

**Temmuz'23**

Sayı/Number: 2 / Volume: 13  
Yıl/Year: 2023

**Yayın Sahibi**

TMMOB  
Elektrik Mühendisleri Odası Adına  
Mahir ULUTAŞ

**Sorumlu Yazı İşleri Müdürü**

Eylem ÖLMEZOĞLU

**Yayın İdare Merkezi**

Ihlamur Sokak No:10 Kat:3  
Kızılay - Ankara  
Tel: (312) 425 32 72  
Faks: (312) 417 38 18  
<http://bilimseldergi.emo.org.tr>  
[bilimseldergi@emo.org.tr](mailto:bilimseldergi@emo.org.tr)  
EMO Üyelerine parasız dağıtılır

**Dergi Koordinatörü**

Sevgi Kinacı  
[sevgi.kinaci@emo.org.tr](mailto:sevgi.kinaci@emo.org.tr)

**Sayfa Düzeni**

TMMOB  
Elektrik Mühendisleri Odası

**Yayın Türü**

Yerel Süreli Yayın  
6 ayda bir yayınlanır

**Basım Adedi**

500

**Basım Tarihi**

Temmuz 2023

# EMO BİLİMSEL DERGİ

Elektrik, Elektronik, Bilgisayar, Biyomedikal  
Mühendisliği Bilimsel Dergisi

The Journal of Electrical, Electronics, Computer and  
Biomedical Engineering

## YAYIN KURULU

### BAŞ EDİTÖR/EDITOR IN CHIEF

**Prof. Dr. Timur Aydemir**  
Kadir Has Üniversitesi

### EDİTÖRLER/EDITORIAL BOARD

**Prof. Dr. Erhan Akın**  
Fırat Üniversitesi

**Prof. Dr. Güven Önbilgin**  
Ondokuz Mayıs Üniversitesi

**Prof. Dr. Arif Nacaroğlu**  
Gaziantep Üniversitesi

**Prof. Dr. Özlem Özgün**  
Hacettepe Üniversitesi

**Prof. Dr. Muhittin Gökmen**  
MEF Üniversitesi



**TMMOB**

**Elektrik Mühendisleri Odası**

UCTEA/Chamber of Electrical Engineers



## EMO Bilimsel Dergi Danışma Kurulu

Prof. Dr. A. Hamit Serbest	Çukurova Üniversitesi
Prof. Dr. Altay Güvenir	Bilkent Üniversitesi
Prof. Dr. Cengizhan Öztürk	Boğaziçi Üniversitesi
Prof. Dr. Erhan Akın	Fırat Üniversitesi
Prof. Dr. Güven Önbilgin	Ondokuz Mayıs Üniversitesi
Prof. Dr. Murat Eyüboğlu	Orta Doğu Teknik Üniversitesi
Prof. Dr. Timur Aydemir	Kadir Has Üniversitesi
Prof. Dr. Ali Hikmet Doğru	Orta Doğu Teknik Üniversitesi
Prof. Dr. Arif Nacaroğlu	Gaziantep Üniversitesi
Prof. Dr. Atilla Bir	Fatih Sultan Mehmet Vakıf Üniversitesi
Prof. Dr. Aydın Köksal	Bilişim A.Ş.
Prof. Dr. Aydoğan Özdemir	İstanbul Teknik Üniversitesi
Prof. Dr. Aysin Baytan Ertüzün	Boğaziçi Üniversitesi
Prof. Dr. Belgin Turkey	İstanbul Teknik Üniversitesi
Prof. Dr. Bülent Sankur	Boğaziçi Üniversitesi
Prof. Dr. Cüneyt Güzeliş	Yaşar Üniversitesi
Prof. Dr. Erdal Panayırçı	Kadir Has Üniversitesi
Prof. Dr. Erkan Afacan	Gazi Üniversitesi
Prof. Dr. Ferit Acar Savacı	İzmir Yüksek Teknoloji Enstitüsü
Prof. Dr. H. Bülent Ertan	Orta Doğu Teknik Üniversitesi
Prof. Dr. Haldun Karaca	Dokuz Eylül Üniversitesi
Prof. Dr. İbrahim Eksin	İstanbul Teknik Üniversitesi
Prof. Dr. İnci Çilesiz	İstanbul Teknik Üniversitesi
Prof. Dr. İrfan Karagöz	Gazi Üniversitesi
Prof. Dr. İsmail Hakkı Altaş	Karadeniz Teknik Üniversitesi
Prof. Dr. İsmail Hakkı Çavdar	Karadeniz Teknik Üniversitesi
Prof. Dr. Kemal Leblebicioğlu	Orta Doğu Teknik Üniversitesi
Prof. Dr. Lale Tükenmez Ergene	İstanbul Teknik Üniversitesi
Prof. Dr. Mithat İdemen	Okan Üniversitesi
Prof. Dr. Muhittin Gökmen	MEF Üniversitesi
Prof. Dr. Murat Aşkar	İzmir Ekonomi Üniversitesi
Prof. Dr. Müjde Güzelkaya	İstanbul Teknik Üniversitesi
Prof. Dr. Osman Eroğul	TOBB Ekonomi ve Teknoloji Üniversitesi
Prof. Dr. Oya Kalıpsız	Yıldız Teknik Üniversitesi
Prof. Dr. Özlem Özgün	Hacettepe Üniversitesi
Prof. Dr. Sermin Onaygil	İstanbul Teknik Üniversitesi
Prof. Dr. Tayfun Akgül	İstanbul Teknik Üniversitesi
Doç. Dr. Ahmet Hasan Koltuksuz	Yaşar Üniversitesi
Doç. Dr. Osman Abul	TOBB Ekonomi ve Teknoloji Üniversitesi
Bora Güngören	Portakal Teknoloji
Fikret Küçükdeveci	Kardinero Medikal
Hasan Ali Pazar	Siemens



## İÇİNDEKİLER / CONTENTS

<b>Rezistivite Cihazı Tasarımı ve Mobil Platformlarda İki Boyutlu Rezistivite Haritalarının Oluşturulması</b> <i>Resistivity Device Design and Creation of Two-Dimensional Resistivity Maps on Mobile Platforms</i> Hüsnü Canbolat, Murat Yiğit, Reşat Mutlu	7
<b>Evrişimsel Sinir Ağları Temelli Derin Öğrenme Modelleri Kullanılarak Beyin Tümörü Manyetik Rezonans Görüntülerinin Sınıflandırılması</b> <i>Classification of Brain Tumor Magnetic Resonance Images Using Convolutional Neural Networks-Based Deep Learning Models</i> Fatih Uysal, Metehan Erkan	19
<b>DA Mikro Şebeke Sisteminin Tasarımı ve Yönetimi</b> <i>Design and Management of DC Microgrid System</i> Waleed Khalid Abdulkareem Albayati , Selçuk Alparslan Avcı	29
<b>Grafik Sinir Ağlarına Genel Bir Bakış</b> <i>An Overview of Graph Neural Networks</i> Hamza Talha Gümüş, Can Eyüpoğlu	39
<b>Makine Öğrenimi Tabanlı Kısa Vadeli Fotovoltaik Çıkış Gücü Tahminlemesi</b> <i>Machine Learning Based Short Term Photovoltaic Output Power Prediction</i> Berrin Eryılmaz, Heybet Kılıç, Fatih Koçyiğit	57
<b>Elazığ İlinde Şebekeye Bağlı 1036,8 kwp Fotovoltaik Güneş Enerjisi Santralinin Ölçülen ve Simüle Edilen Performans Verilerinin Analizi</b> <i>Analysis of the Measured and Simulated Performance Data of a Grid-Connected 1036,8 kwp Photovoltaic Solar Power Plant in Elazığ</i> Zeynep Tanış, Nihan Altıntaş	71
<b>Kablosuz Ağlarda Farklı Gölgeleyen Kanallar Üzerinden Enerji-Verimli Veri İletimi için Makine Öğrenmesi-temelli Su-Doldurma Algoritması</b> <i>Performance of Machine Learning-based Water-Filling Algorithm for Energy Efficient Data Transmission over Different Fading Channels in Wireless Networks</i> Ömer Melih Gül	81



# Rezistivite Cihazı Tasarımı ve Mobil Platformlarda İki Boyutlu Rezistivite Haritalarının Oluşturulması

## Resistivity Device Design and Creation of Two-Dimensional Resistivity Maps on Mobile Platforms

    
Hüsnü Canbolat<sup>1</sup>, Murat Yiğit<sup>2</sup>, Reşat Mutlu<sup>3</sup>

<sup>1</sup>Trabzon Üniversitesi, Trabzon, Türkiye

[husnucanbolat@trabzon.edu.tr](mailto:husnucanbolat@trabzon.edu.tr)

<sup>2-3</sup>Çorlu Mühendislik Fakültesi, Tekirdağ Namık Kemal Üniversitesi, Tekirdağ, Türkiye

[92muratyigit@gmail.com](mailto:92muratyigit@gmail.com)

[rmutlu@nku.edu.tr](mailto:rmutlu@nku.edu.tr)

### Öz

Rezistivite (elektrik özdirenç) ölçüm yöntemi jeofizik araştırmalarda başlıca kullanılan yöntemlerdendir. Rezistivite yönteminde zemine yerleştirilen iki metal elektrot sayesinde yer içine elektrik akımı verilir. Yer yüzeyindeki diğer iki elektrotla yer içinde oluşan gerilim farkı ölçülür. Dört elektrotun aralıklarının değiştirilmesiyle farklı derinliklerden ölçümler alınır. Bu ölçümlerle bir boyutlu rezistivite haritaları oluşturulur. İki boyutlu rezistivite haritalarını oluşturabilmek için ise ölçüm yapılan alanda elektrot konumlarını yatay doğrultuda değiştirmek ve elektrot arası mesafenin değiştirilmesi gerekir. Bu çalışmada, toprağa yerleştirilen sekiz elektrot ile rezistivite yönteminde kullanılan özel dizimlere göre uygun akım-gerilim elektrotlarını anahtarlayarak toprak direnç değerlerini ölçen elektronik cihaz prototipi üretilmesi, ölçülen direnç değerlerinden iki boyutlu rezistivite haritaları oluşturabilen Android platformlarda çalışan yazılım yapılması amaçlanmıştır. Ölçülen özdirenç değerleri interpolasyon yapıldıktan sonra JavaScript kütüphaneleri kullanılarak görselleştirilmiştir.

Anahtar kelimeler: Rezistivite, Elektrik Özdirenç Yöntemi, Elektronik Cihaz Tasarımı, Veri Görselleştirme

### Abstract

Resistivity (electrical resistivity) measurement method is one of the main methods used in geophysical research. In the resistivity method, electric current is given into the ground by means of two metal electrodes placed on the ground. The voltage difference between the other two electrodes on the ground surface and the ground is measured. By varying the spacing of the four electrodes, measurements are taken from different depths. With these measurements, one-dimensional resistivity maps are created. In order to create two-dimensional resistivity maps, it is necessary to change the electrode positions in the horizontal direction and change the distance between the electrodes in the measurement area. In this study, it is aimed to produce an electronic device prototype that measures the soil resistance values by switching the

appropriate current-voltage electrodes according to the special arrays used in the resistivity method with eight electrodes placed in the soil, and to develop software that runs on Android platforms that can create two-dimensional resistivity maps from the measured resistance values. Measured resistivity values were visualized using JavaScript libraries after interpolation.

Keywords: Resistivity, Electrical Resistivity Method, Electronic Device Design, Data Visualization

### 1. Giriş

İlk çalışmaları Wenner ve Conrad Schlumberger tarafından yirminci yüzyılın başlarında yapılan rezistivite yöntemi günümüzde de temel ilkelerinden ayrılmamıştır [1],[2]. Rezistivite (elektriksel özdirenç) yöntemi bir besleme kaynağı sayesinde yeryüzünden yeraltına iki akım elektrotu ile akım verilerek yeraltında meydana gelen gerilim farkının ölçüm elektrotlarıyla ölçülmesi ilkesi ile çalışır. Ölçülen direnç değeri elektrotların birbirlerine olan uzaklıklarına (dizimlere) bağlı geometrik katsayı ile çarpılarak toprağın direnci dolayısıyla özdirenci hesaplanır. Bu çalışmada, rezistivite yönteminde literatürde yaygınca rastlanılan dizimler ile çalışılmıştır.

Daha sonra ölçüm elektrotları sökülerek birbirine olan mesafeleri değiştirilir. Tekrar ölçümler alınarak ölçülen değerler kaydedilir. Bu ölçümlerle bir boyutlu rezistivite haritaları oluşturulur. Elektrotlar yatay doğrultuda hareket ettirilerek aynı işlem yapılırsa iki boyutlu rezistivite haritaları oluşturulur. Aynı ölçüm sahasında dikey ve yatay doğrultuda ölçümler alınarak oluşturulan iki boyutlu haritalar birleştirilerek üç boyutlu rezistivite haritaları oluşturulur.

Bilgisayar ve elektronik teknolojilerinin ilerlemesiyle bilgisayar kontrollü rezistivite cihazları geliştirilmeye ve iki-üç boyutlu rezistivite haritaları uygulanmaya başlanmıştır [3]. Böylece iş yükü azaltılarak yöntemin uygulanabilirliği artırılmıştır.

Rezistivite yönteminin günümüzde yeraltı suyu ve jeotermal etütlerde [5],[6] yer altı suyu kirlenmesinin egemen olduğu kesimlerin belirlenmesinde, yer içinin jeofiziksel yapısının

araştırılmasında [7],[8], baraj kurulumu sonrası oluşan kaçakların tespitinde [9], yer altı boşluklarının tespitinde [10], arkeolojik çalışmalarda [11]-[15] kullanılmaktadır. [16] ve [17]'de dizilimlerin dijitalize edilerek toprak öz direnç yöntemi iş yükünün azaltılmasına yönelik çalışmalar görülebilir. Toprak haritalarının çok boyutlu haritalanmalarına yönelik çalışmalar [18]-[20]'de bulunabilir.

Bu çalışmanın amacı yüzeye yerleştirilen 8 elektrot ile seçilen dizilimlere göre gerekli kombinasyonları üreterek uygun anahtarlamayı yaparak toprak direncini ölçen, gerçek zamanlı olarak ölçülen değeri ve elektrotunun ölçüm yaparken bulunduğu konumları Android cihaza aktaran, gelen verilere göre Android cihazda iki boyutlu toprak öz direnç haritası oluşturan rezistivite cihazı yapmaktır.

Ülkemizde yapılan çalışmalarda çoklu elektrotlu rezistivite cihazları üretilmiştir [16],[17]. Tasarlanan cihazın diğer cihazlardan farkı 2 boyutlu rezistivite haritası oluşturabilmesi ve bilgisayar ortamına gerek olmadan Android cihazlarda haritalama yapabilesidir.


Bu makalenin bölümleri şu şekilde sıralanmıştır. Giriş bölümünün ardından kullanılan metodun kuramsal temelleri, piyasada kullanılan özel dizilimler ve bir-iki-üç boyutlu boyutlara göre rezistivite haritalarının oluşturulması açıklanmıştır. Üçüncü bölümde tasarlanan ve gerçekleştirilen cihazın çalışma ilkelerinden, kullanılan mikrodenetleyici, invertör, akım sensörü Bluetooth ve röle kartlarının özellikleri ve tasarlanan ölçüm devreleri açıklanmıştır. Dördüncü bölümde mikrodenetleyicinin yazılımı ve akış diyagramları, Android programlamada kullanılan Appinventor yazılımı, ölçülen verilerin görselleştirilmesi için kullanılan JavaScript kütüphanesi ve ölçülen veriler için uygulanan interpolasyon hakkında bilgi verilmiştir. Beşinci bölümde gerçekleştirilen rezistivite cihazından veriler toplanarak Android cihazda rezistivite haritası oluşturulmuştur. Ayrıca ölçüm değerleri bilgisayar ortamına da aktarılarak MATLAB programı ile iki boyutlu rezistivite haritaları çizdirilmiştir. Makale son bölüm ile bitirilmiştir.

## 2. Elektrik Öz direnç Yöntemi Denklemi ve Kullanılan Özel Dizilimler

Rezistivite metodunun hedefi yeraltında bulunan öz direnç dağılımlarının yerüstünden bulunmasıdır. Rezistivite yönteminde elektriksel bir güç kaynağının sağladığı akımlar zemine verilir. Bu elektrik akımlarının neden olduğu elektrotlar arasındaki potansiyel farkların ölçümü yapılır. Ölçülen potansiyel farkların konuma göre değişimine bakılarak yeraltının elektriksel parametreleri üzerine veri toplanmış olur. Bu yöntem için toprağa dört adet elektrot (kazık) yerleştirilir. Elektrotlardan ikisine DC gerilim uygulanır ve kalan elektrot çiftinin potansiyel farkı ölçülmüş olur. Şekil 1'de yöntem grafikleştirilmiştir. Bu şekilde A ve B akım uygulanan elektrotları göstermekteyken, M ve N potansiyel farkları ölçülen elektrotları göstermektedir. Akım elektrotları güç kaynağına bağlanmıştır ve toprağı beslemektedir. Şekil 1'de kaynak tarafından oluşturulan elektrik alan ve eşpotansiyel yüzeyler de gösterilmiştir. Şekil 1'de Wenner Alfa dizilim yöntemi kullanılmıştır.

Jeofizik Mühendisliğinde rezistivite metoduna Ohm Kanunu'nun vektörel şekilde yazılmasıyla giriş yapılır;

$$\vec{J} = \sigma \vec{E} = \left(\frac{1}{\rho}\right) \vec{E} = \left(\frac{1}{\rho}\right) \nabla V \quad (1)$$



Şekil 1: Rezistivite metodunun şekilsel olarak gösterimi [20]

Denklem 1'de verilenler sırasıyla açıklanacak olursa:  $\vec{J}$  Akım yoğunluğu vektörüdür ve birimi  $A/m^2$ 'dir,  $\vec{E}$  Elektrik alan vektörüdür ve birimi  $V/m$ 'dir,  $V$  Elektrik potansiyeldir ve birimi Volt'tur,  $\sigma$  elektriksel iletkenlikdir ve birimi  $1/\Omega.m$ 'dir, ve  $\rho$  elektriksel öz dirençtir ve birimi  $\Omega.m$ 'dir. Akım yoğunluğu birim alandan geçen elektrik akımının değeridir ve Denklem 2'deki gibi tanımlanabilir.

$$J = \frac{dI}{dS} \quad (2)$$

Burada dS diferansiyel dI akımın geçtiği diferansiyel yüzey alanıdır [ $m^2$ ].

Bir elektrottan geçen akım

$$I = \int_S \vec{J} d\vec{S} \quad (3)$$

olarak bulunabilir.

Elektrotların ölçüm sahasına göre boyutları oldukça küçük olduğundan, noktasal kaynak olarak kabul edilebilirler. Toprak yüzeyindeki noktasal bir kaynaktan r uzaklığındaki eşpotansiyel yüzey bir yarı küre olarak alınabilir. Yeraltının ayrıca homojen kabul edilmesiyse; bu elektrottan çıkarak yeraltından akan akım  $(4\pi r^2)/2$  alanlı bu yarı küreye dik olarak geçer [20].



Şekil 2: Akım yoğunluğunun homojen bir toprakta dağılımı [20]

Yukarıdaki şekilde toprak içinde bulunan eşpotansiyel yüzeyler ile bunlara dik olarak kesen akım yoğunluğu çizgileri temsil olarak çizilmiştir. Bu eşpotansiyel yüzey üzerindeki akım yoğunluğu

$$J = \frac{I}{\left(\frac{1}{2}\right)(4\pi r^2)} = \frac{I}{2\pi r^2} \quad (4)$$

olarak hesaplanabilir.



Elektriksel potansiyelin eksi gradyanı alınarak, elektrik alan vektörü bulunabilir. Bundan dolayı

$$\frac{I}{2\pi r^2} = -\frac{1}{\rho} \frac{\partial V}{\partial r} \quad (5)$$

elde edilir. Bu diferansiyel denklemin çözümü elektriksel potansiyeli verecektir. Bu çözüm

$$\int dV = -\int \frac{\rho I}{2\pi r^2} dr \quad (6)$$

integrali olarak verilir.  $r=0$  konumuna konulmuş ve akımın geçtiği sadece bir noktasal elektrotun var olması kabulüyle ve elektrottan sonsuz uzaklıktaki elektriksel potansiyelin değeri sıfır alınarak, toprak altında  $r$  yarıçapında ölçülen elektriksel potansiyel

$$V(r) = \frac{\rho I}{2\pi r} \quad (7)$$

şeklinde bulunur. Denklem 7'de  $\rho$  toprağın öz direnç değeridir.

Denklem 7, aralarında bulunan uzaklığa boyutları oldukça küçük bir elektrot çiftine uyarlanırsa, bu çift arasında bulunan potansiyel fark:

$$V = \frac{\rho I}{2\pi r_A} - \frac{\rho I}{2\pi r_B} = \frac{\rho I}{2\pi} \left[ \frac{1}{r_A} - \frac{1}{r_B} \right] \quad (8)$$

şeklinde verilebilir. Denklem 8'de  $r_A$  herhangi bir A noktasal kaynağına olan uzaklık,  $r_B$  herhangi bir B noktasal kaynağına olan uzaklıktır.

Şekil 1'de verilen Wenner Alfa dizilim yönteminde A ve B noktalarına iki akım elektrotu ve bağlanmıştır. Bu durumda AM, MB, AN ve NB mesafelerine bağlı olarak, M ve N noktalarında ölçülen elektriksel potansiyeller, sırasıyla:

$$V_M = \frac{\rho I}{2\pi} \left[ \frac{1}{AM} - \frac{1}{MB} \right] \quad (9)$$

$$V_N = \frac{\rho I}{2\pi} \left[ \frac{1}{AN} - \frac{1}{NB} \right] \quad (10)$$

olarak bulunur.

M ve N arasında ölçülen gerilim ( $V_{MN}$ ):

$$V_{MN} = V_M - V_N = \frac{\rho I}{2\pi} \left[ \left( \frac{1}{AM} - \frac{1}{MB} \right) - \left( \frac{1}{AN} - \frac{1}{NB} \right) \right] \quad (11)$$

denklemlerle verilir. Denklem 11'de sadece elektrotların arasındaki mesafelere bağlı olan köşeli parantezin içinde verilen ifade, geometrik faktör diye isimlendirilir. Geometrik faktör  $K$  ile sembolize edilir ve

$$K = \frac{2\pi}{\left( \frac{1}{AM} - \frac{1}{MB} \right) - \left( \frac{1}{AN} - \frac{1}{NB} \right)} \quad (12)$$


olarak verilir. Yapılan dört elektrotlu ölçüm yönteminde M ve N noktalarının arasındaki gerilimin A ve B noktalarına bağlı gerilim kaynağından çekilen akım ile bölünmesiyle M ve N noktalarının arasında bulunan toprağın elektriksel direnci  $R$  bulunabilir. Toprak homojen kabul edilirse, toprağın öz direnci:

$$\rho = K \frac{V_{MN}}{I} \quad (13)$$

$$\rho = KR \quad (14)$$

şeklinde hesaplanabilir.


Geometrik faktör seçilen elektrot dizilimleri ile değişir [21]. Wenner Alfa, Wenner Beta, Wenner Beta, Wenner Schlumberger ve Dipol Dipol elektrot dizilimleri en sık kullanılan elektrot dizilimlerdir. Bu dizilimler için bu katsayılar Şekil 3'te verilmiştir.




Şekil 3: Bu çalışmada kullanılan dizilimler ve K geometrik faktörü değerleri [21]

## 2.2 Dizilimlere Göre Haritalandırılmalar

Bu kısımda bir, iki ve üç boyutlu rezistivite haritalarının oluşturma adımları anlatılacaktır. Şekil 4'te rezistivite metoduyla üretilen bir, iki ve üç boyutlu haritalar verilmiştir. Şekil 4.a'da Wenner alfa dizilimini kullanarak düşey doğrultuda öz direnç ölçümü gösterilmiştir. Bir boyutta harita hazırlanması için kullanılan elektrotların (kazıkların) aralıkları değiştirilerek tekrar tekrar ölçüm alınmalıdır. Şekil 4.b'de iki boyutlu rezistivite haritasının hazırlanması için gerekli öz direnç ölçümü gösterilmiştir. İki boyutlu haritanın oluşturulabilmesi için ölçüm elektrotlarının aralıklarındaki mesafenin değiştirilerek, yatay düzlemde kaydırılması ve ölçümlerin alınması gereklidir. Şekil 4.c'de üç boyutlu öz direnç haritasının hazırlanması için gerekli öz direnç ölçümü gösterilmiştir. Üç boyutlu harita iki boyutlu haritaların birleştirilmesiyle üretilir. Şekil 5'te iki boyutlu rezistivite (öz direnç) haritalarının birleştirilmesiyle elde edilen üç-boyutlu bir rezistivite haritası yer almaktadır.



Şekil 4: a) Bir boyutta, b) İki boyutta ve c) Üç boyutta haritalama için yapılan öz direnç ölçümleri [3]



Şekil 5: İki boyutlu öz direnç haritalarından üç boyutlu harita çıkarılması [14]

### 3. Cihazın Çalışmasının Açıklanması ve Donanımı

Bu kısımda rezistivite cihazının donanımı, hazırlanan ölçüm devreleri ve cihazın elektriksel devresi açıklanacaktır. Tasarlanan cihaz rahatlıkla bulunabilen elektronik parçalar ile oluşturulmuştur.


Cihazda güç kaynağı olarak 12 Volt 7000 mAH Autoware marka akü kullanılmıştır. Akü çıkışına 300 Watt güce sahip evirici yerleştirilmiştir. Bu evirici sayesinde bu akü geriliminden şebeke gerilimi yani 220 Volt sinüoidal gerilim elde edilmiştir. Şekil 6'de tasarlanan rezistivite cihazında kullanılan evirici görülebilir. Rezistivite metodu doğru gerilim ile uygulanan bir metot olduğu için evirici çıkışına, kapasitör filtreli köprü doğrultucu devresi bağlanarak yaklaşık 300 Volt DC gerilim elde edilmiştir. Elektrot akımları Hall etkisi ilkesiyle çalışan ve +5 ile -5 Amper aralığını ölçen ACS712 akım sensörü ile ölçülmüştür. Bu akım sensörü 2,5 Voltluk bir DC offset geriliminin üzerine ölçülen bir amper için 185 mV bindirerek çıkışına vermektedir.



Şekil 6: Cihazın elektrotlarının besleme gerilimini elde etmek için kullanılan invertör [22]

Bu cihazda Arduino Mega 2560 kartı kullanılmıştır. Bu kart Atmega2560 tabanlıdır. 16 MHz'de çalışmaktadır. Kartta bulunan elli dört adet dijital giriş/çıkış ve on altı adet analog giriş bu çalışma için yeterlidir. Kart ayrıca dört UART'ye, bir adet USB bağlantı soketine, bir adet güç soketine, bir adet ICSP konektörüne ve reset tuşuna sahiptir. Kart USB kablosu ile rahatlıkla bilgisayara bağlanabilmekte ya da adaptörden veya pilden beslenebilmektedir [23]. Çalışmada kartın beslenmesi kullanılan eviricinin sahip olduğu 5 Volt çıkışından yapılmıştır. Kartın 20. ve 21. seri haberleşme pinlerine bağlanmış HC06 Bluetooth seri haberleşme modülü sayesinde Android platformla haberleşmesi sağlanmıştır. Bu modül on metreye kadar olan mesafede haberleşebilmektedir. Yapılan ölçümler sekiz tane elektrotla alınmıştır. Tasarlanan cihazda her bir elektrotun hem akım elektrotu hem de gerilim elektrotu olabilmeye sağlanmıştır. Bu işlem için her bir elektrotta dört röle bağlanmıştır. Sekiz elektrotla gerekli olan otuz iki röle yerine iki tane on altı kanallı Oem marka röle kartı kullanılmıştır. Şekil 7'de tasarlanan cihazın çalışma şeması görülmektedir. Rezistivite cihazın ön tarafına born jak monte edilmiştir. Sekiz elektrot timsah kablolarla jaklara bağlanmıştır. Elektrotlar sağdan sola doğru numaralandırılmıştır ve yazılımda da bu sıraya göre konumlar belirlenmiştir. Dizilimlerinden seçilen elektrot dizilimine bağlı olarak sekiz elektrottan dizilim şartlarını karşılayan elektrot konumları 1. akım elektrotu için C1, 2. akım elektrotu için C2, 1.gerilim elektrotu için P1, 2.gerilim elektrotu için P2 (C1, C2, P1, P2) şeklinde kodlanarak Bluetooth haberleşmesi ile mikrodnetleyici kartına bildirilir.

Mikrodnetleyici uygun rölelerin anahtarlamasını yaparak hangi elektrotun akım ve hangi elektrotun gerilim elektrotu olacağını tayin eder. Ardından akım sensörü ile akım elektrotu olarak tayin edilen elektrotun akımı bağlandığı ölçüm kartı ile okunur. Ölçüm yapan bu kartın vazifesi gelen sinyali mikrodnetleyici kartının ölçebileceği gerilim değerine dönüştürmektir. Gerilim verilen toprakta P1-P2 gerilim elektrotlarının arasında oluşmuş gerilim farkı, ölçüm kartı ile ön işlem yapılarak mikrodnetleyici kartına iletilmiş olur. Mikrodnetleyici ölçülen gerilimi ölçülen akıma bölerek elektriksel direnci hesaplar ve Android cihaza (C1, C2, P1, P2) formatında iletir. Özel dizilimlere uygun bütün kombinasyonlardaki direnç değerleri ölçülüp hesaplanıp geometrik faktör ile çarpıldıktan sonra hesaplanan direnç değerleri için interpolasyon yapılır ve Android platformda rezistivite haritaları oluşturulur.



Şekil 7: Cihazın Blok Diyagramı

Şekil 10'da cihazın devre şeması görülebilir. Mikrodnetleyicinin yirmi ikinci pininden itibaren elli dördüncü pinine kadar tüm pinleri röle kartına bağlanmıştır. Dörderli gruplanmış rölelerin birer uçları birbirlerine bağlanarak, sekiz röle grubu meydana getirilmiştir. Bunun sonucunda sekiz elektrottan her biri gerilim ya da akım elektrotu (probu) olarak çalışabilir hale gelmiştir. Mikrodnetleyici kartı ölçüm kartında kuvvetlendirilen ve toplam ön işleminden geçen akımları ve gerilimleri ADC0, ADC1, ADC2, ADC3 ve ADC4 Analog Dijital Dönüştürücülerini (ADC) kullanarak okur. Şekil 10'da mikrodnetleyici kartı, kullanılan röle bağlantıları, ölçüm kartının devreleri, mikrodnetleyici kartına bağlı Bluetooth modülü, evirici, tam dalga doğrultucu devre ve ölçüm kartında ön işlemden geçirilen gerilim ve akımı okuyan ADCler görülmektedir. Şekil 8'de tasarlanan ölçüm kartının şeması verilmiştir.


ACS712 sensörünün çıkışında içinden akım geçmez iken 2,5 Volt'luk bir gerilim okunmaktadır. Ölçüm problemlerinden akım akarken, ACS712 akım sensörü çıkışında 2,5 V üzerine eklenen bir gerilim değeri görülmektedir. ACS712 ölçtüğü her bir amper değeri için 0,185 Volt gerilim üretmekte ve bu gerilimi

2,5 Volt'luk offset gerilimine eklemektedir. Toprağa verilen gerilim ve toprağın sahip olduğu yüksek direnç değeri göz önüne alındığında, zeminden geçen akım bir amperi bulmamaktadır. Akan akım çok daha altındadır. Bundan dolayı ACS712'nin çıkış gerilimi Analog dijital dönüştürücünün okuyabileceği değere yükseltilmelidir. Akım ölçümünün mikrodenetleyici kartının ADC0 pini ile yapılması tercih edilmiştir. Şekil 8'de görülen A bölümünde 5 Voltluk gerilim, gerilim bölücü devresi kullanarak yarıya indirilmiş ve voltaj izleyicisi olarak kullanılmış LM358N opampına beslenerek, bu opamp çıkışında 2,5 Volt'luk gerilim elde edilmiştir. Şekil 8'de B bölümünde, sensör çıkış gerilimi 2,5 Volt'tan çıkarılıp, daha sonra on kat yükseltilip, yeniden 2,5 Volt'luk referans gerilimi eklenmiştir.


Yapılan toprak ölçüm deneylerinde okunmuş bazı gerilim değerlerinin eksi değere sahip ve çözünürlüğü analog dijital çeviricinin okuyabileceği çözünürlükten düşük gerilimler olduğu gözlemlenmiştir. Bu durumlar için işlemsel yükselteçler kullanılarak -1,-10 ve 11 kat yükseltme işlemleri uygulanmıştır. Eğer ölçülen gerilim değeri analog dijital çeviricinin okuyabileceği çözünürlükte ve pozitif gerilim değerine sahipse Şekil 8'de C kısmında V\_IN pininden yani ADC1 kanalı ile okuma gerçekleştirilmektedir. Eğer ölçülen gerilim eksi ve 0,7 Volt'un üzerindeyse, Şekil 9'da alt tarafta görülen eviren kuvvetlendiriciyle -1 kat kuvvetlendirilmekte ve ADC3 kanalıyla okuma işlemi yapılmaktadır. Gerilim eksi ve 0,7 Volt'un altındaysa Şekil 9'da üst tarafta görülen eviren kuvvetlendiriciyle -10 kat kuvvetlendirilmekte ve ADC2 kanalıyla okuma gerçekleştirilmektedir. Şekil 8'de C kısmında sadece V\_IN pinindeki gerilim değerini 11 kat yükselten evirmeyen yükselteç yer almaktadır. Yükseltilecek gerilim değeri 4. Analog dijital çevirici (ADC4) kanalından okunmaktadır.

Şekil 9'da opamplarla kurulan eviren kuvvetlendiriciler gösterilmiştir. Evirmeyen kuvvetlendiriciler farklı bir ölçüm kartının bağlantı kablolarıyla (jumperlar) mikrodenetleyicinin V\_IN pinine bağlıdır. Şekil 11'de bu çalışma için tasarlanmış baskı devre görülebilir. Şekil 12'de bu kartın üç boyutlu bir çizimi görülebilir.


Şekil 13'te tasarlanan cihazın içi boşaltılmış endüstriyel invertör kasasına yerleşimi görülmektedir. Arduino Mega 2560, röle kartları, invertör ve ölçüm kartı sabitlenmiş olup, akü ise rahatlıkla söküp takılabilmesi için sabitlenmemiştir.



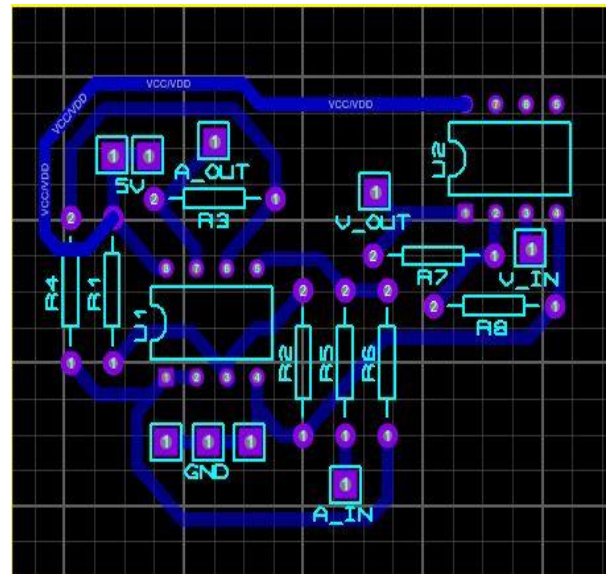
Şekil 9: Ölçüm kartının Opamp tabanlı eviren yükselteçleri




Şekil 10: Cihazın Devresi




Şekil 8: Vazifesine göre bölünmüş Ölçüm kartı devresi



Şekil 11: Ölçüm kartının baskı devre şeması



Şekil 12: Ölçüm kartının 3D bir çizimi



Şekil 13: Montaj edilmiş Rezistivite cihazı

#### 4. Sistem Yazılımı ve Algoritması

Bu bölümde Android platformlarda oluşturulan Appinventor program blokları, haritalandırmanın yapılabilmesi için gerekli olan JavaScript kodları, Arduino Mega 2560 mikrodenetleyicisinin programlanması için oluşturulan algoritma anlatılacaktır.

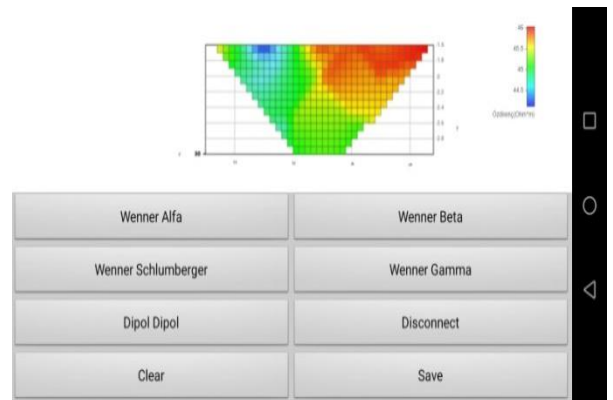
##### 4.1 AppInventor yazılımı ve Arayüzleri

Android platformlarda Cihaz için yazılan program AppInventor blokları kullanarak hazırlanmıştır. AppInventor yazılımı Android dillerini bilmeksizin Android işletim sisteminde kolayca uygulamaların yapılmasını sağlar. Görsel programlama özellikleri çok kolay bir şekilde uygulamaların yapılmasını sağlamaktadır [24]. Şekil 14'te bu cihazın Android platformlarda çalıştırılması için hazırlanan ara yüz gösterilmiştir. Şekil 14'ün A kısmındaki buton, checkbox, label, listpicker, listview, notifier, passwordtextbox, screen, slider, spinner, switch, textbox, timepicker, webviewer gibi yapıtaşlarının kullanımıyla Şekil 14'ün B kısmındaki arayüz oluşturulabilmektedir. Şekil 14'ün C kısmındaysa kullanılmış yapıtaşlarının ayarları düzenlenebilmektedir.

Şekil 15'te gösterilen ara yüzdeki butonlara basarak sekiz elektrottan çalışmada kullanılan dizilimlere uygun olan elektrotların tayin edilmesi ve bu elektrotların mikrodenetleyiciye iletilerek akım ve gerilim ölçümü için uygun elektrotların görevlendirilmesi yapılmaktadır. Bu görevlendirmeden sonra sekiz elektrot ile dizilim için gerekli şartları sağlayan bütün dizilim kombinasyonları için ölçülen akım ve gerilim değerleri Bluetooth kablosuz haberleşmesi ile Android platformda çalışan cihaza iletilmektedir.



Şekil 14: Android platform için tasarlanan ara yüz




Şekil 15: Android platform için tasarlanan arayüz ve seçilmiş metoda uygun şekilde oluşturulmuş öz direnç haritası

##### 4.2 Mikrodenetleyici yazılımı ve akış diyagramı

Bu kısımda mikrodenetleyici için gerekli Arduino yazılımı ve akış diyagramları anlatılacaktır.

Android platformun C1, C2, P1, P2 formatıyla gönderdiği gerilim-akım elektrotlarının konularının bilgisi alındığında, önce "Reset" fonksiyonu çalıştırılır ve mikrodenetleyicinin 32 pinine bağlanmış 2 röle kartındaki 32 röleye Lojik 1 sinyali gönderilerek, DC gerilim kaynağıyla zemine uygulan gerilim kesilir ve ölçümler alınması bitirilir. Bu sayede DC gerilim kaynağı sadece ölçümler esnasında çalıştırılarak aküden enerji tasarrufu elde edilir. Rölelerin anahtarlama hızı transistörler kadar yüksek değildir. Kullanılan rölelerden bazılarının muhtemel eş zamanlı anahtarlamasından kaynaklı sorunların önlenmesi ve akımlarla gerilimlerin doğru bir şekilde ölçülebilmesi için 1,5 saniye beklenmektedir. Bu bekleme süresinin deneysel çalışmalarda toprakta oluşan gerilimin deşarj olması için yeterince uzun olduğu görülmüştür. Beklemenin ardından "Set" fonksiyonu çalıştırılır. Elektrotların konumuna göre mikrodenetleyicinin 22 ile 54 arasındaki pinlerden seçilmiş dizilimin kombinasyonlarına denk gelen elektrotların röleleri devreye alınarak, elektrotlar görevlendirilmiş olur. 1,5 saniye beklemeden sonra "Akım Oku" ve "Gerilim Oku" fonksiyonları çalıştırılmaya başlanır. Elektrotların akım ve gerilimleri ölçülür. Bu değerler Android cihaza gönderilir. Ölçüm işlemi yeniden çağrılana kadar durdurulur. Akım ve gerilimler ölçülürken, ölçümlerin hatalarının azaltılması için 200 ölçüm alınıp ölçümlerin ortalaması alınmaktadır. Şekil 16'de mikrodenetleyici yazılımının akış diyagramı yer almaktadır.



Şekil 16: Arduino yazılımı için akış diyagramı

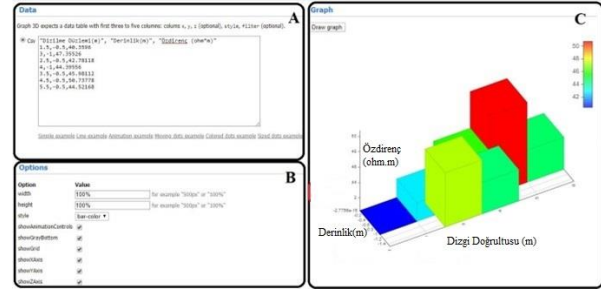
### 4.3 JavaScript yazılımı

Bu bölümde cihazın ölçtüğü akım ve gerilimlerden Android platformda 2D rezistivite haritası oluşturabilmek için ihtiyaç duyulan JavaScript görselleştirme kütüphanesi ve JavaScript yazılımı algoritmaları verilmiştir.

JavaScript, web tarayıcılarının yaygınca kullandığı dinamik bir programlama dilidir. Web sayfalarına canlılık ve dinamiklik getirmesi amacıyla oluşturulan bir betik dildir. Bu dil HTML kodu içine gömülü ya da dahili bir şekilde yazılabilmektedir. Web sayfası yüklendiği zaman direkt çalıştırılabilmektedir. Bundan dolayı bu kodlar bir derleyici kullanımına ihtiyaç duymaksızın çalışabilmektedir. JavaScript kodları tüm Web tarayıcıları üzerinde çalışabilmektedir. Bundan dolayı AppInvertor ile tasarlanan program ile ölçülen direnç değerlerinden rezistivite haritası oluşturulabilmesi için Şekil 14'ün B kısmındaki alana Web tarayıcısı yerleştirilmiştir. Yerleştirilen Web tarayıcısı [25]'da bulunan JavaScript görselleştirme kütüphanesi kullanılarak ölçülen direnç değerleri haritalanmıştır. 2D rezistivite haritasının oluşturulması için 2 parametrenin bilinmesini gerektirmektedir. Birinci parametre ölçüm elektrotlarının konumları ve ikinci parametre ise elektrotlardan ölçülen akım-gerilim değerleridir. Ölçülen akım ve gerilimlerden ölçüm bölgesinin elektriksel direnci hesaplanır. Ardından konumu bilinen bu direnç geometrik faktör ile çarpılarak 2D rezistivite haritasına gereken öz direnç bulunmuş olur.

Şekil 17'de görülen grafikte Sekiz elektrot kullanan Wenner Alfa dizilimi için oluşan 7 farklı kombinasyon çizdirilmiştir. Şekil 17'de A kısmında kullanılan JavaScript kütüphanesi veri giriş paneli görülmektedir. B kısmında kullanılacak grafiğin seçimi, eksenlerin isimleri, grafik dönüş ayarları ve renk skalası gibi ayarlar bulunmaktadır. C kısmındaysa A ile B kısımlarındaki değerler ve ayarlar kullanarak çizilen grafik bulunmaktadır.

Tablo 1'de Wenner Alfa diziliminde seçilebilecek akım ve gerilim elektrotları kombinasyonları yer almaktadır.



Şekil 17: JavaScript görselleştirme kütüphanesi için Web simülasyon sayfası [25]

Tablo 1: Wenner Alfa dizilimi için 8 elektrot için atanması gereken akım-gerilim elektrot kombinasyonları


Akım Probu1 (C1)	Akım Probu2 (C2)	Gerilim Probu1 (P1)	Gerilim Probu2 (P2)
1	4	2	3
2	5	3	4
1	7	3	5
3	6	4	5
2	8	4	6
4	7	5	6
5	8	6	7

Şekil 17'de C kısmında ölçülen gerçek değerler kullanılarak oluşturulmuş harita yer almaktadır ve bu haritanın çözünürlüğü düşüktür. Bundan dolayı interpolasyon işlemi ile ölçülen akım-gerilim değerlerine göre hesaplanan öz direnç değerleri kullanarak ara değerler hesaplanmıştır. Böylece haritanın çözünürlüğü artırılmıştır. Kodlama kolaylığı açısından interpolasyon yöntemi olarak üçgen interpolasyonu seçilmiştir. İnterpolasyon işlemi için ilk önce ölçülmüş bütün değerlerin hesaplanacak değere olan uzaklığı Denklem 14'te verilen iki nokta arası uzaklık formülünden hesaplanır. Daha sonra uzaklıklarına göre sıralandırılarak hesaplanacak ara değere en yakın üç nokta tespit edilip seçilerek Denklem 15'te verilen denkleme göre üçgen interpolasyonu yapılarak ara değer hesaplanmıştır. Burada  $d_1, d_2, d_3, \dots, d_N$  hesaplanacak değer ile ölçülen değer arası uzaklık,  $H_1, H_2, H_3$  hesaplanan öz direnç değerlerinden en yakın olan üç tanesi,  $H_S$  hesaplanacak ara değer,  $(X_{HN}, Y_{HN})$  ölçülen değerlerin koordinatları,  $(P_x, P_y)$  hesaplanacak ara değer koordinatlarıdır.

