology Review*, 11(23), 75.  
<https://doi.org/10.4995/var.2020.13121>
- Rhayem, A., Mhiri, M. B. A., & Gargouri, F. (2020). Semantic Web Technologies for the Internet of Things: Systematic Literature Review. *Internet of Things*, 11, 100206.  
<https://doi.org/10.1016/j.iot.2020.100206>
- Süzen, A., & Taşdelen, K. (2016). Anlamsal Web Teknolojisi İle İçerik Arama. *El-Cezeri Fen ve Mühendislik Dergisi*, 3(1), 118–124.  
<https://doi.org/10.31202/ecjse.67150>
- Tonta, Y., & Madran, O. (2009). *The Future of Web 2.0 in Libraries and Information Centers: Open Discussion*.  
<http://eprints.rclis.org/14691/>
- Türksoy, H. (2007). *Ontoloji tabanlı etkinlik ve öğrenme nesnesi paylaşım sistemi*. Fen Bilimleri Enstitüsü.
- Yaşar, C. (2007). *Wordnet Üzerinden Türkçe Bilişim Ontolojisinin Oluşturulması* [Yüksek Lisans]. Çanakkale Onsekiz Mart Üniversitesi.







**IKSAD**  
Publishing House



**ISBN: 978-625-367-494-6**