Şekil 18'de interpolasyon sonucu oluşturulan rezistivite haritası gösterilmiştir. Şekil 19'da haritalandırmada kullanılan JavaScript kodunun akış diyagramı görülebilir. İlk başta hazır kütüphane ile oluşturulan haritanın döndürme ayarı, zımlama ayarı, renk ayarı, harita yüksekliği ve genişliği ayarı gibi ayarlar JavaScript kodları ile ayarlanmaktadır. Ardından yatay eksen değeri, dikey eksen değeri ve  $(X, Y, Z)$  konumuna bağlı öz direnç formatında gönderilen ölçülen değerlerin yatay ve dikey eksen eksenlerde bulunan tüm noktalar 0,1 metre adım ile interpolasyon döngüsüne sokulur. Ölçülen verilerden hangilerinin en yakın üç nokta olduğu bulunur. Bu üç noktayla Denklem 15'te verilen formül kullanılarak üçgen interpolasyonu yapılır. Tüm döngü esnasında elde edilen veriler kaydedilir. İnterpolasyon işleminin sonunda, elde edilen bu değerler hazır JavaScript görselleştirme kütüphanesine gönderilir ve 2D toprak öz direnç haritası oluşturulmuş olur.

$$d_N = \sqrt{(X_{H_N} - P_X)^2 + (Y_{H_N} - P_Y)^2} \quad (14)$$

$$H_s = \frac{d_2 d_3 H_1 + d_1 d_3 H_2 + d_1 d_2 H_3}{d_1 d_2 + d_2 d_3 + d_1 d_3} \quad (15)$$




Şekil 18: Seçilen dizilime yöntemine göre oluşturulmuş haritanın üst profili

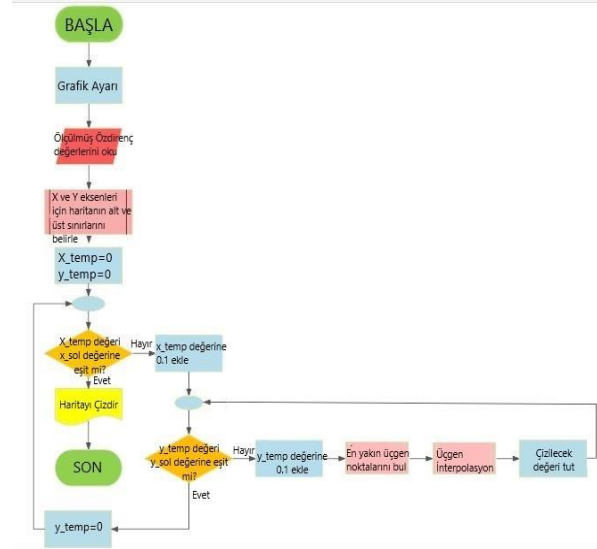
## 5. Deneysel Çalışmalar

Bu kısımda gerçekleştirilmiş cihazla yapılan deneyler üzerine bilgi, deneylerin sonucunda Android platformda oluşturulmuş 2D öz direnç haritaları ve deney verilerinin MATLAB programında doğrusal (lineer) ve kübik interpolasyon yapılmasıyla oluşturulmuş haritalar ile Android platformda oluşturulan haritaların karşılaştırması yer almaktadır.


Deneysel çalışmalar Şekil 20’de görülen Çorlu Mühendislik Fakültesi’nin bahçesinde işaretlenmiş sahalarda yapılmıştır. Şekil 21’de bir metre aralıklarla dizilen sekiz elektrot ve rezistivite cihazının bağlantıları görülmektedir. Android cihazdan gönderilen dizilim bilgisiyle elektrotlar görevlendirilip çalışılan sahanın rezistivite haritası çıkarılacaktır. Şekil 22’de çalışmada kullanılan Android cihazda deney sahasının Wenner Alfa dizilimi seçilerek çizdirilen haritasının fotoğrafı yer almaktadır. Çalışma sahasında ölçülen bütün diziliş yöntemleri için Şekil 23’te Android cihazda üçgen interpolasyonu kullanılarak ve Şekil 24’te MATLAB programında lineer ve kübik interpolasyon ile oluşturulmuş rezistivite haritaları gösterilmiştir.



Şekil 20: Deney alanlarının Google Maps’ten alınmış haritada üzerindeki konumları [26]



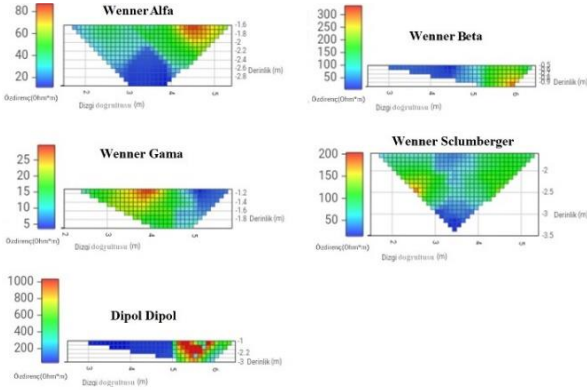
Şekil 19: JavaScript yazılımının akış diyagramı



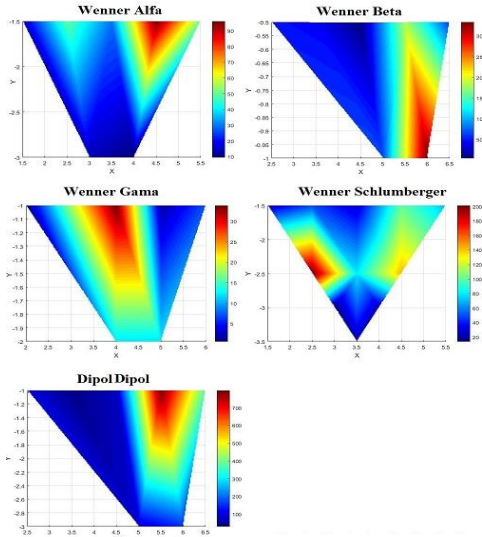
Şekil 21: Deney sahasındaki a) kazıkların 1 metre aralıklı dizilişi ve b) rezistivite cihazının bağlantıları ve fotoğrafı




Şekil 22: Deney sahasının Wenner Alfa dizilimi seçilerek dizilimi toprak yüzeyin haritalandırılması



Şekil 23: Ölçüm sahasında kaydedilen verilerle Android platformda oluşturulan yani bir cep telefonunda çizdirilen tüm dizilim metotları için özdirenç haritaları



(a)



(b)

Şekil 24: Ölçüm alanında kaydedilmiş veriler ile MATLAB programında a) lineer ve b) kübik interpolasyon kullanarak oluşturulmuş tüm dizilim metotlarının özdirenç haritaları

## 6. Sonuç ve Öneriler

Yapılan çalışmada yurtiçinde ve yurtdışında jeofizik ve arkeolojik çalışmalarda çokça kullanılan rezistivite cihazı prototipi üretilmesi amaçlanmıştır. Ülkemizde kullanılan 2 boyutlu rezistivite cihazlarının birçoğu yurtdışı menşelidir. Ülkemizde üretilen bazı cihazlar vardır. Fakat bu cihazlar bir boyutlu rezistivite haritaları oluşturmaktadır ve rezistivite haritalarını bilgisayar üzerinde oluşturabilmektedir. Günümüzde daha çok tercih edilen rezistivite cihazları iki veya üç boyutlu ve Android cihaz üzerinde haritalama yapmaktadır. Bu çalışmada üretilen çok elektrotlu rezistivite cihazı sayesinde teknolojik farkın kapatılması da hedeflenmiştir.

Prototipi yapılan cihaz sekiz elektrotla sahiptir. Sekiz elektrot ile rezistivite yönteminde sıklıkla tercih edilen özel dizilimlere (Wenner Alfa, Wenner Beta, Wenner Gama, Wenner Schlumberger ve Dipol Dipol) uyan akım gerilim kombinasyonlarından alınan çoklu ölçümler mikrodenetleyici ve Android cihazda matematiksel işlemden geçirilerek Android cihazda iki boyutlu rezistivite haritası oluşturulmuştur. Rezistivite cihazında bulunan Arduino Mega 2560 mikrodenetleyicisi, Android cihaz ile Bluetooth modülü üzerinden haberleşmiştir. Özel dizilimlere uygun elektrot bu sayede tayin edilip ölçümler alınmıştır. Android cihaz yazılımı lisans ücreti olmayan ve basitçe kodlanabilen Web üzerinde çalışan Appinventor -Android yazılım geliştirme ortamı-kullanılmıştır. İki boyutlu rezistivite haritalarının oluşturulurken Appinventor içine gömülebilen açık kaynak kodlu JavaScript veri görselleştirme kütüphaneleri kullanılmıştır.

Üretilen rezistivite cihazı prototip maliyeti Aralık 2022 için 4500 ₺ dolaylarındadır. Hesaplı olması açısından prototipi yapılan rezistivite cihazında sekiz elektrot bulunmaktadır.

Hesaplanan özdirenç değerleri ve elektrot konumlarına uygun oluşturulan rezistivite haritalarının çözünürlüğünü yükseltmek için üçgen interpolasyonu Android cihaz üzerinde JavaScript kodlarıyla yapılmıştır. Aynı zamanda elde edilen veriler MATLAB programında yapılan lineer ve kübik interpolasyon yapılarak haritalandırılmıştır. MATLAB programında yapılan interpolasyon uygulanmış rezistivite haritaları, Android cihazda üçgen interpolasyon ile oluşturulan rezistivite haritalarına benzer fakat daha yüksek çözünürlüğe sahiptir. MATLAB programında interpolasyon (lineer ve kübik) yapılırken adım aralıklarının Android cihazdaki adım aralığına göre daha fazla olması çözünürlük farkını doğurmuştur. Android cihazda oluşan donma sorunundan dolayı (adım aralığının 0,1 metreden az seçilmesi halinde) adım aralığı 0,1 seçilmiştir. MATLAB programında kübik interpolasyonla oluşturulan rezistivite haritaları lineer interpolasyon kullanılarak oluşturulan haritalara göre daha yumuşak harita sınırlarına (geçiş) sahiptir.

Prototipi yapılan cihazın fiziksel aksamı; Arduino Mega 2560 mikrodenetleyicisi, Bluetooth modül, araç içi invertör, on altı kanallı iki adet röle kartı, akım-gerilim ölçümü için tasarlanan ölçüm kartları ve sekiz adet galvaniz elektrottan oluşmaktadır. Cihazdan ölçülen akım-gerilim değerleri multimetre ile ölçümün yapıldığı akım-gerilim elektrotlarına bağlanarak ölçümler alınıp karşılaştırılarak cihazdan ölçülen değerlerin doğruluğu test edilmiştir. Multimetre ile ölçümlen akım-gerilim değerleri mutlak doğru kabul edilirse akım ölçümlerinde %5, gerilim ölçümlerinde ise %2,5 ölçüm hatası olduğu görülmüştür. Tasarlanan ölçüm devrelerinin %7,5 civarında

ölçüm hatasına sahip olduğu hesaplanmıştır. Ölçüm devreleri 0,5 miliVolt ölçüm hassasiyetine sahiptir.

Daha sonraki çalışmalarda mikrodenetleyicinin tetikleme için yeterli pin bulunması şartıyla ve eklenmesi istenen elektrotun dört katı kadar röle eklenerek çok daha fazla elektrotlu cihazlar üretilebilir. Aralık 2022 fiyatlarına göre cihaza eklenecek her bir 8 elektrot için 2500 ₺'ye ihtiyaç vardır. Android yazılımı yerine cross platformda oluşturulan programlama dilleri tercih edilirse rezistivite haritaları ios-linux-windows işletim sistemlerine sahip cihazlarda da rezistivite haritaları oluşturulabilir. MATLAB programı kullanılarak iki boyutlu rezistivite haritaları birleştirilmesiyle üç boyutlu rezistivite haritaları oluşturulabilir. İleriki çalışmalarda Mobil cihazlar için de JavaScript kodları yazılarak üç boyutlu rezistivite haritalandırması yapılabilir.

Çalışmada kullanılan dizilimler karşılaştırılacak olursa; 1,5-3 metre derinlikten ölçümlerin alındığı Wenner Alfa ile 1-3 metre derinlikten ölçümlerin alındığı Dipol Dipol dizilimlerinin birbirine yakın rezistivite haritaları oluşturduğu görülmektedir. Fakat Wenner Alfa yönteminde yedi ölçüm kombinasyonuna sahipken Dipol Dipol diziliş yönteminde 18 ölçüm kombinasyonu mevcuttur. Harita üzerindeki farklılık ölçüm kombinasyonları, derinlik ve farklı noktalardan ölçüm yapılmasından kaynaklanmaktadır. 0,5-1 metre derinlikten ölçümlerin alındığı yedi ölçüm kombinasyonu Wenner Beta ve Dipol Dipol dizilimlerinden elde edilen haritalar grafiksel olarak benzerlik göstermektedir. Derinlikler göz önüne alınarak bu benzerlik öngörülebilir. 1-2 metre derinlikten ölçümlerin alındığı yedi ölçüm kombinasyonu olan Wenner Gama ve 1,5-2,5 metre derinlikten ölçümlerin alındığı 11 ölçüm kombinasyonu olan Wenner Schlumberger dizilimlerinde oluşturulan haritalarda elektrotların benzer noktalardan ölçüm alındığı için benzerlik gözükmektedir. Wenner Schlumberger dizilim yöntemi diğer yöntemlerden grafiksel olarak değişik gözükmektedir. Bu farklılıkta Wenner Schlumberger diziliminde ölçüm noktalarının diğerlerinden daha farklı noktalardan daha geniş aralıklardan alınması etkili olmuştur. Literatürde sıkça kullanılan ters-çözüm modelleri yöntemleri, cihazın harita oluşturma algoritmalarına eklenerek sistemin daha doğru haritalama yapacağı öngörülmektedir.

## Kaynaklar

[1] C. Schlumberger, "E' tude sur la Prospection E' lectrique du Sous-sol," Paris, 1920.  
 [2] F. A. Wenner, "Method of Measuring Earth Resistivity," U.S. Government Printing Office, 12.cilt, 4.sayı, 1916.  
 [3] M. H. Loke, "The inversion of two-dimensional resistivity data", Yayınlanmamış Doktora Tezi, Un. Of Birmingham, 1994.  
 [4] H. Nazifi, ve L. Gülen, "Elektromanyetik ve düşey elektrik sondaj metodu kullanılarak yeraltı suyu araştırması", Maden Tetkik ve Arama Dergisi, 158.,333-350, 2019.  
 [5] A. Özdemir, "Çok-Elektrotlu Jeofizik Rezistivite Ölçümlerinin Yeraltı suyu ve Jeotermal Arama Alanlarındaki Uygulamalarının Değerlendirilmesi," Sondaj Dünyası Dergisi, 6.cilt, ss. 7-13, 2008.  
 [6] E. Özgüleş, "Jeotermal Alanların Jeofizik Yöntemlerle Araştırılması ve Bir Uygulama Örneği", Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta, 2011.  
 [7] A. Uçar, "2-Boyutlu Rezistivite Yöntemi Kullanılarak Karstik Aktivite Belirlenmesi", Yüksek Lisans Tezi, Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Antalya, 2014.

[8] A. Ateş, ve B. Yeşil, "Küçük Melen Çayı Yatağı Civarında Yeraltı Suyu Akiferlerinin Tespitinde Jeofizik ve Düşey Elektrik Sondaj Verilerinin Kullanılması: Düzce Örneği", Teknik Bilimler Dergisi, 1-14,2014.  
 [9] S. Yılmaz ve M. Köksoy, "Bir Toprak Dolgu Barajındaki Sızıntı Yollarının Belirlenmesinde Elektrik Özdirenç Görüntüleme ve Doğal Potansiyel Yöntemlerin Uygulanması," Pamukkale Üniversitesi Mühendislik Bilim Dergisi, c. 23(6), ss. 799-803, 2017.  
 [10] A. Neyamadpour, W. A. Wan ve T. Samsudin, "Comparison of Wenner and dipole-dipole arrays in the study of an underground three-dimensional cavity", Journal of Geophysics and Engineering, c.7, ss. 30-40, 2010.  
 [11] M.A Berge, "Elektrik Özdirenç Ters-Çözümüyle Çok Katmanlı Arkeolojik Yerleşmelerin Görüntülendirilmesi," Doktora Tezi, Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü, İzmir, 2011.  
 [12] M.A Berge, M.G Drahor, "3D induced polarization and electrical resistivity tomography surveys from an archaeological site", 12th International Conference of Archaeological Prospection, 2017, 20-22.  
 [13] M. Arslan – N. Tüner-Önen, "Phaselis Kenti'nde 2019 Yılında Gerçekleştirilen Yüzeysel Araştırmaları ve Kazı Çalışmaları," Phaselis V, 2019, 425-463.  
 [14] Y. L. Ekinçi ve M. Kaya, "3D resistivity imaging of buried tombs at the Parion necropolis," Journal Of The Balkan Geophysical Society, 1-8, 2007.  
 [15] F. Fischanger, G. Catanzariti, C. Comina, L. Sambuelli, G. Morelli, F. Barsuglia, A. Ellaithyf, F. Porcelli, "Geophysical anomalies detected by electrical resistivity tomography in the area surrounding Tutankhamun's tomb," Journal of Cultural Heritage, 63-71, 2019.  
 [16] İ. Ulusoy, H. Artuner ve E. Aydar, "Dağıtılmış Anahtarlamalı Özdirenç Görüntüleme Sistemi", Hacettepe Üniversitesi Yerbilimleri Uygulama ve Araştırma Merkezi Bülteni, Yerbilimleri,33.cilt, 205-218, 2012.  
 [17] S. Akpancar, "İki Rezistivite-İp Alıcı / Verici Tasarımı ve Pc'de Verilerin Analizi," Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta, 2012.  
 [18] M. H. Loke, I. Acworth ve T. Dahlin, "A comparison of smooth and blocky inversion methods in 2-D electrical imaging surveys," Exploration Geophysics, c. 34, ss. 182-187, 2003.  
 [19] T. Dahlin, "The development of DC resistivity imaging techniques," Computers & Geosciences, 27.cilt, 1019-1029, 2001.  
 [20] A. Samouëlian, I. Cousin, A. Tabbagh, A. Bruand ve G. Richard, "Electrical resistivity survey in soil science: a review," Soil and Tillage Research, 2.cilt, 173-193, 2005.  
 [21] Elektrik Özdirenç Yöntemi-Jeoelektrik Yöntemler, URL: <https://web.itu.edu.tr/~caglari/jeotermal/jeoelek.html> (Erişim zamanı; Mart, 06, 2022).  
 [22] Araç içi invertör, URL: [www.n11.com/\\_seyahat-urunleri/220v-donusturucu](http://www.n11.com/_seyahat-urunleri/220v-donusturucu), (Erişim zamanı; Nisan, 14, 2020)  
 [23] Arduino Türkiye, URL: [arduinoturkey.com](http://arduinoturkey.com) (Erişim zamanı; Mayıs, 17, 2022).  
 [24] Massachusetts Institute of Technology, "MIT App Inventor", 2010. Erişim Adresi: <https://appinventor.mit.edu/>, (Erişim zamanı; Şubat, 05, 2022).



- [25] GitHub, Graph3d Documentation, URL: <https://visjs.github.io/visgraph3d/docs/graph3d/index.html> (Erişim zamanı; Temmuz, 24, 2022).  
[26] Google Maps, “Çorlu Mühendislik Fakültesi Konumu,” URL: [Google Maps](https://www.google.com/maps) (Erişim zamanı; Nisan ,14 ,2022).

## Özgeçmişler



**Hüsnü Canbolat**, 1995 yılında İstanbul’da doğdu. Lisans ve Yüksek Lisansını Tekirdağ Namık Kemal Üniversitesi Elektronik ve Haberleşme Mühendisliği Anabilim Dalı’nda tamamladı. Yüksek Lisansı, jeofizik ve elektronik disiplinlerinde “Toprak direncini ölçen kablosuz haberleşmeli cihaz tasarımı ve toprak profilinin haritalanması” tezi ile tamamlamıştır. Akademik çalışmalarına Görüntü- Video İşleme, Sinyal İşleme, Ses İşleme, Hareket Analizi, Büyük Veri, İnsan Bilgisayar Etkileşimi, Elektronik Cihazlar konularında devam etmektedir. Özel sektörde elektronik mühendisi, araştırma geliştirme uzmanı ve yazılımcı olarak çalışan Canbolat halen Trabzon Üniversitesi Sporda Performans Değerlendirme ve Yetenek Seçimi Uygulama ve Araştırma Merkezi’nde Öğretim Görevlisi olarak spor yazılımları üzerinde çalışmaktadır. Aynı zamanda Karadeniz Teknik Üniversitesi Elektronik Anabilim Dalı’nda doktora eğitimine devam etmektedir.



**Murat Yiğit**, 1992 yılında Tekirdağ’da doğdu. 2017 yılında Namık Kemal Üniversitesi Elektronik ve Haberleşme Mühendisliği’ne başladı. 2019 yılında endüstriyel otomasyon alanında iş hayatına atıldı. PCB tasarım, gömülü yazılım, işletim sistemleri, web yazılımları, veri tabanı yönetim sistemleri, ağ topolojileri ve protokolleri, endüstriyel haberleşme protokolleri, enerji verimliliği, atık su yönetimi, yanıcı-patlayıcı-boğucu-toksik gaz algılama sistemleri, kişisel koruyucu donanımlar, grafik tasarım, katı model tasarım, mekanik tesisat, metal işleme süreçleri gibi konularda deneyimlidir. Çalışma hayatına IoT, MES, OEE, CRM, PLM gibi konularda yazılımlar geliştirerek; Aselsan, Makine Kimya Enstitüsü, Siemens, Coca Cola, BOTAŞ, organize sanayi bölge müdürlükleri vb. savunma, gıda, enerji ve tekstil endüstrilerinin dijitalleşmesine katkılar sağlamaya devam etmektedir. Evli ve iki çocuk babasıdır.



**Doç. Dr. Reşat Mutlu**, 1973 yılında Tekirdağ’da doğdu. Lisans eğitimini Yıldız Teknik Üniversitesi Elektrik Mühendisliği bölümünde, Yüksek lisans ve doktorasını ise Rensselaer Polytechnic Enstitü’de sırasıyla 1998 ve 2004 yıllarında tamamladı. An itibarıyla Tekirdağ Namık Kemal Üniversitesi Çorlu Mühendislik Fakültesi’nde doçent olarak görev yapmaktadır. Çalışma alanları Elektronik sistemlerin modellenmesi, Memristör, Memristif sistemler, Rezistif RAM bellekler, Güç hattı haberleşme sistemleri ve Rezistif sinterleme sistemleridir.



# Evrişimsel Sinir Ağları Temelli Derin Öğrenme Modelleri Kullanılarak Beyin Tümörü Manyetik Rezonans Görüntülerinin Sınıflandırılması

## Classification of Brain Tumor Magnetic Resonance Images Using Convolutional Neural Networks-Based Deep Learning Models

   
Fatih Uysal<sup>1</sup>, Metehan Erkan<sup>2</sup>

<sup>1</sup>Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik-Mimarlık Fakültesi, Kafkas Üniversitesi, Kars, Türkiye Cumhuriyeti

fatih.uysal@kafkas.edu.tr

<sup>2</sup>Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Gazi Üniversitesi, Ankara, Türkiye Cumhuriyeti

metehan.erkan@gazi.edu.tr

### Özet

Beyin tümörü, beyindeki anormal hücre kitlelerinin iyi veya kötü huylu olarak oluşması ve büyümesidir. Çalışma kapsamında beyin tümörü manyetik rezonans görüntüleri üzerinde evrişimsel sinir ağları temelli derin öğrenme modelleri kullanılarak tümör sınıflarının tespit edilmesi amaçlanmıştır. Beyin tümörlerinin sınıflandırılması için derin öğrenme modellerinden AlexNet, VGG ve MobileNet kullanılmıştır. Kaggle platformu üzerinden açık kaynaklı olarak paylaşılan bir normal ve üç anormal olmak üzere dört sınıflı yapıya sahip olan bir beyin tümörleri veri seti kullanılmıştır. Anormal sınıflar, glioma, meningeoma ve pituitary'dir. Veri seti üzerinde sınıflandırma öncesinde ön işlem ile veri artırma adımlarında; kontrast sınırlı uyarlanabilir histogram eşitleme, dikey ve yatay çevirme işlemleri uygulanmıştır. Bu işlemin ardından derin öğrenme modellerinin veri setine bağımlılığını analiz edebilmek, azaltmak ve tümör sınıflarının tespit edilebilmesi için veri seti farklı farklı eğitim, doğrulama ve test yüzdelerinde kullanılarak sınıflandırmalar gerçekleştirilmiştir. Beyin tümörlerinin sınıflandırılması için farklı ön işlemlerle derin öğrenme modelleriyle gerçekleştirilen 225 adet farklı sınıflandırma işlemi sonucunda en iyi doğruluk ve f1-skorları sırasıyla; AlexNet modelinde %94.471, 0.94; VGG16 modelinde %96.875, 0.97; MobileNetV3 modelinde %95.673, 0.96'dir.

**Anahtar kelimeler:** Beyin Tümörü, Biyomedikal Görüntü İşleme, Derin Öğrenme, Evrişimsel Sinir Ağları, Sınıflandırma, Yapay Zeka

### Abstract

A brain tumor is the generation and growth of benign or malignant abnormal cell masses in the brain. In this paper, it is aimed to classify brain tumors with deep learning models based on convolutional neural network on magnetic resonance images of brain tumors. AlexNet, VGG and

MobileNet deep learning models are used to classify brain tumors. An open-source brain tumors dataset that is available on Kaggle and has 1 normal, 3 abnormal, 4 total classes is used. Abnormal classes are glioma, meningeoma, and pituitary. Contrast limited adaptive histogram equalization (CLAHE), vertical and horizontal flip preprocesses have been used on the dataset as augmentation. After these processes, dataset used with different training, validation, and test split sizes in order to determine the dependency of deep learning models on dataset, reduce this dependency, and detect brain tumor classes. To classify brain tumors, 225 different classification process has been done with deep learning models which has different preprocess parameters and the best accuracy and f1-scores are; for AlexNet model 94.471%, 0.94; for VGG model 96.875%, 0.97; for MobileNetV3 model 95.673%, 0.96; respectively.

**Keywords:** Brain Tumor, Biomedical Image Processing, Deep Learning, Convolutional Neural Networks, Classification, Artificial Intelligence.

## 1. Giriş

Beyin tümörü, beyindeki anormal hücre kitlelerinin kansersiz iyi huylu veya kanserli kötü huylu olarak oluşması ve büyümesiyle meydana gelmektedir. Beyin tümörleri, başlangıç noktalarına bağlı olarak birincil veya ikincil olarak beyine yayılmaktadır. Birincil beyin tümörleri, direkt olarak beyinde başlamaktadır. İkincil beyin tümörleri ise, vücudun diğer kısımlarında başlayıp sonrasında beyine ulaşabilmekte ve genellikle yetişkinlerde daha sık gözlemlenmektedir [1].

Beyin tümörünün büyüme hızı, konumu ve boyutuna bağlı olarak semptom ve belirtileri değişkenlik göstermektedir. Bireylerde beyin tümörüne ilişkin olarak görülebilen genel belirtiler ve semptomlar; dengede, konuşmada ve karar vermedeki zorluklar, kademeli olarak bacak veya kolda hareket ve hissin kaybedilmesi, çift veya bulanık görme gibi çeşitli görme kayıpları, açıklanamayacak

olan kusma ve bulantılar ile öncelikle yavaş seyredip ardından sıklaşan ve daha da şiddetlenen baş ağrıları şeklindedir [1].

Beyin tümörlerinin sebepleri incelendiğinde gerek birincil gerekse de ikincil beyin tümörlerinde çeşitli olduğu görülmektedir. Birincil beyin tümörleri, beynin kendisinden veya beyne yakın olan hipofiz bezi, epifiz bezi, beyni örten zarlar ile kranial sinirlerden kaynaklanmaktadır. İkincil beyin tümörlerinin meydana gelme sebeplerine bakıldığında ise; vücudun meme, kolon, akciğer, böbrek gibi kısımlarında başlayıp ardından beyne yayılan kanserden kaynaklandığı anlaşılmaktadır. Buna ek olarak beyin tümörlerindeki risk faktörlerine bakıldığında, ailede beyin tümörü öyküsünün olması ve radyasyona maruz kalma durumları tümörün beyinde meydana gelmesinde çok büyük bir etkidir [1].

İyi huylu beyin tümörlerinden sıklıkla ve tipik olarak görülenleri; glioma, meningioma, pituitary, craniopharyngioma, schwannoma, neurofibroma, hemangioblastoma, chondroma ve osteoma gibi beyin tümörü tipleridir. Glioma, çoğunlukla beyinde görülmekle birlikte bazen de omurilikte ortaya çıkabilen bir tümör tipidir. Beyin tümörleri içerisinde %33 gibi ciddi bir oranda glioma bulunmaktadır. Meningiomalar, beyin kafatasının altında yer alan ve beyni kaplayıp koruyan dış üç doku tabakası olan meninksler sebebiyle meydana gelmektedir. Bunlar, en yaygın görülen beyin tümörlerinden biri olup, kadınlarda daha sık görülmekte ve çoğunlukla iyi huylu olan tümörlerdir. Pituitary ise, hipofiz bezinde gelişir, büyüme hızı yavaştır ve görme sorunlarına neden olabilir [2]. Çalışma kapsamında sınıflandırma kullanılan anormal sınıflar; glioma, meningioma ve pituitary olarak bilinen bu üç tane iyi huylu beyin tümörü türleridir.

Beyin tümörü manyetik rezonans görüntülerinin derin öğrenmeyle sınıflandırmasının gerçekleştirildiği bu çalışmanın devamında, ikinci kısımda ilgili çalışmalar başlığı altında literatürdeki beyin tümörü tespit ve sınıflandırma çalışmalarından, çalışmanın literatürdeki farkından ve ana katkılarından bahsedilmiştir. Üçüncü kısımdaki materyaller ve yöntemler bölümünde, kullanılan veri seti detayları, veri ön işlemleri ve sınıflandırma modelleri ifade edilmiştir. Uygulamalar başlığı altındaki dördüncü kısımda ise, beyin tümörü sınıflandırması kullanılan uygulama ve uygulama sonucunda elde edilen sonuçlar açıklanmıştır. Son olarak beşinci kısımda yer alan sonuçlar ve gelecek çalışmalar bölümünde de çalışma kapsamında elde edilen beyin tümörü tespit sonuçları ve kullanılan modeller analiz edilerek, ileride ne gibi yeni çalışmalar yapılabileceğinden bahsedilmiştir.

## 2. İlgili çalışmalar

Çalışma kapsamında açık kaynaklı bir veri seti kullanılarak beyin tümörü manyetik rezonans görüntülerinde derin öğrenme modelleriyle sınıflandırma işlemleri gerçekleştirilmiştir. Buna ilişkin olarak literatüre bakıldığında ise beyin tümörlerinin tespit ve sınıflandırılmasıyla ilgili birçok çalışma mevcuttur. Raza ve diğerleri tarafından, Çin'deki Nanfang ve Tianjin Medikal Hastanelerinden alınan


dört farklı sınıfa ait açık kaynaklı beyin tümörü manyetik rezonans görüntülerinde hibrit bir derin öğrenme modeli geliştirilmiş ve güncel dokuz farklı derin öğrenme modeliyle karşılaştırılmıştır [3]. T1-ağırlıklı açık kaynaklı bir beyin tümörü veri seti üzerinde Qureshi ve diğerleri tarafından önerdikleri derin öğrenme temelli ultra-hafif beyin tümörü tespiti sistemi ile çok sınıflı beyin tümörü tespit işlemleri gerçekleştirilmiştir [4]. Çok modlu beyin tümörü tespiti için Maqsood ve diğerleri tarafından, açık kaynaklı BraTS 2018 ve Figshare veri setleri kullanılarak beş adımlı bir yöntem önerilmiştir. Bölütlemeye 17 katmanlı derin sinir ağı, özellik çıkarımında modifiye edilmiş MobileNetV2, sınıflandırmada ise çok sınıflı destek vektör makineleri kullanılmıştır [5]. Almalki ve diğerleri tarafından, Kaggle'daki açık kaynaklı ve dört sınıflı bir beyin tümörü veri setinde farklı sayıda katmanlı önerilen üç tane izole evrimsel sinir ağları ve destek vektör makineleriyle yapılan sınıflandırma doğruluğu %98 olarak elde edilmiştir [6]. Beyin tümörlerinin sınıflandırılması için Younis ve diğerleri tarafından kullanılan evrimsel sinir ağı modeli, VGG16 modeli ve topluluk öğrenmesi ile yapılan işlemler sonucunda en yüksek doğruluk oluşturulan topluluk modelinde %98,41 olarak bulunmuştur [7]. Kaggle platformu üzerinde açık kaynaklı olarak paylaşılan beyin tümörü veri seti kullanılarak, Google-Net ve destek vektör makineleri ile softmax sınıflandırıcı kullanılarak geliştirilen hibrit derin öğrenme modelleriyle Rasool ve diğerlerinin elde ettiği en yüksek doğruluk değeri %98,1'dir [8]. Latif tarafından açık kaynaklı beyin tümör MR görüntüleri üzerinde, evrimsel sinir ağları temelli oluşturulan modellerde sınıflandırma ve bölütlem çalışması yapılarak, sonuçları literatürle karşılaştırılmıştır [9]. Kaggle platformu üzerinde paylaşılan açık kaynaklı beyin tümör görüntüleri kullanılarak, Mgbejime ve diğerleri tarafından önerilen paralel evrimsel sinir ağı modeliyle gerçekleştirilen sınıflandırma işlemiyle %98,7 doğruluk değeri elde edilmiştir [10]. Nayak ve diğerleri tarafından, Figshare üzerinden açık kaynaklı olarak paylaşılan çok sınıflı beyin tümör görüntüleri üzerinde geliştirilen Dense EfficientNet modeli ile sınıflandırma sonucunda elde edilen doğruluk %98,78'dir [11]. BrainGAN olarak Alrashedy ve diğerleri tarafından önerilen çatı (framework) ile beyin tümör görüntülerinde öncelikle DCGAN ve Vanilla GAN ile veri artırma işlemi, ardından ise evrimsel sinir ağı, MobileNet ve ResNet ile çok sınıflı sınıflandırma yapılarak, en iyi sınıflandırma sonucu DCGAN ile üretilen verilerle ResNet modelinde %99,09 doğruluk olarak açıklanmıştır [12]. Beyin tümör görüntülerinde çekişmeli üretici ağlar ve varyasyonel otokodlayıcıların birleşimiyle ResNet sınıflandırıcı kullanılarak gerçekleştirilen sınıflandırma işleminde Ahmad ve diğerleri doğruluğu %96,25 olarak elde etmiştir [13]. Tummala ve diğerleri tarafından, T1 ağırlıklı beyin MR tümör görüntülerinden sınıflandırma için görü transformerları (vision transformers) topluluk (ensemble) öğrenmesiyle kullanılarak elde edilen en yüksek doğruluk %98,70'dir [14]. Özellikle son yıllarda yapılan çalışmalar incelendiğinde beyin tümörü sınıflandırılması ile ilişkili olarak kullanılan veri setlerinin çoğunlukla açık kaynaklı manyetik rezonans görüntüleri olduğu, kullanılan modellerin ise derin öğrenme temelli VGG, MobileNet, Google-Net gibi modeller olduğu görülmektedir.

Beyin tümörü manyetik rezonans görüntülerinin derin öğrenmeyle sınıflandırılmasının gerçekleştirildiği bu çalışmanın literatürden farkı ve ana katkıları aşağıda maddeler halinde sıralanmıştır.

- Literatürdeki mevcut derin öğrenme modellerinden AlexNet, VGG ve MobileNetV3, çalışma kapsamında çok sınıflı sınıflandırma için modifiye edilmiştir.
- Veri setinin ham olarak kullanılmasının aksine beyin tümörü tespitinde modellerin en iyi şekilde eğitimine katkı sağlamak için çeşitli çok sayıda ön işlem ve veri artırma işlemleri uygulanmıştır.
- Sınıflandırma kapsamında elde edilen sonuçların tam olarak ve doğru bir şekilde analiz edilebilmesi için mümkün olan tüm değerlendirme metrikleri (hassasiyet, duyarlılık, fl-skor, test doğruluğu, ROC eğrisi, AUC skoru, doğrulama ve eğitim kaybı) elde edilmiştir.
- Veri seti dağılımında üç farklı yaklaşıma gidilerek, derin öğrenme modellerindeki özellikle eğitim veri seti miktarının ağ öğrenimine etkisi bu çalışma özelinde incelenmiştir.
- Çalışma kapsamında toplamda 225 adet farklı sınıflandırma işlemi gerçekleştirilerek; en iyi veri seti dağılımı, en uygun ön işlem ve en optimum derin öğrenme modeli belirlenmiştir.


### 3. Materyaller ve Yöntemler

Derin öğrenmeyle beyin tümörü manyetik rezonans görüntülerinin sınıflandırılması çalışması için kullanılan veri seti, açık kaynaklı ve Kaggle platformu üzerinde paylaşılan bir veri setidir [15]. Veri setinde, biri normal, diğer üçü anormal olmak üzere toplamda 4 farklı sınıf mevcuttur. Anormal sınıflar ise; glioma, meningioma ve pituitary'dir. Bu sınıflara ilişkin örnek görseller aşağıdaki şekil-1'de verilmiştir.



Şekil-1: Beyin tümörü manyetik rezonans görüntülerine ilişkin görseller

Veri setindeki her biri sınıfa ait görüntü miktarları incelendiğinde birbirinden farklı olduğu ancak anormal sınıfların miktarlarının birbirlerine çok yakın, normal sınıfın miktarının ise her bir anormal sınıf miktarının yarısından biraz daha az oldukları gözlemlenmektedir. Veri seti miktarları ve dağılımına ilişkin detaylar aşağıdaki Şekil-2'de verilmiştir.




Şekil-2 Beyin tümörü veri seti dağılımı

Derin öğrenmeyle sınıflandırma ve/veya tespit problemlerinde kullanılan modellerin ağ eğitiminde veri miktarı çok önemlidir. Bu sebeple bu çalışma kapsamında beyin tümörü ham olarak değil, çeşitli ön işlem ve veri artırma adımlarından geçirilerek kullanılmıştır. Veri setinde ön işlem olarak kontrast sınırlı uyarlanabilir histogram eşitleme (CLAHE, contrast limited adaptive histogram equalization) uygulanmıştır. Beyin tümörü veri setine eğitim esnasında ise her bir sınıfta eşit olacak şekilde 1000 görüntü artırması (augmentasyonu) yapılmıştır. Veri artırma işleminde; CLAHE, dikey çevirme (vertical flip) ve yatay döndürme (horizontal flip) işlemleri uygulanmıştır. Ayrıca veri artırma haricinde orijinal görüntülerde de CLAHE işlemi yapılmıştır. Veri artırma işlemleri sonrasında her bir sınıfta ve toplamda elde edilen yeni veri miktarları aşağıdaki tablo-1'de verilmiştir.

Tablo-1: Veri artırma ve sonrasında sınıflara ilişkin görüntü miktarları

Normal	Glioma	Meningioma	Pituitary	Veri artırmaz
396	926	937	901	3160
Normal	Glioma	Meningioma	Pituitary	Veri artırmalı
646	1176	1187	1151	4160

Veri setinde uygulanan CLAHE işlemi ardından her bir sınıftaki görüntülerin kontrastında artma veya azalmalar gözlemlenmiştir. Bu ön işlem sonrasında veri setindeki görüntülere ilişkin örnek görseller aşağıdaki şekil-3'de verilmiştir.



Normal görüntü

Glioma görüntüsü

Meningioma görüntüsü

Pituitary görüntüsü

Şekil-3: Önışlem uygulanmış beyin tümörü manyetik rezonans görüntülerine ilişkin görseller

Beyin tümörü manyetik rezonans görüntülerinin sınıflandırılması için kullanılan derin öğrenme temelli modeller AlexNet, VGG ve MobileNet'dir. Her üç model de ön eğitilmiş olarak transfer öğrenme kullanılmıştır. Son katmanları ImageNet veri setindeki sınıflardan farklı olarak, bu çalışma kapsamında uygun olacak şekilde dört sınıflı olarak değiştirilmiştir.

AlexNet, Alex Krizhevsky tarafından ImageNet veri setiyle gerçekleştirilen 2012 yılındaki yarışmada geliştirilmiş ve başarı elde etmiştir [16]. ImageNet veri seti aslında, ilk kez 2009 yılında duyurulan çok büyük boyutlu ve çok sınıflı bir açık kaynaklı veri setidir [17]. ImageNet ile büyük başarı elde eden AlexNet mimarisi, literatüre sunulduğu tarihten itibaren birçok yeni çalışmada kullanılmıştır. Çalışma kapsamında kullanılan AlexNet mimarisinin yapısı ise aşağıdaki şekil-4'de verilmiştir.

Katman	Kernel	Stride	Padding
Conv2d	(11, 11)	(4, 4)	(2, 2)
ReLU	-	-	-
MaxPool2d	3	2	0
Conv2d	(5, 5)	(1, 1)	(2, 2)
ReLU	-	-	-
MaxPool2d	3	2	0
Conv2d	(3, 3)	(1, 1)	(1, 1)
ReLU	-	-	-
Conv2d	(3, 3)	(1, 1)	(1, 1)
ReLU	-	-	-
Conv2d	(3, 3)	(1, 1)	(1, 1)

ReLU	-	-	-
MaxPool2d	3	2	0
AdaptiveAvgPool2d	-	-	-
Classifier (4 sınıf)	-	-	-

Şekil-4: Modifiye edilen AlexNet mimarisi

VGG, Simonyan ve Zisserman tarafından ImageNet yarışmasında 2014 yılında duyurulan, farklı katmanlara (13, 16, 19) sahip olan ve çoğunlukla 3x3'lük evrişim katmanlarından meydana gelen bir mimarıdır [18]. Bu çalışmayla birlikte kullanılan VGG mimarisi 16 katmanlı olup aşağıdaki şekil-5'deki gibidir.

Katman	Kernel	Stride	Padding
Conv2d	(3, 3)	(1, 1)	(1, 1)
ReLU	-	-	-
Conv2d	(3, 3)	(1, 1)	(1, 1)
ReLU	-	-	-
MaxPool2d	2	2	0
Conv2d	(3, 3)	(1, 1)	(1, 1)
ReLU	-	-	-
Conv2d	(3, 3)	(1, 1)	(1, 1)
ReLU	-	-	-
MaxPool2d	2	2	0
Conv2d	(3, 3)	(1, 1)	(1, 1)
ReLU	-	-	-
Conv2d	(3, 3)	(1, 1)	(1, 1)
ReLU	-	-	-
MaxPool2d	2	2	0
Conv2d	(3, 3)	(1, 1)	(1, 1)
ReLU	-	-	-
Conv2d	(3, 3)	(1, 1)	(1, 1)
ReLU	-	-	-
Conv2d	(3, 3)	(1, 1)	(1, 1)
ReLU	-	-	-
MaxPool2d	2	2	0
AdaptiveAvgPool2d	-	-	-
Classifier (4 sınıf)	-	-	-

Şekil-5: Modifiye edilen VGG mimarisi

MobileNet, içerisinde 3x3 ve 5x5'lik çok sayıda darboğaz (bottleneck) bloklarını içeren geliştirilmiş bir evrişimsel sinir ağıdır. [19]. Çalışmaya ilişkin olarak güncellenen MobileNetV3 mimarisi aşağıdaki şekil-6'da belirtilmiştir.

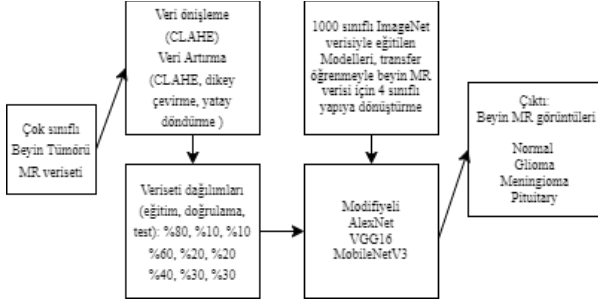
Katman	Kernel	Stride	Padding
Conv2d	(3, 3)	(2, 2)	(1, 1)
InvertedResidual Block			

Conv2d	(3, 3)	(2, 2)	(1, 1)
SqueezeExcitation	(1, 1)	(1, 1)	-
Conv2d	(1, 1)	(1, 1)	-
Farklı Katmanlı 10 x InvertedResidual Block			
Conv2d	(1, 1)	(1, 1)	-
AdaptiveAvgPool2d	-	-	-
Classifier (4 sınıf)	-	-	-

Şekil-6: Modifiye edilen MobileNet mimarisi

#### 4. Uygulamalar

Farklı ön işlemlerle derin öğrenme modelleriyle beyin tümörü sınıflandırılması için toplamda 225 adet farklı sınıflandırma işlemi gerçekleştirilmiştir. Çok sınıflı beyin tümörü sınıflandırılması için bu çalışma kapsamında önerilen modeller aşağıdaki şekil-7’de verilmiştir.



Şekil-7: Beyin tümörü sınıflandırması için önerilen modeller

AlexNet, VGG ve MobileNet temelli derin öğrenme modelleriyle gerçekleştirilen sınıflandırma işlemlerinde Tübitak Truba sisteminden faydalanılmıştır. Kullanılan veri setinde eğitim, doğrulama ve test yüzdeleri öncelikle üç farklı dağılım üzerinde ele alınmıştır. Bunlar; doğrulama ve test yüzdeleri eşit olacak şekilde %10, %20 ve %30’dur. Ardından veri artırma olmadan analiz için, 4.dağılım’da yapılmıştır. Bu farklı durumlar için kullanılan tüm yüzdeler ile veri miktarı dağılımları aşağıdaki tablo-2’de verilmiştir.

Tablo-2: Veri seti yüzdeleri ve veri miktarı dağılımı

Dağılımlar	Eğitim	Doğrulama	Test
1.Dağılım	%80 ; 3328	%10 ; 416	%10 ; 416
2.Dağılım	%60 ; 2496	%20 ; 832	%20 ; 832
3.Dağılım	%40 ; 1664	%30 ; 1248	%30 ; 1248
4.Dağılım	%80 ; 2528	%10 ; 316	%10 ; 316

Beyin tümörü sınıflandırılması işlemlerinde veri seti dağılım yüzdeleri değiştirilerek, farklı modellerle, CLAHE’de farklı tile boyutu ve clip limit değerleri için toplamda gerçekleştirilen çok sayıda farklı sınıflandırma işlemiyle; sınıflandırma için en uygun model, veri seti dağılımı ile önışlemin bulunması hedeflenmiştir. CLAHE için tile boyutlarında (2,2), (4,4), (6,6), (8,8), (10,10), clip limitler için ise 1, 2, 3, 4, 5 olmak üzere 5’er farklı değer kullanılmıştır. Sırasıyla veri seti, model, dağılım sırası, tile boyutu ve clip

limit değişkenleriyle 225 adet sınıflandırma yapılmıştır. Her bir model için değişken kombinasyonları adedince eğitim yapıldı. Örneğin model: VGG16, 1.dağılım, kare boyutu (tile size): (4,4), klip limit (clip limit):4 gibi. Her bir model eğitiminde verilen parametrelere sahip veri seti hazırlandıktan sonra ön eğitilmiş modellerin tüm katmanları eğitime başlandı. Eğitimde çapraz entropi kaybı (cross entropy loss), rasgele gradyan inişi (stochastic gradient descent) ve adım (step) öğrenme oranı kullanılmıştır. Ardından eğitilmiş modeller test edilmiştir. Test sonuçları incelendiğinde en iyi sınıflandırma sonucu elde edilen kombinasyon aşağıdaki tablo-3’de verilmiştir.

Tablo-3: En iyi sınıflandırma sonucuna sahip model kombinasyonları


Modeller	Dağılım	Tile Boyutu	Clip Limiti
AlexNet	1.dağılım	(10,10)	1
VGG	1.dağılım	(2,2)	3
MobileNet	1.dağılım	(8,8)	2

Tablo-3’de verilen model kombinasyonlarıyla elde edilen sınıflandırma sonuçları ise, aşağıdaki tablo-4’de belirtilmiştir.


Tablo-4: Sınıflandırma sonuçları

Modeller	Hassasiyet	Duyarlılık	F1-skor	Doğruluk
AlexNet	0.94	0.94	0.94	%94,471
VGG	0.97	0.97	0.97	%96,875
MobileNet	0.96	0.96	0.96	%95,673


Tablo-3’de verilen model kombinasyonlarıyla elde edilen confusion matrix, eğitim ve doğrulama için her bir epochtaki kayıpları ifade eden grafikler, ROC eğrileri sırasıyla aşağıdaki şekillerde ifade edilmiştir.



Şekil-8: AlexNet için confusion matrix



Şekil-9: VGG için confusion matrix



Şekil-10: MobileNet için confusion matrix




Şekil-11: AlexNet için eğitim doğrulama kaybı




Şekil-12: VGG için eğitim doğrulama kaybı



Şekil-13: MobileNet için eğitim doğrulama kaybı




Şekil-14: AlexNet için ROC eğrisi



Şekil-15: VGG için ROC eğrisi





Şekil-16: MobileNet için ROC eğrisi


Yukarıdaki şekillerde ve tablo-4’de verilen sınıflandırma sonuçları incelendiğinde; en iyi f1-skor, hassasiyet ve test doğruluk değerlerinin VGG modelinden elde edildiği gözlemlenmektedir.

Tablo-3’de verilen model detayları ile Tablo-4’de verilen sınıflandırma sonuçları; çalışma kapsamında gerçekleştirilen 225 adet farklı sınıflandırma işlemi sonucunda bulunan ve kullanılan verisetinde hem veri artırma hem de CLAHE’nin uygulandığı veriler üzerinde gerçekleştirilmiştir. Elde edilen sonuçların daha detaylı analizi için ayrıca veri artırma ve CLAHE işlemlerinin diğer farklı üç durumu için 9 farklı sınıflandırma işlemi de yapılmıştır. Bu durumlar sırasıyla; 1.durum: veri artırma var, clahe yok; 2.durum: veri artırma yok, clahe var; 3.durum: veri artırma yok, clahe yok şeklindedir. Farklı durumlarda elde edilen sınıflandırma sonuçları aşağıdaki Tablo-5’de verilmiştir.

Tablo-5: Farklı Durumlar için Sınıflandırma sonuçları

Modeller	Hassasiyet	Duyarlılık	F1-skor	Doğruluk
AlexNet (1.durum)	0.93	0.93	0.93	%93,269
VGG (1.durum)	0.95	0.95	0.95	%94,712
MobileNet (1.durum)	0.95	0.95	0.95	%94,712
AlexNet (2.durum)	0.96	0.96	0.96	%95,886
VGG (2.durum)	0.96	0.96	0.96	%96,203
MobileNet (2.durum)	0.96	0.96	0.96	%95,886
AlexNet (3.durum)	0.95	0.95	0.95	%94,937
VGG (3.durum)	0.95	0.95	0.95	%95,253
MobileNet (3.durum)	0.95	0.95	0.95	%94,937


Tablo-5 incelendiğinde farklı durumlar için en iyi doğruluk sonucu VGG modelinde 2.durum için elde edildiği görülmektedir. Bu durum için ilgili değerlendirme metrikleri aşağıdaki şekillerle eklenmiştir.



Şekil-17: VGG (2.durum) için confusion matrix



Şekil-18: VGG (2.durum) için eğitim doğrulama kaybı



Şekil-19: VGG (2.durum) için ROC eğrisi

Hem veri artırma hem de CLAHE varken elde edilen sonuçları gösteren Tablo-4 ile veri artırma ve CLAHE’deki farklı durumlar için elde edilen sonuçları gösteren Tablo-5 incelendiğinde; en iyi değerlendirme metrik sonuçlarının yine Tablo-4 ‘deki VGG modelinde %96,875 doğruluk ve 0.97 f1-skor olarak elde edildiği görülmektedir.

## 5. Sonuçlar ve Gelecek Çalışmalar

Beyin tümörü manyetik rezonans görüntülerinin derin öğrenme sınıflandırılması çalışmasıyla; en iyi veri seti

dağılımı, en uygun önışlem ve en optimum derin öğrenme modelinin belirlenmesi amaçlanmıştır. Elde edilen sonuçlar incelendiğinde veri seti dağılımı deęişiminin sınıflandırma sonuçlarını önemli oranda etkilediđi ve veri setinin miktarının hem ađ eđitimi hem de test sonuçlarında olumlu/olumsuz etkiler oluşturabildiđi anlaşılmıştır. Ayrıca geręekleştirilen çeşitli önışlemlerinde sınıflandırma sonuçlarına katkı sağlayabildiđi görülmüştür.

Çalışmanın devamında literatürdeki açık kaynaklı diđer beyin tümörü veri setleri de kullanılarak, daha çok sayıda derin öğrenme temelli modeller kullanılarak beyin tümörü tespiti için hekimlere yardımcı otomatik bir sistem geliştirilebilir. Buna ek olarak; sınıflandırma problemlerinin yanı sıra anormal (hastalıklı, pozitif, tümörlü) görüntülerin hekimler aracılığıyla manuel bölütlemesi yaptırılarak, buna yönelik yine yapay zekâ destekli otomatik bölütleme çalışmaları geręekleştirilebilir.

**Bilgilendirme;** bu araştırmada yer alan tüm nümerik hesaplamalar TÜBİTAK ULAKBİM, Yüksek Başarım ve Grid Hesaplama Merkezi'nde (TRUBA kaynaklarında) geręekleştirilmiştir.

## 6. Kaynaklar

- [1] Mayo Clinic. "Brain Tumor." Brain Tumor- Symptoms and Causes. URL: <https://www.mayoclinic.org/diseases-conditions/brain-tumor/symptoms-causes/syc-20350084>. (Erişim Tarihi: 08.08.2022)
- [2] Hopkins Medicine. "Brain Tumor Types." Brain Tumor Types. URL: <https://www.hopkinsmedicine.org/health/conditions-and-diseases/brain-tumor/brain-tumor-types>. (Erişim Tarihi: 08.08.2022)
- [3] A. Raza, et al., "A Hybrid Deep Learning-Based Approach for Brain Tumor Classification," *Electronics*, vol. 11, no. 7, p. 1146, Nis. 2022, doi: 10.3390/electronics11071146.
- [4] S. A. Qureshi, et al., "Intelligent Ultra-Light Deep Learning Model for Multi-Class Brain Tumor Detection," *Applied Sciences*, vol. 12, no. 8, p. 3715, Nis. 2022, doi: 10.3390/app12083715.
- [5] S. Maqsood, R. Damaševičius, and R. Maskeliūnas, "Multi-Modal Brain Tumor Detection Using Deep Neural Network and Multiclass SVM," *Medicina*, vol. 58, no. 8, p. 1090, Ađu. 2022, doi: 10.3390/medicina58081090.
- [6] Y. E. Almalki, et al., "Isolated Convolutional-Neural-Network-Based Deep-Feature Extraction for Brain Tumor Classification Using Shallow Classifier," *Diagnostics*, vol. 12, no. 8, p. 1793, Tem. 2022, doi: 10.3390/diagnostics12081793.
- [7] A. Younis, L. Qiang, C. O. Nyatega, M. J. Adamu, and H. B. Kawuwa, "Brain Tumor Analysis Using Deep Learning and VGG-16 Ensembling Learning Approaches," *Applied*

*Sciences*, vol. 12, no. 14, p. 7282, Tem. 2022, doi: 10.3390/app12147282.

[8] M. Rasool, et al., "A Hybrid Deep Learning Model for Brain Tumour Classification," *Entropy*, vol. 24, no. 6, p. 799, Haz. 2022, doi: 10.3390/e24060799.

[9] G. Latif, "DeepTumor: Framework for Brain MR Image Classification, Segmentation and Tumor Detection," *Diagnostics*, vol. 12, no. 11, p. 2888, Kas. 2022, doi: 10.3390/diagnostics12112888.

[10] G. T. Mgejime, M. A. Hossin, G. U. Nneji, H. N. Monday, and F. Ekong, "Parallelistic Convolution Neural Network Approach for Brain Tumor Diagnosis," *Diagnostics*, vol. 12, no. 10, p. 2484, Ekim 2022, doi: 10.3390/diagnostics12102484.

[11] D. R. Nayak, N. Padhy, P. K. Mallick, M. Zymbler, and S. Kumar, "Brain Tumor Classification Using Dense Efficient-Net," *Axioms*, vol. 11, no. 1, p. 34, Ocak 2022, doi: 10.3390/axioms11010034.

[12] H. H. N. Alrashedy, A. F. Almansour, D. M. Ibrahim, and M. A. A. Hammoudeh, "BrainGAN: Brain MRI Image Generation and Classification Framework Using GAN Architectures and CNN Models," *Sensors*, vol. 22, no. 11, p. 4297, Haz. 2022, doi: 10.3390/s22114297.

[13] B. Ahmad, J. Sun, Q. You, V. Palade, and Z. Mao, "Brain Tumor Classification Using a Combination of Variational Autoencoders and Generative Adversarial Networks," *Biomedicines*, vol. 10, no. 2, p. 223, Ocak 2022, doi: 10.3390/biomedicines10020223.

[14] S. Tummala, S. Kadry, S. A. C. Bukhari, and H. T. Rauf, "Classification of Brain Tumor from Magnetic Resonance Imaging Using Vision Transformers Ensembling," *Current Oncology*, vol. 29, no. 10, pp. 7498–7511, Ekim 2022, doi: 10.3390/curroncol29100590.

[15] Sartaj. "Brain tumor classification (MRI)". Kaggle. URL: <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri>. (Erişim Tarihi: 08.08.2022)

[16] A. Krizhevsky, 'One weird trick for parallelizing convolutional neural networks'. arXiv: [1404.5997](https://arxiv.org/abs/1404.5997), 2014.

[17] J. Deng, W. Dong, R. Socher, L.-J. Li, Kai Li and Li Fei-Fei, "ImageNet: A large-scale hierarchical image database," 2009 IEEE Conference on Computer Vision and Pattern Recognition, 2009, pp. 248-255, doi: 10.1109/CVPR.2009.5206848.

[18] K. Simonyan and A. Zisserman, 'Very Deep Convolutional Networks for Large-Scale Image Recognition'. arXiv: [1409.1556](https://arxiv.org/abs/1409.1556), 2014.

[19] A. Howard, et al., 'Searching for MobileNetV3'. arXiv: [1905.02244](https://arxiv.org/abs/1905.02244), 2019

## Özgeçmişler



**Dr. Fatih Uysal**, Lisans eğitimi Kırıkkale Üniversitesi Mühendislik-Mimarlık Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nde, Yüksek Lisans ve Doktora eğitimini ise Gazi Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda tamamlamıştır. Dr. Uysal, Doktora eğitimini tamamladıktan sonra Kafkas Üniversitesi Mühendislik-Mimarlık Fakültesi Elektrik-Elektronik Mühendisliği Bölümünde Dr. Öğr. Üyesi ve Elektronik Anabilim Dalı Başkanı olarak çalışmaya başlamıştır. Ayrıca Derin Öğrenme ve Biyomedikal Görüntü İşleme alanında çalışmaları bulunmaktadır.



**Metehan Erkan**, lise eğitimini Kırkkonaklar Anadolu Lisesi'nde tamamladıktan sonra eğitim hayatına Gazi Üniversitesi Mühendislik Fakültesi'nde çift ana dal programına katılarak devam etmiştir. İnşaat Mühendisliği yanında Elektrik-Elektronik Mühendisliği'nde lisans eğitimlerini sürdürmektedir.



# DA Mikro Şebeke Sisteminin Tasarımı ve Yönetimi

## Design and Management of DC Microgrid System

Waleed Khalid Abdulkareem Albayati<sup>1</sup>, Selçuk Alparslan AVCI<sup>1</sup>

<sup>1</sup>Elektrik-Elektronik Mühendisliği Bölümü  
Karabük Üniversitesi  
khalidmostafa368@gmail.com, selcukavci@karabuk.edu.tr

### Özet

Güneş enerjisi kaynakları yalnızca gün boyunca ve PV (fotovoltaik) dizi kapasitesine ve ışınım düzeyine bağlı olarak belirli derecelendirmelerle güç sağlayabilirler. Bu nedenle mümkün olduğunca maksimum düzeyde kullanılmalıdır. Ancak bazen üretilen tepe gücü, yük talebinden daha fazladır ve artan enerji şebekeye bağlı eviriciler kullanılarak veya pil depolama sistemi gibi bir depolama cihazı kullanılarak şebekeye aktarılır. Bu çalışmada, depolama sistemli şebeke bağlantılı bir DA mikro şebekesi ve 10 kW kapasiteli PV dizisi simüle edilmiştir. PV dizisinde, maksimum güç noktasını izlemek için bir P&O maksimum güç noktası izleme algoritması kullanılır. İncelenen DA mikro şebekesi, AC ve DA yükleri içerir. Önerilen sistem, tüm beklenen çalışma durumları için simüle edilmiştir. MATLAB/Simulink programı kullanılarak simülasyon yapılmıştır. Simülasyon sonuçları, simüle edilen tüm durumlarda PV dizisinin maksimum gücü sağladığını ve yük paylaşımının PV dizisinden üretilen güce ve akü sisteminde depolanan enerjiye bağlı olduğunu göstermektedir. Öncelik, yüke PV dizisinden ve ardından akülerden gerekli elektrik enerjisinin sağlanmasıdır ve daha fazla talep varsa, elektrik şebekesi bunu sağlayacaktır.

**Anahtar kelimeler:** Güneş Enerjisi, Mikro Şebekeler, MPPT, P&O, Tepe Gücü

### Abstract

Solar energy sources can supply power during day only and with specific ratings depending on the PV array capacity and the irradiance level, therefore it should be used as much as possible. But the sometimes the produced peak power is more than the load demand, and the remaining energy transferred on the grid using grid-tied inverters or using a storage device such as a battery storage system. In this work a grid connected DC microgrid with storage system is and PV array with 10 kW capacity is simulated. A P&O maximum power point tracking algorithm is used to track the maximum power point for the PV array. The studied DC microgrid contains AC and DC loads. The proposed system is simulated for all expected operating cases. The simulation is done using MATLAB/Simulink program. The simulation results show that the PV array provides the maximum power, and the load sharing depends on the power generated by the PV array and the energy stored in the battery system, for all the simulated cases. The necessary electrical energy from the PV array and then the batteries, and if there is more demand the utility grid will supply it.

**Keywords:** Solar Energy, Microgrids, MPPT, P&O, Peak Power

## 1. Giriş

Bu Güç sistemi, daha güvenli, daha yeşil ve daha verimli bir akıllı şebekeye dönüştürülmek üzere tasarlanmıştır [1]. Bu aşamalı geçiş, çevresel hedeflere ulaşılmasına yardımcı olabilir, şebeke son kullanıcı etkileşimlerini içerir, dağıtılmış enerji kaynaklarının (DER) büyük ölçekli kombinasyonunu destekler ve güç kontrol tekniklerine ek olarak aşamalı yönetim yöntemlerine ihtiyaç duyar.

Elektriği yüksek seviyeli gerilim sistemlerinden orta ve düşük seviyeli müşterilere çeviren dağıtılmış sistemler, güç sistemindeki güç akışlarını besleyen temel bağlantılardır [2]. Yenilenebilir kaynaklar, enerji depolama sistemi ve dağıtılmış güç jeneratörleri [3] gibi DER'ler genellikle orta veya düşük seviyeli gerilimli güç cihazlarıdır ve normalde dağıtılmış sistemler aracılığıyla güç aktarır. Hızla artan sayıda DER ile dağıtılmış sistemler, beklenilmeyen zorluklarla karşılaşılır. 2030 yılına kadar DER'lerin evrensel toplam elektrik üretiminin yaklaşık %30'unu karşıladığını varsayılır [4]. Buna bağlı olarak, optimize edilmiş enerji verimliliği ve azaltılmış kirlilik ile daha çevre dostu bir elektrik güç sistemi kurulabilir. Fakat, DER'lerin sayısının artması, birkaç DER'in aralıklı olmasının bir sonucu olarak daha büyük bir üretim-harcama dengesizlik tehlikesine yol açabilir. Ayrıca, kararlılıkla ilgili sorunlar olan: bozulan güç kalitesi, salınım frekansı ve düzensiz voltaj gibi sorunlar ortaya çıkar. IEEE Std. 1547 gibi birçok protokol [5], DER'ler ile ilgili gömülü dağıtılmış sistemlerin çalışması için yüksek standartlar oluşturan uygulamalar başlattı. Ne yazık ki, yıllar önce yalnızca temel yerel yükleri sağlamak için tasarlanmış eski dağıtılmış sistemler, bu katı isteklerle karşılaşmak için yeterli seviyede değildir. Fakat bu protokoller, DER'lerin daha düzenli olmalarını, entegrasyonlarını ve kötüye kullanılmamalarını önemli ölçüde sağlamak için zorunludur.

## 2. Mikro şebekeler

Mikro şebeke, farklı dağıtılmış üretim kaynaklarının (DG'ler), güç bankası sisteminin ve yüklerin toplanmasını içeren modern bir sistemdir ve kullanıcılar için, dağıtılmış üretimin mevcut olduğu bazı alanlarda güvenilir, sürdürülebilir ve fiyat açısından rekabetçi maliyet gücü sağlayarak geleneksel elektrik şebekesine yardımcı olabilir. Klasik elektrik şebekesinde güç üretimi, büyük senkron jeneratörlerden bir

iletim/dağıtım ağı aracılığıyla son kullanıcılara tek yönlü olarak akan güç ve enerji ile son derece merkezleştirilmiştir. Ancak, konvansiyonel elektrik hizmetleri ile ilgili teknolojik sorunlar ve fosil yakıtların tutuşturulmasından kaynaklanan çevresel sorunlar, yeni bir güç sistemi teknolojisi geliştirmeyi zorunlu hale getirmiştir.

Rüzgar, fotovoltaik (PV), biyokütle, pil, mikro türbin, yakıt hücresi vb. gibi dağıtık enerji kaynağı (DER) birimlerinin gelişmesiyle birlikte, mikro şebeke sistemleri, bu teknolojileri entegre etmede etkili bir sistem olarak artan bu teknolojilere dikkat çekmiştir. DER birimleri elektrik şebekesi sistemlerine dönüştürülür. Aslında, mikro şebekenin belirli bir tanımı yoktur ve tanım farklı bölgelere veya ülkelere göre değişebilir. Şekil 1'de PV sistemleri, rüzgar enerjisi sistemleri, birleşik ısı ve güç ünitesi (CHP), mikro türbinler, yakıt hücreleri gibi DG'lerden oluşan bir mikro şebekenin tipik yapısını göstermektedir. Mikro şebekeleri AC ve DA tür olarak sınıflandırabiliriz.

AC mikro şebekeleri mevcut AC güç şebekesine bağlanabilir, ancak sistemin kararlılığını korumak için senkronizasyon işlemi karmaşık kontrol stratejileri gerektirir. DA mikro şebekelerde ise gelişmiş verimlilik ve daha iyi kısa devre koruması vardır. Ek olarak, genellikle aynı mikro şebeke sistemine bazı senkron birimleri (örneğin dizel jeneratörler) ve bazı senkron olmayan birimleri (örneğin mikro türbin makineleri) bağlarız. Daha fazla DA yükü (özellikle Hibrit Elektrikli Araçlar) seviyesini artırarak, çoklu (iki yönlü) yol dönüştürücüler aracılığıyla hibrit AC/DA senkron ve asenkron mikro şebekeler giderek daha popüler hale gelecektir. Şekil 2, güç elektroniği arayüzlerini ve çoklu DER birimlerini içeren hibrit bir AC/DA mikro şebeke tipik sistem yapısını göstermektedir [6].

### 2.1. Bağımsız DA mikro şebekeler

Mikro şebekeler AC, DA veya hibrit tip olabilir. Her türün avantajları ve dezavantajları vardır. DA mikro şebekeleri sayesinde, güç elektroniği arayüzlerinin basit olduğunu ve bunun da daha az arıza noktasına yol açtığını görebiliriz. Ayrıca, geleneksel AC şebekesine göre harmonik, reaktif güç ve yüksek verimlilik olmadığı gibi bu sistemde dengesizlik sorunları da yoktur. Bu avantajlara rağmen, sistemin karşılaştığı bazı zorluklar ise; farklı sistemlerin uyum sorunları, güç sisteminin korunmasıyla ilgili sorunlar, sistem konusunda deneyimli kişilerin olmaması ve sistemde kullanılan standart iletim hatlarının olmaması gibi sıralanabilir. Bu zorlukların tümü, DA mikro şebekelerin [7] önündeki engelleri temsil eder.

### 2.2. Şebekeye bağlı DA mikro şebekeler


DA mikro şebekeler, baypas anahtarları aracılığıyla ortak bir bağlantı noktasındaki bir DA şebekeye bağlanarak bağımsız olarak adalı modda veya şebekeye bağlı modda çalışabilir [8]. Şekil 2.4'te gösterildiği gibi, bir DA mikro şebeke, yükü adalı modda sağlamak veya ana şebekeyi şebekeye bağlı modda beslemek için paralel olarak bağlanan ve birlikte çalışan çok sayıda dönüştürücülerden oluşur. DA mikro şebeke kontrol sistemi, voltaj değişimini azaltırken aynı zamanda derecelerine göre dönüştürücüler arasında optimum akım paylaşımını sağlamalıdır [9].

Uzman-bağımlı ve eğim kontrolü gibi birçok yaklaşım, DA mikro şebekeleri kontrol etmek için kullanılır. Uzman-bağımlı yaklaşımındaki ana dönüştürücü, DA mikro şebekenin voltajını yönetmekten ve yükü beslemek için diğer dönüştürücülere

sinyal göndermekten sorumludur. Ana dönüştürücünün arızalanması tüm sistemin arızalanmasına yol açtığından, bu sistem daha zayıf bir güvenilirliğe sahiptir [10]. Sarkma yaklaşımı, tüm dönüştürücüler bir DA mikro şebekenin voltajını yönetmekten sorumlu olduğunda yaygın olarak kullanılır. Düşme direnci ve referans voltajı, sarkma yönteminde her dönüştürücü için belirtilmesi gereken parametrelerdir. Sarkma direnci, dönüştürücü değeri kullanılarak hesaplanır. Sarkma yaklaşımı etkili bir yöntem olsa da, her bir dönüştürücüyü mikro şebekeye bağlayan hat direncinin etkileri nedeniyle birden çok dönüştürücü arasında daha az akım paylaşımı doğruluğu ve mikro şebeke voltajının yüklemeye ile düşmesi gibi birkaç dezavantajı vardır [11]. Bu makalede, sistemdeki gücü yönetmek için bu makalede eğim kontrol yaklaşımı kullanılmıştır.

### 3. DA mikro şebeke sistem modellemesi


Önerilen sistem DA mikro şebeke sistemini temsil etmektedir. Sistem, yenilenebilir bir enerji kaynağı olarak PV dizi sisteminden, şarj kontrolörlü Batarya depolama sisteminden (EMS) ve AC & DA yüklerinden oluşmaktadır. Mikro şebeke sistemi ayrıca kontrolsüz tam köprü doğrultucu aracılığıyla elektrik şebekesine bağlanır. Önerilen sistemin her bir parçası, tüm sistemin Simulink modelini gösteren Şekil 1'de ayrıntılı olarak açıklanmıştır. Bu modelde, PV dizi sisteminin ışınım seviyesini kontrol etmek için bir gösterge aracı kullanıldı.



Şekil 1: Önerilen sistem için simulink modeli.

### 3.1. PV sisteminin modellenmesi

Bir PV hücresi, davranışı Şekil 2'deki devre tarafından tahmin edilebilen doğrusal olmayan bir kaynaktır. Model, güneş pili davranışını matematiksel olarak tam olarak karakterize etmeyi sağlar. Modelin amacı, sıcaklık, güneş ışınımı, gerilim, akım ve maksimum güç üretimi arasındaki ilişkiyi bulmaktır. Daha sonra voltaj-akım karakteristiği çizilebilir. Sonraki bölüm, PV paneli için karakteristik eğriyi çizmek için gerekli parametreleri yaklaşık olarak belirlemenin bir yolunu açıklar.



Şekil 2: Tek diyotlu fotovoltaik hücrenin eşdeğer modeli.

Foton olayı, şekil 2'deki foton akımı IPV'sini oluşturan yük taşıyıcılarına neden olur. Bu, bir diyot ile paralel bir akım kaynağı olarak modellenilebilir. Şekil 2'de gösterildiği gibi ileri voltaj V ve diyot akımı ID'dir. Kaçak akım, akım kaynağına paralel bir direnç olarak modellenmiştir. Bu, şekil 2'de gösterildiği gibi içinden ISH akımı geçen ve metal kontak ile yarı iletken ve üst ve arka metal kontaklar arasındaki temas direnci olan Rsh şönt direncidir. Yük akımı I, güneş pilinin çıkış akımıdır [12]. Kirchoff'un mevcut yasasına göre, çıkış akımı şu şekilde verilir:

$$I = I_{PV} - I_d - I_{SH} \quad (1)$$

Shockley diyot denklemi ile diyot üzerinden yönlendirilen akım şu şekilde tanımlanabilir:

$$I_d = I_0 \left( e^{\left[ \frac{q(V+I.R_S)}{mkT_C} \right]} - 1 \right) \quad (2)$$


Paralel dirençten geçen akım şu denklemle gösterilebilir:

$$I_{SH} = \frac{V + I.R_S}{R_{SH}} \quad (3)$$


Foton akımı aşağıdaki denklemle ifade edilebilir:

$$I_{PV} = [I_{SC} + K_i(T_C - 298)] * \frac{G}{1000} \quad (4)$$

Bu sistemde kullanılan güneş paneli modeli Alfa solar P6L60-220 olup, tek seri modül oluşturmak için beş dizi paralel yöntemle bağlanmıştır. Kullanılan PV dizisi modeli için PV & IV karakteristik eğrileri; tek modül ve PV dizisi şekil 3 ve şekil 4'te gösterilmiştir. Işınlama seviyesinin değiştirilmesi PV hücre panelinde voltaj değişimlerine neden olur. PV hücre panelinin akımı doğrudan ışınlama seviyesi ile ilgilidir.




Şekil 3: PV dizisinin tek modülü için PV-IV eğrileri.



Şekil 4: PV dizi sistemi için PV-IV eğrileri.

### 3.2. PV sistem kontrolü


PV sistem dizileri, kritik DA yüklerine, doğrusal olmayan IV özelliklerinden dolayı doğrudan verimli bir şekilde sisteme bağlanamaz. Bu nedenle, PV sistem voltajını artırmak için DA-DA yükseltici dönüştürücü içeren PV güç kontrol sistemi kullanılacaktır [13]. DA-DA yükseltici dönüştürücü tasarım devresi şekil 5'te gösterilmiştir.



Şekil 5: Yükseltici dönüştürücü.

Maksimum güç izleme sistemi (MPPT), PV hücreleri tarafından çıkarılabilecek maksimum güç noktasını izlemek için kullanılır. PV ve IV eğrilerini içeren karakteristik grafikler,

güneş panelleri üzerindeki güneş ışınımından ve güneş hücrelerinin sıcaklığından etkilenecektir ve maksimum güç izleme sisteminden alınan sıcaklık ve güneş ışınım değerleri değiştiğinde dalgalanacaktır. Perturb and Observation Tanique, uygulanması kolay olduğu ve daha karmaşık algoritmalarından daha az hesaplama kaynağı gerektirdiği için kullanılır. P&O algoritması için mantık akış şeması şekil 6'da gösterilmiştir. P&O, iki ardışık ölçüm noktasındaki çıkış gücünü karşılaştırarak PV panelinin voltajını veya akımını düzenler.



Şekil 6: MPPT P&O algoritması.

### 3.3. Enerji depolama sistemi

Yenilenebilir enerji kaynakları kesintili olduğundan, güneş enerjisi üretiminin çok az olduğu veya hiç olmadığı dönemleri telafi etmek için bir enerji depolama sistemi gereklidir. Enerji depolama sistemi temel olarak pili ve pil şarj kontrol cihazını içerir. Enerji depolama sistemi, güç dalgalanmalarının etkilerini dengeleyecek ve mikro şebeke güç sistemlerinin kurulu olduğu mevcut yenilenebilir enerji kaynaklarının güvenilirliğini ve kararlılığını artıracaktır [14].


### 3.4. Enerji depolama sistemi kontrolü

Enerji depolama denetleyicisi, mikro şebeke sisteminde akü sistemine giden ve akü sisteminden gelen akım akışını kontrol etmek için kullanılır. Pili korumak ve DA bara voltajını düzenlemek için gerekli bir parçadır. Bu sistemde, Akü Sisteminin şarj kontrolörü olarak çift yönlü bir düşürücü - yükseltici dönüştürücü kullanılacaktır.

#### 3.4.1. Çift yönlü dönüştürücü

Mikro şebekedeki pillerden ve pillere güç akışına izin vermek için bir düşürücü-yükseltici dönüştürücü gereklidir. Önceki düşürücü ve yükseltici dönüştürücüler, çift yönlü güç akışı özelliğine sahip değildir. Bunun nedeni, hepsinin tasarımlarında ters akım akışını engelleyen diyotların bulunmasıdır. Şekil 7'te gösterildiği gibi, düşürücü ve yükseltici dönüştürücülerin yetenekleri birleştirilerek ve diyotları anahtarlarla değiştirilerek çift yönlü bir dönüştürücü tasarlanabilir. Üstteki anahtar, dönüştürücüyü bir düşürücü dönüştürücü olarak çalıştırmak için kullanılır, gücü yüksek voltaj tarafından düşük voltaj tarafına aktarır ve alttaki anahtar, dönüştürücüyü düşük voltaj tarafından gücü aktaran bir destek dönüştürücü olarak çalıştırmak için kullanılır. yüksek gerilim tarafı Çift yönlü dönüştürücü, yenilenebilir enerji kaynaklarının dalgalanmalarını yumuşatmak ve gerilimi stabilize etmek için

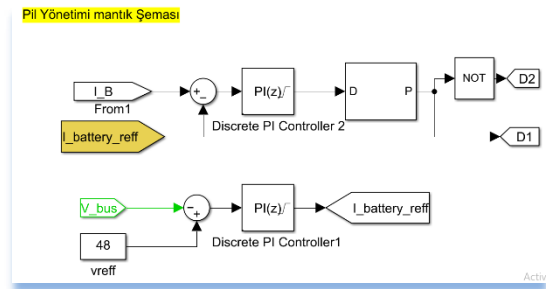
enerjinin aküye mi yoksa aküden mi gönderilmesi gerektiğini belirleyen bir şarj kontrolörü tarafından kontrol edilecektir [15].



Şekil 7: Bir düşürücü-yükseltici dönüştürücü devre şeması.

#### 3.4.2. Enerji yönetim sistemi kontrol süreci

Pil şarj kontrolörü, tereyağından gelen veya tereyağına giden güç akışını kontrol eder. PV sistemi tarafından üretilen gücün yük gücünden fazla olması ve pil SOC'sinin değişken olması durumunda, şarj kontrol cihazı, fazla gücün pil sistemine doğru akmasına izin vermek için çift yönlü dönüştürücüyü kontrol edecektir. Diğer durumda, PV sistemi tarafından üretilen güç, yük gücünden daha azdır ve pil SOC'si değişkendir, şarj kontrolörü, pilde sıralanan gücün veri yolu sistemine doğru akmasına izin vermek için çift yönlü dönüştürücüyü kontrol edecektir. Kontrol işlemi iki döngü (gerilim döngüsü ve akım döngüsü) içerir; gerilim döngüsünde, akü referans akımını elde etmek için bara gerilimi ile bir referans gerilimi arasında bir karşılaştırma yapılır. Şarj kontrol sisteminde iki adet PI kontrolör kullanılmaktadır. Enerji yönetimi algoritması şekil 8 'te gösterilmiştir.



Şekil 8: Enerji yönetimi algoritması.

### 3.5. DA bara sistemi

DA bara hem DA yüklerini hem de AC yükünü içerir. DA yükünün, doğrudan DA barasına bağlı toplam 5 kW gücünde dirençli yük olduğu varsayılır. AC yükü DA baraya bir tam köprü tek faz üzerinden bağlanır ve toplam güce sahip kurulum trafosu 5 kW'dır. Yani, baraya bağlı toplam yükler 10 kW'dır. DA bara voltajı 48 VDA olarak ayarlanmıştır. DA barası, tam köprü kontrolsüz doğrultucu kullanılarak ana şebeke şebekesine bağlanır ve bu nedenle şebekeye gerçek güç iletme yeteneği yoktur. Enerji depolama sistemi, PV sistemi tarafından üretilen güç, yük talebini aştığında fazla gücü korumak için kullanılır. Bu arada, PV sistemi tarafından



üretilen güç yük talebinden daha az olduğunda, depolama sistemi yükü sağlayacaktır.

### 3.6. DA mikro şebekelerde enerji yönetimi

#### 3.6.1. Enerji yönetim sistemi


Güç yönetimi sorunlarını çözmek, birçok etkinlik ve deney yürüterek, geçtiğimiz on yıllar boyunca bazı araştırmacıların ana göreviydi. Enerji yönetimi, kaynaktan yüke akan gücün kontrol edilmesi anlamına gelir. Ve bu amacı gerçekleştirmek için; birçok farklı güç kontrol tekniği geliştirilmiştir [16]. Mikro şebekedeki güç kontrol teknikleri temel olarak aşağıdaki hedeflere ulaşmayı amaçlar:

1. Sisteme herhangi bir etkide bulunulmadan mikro şebekelerde yeni nesil dağıtılmış sistemler (DG'ler) ve dağıtılmış depolama sistemi (DS) ekleme veya çıkarma yeteneği ve esnekliği,
2. Ortak DC bara voltajındaki değişimi kolayca ve esnek bir şekilde düzenleme yeteneği,
3. Mikro şebeke içinde uygun enerji akışının kontrol edilmesini ve dengelenmesini sağlama,
4. Paralel güç dönüştürücüler arasında kararlı akım paylaşımını etkinleştirme ve güç yönetimi devresi ile güç dengesini sağlama.

Mikro şebeke enerji yönetimi, ekonomik güç dağıtımını hedefler. Enerji yönetimi, optimizasyona dayalı ve kurula dayalı yaklaşımlar olarak kategorize edilebilir. Birinci yaklaşımda, sistemin yönetimi matematiksel optimizasyon ile yapılır ve amaç fonksiyonu ve kısıtlar ile gerçekleştirilir. Ancak kural tabanlı bir yaklaşım, sistemi, çok etmenli bir sistem tarafından tanımlanan ve bulanık mantık yaklaşımlarına dayanan basit kurallar gibi ön ekli kurallara göre çalıştırır. Optimizasyon süreci, birçok kısıtlamayı karşılarken farklı yenilenebilir enerji üretimi ve yük gücü talebinin tahminini dikkate almalıdır. Bu makalede, sistemi kontrol etmek için kural tabanlı bir yaklaşım kullanılmıştır [16].

#### 3.6.2. Enerji yönetim mekanizması

Yük paylaşımı, PV dizisi sistemi tarafından üretilen gerçek gücün miktarına bağlıdır. Güç akışı, DA-DA dönüştürücü tarafından yükseltildikten sonra PV sistemi tarafından üretilen gerilim ile tam köprü kontrolsüz doğrultucu DA çıkış gerilimi arasındaki fark olan DA-bara gerilimine bağlıdır. Şekil 9, yük paylaşım sürecinin algoritmasını göstermektedir.



Şekil 9: Yük paylaşım algoritması


## 5. Sonuçlar

Toplam kapasitesi 10 kW olan bir PV dizisi, burada tipik AC ve DA yüklerine güç sağlamak için düşünülmüştür. 5 kW kapasiteli DA yükler doğrudan DA bus sistemine bağlanır. DA yüklerle eşit kapasiteli AC yükler ise tam köprü tek fazlı evirici ve yükseltici transformatör kullanılarak DA bara sistemine bağlanır. DA mikro şebeke sistemi için simülasyon sonuçları bu bölümde burada tartışılmaktadır. Sonuçlar, farklı ışınlama seviyeleri ve yük kapasiteleri altında kaydedilir. Işınlama seviyeleri 250 kW, 500 kW ve 1000 kW olarak kabul edilir. Yük kapasiteleri ise yarım yük ve tam yük olarak kabul edilir.


*Durum 1:* 250 W/m<sup>2</sup> Güneş Işınımı ve 0,5 yük

Bu durumda ışınlama seviyesi 250 W/m<sup>2</sup> olarak kabul edilir. Sistem yüklerinin yarı kapasitesi sistem barasına bağlanır. Sistemin güç göstergeleri şekil 10'da gösterilmiştir. Sistem akım ve gerilim eğrileri ise şekil 11 ve şekil 12'de gösterilmiştir. Sonuç olarak, PV sistemin ürettiği güç 2,5 kW'dır. Bus'a bağlı sistem yükleri ise 5 kW'dır. Böylece, PV sistemi yüklerin yarısına güç sağlar ve geri kalan yükler akü ve şebeke sistemi tarafından desteklenir. Akü deşarj modunda olacak ve aküde


depolanan gücün %20'sini aldıktan sonra akü duracak ve şebeke yükü beslemeye başlayacaktır.



Şekil 10: 250W/m<sup>2</sup> ve 0,5 yük durumunda sistem için güç göstergeleri



Şekil 11: 250W/m<sup>2</sup> ve 0,5 yük durumunda sistem akımları




Şekil 12: 250W/m<sup>2</sup> ve 0,5 yük durumunda sistem gerilimleri


#### Durum 2: 250 W/m<sup>2</sup> Güneş Işınımı ve tam yük

Bu durumda ışınım seviyesi 250 W/m<sup>2</sup> olarak kabul edilir. Sistem yüklerinin tam kapasitesi sistem bus'a bağlanır. Sistemin güç göstergeleri şekil 13'te gösterilmektedir. Sistem akım ve gerilim eğrileri ise şekil 14 ve şekil 15'te gösterilmektedir. pil tepkisi şekil 16'te gösterilmiştir. Bu durumda PV sistem sadece 2,5 kW üretmektedir. DA baraya bağlanan yüklerin toplam kapasitesi ise 10 kW'dır. Böylece, PV sistemi yükün yalnızca 0,25'ine güç sağlar ve pil ve şebeke yükün geri kalan 0,75'ine güç sağlar. Akü deşarj modunda olacak ve aküde depolanan


gücün %20'sini aldıktan sonra akü duracak ve şebeke yükü beslemeye başlayacaktır.




Şekil 13: 250W/m<sup>2</sup> ve tam yük durumunda sistem için güç göstergeleri



Şekil 14: 250W/m<sup>2</sup> ve tam yük durumunda sistem akımları



Şekil 15: 250W/m<sup>2</sup> ve tam yük durumunda sistem gerilimleri




Şekil 16: 250W/m<sup>2</sup> ve tam yük durumunda sistemin pil tepkisi


#### Durum 3: 500 W/m<sup>2</sup> Güneş Işınımı ve 0,5 yük

Bu durumda radyasyon seviyesi 500 W/m<sup>2</sup> olarak kabul edilir. Sistem yüklerinin yarı kapasitesi sistem barasına bağlanır. Sistemin güç göstergeleri şekil 17'de gösterilmiştir. Sistem akım ve gerilim eğrileri ise şekil 18 ve şekil 19'da gösterilmiştir. Bu durumda ise PV sistem 5 kW gerçek güç üretmektedir. Ayrıca DC baraya bağlı DC & AC yüklerin toplam kapasitesi ise 5 kW'dır. Bu nedenle, PV sistemi yüklerin tamamına güç sağlar ve akü ve şebeke yükün beslenmesinde etkisi yoktur. Akü sistemi şekil 20'de gösterildiği gibi şarj modunda kalacaktır. PV sistemi tarafından üretilen güç, yük sistemi tarafından talep edilen güce eşit olduğundan, akü sistemi ana şebekeden şarj olacaktır. Bu nedenle, şekil 20'de pilin şarj


modunda olduğunu ve şekil 17'de şebeke gücünün eşit olmadığını göstermektedir.




Şekil 17: 500W/m<sup>2</sup> ve 0,5 yük durumunda sistem için güç göstergeleri



Şekil 18: 500W/m<sup>2</sup> ve 0,5 yük durumunda sistem akımları



Şekil 19: 500W/m<sup>2</sup> ve 0,5 yük durumunda sistem gerilimleri




Şekil 20: 500W/m<sup>2</sup> ve 0,5 yük durumunda sistemin pil tepkisi


#### Durum 4: 500 W/m<sup>2</sup> Güneş Işınımı ve tam yük

Bu durumda ışınım seviyesi 500 W/m<sup>2</sup> olarak kabul edilir. Sistem yüklerinin tam kapasitesi sistem bus'a bağlanır. Sistemin güç göstergeleri şekil 21'de gösterilmektedir. Sistem akım ve gerilim eğrileri ise şekil 22 ve 23'de gösterilmektedir. Bu durumda ise, PV sistem 5 kW gerçek güç üretmektedir ve DA baraya bağlı DA & AC yüklerin toplam kapasitesi 10 kW'dır. Böylece, PV sistemi yüklerin %50'sine güç sağlarken, batarya ve şebeke, yükün geri kalan %50'sine güç sağlar. Akü sistemi deşarj moduna geçecek ve şarj durumu (SOC) deşarj moduna


geçecek ve akü bittiğinde şebeke yükü beslemeye başlayacaktır. Akü tepkisi şekil 24'te gösterilmiştir.




Şekil 21: 500W/m<sup>2</sup> ve tam yük durumunda sistem için güç göstergeleri



Şekil 22: 500W/m<sup>2</sup> ve tam yük durumunda sistem akımları



Şekil 23: 500W/m<sup>2</sup> ve tam yük durumunda sistem gerilimleri




Şekil 24: 500W/m<sup>2</sup> ve tam yük durumunda sistemin pil tepki


#### Durum 5: 1000 W/m<sup>2</sup> Güneş Işınımı ve 0,5 yük

Bu durumda ise, ışınım seviyesi 1000 W/m<sup>2</sup> olarak kabul edilir. Sistem yüklerinin yarı kapasitesi sistem barasına bağlanır. Sistemin güç göstergeleri şekil 25'de gösterilmektedir. Şekil 26 ve 27'de ise sistem akım ve gerilim eğrileri gösterilmektedir. Batarya ve şebeke, yükün geri kalan %50'sine güç sağlar. Bu durumda ise, PV sistem 10 kW gerçek güç üretmektedir ve DA baraya bağlı DA & AC yüklerin toplam kapasitesi 5 kW'dır. Böylece, PV sistemi yüklerin %100'üne güç sağlar ve fazla güç depolama sistemine yüklenir. Akü şarj modunda kalırken, şebeke yükün beslenmesine katılmaz. FV Sistem gücü nedeniyle, maksimum yükü karşılayacaktır ve mikro şebeke sisteminin genel performansı, yarı yüklü veya tam yüklü


durumda aynı kalacaktır. Bu nedenle, sonuçlar yalnızca yarım yük durumunda kaydedilir.



Şekil 25: 1000W/m<sup>2</sup> ve 0,5 yük durumunda sistem için güç göstergeleri



Şekil 26: 1000W/m<sup>2</sup> ve 0,5 yük durumunda sistem akımları



Şekil 27: 1000W/m<sup>2</sup> ve 0,5 yük durumunda sistem gerilimleri

## 6. Sonuçlar

DA yükü, AC yükü, MPPT sistemli PV dizisi ve Şekil 1'de açıklandığı gibi akü depolama sisteminden oluşan ve incelenen şebekeye bağlı DA mikro şebekesi, beklenen tüm çalışma durumları için simüle edilmiştir. Işınım seviyesi sıfır W/m<sup>2</sup>'den 1kW/m<sup>2</sup>'ye kadar derecelendirilmiştir. Beş çalışma durumu simüle edilmiştir ve tüm bu durumlarda PV dizisi maksimum güçte çalışmaktadır. P&O MPPT algoritmasının kullanılması, önerilen DA-DA yükseltici dönüştürücüye maksimum güç noktasını yüksek performansla izleme yeteneği verir.

PV dizi ve pil depolama sisteminden yükleri beslemek için seçilen öncelikli iki kaynağın değeri, yük talebinden daha az olduğunda, elektrik şebekesi gerekli enerji miktarını tamamlayacaktır. Pil şarjının sadece PV dizi gücüne bağlı olmasını sağlayacak şekilde tasarlanan BMS, ayrıca PV dizisi tarafından üretilen güç yük talebinden daha az olduğunda pilin yükleri beslemesini sağlar, ayrıca elektrik şebekesinden pil şarjını önerir.

Simülasyon sonuçları, önerilen sistemin hem yüksek hem de düşük ışınım seviyesinde yüksek performansını göstermektedir ve bundan dolayı önerilen sistem açık ve bulutlu havalarda kullanılabilir. Yük talebini aşan tüm

PV enerjisinin depolanmasını sağlamak için, akümülatör sisteminin minimum kapasitesi, PV dizisi maksimum gücü ile yük kapasitesi arasındaki farktan daha yüksek olmalıdır. Kontrolörlerin izolasyonu (MMPT & BMS) ile sistem daha güvenilir hale getirilir ve hızlı yanıt verilir.

## 7. Kaynaklar

- [1] N. Pragma, R.K. Nema and S. Rangnekar. A current and future state of art development of hybrid energy system using wind and PV-solar: A review, Renewable and Sustainable Energy Reviews, vol. 13, pp. 2096-2103, 2009.
- [2] J.M. Guerrero, P.C. Loh, T. Lee and M. Chandorkar. Advanced Control Architectures for Intelligent Microgrids – Part II: Power Quality, Energy Storage, and AC/DC MicroGrids, IEEE Transactions on Industrial Electronics, vol. 60, pp. 1263-1270, 2012.
- [3] M. F. Akorede, H. Hizam, and E. Pouresmaeil. Distributed energy resources and benefits to the environment, Renew. Sustain. energy Rev., vol. 14, pp. 724–734, 2010.
- [4] T. Adefarati, N. B. Papy, M. Thopil, and H. Tazvinga. Non-renewable distributed generation technologies: A review, Handb. Distrib. Gener., pp. 69–105, 2017.
- [5] T. Funabashi. Integration of Distributed Energy Resources in Power Systems, Academic Press, Japan, 2016.
- [6] G. D. Wenzhong. Energy storage for sustainable microgrid, Academic Press, Japan, 2015.
- [7] K. Shah, P. Chen, A. Schwab, K. Shenai, S. Gouin-Davis, and L. Downey. Smart efficient solar DC micro-grid, 2012 IEEE Energytech, pp. 1–5, 2012.
- [8] J. M. Guerrero, J. C. Vasquez, J. Matas, L. G. De Vicuña, and M. Castilla. Hierarchical control of droop-controlled AC and DC microgrids—A general approach toward standardization, IEEE Trans. Ind. Electron., vol. 58, pp. 158–172, 2010.
- [9] M. Mokhtar, M. I. Marei, and A. A. El-Sattar. A control scheme for islanded and grid-connected DC microgrids, 2017 Nineteenth International Middle East Power Systems Conference (MEPCON), pp. 176–180, 2017.
- [10] R. A. F. Ferreira, H. A. C. Braga, A. A. Ferreira, and P. G. Barbosa. Analysis of voltage droop control method for dc microgrids with Simulink: Modelling and simulation, 2012 10th IEEE/IAS International Conference on Industry Applications, pp. 1–6, 2012.
- [11] G. Niyitegeka, J. Choi, and Y. Ok. Improved droop control for effective load sharing and voltage regulation in DC microgrids, 2016 Electric Power Quality and Supply Reliability (PQ), pp. 125–132, 2016.
- [12] K. Dubey and M. T. Shah. Design and simulation of Solar PV system, 2016 International Conference on Automatic Control and Dynamic Optimization Techniques (ICACDOT) IEEE, pp. 568–573, 2016.
- [13] M. H. Rashid. Power electronics: circuits, devices, and applications, Pearson Education, India, 2009.
- [14] A. K. Podder, N. K. Roy and H. R. Pota. MPPT methods for solar PV systems: a critical review based on tracking nature, IET Renewable Power Generation, vol. 13, pp. 1615-1632, 2019.
- [15] J. A. Grant. Design and Simulation of a DC Microgrid for a Small Island in Belize, Sustain. Energy Eng. Sch. Energy, 2018.
- [16] D. W. Gao. Energy storage for sustainable microgrid, Academic Press, Japan, 2015.

## Özgeçmişler



**Waleed Khalid Abdulkareem Albayati**, Lisans derecesini Kerkük Üniversitesi Elektrik Mühendisliği Bölümü'nden aldı. Yüksek lisans derecesini 2023 yılında Karabük Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nden almıştır. Araştırma alanları MPPT ve yenilenebilir enerji konularıdır.



**Dr. Selçuk Alparslan Avcı**, 1984 yılında Karabük'te doğdu. Lisans derecesini 2007 yılında Kırıkkale Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nden aldı. Yüksek lisans ve doktora derecelerini Gazi Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nden sırası ile 2014 ve 2021 yıllarında almıştır. 2022 yılından beri Karabük Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nde görev yapmaktadır. Araştırma alanları elektromanyetik alanlar, plazma ortamlar, sayısal yöntemler, anten tasarımı ve yenilenebilir enerji konularıdır.



# Grafik Sinir Ağlarına Genel Bir Bakış

## An Overview of Graph Neural Networks

 Hamza Talha Gümüş<sup>1</sup>, Can Eyüpoğlu<sup>2</sup> 

<sup>1</sup>Bilgisayar Mühendisliği Ana Bilim Dalı, Atatürk Stratejik Araştırmalar ve Lisansüstü Eğitim Enstitüsü,  
Milli Savunma Üniversitesi, İstanbul, Türkiye  
hamzatalhagumus@gmail.com

<sup>2</sup>Bilgisayar Mühendisliği Bölümü, Hava Harp Okulu, Milli Savunma Üniversitesi, İstanbul, Türkiye  
ceyupoglu@hho.msu.edu.tr

### Öz

Grafik sinir ağları (GNN), yapay sinir ağı (ANN) ailesine mensup ve grafikler üzerinden bilgi çıkarımı işlemi gerçekleştiren bir derin öğrenme yöntemidir. İlk kullanımı 2008 yılında gerçekleşmiş, gelişimi ise 2014 yılı ve sonrasında olmuştur. Evrişimli sinir ağlarının (CNN) görseller üzerinde beklenen performansı karşılamamasına karşılık olarak geliştirilen GNN'ler; fizik, kimya, biyoloji, siber güvenlik gibi birçok alanda kullanılmaktadır. Bu çalışmada GNN'ler ve modelleri temel olarak anlatılmış ve kapsamlı bir literatür taraması gerçekleştirilmiştir. Çalışma içerisinde bir GNN modelinin tasarım adımlarına değinilerek geliştirilen modeller incelenmiş, GNN modellerinin CNN ve yinelemeli sinir ağları (RNN) etkili modellere karşı güçlü ve zayıf yönleri gösterilmiştir.

**Anahtar Kelimeler:** Grafik Sinir Ağları, Yapay Sinir Ağları, Derin Öğrenme, Evrişimli Sinir Ağları, Yinelemeli Sinir Ağları

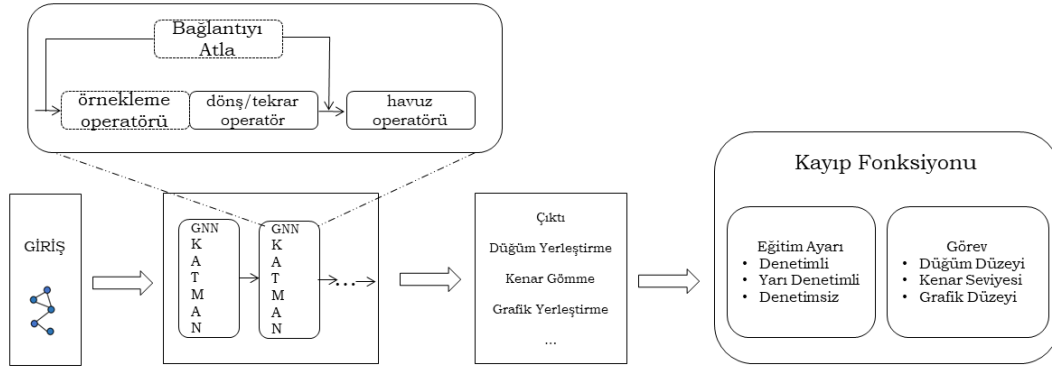
### Abstract

Graph neural networks (GNN) are a deep learning method that belongs to the artificial neural network (ANN) family and performs information extraction from graphs. It was first used in 2008 and its development started in 2014 and onwards. GNNs, which were developed in response to the failure of convolutional neural networks (CNN) to meet the expected performance on visuals, are used in many fields such as physics, chemistry, biology and cyber security. In this study, GNNs and their models are basically explained and a comprehensive literature review is carried out. In the study, the developed models are examined by referring to the design steps of a GNN model, and the strengths and weaknesses of GNN models against CNN and recurrent neural networks (RNN) effective models are shown.

**Keywords:** Graph Neural Networks, Artificial Neural Networks, Deep Learning, Convolutional Neural Networks, Recurrent Neural Networks

### 1. Giriş

Grafik Sinir Ağları (Graph Neural Networks-GNN), grafik üzerinde çalışan sinir ağı ailesine mensup bir kavramdır. Derin öğrenmenin alt dalı olan Evrişimli Sinir Ağlarının (Convolutional Neural Networks-CNN) yetersiz kaldığı Öklid dışı uzayda kullanılmak için geliştirilmiş ve büyük başarılar yakalamıştır. Evrişimli sinir ağlarına bakıldığında ise görsel bilgi analizi üzerinde başarılı olmuş ve yaygın olarak kullanılmaktadır. Genel kullanım alanları resim tanıma, resim sınıflandırma ve tıpta görüntü analizi olsa da doğal dil işlemede dâhil olmak üzere birçok alanda kullanılmaktadır. Tarihsel gelişimi ilk olarak 1962 yılında Hubel ve Wiesel [1] tarafından kullanılmıştır. Bu çalışma sonrasında sinir ağlarına yeni bir bakış gelerek gelişimi hızla devam etmiştir. CNN'ler 1D ve 2D'de büyük başarılar sağlamış ve kendini kanıtlamıştır. Tarihsel süreçte geliştirilen sinir ağlarına fikir oluşturmuştur. GNN ise günümüzde çok yeni bir çalışma alanı olup her geçen gün gelişmektedir. Tarihsel gelişimini incelediğimizde Yinelemeli Sinir Ağlarının (Recurrent Neural Networks-RNN) grafikler üzerinde kullanılması ile başlamıştır. 1997 yılında Sperduti ve Starita [2] tarafından ortaya atılan bu düşünce 2009 yılında Scarselli [3] tarafından İleri Beslemeli Sinir Ağları (Feed Forward Neural Networks-FFNN) ile kullanılarak GNN'ler için bir algoritma geliştirilmiştir. İlk GNN modeli grafik etki alanlarını öğrenmek için 2005 yılında Gori ve ark. [4] tarafından literatüre dahil edilmiştir. Geleneksel yöntemlerin yetersiz olması ve veri kaybına sebep olması ile sonuçta ön adımlarda takılı kalılabileceği sorunu çözmek için çalışma gerçekleştirilmiştir. GNN modelinin önerilmesi ve farklı grafik türleri üzerinde başarı sağlandığı belirtilerek, model üzerinde deneyler yapılmış ve bilim dünyasına sunulmuştur [4]. Gori ve ark. bu modeli geçmişte yaptıkları çalışmaların üzerine ekleyerek bulmuştur. Daha önceki yıllardan örnek vermek gerekirse yönlendirilmiş grafikler için RNN kullanarak 2003 yılında bir sinir ağı modeli önerilmiştir [5]. GNN ile ilgili kapsamlı bir çok araştırma ve karşılaştırma [6-10] yapılmıştır. GNN'ler ilk olarak 2005 yılında ortaya atılsa da gelişimi 2014 yılı ve sonrasında olmuştur. Temel olarak bir GNN modeli Şekil 1'de [7] görülmektedir.



Şekil 1: Grafik sinir ağı modeli temel tasarım hattı

## 2. Grafik Sinir Ağları

GNN model tasarımı temel olarak dört işlem adımından oluşmaktadır. İlk adım grafiğin yapısını bulmak, ikinci adım grafiğin tipi ve ölçeğini belirlemek, üçüncü adım tasarım kayıp fonksiyonunu hesaplamak ve son adımda hesaplama modülleri kullanılarak tasarımı tamamlamak şeklindedir [7]. İlk adım olan grafiğin yapısını bulunurken iki farklı durum gözlemlenmektedir. Birinci durum grafikler üzerinde bulunan bilgilerin açık olduğu yapısal senaryolardır. İkinci durum ise bilgilerin açık olmadığı yapısal olmayan senaryolar olarak adlandırılmaktadır. Bu işlem gerçekleştirildikten sonra grafik türü belirlenmektedir. Grafikler türlerine göre yönlü/yönsüz, homojen/heterojen, statik/dinamik gibi farklı türleri bulunmaktadır. Aynı şekilde bu grafiklerin birleşiminden de bir grafik oluşturulabilmektedir. Grafikler karmaşık yapılar olduğu için bu adım oldukça önemlidir [7]. Şekil 2’de [7] grafik türü ve ölçeğine göre değişkenler şeması görülmektedir.

### 2.1. Grafik Türü ve Ölçeği


Grafiklerde kenarlar bilgiler içermektedir. Yönlendirilmiş grafiklerde bu kenarlar kullanılarak modelleme yapılmaktadır. Bu tür durumlar için Yoğun Grafik Yayılımı (Dense Graph Propagation-DGP) geliştirilmiştir [11]. Heterojen grafikler ise farklı tiplerden oluşmuş düğüm ve kenarlardan meydana gelmektedir. İlk tür olan meta yol tabanlarında, tüm konularda bulunan düğümlerin türleri belirlenmektedir. Kenar tabanlı yöntemler ise genellikle örnekleme, toplama ve özellik kodlama için kullanılmaktadır. İlk olarak web ölçeği kapsamında Heterojen Grafik Dönüştürücü (Heterogeneous Graph Transformer-HGT) [12] modeli önerilmiştir. Bir diğer model olan Heterojen Grafik Sinir Ağı (Heterogeneous Graph Neural Network-HetGNN) [13] ise grafik madenciliği ve grafik model görevleri olan, bağlantı tahmini ve düğüm sınıflandırmayı kolaylaştırmak için geliştirilmiş bir modeldir. İlişkisel grafikler çok fazla bilgi içeren grafikler olarak tanımlanabilmektedir. Bilgi grafiklerinden sağlanan faydayı arttırmak için İlişkisel Evrişimli Sinir Ağları (Relational Graph Convolutional Network-R-GCN) [14] modeli önerilmiştir. Bir diğer model olan G2S doğal dil işlemede genellikle Geçitli Grafik Sinir Ağları (Gated Graph Sequence Neural Networks-GGNN) [15], üzerinde bulunan tüm bilgileri kodlayan bir modeldir. Grafikten dizi oluşturmada ortaya çıkan bir problem olan dilbilgisi ve veri kaybına karşı geliştirilmiştir. Çok katmanlı

grafikler, düğümlerin birden fazla kenarla ilişkili olması durumunda ortaya çıkmaktadır. Bu tür grafikler çok boyutlu olduğu için tek boyutlu grafiklere önerilen modeller yetersiz kalmıştır. Bu sebeple çok boyutlu grafik sinir ağı olarak bilinen mGCN [16] modeli önerilmiştir. Dinamik grafikler ise zamana bağlı olarak değişen grafiklerdir. İlk örnek modelimiz olan Difüzyon Evrişimli Tekrarlayan Sinir Ağı (Diffusion Convolutional Recurrent Neural Network-DCRNN) [17], trafik modelleri gibi karmaşık, zamana göre değişen ve uzun süreli tahmine dayalı etkiler göz önüne alınarak geliştirilmiş bir modeldir. Mekansal-Zamansal Grafik Evrişimli Ağlar (Spatiotemporal Graph Neural Network-STGNN) [18], trafik analizini zamansal ve mekansal olarak ele almış, tahmin etme sorununa farklı bir bakış açısıyla yaklaşarak yeni bir model önermiştir. Yapısal-RNN [19], gelişmiş uzay zaman grafiklerinde RNN yardımıyla gerçek dünyada işe yarayan bir form oluşturma amacıyla geliştirilmiştir. Bilinen çalışma ise insan hareketlerinin modellenmesidir. Aynı şekilde benzer bir durum Mekansal-Zamansal Grafik Evrişim Ağları’nda da (Spatial Temporal Graph Convolutional Networks-ST-GCN) [20] bulunmaktadır. İnsan eylemlerini tanımlamak amacıyla iskelet modellemesi gerçekleştirilmek istenmiş ve dinamik iskelet modeli önerilmiştir. Dinamik Grafik Evrişimli Ağlar (Dynamic Graph Neural Networks-DGNN) [21], Uzun-Kısa Süreli Bellek Ağları (Long Short-Term Memory-LSTM) ve Grafik Evrişim Ağlarını (Graph Convolutional Networks-GCN) içeren zamansal değişime göre en fazla fayda sağlamaya çalışan yeni bir model olarak önerilmiştir. Zaman yapısını kodlayan LSTM ile grafik yapısını kodlayan grafik evrişim katmanları kullanılırken Birleştirilmiş Dinamik Grafik Evrişim Ağı (Concatenate Dynamic Graph Convolutional Networks-CD-GCN) ve köşe kod çözümü yapısına sahip Şelale Dinamik Grafik Evrişim Ağı (Waterfall Dynamic Graph Convolutional Networks-WD-GCN) adında iki farklı model tekniği de sunulmuştur. Yakın geçmişte Evrim Geçiren Grafik Evrişim Ağları (Evolving Graph Convolutional Networks-EvolveGCN) [22] modeli, zamansal grafiklerde düğüm farklılığından doğan sorunlara çözüm olması sebebiyle geliştirilmiştir. RNN’lerin düğüm bilgisi eksikliği ve düğüm kümesi değişiminde karşılaştığı zorluğa çözüm amacıyla çalışmaya başlanmış ve yapılan deneylerde daha iyi bir performans sergilediği görülmüştür. Dinamik ağlar, GNN’de yeni kullanılmaya başlanmıştır. Dinamik Sinir Ağı (Dynamic Neural Networks-DNN) modelleri ile ilgili kapsamlı bir araştırma [23] mevcuttur. DNN modelleri üç




farklı tabanda incelenmiştir. Şekil 3'te DNN'lerde grafik sinir

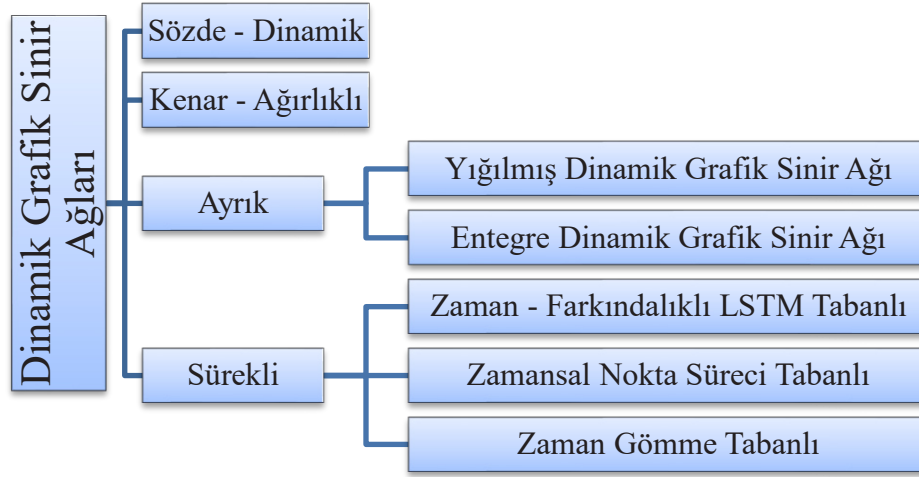
model genellemesi görülmektedir.



Şekil 2: Grafik türü ve ölçeğine göre değişkenler



Şekil 3: Dinamik sinir ağlarında grafik sinir model genellemesi



Şekil 4: Dinamik sinir ağ türleri

Şekil 3'ten yola çıkarak istatistiksel modellerin çıkarımlara ve istatistiksel verilere dayalı olduğu görülmektedir. Rastgele modeller, Rastgele Grafik Modeller (Random Graph Models-RGM) ve Üstel Rastgele Grafik Modelleri (Exponential Random Graph Models-ERGM) üzerinde çalışmaktadır. Aktiviteye yönelik modeller, düğümlerin davranışlarını modellemektedir. İlişkisel olay modelleri ise zamansal modeller olarak tanımlanabilmektedir. Gelecekte gerçekleşme olasılığını hesaplamaktadır ve bunu düğümler arasındaki ilişkilerle yapmaktadır. Üretici olasılık modeller olarak bilinen dinamik modellerden gizli uzay modeli, Markov Zinciri Monte Carlo (Markov Chain Monte Carlo-MCMC) yöntemini kullanarak düğümleri ölçeklemektedir. Stokastik blok modeli ise gizli uzay modelinden farklı olarak daha fazla düğümü ölçekleyebilmektedir. Stokastik Aktör Odaklı Modeller (Stochastic Actor Oriented Models-SAOM), model içerisinde düğümlerin konum ve davranışlarını temsil etmektedir. Dinamik ağlar, temsil öğrenme gizli grafiklerde kullanılmaktadır. Tensör ayrıştırma tabanlı yöntemler, zaman özneline matris genelleştirmeleridir. Rastgele yürüyüşe dayalı yöntemler gömme görevlerine yardımcı olmaktadır. Derin öğrenmeye dayalı modeller ise adından da anlaşılacağı gibi derin öğrenme yaklaşımları içermektedir. Boltzmann makineleri olasılıksal çıkarımlarda üretkenlikte kullanılmaktadır. DNN'lere baktığımızda ise GNN'lerde olduğu gibi grafiği kodlayan fakat isminden de anlaşılacağı gibi dinamik grafikleri kodlayan ağlardır. Şekil 4'te DNN türleri görülmektedir [23].

Sözde dinamik modeller ağın birden fazla anlık görüntüsünü modellemektedir. Ayrıca bağlantı eklemede de kullanılmaktadır [24]. Üretken Grafik Evrişim Ağı (Generative Graph Convolutional Networks-G-GCN) [25], büyüyen grafiklerde süreç modellenirken soğuk başlatmanın oluşturduğu sorunlara karşılık bu modelden tamamlanmıştır. Model üst seviye performans göstermiştir. Düğümler için bağlantı tahmini yapabilmektedir. Aynı durum Varyasyonel Grafik Otomatik Kodlayıcı (Variational Graph Auto-Encoders-VGAE) [26] için de geçerlidir. VGAE denetimsiz öğrenmeyle eğitilmektedir. Yönlendirilmiş grafiklerde başarılı ve gizli bilgileri öğrenme yeteneğine sahiptir. Aynı durum yarı denetimli öğrenme kullanılarak da denenmiş ve başarılı olduğu belirtilmiştir [27]. Kenar ağırlıklı modeller, dinamik ağ modelinin basitleştirilmiş halidir. Dinamik ağ


basitleştirilerek kenar ağırlıklı bir ağa dönüştürülür ve statik GNN modelleri ile kullanılır. En bilinen model ise Zamansal Bağımlı Grafik Sinir Ağı (Tree Decomposed Graph Neural Network-TDGNN) [28] adıyla bilinmektedir. Bu yöntem ile hedef düğüme komşu olan düğüm bilgileri ve özellikleri, zamansal toplayıcı (Temporal Aggregator-TDAg) ile toplanmaktadır. Model bağlantı tahmini için kullanılmaktadır. Ayrık modelleme kullanılarak statik grafiklerde anlık görüntü alma başarılıdır. Statik dinamik modellerde Birleştirilmiş Dinamik Grafik Evrişim Ağı (Concatenate Dynamic Graph Convolutional Networks-CD-GCN) ve Şelale Dinamik Grafik Evrişim Ağı (Waterfall Dynamic Graph Convolutional Networks-WD-GCN) kullanılmaktadır. Entegre Dinamik Sinir Ağları ise birçok dinamik sinir ağı modelinde olduğu gibi GNN ve RNN'leri birleştirerek modellemeyi, bu birleşim ile kodlayan modellerdir [23]. Konvolüsyonlu Uzun Kısa Süreli Bellek (Convolutional Long Short-Term Memory-ConvLSTM) [29] modelinden ilham alınarak geliştirilmiştir. Bu model tahmin için Tekrarlayan Sinir Ağlarından olup girdiden duruma ve durumdaki duruma geçiş için evrişimsel yapısı bulunmaktadır. Tahmin için kullanılan tahminini geçmiş durumlardan çıkarmaktadır. Sonraki yıllarda bu modeller genişletilerek yeni modeller geliştirilmiştir. Yağış tahminleri ve uçuş güvenliği için Evrişimsel LSTM, değişken konumlarda yapı öğrenmesi için Yörünge GRU (Trajectory GRU-TrajGRU) [30], geçmişten çıkarım yaparak geleceği tahmin eden Üreten Tekrarlayan Sinir Ağı (Recurrent Neural Networks for Predictive Learning-PredRNN) [31], Gradient Otoyol Birimi önerisiyle geliştirilen tekrarlayan ağ ve PredRNN'in gelişmiş versiyonu olan ve zaman ikilemini çözmek için önerilen PredRNN++ [32], video tahmini için etkin bir model [33] ve biyomedikal sektörde görüntü segmentasyonu için U-Net [34] modeli geliştirilmiştir [35]. Evrişimsel LSTM'den esinlenerek geliştirilen bir diğer model ise girdi olarak düğümlerde ConvLSTM'nin kullandığı 3B tensörlerin aksine özellik vektörü kullanan GCRN-M2 [36] modelidir. ImageNet [37], Moment in Time [38] ve Places [39] veri setleri entegre ağlarda çoğunlukla kullanılmaktadır. Dinamik otomatik kodlayıcılar ve üretken modellerde ayrık bölümde işlenmektedir [23]. Burada en bilinen model Dinamik Grafik Gömme Modelidir (Deep Embedding Method for Dynamic Graphs-DynGEM) [40]. Dinamik grafiklerde hesaplamayı iyileştirmek için geliştirilen model

anlık görüntüleri kullanmaktadır. Sürekli ağlar ise üç farklı yaklaşım üzerinde incelenmektedir [23]. İlk yaklaşım RNN tabanlı modellerdir. Yenilemeden kaynaklı olarak ağ sürekli güncellenmektedir. Bu tabanda iki farklı model geliştirilmiştir. Bunlarda ilki özel olarak tasarlanmış ve yönlendirilmiş grafikler üzerinde çalışan Akış Grafik Sinir Ağı (Streaming Graph Neural Networks-SGNN) [41], diğeri ise gelecekteki yerini modelleyebilen ve gömme yörüngeleri üzerinde öğrenim sağlayan JODIE [42] modelidir. Zamansal nokta süreci tabanında en bilinen yöntem know-evolve [43] yöntemi olmuştur. Doğrusal olmayan bir biçimde gelişen varlık temsillerini öğrenebilmektedir. Etkileşim ağlarına dönüşüm içinde Geçici Nokta Süreci (Temporary Point Process-TTP) parametreleri yardımı ile gerçekleştirilmektedir. Yapılan deneyler sonucu başarı göstermiştir. Geliştirilen bir başka model olan DyRep [43], düşük boyutlu grafiklerde düğüm yerleştirme işlemi için kullanılmaktadır. Bilgi grafiklerinde başarılı olmuş, yapısal ve düğümler arası iletişimi ifade edebilmesi yeteneği ile modelleme gerçekleştirebilmektedir [23]. Son taban modeli olan zaman gömmeli modeller, zaman temsilde konumsal kodlama kullanmaktadır [44]. Zamansal Grafik Dikkat (Temporal Graph Attention-TGAT) [45] katmanı ile zaman özellik öğrenmesi gerçekleştirirken aynı zamanda komşuluk özelliklerini toplamasında sağladığı verim ile öne çıkmaktadır. Diğer grafiklere baktığımızda ise hipergraflar ve imza grafikleri görülmektedir. Hipergraflar üst düzey veri kümelerini kodlayabilen modellerdir. Bilinen model olan Hipergraf Sinir Ağları (Hypergraph Neural Networks-HGNN) [46], karmaşık verilerin modellenmesi için geliştirilmiştir. Yapılan deneyler sonucu model iyi bir performans göstermiştir. İmzalı grafikler ise negatif ya da pozitif gibi farklı ve zıt olabilen işaretli grafiklere denilmektedir [7]. Bu modeller sadece pozitif grafiklere odaklanıldığı için gelişim sürecinde ortaya çıkan sorunlar nedeniyle doğmuştur. Model ayrıca düğüm temsillerini belirlemek için geliştirilmiş ve İmzalı Grafik Evrişimli Ağ (Sparse Graph Convolution Network-SGCN) [47] olarak adlandırılmıştır.

## 2.2. Tasarım Kayıp Fonksiyonu

Grafik türü ve ölçeği belirlendiğinde ise sırada tasarım fonksiyonunu anlamak ve oluşturmak vardır. Tasarım kaybı fonksiyonu Şekil 1'de de görüldüğü gibi eğitim ayarı ve görev kısımlarından oluşmaktadır. Görevler; düğüm düzeyi, kenar seviyesi ve grafik düzeyi olarak ayrılabilir. Düğüm düzeyi görevleri, düğümlere odaklanmaktadır. Düğüm ile ilgili en bilinen görevler ise düğüm sınıflandırması ve düğüm kümesi görevleridir. Kenar seviyesi, kenarlarla ilgilenmekte ve kenar türünün sınıflandırılmasına odaklanmaktadır. Bağlantı tahmini ve kenar sınıflandırma, örnek görev olarak verilebilmektedir. Grafik düzeyi ise grafik temsil amaçlı öğrenmeye odaklanmaktadır. Grafik sınıflandırma bu görevlerde en bilinen örnektir [7]. Eğitim ayarına bakıldığında ise derin öğrenmede olduğu gibi denetimli, yarı denetimli ve denetimsiz türler görülmektedir. Denetimli eğitim, etiketlenmiş veriler sayesinde gerçekleşmektedir. Yarı denetimli eğitim ise az sayıda etiketlenmiş düğüm ve belirsiz sayıda etiketlenmemiş düğüm ile gerçekleşmektedir. Bu iki eğitim ayarı ile tasarım kolayca gerçekleşmektedir. Denetimsiz eğitimler ise sadece etiketlenmemiş veriler ile gerçekleştirilmekte ve grafik özellikleri bu ayarda grafik tarafından sağlanan bilgiler ile oluştuğu için oldukça zordur.

Bu sebeple otomatik kodlayıcılar ve karşılaştırmalı öğrenme yöntemleri ile yapılmaktadır. Şekil 5'te denetimsiz ayar modelleri görülmektedir.



Şekil 5: Denetimsiz ayar modelleri

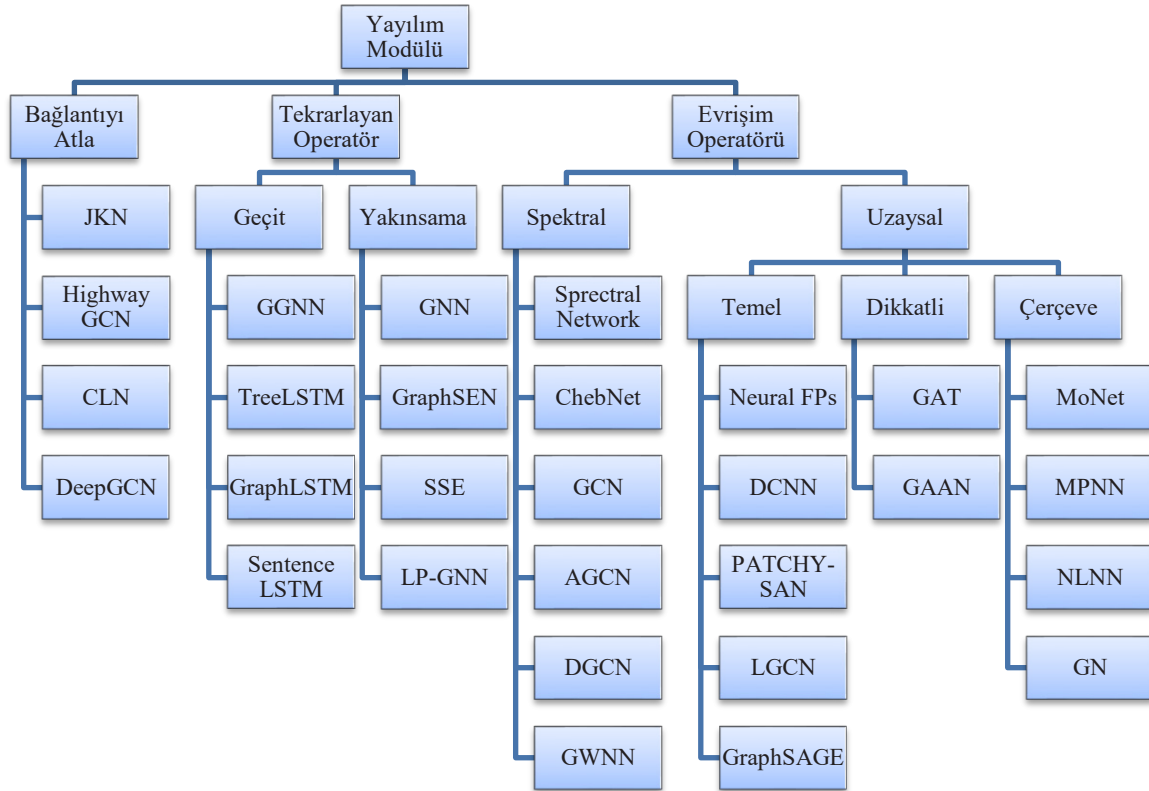
Şekil 5'te [7] görüleceği üzere denetimsiz öğrenme için farklı modeller geliştirilmiştir. Öncelikle otomatik kodlayıcıları incelendiğinde beş farklı model görülmektedir. İlk olarak Değişken Otomatik Kodlayıcı (Graph Autoencoders-GAE) yapısına sahip grafikler üzerinde çalışabilen Varvasyonel Grafik Otomatik Kodlayıcı (Variational Graph Autoencoders-VGAE), ilk geliştirilen modellerden birisi olmuştur. Bu model için grafik evrişimli ağlar kullanılmaktadır [26]. Grafik gömme görevi, düşük boyutlarda etkin bir yöntem olmuştur fakat eşitlemelerde geçmiş dağıtımda zorlanmaktadır. Bu soruna çözüm oluşturmak için çekişmeli olarak Düzenlenmiş Grafik Otomatik Kodlayıcı (Adversarially Regularized Graph Autoencoder-ARGA) [48] ve düşmanca Düzenlenmiş Değişken Grafik Otomatik Kodlayıcı (Adversarially Regularized Variational Graph Autoencoder-ARVGA) [48] modelleri geliştirilmiştir. Geliştirilen modeller grafik sınıflandırma ve bağlantı tahmini görevlerinde iyi bir performans elde etmiştir. Geleneksel yöntemler modernleşirken, ağlarda bulunan bir başka soruna da çözüm bulmuştur. Bu sorun grafik ağlarını keşfetme temelli, grafik kümelemedir. Marjinalleştirilmiş Grafik Otomatik Kodlayıcı (Marginalized Graph Autoencoder-MGAE) [49] modeli, temsili öğrenmede sadece denetimsiz olarak çalışmamaktadır ve bozuk özellikler marjinalleştirilerek işlem yapılmaktadır. Aynı zamanda en önemli özelliği de otomatik kodlayıcıyı grafik alanına iletmesi olarak belirtilmiştir. Deneyler sonucu gösterdiği performans başarılı sayılmış düğüm temsili görevinde kullanılmıştır. Bir başka model olan simetrik otomatik kodlayıcı GALA [50], Laplacian yardımıyla işaretli grafikler üzerinde kararlı bir model olmuştur. Bağlantı tahmini ve kümelemede iyi bir performans elde etmiş olan GALA, görüntü kümeleme görevlerinde performansını arttırmıştır. Bir başka model olan Uyarlamalı

Grafik Kodlayıcıyı (Adaptive Graph Encoder-AGE) [51] ise GCN'lerin dezavantajlarından yola çıkarak geliştirilmiş bir modeldir. Modelin sağladığı faydalar performans ve sağlamlık amacı, gerçek dünyada tutarlı olmayan matris kurtarımına önem vermesi olmuştur. İki modülden oluşan AGE ilk modülünde Laplacian yumuşatması kullanırken ikinci modülünde ise özellikleri güçlendiren bir kodlayıcı kullanmaktadır. Deneylerden elde edilen sonuçlara göre model performansı son derece başarılıdır. İkinci taban olan karşılaştırmalı öğrenme içinde farklı modeller geliştirilmiştir. Derin Grafik Infomax (Deep Graph Infomax-DGI) [52], iyi temsiller öğrenmek için görüntü temsili model önermektedir. Görsel temeli bulunan çok modellenli bir öğrenme yaklaşımı sunarken, sınırlı verilerle ilgilenmektedir. Düşük boyutlu veriler üzerinde bilgiyi arttırmaktadır. InfoGraph [53], karşılık bilgiyi maksimum seviyeye getirmeye çalışan bir modeldir, asıl amacı ise grafik temsil öğrenmedir. Deneyler

sonucu etiketlenmemiş düğümler üzerinde etkili olduğu görülmüştür. Farklı ölçeklerde olan grafiklerde düğüm, kenar ve üçgen özneline başarılı olmuştur. Son model olan çoklu öğrenme ise [54], kendi kendini denetleyen ve grafik difüzyonları ile elde edilmiş bir modeldir. Deneyler sonucunda %50 başarı gösterilmiş, görüntü sayısı artışı ve çoklu katmanda performansın iyileşmediği belirtilmiştir.

### 2.3. Hesaplama Modülleri

GNN'lerin temel yapısının incelendiği çalışmamızda son incelenecek olan kısım hesaplamalı modüllerin bulunduğu kısımdır. Bu kısımda yayılım, örnekleme ve havuzlama modülü incelenecektir. Yayılım modülü, düğümler arası bilgi aktarımı için, örnekleme modülü, büyük grafiklerde yayılım yapmak amacıyla, havuzlama modülü ise düğümlerden bilgi çıkarma amacıyla kullanılmaktadır [7]. Şekil 6'da [7] yayılım modülü görülmektedir.



Şekil 6: Yayılım modülü


#### 2.3.1. Yayılım Modülü

Yayılım modülü üç farklı grup içerisinde incelenmektedir. İlk grup bağlantıyı atla operatörleridir. Bağlantıyı atla operatörleri derin GNN'ler elde etme amacıyla modellenmektedir. İlk incelediğimiz model olan Sıçrayan Bilgi Ağları (Jumping Knowledge Networks-JKN) [55], komşu toplama prosedürüyle özellik analizi yapmaktadır. Komşu düğüm aralığında olan mesafeyi rastgele yürüyüş benzetimli komşu aralıklı öğrenme ile amaçlayan bir modeldir. Sosyal ve biyoinformatik ağlarda başarılı olmuştur. JKN'ler evrişimli ağlar ve dikkat ağlarından daha iyi yararlanmak içinde kullanılmaktadır. Otoyal ağları, LSTM tabanında derine inebilmek için

geliştirilmiş bir modeldir [56]. Dil modelleme deneylerinde başarı göstermiştir. Ayrıca geliştirilerek evrişimli ağlarda coğrafi konum belirlemede de kullanılması için çalışmalar yapılmıştır [57]. Yapılan çalışma performans açısından başarılı olmuştur. Sütun Ağı (Column Network-CLN) [58], topluluk sınıflandırma amacıyla kullanılmaktadır. Toplu sınıflandırma genel olarak zor bir görev olduğu için geliştirilen Sütun Ağı, çok sayıda ilişkili alanlar özneline toplu sınıflandırmayı gerçekleştirmektedir. Model dünya tabanlı uygulamalar olan yazılımsal gecikme tahmini, medikal diyabet sınıflandırması ve film-tür sınıflandırmasında başarılı olmuştur. En önemli özelliği ise öğrenme ve çıkarımı ağ üzerindeki ilişkilerin sayısı ile doğrudur. Derin Grafik Evrişimli Ağlar (Deep Graph


Convolutional Networks-DeepGCN) [59], model tabanlı optimizasyon yöntemleri ve ayırt edici öğrenme yöntemlerinin sorunlarına el atmaktadır. DeepGCN'lerin amacı ise gürültü gidericiler ve değişken bölme yöntemleri yardımıyla hızlı ve etkili bir CNN elde etmektir. Deneyler sonucu Gauss gürültü giderici ve düşük seviyeli görüş uygulamalarında başarı yakalamıştır. DeepGCN'ler farklı modeller olan ResGCN, ResNet ve DenseGCN'den ilham almıştır. ResNet [60], derin ağların eğitimi için kullanılmaktadır. Farklı veri kümelerinde yapılan deneyler sonucunda başarı elde etmiştir. Ayrıca ResNet [61], kimlik eşlemeleri için de kullanılmaktadır. Bu kullanımda ileri ve geri sinyalleri bloklar arası atlama ile gerçekleştirmektedir. Bu durum eğitimi kolaylaştırmak ve genelleme yapımını geliştirmek için kullanılmaktadır. Yoğun Bağlantılı Evrimsel Ağlar olarak bilinen DenseNet [62], giriş ve çıkış arasında bağlantı kısılalığından yararlanarak derin ve verimli bir eğitim içeren modellemedir. Her katman birbirinden beslenmekte ve bu sayede doğruluk yüksek tutulmaktadır. Bu ağlarda özellikler tekrar kullanılabilmekte ve parametre sayısının azalmasıyla özellik yayılımını kuvvetlendirmektedir.

Artık Grafik Evrişim Ağı olarak tanımlanan ResGCN [63] ise anormal düğüm tespiti ile izinsiz giriş tespiti yapabilmektedir. Tespit işleminde karşılaşılan durumlar olan artık modelleme ve ağ yumuşatma, ResGCN ile çözülebilmektedir. Model sayesinde anormal düğümlerin oluşturduğu etkiler azaltılmaktadır. Derin ağlar sadece grafik ağlarında değil CNN'ler üzerinde de bulunmaktadır. GCN ve CNN'ler birbirlerini evrensellemektedir. Derin CNN'lere bakıldığında [64] görüntü sınıflandırma, belge analizi ve konuşma tanıma alanlarında uygulanmaktadır. Aynı şekilde Derin GAN yani Derin Üretken Düşman Ağı görüntüden görüntüye çeviri ve yüz yaşlanması gibi alanlarda kullanılmaktadır. Tekrarlayan operatörler, yayılım modülünde bulunan bir diğer operatör grubudur. Bu operatörlerde katmanların ağırlıkları eşittir [23]. Tekrarlayan operatörler, yakınsama tabanlı yöntemler ve geçit tabanlı yöntemler olarak iki farklı grupta incelenmektedir. Şekil 7'de [7] tekrarlayan operatörler görülmektedir.



Şekil 7: Tekrarlayan operatörler-yakınsama

İlk incelenen grup olan yakınsama tabanlı yöntemler, dört farklı modelden oluşmaktadır. Temel olarak GraphESN, SSE ve LP-GNN modelleri ele alınmıştır. GraphESN yani Grafik Yankı Durum Ağlarını anlayabilmek için öncelikle ESN'lerin yani Yankı Durum Ağlarının anlaşılması gerekmektedir. ESN'ler RNN yankı durumlarının oluşması ile adlandırılmaktadır. İlk bakış sinir ağlarında gerçek zamanlı durumlarda işlenebileceğinin düşünülmesiyle temeli oluşturulmuştur. İlk çalışma sinirsel nöron okuması, nörofizyoloji ve nöroteknoloji'de kullanılmıştır. Kullanım Turing makinelerine dayanmaktadır ve titiz bir şekilde matematiksel işlemler üzerinde çalışmaktadır [65]. ESN'ler, RNN'lerin yankı durumlarında davranışları ve onlara karşı geliştirilen bir model olarak karşımıza çıkar [66]. GraphESN'ler ise ESN'lerin grafikler üzerinde geliştirilmesiyle oluşturulmaktadır. GraphESN'ler farklı grafik türlerinde (yönlendirilmiş/yönlendirilmemiş, döngüsel, etiketli) Özyinemeli Sinir Ağlarının yani RecNN modeline karşı oluşturulmuştur. ESN'ler ile bu yönü benzerdir. Performans için eğitimsiz kodlama kullanılmaktadır. Bir avantajı ise sinir ağları ve çekirdek tabanında yaklaşımları karşılaştırabilmektedir [67]. SSE modeli stokastik kararlı durum gömme ağ modeli olarak bilinmektedir. Grafiklerde yinelemeli algoritma kullanımında kararlı durum öğrenimi için kullanılmaktadır. Model ayrıca algoritmanın kullanımında 10.000.000'dan fazla düğüm için grafik işleyebilmektedir. Ayrıca model karşımıza çıkan sabit durumlarda kısıtlamalar arasında geçiş yapabilmektedir [68]. Lagrange Yayılımı Grafik Sinir Ağı (Lagrangian Propagation Graph Neural Network-LP-GNN) modelinde grafiklerde bilgi yayılımında Lagrange çerçevesi kullanılmaktadır. LP-GNN, GNN mimarisi üzerinde inşa edilmiş GNN yapısını genişleten bir modeldir. Komşu düğüm arasındaki durum incelemelerinde difüzyon mekanizmasından yararlanmaktadır. Difüzyon mekanizması, nöral ağlarda karşılaşılabilen problemlerden olan derinlik ve yeniden sarma gibi problemlerin üstesinden gelmek için kullanılan Grafik Makine Öğrenmesi yöntemidir. LP-GNN'de GNN hesaplamaları kolaylaştırılmaya çalışılmıştır. Grafiklerin işlenmesi için başarılı olacağı belirtilmiştir [69].




Şekil 8: Tekrarlayan operatörler-geçit

Tekrarlayan operatörler içerisinde incelenen bir diğer model ise Şekil 8’de [7] de görüldüğü gibi geçit ya da kapı tabanlı yöntemlerdir. Bu yöntemler dört farklı model ile anlatılmaktadır. Modellerin anlaşılabilirliği için öncelikle Kapılı Tekrarlayan Birim (Gated Repetitive Unit-GRU) ve Geleneksel Uzun Kısa Süreli Bellek (LSTM)’in anlaşılması gerekmektedir. Bu yöntemler kapı kullanmayı amaçlamaktadır. Tekrarlayan sinir ağlarında kodlayıcı ve kod çözücü işlemlerinde yardımcı olmaktadır [70]. GRU’lar derinleştirilerek bilgi akışını kontrol etmektedir. Derin Basit Kapılı Birim (Deep Simple Gated Unit-DSGU) ve Basit Kapılı Birim (Simple Gated Unit-SGU), uzun süreli bağımlılıkları öğrenmek için kullanılmaktadır. GRU bilgi akışını kontrol etmek için birden fazla kapı kullanırken SGU ve DSGU ise sadece çarpımsal kapıları kullanmaktadır. Bu sayede öğrenme hızı arttırılabilmektedir. Bu kapı birimleri RNN’lerde ilişki analizi için kullanılan RNN Geleneksel Grafiği (RNN Conventional Graph-RCG) için de kullanılmaktadır [71]. Geleneksel Uzun Kısa Süreli Bellek (LSTM) ise geniş zaman aralıklarında kullanılmaktadır. Asıl amacı bilgi depolamayı öğrenmektir. LSTM gelişmişlik düzeyiyle hesaplama karmaşıklığını sıfıra indirmektedir. Tekrarlayan sinir ağları tarafından çözülemeyen zorluk olan uzun süre gerektiren gecikmeli görevleri de çözebilmektedir. LSTM başarılı olmuştur ve öğrenme seviyesi yüksek olmakla birlikte hızlıdır [72]. GGNN yani Kapılı Grafik Sinir Ağı, özellik öğrenmeye dayalı geliştirilmiş bir metottur. GNN’ler yaygın olarak bilgi tabanları, doğal dil bilimleri ve sosyal bilimler alanlarında kullanılmaktadır. Referans olarak kapılı tekrarlayan modüller alınmış ve optimizasyon kullanılmıştır. Geliştirilen model sıra-geçit tabanlı modellere göre daha olumlu sonuçlar vermiş yapay zekâ ve grafik öğrenme algoritmalarında kullanılmıştır. Model temel olarak yüksek performans sergilemiştir [73]. Model sonraki yıllarda grafik – sıralı öğrenme için revize edilerek geliştirilmiştir. GNN’lerde yaygın bir biçimde kullanılan NLP öğrenme aşamasında farklı sorunlar yaratabilmektedir. Geliştirilen model dilbilgisi tabanlı öğrenme yaklaşımlarında iyi bir performans elde etmiştir [74]. GGNN’ler, GNN’lerin yetersizliklerini ortadan kaldırmak için geliştirilmiş ve bu amaçla Kapı Tekrarlayan Birimlerini (GRU) ve hesaplama için zaman içinde geri yayılımı (Backpropagation Through Time-BPTT) kullanmaktadır [7]. Sinir ağlarının gelişiminde farklı algoritmalar kullanılmıştır. Bu algoritmaların biri de Geri Yayılım (Backpropagation-BP) algoritmasıdır. Algoritma makine öğrenme algoritması olan gradient descent’i kullanmaktadır. Gradient descent algoritması GNN’lerde grafik üzerinde bulunan noktaların ya da belirlenecek bir işlevin yerel ekstremum noktalarını bulmak için kullanılan yinelemeli bir optimizasyon algoritmasıdır. Makine öğrenme ve derin öğrenme de sıklıkla kullanılmasıyla birlikte en çok kullanım amacı en az kayıp oluşturmaktır. BP algoritması bu algoritma özelinde türetilmiştir. Bu sayede geliştirilen model ile önyargı ve nöron ağırlığı hataları tespit edilebilmektedir. BPTT ise BP algoritmasının yinelenen sinir ağlarına uygulanması için geliştirilmiş ve sıralı modeller için verim sağlamıştır. Bunun başlıca nedeni RNN üzerinde yapılan deneylerde RN’lerin tekrarlama yapması ve geçmiş bilgisini tutmasıdır [75-77]. TreeLSTM, ağaç yapısı kullanılarak genişletilen LSTM türevi bir metottur. Metot yapılan deneyler sayesinde ve düşünce amacı ile iki cümle anlam tahmini ile duygu sınıflandırmasında kullanılmıştır. Kompozisyonel Dağılım Semantik Modellerinin değerlendirilmesi ile anlamsal ilişki ve yargı tahmini-iki

cümle anlam tahminini oluşturmuştur. Öte yandan uzun cümlelerin anlam ifadelerinde bulunan anlamsızlıkları ortadan kaldırmak için zengin küme ve denetimli eğitim kullanılması gerekmektedir. Bu durum sonucu duygu ağacı bankası oluşturulmuştur. Ağaç kümesinde eğitilen Özyinelemeli Tensör Sinir Ağı ile duygu tahmini yapılmış ve yüksek performans göstermiştir. Ayrıca bu model olumlu ve olumsuz ifade kavramı ile alanında tek model olmuştur. TreeLSTM, LSTM mimarisi üzerinde geliştirilerek Child-Sum Tree-LSTM ve N-ary Tree-LSTM modellerini de oluşturmuştur. Child-Sum, yüksek dallanma ve çocuk sırasız için uygunken, N-ary, N sayılı dallanma ve sıralı ağaç yapılarında kullanılmaktadır [7, 78-80]. Grafik LSTM, TreeLSTM’in geliştirilmiş versiyonudur. TreeLSTM modellerine uygulanabilmektedir. Grafik yapılı LSTM ilişki ayıklama [81], nesne ayrıştırma [82] ve konuşma modellemesi [83] gibi farklı alanlarda kullanılmıştır. İlişki ayıklamada, yapılan çalışmalar genellikle ikili ilişkilerde ayıklama ile yapılmaktadır. Daha fazla ilişki için n-ary kullanılarak, grafik uzun vadeli bellek ağları yardımı ile daha fazla ilişki ayıklanması denenmiştir. Bu sayede çok görevli öğrenme sağlanacak ve çapraz bilgi üretme gerçekleşecektir. Bu ilişkilerde keyfi aritmetik kullanılmaktadır. Geliştirilen model başarılı olmuştur [81]. Anlamsal nesne ayrıştırması ile LSTM kullanılarak geliştirilen süper pikseller yardımıyla yeni bir grafik elde edilmektedir. Bu sayede Graph LSTM görüntülere daha iyi odaklanabilmekte ve daha fazla başarı sağlamaktadır [82]. Konuşma modellemesinde ise diğer kullanım amaçlarında kullanılan uzun vadeli bellek ağları yerine uzun kısa süreli bellek kullanılmıştır. Bu sayede çift yönlü ağaç kullanılmış, modelleme ve yorumlamada tanımlama işlemi kolaylaşmıştır [82]. Tekrarlayan operatörlerde incelenen son model olan S-LSTM, metin kodlaması amacıyla geliştirilmiştir. Geliştirilen model, dizi etiketleme için kullanılan BiLSTM modeliyle rekabet edebilmektedir [84-85].

Evrişim operatörü, yayılım modülü altında incelenen bir diğer operatördür. Evrişim operatörleri en çok kullanılan yayılım modülü operatördür. Evrişim operatörü uzaysal yaklaşım ve spektral yaklaşım olmak üzere iki başlık altında incelenmektedir. Şekil 9’da [7] evrişim operatörü spektral yaklaşımlar görülmektedir.

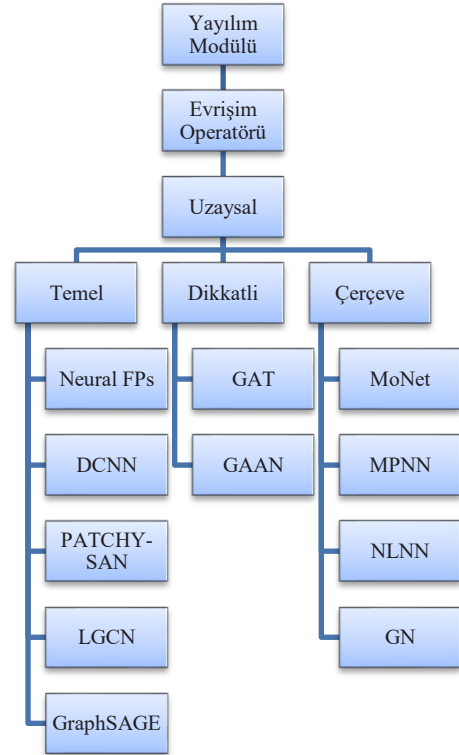
Spektral yaklaşımlar, grafiklerin görüntü yönüne odaklanmaktadır. Bu durum grafiklerin sinyal işleme alanına dayandığını göstermektedir. Büyük veriler grafiklerde ağırlık dengelemek için uç köşelerde bulunmaktadır. Bu sebeple grafiklerde sinyal işleme yapılırken sayısal ve görüntü yönüne dikkat edilmektedir. Bu düzensiz yapılar grafik görüntü işleminde düzene sokularak temel işlemler genelleştirilmektedir. Bunun sebebi verimli ve güvenli bir şekilde bilgi çıkarımı yapmaktır [7, 86]. Evrişimin temelinde Fourier dönüşümü bulunmaktadır. Doğrusal sinyal işleme için frekans filtreleme kullanılmaktadır [87]. Spektral yaklaşımlar altı farklı alt başlıkta incelenmektedir.



Şekil 9: Evrişim operatörü–spektral

Spektral ağ, geometrik derin öğrenmenin geliştirilmesiyle elde edilmektedir. Bilgisayarlı görme, doğal dil işleme ve ses analizi konularında derin sinir ağları kullanılmaktadır. Geometrik derin öğrenme bu alanlardaki sorunlara çözüm olma amacıyla oluşturulmuştur [88]. Aynı şekilde Öklid olmayan uzayda derin öğrenme gerçekleşmesi için büyük verilerde test edilen model başarılı olmuştur [89]. ChebNet, Chebyshev polinom yaklaşık algoritması ile dönüşüm hesabı yapmak için geliştirilmiştir. Amaç grafik köşelerinde dalgacık dönüşümü gerçekleştirmektir. Çözüm için grafik Laplacian spektral ayrışmasını kullanmaktadır [90]. Laplacian, grafik öğrenmede sıklıkla kullanılmaktadır. Karışık ve büyük verilerde başarı göstermektedir [91]. Aynı şekilde CNN üzerindeki uygulamalarda geliştirilerek grafik spektral teorisi ile sorun çözülmektedir [92]. Yakın geçmişte Chebnet gelişerek yüksek boyutlu fonksiyonlarda da verimli olmuştur. Düzeltilmiş doğrusal birimleri (Rectified Linear Unit-ReLU), düzeltilmiş güç üniteleri (Rectified Power Units-RePU) ile karşılaştırılarak verimleri ölçülmüştür. Model sayısal olarak kararlı ve verimlidir. RePu daha güzel sonuçlar vererek başarısını kanıtlamıştır [93]. Bu çalışma sonrasında Chebnet'e olan ilgi artmış ve pratik olarak karşılaştırma tekrar yapılmıştır. Chebyshev polinom yaklaşık hiyerarşi kuramı üzerine yeni bir model geliştirilmiş, geliştirilen modelde RePu kullanılmıştır. Yapılan karşılaştırma bir sonraki deneylerde ChebNet ile yapılarak ChebNet'in daha kararlı ve verimli olduğu ortaya konulmuştur [94]. AGCN, yani Uyarlanabilir Grafik Evrişimli Sinir Ağları CNN'lerin evrimleşmesi ile gerçekleşmektedir. CNN'ler alt modellerine ayrılırken grafik uygulamaları için Graph CNN'ler geliştirilmiştir [95]. Graph CNN, görüntü analizi ve grafiklerde kullanılmaktadır. Başarısı kanıtlanmış ve nokta bulutlarında sıklıkla kullanılmaktadır [96]. AGCN, temel

girişlerde karmaşa olsa da CNN'in geliştirilmesi ile görev odaklı eğitim sonucu uygulanabilir GNN'yi oluşturmaktadır. Öğrenme için metrik öğrenme tavsiye edilmiş, deneyler sonucunda ise üstün başarı göstermiştir [97]. DGCN, yani ikili grafik evrişim ağı grafik analizi ile veri ayıklamayı amaçlamaktadır. Yarı denetimli öğrenme ile küresel tutarlılık ve yerel tutarlılık sağlamaktadır. Deneyler sonucu başarı gösteren DGCN, iki evrişimsel ağ kullanarak çalışmakta ve bu çalışma sonucunda denetimsiz bir kayıp çıkmaktadır [98]. GWNN, yani Grafik Dalgacık Sinir Ağı grafik dalga dönüşümü kullanarak Spektral Grafik CNN'lerin eksikliklerini ortadan kaldırmak için geliştirilmiş bir metottür. Metot matris ayrışmasına ihtiyaç duymadan elde edilebilmekte ve seyrek–yerel grafik dalgaları sayesinde verimlidir. Yarı denetimli sınıflandırma ile Pubmed, cora ve citiseer ile test edilmiş CNN'lere göre yüksek başarı göstermiştir [99]. Evrişim operatörlerinde inceleyeceğimiz bir diğer başlık ise Uzaysal yaklaşımlardır. Uzaysal yaklaşımlar Şekil 10'da [7] görülmektedir.



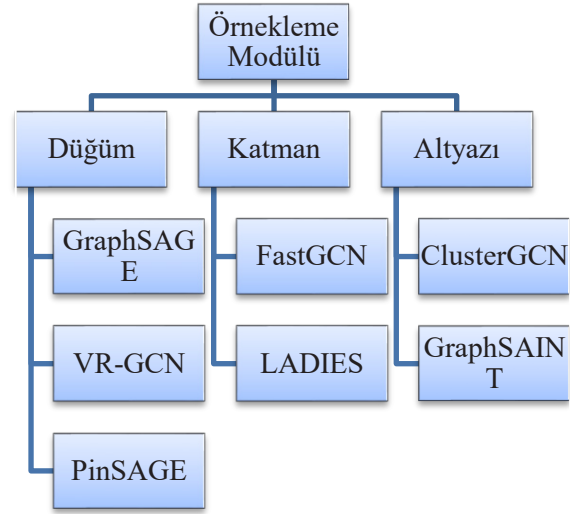
Şekil 10: Evrişim operatörü–uzaysal

Evrişim operatörü uzaysal yaklaşımlar üç farklı başlık altında incelenmektedir. Bu başlıklar, temel uzaysal yaklaşımlar, dikkat temelli uzaysal yaklaşımlar ve çerçeve genellemesinde uzaysal yaklaşımlar şeklindedir [7]. Temel uzaysal yaklaşımlar, örtüşme miktarı grafiklerin değişmeyen özellikleri üzerinde zaman eksenini boyunca gerçekleşen yaklaşımlardır. Bu yaklaşımların karşılaştığı zorluk ise farklı boyutlardaki kümelerin evrişim operatörü tanımlanması ve CNN tabanında değişmezliklerin kontrol edilmesidir. Yaklaşımlar beş farklı model ile incelenmektedir [7]. Neural FPs, sinirsel parmak izi olarak tanımlamakta ve temeli dairesel parmak izlerine dayanmaktadır. Model düşüncesi sinirsel parmak izlerinin sabit parmak izlerine kıyasla yeni avantajlar sunacağı araştırmasıyla doğmuştur. Tahmin

performansı, yorumlama ve parsimoni avantajları ile öne çıkan sinirsel parmak izleri, doğrusal yönden grafikler üzerinde çalışmaktadır. Veri odaklı özellikler makine görüşü, konuşma tanıma ve doğal dil işleme gibi alanlarda manuel giriş ve özelliklerin yerini almakta olduğu bilinmektedir. Geliştirilen model bu alanlarda başarı sağlamak ayrıca sanal tarama, malzeme tasarımı ve ilaç tasarımı çalışmaları için öncü olduğu düşünülmüştür [100]. DCNN, en sık kullanılan grafik sinir ağlarından olup difüzyon-konvolüsyonel sinir ağları olarak adlandırılmaktadır. Düğüm sınıflandırılmada kullanılan DCNN, grafiklerin yapılandırılan verilerden öğrenimini difüzyonel gösterimler ile sağlamaktadır [101]. PATCHY-SAN, grafik verilerinde öğrenme sorunu üzerinde durmaktadır. Sorun temele indiğinde iki ana sorun halinde düşünülmüş ve çözüm üretilmeye çalışılmıştır. Komşuluk sorunları üzerinde duran model, düğüm dizilerinin anlaşılabilirliği ve normalleştirme ile eşleştirilmesi durumlarını rastgele grafiklerde yapmak için geliştirilmiştir. Rastgele grafikten bahsedilen ise grafiklerin yönlü, yönsüz, homojen, heterojen, ayrık ve sürekli olma durumlarıdır. CNN temelinde yapılan deneyler eşliğinde model üstün performans göstermiş, gelecek çalışmalar için ise RNN tarzı sinir ağlarının kullanılmasıyla ön eğitim ve ilişkisel grafik modellerin oluşturulabileceğini belirtmiştir [102]. LGCN, öğrenilebilir grafik evrişimsel ağlar olarak tanımlanmaktadır. CNN'lerin genel sorunu olan ızgara verilerinde elde edilen başarının grafiklerde de elde edilmesi istemiyle geliştirilmiştir. Genel anlamda eşli işlem kullanılması gerekli olan durumlar için yani komşu sayılarının değişken olduğu durumlarda ele alarak öğrenilebilir grafik eşlemsel katmanı (Learnable Graph Convolutional Layer-LGCL) altında bir öneri ile sorunu ele almıştır. LGCL verileri bir boyutlu ızgara verilere çevirirken, komşu sayısını sabit seçerek eş işlem yapılmasını mümkün kılmaktadır. Transdüktif ve endüktif öğrenme yöntemleri ile büyük boyutlu grafiklerde de işlem alt grafik eğitimi ile gerçekleştirilmiştir. Önerilen yöntem farklı veri setlerinde deneyerek yüksek performanslı sonuçlar elde etmiştir. Alt grafikler için önerilen LGCL tabanlı algoritma büyük boyutlu grafiklerin eğitiminde başarı sağlamıştır. Gelecek çalışmalarda ise düğüm sınıflandırma konusunda geliştirilebileceği gözlemlenmiştir [103]. GrapSAGE ise büyük grafiklerde endüktif temsili öğrenmeyi amaçlamaktadır. Temel de düğüm gömmelerinin verimli bir şekilde sağlanmasıyla model kendini göstermektedir. Model farklı veri setlerinde deneylerle gözlemlenmiş ve başarı göstermiştir [104].

### 2.3.2. Örneklem Modülü

Örneklem modülü, GNN temel tasarım evreleri olan üç modülden birisidir. İkinci modül olarak incelenen örneklem modülü, komşu patlaması sorununu çözmek için oluşturulmuştur. Komşu patlaması, komşu katmanlardan toplanan mesajların birikmesi ve birden fazla GNN katmanı içerisinde takipleşmesiyle boyutun derinliklere inmesi olarak tanımlanmaktadır. Bir başka önemli özelliği de her düğüm için komşuluk bilgileri yüksek boyutlara ulaşması sebebi ile biriktirilerek depolanması sonucu işlenememektir. Örneklem modülü, burada yayılımı gerçekleştirir ve işlenmesinin önündeki engeli ortadan kaldırmaktadır. Örneklem modülü temel olarak düğüm örneklem, katman örneklem ve alt grafik örneklem olarak üç başlık altında incelenebilmektedir [7]. Şekil 11'de [7] örneklem modülü ve alt başlıklar halinde örneklem modülünü kapsayan modeller görülmektedir.



Şekil 11: Örneklem modülü

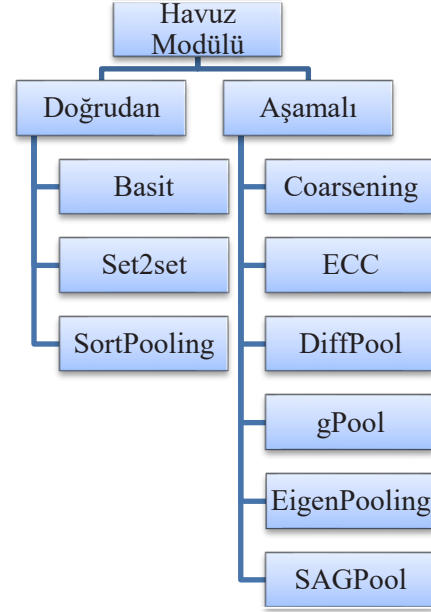
Düğüm örnekleme, düğümlerin boyutlarının küçültülmesi ile gerçekleşmektedir. Bu işlem için en basit yöntem komşu düğüm alt kümelerinden birisinin seçilmesidir. Düğüm örnekleme üç farklı model ile işlenmektedir [7]. GraphSAGE, bu işlemi her bir düğüm için 2-50 düğüm komşuluğunda sabit ve az bir sayı ile sağlamaktadır [7]. VR-GCN, Varyans azaltmalı grafik evrişim ağları olarak tanımlanmaktadır. GCN'de bulunan temel sorunlardan biri olan hesaplanan boyutun özyinelemeli olması sebebiyle sürekli artması ve azaltmaya yönelik çalışmaların başarısız olma noktasını referans almaktadır. Bu duruma karşı olarak komşu boyut örnekleme yapabilen kontrol değişken tabanlı bir algoritma geliştirilmiştir. Geliştirilen algoritma GCN'de azaltma çalışmalarının başarısını garanti etmektedir [105]. Pingsage, önem öncelik temelinde geliştirilmiş bir örneklem modülü modelidir. Sistem, hedef düğümü başlangıç kabul ederek en üstteki normalleştirilmiş ziyaret düğümlerini seçmektedir. Bu sistem bir nevi kıyaslama sistemi olarak tanımlanmaktadır. Teknolojinin gelişmesi yüksek performanslı yol açsa da kullanıcı sayısı çok fazla olan web tabanlı sistemlerde bu büyük bir sorun olarak algılanmaktadır. Bu soruna çözüm oluşturmak için geliştirilen model, grafik yapısı ile birlikte düğüm özelliklerini de içeren düğümlerin gömmelerini oluşturmaktadır. Geçmiş çalışmalara kıyasla daha verimli bir model geliştirmek için yüksek verimli rastgele yürüyüşlere dayanan bir model önerilmiştir. Gömme oluşturmaya yardımcı olması için de MapReduce çıkarım algoritması geliştirilmiştir. Model Pinterest üzerinde bulunan farklı ortamlarda denenmiş ve başarılı olmuştur. Model günümüz itibarı ile en başarılı grafik gömme modeli olmuştur. Ayrıca web tasarım ölçeğinin yeni nesil versiyonlarının önünü açarak öncü olma konumuna geçmektedir [106]. Bir diğer örneklem yöntemi olan katman örnekleme, her katmanda küçük bir düğüm tutulmasıyla gerçekleşmektedir. Bunun sebebi genişlemeyi engellemektir. Katman örnekleme iki farklı model altında incelenmektedir [7]. FastGCN, GCN'lerin temel sorunu olan bellek boyutlama konusunda yeni bir yaklaşım sunmaktadır. Tasarlanan model



eksiklerin eğitimini tamamlarken ayrıca model sonucu çıkarımları da göstermektedir. Yapılan deneyler sonucu, tahminler belirli bir doğrultuda kalırken eğitimin verimli bir başarı gösterdiği gözlemlenmiştir. FastGCN, örnekleme alıcı alanı örnekleme yapmaktadır [107]. Sabit örnekleme aksine, katman bazında örnekleme olması için eğitilebilir ve uygulanabilir bir model geliştirilmiştir. Model öznelinde hızlı grafik gösteriminde kullanımı düşünülmüştür. Model üst katmandan alt katmana doğru örnekleme gerçekleştirirken, farklı üst düğüm paylaşımı ve sabit boyut örnekleme olması sebebi ile alt katmanları örnekleme yapmaktadır. Bu açık varyans azaltmayı sağlayabildiği için eğitim de gelişmektedir. Farklı deneylerde hız konusunda performans gösterilmiş olsa da doğruluğu konusunda karara varılamamıştır [108]. LADIES, katman bazında örnekleme oluşan seyreklik sorunlarına azaltmak için önerilmiş bir modeldir. Kelime anlamı olarak katmana bağlı önem örnekleme olarak tanımlanabilmektedir. Üst katmanda bulunan örneklenmiş düğümleri referans alan model, düğümleri seçerek olasılık hesaplamaktadır. Olasılığı hesaplarırken bipartite grafiğini kullanmaktadır. Bu grafiğin en temel özelliği, köşelerini ayırık ve bağımsız kümeler ayırabilmesidir. Özyinelemeli olarak sabit sayıda katman başına düğüm örnekleme yapmaktadır. Yapılan deneyler sonucu verimli sonuçlar elde edilmiştir [109]. Örnekleme modülünde incelenen son yöntem ise alt grafik örnekleme modülüdür. Alt grafik örnekleme modülünde iki farklı model başlığı altında incelenmektedir. Temel yöntem alt grafiğe örnekleyerek, komşuluk aramasında alt grafikleri kısıtlamaktır [7]. ClusterGCN, GCN'lerde katmanların yükselmesiyle artan maliyetler ve geniş alan gereksinimi sorunlarına çözüm oluşturmak için önerilen bir küme algoritmasıdır. Önerilen model GCN'lerde SGD tabanlı algoritmalar için de gelişim göstermiştir. SGD algoritmaları, stokastik gradyan iniş algoritmaları olarak tanımlanmaktadır. Bir işlevin pürüzsüzlüğü yani sahip olduğu alanlar öznelinde sürekli türevlerin sayısı ile ölçülen özelliği optimize etmek için kullanılan yinelemeli alan bir yöntemdir. Küme-GCN'in çalışma mantığı, adımlarında grafik kümeleme algoritması kullanarak oluşturulan alt grafiklerin ilişkilendirilmesi sonucu düğüm bloklaşması ve mahalle aramasını kısıtlamasıyla oluşmaktadır. Bu sayede belleklerde ve hesaplamalarda verim oluşturmaktadır. Yapılan deneyler sonucu başarı elde etmiş ve yüksek performans göstermiştir [110]. GraphSAINT'te ise alt grafik oluşturma amacıyla düğümler ve kenarlar örnekleme yapmaktadır. Bu yönüyle kümeGCN'den ayrılmaktadır. Yinelemeli grafik tabanlı endüktif öğrenme yöntemidir. Her yinelemede düzgün bir alt grafik oluşturulmaktadır. Yapılan deneyler sonucunda üstün performans göstermiş ve başarısını kanıtlamıştır [111].

### 2.3.3. Havuzlama Modülü

Havuzlama modülü, GNN temel tasarımı için geliştirilen üç modül arasından incelenen sonuncu modüldür. Genel özellikler elde etme amacıyla çoğunlukla evrişim modüllerinden sonra gelmektedir. Bilgisayarlı görüde sıklıkla kullanılmaktadır. Büyük yapı ve karışık düzenli grafiklerin görevleri gerçekleştirilebilmesi için havuzlama katmanında tasarlanmaktadır. Havuzlama katmanı doğrudan ve aşamalı olmak üzere iki başlık altında incelenmektedir. Şekil 12'de havuzlama katmanı modülleri ve modelleri görülmektedir [7].



Şekil 12: Havuz modülü

Doğrudan havuzlama modülleri, okuma işlevleri olarak variant öznelinde isimlendirilmektedir. Farklı düğüm seçme stratejisine sahip olan düğümler, temsili öğrenmeyi doğrudan grafik düzeyinde sağlamaktadır. Üç farklı model üzerinde incelenmektedir. Basit havuzlama yöntemi, farklı modeller tarafından kullanılmaktadır. Model temel olarak maksimum, toplam, ortalama ve dikkat işlevleri üzerinde durmaktadır. Bu işlemler ile düğüm bazında yardımcı olarak grafik gösterimi elde edilmektedir [7]. Set2Set, MPNN modellerinde grafik öğrenme için kullanılmaktadır. Set2set, zincir kuralı kullanarak karmaşık yapılarda ortak olasılık öğrenimini temsil etmek için önerilmektedir. Yapılan deneyler sonucu set2set'in sıralama ve bilinmeyen grafik modellerinin ortak olan olasılıklarını hazırlamada verimli bir tutum sergileyerek yüksek performans göstermiştir. Temsil için ise LSTM tabanlı yöntemler kullanılmaktadır [112]. SortPooling, sıralı havuzlama olarak tanımlanabilmektedir. Tensör formlarında bulunan genel iki zorluğun çözüme ulaştırılması düşünülmüştür. Bu zorluklar, grafik içerisinde kodlanmış bilginin analiz edilerek faydalı şekilde nasıl çıkarılacağı ve bir grafiğin anlamlı ve verimli bir şekilde nasıl sıralanacağı sorunlarıdır. Analiz zorluğu için GCN modeli tasarlanmış ve çekirdek bağlantıları sağlanmıştır. Sıralama zorluğunda ise sıralı havuzlama modeli devreye girerek katman oluşturulmuştur. Karşılaştırmalı grafikler ile yapılan deneylerde başarı sağlamıştır. En önemli husus ise bu model sayesinde gradyan tabanlı öğrenmeyi desteklemesidir [113].

Hiyerarşik havuzlama modülünde ise karmaşık grafiklerin hiyerarşik durumlarının da incelendiği modellerdir. Altı farklı modelden oluşmaktadır. Genel adıyla graph coarsening yani grafik kabalaştırma, ilk sinir ağlarının dayandığı kümeleme yöntemidir. İçerisinde bulunan öz bileşim adımı modeli verimsizleştirmektedir. Model geliştirilerek Graclus adında yeni bir model oluşturulmuştur. Bu model, k-means yöntemini kullanmaktadır. Model, hedefini doğrudan optimize edebilmekte ve yüksek kalitelidir. Deneysel sonuçlarda yüksek başarı elde etmiştir. Bu modelin en büyük başarısı ise daha hızlı olması ve

havuzlama sağlamasıdır. Model, ChebNet ve MoNet'te düğüm çiftlerini eşlemek ve birleştirmek için kullanılmaktadır [114]. ECC yani kenar koşullu evreşim, özyineleme kullanarak altörnekleme ile havuzlama modülünü tasarlamaktadır. Altörnekleme yöntemi Laplacian'ın öz vektörünün (en büyük ve işaret dâhilinde) ikiye bölünmesi ile oluşturulmaktadır [7]. Model temel olarak normal ızgaralardan geliştirilerek rastgele grafikler elde etmektedir. Yapılan deneyler sonucu üstün performans göstermiştir [115]. DiffPool yani fark havuzu, grafiklerde hiyerarşik yapıların temsillerini oluştururken, GNN mimarilerini uç uca birleştirebilmektedir. İşlem gerçekleşirken fark havuzu öncelikle küme ataması öğrenmektedir, düğümler küme ile eşlenerek GNN temel tasarımı için girişi kaba bir şekilde oluşturmaktadır. Yapılan deneyler sonucu üstün performans göstermiş ve son teknolojiye ulaşmıştır [116]. gPool, proje vektörü kullanarak düğümlerde puan öğrenme ve en yüksek puanı seçmektedir. Diffpoll ile olan farkı her katmanda vektör kullanmasıdır. gPool, havuz oluşturma için önerilirken ayrıca biriktirme içinde gUnpool modeli önerilmiştir. GUnpoll modeli, gPool modelinin tersine çalışması olarak da tanımlanabilmektedir. gPool, grafik sınıflandırma ve düğüm sınıflandırma için kullanılmaktadır. Deneyler sonucu yüksek başarı göstermiştir [117]. Eigenpooling, GNN'lerde görev dönüşümü ile başarı sağlamayı amaçlamaktadır. Düğüm özellikleri belirli işlemler dâhilinde işlenerek birçok görevin performansını yükseltmektedir. En bilinen yaygın kullanım ise düğümlerin gösterimlerinin birleştirilmesidir. Model temel olarak havuzlama işlemi gerçekleşirken düğümlerin özelliklerini ve yapılarını Fourier prensibine dayanarak gerçekleştirebilmesidir. Teorik analizde yüksek başarı göstermiş fakat uygulama deneylerinde başarı göstermesine rağmen teorik analiz başarı seviyesine yükselmemiştir. Kısaca bu model, düğüm özellikleriyle birlikte yerel yapının kullanılması amacıyla tasarlanmış ve alt grafik bilgi çıkarımı için kullanılmaktadır [118]. Havuzlama modülünde ve GNN temel tasarımı için incelenen son model olan SAGPool, grafik temsil öğrenmesinde özellik ve topoloji kullanımı sağlayarak öğrenme gerçekleştirme amacıyla önerilmiştir. Evreşim işlemlerinde geliştirilme yapılması ve havuzlama modülleri kullanımının yaygınlaşmasıyla performanslarda olan artıştan etkilenen SAGPool, grafiklerde alt örnekleme işleminde bulunan zorluklara odaklanmaktadır. Yapılan deneyler diğer modeller ile karşılaştırılarak üstün performansa ulaştığı gözlemlenmiştir. SAGPool'ün en dikkat çeken özelliği ise zaman ve mekân karmaşıklığı ile dikkat temelli bir yöntem oluşturarak kullanılması olmuştur [119].

### 3. Grafik Sinir Ağlarının Dezavantajları

GNN'ler temelde Yapay Sinir Ağı (Artificial Neural Network-ANN) ailesine mensup CNN'lerden türetilmiştir. Geliştirilen modeller kendine özgü olmakla beraber hedefe odaklı geliştirilmektedir. Genel olarak GNN'lerin dezavantajlarına bakacak olursak; ölçeklenebilirlik, görülmemiş grafiklerde sınırlı genelleme, dinamik grafiklerin işleme zorluğu, yorumlanabilirlik, standart mimari eksikliği, veri seyrekliği ve gürültüsü ile teoride sınırlılık şeklinde gösterilebilir.

GNN modelleri her ne kadar başarı sağlamış olsa da dezavantajları bulunmaktadır. Bu dezavantajlar model

geliştirmeyi güçlendirmekte ve anlam karmaşasına yol açmaktadır. Gerçek dünya uygulamalarında, topolojiler esnek ve karmaşıktır. Bu durum heterojen ve dinamik grafiklerde zorluk oluşturmaktadır. Zamansal grafikler, grafik tahmini, çizge model geliştirilmesi ile kenar sinyallerinin öznitelikleri bu zorluklara örnek olmaktadır. Dinamik grafiklerde sinyallerin zaman içinde değişmesi, gelişen grafiklerde ise yapının değişmesine bağlı sinyal değişikliği sebebiyle bu durum oluşmaktadır. Dinamik grafiklere GNN modellerin etkin bir çalışma alanı olan trafik ağları örnek olabilirken, gelişen grafiklere sosyal ve bilgisayar ağları örnek verilebilmektedir. Farklı grafik türleri için de bu durum geçerlidir. Geliştirilen model kendine özgü grafikte kolaylıkla işlem yapabilirken farklı bir grafikte zorlanmaktadır. Özel havuzlama operatörü oluşturularak bu zorluk yok edilebilir. Mevcut havuzlama yöntemleri grafik düzeyindeki görevlere odaklanmıştır. Bu durum GNN modellerinin farklı görev ve çoklu görevler üzerindeki etkisini azaltmaktadır. Geliştirilen modeller bu sebeple bir ya da iki görev için geliştirilmiştir. Benzer görevlerde ise bu durum avantaja çevrilebilir. Model derinliği, sadece sinir ağlarının değil derin sinir mimarilerinin de zorlukları arasındadır. Karşılık olarak evreşim katmanı kullanılmasıyla performansa beklenti karşılanamamaktadır. Bu durum derin modellerde etkili olmakla birlikte, günümüzde devam etmektedir. Aynı şekilde büyük ölçekli verilerde performansa etki eden durumlar arasındadır. Havuzlama modellerinin küçük kıyaslama veri kümelerini seçmesi karşılaştırma durumunu azaltmaktadır. Kullanılan veri setleri yaygın olsa da yeterlilik bakımından tartışılmaktadır. Karmaşık ağlar da geliştirilen modellerin önem gösterdiği konulardan olmuştur. GNN'lerin çoğunlukla kenar ve düğüm ile sınırlı olması karmaşık modeller yüksek dereceli yapı olarak adlandırılmaktadır. Bu durum da GNN modellerinin zorluklarındandır. Verilerde bulunan gürültü, GNN modellerinde gürültü giderici katmanlara yönlendirmiştir. Fakat bu durum yine de sorunu tam anlamıyla çözememiştir. İlaç tasarımı ve hastalık teşhisi gibi durumlarda gerçek verilerin kullanılması topolojiyi bozması sebebiyle performansı düşürmektedir. Aynı durum yorumlanabilirlikte de karşımıza çıkmakta ve her model için havuzlama modeli geliştirilmesi önerilmektedir. Gerçek yaşam üzerinde işlenmesi, modelin ne kadar yorumlanabildiğine bağlı olmaktadır. Mevcut havuzlama yöntemlerinin sezgisel tasarımı da modelin ifade gücünü azaltması sebebiyle yorumlanabilirlik ve ifade gücü zorluklarını oluşturmaktadır. Bir diğer sorun olan ölçeklenebilirlik ise, büyük grafiklerle modellenen endüstri uygulamaları için karşılaşılan bir zorluktur. Twitter örneğinde, milyarlarca düğüm bulunmaktadır ve modeller bu denli büyük bağlamlar için uygunsuzdur. Bu durum göz ardı edilerek çözülmüş olsa da ölçekleme sorunu GNN modellerinin en sık karşılaştığı zorluklardan biri olmaktadır. GNN modelleri, her ne kadar bir amaç uğruna konu kapsamında geliştirilse de bu zorluklarla karşılaşabilmektedir. Bu durum GNN'lerin başarısını azaltsa da diğer sinir ağlarına göre performans-verim bakımından en yetenekli sinir ağı olma durumunu sürdürmektedir. Tablo 1'de sinir ağı modellerinin karşılaştırması görülmektedir [120-122].

Tablo 1: Sinir Ağlarının Karşılaştırması

Özellik	ANN	GNN	CNN	RNN
<b>Giriş Verileri</b>	Metin, görüntü, zaman serisi verileri, sayısal değerli veriler ve kategorik veriler.	Düğümün ve kenarların sırasıyla varlıkları ve ilişkilerini temsil ettiği, sosyal ağlar, moleküler grafikler vb. gibi grafik yapıları veriler.	Görüntüler, videolar ve konuşma sinyalleri gibi ızgara yapıları veriler.	Zaman serileri, metin dizileri, konuşma sinyalleri vb. gibi sıralı veriler.
<b>Veri Gösterimi</b>	Satır ve sütunlardaki yapılandırılmış veriler veya özellik vektörleri gibi tabular veya vektörleştirilmiş veriler.	Düğümün ve kenarların sırasıyla varlıkları ve ilişkilerini temsil ettiği, sosyal ağlar, moleküler grafikler vb. gibi grafik yapıları veriler.	Piksel yoğunluklarına veya ızgaraya özgü diğer özelliklere sahip sabit boyutlu ızgaralar.	Kelime dizileri veya zaman adımları gibi zamansal bir düzene sahip veri dizileri.
<b>Topoloji İşleme</b>	Tipik olarak tam bağlı katmanlar olarak tasarlanan sabit giriş-çıkış bağlantısı varsayar.	Dinamik grafik topolojilerini modelleyebilir ve grafik yapısındaki değişikliklere uyum sağlayabilir.	Yerel konvolüsyon işlemleri ile sabit boyutlu alıcı alanlar kullanır.	Zamansal dinamikleri yakalayan giriş verileri içindeki sıralı bağımlılıkları modeller.
<b>Komşuluk Toplama</b>	Sabit boyutlu giriş özellikleri üzerinde, komşuluk toplamayı açık bir şekilde ele almadan çalışır.	Mesaj geçişi veya grafik konvolüsyon işlemleri yoluyla komşu düğümlerden/kenarlardan özellikleri toplar.	Tipik olarak sabit ızgara topolojisi varsayar ve ızgara yapısındaki değişiklikleri açıkça modellemez.	Sıralı kalıpları yakalayan tekrarlayan bağlantılar aracılığıyla zamansal bağımlılıkları modeller.
<b>Özellik Öğrenme</b>	Katman aktivasyonlarına ve ağırlık parametrelerine dayalı olarak girdi özelliklerinin hiyerarşik temsillerini öğrenir.	Düğümün ve kenarların temsillerini grafik yapısına ve düğüm/kenar özelliklerine dayalı özellikler olarak öğrenir.	Verilerdeki yerel örüntülerin hiyerarşik temsillerini öğrenerek uzamsal hiyerarşileri yakalar.	Tekrarlayan bağlantılara ve gizli durumlara dayalı olarak sıralı veri temsillerini öğrenir.
<b>Ölçeklenebilirlik</b>	Büyük ölçekli veri kümelerini işleyebilir ve özellikle optimize edilmiş uygulamalarla tipik olarak ölçeklenebilir.	Dinamik çizge yapıları ve mesaj geçirme işlemleriyle başa çıkma ihtiyacı nedeniyle ölçeklenebilirlik sorunlarından muzdarip olabilir.	Sabit boyutlu ızgaralar üzerinde çalıştıkları ve optimize edilmiş konvolüsyon işlemlerinden yararlandıkları için genellikle ölçeklenebilirdir.	Değişken uzunluktaki dizilerle başa çıkabilir ancak eğitim sırasında kaybolan veya patlayan gradyanlardan muzdarip olabilir.
<b>Yorumlanabilirlik</b>	Karmaşık öğrenilmiş özellikler ve veri yapısının açık bir şekilde temsil edilmemesi nedeniyle yorumlanabilirlikten yoksun olabilir.	Çizge yapısına dayalı olarak düğüm ve kenar özelliklerinin yorumlanabilir gösterimlerini sağlayabilir.	Karmaşık öğrenilmiş özellikler ve açık uzamsal hiyerarşi eksikliği nedeniyle yorumlanabilirlikten yoksun olabilir.	Karmaşık öğrenilmiş özellikler ve gizli durumlar nedeniyle yorumlanabilirlikten yoksun olabilir.
<b>Uygulama</b>	Sınıflandırma, regresyon ve örüntü tanıma gibi tablo halindeki veya vektörleştirilmiş veriler üzerindeki görevler için olarak kullanılmaktadır.	Sosyal ağ analizi, ilaç keşfi, tavsiye sistemleri gibi çizge yapıları veriler üzerindeki görevler için çok uygundur.	Görüntü sınıflandırma, nesne algılama, konuşma tanıma vb. gibi ızgara yapıları veriler üzerindeki görevler için yaygın olarak kullanılmaktadır.	Dil modelleme, konuşma tanıma, zaman serisi tahmini gibi sıralı veriler üzerindeki görevler için yaygın olarak kullanılmaktadır.

#### 4. Sonuç

GNN, her geçen gün kullanım alanı genişleyen ve popülerliği artan bir kavram olmaktadır. Modellerin geliştirilmesi, alana özgü olmaması ve belirli bir alan için geliştirilen modelin farklı alanlarda kullanılması GNN'lerin yaygınlaşmasını sağlamaktadır. Bu çalışmada GNN'ler kapsamlı bir şekilde ele alınmıştır. Öklid dışı uzayda yüksek performans sergileyen GNN'ler hakkında farklı alanlar özelinde uluslararası birçok çalışma yapıldığı görülmektedir. Ancak Türkiye'de gerçekleştirilen çalışmaların az olduğu ve ülkemizde bu ağ türünün popülerlik elde edemediği değerlendirilmektedir. Çalışmada GNN modeli temel alınarak geliştirilen yöntemler ve uygulamalar anlatılmıştır. Ayrıca GNN modellerinin genel eksik yönlerine değinilmiş ve sınır ağları karşılaştırılmıştır. Bu çalışmanın ilk Türkçe kaynaklardan biri olmakla birlikte ardılı olacak çalışmalara katkı sağlayacağı düşünülmektedir.

#### 5. Teşekkür

Bu çalışma Milli Savunma Üniversitesi Atatürk Stratejik Araştırmalar ve Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Siber Güvenlik Tezsiz Yüksek Lisans Programına bağlı olarak yürütülen "Siber Güvenlikte Grafik Sinir Ağları" adlı dönem projesinin bir bölümüdür.

#### 6. Kaynakça

- [1] D.H. Hubel, T.N. Wiesel, "Receptive fields, binocular interaction and functional architecture in the cat's visual cortex." *J Physiol.* 1962 Jan; vol. 160, no. 1, pp. 106–154.2, 1962.
- [2] A. Sperduti, A. Starita, "Supervised neural networks for the classification of structures." in *IEEE Transactions on Neural Networks*, vol. 8, no. 3, pp. 714-735, May 1997
- [3] F. Scarselli, M. Gori, A.C Tsoi, M. Hagenbuchner, G. Monfardini, "The Graph Neural Network Model." *IEEE Transactions on Neural Networks*, vol. 20, no. 1, pp. 61-80. 2019.
- [4] M. Gori, G. Monfardini, F.A. Scarsell, "New Model for Learning in Graph Domains." *Proceedings. 2005 IEEE International Joint Conference on Neural Networks*, vol. 2, pp. 729-734, 2005.
- [5] M. Gori, M. Maggini, L. Sarti, "A recursive neural network model for processing directed acyclic graphs with labeled edges." in *Proceedings of the International Joint Conference on Neural Networks*, Portland (USA), pp. 1351–1355, July 2003.
- [6] Z. Chen, J. Xu, C. Alippi, S.X. Ding, Y. Shardt, T. Peng, C. Yang, C. "Graph neural network-based fault diagnosis: a Review." *ArXiv.* 2021
- [7] J. Zhou, et. Al., "Graph neural networks: A review of methods and applications." *AI Open.* Vol. 1, p.57-81, 2020.
- [8] N.A. Asif, Y. Sarker, R.K. Chakraborty, M.J. Ryan, H. Ahamed, D.K., Saha, F.R. Badal, S.K. Das, F. Ali, S.I Moyeen, R. Islam, Z. Tasneemi "Graph Neural Network: A Comprehensive Review on Non-Euclidean Space." April 27, 2021.
- [9] M.M. Bronstein, J. Bruna, Y. LeCun, A. Szlam, P. Vandergheynst, "Geometric deep learning: going beyond Euclidean data." *IEEE SIG PROC MAG*, 2017
- [10] Z. Wu, S. Pan, F. Chen, G. Long, C. Zhang, P.S. Yu, "A Comprehensive Survey on Graph Neural Networks." *Journal Of Latex Class Files*, Vol. 32, No. 1, pp. 4-24, August 2019
- [11] M. Kampffmeyer, Y. Chen, X. Liang, H. Wang, Y. Zhang, E.R. Xing, "Rethinking Knowledge Graph Propagation for Zero-Shot Learning." *CVPR* 2019
- [12] Z. Hu, Y. Dong, K. Wang, Y. Sun, Y. "Heterogeneous graph transformer." In: *Proceedings of WWW*, 2020, pp. 2704–2710
- [13] C. Zhang, D. Song, C. Huang, A. Swami, N.V. Chawla, "Heterogeneous graph neural network." In: *Proceedings of KDD.* 2019, pp. 793–803.
- [14] M. Schlichtkrull, T.N. Kipf, P. Bloem, R. van den Berg, I. Titov, M. Welling, "Modeling relational data with graph convolutional networks." In: *Proceedings of ESWC.* Springer, 2018, pp. 593–607.
- [15] D. Beck, G. Haffari, T. Cohn, "Graph-to-sequence learning using gated graph neural network." *Proceedings of ACL*, 2018, pp. 273–283.
- [16] Y. Ma, S. Wang, C.C. Aggarwal, D. Yin, J. Tang, J., "Multi-dimensional graph convolutional networks." In: *Proceedings of SDM*, 2019, pp. 657–665.
- [17] Y. Li, R. Yu, C. Shahabi, Y. Liu, "Diffusion convolutional recurrent neural network: Data-driven traffic forecasting." in *Proceedings of the 7th International Conference on Learning Representations*, 2018.
- [18] B. Yu, H. Yin, Z. Zhu, "Spatiotemporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting. *Proceedings of IJCAI.* 2018, pp. 3634–3640.
- [19] A. Jain, A.R. Zamir, S. Savarese, A. Saxena, "Structural-rnn: deep learning on spatio-temporal graphs." In: *Proceedings of CVPR*, 2016, pp. 5308–5317.
- [20] S. Yan, Y. Xiong, and D. Lin, "Spatial temporal graph convolutional networks for skeleton-based action recognition." in *Proc. 32nd AAAI Conf. Artif. Intell.*, 2018, pp. 3634–3640
- [21] F. Manessi, A. Rozza, M. Manzo, "Dynamic graph convolutional networks. *Pattern Recogn.*" *Pattern Recognition Vol. 97* Is. C, Jan 2020.
- [22] A. Pareja, G. Domeniconi, J. Chen, T. Ma, T. Suzumura, H. Kanezashi, T. Kaler, T. Schardl, "Evolvegcn: evolving graph convolutional networks for dynamic graphs." *Proceedings of AAAI* 34, 2020, pp. 5363–5370.
- [23] J. Skarding, B. Gabrys, K. Musial, "Foundations and modelling of dynamic networks using Dynamic Graph Neural Networks: A survey." in *IEEE Access*, vol. 9, pp. 79143-79168, 2021.
- [24] A. Goldenberg, A.X. Zheng, S.E. Fienberg, E.M. Airoldi, "A Survey of Statistical Network Models." *Foundations and Trends® in Machine Learning*, Vol. 2, no. 2, pp. 129–233, February 2010.
- [25] D. Xu, C. Ruan, K. Motwani, E. Korpeoglu, S. Kumar, K. Achan, "Generative Graph Convolutional Network for Growing Graphs." *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, May 2019, pp. 3167– 3171,
- [26] T.N. Kipf, M. Welling, "Variational graph auto-encoders." In: *NIPS Bayesian Deep Learning Workshop.CoRR*, 2016.

- [27] T.N. Kipf, M. Welling, “Semi-supervised classification with graph convolutional networks.” In 5th International Conference on Learning Representations, ICLR 2017, Toulon, France, April 24-26, 2017, Conference Track Proceedings. OpenReview.net, 2017.
- [28] M. Ou, P. Cui, J. Pei, Z. Zhang, W. Zhu, “Asymmetric transitivity preserving graph embedding.” in Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016, pp. 1105–1114.
- [29] X. Shi, Z. Chen, H. Wang, D.Y. Yeung, W.K. Wong, W.C. Woo, “Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting.” *NeurIPS* 2015.
- [30] X. Shi, Z. Gao, L. Lausen, H. Wang, D.Y. Yeung, E.K. Wong, W.C. Woo, “Deep learning for precipitation nowcasting: A benchmark and A new model.” In *Advances in Neural Information Processing Systems 30: Annual Conference on Neural Information Processing, 2017*, pp. 5617–5627.
- [31] Y. Wang, M. Long, J. Wang, Z. Gao, P.S. Yu, “PredRNN: Recurrent neural networks for predictive learning using spatiotemporal LSTMs.” *Advances in Neural Information Processing Systems. 2017*, pp. 880–889.
- [32] Y. Wang, M. Long, J. Wang, Z. Gao, P.S. Yu, “Predrnn++: Towards A resolution of the deep-in-time dilemma in spatiotemporal predictive learning.” In Jennifer G. Dy and Andreas Krause, editors, *Proceedings of the 35th International Conference on Machine Learning. ICML 2018, Stockholmssmassan, Stockholm, Sweden, July 10-15, 2018*, vol. 80 of *Proceedings of Machine Learning Research*, pages 5110–5119. PMLR, 2018.
- [33] J. Xu, H. Xu, B. Ni, X. Yang, T. Darrell, “Video prediction via example guidance.” In Hal Daume III and Aarti Singh, editors, *Proceedings of the 37th International Conference on Machine Learning*, volume 119 of *Proceedings of Machine Learning Research*, PMLR, Jul 2020, pp. 10628–10637.
- [34] O. Ronneberger, P. Fischer, T. Brox, “U-net: Convolutional networks for biomedical image segmentation.” *CoRR*, 2015.
- [35] Y. Aoyagi, N. Murata, H. Sakaino, “Spatio-temporal Predictive Network For Videos With Physical Properties.” *CVPR2021, 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2021, pp. 2268-2278.
- [36] Y. Seo, M. Defferrard, P. Vandergheynst, X. Bresson, “Structured Sequence Modeling with Graph Convolutional Recurrent Networks.” In *Neural Information Processing, Lecture Notes in Computer Science*, 2018, pp. 362–373.
- [37] J. Deng, W. Dong, R. Socher, L. Li, K. Li, F. Li, “Imagenet: A large-scale hierarchical image database.” In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 2009, pp. 248–255.
- [38] M. Monfort, B. Zhou, S.A. Bargal, A. Andonian, T. Yan, K. Ramakrishnan, L.M. Brown, Q. Fan, D. Gutfreund, C. Vondrick, A. Oliva, “Moments in time dataset: one million videos for event understanding.” *CoRR*, 2018.
- [39] B. Zhou, A. Lapedriza, A. Khosla, A. Oliva, A. Torralba, “Places: A 10 million image database for scene recognition.” *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol. 40 no. 6, pp. 1452–1464, 2018.
- [40] P. Goyal, S.R. Chhetri, N.S. Mehrabi, E. Ferrara, A. Canedo, “DynamicGEM: A library for dynamic graph embedding methods.” *arXiv preprint arXiv:1811.10734*, 2018.
- [41] Y. Ma, Z. Guo, Z. Ren, E. Zhao, J. Tang, D. Yin, “Streaming Graph Neural Networks.” *Arxiv*, October 2018.
- [42] S. Kumar, X. Zhang, J. Leskovec, “Predicting dynamic embedding trajectory in temporal interaction networks.” In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2019, pp. 1269–1278.
- [43] R. Trivedi, H. Dai, Y. Wang, L. Song, “Know-evolve: Deep temporal reasoning for dynamic knowledge graphs.” In *Proceedings of the 34th International Conference on Machine Learning, ICML 2017. Sydney, NSW, Australia, 6-11 August 2017*, volume 70 of *Proceedings of Machine Learning Research, PLMR*, 2017, pp. 3462–3471.
- [44] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A.N. Gomez, L. Kaiser, I. Polosukhin, “Attention is All you Need.” In *Advances in Neural Information Processing Systems vol. 30*, pp. 5998–6008, 2017.
- [45] D. Xu, C. Ruan, E. Korpeoglu, S. Kumar, K. Achan, “Inductive representation learning on temporal graphs.” *ArXiv*, 2020.
- [46] Y. Feng, H. You, Z. Zhang, R. Ji, Y. Gao, “Hypergraph neural networks.” In: *Proceedings of AAAI*, vol. 33, pp. 3558–3565. 2018.
- [47] T. Derr Y. Ma J. Tang “Signed graph convolutional networks.” in *2018 IEEE International Conference on Data Mining (ICDM)*, IEEE, 2018, pp. 929–934.
- [48] S. Pan, R. Hu, G. Long, J. Jiang, L. Yao, C. Zhang, “Adversarially regularized graph autoencoder for graph embedding.” in *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence*, 2018. *Proceedings of IJCAI*, 2018. Pp. 2609–2615.
- [49] C. Wang, S. Pan, G. Long, X. Zhu, J. Jiang, “Mgae: marginalized graph autoencoder for graph clustering.” In: *Proceedings of CIKM*. 2017. pp. 889–898.
- [50] J. Park, M. Lee, H.J. Chang, K. Lee, J.Y. Choi, “Symmetric graph convolutional autoencoder for unsupervised graph representation learning.” In: *Proceedings of ICCV*, 2019. pp. 6519–6528.
- [51] G. Cui, J. Zhou, C. Yang, Z. Liu, “Adaptive graph encoder for attributed graph embedding.” In: *Proceedings of KDD*, 2020. pp. 976–985.
- [52] P. Velickovic, W. Fedus, W.L. Hamilton, P. Lio, Y. Bengio, R.D. Hjelm, “Deep Graph Infomax.” *ICLR* 2019.
- [53] F.Y. Sun, J. Hoffmann, V. Verma, J. Tang, “Infograph: unsupervised and semisupervised graph-level representation learning via mutual information maximization.” *Proceedings of ICLR*. 2020.

- [54] K. Hassani, A.H. Khasahmadi, "Contrastive multi-view representation learning on graphs." In: Proceedings of ICML, pp. 4116–4126. 2020.
- [55] K. Xu, C. Li, Y. Tian, T. Sonobe, K. Kawarabayashi, S. Gegelka, "Representation Learning on Graphs with Jumping Knowledge Networks." In: Proceeding of ICML. 2018. pp. 5449–5458.
- [56] J.G. Zilly, R.K. Srivastava, J. Koutnik, J. Schmidhuber, "Recurrent highway networks." In: Proceedings of ICML. 2016, pp. 4189–4198.
- [57] A. Rahimi, T. Cohn, and T. Baldwin, "Semi-supervised User Geolocation via Graph Convolutional Networks." In Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics, vol 1, pp. 2009–2019, 2018.
- [58] T. Pham, T. Tran, D. Phung, S. Venkatesh, "Column networks for collective classification." In: Proceedings of AAAI, 2017. pp. 2485–2491.
- [59] G. Li, M. Muller, A. Thabet, B. Ghanem, "DeepGCNs: Can GCNs Go as Deep as CNNs?." ICCV 2019 In: Proceedings of ICCV, 2019, pp. 9267–9276.
- [60] K. He, X. Zhang, S. Ren, J. Sun, "Deep Residual Learning for Image Recognition." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 770–778.
- [61] K. He, X. Zhang, S. Ren, J. Sun, "Identity Mappings in Deep Residual Networks." European Conference on Computer Vision, ECCV 2016: Computer Vision – ECCV 2016, pp 630–645.
- [62] G. Huang, Z. Liu, L. Van Der Maaten, K.Q. Weinberger, "Densely connected convolutional networks." In: Proceedings of CVPR, 2016, pp. 4700–4708.
- [63] Y. Pei, T. Huang, W.V. Ipenburg, M. Pechenizkiy, "ResGCN: Attention-based Deep Residual Modeling for Anomaly Detection on Attributed Networks." Mach Learn vol. 111, pp. 519–541, 2022.
- [64] R.N. Abirami, P.M.D.R. Vincent, K. Srinivasan, U. Tariq, C.Y. Chang, "Deep CNN and Deep GAN in Computational Visual Perception-Driven Image Analysis." Complexity, cilt 2021, Article ID 5541134, 30 sayfa, 2021.
- [65] W. Maass, T. Natschlager, H. Markram, "Real-time computing without stable states: A new framework for neural computation based on perturbations." Neural Computation, vol. 14, no. 11, pp. 2531–2560, 2002.
- [66] H. Jaeger, The "Echo State." Approach to Analysing and Training Recurrent Neural Networks-With an Erratum Note, German National Research Center for Information Technology GMD Technical Report, vol. 148. p. 13. 2001.
- [67] C. Gallicchio, A. Micheli, "Graph Echo State Networks." The 2010 International Joint Conference on Neural Networks (IJCNN), 2010, pp. 1-8.
- [68] H. Dai, Z. Kozareva, B. Dai, A. Smola, L. Song, "Learning Steady-States of Iterative Algorithms Over Graphs." 35th International Conference on Machine Learning, PMLR 80, 2018, pp. 1106–1114.
- [69] M. Tiezzi, G.M. Dimitri, M. Bianchini, M. Maggini, F. Scarselli, "Inductive–transductive learning with graph neural networks." In: IAPR Workshop on Artificial Neural Networks in Pattern Recognition. Springer. pp. 201–212. 2018.
- [70] K. Cho, B. Van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, Y. Bengio, "Learning phrase representations using rnn encoder–decoder for statistical machine translation." Proceedings of EMNLP, 2014, pp. 1724–1734.
- [71] Y. Gao, D. Glowacka, "Deep Gate Recurrent Neural Network." JMLR: Workshop and Conference Proceedings, 2016, pp.350–365.
- [72] J. Cheng, L. Dong, M. Lapata, "Long short-term memory networks for machine reading." In: Proceedings of EMNLP, 2016, pp. 551–561.
- [73] Y. Li, D. Tarlow, M. Brockschmidt, R. Zemel, "Gated graph sequence neural networks." in Proceedings of the 5th International Conference on Learning Representations, 2016, pp. 273–283.
- [74] D. Beck, G. Haffari, T. Cohn, "Graph-to-sequence learning using gated graph neural network." Proceedings of ACL, 2018, 273–283.
- [75] J Guo, "BackPropagation Through Time." 2013.
- [76] V. Ranganathan, S. Natarajan, "A New Backpropagation Algorithm without Gradient Descent." Arxiv. 2018.
- [77] S. Ruder, "An overview of gradient descent optimization algorithms." Arxiv. 2016.
- [78] K.S. Tai, R. Socher, C.D. Manning, "Improved semantic representations from treestructured long short-term memory networks." In: Proceeding of IJCNLP, 2015, pp. 1556–1566.
- [79] R. Socher, A. Perelygin, J.Y. Wu, J. Chuang, C.D. Manning, A.Y. Ng, C. Potts, "Recursive Deep Models for Semantic Compositionality Over a Sentiment Treebank." Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing, 2103, pp. 1631–1642.
- [80] M. Marelli, L. Bentivogli, M. Baroni, R. Bernardi, S. Menini, R. Zamparelli, "SemEval-2014 Task 1: Evaluation of Compositional Distributional Semantic Models on Full Sentences through Semantic Relatedness and Textual Entailment." Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014), 2014, pp. 1–8.
- [81] N. Peng, H. Poon, C. Quirk, K. Toutanova, W.T. Yih, "Crosssentence N-ary relation extraction with graph LSTMs." Trans. Assoc. Comput. Linguistics, vol. 5, pp. 101–115, Dec. 2017.
- [82] X. Liang, X. Shen, J. Feng, L. Lin, S. Yan, "Semantic object parsing with graph lstm." In: Proceedings of ECCV, 2016, pp. 125–143.
- [83] V. Zayats, M. Ostendorf, "Conversation modeling on reddit using a graph-structured LSTM." Trans. Assoc. Comput. Linguistics, TACL. vol. 6, pp. 121–132, 2018.
- [84] Y. Zhang, Q. Liu, L. Song, "Sentence-state LSTM for text representation." In: Proceedings of ACL. Vol. 1, pp. 317–327, 2018.
- [85] Z. Huang, X. Xu, K. Yu, "Bidirectional LSTM-CRF Models for Sequence Tagging." ArXiv, 2015.
- [86] Y. Shulman, "SimPool: Towards Topology Based Graph Pooling with Structural Similarity Features."

- ArXiv. 2020.
- [87] S. Mallat, “A Wavelet Tour of Signal Processing.” Elsevier. 1999.
- [88] J. Bruna, W. Zaremba, A. Szlam, Y. LeCun, “Spectral networks and locally connected networks on graphs.” in 2nd Int. Conf. Learn. Repres., Banff, AB, Canada 2014.
- [89] M. Henaff, J. Bruna, Y. Lecun, “Deep Convolutional Networks on Graph-Structured Data.” ArXiv. 2015.
- [90] D.K. Hammond, P. Vandergheynst, R. Gribonval, “Wavelets on graphs via spectral graph theory.” Appl. Comput. Harmon. Anal. Vol. 30, pp. 129–150, 2011.
- [91] H.P. Matic, P. Frossard, “Graph Laplacian mixture model.” Arxiv, 2020.
- [92] M. Defferrard, X. Bresson, P. Vandergheynst, “Convolutional Neural Networks on Graphs with Fast Localized Spectral Filtering.” NeurIPS, 2016, pp. 3844–3852.
- [93] B. Li, S. Tang, H. Yu, “Better Approximations of High Dimensional Smooth Functions by Deep Neural Networks with Rectified Power Units.” Communications in Computational Physics vol. 27, no. 2, pp. 379–411, 2020.
- [94] S. Tang, B. Li, H. Yu, “ChebNet: Efficient and Stable Constructions of Deep Neural Networks with Rectified Power Units using Chebyshev Approximations.” ArXiv, 2019.
- [95] R. Li S. Wang F. Zhu J. Huang “Adaptive graph convolutional neural networks.” In Thirty-Second AAAI Conference on Artificial Intelligence, 2018, pp. 2546-3553.
- [96] Y. Wang, Y. Sun, Z. Liu, E. Sarma, M.M. Bronstein, J.M. Solomon, “Dynamic Graph CNN for Learning on Point Clouds.” ACM Transactions on Graphics, Vol. 38, no. 146, pp 1–12, 2019.
- [97] R. Li S. Wang F. Zhu J. Huang, “Adaptive graph convolutional neural networks.” In Thirty-Second AAAI Conference on Artificial Intelligence, 2018, pp. 2546-3553.
- [98] C. Zhuang Q. Ma, “Dual graph convolutional networks for graphbased semi-supervised classification.” in Proc. Web Conf., 2018, pp. 499–508.
- [99] B. Xu, H. Shen, Q. Cao, Y. Qiu, X. Cheng, “Graph wavelet neural network.” In: Proceedings of ICLR. 2019.
- [100] D.K. Duvenaud, D. Maclaurin, J. Aguileraiparraguirre, R. Gomezbombarelli, T.D. Hirzel, A. Aspurguzik, R.P. Adams, “Convolutional networks on graphs for learning molecular fingerprints.” In: Proceedings of NIPS, Neural Inf. Process. Syst., 2015, pp. 2224–2232.
- [101] J. Atwood, D. Towsley, “Diffusion-Convolutional Neural Networks.” 29th Conference on Neural Information Processing Systems (NIPS 2016), 2016, pp. 1993–2001.
- [102] M. Niepert, M. Ahmed, K. Kutzkov, “Learning convolutional neural networks for graphs.” in Proc. Int. Conf. Mach. Learn., 2016, pp. 2014– 2023.
- [103] H. Gao, Z. Wang S. Ji “Large-scale learnable graph convolutional networks.” in Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, ACM, 2018, 1416–1424.
- [104] W.L. Hamilton, R. Ying, L. Leskovec, “Inductive representation learning on large graphs.” In Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS’17). 2017, pp. 1025–1035.
- [105] J. Chen, J. Zhu, L. Song, “Stochastic Training of Graph Convolutional Networks with Variance Reduction” Proceedings of the 35 th International Conference on Machine Learning, Stockholm, Sweden, PMLR 80, 2018.
- [106] R. Ying, R. He, K. Chen, P. Eksombatchai, W.L. Hamilton, J. Leskovec, “Graph convolutional neural networks for web-scale recommender systems.” in Proc. 24th ACM SIGKDD Int. Conf. Knowl. Discovery Data Mining. 2018. Pp. 974–983.
- [107] J. Chen, T. Ma, C. Xiao, “FastGCN: Fast Learning with Graph Convolutional Networks via Importance Sampling.” ICLR, 2018.
- [108] W. Huang, T. Zhang, Y. Rong, J. Huang, “Adaptive sampling towards fast graph representation learning.” Proceedings of NeurIPS, 2018, pp. 4558–4567.
- [109] D. Zou, Z. Hu, Y. Wang, S. Jiang, Y. Sun, Q. Gu, “Layer-dependent importance sampling for training deep and large graph convolutional networks.” In: Proceedings of NeurIPS, 2019, pp. 11249–11259.
- [110] W.L. Chiang, X. Liu, S. Si, Y. Li, S. Bengio, C.J. Hsieh, “Cluster-GCN: An Efficient Algorithm for Training Deep and Large Graph Convolutional Networks.” In The 25th ACM SIGKDD Conference on Knowledge Discovery and Data Mining (KDD ’19), 2019, pp. 257–266.
- [111] H. Zeng, H. Zhou, A. Srivastava, R. Kannan, V.K. Prasanna, “Graphsaint: graph sampling based inductive learning method” In: Proceedings of ICLR. 2020.
- [112] O. Vinyals, S. Bengio, M. Kudlur, “Order Matters: Sequence to Sequence for Sets.” ArXiv. 2015.
- [113] M. Zhang, Z. Cui, M. Neumann, Y. Chen, A<sup>n</sup> End-to-End Deep Learning Architecture for Graph Classification” AAAI’18/IAAI’18/ EAAI’18: Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence and Thirtieth Innovative Applications of Artificial Intelligence Conference and Eighth AAAI Symposium on Educational Advances in Artificial Intelligence, 2018, no. 544, pp. 4438–4445.
- [114] I.S. Dhillon, Y. Guan, B. Kulis, “Weighted graph cuts without eigenvectors amultilevel approach.” IEEE TPAMI vol. 29, pp. 1944–1957, 2007.
- [115] M. Simonovsky, N. Komodakis, “Dynamic edge-conditioned filters in convolutional neural networks on graphs.” In: Proceedings of CVPR, 2017. pp. 3693–3702.
- [116] Z. Ying, J. You, C. Morris, X. Ren, W. Hamilton, J. Leskovec, “Hierarchical graph representation learning with differentiable pooling.” Advances in neural information processing systems, NeurIPS, 2018, pp. 4805-4815.
- [117] H. Gao, S. Ji, “Graph u-nets.” In: Proceedings of ICML, 2019, pp. 2083–2092.
- [118] Y. Ma, S. Wang, C.C. Aggarwal, J. Tang, “Graph

- Convolutional Networks with EigenPooling.” In: Proceedings of KDD, 2019, pp. 723–731.
- [119] J. Lee, I. Lee, J. Kang, “Self-attention graph pooling.” ICML, 2019, pp. 3734–3743.
- [120] L., Waikhom, R., Patgiri, “Graph Neural Networks: Methods, Applications, and Opportunities” Arxiv, 2021.
- [121] C., Liu, Y., Zhan, C., Li, B., Du, J., Wu, W., Hu, T., Liu, & D., Tao, “Graph Pooling for Graph Neural Networks: Progress, Challenges, and Opportunities,” ArXiv, 2022, abs/2204.07321.
- [122] S. Georgousis, M. P. Kenning and X. Xie, "Graph Deep Learning: State of the Art and Challenges," in IEEE Access, vol. 9, pp. 22106-22140, 2021, doi: 10.1109/ACCESS.2021.3055280.

## Özgeçmişler



**Hamza Talha Gümüş**, lisans eğitimini Kırıkkale Üniversitesi Elektrik Elektronik Mühendisliği bölümünde tamamladı. Milli Savunma Üniversitesi Siber Güvenlik (Tezsiz) Yüksek Lisans programından Şubat 2023 tarihinde mezun oldu. Adalet ön lisans, Web Tasarım ve Kodlama ön lisans ve Bilgisayar Programcılığı ön lisans programlarından mezuniyeti bulunmaktadır. Ayrıca Coğrafi Bilgi Sistemleri ön lisans, Yönetim Bilişim Sistemleri Lisans ve Siyaset Bilimi ve Uluslararası İlişkiler Lisans programlarına devam etmektedir. Türkiye Hayat ve Emeklilik A.Ş.’de Bilgi Güvenliği Uzman Yardımcısı olarak çalışmaktadır.



**Can Eyüpoğlu**, lisans eğitimini 2012 yılında İstanbul Kültür Üniversitesi Bilgisayar Mühendisliği Bölümü’nde tamamlamıştır. Yüksek lisans ve doktora derecelerini 2014 ve 2018 yıllarında İstanbul Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda almıştır. 2021 yılında Bilgisayar Bilimleri ve Mühendisliği Bilim alanında Doçent unvanı almıştır. Halen Milli Savunma Üniversitesi Hava Harp Okulu Bilgisayar Mühendisliği Bölümü’nde Doçent Bölüm Başkanı olarak görev yapmaktadır. Araştırma alanları arasında yapay zeka, makine öğrenmesi, veri mahremiyeti ve görüntü işleme bulunmaktadır.



# Makine Öğrenimi Tabanlı Kısa Vadeli Fotovoltaik Çıkış Gücü Tahminlemesi Machine Learning Based Short Term Photovoltaic Output Power Prediction

<sup>1</sup>Berrin ERYILMAZ<sup>1</sup>, <sup>2</sup>Heybet KILIÇ<sup>2\*</sup>, <sup>3</sup>Fatih Koçyiğit<sup>3</sup>

<sup>1</sup>Dicle Üniversitesi Fen Bilimleri Enstitüsü, Yenilenebilir Enerji Kaynakları Ana Bilim Dalı,  
Diyarbakır, Türkiye

<sup>1</sup>[berrin.eryilmaz@gmail.com](mailto:berrin.eryilmaz@gmail.com), <sup>2</sup>[heybet.kilic@dicle.edu.tr](mailto:heybet.kilic@dicle.edu.tr), <sup>3</sup>[fatihkocyyigit21@hotmail.com](mailto:fatihkocyyigit21@hotmail.com)

## Öz

Fosil yakıt kaynaklarının sınırlı olması ve çevreye zararlı etkilerinin olması nedeniyle fotovoltaik (PV) sistemlerinin kurulmasına olan ihtiyaç giderek artmaktadır. PV sistemlerinin hava koşullarına bağımlılığı PV güç çıkışlarında kararsızlığa, gerilim, frekans dalgalanmaları ve kesintilere neden olmaktadır. Bu durum ise PV enerjisinin şebekelere entegrasyonunu zorlaştırmaktadır. Bu yüzden PV güç çıkışını önceden kısa süreli tahmin etmek karşılaşılan zorlukların üstesinden gelmek için çok önemlidir. Bu çalışmanın amacı, literatürde makine öğrenimi modellerinde yaygın olan aşırı öğrenme ve yavaş öğrenme dezavantajlarının üstesinden gelerek daha hızlı öğrenen ve yüksek doğrulukta performans gösteren Gürbüz Düzenlenmiş Rastgele Vektör Fonksiyon Bağlantı (GD-RVFL) ağı modelini kısa vadeli PV çıkış gücünü tahmin etmede kullanmak ve bu kapsamda önerilen modeli 10 farklı makine öğrenimi yöntemi olan Bayesian Ridge Regressor (BRR), Linear Regressor (LR), Gaussian Process Regressor (GPR), Support Vector Machine (SVM), Extreme Learning Machine (ELM), Yapay Sinir Ağı (YSA), Gradient Boosting Regressor (GBR), Random Forest Regressor (RFR), Lasso Regressor (LAR) ve Ridge Regressor (RR) yöntemleri ile karşılaştırılarak modellerinin performansını değerlendirmektir. Yapılan bu karşılaştırma sonucunda GD-RVFL'nin etkinliği diğer 10 makine öğrenimi modeline göre önemli ölçüde daha iyi performans gösterdiği görülmüştür.

**Anahtar kelimeler:** GD-RVFLN, KKA, Makine öğrenimi, PV çıkış gücü tahmini

## Abstract

The need for the installation of photovoltaic (PV) systems is increasing due to the limited resources of fossil fuels and their harmful effects on the environment. The dependence of PV systems on weather conditions causes instability, voltage, frequency fluctuations and interruptions in PV power outputs. This situation complicates the integration of PV energy into the grids. Therefore, short-term forecasting of PV power output is crucial to overcoming the challenges. The aim of this study is to use the Robust Arranged Random Vector Function Interconnect (GD-RVFL) network model, which learns faster and performs with high accuracy, overcoming the excessive learning and slow learning disadvantages that are common in machine learning models in the literature, to predict the short-term PV output power and in this context. Bayesian Ridge Regressor (BRR), Linear Regressor (LR), Gaussian Process Regressor (GPR), Support Vector Machine (SVM), Extreme

Learning Machine (ELM), Artificial Neural Network (ANN), Gradient To evaluate the performance of the models by comparing them with the Boosting Regressor (GBR), Random Forest Regressor (RFR), Lasso Regressor (LAR) and Ridge Regressor (RR) methods. As a result of this comparison, it was seen that the efficiency of GD-RVFL significantly outperformed the other 10 machine learning models.

**Keywords:** RR-RVFLN, CCA, Machine Learning PV output prediction


## 1. Giriş

Sanayinin gelişimi, hızlı kentleşme ve teknolojik büyüme enerjeye olan talebi gün geçtikçe daha önemli hale getirmektedir. Bu sürekli artan enerji talebini karşılamak için elektrik üretimi ve dağıtımına ihtiyaç vardır. Bilindiği gibi enerji üretimi yenilenebilir enerji kaynakları (YEK) (güneş, rüzgâr, su, biyokütle ve jeotermal gibi kaynaklar) ve yenilenebilir olmayan fosil enerji kaynakları (doğal gaz, kömür, nükleer ve petrol) tarafından üretilmektedir. Ancak fosil enerji kaynaklarının yapılarında hidrokarbon ve yüksek oranda karbon bulundurmaları atmosfere tehlikeli sera gazı (CO<sub>2</sub>) yayımlarına yol açmakta bu durum ise çevre ve insan sağlığı için büyük risk oluşturmaktadır. Nitekim, Dünya Meteoroloji Örgütü'nün (DMÖ) "Küresel İklimin Durumu 2020 raporu", sera gazı konsantrasyonlarının, son on yılda emsalsiz artan küresel sıcaklığın sonucunda kara ve okyanus sıcaklarının yükselmesine, buzulların erimesine ve aşırı hava olaylarına (sel baskınları, yoğun kar yağışları, şiddetli fırtınalar ve kuraklıklar gibi) neden olduğunu belgelemektedir [1]. Fosil enerji kaynaklarının çevreye olan tehlikeli etkileri ve gittikçe tükenmesi nedeniyle bu enerji kaynaklarına sınırlandırmalar getirilmiş, sürdürülebilirliği ve çevreye olan zararsız etkisi nedeniyle yenilenebilir enerji kaynaklarına dünya çapında bir yönelim söz konusu olmuş ve yenilenebilir enerji alanında çok büyük yatırımlar yapılmıştır. Dünya Enerji Konseyi (DEK) (World Energy Council)'nin 2021 Yenilenebilir Enerji Küresel Durum Raporuna göre, Yenilenebilir enerji kaynaklarına yapılan küresel yatırımlar 2020'de toplam 303,5 milyar ABD dolarına ulaşmıştır. Gelişmekte olan ülkeler ise yenilenebilir enerji yatırımında 153,4 milyar ABD dolarına ulaşmıştır. Yapılan bu yatırımların 148,6 milyar ABD doları güneş ve rüzgâr enerjisine yapılarak yenilenebilir enerji yatırımlarının neredeyse yarısını oluşturmuştur [2]. Uluslararası Enerji Ajansının (UEA) Dünya Enerji Yatırımı 2022'e göre, yenilenebilir enerji kaynakları, toplam enerji sektörü yatırımının %80'inden fazlasını oluşturduğunu, güneş enerjisi,

bu yatırımların neredeyse yarısını oluşturduğunu ve 2022'de yenilenebilir enerji kaynaklarına yatırımın 1,4 trilyon ABD dolarını aşması beklendiğini raporlamıştır [3]. Dahası DEK'e göre; elektrik enerjisi talebi 2060 yılına kadar iki katına çıkacağı ve elektrik enerjisi üretimi yenilenebilir kaynaklardan üretilmesi için uygun politikalar çıkarılarak önemli yatırımlar yapılacağı, yapılacak bu yatırımların da liderliğini güneş ve rüzgâr enerjilerinin yapacağı tahmin edilmektedir [2]. Güneş ve rüzgâr enerjisinde yaşanan ya da olumlu yatırım artışları daha fazla enerji tesisinin kurulmasını artırmakta bu da bu tesislerin merkezi şebekelere entegrasyonunu gerektirmektedir.

Ancak, PV santrallerin hava koşullarına bağımlılığı nedeniyle panellerde elektrik elde edimi ve dağıtımı zor olmaktadır. Gün boyunca güneş ışınımı yoğunluğunun istikrarsız doğası, PV güç üretiminde dalgalanmalara neden olmaktadır [4]. PV güç üretimindeki beklenmedik bu dalgalanmalar, santrallerin ya aşırı elektrik üretmesine ya da hiç elektrik üretmemesinden dolayı şirketlerin ek elektrik satın almasına neden olabilmektedir [5]. Sonuç olarak, PV gücünün yüksek entegrasyonu, yaşanan dalgalanmalar (aşırı elektrik üretimi veya elektrik üretilmemesi) nedeniyle mevcut şebeke sistemlerinin çalışması için birçok yeni sorunları da beraberinde getirmektedir [6]. Bu sorunlar, PV güç kaynağının meteorolojik koşullara duyarlılığını, yüksek kurulum maliyetlerini ve elektrik üretiminin kesintisini içerir [7]. Yaşanan bu sorunlara PV güç santrallerinden üretilen enerjinin depolanması bir çözüm olarak görülürken, sistemi önceden kontrol için mevcut enerjinin kesin bir tahmini gerekmektedir [4]. Bu duruma etkili bir çözüm ise PV güç çıkışı için doğru bir tahmin modeli bulmaktır.

Bu çalışmanın amacı makine öğrenimi ile PV çıkış gücünü kısa dönemli (10 dakika) olarak tahmin etmektir. Çıkış gücü tahmin etmek için literatürde birçok çalışma vardır. Bu çalışmada amaç literatürde kullanılan yöntemlerin geç öğrenme, aşırı öğrenme gibi iki temel dezavantajının üstesinden gelip tahmini daha kolay ve yüksek doğrulukta yapmaktır. Bu çalışmada giriş parametrelerini azaltmak için her PV santralde ulaşılabilen güneş ışınımı, güneşlenme süresi, rüzgâr hızı, ortam sıcaklığı, panel yüzey sıcaklığı, bulutluluk oranı, DC akım, gerilim ve bağıl nem 9 özellik(parametre) kullanılarak hava tipi modellenmiş ve 4 hava tipi modeli oluşturulmuştur. Bu hava tipi modelleri de kullanılarak GD-RVFLN yardımıyla PV çıkış gücü tahmini yapılmaya çalışılmıştır.



Şekil 3: Güneş ölçüm istasyonunun yandan görünümü

Güneş enerjisinden yararlanan sistemler, yatırımcı tarafından uygun maliyetli olarak kabul edilmeyen yüksek bir ilk yatırım maliyetine sahip olabilmektedir. Bu amaçla, bölgedeki güneş enerjisi projelerine para yatırmadan önce bölgenin güneş enerjisi potansiyelini değerlendirmek çok önemlidir. Dünya çapında güneş enerjisi ile ilgili temel bilgileri bilmek, herhangi bir bölgedeki güneş enerjisi uygulamaları için araştırma, planlama ve tasarım konusunda son derece yardımcı olacaktır.

Türkiye'de güneş ışınım verileri meteorolojik genel müdürlüğü (MGM) tarafından ölçülmektedir. Bu verilerin ölçümü için MGM illerde ölçüm istasyonları kurmuştur. Ekonomik ya da MGM yapısındaki değişikliklerden ötürü son yıllarda Türkiye'deki bazı illerde güneş ışınımı ile ilgili ölçüm istasyonların veri sağlamamaktadır [41]. Bu illerden bir tanesi olan Diyarbakır'da 2009 yılından itibaren bu veriler sağlanmaktadır. Belirtilen nedenlerden ötürü şekil 3'te gösterilen Dicle Üniversitesi bünyesindeki ölçüm istasyonu Diyarbakır iline ait güneş ışınım verileri ölçen tek istasyon konumundadır. Sonuç olarak Diyarbakır ve çevresinde ışınım verilerini sağlamasından ötürü şekil 3'te gösterilmiş bahsi geçen ölçüm istasyonu hem akademik araştırmalar hem de ticari uygulamalar açısından büyük önem taşımaktadır.

Bu çalışmada, Türkiye'de bulunan ve konum itibariyle güneş enerjisi açısından oldukça yüksek bir potansiyele sahip olan Diyarbakır iline ait güneş enerjisi verileri analiz edilmiştir. Daha sonra ilin ışınım değerleri ve güneşlenme süreleri güneş enerjisi açısından enerji üretimine elverişli olup olmadığı incelenmiştir [5]. Bu çalışmadaki diğer bir amaç ise Diyarbakır ili için güneşlenme süresi ve global ışınım verilerini elde ederek hem ticari çalışmalara hem de literatüre katkı sunmaktır.

### 1.1. PV Çıkış Gücü Tahmin Yaklaşımları

PV güç çıkışı için doğrudan ve dolaylı olmak üzere iki ana tahmin yaklaşımı vardır [8, 9, 10, 11]. Doğrudan tahmin yöntemleri [12-13], PV güç çıkışını tahmin etmek için genellikle meteorolojik ve PV çıkış gücü gibi geçmiş verileri kullanır. Bu yöntem için kullanılan teknikler [14-17], YSA, hibrit YSA, çok katmanlı algılayıcı sinir ağı (MLPNN), tek örtülü katmanlı ileri beslemeli sinir ağı (single shrouded layer feed-forward neural network) (SLFN), tekrarlayan sinir ağı (RNN), ileri beslemeli sinir ağı (FFNN), Geri Beslemeli sinir ağıdır (FBNN), aşırı öğrenme makine (ELM) ve destek vektör regresyonu (SVR) gibi yöntemlerdir. Doğrudan yöntemlerin dolaylı yöntemlere kıyasla gün öncesi PV güç çıkışı tahmini açısından daha iyi sonuç verdiği kanıtlanmıştır [18]. Dolaylı tahmin yöntemleri [8, 19, 20] güneş radyasyonu, ortam sıcaklığı gibi meteorolojik parametreleri ve çevresel parametreleri matematiksel modeller kullanarak tahmin eder. Dolaylı tahmin yöntemlerindeki sonraki adım eşdeğer diyot modeli, basit verimlilik modeli ve Sandia modeli gibi modelleri kullanarak PV çıkış gücü tahmin etmektir. Dolaylı tahmin için kullanılan teknikler [21-22] Sayısal Hava Tahmini (SHT), uydu gökyüzü görüntüsü, hibrit yapay sinir ağı ve istatistiksel tabanlı yöntemlerdir.

Yukarıda isimleri verilen modeller PV güç çıkışı tahminlemede faydalı olsa da her modelin kendi zorlukları vardır. Değinen bu modellerden SVR modeli [23-25] hem büyük hesaplama sürecine ihtiyaç duyar hem de büyük veri kullanımı durumlarına yanıt vermez. Öte yandan, YSA modeli [26-27], iyi bir performans göstermesi için kullanıcıların ağ topolojisini ve parametreleri belirlemesine ihtiyaç duyar.

Kıscacası tahminleme için kullanılan modeller doğru kullanılmadığı takdirde iyi sonuçlar vermeyebilir. Bu yüzden tahminleme için iyi bir model seçimi gerekmektedir. Literatürde PV çıkış gücü tahminlemesi için oldukça fazla sayıda çalışma vardır. Bu kapsamda kısa vadeli PV çıkış gücü tahmini için yapılan bilimsel çalışmaların bir kısmı aşağıda verilmiştir.

Zhou ve ark. [18], PV çıkış gücünü tahmin etmek için aşırı öğrenme makinesi (ELM), genetik algoritma (GA) ve özelleştirilmiş Benzer Gün Analizi (BGA) tabanlı bir hibrit model (BGA-GA-ELM) geliştirilmiştir. BGA için beş meteorolojik girdiye dayalı olarak farklı günler arasındaki benzerliği ölçmek için Pearson Korelasyon katsayısı kullanılmış. Yüksek korelasyona sahip parametreler ELM için eğitim seti olarak seçilmiştir. Daha sonra tahmin doğruluğunu iyileştirmek için ELM' de gizli önyargı ve girdi ağırlığının optimal değerleri GA tarafından belirlenmiştir. Önerilen tahmin modelinin performansı, regresyon katsayısı (R2), ortalama mutlak hata (OMH) ve normalleştirilmiş ortalama karekök hata (nOKH) ile değerlendirilmiştir. Sonuçlar, BGA-GA-ELM modelinin gün öncesi PV çıkış gücü tahmininde daha yüksek doğruluk ve kararlılığa sahip olduğunu göstermiştir. VanDeventer ve ark. [28], kısa vadeli PV gücü tahmini için Genetik algoritmaya dayalı bir support vektör makinesi (GASVM) modeli geliştirdiler. GASVM modelinde, başlangıçta SVM sınıflandırıcı olarak geçmiş hava durumu verileri sınıflandırılmış, daha sonra genel uyum tekniği kullanılarak genetik algoritma (GA) tarafından optimize edilmiştir. Önerilen GASVM modelinin tahmin doğruluğu, OKH ve OMYH temelinde değerlendirilmiştir. Deneysel sonuçlar, önerilen GASVM modelinin, OKH değerinde yaklaşık 669.624W ve OMYH hatasının %98,76'lık farkla geleneksel SVM modelinden daha iyi performans gösterdiğini göstermiştir. Massaoui ve ark. [29], Bayesian Ridge Regresyon (BRR) modelini, Sürekli Dalgacık Dönüşümünü (SDD) ve Gradient Boosting kategorik özelliklerle (Catboost) birleştiren bir BBR-SDD-Catboost hibrit modelini önermişlerdir. Bu modelde, en alakalı özellikleri seçmek için bir Bayesian Ridge Regresyon modeli kullanılır. Ardından, SSD ayrıştırma tekniği seçilen özellikleri bir zaman-frekans alanına dönüştürür. Catboost modeli, bir gün öncesi için tahmin çıktısını üretir. Son olarak sonuçlar, ters SSD kullanılarak çıkarılır. Hibrit model, OKH=3.81 ile kısa vadeli 24 saat ilerisi tahmininde doğru sonuçlar elde etmiştir. Gutiérrez ve ark. [30], fotovoltaik güç üretimini tahmin etmek için Makine Öğrenimi ve Yapay Zekâ yöntemleriyle uyumlu tekniklerden dört tahmin modeli önermiştir: K-En Yakın Komşular (KNN), Doğrusal Regresyon (LR), Yapay Sinir Ağları (ANN) ve Destek Vektör Makineleri (SVM). Elde edilen sonuçlar, dört yöntemin yeterli fotovoltaik enerji üretimi tahminleri ürettiğini ancak OKH ve OMH'ye göre en iyi tahmin YSA tahmin modeline ait olduğunu göstermiştir. Afzal ve ark. [31], termal faktörlere dayalı enerji tesisin üretimini tahmin etmek için Ridge, Lineer regresör (LR) ve destek vektör regresörü (SVR) algoritmalarını kullanmışlardır. Kombine çevrim santralini enerji çıktı verileri egzoz vakumu, ortam sıcaklığı, bağıl nem ve ortam basıncı gibi termal girdi değişkenlerinin bir faktörü olarak toplanmıştır. İlk olarak, Ridge algoritması tabanlı modelleme ayrıntılı olarak gerçekleştirilmiş ve ardından SVR (LR) olarak adlandırılan SVR tabanlı LR, SVR tabanlı radyal tabanlı fonksiyon—SVR (RBF) ve SVR tabanlı polinom regresyon SVR (Poly.) algoritmalar uygulanmıştır. Enerji çıkış verilerinin modellenmesinden, diğer algoritmalara kıyasla çok yakın tahminler sağlamada SVR'nin (RBF) en uygun olduğu

görülmüştür. Elde edilen SVR (RBF) eğitimi  $R^2 = 0,98$  iken diğer tüm eğitimler 0,9-0,92 olmuştur. Khalyasmaa ve ark. [32], meteorolojik verilere dayalı fotovoltaik enerji santrallerinin üretim tahmin için Random Forest regresörü, Gradient Boosting Regressor, Lineer Regresyon ve Karar Ağaçları regresyonu dahil olmak üzere farklı makine öğrenimi algoritmalarının uzaktan elde edilen verilere uygulanmasını incelemiştir. Hiper parametre optimizasyonu ve algoritmaların ardışık düzeni ile ilgili hesaplama deneylerine dayanarak, PV santral enerji çıktısı tahmin sisteminin optimal yapısı ve ayarları, algoritmaların her biri için uygulama kısıtlamaları ile birlikte belirlenip uygulanmıştır. Bu hesaplamalar sonucu performans iyileştirme Lineer Regresyon için %55'ten %94'e ve karar ağaçları için %88'den %91'e, topluluk algoritmalarının doğruluğu ise, Random Forest regresörü, Gradient Boosting Regressor gibi, önemli ölçüde değişmediği görülmüştür. Chahboun ve Maaroufi [33], Fotovoltaik gücün saatlik tahmini için birkaç güncel makine öğrenme algoritmasının performansı karşılaştırmışlardır. Kullanılan yöntemler, bayesian regularized sinir ağları, k-nearest neighbors, gradient boosting, random forest, support vector regresyon ve multivariate adaptive regression olmuştur. Daha sonra bu yöntemler R2, OKH ve OMH ile değerlendirilmiştir. Sonuçlar, bayesian regularized sinir ağlarının en iyi tahmin doğruluğuna  $R^2=99,99\%$  sahip olduğunu göstermiştir. Bu çalışmada önerilen yöntem, bir tek örtülü katmanlı ileri beslemeli sinir ağı (single shrouded layer feed-forward neural network) (SLFN) türü olan Rastgele Vektör Fonksiyonel Bağlantı(link) Ağ (Network) olarak adlandırılan RVFLN'nin gerekli algoritmalara geliştirmiş hali olan Robust Regularized Random Vector Functional Link Network (GD-RVFLN) modelidir. Yapılan diğer literatür araştırmalarında RVFLN modelini kullanarak PV gücü tahmini yapan iki çalışmaya rastlanılmıştır. Arpit ve Tripathi [34], PV gücünü tahmin etmek için tek örtülü katmanlı ileri beslemeli sinir ağı (single shrouded layer feed-forward neural network) (SLFN), rastgele ağırlıklı tek örtülü ileri beslemeli sinir ağı (random weight single shrouded layer feed-forward neural network) (RWSLNF) ve rastgele vektör fonksiyonel bağlantı ağı (random vector functional link) (RVFL) olmak üzere üç modeli karşılaştırmıştır. Bu karşılaştırma sonucunda RVFL' nin diğer RWSLNF' lerden ve SLFN' lerden daha iyi performans gösterdiği tespit edilmiştir. Mishra ve ark. [35], güneş ışınımı, PV çıkış gücünü ve rüzgâr hızının tahmin etmek için Gürbüz Düzenleştirilmiş Rastgele Vektör Fonksiyonel bağlantı (GD-RVFL) ağı olarak bilinen ultra kısa bir Tahmin modeli önermişlerdir. Önerilen metodolojinin doğruluğunu elde etmek için test, farklı atmosfer koşullarında çeşitli zaman aralıklarında gerçekleştirilmiştir. Önerilen yöntemin diğer modellere (yani Rastgele vektör fonksiyonel bağlantı (RVFL) ve Robust Extreme learning machine (R-ELM) vb.) kıyasla çok üstün performans gösterdiği görülmüştür.

Bu çalışmanın amacı, literatürde makine öğrenimi modellerinde yaygın olan aşırı öğrenme ve yavaş öğrenme dezavantajlarının üstesinden gelerek daha hızlı öğrenen ve yüksek doğrulukta performans gösteren GD-RVFL ağı modelini kısa vadeli PV çıkış gücünü tahmin etmede kullanmak ve bu kapsamda önerilen modeli, 10 farklı makine öğrenimi yöntemi olan BRR, LR, GPR, SVM, ELM, YSA, GBR, RFR, LAR ve RR yöntemleri ile karşılaştırılarak modellerinin performansını değerlendirmektir.

Bu çalışmanın yapısı sırasıyla şu şekilde sıralanmıştır: Bölüm 2, bölgenin konumu, iklimi hakkında ve data seti hakkında bilgi vermektedir. Önerilen yöntem ve karşılaştırma

yöntemleri açıklanmıştır. Bölüm 3'te tahmin sonuçları verilip değerlendirilmiştir. Bölüm 4'te çalışma sonuca bağlanmıştır.

## 2. Materyal ve Metot

### 2.1. PV Santral


Bu çalışmadaki tarihsel veriler Şekil 1'de gösterildiği üzere, Diyarbakır ili Dicle Üniversitesi kampüsünde bulunan bir PV elektrik santralinden [36-38] ve meteorolojik istasyondan [39-42] Mayıs 2019-Nisan 2022 tarihleri aralığında elde edilmiştir.



Şekil 1: PV güç istasyonunun veri toplama sistemi [36]

### 2.2. Güneş ölçüm istasyonu

Bu çalışmadaki girdi verileri güneş ışınlı (R), ortam sıcaklığı (T), panel yüzey sıcaklığı, güneşlenme süresi, bulutluluk oranı, Rüzgâr hızı (W), DC akım, gerilim ve bağıl nem (H) parametreleridir. Bu veriler, şekil 2'de gösterilen, Diyarbakır (Enlem: 37°55' D, Boylam: 40°14' K) Dicle Üniversitesi Bilim ve Teknoloji Uygulama ve Araştırma Merkezi (DÜBTAM) binası çatısında bulunan güneş ölçüm istasyonundan alınmıştır. Bu istasyonda elde edilen veriler 10 dakikalık periyotlarla elde edilmiştir. Bu veriler üzerinde K katlamalı çapraz doğrulama tekniği uygulanmıştır.



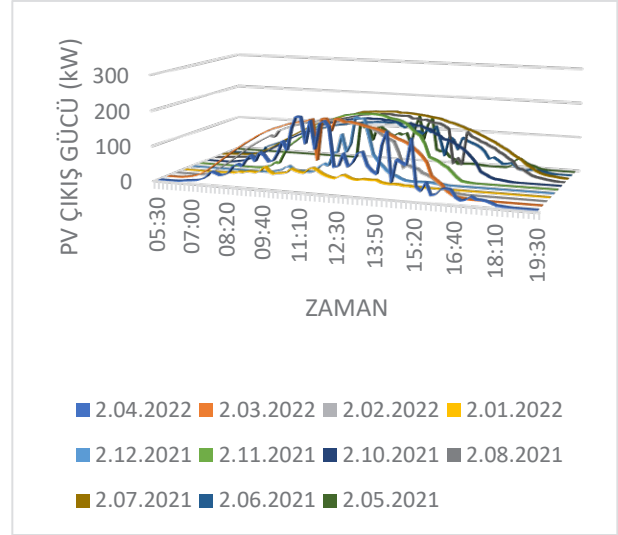
Şekil 2: Dicle Üniversitesi güneş ölçüm istasyonu [40]

Bu teknikte, modellerin çalışma sürecinde eksik ve aşırı öğrenmeyi tespit edip önleyerek test aşamasında en iyi modeli oluşturmayı amaçlamaktadır. Bu teknikte veri seti eğitim seti ve test seti olarak ayrılmış, eğitim seti k adet alt kümeye bölünmüştür. Bu işlem k- kez tekrarlanır. Her tekrarda sıradaki alt küme eğitim setinden çıkarak test seti olarak kullanılır.

$$E = \frac{1}{k} \sum_{i=1}^k E_i \quad (1)$$

Bu işlem tamamlandığında modelin başarısı veya genel hatası (E), eşitliğindeki gibi k kadar ortalaması alınarak bulunur. Bu çalışmada k=10 alınarak veri seti için veri setinin %75'i eğitim verisi (Mayıs 2019- Temmuz 2021), %25'i ise test verisi (Ağustos 2021- Nisan 2022) olarak kullanılmıştır.

Şekil 3 Mayıs 2021-Nisan 2022 tarihleri arası her ayın 2'sindeki PV güç çıkış eğrilerini göstermektedir. PV güç çıkış eğrilerindeki dalgalanmaların nedeni PV santrallerinin meteorolojik koşullara bağlılığından kaynaklanmaktadır.



Şekil 3: Her ayın 2'sinde PV çıkış gücü eğrileri

### 2.3. Kanonik Korelasyon Analizi (KKA) ile Hava Tipi Sınıflandırması

KKA yöntemi, girdi parametrelerini hava tipine göre sınıflandırmak için kullanılmıştır. Kanonik korelasyon analizi, iki değişken grubu arasındaki ilişkileri belirlemek ve ölçmek için kullanılan istatistiksel bir tekniktir [43,44]. Kanonik korelasyon analizi kümeler içindeki ve kümeler arasındaki değişkenliği en iyi açıklayan bir dizi kanonik değişkeni, her bir küme içindeki değişkenlerin ortogonal doğrusal kombinasyonlarını belirlemeye yarar. [45]. Bu çalışma Kanonik korelasyon analizine bağlı olarak, bir günün gündüz dilimlerini yarımsar saatlik periyotlara böler ve ardından her yarımsar saatlik periyodu meteorolojik koşullara göre sınıflandırır ve etiketler. Burada dikkat edilmesi gereken husus, zaman aralığı uzunluğu yerel meteorolojik koşullara bağlı olduğu için zaman aralığı uzunluğu tüm bölgeler için farklılık göstermektedir. Genellikle, zaman aralığının uzun olması, meteorolojik koşulların stabil olma durumuna bağlıdır. Bu çalışmada, ilk adımda belli bir günün gündüz dilimleri yarımsar saatlik zaman aralıklarına bölündü. İkinci adımda, her bir yarımsar saatlik zaman aralığına 4 farklı hava tipi etiketleri verildi. Üçüncü adımda bu hava tiplerinin yarımsar saatlik zaman aralıkları 4 farklı PV güç çıkış seviyesine göre sınıflandırıldı. Etiketler ve bunlara karşılık gelen sınıflandırmalar sırasıyla şu şekildedir; PV güç üretimlerine göre Hava Tipi A (HT-A) en uygun, Hava Tipi B (HT-B) en uygun ikinci hava tipidir ve bu şekilde en az uygun tip olan Hava Tipi D (HT-D)'e kadar devam eder. Çalışmada belli bir tarih ve saatin hava tipini belirlemek için önceki yıllara ait en yakın benzer günlerden alınan zaman aralığındaki veri kümesinin bir bölümü seçildi. Bu veri kümeleri, 10 dakikalık

PV güç çıkış verileri ile güneş ışınımı, ortam sıcaklığı, panel yüzey sıcaklığı, güneşlenme süresi, bulutluluk oranı, rüzgâr hızı, DC akım, gerilim ve bağıl nem verilerinden oluşmaktadır. Tablo 1'de PV güç çıkışlarının A-D hava tiplerine göre dört seviyede sınıflandırılabilceği gösterilmektedir.

Tablo 1: PV güç çıkış seviyesine göre dört tip hava durumu sınıflandırması


Hava Tipi	Formül
Hava Tipi A	$y_i > AVGy + \frac{MAXy - AVGy}{2}$
Hava Tipi B	$VGy < y_i \leq AVGy + \frac{MAXy - AVGy}{2}$
Hava Tipi C	$VGy - \frac{AVGy - MINy}{2} < y_i \leq AVGy$
Hava Tipi D	$0 < y_i \leq AVGy - \frac{AVGy - MINy}{2}$

Bu çalışmada kullanılan hava tipi sınıflandırma yöntemi diğer geleneksel yöntemlere göre kullanımı daha kolaydır ve istenildiği takdirde zaman aralıkları uzunluğuna göre dörtten daha az veya daha fazla seviyeye değiştirilebilir.

$$AVGy = \frac{1}{n} \sum_{i=1}^n y_i \quad y_i \in T \quad (2)$$

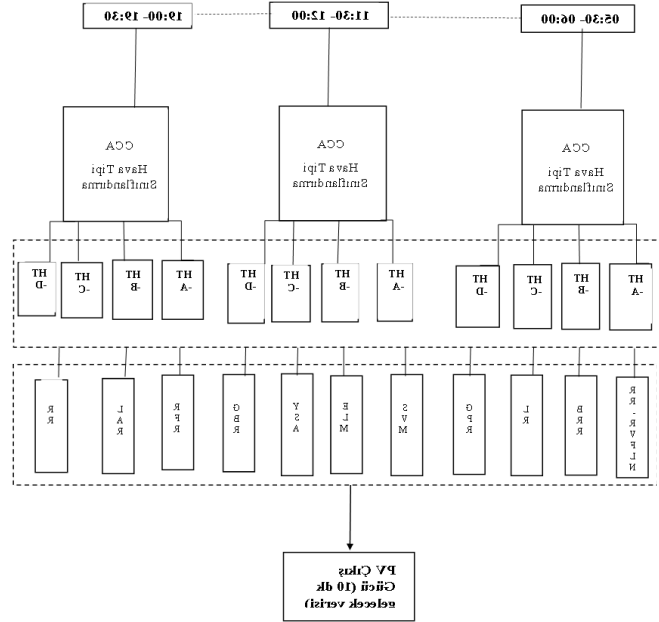
Denklem 2'de T, 2 Haziran 05:30- 06:00 gibi yarımsaatlik bir zaman aralığında seçilen veri setini ifade eder. Sırasıyla; n veri noktalarının sayısını,  $y_i$  PV çıkış gücünü ( $y_i \in T$ ), AVGy veri setinin ortalama PV çıkış gücünü temsil eder ve MAXy ve MINy ise sırasıyla seçilen veri setinin maksimum PV güç çıkışını ile minimum PV güç çıkışını temsil eder.

Bu çalışmanın algoritması Şekil 4'de gösterildiği gibidir. Bu çalışmada Gürbüz Düzenlenmiş Random Vektör Fonksiyon ağı (GD-RVFLN) modelinin işlevi, hava tipini belirleyen verileri girdi olarak kullanıp PV çıkış gücünü tahmin etmektir. Bu çalışmada ilk olarak, Kanonik Korelasyon Analizi kullanarak girdi parametreleri ile PV güç çıktısı arasındaki korelasyonlar belirlendi, son günlere ait her yarım saatte bir PV güç çıkış verileri ile bu verilere karşılık gelen meteorolojik veriler veri setleri olarak toplandı daha sonra, geçmiş veri setlerinden öznitelikler çıkarıldı, sonra her yarım saatlik dilimlere hava tipi etiketleri verildi ve ardından GD-RVFLN modeli eğitildi (Şekil 5).



Şekil 4: KKA'ya bağlı hava tipi sınıflandırma süreci

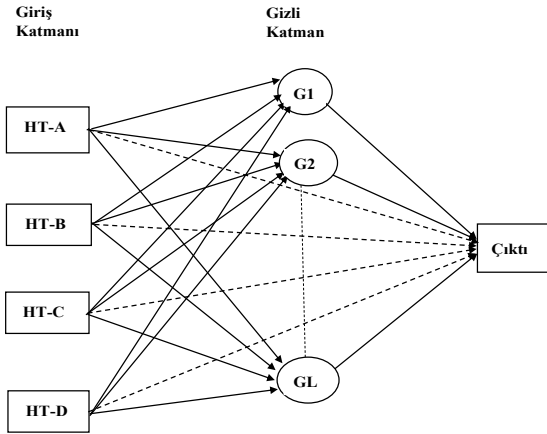
Şekil 5'te gösterilen tahmin süreci, eğitim ve tahmin olmak üzere iki adımdan oluşur.



Şekil 5: Hava tipi sınıflandırmasına dayalı PV tahmin yöntemi

#### 2.4. Orijinal Rastgele Vektör Fonksiyon Bağlantı (RVFL) Ağ Modeli

Rastgele Vektör Fonksiyon Bağlantı (RVFL) ağı, sınıflandırma, görsel izleme, regresyondan tahmine kadar çeşitli alanlardaki üstün performansı nedeniyle araştırmacılar arasında önemli ölçüde ilgi görmüştür. RVFL, gizli nöronların ağırlıklarının ve sapmalarının uygun bir aralıkta rastgele oluşturulduğu ve çıktı ağırlıkları basit bir kapalı form çözümü ile hesaplanırken sabit tutulduğu tek katmanlı ileri beslemeli bir sinir ağı (SLFN)'dır [46, 47]. RVFL ağında giriş katmanından çıkış katmanına doğrudan bağlantılardan büyük ölçüde yararlanır. Doğrudan bağlantıların işlevi, rastgeleleştirme için bir düzenleme yapmasıdır. Ayrıca Extreme Learning Machine (ELM) gibi diğer muadillerine kıyasla RVFL ağı, giriş katmanı ile gizli katman arasındaki ağırlıkları rastgele ataması ve ayarlama işlemine ihtiyaç duymaması nedeniyle model karmaşıklığının düşük tutulmasına yardımcı olur [48]. Şekil 6 Hava tipine dayalı RVFL ağ modelini göstermektedir.



Şekil 6: Hava tipi sınıflandırmasına dayalı PV tahmin yöntemi

Eğitim örneklerinin belirli bir veri seti göz önünde bulundurulduğunda  $S = \{(X_i, Y_i | i = 1, \dots, N)\} \subset R^d \times R$ , RVFLN, aşağıdaki gibi  $L$  gizli düğümüne sahip özel bir tek katmanlı ileri beslemeli bir sinir ağı türü olarak tanımlanabilir.

$$f(x) = \sum_{j=1}^L \beta_j h_j(v_j, b_j, x) \quad (3)$$

(3) nolu denklemde  $v_j$  ve  $b_j$ , sırasıyla gizli düğüm parametreleri olan girdi ağırlığı ve gizli katman düğüm sapmasını ifade eder.  $\beta_j, j$ 'nci gizli katman düğümü ile çıktı düğümü arasındaki çıktı ağırlığını ve  $h_j$ , aktivasyon fonksiyonunu temsil eder. Genel olarak, aşağıdaki radyal tabanlı fonksiyon kullanılabilir.

$$h_j = h\left(\frac{\|x - v_j\|}{b_j}\right) \quad v_j \in R^d, b_j \in R^+ \quad (4)$$

$N$  örnek  $(x_i, y_i) \subset R^d \times R$  için, karesel hataların toplamı olarak kullanılır.

$$J = \sum_{i=1}^N \left\| \sum_{j=1}^L \beta_j h_j(v_j, b_j, x) - y_i \right\|^2 \quad (5)$$

RVFLN'de gizli düğüm parametreleri olan  $v_j$  ve  $b_j$  rastgele atanabilir, burada ağ yaklaşımı performansını sağlamak için yalnızca çıkış katmanının doğrusal parametrelerinin analitik olarak hesaplanması gerekir. Böylece denklem (5) aşağıdaki gibi ikinci dereceden optimizasyon problemi olarak tanımlanabilir.

$$J \arg \min_{\beta} = \|G\beta - Y\|^2 \quad (6)$$

Burada

$$G = \begin{bmatrix} h(v_1, b_1, x_1) & \dots & h(v_L, b_L, x_1) \\ \vdots & \ddots & \vdots \\ h(v_1, b_1, x_N) & \dots & h(v_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (7)$$

$$\beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_L \end{bmatrix}_{L \times 1} \quad \text{Ve} \quad Y = \begin{bmatrix} y_1 \\ \vdots \\ y_L \end{bmatrix}_{N \times 1} \quad (8)$$

$G$ , gizli katman çıktısıdır.  $Y$  ve  $\beta$  sırasıyla örneklenen çıktı ve çıktı ağırlığını temsil eder. Genel olarak, optimal çıktı ağırlığı  $\beta$  aşağıdaki gibi tanımlanabilir.

$$\beta = G^+ Y \quad (9)$$

Burada  $G^+$ ,  $G$  matrisinin Moore-Penrose'a göre genelleştirilmiş transpozesidir, yani tersidir.

### 2.5. Regularized RVFLN (Düzenlenmiş RVFL Ağı)

Düzenlenmiş (D)-RVFL ağıının avantajı, modelin etkili bir şekilde uyum göstermesinin yanında çıktı ağırlığının büyüklüğünü azaltarak model karmaşıklığını da azaltmasıdır. Normal düzenlenmiş RVFLN, hedef fonksiyonunda düzenlenmiş terimi ( $l_2$  normu) tanıtan ridge regresyon yöntemi [49] kullanılarak oluşturulabilir. Belirli bir  $N$  farklı örnek için  $(x_i, y_i)$ ,  $l_2$  normlu D-RVFL ağı denklem 10'daki gibi tanımlanabilir.

$$\begin{aligned} \min: J & \\ &= \frac{1}{2} \|\beta\|_2^2 \\ &+ \frac{C}{2} \sum_{i=1}^N \varepsilon_i^2, \quad \text{s.t: } h(x_i)\beta \\ &= y_i - \varepsilon_i, \quad \forall i. \end{aligned} \quad (10)$$

Burada  $C$ , eğitim hatasını ve çıktı ağırlık normunu dengeleyen düzenleme parametresini temsil eder.  $\sum_{i=1}^N \varepsilon_i^2$  Ampirik kaybı  $\|\beta\|_2^2$  yapısal kaybı temsil eder. Düzenlenmiş en küçük kareler algoritmasına göre, çözüm  $\beta$  aşağıdaki gibi ifade edilebilir:

$$\beta = \begin{cases} \left(G^T G + \frac{I}{C}\right)^{-1} G^T Y, & N \geq L \\ G^T \left(G G^T + \frac{I}{C}\right)^{-1} Y, & N < L \end{cases} \quad (11)$$

Denklem (11) düzenlenmiş RVFLN'nin çevrimdışı öğrenme formu olarak ifade edilir. Çevrimiçi öğrenme formu ise, eşitlik 12'de tanımlanan özyinelemeli bir çözüme atıfta bulunur.

$$\beta \begin{cases} J_k = J_{k-1} + G_k^T G \\ \beta_k = \beta_{k-1} + J_k^{-1} G_k^T (Y_k - G_k \beta_{k-1}) \end{cases} \quad (12)$$

Burada  $G_k, k$ 'nci örnek için oluşturulmuş gizli katman çıktısını belirtir. Modelin başlangıç değerleri aşağıdaki gibidir:

$$\begin{cases} J_0 = G_0^T G_0 + \frac{I}{C} \\ \beta_0 = J_0^{-1} G_0^T Y_0 \end{cases} \quad (13)$$

Gizli düğüm sayısından daha fazla sayıda örnek gerektiren geleneksel RVFLN'nin aksine, düzenlenmiş RVFLN, modeli az miktarda örnek kullanarak başlatabilir. Ayrıca, düzenlenmiş RVFLN'nin çıktı ağırlığı normu nispeten küçük olduğundan, model iyi performans göstermektedir. Ancak aykırı değerli verilerle karşılaştığında, düzenlenmiş RVFLN'nin kalitesi bozulabilir ve model uyumsuzluğuna yol açabilir. Bu yüzden  $C$  düzenleme parametresini tam olarak kullanmayabilir. Bu nedenle, RVFLN'nin geliştirilmesine ihtiyaç duyulmuştur. Aşağıdaki bölümde, sağlam

düzenleştirilmiş (Robust Regularized) RVFLN sunulmaktadır [50].

## 2.6. Gürbüz Düzenlenmiş Rastgele Vektör Fonksiyon Bağlantı Ağı (GD-RVFLN)

RVFLN modelinin sağlamlığını iyileştirmek için kernel density estimation (NKDE) yöntemi ve ağırlıklı ampirik kayıplı ridge-tip düzenlenmiş RVFL ağı yöntemleri çalışmaya dahil edilmiştir. Gürbüz Düzenlenmiş RVFLN yönteminde, ampirik kayıp ağırlıkları, NKDE yönteminin tahmin ettiği örnek güvenilirliğe göre belirlenmektedir. Böylelikle yüksek ve düşük örnek güvenilirliğe sahip kayıp ağırlıklarının değerlerinin düşürülmesi ve artırılması istenmeyen aykırı değerlerin etkisini azaltmakta veya ortadan kaldırmaktadır [51].

Bir optimizasyon yöntemi olan Robust regularized RVFLN yöntemi, belirli bir  $N$  farklı örnek  $(x_i, y_i)$  için, aşağıdaki matematiksel formülle ifade edilebilir.

$$\beta \min: \frac{1}{2} \|\beta\|_2^2 + \frac{C}{2} \sum_{i=1}^N p_i \|\varepsilon_i\|_2^2 \quad (14)$$

$$s. t: h(x_i)\beta = y_i - \varepsilon_i, \forall i.$$

Bu formüldeki  $p_i$ ,  $i$ 'nci örneğin ampirik kayıp ağırlığını ifade eder.  $\beta$  optimal çıkış ağırlığıdır.  $C$ , düzenleme parametresidir ve  $\varepsilon$ , artık hatadır. Karush-Kuhn-Tucker (KKT) teoremine göre, yukarıdaki optimizasyon formülü matematiksel olarak aşağıdaki ikili optimizasyon formülüyle ifade edilebilir.

$$J_{\ell_2}(\beta, \varepsilon, \alpha) = \frac{1}{2} \|\beta\|_2^2 + \frac{1}{2} C \sum_{i=1}^N p_i \varepsilon_i^2 - \sum_{i=1}^N \alpha_i (h(x_i)\beta - y_i + \varepsilon_i) \quad (15)$$

Burada  $i$ 'nci giriş örneği için  $\alpha_i$ , Lagrange çarpanı ve  $h$  aktivasyon fonksiyonudur. Burada,  $\beta$ ,  $\varepsilon$ ,  $\alpha$  değerleri, yukarıdaki ikili optimizasyon formülünün kısmi türevi alınarak bulunabilir. Dolayısıyla, formül şu şekilde türetilebilir:

$$\frac{\partial J_{\ell_2}}{\partial \beta} = 0 \rightarrow \beta = G^T \alpha \quad (16)$$

$$\frac{\partial J_{\ell_2}}{\partial \varepsilon} = 0 \rightarrow \alpha = CP\varepsilon \quad (17)$$

$$\frac{\partial J_{\ell_2}}{\partial \alpha} = 0 \rightarrow G\beta - Y + \varepsilon = 0 \quad (18)$$

Burada,  $P$  ampirik kayıp ağırlık matrisini ifade eder. Farklı büyüklükteki eğitim örneği setleri için yukarıdaki formüllere aşağıdaki alternatif çözümler elde edilebilir.  $N < L$  olduğu durumda formül (18)'den. (19) formül elde edilir:

$$PG\beta - PY + P\varepsilon = 0 \quad (19)$$

(17) ve (18) formüllerden formül (20) ulaşılır.

$$\left(\frac{1}{C} + PGG^T\right) \alpha = PY \quad (20)$$

(20)'deki  $\alpha$ 'yı yalnız bırakır 16. Formüldeki yerine koyarsak formül (21) elde edilir.

$$\beta = G^T \left(\frac{1}{C} + PGG^T\right)^{-1} PY \quad (21)$$

$N > L$  olduğu durumda (17)'deki  $\alpha$  değerini (18)'de yerine yazıldığında formül (22) elde edilir.

$$\beta = G^T CP\varepsilon \quad (22)$$

(22)'deki  $P\varepsilon$  aşağıda gösterildiği gibi yalnız bırakılır.

$$P\varepsilon = \frac{1}{C} (G^T)^{-1} \beta \quad (23)$$

(23), (19)'da yerine yazılarak (24) elde edilir.

$$PG\beta - PY + \frac{1}{C} (G^T)^{-1} \beta = 0 \quad (24)$$

Böylece,

$$G^T PG\beta - G^T PY + \frac{1}{C} \beta = 0 \quad (25)$$

(25)'deki  $\beta$  yalnız bırakıldığında aşağıdaki (26) elde edilir.

$$\beta = \left(\frac{1}{C} + G^T PG\right)^{-1} G^T PY \quad (26)$$

Sonuç olarak, yukarıdaki çıktı ağırlıkları  $\beta$  kısaca aşağıdaki formüldeki gibidir.

$$\beta = \begin{cases} G^T \left(\frac{1}{C} + PGG^T\right)^{-1} PY, & N < L \\ \left(\frac{1}{C} + G^T PG\right)^{-1} G^T PY, & N \geq L \end{cases} \quad (27)$$

$i=1, \dots, N$  sayıda örneklem için Ampirik kayıp ağırlığı  $p_i$ ,  $C$  parametresi hariç optimal çıkış ağırlığı  $\beta$  çözümü için oldukça önemli bir parametredir. Çünkü model sağlamlığının iyileştirilmesi  $p_i$ 'nin hesaplanmasıyla elde edilir. Burada  $p_i$  örneklerin çözüme katkısıdır. Dolayısıyla, amaca ulaşmak için bu katkının örneğin güvenilirliğine yakın olmasına izin verildi. Örnek güvenilirliği, artık olasılık yoğunluk fonksiyonu kullanılarak NKDE yöntemi ile tahmin edilebilir. Bu yolla, düşük yoğunluklu aykırı değerler ayarlanarak çözüme küçük ya da sıfır katkı sağlar. Artık olasılık dağılımı ise Robust regularized RVFLN yöntemindeki  $P$ 'nin bir birim matrisi olarak ayarlanması ile elde edilebilir. Yani;

$$\varepsilon_j = \sum_{i=1}^L \beta_i h_i(v_i, b_i, x_i) - y_j \quad j = 1, 2, \dots, N \quad (28)$$

Daha sonra, artıkların olasılık yoğunluğu  $f(x)$ , aşağıdaki gibi NKDE yöntemi ile elde edilir.

$$f(x) = \frac{1}{hN} \sum_{j=1}^N \phi\left(\frac{x-\varepsilon_j}{h}\right) \quad (29)$$

$$\phi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \quad (30)$$

Burada, sırasıyla  $\phi$ , Gauss çekirdek fonksiyonu,  $\hat{\sigma}$  artıkların standart sapmasını ve  $h=1.06\hat{\sigma}N^{-1/5}$  tahmin edilen pencere genişliğini ifade etmektedir. Formül (27) kullanılarak, her artık hata  $\varepsilon_i$ 'nin olasılığı, yani,  $f(\varepsilon_i)$  elde edilebilir. Diğer taraftan  $f(\varepsilon_i)$  fonksiyonu ile örneğin güvenilirliği doğru orantılıdır. Yani,  $f(\varepsilon_i)$ 'nin değeri yüksek olduğunda örnek güvenilirliği yüksek olur, küçük olduğunda örnek güvenilirliği de küçük olur. Bu nedenle,  $f(\varepsilon_i)$ 'yi ayarlanarak doğrudan pi ağırlığı da ayarlanabilir.

Çıktı ağırlığı hesaplama formülü (27) ile numune ağırlığı değerlendirme denklemi formül (29) arasındaki yinelemeli değişim, yenilemeli olmayan yöntemle göre daha doğru örnek güvenilirliği sağlamaktadır. Ancak yinelemeli değişim daha yüksek hesaplama yüküne sahip olduğu için bu çalışmada yinelemeli olmayan yöntem kullanılmıştır.

## 2.7. Karşılaştırma Yöntemleri

Bu çalışmada önerilen modelin doğruluğunu karşılaştırmak için 10 farklı makine öğrenme modeli kullanılmıştır. Bu modeller sırasıyla şu şekildedir; Bayesian Ridge Regressor (BRR), Linear Regressor (LR), Gaussian Process Regressor (GPR), Support Vector Machine (SVM), Extreme Learning Machine (ELM), Yapay Sinir Ağı (YSA), Gradient Boosting Regressor (GBR), Random Forest Regressor (RFR), Lasso Regressor (LAR) ve Ridge Regressor (RR). Tüm bu modeller kendi avantaj ve dezavantajlarına sahiptir. Bu çalışmada modellerin tahmin süresi şekil 3.5'te gösterildiği gibidir. Buna göre ilk olarak, güneş ışınımı, güneşlenme süresi, rüzgâr hızı, ortam sıcaklığı, panel yüzey sıcaklığı, bulutluluk oranı, DC akım, gerilim ve bağıl nem parametreleri Konikal Korelasyon Analizi (KKA) modeli kullanarak hava tipi seviyelerine göre dört sınıfa ayrılmıştır. Bu modeller, bu dört sınıfa ayrılan hava tipini giriş olarak kullanılarak kısa vadeli 10 dakika ileri zaman çözünürlüğüne sahip PV çıkış gücünü tahmin etmiştir.

## 3. Bulgular ve Tartışma

PV çıkış gücü, güneş radyasyonu, ortam sıcaklığı ve rüzgâr hızı vb. gibi meteorolojik parametrelerle yakından ilişkilidir. Bu çalışmada 10 dakika aralıklara sahip Makine öğrenimi modellerini test etmek için kullanılan eğitim verileri, Mayıs 2019 ile Nisan 2022 arasındadır. Bu çalışmada farklı modellerin tahmin performansını göstermek ve karşılaştırmak için her ayın 2'si seçildi.

### 3.1. Değerlendirme Endeksleri

Bir modelin tahmin doğruluğunu değerlendirmeye ve kıyaslamaya, standartlaştırılmış performans ölçüleri, yardımcı olur. Sırasıyla denklem (4.1) ve (4.2)'de gösterildiği gibi Ortalama Mutlak Yüzdeler Hata (OMYH/OMYH) ve Ortalama Karesel Hatası (OKH), bu çalışmadaki modellerinin doğruluğunu değerlendirmede kullanılmıştır: OMYH, tahminin doğruluğunu ölçen ve gerçek veri kümeleri için tahmin çeşitliliğini doğrulayan standart bir tahmin tekniğidir.

$$OMYH = \frac{1}{N} \sum_{i=1}^n \frac{|P_{Gerçek}(i) - P_{Tahmin}(i)|}{P_{Gerçek}(i)} \times 100\% \quad (31)$$

Ortalama görelî hatanın aralıklarına karşılık gelen ifadeler sırasıyla şu şekildedir;

$$\begin{aligned} 0 \leq OMYH \leq 10 & \text{ mükemmel tahmin doğruluğu,} \\ 10 \leq OMYH \leq 20 & \text{ iyi tahmin doğruluğu,} \\ 20 \leq OMYH \leq 50 & \text{ idare eder, tahmin doğruluğu,} \\ OMYH \geq 50 & \text{ ise yanlış tahmini ifade etmektedir.} \end{aligned}$$

OKH, tahmin edilen değerler ile gerçek gözlemler arasındaki karesel farklılıkların ortalamasının karekökünü kullanarak hatanın ortalama değerini tahmin eder. Bu nedenle, özellikle istenmeyen büyük sapmalarla baş etmede daha sağlamdır ve araştırmacıya aykırı değerleri belirleme ve ortadan kaldırma yeteneği verir.

### OKH

$$OKH = \sqrt{\frac{1}{N} \times \sum_{i=1}^N (P_{Tahmin}(i) - P_{Gerçek}(i))^2} \quad (32)$$

Yukardaki formüllere göre  $P_{Tahmin}$  ve  $P_{Gerçek}$  sırasıyla PV tahmin gücünü, ölçülen PV gücünü temsil eder. N, veri ölçümlerinin sayısıdır. OKH değeri  $0 \leq OKH < \infty$  a kadar değişebilir. Negatif eğilimli düşük değerler daha iyi performans gösterir. OKH=0 olma durumu modelin hatasız olduğunu gösterir.

### 3.2. Tahmin Sonuçları

Bu çalışmada kullanılan büyük veri kümesi, Dicle üniversitesi kampüsünde kurulu olan PV güç santralinden ve güneş istasyonundan toplanmıştır; makine öğrenimi modellerinin büyük verilere ihtiyaç duymasının nedeni test sonuçlarının diğer koşullara uygulanabilir olması için etkin bir şekilde eğitilmesi içindir. Bu aşamada, modellerin tahmin doğruluğunu değerlendirmede kullanmak için her ayın 2'si seçilmiştir.

#### 3.2.1. Hava tipi sınıflandırmasına dayalı GD-RVFLN modeli tahmin sonuçları

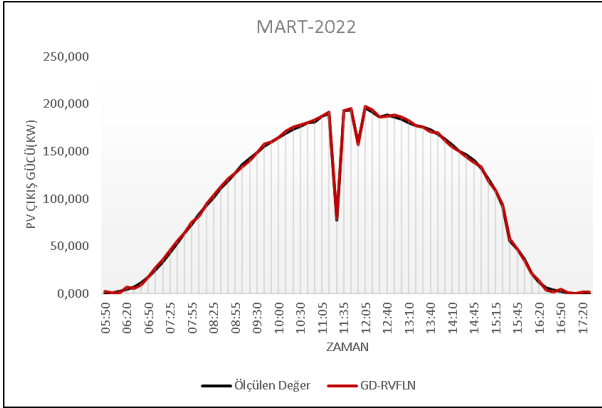
Modelin performans doğruluğunu artırmak için klasik RVFLN modeli geliştirilerek oluşturulan ve hava tipi sınıflandırmasına dayalı olan GD-RVFLN modelini önerilmiştir. Önerilen bu modelin tahmin sonuçları göstermiştir ki Mayıs 2022-Nisan 2021 tarihleri arasındaki tüm aylarda GD-RVFLN modeli  $0 \leq OMYH \leq 10$  aralığında değerler olarak mükemmel tahmin doğruluğuna sahiptir (tablo 4.1'de gösterildiği gibidir). Aşağıdaki şekiller GD-RVFLN modelinin mükemmel doğruluk gösterdiği ay ile nispeten daha az mükemmellik gösterdiği aylardan alınan ve bu modelin ölçülen gerçek PV çıkış gücü sonuçlarıyla karşılaştırıldığı tahmin sonuçlarını göstermektedir.

Tablo2: PV güç çıkış seviyesine göre dört tip hava durumu sınıflandırması

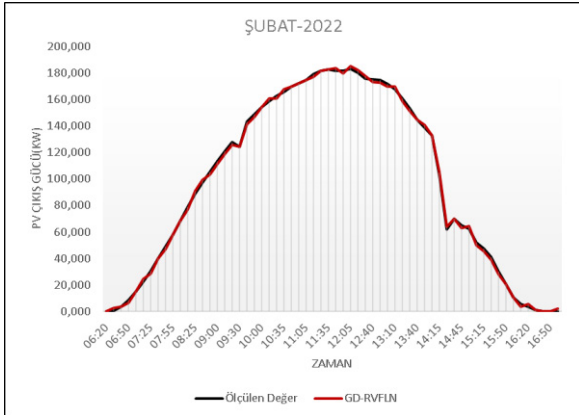
Tarih	OMYH (%)	OKH
2.04.2022	3,919	1,646
2.03.2022	1,724	1,684
2.02.2022	1,687	1,680



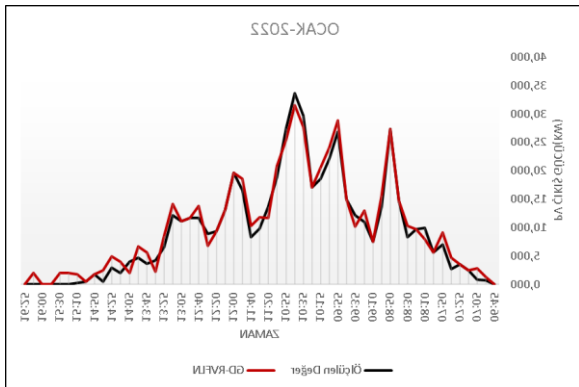
2.01.2022	9,767	1,398
2.12.2021	8,886	1,445
2.11.2021	1,895	1,732
2.10.2021	2,254	1,499
2.08.2021	1,861	1,345
2.07.2021	1,811	1,664
2.06.2021	4,741	1,570
2.05.2021	5,407	1,358



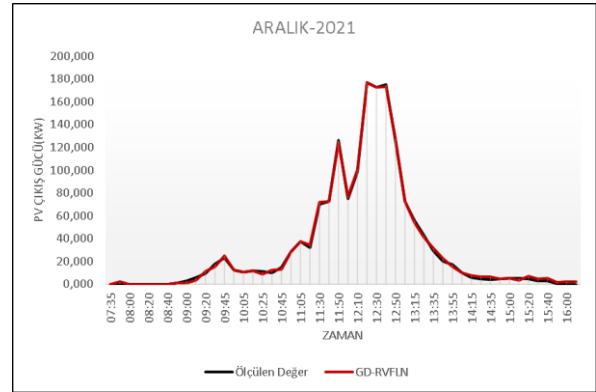
Şekil 6: 02.03.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



Şekil 7: 02.02.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



Şekil 8: 02.01.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



Şekil 9: 02.12.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması

Yukarıdaki şekillerde görüldüğü üzere önerilen GD-RVFLN modeli gerçek PV çıkış gücü ile yüksek doğrulukta performans göstermiştir. Şekillere bakıldığında bazı aylar arasında ölçüm sonuçlarında uyumsuzluk görülmektedir. Örneğin, şekil 4.6 ile şekil 4.8'e bakıldığında, Ocak 2022 de modelin tahmin doğruluğu OMYH=9,76 iken, Şubat 2022'deki doğruluk değeri, OMYH=1,68 çıkmıştır. Şekil 4.8'deki grafiğe bakıldığında grafikte PV çıkış gücünde inişler çıkışlar görülmektedir ayrıca o gün PV çıkış gücünün en yüksek değeri yaklaşık 35 kW'tır. PV sistemleri büyük oranda meteorolojik koşullara bağlıdır. Havanın bulutlu ya da yağmurlu olduğu günlerde PV çıkış gücü ya hiç üretilmemekte ya da düşük değerler üretmektedir bu da PV çıkış gücünde iniş ve çıkışlara neden olmaktadır. Şekil 4.8'deki grafiğin inişli çıkışlı olmasının nedeni de bu durumdan kaynaklanmaktadır. Bu yüzden Ocak 2022 ile Şubat 2022 arasındaki tahmin sonuçlarının farkının yüksek olmasının nedeni Ocak ayının 2'sinde yaşanan hava durumunun tutarsızlığından kaynaklanmaktadır. Buna rağmen havanın kararsız olduğu günlerde bile GD-RVFLN modeli  $0 \leq OMYH \leq 10$  aralığında kalmaya devam ederek gerçek PV çıkış gücüyle yüksek benzerlik göstermiştir.

Hava tipi sınıflandırma yönteminin modellerde kullanılması çoğu makine öğrenimi modelinde kısa vadeli PV çıkış gücü tahmininin doğruluğunu artırdığı göstermiştir. Bununla birlikte hem hava tipi sınıflandırmasının hem de PV güc çıkış tahminin, güneş radyasyonu ile yüksek korelasyona sahip olduğu bilinmektedir. Dolayısıyla kararsız hava koşullarında güneş radyasyonundaki yüksek dalgalanmalar modellerin doğruluğunu önemli ölçüde etkilemiştir. Şekillerden ve tablolardan (tablo 3 ve tablo 4) da anlaşıldığı gibi en iyi performans gösteren ilk dört model, GD-RVFLN, BRR, LR, GPR'dir. Tüm modeller arasında ise mükemmel doğruluk gösteren model bu tezde önerilen model olan GD-RVFLN modeli olmuştur.

Bu çalışmada veriler her ayın belli bir gününde alındığı için PV çıkışı gücü, o günün meteorolojik koşullarına bağlı olarak önemli ölçüde farklılık göstermektedir. Meteorolojik koşulların sabit olduğu günlerde bu çalışmada önerilen model olan GD-RVFLN'nin ortalama mutlak yüzdelik hata değerleri sırasıyla, 1,68; 1,72; 1,81; 1,86 ve 1,89 olmuştur. Öte yandan neredeyse tüm modeller meteorolojik koşulların sabit olduğu günlerde yüksek performans göstermiştir. Meteorolojik koşulların kötü olduğu günlerde ise (2 Ocak ve 2 Aralık) modellerin çoğu daha az iyi performans göstermiştir. Bu duruma rağmen önerilen GD-RVFLN modeli  $0 \leq OMYH \leq 10$  aralığında kalarak mükemmel doğruluk gösterme performansını korumuştur. Makine öğrenmesi modellerinde çıktılar tahmin etme,

Tablo3: On bir makine öğrenimi modeli için OMYH (%) değerleri

TARİH	GD-RVFLN	BRR	LR	GPR	SVM	ELM	YSA	GBR	RFR	LAR	RR
2.04.2022	3,919	5,497	8,477	10,599	12,288	12,020	13,022	11,714	14,613	15,251	12,175
2.03.2022	1,724	2,752	3,768	4,265	5,691	6,489	7,527	6,585	8,595	8,963	10,972
2.02.2022	1,687	2,564	3,031	3,777	4,762	6,347	7,806	7,771	7,656	10,954	10,654
2.01.2022	9,491	12,270	20,295	23,472	20,146	27,062	26,831	35,706	35,566	39,002	39,930
2.12.2021	4,861	7,858	9,662	13,114	10,997	19,920	27,952	18,916	21,252	22,488	29,255
2.11.2021	1,895	1,989	2,842	4,002	3,954	4,391	5,423	6,334	4,418	6,208	10,337
2.10.2021	2,254	3,364	4,021	4,921	5,453	6,170	8,564	8,647	7,910	8,949	9,722
2.08.2021	1,861	3,987	4,946	7,583	7,707	6,411	9,887	10,690	7,873	11,531	9,667
2.07.2021	1,811	3,137	4,020	4,337	5,102	6,620	6,235	6,549	9,427	8,490	9,901
2.06.2021	2,293	3,478	6,125	4,940	7,569	7,676	9,531	10,243	7,780	11,007	11,395
2.05.2021	3,828	7,947	7,255	6,047	11,172	10,434	12,828	6,654	8,777	7,068	9,723

Tablo3: Tablo 4.3 On bir makine öğrenimi modeli için OKH değerleri

TARİH	GD-RVFLN	BRR	LR	GPR	SVM	ELM	YSA	GBR	RFR	LAR	RR
2.04.2022	1,646	2,498	3,519	4,016	5,112	5,897	6,506	7,046	7,968	8,859	7,569
2.03.2022	1,684	2,590	3,368	4,369	5,117	5,894	7,180	8,202	9,022	9,295	10,806
2.02.2022	1,680	2,485	3,266	3,771	4,678	5,631	6,532	7,769	7,921	9,495	10,221
2.01.2022	1,789	2,450	3,425	4,282	4,382	5,994	6,197	7,349	8,165	8,981	9,498
2.12.2021	1,617	2,354	3,038	4,160	4,243	6,139	7,524	7,277	7,845	8,618	8,962
2.11.2021	1,732	2,419	3,162	4,402	5,109	5,643	6,573	6,675	7,071	8,696	9,859
2.10.2021	1,499	2,248	3,134	3,973	4,353	5,640	6,630	7,445	7,845	8,981	10,053
2.08.2021	1,345	2,458	3,244	4,179	4,832	4,984	6,560	7,448	7,237	8,650	9,102
2.07.2021	1,664	2,468	3,215	3,873	4,707	5,824	6,354	6,881	8,533	9,354	9,760
2.06.2021	1,574	2,563	3,383	3,934	5,182	5,436	6,761	7,260	7,346	8,765	9,562
2.05.2021	1,351	2,173	2,585	3,128	4,104	4,993	5,564	5,630	5,899	6,068	7,506

öncelikle büyük miktarda verilerin eğitilmesi ile gerçekleşir, ancak verilerdeki düzensizlikler tahmin doğruluğunu olumsuz etkileyen ana faktördür. Bu nedenle modellerde kullanılan verilerin en iyi hava koşullarında elde edilen verilerden oluşması önem arz etmektedir. Ancak bu çalışmada modellerin performansını analiz etmek için her ayın belli bir günü tercih edildi. Bu yüzden modellerin değerlendirmesi seçilen günün hava koşulunun iyi veya kötü olma durumuna bağlı olarak aylık değil tek bir gün için değerlendirmeler yapıldı. Bu anlamda, hava durumunun iyi olduğu günlerde diğer bir deyişle, havanın yağışsız, gökyüzünün açık olduğu günlerde PV çıkış gücü tahmini tüm modellerde nispeten yüksek performans göstermiştir. Öte yandan, gökyüzünün bulutlu ve yağışlı olduğu kararsız hava koşullarının olduğu günlerde elde edilen eğitim ve tahmin veri setlerinde büyük dalgalanmalar olmaktadır. Bu dalgalanmalar daha düşük bir tahmin doğruluğuna yol açmaktadır. Kararsız hava koşullarında en iyi modeller arasında en iyi PV çıkış gücü tahmini sağlayan model GD-RVFLN modelidir.

#### 4. Sonuçlar

Bu çalışmada, gün öncesi PV çıkış gücünü tahmini on bir farklı makine öğrenimi modelleri üzerinde çalışıldı. İleri sürülen algoritmalar, PV çıkış gücünü tahmin etmek için hava koşullarına bağımlı olan meteorolojik verilerinin kullanılmasında, hava koşullarının belirsizliği nedeniyle modellerin tahmin sonucunda hem periyodik hem de rastgele değişimlere sebep olduğunu göstermiştir. Bu yüzden istikrarı yakalamak için birden fazla saatlik meteorolojik veriler üzerinde hava tipi sınıflandırması yapmak gerekmektedir. Bu çalışmada hava tipi sınıfını bulmak ve PV çıkış gücü tahmini iyileştirmek için GD-RVFLN modeli önerildi ve analiz için 10 farklı makine öğrenimi modeli seçildi. Çıkan sonuçlarda, 11 farklı makine öğrenimi içinde en iyi performansı gösteren modellerin önerilen model GD-RVFLN ve BRR modelleri olduğu bulundu.

Bu çalışmadaki yenilik, geleneksel yapay zekâ modellerinde karşılaşılan sorunların; örneğin çok büyük sayıda veri kullanımından kaynaklı bazı verilerin göz ardı edilmesi, verilerdeki uyumsuzluk ve yetersiz genelleme gibi birtakım sorunların üstesinden gelmek için PV çıkış gücünün meteorolojik verilerle korelasyonu göz önüne alınarak makine öğrenimi modellerini birleştirmektir. Önerilen modeller, Diyarbakır Dicle üniversitesi kampüsünde bulunan PV güç santraline kısa vadeli PV güç tahmini uygulanarak analiz edildi. Sonuçlar, önerilen hava tipi sınıflandırmasına dayalı makine öğrenme modellerinin göstermiş oldukları yüksek doğrulukları nedeniyle pratik uygulamalar için büyük potansiyele sahip olduğunu göstermiştir.

PV çıkış gücünün sürekli değişmesi şebekede gerilim, frekans dalgalanmaları ve güç kalitesi problemlerine neden olmaktadır. İletim ve dağıtım şebekelerinde gerilim ve frekans kontrolü kısa zamanlı (saniyeler ve dakikalar seviyelerinde) yapılması gerektiği için kısa dönemli PV çıkış gücü tahminine ihtiyaç duyulmaktadır. Literatürde de hem PV çıkış gücü tahmini hem de gerilim ve frekans kontrolü yapan çalışmalar az sayıda bulunmaktadır. Bundan dolayı PV çıkış gücü tahmini, kontrol çalışmaları, güç iletim ve dağıtımda ciddi öneme sahiptir. Gelecek çalışmalarda PV çıkış gücü tahmin tabanlı gerilim, frekans kontrolü çalışmaları ve güç kalitesi iyileştirme çalışmaları yapılabilir.

#### 5. Kaynaklar

- [1] P. Markuse, Provisional Report on the State of the Global Climate 2020, World Meteorological Organization (WMO), 2021. Erişim Tarihi: 21 Ocak 2022. [https://library.wmo.int/index.php?lvl=notice\\_display&id=21804#.YwThLEdBxPZ](https://library.wmo.int/index.php?lvl=notice_display&id=21804#.YwThLEdBxPZ)
- [2] H.E. Murdock, D. Gibb, T. André vd. Renewables 2021 Global Status Report, World Energy Council, REN21, 2021. Erişim Tarihi: 21 Ocak 2022. <https://www.ren21.net/reports/global-status-report/>
- [3] T. Gould, J. Coppel, T. Bienassis vd., World Energy Investment 2022, International Energy Agency, 2022. Erişim Tarihi: 21 Ocak 2022. <https://www.iea.org/reports/world-energy-investment-2022>
- [4] F. Barbieri, S. Rajakaruna, ve A. Ghosh. "Very short-term photovoltaic power forecasting with cloud modeling: A review," Renewable and Sustainable Energy Reviews, 75, Aug. 2017, s. 242-263.
- [5] G. Gowrisankaran, S. S. Reynolds ve M. Samano, "Intermittency and the value of renewable energy," Journal of Political Economy, vol. 124, no.4, Aug 2016, s. 1187-1234.
- [6] G. Stein ve T. M. Letcher, "Integration of PV generated electricity into national grids. In A comprehensive guide to solar energy systems" Academic Press, 2018, s.321-332.
- [7] G. Cervone, L. Clemente-Harding, S. Alessandrini, ve L. Delle Monache, "Short-term photovoltaic power forecasting using Artificial Neural Networks and an Analog Ensemble," Renewable Energy, vol.108, Aug. 2017, s. 274-286.
- [8] Z.L. Yang, M. Mourshed, K. Liu, vd., "A novel competitive swarm optimized RBF neural network model for short-term solar power generation forecasting," Neurocomputing, vol. 397, Jul. 2020, s.415-421.
- [9] D. Li and K. Sun, "Random Forest solar power forecast based on classification optimization," Energy, vol. 187, Nov. 2019, s. 1-11.
- [10] I. A. Ibrahim ve T. Khatib, "A novel hybrid model for hourly global solar radiation prediction using random forests technique and firefly algorithm," Energy Convers Manag, 2017, s.409-422.
- [11] H.Z. Wang, H.Y. Yi, J.C. Peng, vd., "Deterministic and probabilistic forecasting of photovoltaic power based on deep convolutional neural network," Energy Convers Manag, vol. 153, Dec. 2017, s.409-422.
- [12] H.Z. Wang, Z.X. Lei, X. Zhang, vd., "A review of deep learning for renewable energy forecasting," Energy Convers Manag, vol. 198, Oct 2019, s.1-16.
- [13] M.R. Douiri, "Particle swarm optimized neuro-fuzzy system for photovoltaic power forecasting model," Sol Energy, vol. 184, s.91-104, 2019.
- [14] Y.T. Li, Y. He, Y. Su, vd., "Forecasting the daily power output of a grid connected photovoltaic system based on multivariate adaptive regression splines," Appl Energy, vol.180, 15 Oct. 2016, s.392-401.
- [15] H. Wang ve J. Shen, "An Improved Model Combining Evolutionary Algorithm and Neural Networks for PV Maximum Power Point Tracking," in IEEE Access, vol. 7, 2019, s. 2823-2827.
- [16] Duman Altan , B. Diken ve B. Kayışoğlu , "Prediction of Photovoltaic Panel Power Outputs using Time Series and Artificial Neural Network Methods", Tekirdağ Ziraat Fakültesi Dergisi, c. 18, sayı. 3, ss. 457-469, Eyl. 2021, doi:10.33462/jotaf.837446
- [17] K. Tümay Ateş , "Çok Katmanlı Yapay Sinir Ağı Modeli ve Kültürel Algoritma Modeli Kullanılarak Geliştirilen Melez Yöntem ile Kısa Vadeli Fotovoltaik Enerji Santrali Çıkış Gücü Tahmini", Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi, c. 5, sayı. 1, ss. 342-354, Mar. 2022, doi:10.47495/okufbed.1028813

- [18] K.J. Wang, X.X. Qi, H.D. Liu, vd., "Deep belief network-based k-means cluster approach for short-term wind power forecasting," *Energy*, vol. 168, Dec. 2018, s. 840-852.
- [19] K.J. Wang, X.X. Qi, ve H.D. Liu, "A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network," *Appl Energy*, vol. 251, Oct. 2019.
- [20] L.Y. Liu, Y. Zhao, D.L. Chang, vd., "Prediction of short-term PV power output and uncertainty analysis," *Appl Energy*, vol. 228, Oct. 2018, s.700-711
- [21] G. Cervone, L. Clemente-Harding, S. Alessandrini, vd., "Short-term photovoltaic power forecasting using artificial neural networks and an analog ensemble," *Renew Energy*, vol. 108, Aug. 2017, s.274-284.
- [22] S. Sobri, S. Koohi-Kamali, ve N. Rahim Abd, "Solar photovoltaic generation forecasting methods: a review," *Energy Convers Manag*, vol.156, Jan. 2018, s. 459-497.
- [23] M.Q. Raza, M. Nadarajah, ve C. Ekanayake, "Review on recent advances in PV output power forecast," *Sol Energy*, vol. 136, Oct. 2016, s.125-144.
- [24] L.W. Zheng, Z.K. Liu, J.N. Shen, vd., "Very short-term maximum Lyapunov exponent forecasting tool for distributed photovoltaic output," *Appl Energy*, vol. 229, Nov. 2018, s.1128-1139.
- [25] X. Zhao, H. Wei, H. Wang, vd., "3d-cnn-based feature extraction of ground-based cloud images for direct normal irradiance prediction," *Sol Energy*, vol.181, 2019, s.510-518.
- [26] Y. Zhou, N. Zhou, L. Gong, vd., "Prediction of photovoltaic power output based on similar day analysis, genetic algorithm and extreme learning machine," *Energy*, vol. 204, 2020, s. 117894.
- [27] R. Ahmed, V. Sreeram, Y. Mishra, vd., "A review and evaluation of the state-of-the-art in PV solar power forecasting: techniques and optimization," *Renew Sustain Energy Rev*, vol. 24, May 2020, s.1-26.
- [28] W. VanDeventer, E. Jamei, G. S. Thirunavukkarasu, vd., "Short-term PV power forecasting using hybrid GASVM technique," *Renewable energy*, vol.140, 2019, s.367-379.
- [29] M. Massaoudi, S. S. Refaat, H. Abu-Rub, vd., "A Hybrid Bayesian Ridge Regression-CWT-Catboost Model For PV Power Forecasting," 2020 IEEE Kansas Power and Energy Conference (KPEC), 2020, s. 1-5
- [30] L. Gutiérrez, J. Patiño, ve E. Duque-Grisales, "A Comparison of the Performance of Supervised Learning Algorithms for Solar Power Prediction," *Energies*, vol.14, no. 15, 2021, s. 4424,
- [31] A. Afzal, S. Alshahrani, A. Alrobaian, vd., "Power plant energy predictions based on thermal factors using ridge and support vector regressor algorithms" *Energies*, vol.14, no. 21, 2021, 7254.
- [32] A. I. Khalyasmaa, S. A. Eroshenko, V. A. Tashchilin, vd., "Industry experience of developing day-ahead photovoltaic plant forecasting system based on machine learning," *Remote Sensing*, vol. 12, no.20, 2020, 3420.
- [33] S. Chahboun ve M. Maaroufi, "Novel comparison of machine learning techniques for predicting photovoltaic output power," *International Journal of Renewable Energy Research (IJRER)*, vol.11, no.3, 2021, s. 1205-1214.
- [34] A. Aggarwal ve M. M. Tripathi, "Short-term solar power forecasting using Random Vector Functional Link (RVFL) network," *In Ambient Communications and Computer Systems*, Springer, Singapore, 2018, s.29-39.
- [35] S. P. Mishra, P. P. Padhi, J. Naik, vd., "An efficient Robust Random Vector Functional Link network for Solar Irradiance, Power and Wind speed prediction," 2021 1st Odisha International Conference on Electrical Power Engineering, Communication and Computing Technology(ODICON), 2021, s. 1-7.
- [36] C. Haydaroglu, "Dicle Üniversitesi Güneş Enerjisi Santralinin Performans Analizi," (Yayımlanmamış Yüksek Lisans Tezi), Dicle Üniversitesi, Fen Bilimler Enstitüsü, 2017.
- [37] C. Haydaroglu ve B. Gümüş, "Dicle Üniversitesi güneş enerjisi santralının PVsyst ile simülasyonu ve performans parametrelerinin değerlendirilmesi," *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, vol. 7, no. 3, 2016. s. 491-500.
- [38] C. Haydaroglu ve B. Gümüş, "Investigation of the effect of short-term environmental contamination on energy production in photovoltaic panels: Dicle University solar power plant example," *Applied Solar Energy*, vol.53, no.1, 2017, s.31-34.
- [39] H. Kılıç, "Güneş Enerjisi ile İlgili Meteorolojik Verilerin Tahmini İçin Yöntem Geliştirilmesi," (Yayımlanmamış Yüksek Lisans Tezi), Dicle Üniversitesi, Fen Bilimler Enstitüsü, 2016.
- [40] B. Gumus ve H. Kilic, "Time dependent prediction of monthly global solar radiation and sunshine duration using exponentially weighted moving average in southeastern of Turkey," *Thermal Science*, vol.22, no.2, 2018, s. 943-951.
- [41] H. Kılıç, B. Gümüş ve M. Yılmaz, "Diyarbakır İli İçin Güneş Enerjisi Verilerinin Meteorolojik Standartlarda Ölçülmesi ve Analizi," *EMO Bilimsel Dergi*, vol.5, no.10, 2016, s.15-19.
- [42] M. Yılmaz, B. Gümüş, H. Kılıç ve M. E. Asker, "Chaotic analysis of the global solar irradiance," 2017 IEEE 6th International Conference on Renewable Energy Research and Applications (ICRERA), 2017, s. 1058-1066
- [43] C. Shen, M. Sun, M., Tang, ve C. E. Priebe, "Generalized canonical correlation analysis for classification," *Journal of Multivariate Analysis*, vol.130, 2014, s. 310-322.
- [44] W. Zuobin, M. Kezhi ve G.-W. Ng, "Feature Regrouping for CCA-Based Feature Fusion and Extraction Through Normalized Cut," 2018 21st International Conference on Information Fusion (FUSION), 2018, s. 2275-2282.
- [45] A. Afifi, V. A. Clark ve Susanne May, Canonical Correlation Analysis | R Data Analysis Examples, UCLA: Statistical Consulting Group,2004, Erişim tarihi: 12 Temmuz 2022. <https://stats.oarc.ucla.edu/r/dae/canonical-correlation-analysis/>
- [46] Y. H. Pao ve Y. Takefuji, "Functional-link net computing: theory, system architecture, and functionalities," in *Computer*, vol. 25, no. 5, May 1992, s. 76-79.
- [47] Y.H. Pao, G.H. Park, ve D.J. Sobajic, "Learning and generalization characteristics of the random vector functional-link net," *Neurocomputing*, vol.6, no.2, 1994, s.163-180.
- [48] Q. Shi, R. Katuwal, P. N. Suganthan, ve M. Tanveer, "Random vector functional link neural network based ensemble deep learning" *Pattern Recognition*, vol.117, 2021, s.107978.
- [49] A. E. Hoerl ve R. W. Kennard, "Ridge regression: Applications to nonorthogonal problems," *Technometrics*, vol. 12, no. 1, 1970, s. 69-82.
- [50] H. T. Huynh ve Y. Won, "Regularized online sequential learning algorithm for single-hidden layer feedforward neural networks," *Pattern Recognit. Lett.*, vol. 32, no. 14, Oct. 2011, s. 1930-1935.
- [51] W. Dai, Q. Chen, F. Chu, X. Ma ve T. Chai, "Robust Regularized Random Vector Functional Link Network and Its Industrial Application," in *IEEE Access*, vol. 5, 2017, s. 16162-16172.

## Özgeçmişler



**Berrin Eryılmaz**, 1989 doğumlu, B.Sc. Gediz Üniversitesi Elektrik-elektronik Mühendisliği bölümünden 2014 yılında mezun oldu. Yüksek Lisans derecesini 2022 yılında Dicle Üniversitesi Fen Bilimleri Enstitüsü Yenilenebilir Enerji Kaynakları Anabilim Dalı'nda almıştır. Araştırmaları Makine öğrenimi tabanlı enerji tahminlemesi konularına odaklanmaktadır.



**Dr. Heybet Kılıç**, Gaziantep Üniversitesi'nde 2009 yılında Elektrik Elektronik Mühendisliği alanında lisans derecesini, 2016 yılında Elektrik ve Elektronik Mühendisliği alanında yüksek lisans derecesini ve 2021 yılında enerji sistemleri alanında doktora derecesini Dicle Üniversitesi'nden elde etmiştir. 2015 yılından bu yana Dicle Üniversitesi Elektrik Güç ve Enerji Bölümü'nde Yardımcı Doçent olarak görev yapmaktadır ve güç sistemleri, güç elektroniği ve yenilenebilir enerji sistemleri konularında dersler vermektedir. 2018-2020 yılları arasında ise Hollanda'daki TU Delft Elektrik Mühendisliği, Matematik ve Bilgisayar Bilimleri Fakültesi'nde Elektrikli Sürdürülebilir Enerji Departmanı'nda doktora araştırmacısı olarak görev yaptı. Araştırma ilgi alanları arasında fotovoltaikler, rüzgar enerjisinin dönüştürülmesi, güç sistemleri, mikro şebekeler, siber-fiziksel enerji sistemleri ve veri bilimi bulunmaktadır.



**Fatih Koçyiğit**, 1977 doğumlu, B.Sc. Dicle Üniversitesi Makine Mühendisliği bölümünden 2000 yılında mezun oldu. Yüksek Lisans ve Doktora derecelerini sırasıyla 2008 ve 2012 yıllarında Elazığ Fırat Üniversitesi Fen Bilimleri Enstitüsü Enerji Anabilim Dalı'nda almıştır. Halen Diyarbakır Dicle Üniversitesi'nde Doçent olarak çalışmaktadır. Araştırmaları ısı transferi, termodinamik, enerji, ekserji ve termal iletkenlik konularına odaklanmaktadır.



## Elazığ ilinde şebekeye bağlı 1036,8 kWp fotovoltaik güneş enerjisi santralının ölçülen ve simüle edilen performans verilerinin analizi

### Analysis of the measured and simulated performance data of a grid-connected 1036,8 kWp photovoltaic solar power plant in Elazığ

   
Zeynep TANIŞ, Nihan ALTINTAŞ\*

Elektrik Mühendisliği Bölümü, Yıldız Teknik Üniversitesi, İstanbul, Türkiye  
zynpctnts@gmail.com, naltin@yildiz.edu.tr\*

#### ÖZ

Bu çalışmada, Elazığ ilindeki 1036,8 kWp kurulu güce sahip Fotovoltaik Güneş Enerji Santralının Ocak-Aralık 2018 tarihleri arasında alınan performans verilerinin analizi sunulmuştur. Mevcut santral güneşe 30°'lik sabit eğime sahip, her biri 20 adet FV modülün birbirine seri bağlanmasıyla oluşan toplam 192 diziden meydana gelmektedir. Santralde 3840 adet 270Wp polikristal güneş paneli kullanılmış olup, 24 adet 36 kW string inverter ile şebekeye bağlantı gerçekleştirilmiştir. Santralden alınan üretim verileri ve PVsyst programı kullanılarak elde edilen simülasyon verileri birbiriyle karşılaştırılmıştır. Santralin 2018 yılına ait ölçülen ve tahmin edilen yıllık enerji verimleri sırasıyla 1575,12 kWh/kWp ve 1503,95 kWh/kWp olarak tespit edilmiştir. Verim değerleri arasındaki % 4,73'lük düşük yüzdelerlik fark, simülasyon sonuçlarının tesis hakkında güvenilir veriler sağladığını göstermektedir. Ölçülen hava durumu verilerine göre simülasyon gerçekleştirildiğinde tahmin edilen üretim değerinin gerçek üretim değerinden %0,63 daha az olduğu görülmüştür. Bu verileri PVsyst simülasyon programında girdi olarak kullanıldığında üretilen enerji değeri ölçülen sistemdeki enerji değerine yaklaştığı tespit edilmiştir.

Anahtar kelimeler: performans tahmini, şebeke-etkileşimli güneş santrali, kapasite faktörü, pvsyst.

#### ABSTRACT

In this study, the analysis of the performance data of the Photovoltaic Solar Power Plant with an installed power of 1036,8 kWp in the province of Elazığ between January and December 2018 is presented. The existing power plant consists of a total of 192 strings, each of which consists of 20 PV modules connected in series, with a constant slope of 30° to the south. 3840 pieces of 270Wp polycrystalline solar panels were used in the power plant, and connection to the grid was made with 24 pieces of 36 kW string inverters. Production data from the plant and simulation data obtained using the PVsyst program were compared with each other. The measured and estimated annual energy efficiencies of the power plant for 2018 were determined as 1575,12 kWh/kWp and 1503,95 kWh/kWp, respectively. The low percentage difference of 4,73% between the yield values indicates that the simulation results provide reliable data about the plant. When the simulation was performed according to the measured weather data, it was seen

that the estimated production value was 0,63 % higher than the actual production value. When this data is used as an input in the PVsyst simulation program, it has been determined that the energy value produced approaches the energy value in the measured system.


Keywords: performance estimation, grid-interactive solar plant, capacity factor, pvsyst.

#### 1. Giriş


Ülkelerin enerji ihtiyaçları her geçen gün artmaktadır. Hali hazırda tükenmekte olan konvansiyonel enerji kaynaklarına en önemli alternatif yenilenebilir enerji kaynaklarıdır. FV teknolojiden enerji üretimi; uygun fiyatlı, tükenmez, basit, az bakım ihtiyacı ve temizdir. Şebekeye bağlı FV güneş enerji santralleri bu özelliklerinden dolayı son yıllarda büyük çapta enerji elde etmenin en iyi alternatifi olarak görülmektedir. FV güneş enerji sistemleri verimlerinin düşük olması nedeniyle enerji üretimini geleneksel yollar ile yapan kömür, gaz ve nükleer santrallerinin yerini alabilecek seviyeye ulaşamamıştır. Bu sistemlerin maliyetini düşürmek ve verimini arttırmak için analiz, simülasyon ve donanım geliştirme alanlarında önemli ilerlemeler kaydedilmesine rağmen, kaliteli ve güvenilir elektrik enerjisi sağlamak için güç sisteminin uygun planlanması ve işletilmesi ile ilgili çalışmaların yapılmasına hala ihtiyaç vardır. Özellikle güneş enerjisinin potansiyelini ortaya çıkarmak ve uzun vadeli faydalar elde etmek için ülkelerinde uygun politikalar uygulaması gerekir. Türkiye güneş enerjisi bakımından dünyanın en zengin bölgeleri arasında yer almasına karşın FV santral yatırımlarının oldukça az olduğu gözlemlenmiştir [1]. T.C. Enerji Bakanlığının 2022 yılı Aralık ayında yayınladığı raporda, Türkiyedeki Güneş Enerji Santrallerinin kurulu gücünün 9425,4 MW seviyesine ulaştığı ve toplam FV Güneş Enerji Santral sayısının da 9353'e ulaştığı belirtilmiştir [2].

Güneş Enerjisi Potansiyel Atlası (GEPA) verilerine göre; Türkiye'nin güneşlenme süresi yıllık toplam 2741 saat iken günlük ortalama 7,5 saattir. Aynı zamanda metrekareye düşen yıllık toplam güneş enerjisi 1527 kWh/m<sup>2</sup>/yıl iken bu değer günlük ortalama 4,18 kWh/m<sup>2</sup>/gün'dür. Elazığ ilinin de içinde bulunduğu coğrafya kışın sert ve soğuk olmasına rağmen Türkiye'de en fazla ışıma alan bölgedir [3].

FV Güneş Enerjisi Santrali tarafından üretilen güç, güneşten yayılan güneş ışığına bağlıdır. Santralin kurulduğu bölge olan Elazığ ili tüm yıl boyunca güneş ışımasının daha fazla absorbe edildiği ve coğrafi olarak iyi konuma sahip bir bölgedir. Elazığ bölgesinde yer alan şebeke bağlantılı FV Güneş Enerjisi Santrali'nin yıl boyunca almış olduğu ışıma değerleri Şekil 1'de gösterilmiştir [4].



Şekil 1: Elazığ global radyasyon değerleri (kwh/m<sup>2</sup>/gün)



(a)



(b)

Şekil 2: FV güneş santralini a) coğrafi konumu, b) fotoğrafı

Yüksek rakımlı Elazığ ilinde havada oluşan su buharı, kar ve yağmur olarak yoğunlaştığı için atmosfer daha berraktır ve dolayısıyla ışıma engellenmesi de en düşük seviyededir. Şekil 2(a)'da Elazığ ilinde bulunan FV Güneş Santralini coğrafi konumu, Şekil 2(b)'de ise kurulu santrale ait görsel verilmiştir.

FV güneş enerji santrallerinin tasarım, ön fizibilite ve performans analizleri simülasyon programları yardımıyla yapılmaktadır. PVsyst simülasyon programı, FV Güneş Enerjisi Santralini performansını tahmin etmek için geliştirilmiş programlar arasında detaylı ve doğruya yakın verileri nedeniyle öne çıkmaktadır [5], [6]. Bu yazılım programı şebekeye bağlı yada şebekeden bağımsız DC güneş enerji sistemlerinin tasarımı ile girilen modül ve yer verilerine göre sistemlerin performans analizlerini yapar [7]. Meteorolojik veriler için yerleşik veritabanında coğrafi koordinatlar ile aylık hava durumu verilerini içeren veri kümesi vardır. Hava durumu verileri ve güneş ışıma verileri veri tabanında bulunmadığı takdirde; bu veriler NASA SSE [8], PVGIS [9], Metenorm [10] vb farklı veri kaynaklardan elde edilerek PVsyst veri tabanına girilir [11]-[15]. Gerçek meteoroloji verilerinin ölçümleri çok karmaşıktır. Bazı durumlarda önceden tanımlanmış kaynaklardan hiçbirini tatmin edici verileri sunamaz. Yerel hava istasyonu veya sensörler gibi daha iyi bir veri kaynağı varsa bu kaynakların verileri kullanılabilir.

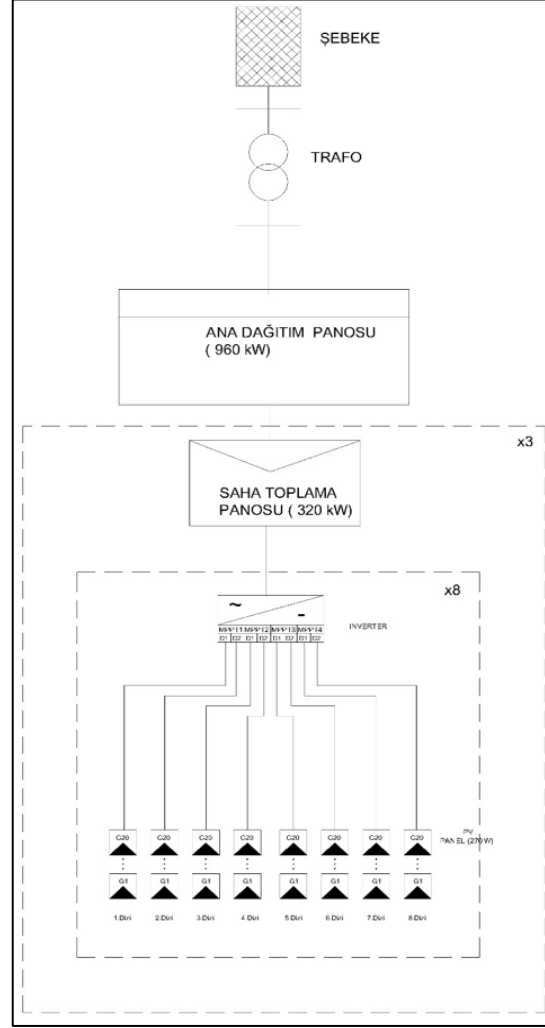
Bu çalışmada, FV güneş enerji üretiminin etkinliğini incelemek için 1036,8 kWp şebekeye bağlı FV Güneş Enerjisi Santralini performans analizleri yapılmıştır. Ocak 2018-Aralık 2018 ayları arasında toplanan gerçek veriler analiz edilip tesisin performans parametreleri hesaplanmıştır. Ölçülen değerler ile PVsyst yazılımı kullanılarak elde edilen değerler karşılaştırılmıştır. Simülasyon, Metenorm 7.1 tarafından üretilen meteorolojik uzun vadeli veriler kullanılarak gerçekleştirilmiştir.

Performans analizi, enerji üretiminin yakından takibini sağlayarak yeterli bakım planlarının oluşturulmasına yön göstermektedir. FV sistemin ürettiği enerjinin ve sistem verimliliğinin zamana bağlı değişimi maliyet açısından önemlidir. Dolayısıyla büyüyen FV endüstrisine kurulacak FV sistemin ömrü boyunca üreteceği enerji miktarı ile ilgili doğru tahminler verebilmek çok önemlidir. Bu yönüyle çalışma, gelecekte yapılacak sistemlere referans olacağı için Türkiye ve Elazığ ilindeki FV endüstrisi için önem taşımaktadır.

## 2. Güneş Santralini Özellikleri

1036,8 kWp kurulu güce sahip FV Güneş Enerjisi Santrali 38,68°N, 39,83°E koordinatlarında ve 962m rakımda bulunmaktadır. Şekil 3'de verilen genel bağlantı şemasında da görüldüğü gibi santral güneş panelleri, inverterler, saha toplama panosu, ana dağıtım panosu trafo ve şebeke bağlantı ekipmanlarından oluşmaktadır. FV Güneş Enerjisi Santrali 270Wp değerinde 3840 adet





Şekil 3: FV güneş enerjisi santralının genel bağlantı şeması

CW Enerji firmasının CWT270-60PP adlı polikristal güneş panelinden oluşmaktadır. Paneller 30°'lik açı ile güneşe bakacak şekilde yerleştirilmiştir. Santralde toplam 192 dizi bulunmaktadır. Her bir dizi seri bağlı 20 adet güneş panelinden oluşur ve bu diziler string inverterlere bağlanır. Santralde Huawei firmasının 24 adet SUN2000-36KTL string inverterleri kullanılmıştır. İnverterler ile DC'den AC'ye çevrilen gerilimin değerini yükseltmek için 1250 kVA gücünde kuru tip hermetik trafo kullanılmıştır.

FV Güneş Enerjisi Santrali'nin yakınında bulunan entegre hava izleme istasyonu güneş ışınımı verilerini, rüzgar hızını, nemi ve yağmuru kaydeder. İnvertere entegre halinde bulunan data logger veri kaydedici, her bir inverterin giriş ve çıkışında güneş ışınımını, gerilimi, akımı, gücü ve ayrıca düzenli aralıklarla rüzgar hızı ve modül sıcaklığını kaydeder. Kayıt aralığı, IEC 61724 standardı [16] izleme klavuzlarına göre 1 dakika ile 10 dakika arasında olmalıdır. Merkezi Denetleme Kontrol ve Veri Toplama (SCADA) sistemi, tesisin izlenen verilerin değerlendirilmesinde kullanılır. Bilgileri sunucudan alır ve kontrol adalarındaki grafik ekranlarını günceller. Veri dosyaları periyodik olarak kaydedilir ve gerektiğinde alınabilir. Bu çalışmada Ocak 2018–Aralık 2018 dönemlerine ait veriler, veri kaydediciden alınmış ve performans parametreleri hesaplanmıştır.

Tablo 1: FV modülünün özellikleri

Maksimum güç ( $P_{max}$ )	270Wp
Maksimum güç gerilimi ( $V_{MP}$ )	32,22 V
Maksimum güç akımı ( $I_{MP}$ )	8,4 A
Açık devre gerilimi ( $V_{OC}$ )	38,1 V
Kısa devre gerilimi ( $I_{SC}$ )	8,94 A
$P_{max}$ sıcaklık katsayısı	0,44 %/°C
$V_{OC}$ sıcaklık katsayısı	-0,34 %/°C
$I_{SC}$ sıcaklık katsayısı	0,06 %/°C
Modül verimi STC	16,23 %

Tablo 2: İnvertere ait elektriksel özellikler

Maksimum DC güç ( $\cos\phi=1$ )	40,8 kW
Maksimum giriş gerilimi	1000 V
MPP voltaj aralığı	480V-850V
MPP sayısı	4
MPP dizi giriş sayısı	A2-B2-C2-D2
Giriş gerilimi	200V
Maksimum giriş akımı	4x22A
Nominal güç (25°C/50°C, 50Hz)	36 kW
Maksimum güç (25°C/50°C, 50Hz)	40 kW
Nominal AC frekans/gerilim	50 Hz/400V
Maksimum AC akım	57,8 A
Maksimum verim	98,8%

### 3. Performans Parametreleri

Şebekeye bağlı bir FV sistemin performansını analiz etmek için, Uluslararası Elektroteknik Komisyonu tarafından performans parametreleri (IEC 61724) belirlenmiştir [17]-[20]. Tablo 3'de verilen temel parametreler mevcut FV sistemin temel performans parametreleri olan performans oranı ve kapasite faktörünün belirlenmesi için kullanılır [21].

Tablo 3: Performans parametreleri

Parametre	Kısaltma	Denklem
Referans verimi	$Y_R$	$=H_T/G_{STC}$
Dizi verimi	$Y_A$	$=E_{DC}/P_{pvrate}$
Nihai verim	$Y_F$	$=E_{AC}/P_{pvrate}$
Sistem kaybı	$L_s$	$=Y_A - Y_F$
Dizi kaybı	$L_c$	$=Y_R - Y_A$
FV verimi	$n_{pv}$	$=(E_{DC}/A.H_T) \times 100$
Sistem verimi	$n_{sys}$	$=(E_{AC}/A.H_T) \times 100$
Inverter verimi	$n_{inv}$	$=(E_{AC}/E_{DC}) \times 100$
Performans oranı	PR	$=Y_F/Y_R$
Kapasite faktörü	CF	$=E_{AC,a}/(24*365*P_{pv.rate})$

FV dizelerden üretilen DC enerji  $E_{DC}$ , inverterden günlük üretilen AC enerji  $E_{AC}$ , bir yıl boyunca inverterde üretilen toplam enerji  $E_{AC,a}$ , inverter çıkışındaki AC kurulu güç  $P_{AC}$ , FV dizisinin standart test koşullarındaki nominal kurulu gücü  $P_{DC}$  (standart test koşulları:  $1\text{ kW/m}^2$  güneş ışınımı ve  $25^\circ\text{C}$ 'lik hücre sıcaklığı), DC kurulu güç  $P_{pvrate}$ , belli bir düzleme gelen toplam güneş ışınımı  $H_T$ , standart test koşullarındaki referans ışınım  $G_{STC}$ , dizi alanı  $A$  ile gösterilmektedir.

FV sistem tarafından üretilen toplam enerji ( $E_{AC}$ ), maksimum gücün anlık değerlerinin ölçüm aralığına entegrasyonu ile bulunur [33]. Üretilen enerji,

$$E_{AC} = \int_0^{t_s} P_{AC} dt \quad (1)$$

olarak hesaplanır. Burada  $t_s$  entegrasyon periyodu,  $d_t$  süre ve  $P_{AC}$  ise toplam AC kurulu güç değeridir [22].

Tablo 4: Simülasyon verileri

Aylar	Girdiler					Çıktılar		
	$G_{yatay}$ ( $\text{kWh/m}^2$ )	$D_{yatay}$ ( $\text{kWh/m}^2$ )	T ( $^\circ\text{C}$ )	$G_{modül}$ ( $\text{kWh/m}^2$ )	$G_{etken}$ ( $\text{kWh/m}^2$ )	$E_{dizi}$ (MWh)	$E_{şebeke}$ (MWh)	PR
Ocak	59,5	29,54	-1,24	91,6	88,9	91,1	89,7	0,945
Şubat	76,7	37,38	0,62	105,3	102,4	103,7	102,1	0,935
Mart	116,3	60,95	6,89	137,4	133,4	130,6	128,6	0,903
Nisan	136,1	74,45	11,80	143,0	138,5	132,3	130,2	0,878
Mayıs	179,4	78,15	17,08	176,2	170,7	157,7	155,0	0,849
Haziran	209,1	78,18	22,93	197,6	191,2	171,0	168,1	0,820
Temmuz	208,5	77,22	27,51	199,8	193,2	168,6	165,7	0,800
Ağustos	203,8	64,24	27,19	213,7	207,5	180,1	176,9	0,798
Eylül	150,7	50,55	20,92	176,5	171,9	152,7	150,1	0,820
Ekim	105,9	45,69	14,81	141,2	137,4	128,9	126,8	0,866
Kasım	64,5	29,83	6,73	94,6	91,9	89,9	88,4	0,902
Aralık	50,6	24,50	1,22	80,3	78,0	79,0	77,7	0,934
Yıllık	1561,1	650,69	13,11	1757,1	1704,8	1585,5	1559,2	0,856

### 4. Materyal ve Metot

#### 4.1 PVsyst simülasyon verileri


PVsyst programında meteorolojik veriler için yerleşik veritabanında coğrafi koordinatlar ile aylık hava durumu verilerini içeren veri kümesi bulunmaktadır. Fakat Elazığ iline ait hava durumu ve güneş ışınımı verileri veri tabanında bulunmadığı için ilgili veriler Metenorm 7.1 kaynağından alınarak programa yüklendi. Tablo 4'te programa girilen veriler ve programdan alınan çıktılar verilmiştir. Elazığ ilinde yer alan FV Güneş Enerjisi Santrali lokasyonuna ait meteorolojik veriler;  $G_{yatay}$  yatay düzleme gelen küresel ışınım,  $D_{yatay}$  yatay yayılı ışınım, T ortam sıcaklığı,  $G_{modül}$  FV modül yüzeyine gelen ışınım,  $G_{etken}$  etken global ışınım iken elde edilen çıktılar ise;  $E_{dizi}$  dizi çıkışındaki etkin enerji,  $E_{şebeke}$  şebekeye verilen enerji, PR performans oranıdır. Böylece simülasyon programı yardımıyla FV Güneş Enerjisi Santralinin yıl boyunca üretmesi tahmin edilen enerji üretim verileri detaylı bir şekilde elde edilmiştir.

Ayrıca programdan elde edilen mevcut FV santraline ait kayıp şeması Şekil 4'de görülmektedir. Kayıp şeması sayesinde, ana kayıp kaynakları ayrıntılı olarak görüldüğü için daha kaliteli sistem tasarımı yapılabilmektedir. Kayıp hesaplaması ilk olarak, standart test koşullarında global etkili ışınım ve dizilerin nominal enerjisi ile yapılır. Daha sonra sistem tipine göre farklı türden kayıplar dikkate alınır. Her kayıp, önceki enerjinin yüzde değeri olarak tanımlanır. Kayıp

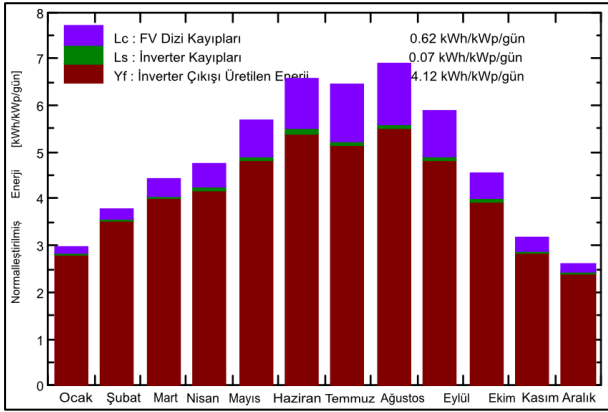
diyagramı bir yıllık yada aylık olarak ayrıntılı bir şekilde gösterilebilir.

Şekil 4'ten FV dizisinde üretilen nominal enerjinin 1774 MWh olduğu görülmektedir. Sonuçlar şebekeye aktarılan enerjinin 1559 MWh olduğunu ve tüm sistemin %13,4'lük bir kayba sahip olduğunu göstermektedir.

Şekil 5'te,  $L_c$  FV dizi kayıpları ve diğer kayıplar dâhil olmak üzere sistem kayıpları ve  $Y_f$  nihai verim inverter çıkışı üretilen enerji ( $\text{kWh/kWp/gün}$ ) görülmektedir. Farklı sistemler arasındaki karşılaştırmayı kolaylaştırmak için dizi standart test koşullar altında, nominal kurulu gücü ile normalize edilir. Haziran, Temmuz ve Ağustos ayları en yüksek enerji üretimine ve aynı zamanda en yüksek dizi ve inverter kayıplarına sahip aylardır. Bu durum yılın yaz sezonundaki yüksek sıcaklığın dizi ve inverter kayıplarını arttırdığını gösterir. Dizi kayıpları, FV modüllerin verimliliğini belirler. İnverter kayıpları DC enerjii AC enerjiye dönüştürürken kaybolan enerji olarak tanımlanabilir. Kullanılan inverterlerin verimliliği ne kadar yüksek olursa sistem kayıpları o kadar az olacaktır.




Şekil 4: FV santrale ait kayıp şeması




Şekil 5: İnverter çıkışı enerji üretimi ve kayıplar

#### 4.2 Hava durumu verileri

Şekil 6 ve 7'de PVsyst programında girdi olarak kullanılan hava durumu verileri ile gerçek ölçülen hava durumu verileri karşılaştırılmıştır. Aylık ortalama güneş radyasyonu için Metenorm 7.1'den türetilen uzun vadeli (2003-2010) ortalama değerler kullanılmıştır. Şekil 6'dan görüldüğü gibi, Temmuz ve Ağustos güneş ışınımının en iyi olduğu aylar iken, Aralık ve Ocak ışınımının en düşük olduğu aylardır.



Şekil 6: Ölçülen ve Metenorm'dan Türetilen Aylık Ortalama Güneş Işınımları




Şekil 7: Ölçülen ve Metenorm'dan Türetilen Aylık Ortalama Ortam Sıcaklıkları


#### 4.3 Performans verileri

FV sistemden elektrik enerjisi üretim miktarı, FV sistemdeki modüller, hücre sıcaklığı, güneşin geliş açısı, yük direnci ve birçok faktöre bağlıdır [23].

Şekil 8, Elazığ ilinde yer alan FV Güneş Enerjisi Santrali için aylık enerji üretimini göstermektedir ve Şekil 9'da verilen ölçülen ışınım verileri ile aynı eğilimi takip etmektedir. Bir FV sisteminin sistem performansı, ürettiği elektrik enerjisi ile belirlenir.



Şekil 8: Elazığ ili FV güneş enerjisi santralinin aylık enerji üretimi




Şekil 9: Ölçülen aylık ortalama toplam güneş ışınımı verileri


#### 4.3.1 Şebekeye aktarılan toplam enerji (E<sub>AC</sub>)

Anlık enerji çıkışı, 5 dakika aralıklarla inverter çıkışında şebekeye verilen enerjinin ölçülmesiyle elde edildi [24].

Santralin Ocak 2018-Aralık 2018 tarihleri arasında ölçülen ortalama enerji üretimi 1633,09 MWh olarak bulunmuştur. Tahmini enerji üretimi ise PVsyst simülasyon programı kullanılarak 1559,30 MWh olarak hesaplanmıştır. Tahmini enerji üretimi % 4,73'lik bir fark ile ölçülen değere yakın çıkmıştır. Aradaki fark, PVsyst'in ölçülen hava durumu verilerinden ve sistemin sadece ilk yıl üretimi ile kıyaslanmış olmasındandır. Modüller zamanla verim kaybı yaşar. PVsyst'te 25 yıl boyunca yaşanan bu verim kayıplarını göz önünde bulundurarak hesaplama yaptığımız PVsyst sonuçları üretilen enerjiden daha az çıkmıştır. Ölçülen hava durumu verilerine göre simülasyon gerçekleştirildiğinde tahmin edilen üretim değeri 1622,8 MWh olup, gerçek üretim değeri 1633,09 MWh olan sonuçtan %0,63 daha az çıkmıştır. Dolayısıyla ölçülen hava durumu verileri programda girdi olarak kullanıldığında üretilen enerji değerinin ölçülen sistemdeki enerji değerlerine daha da yaklaştığı görülmüştür. Şekil 10'da şebekeye verilen aylık toplam enerjinin gerçek ve tahmini değerleri görülmektedir. Şebekeye verilen aylık toplam enerji Aralık ayında 31,4 MWh ile en düşük seviyede iken Temmuz ayında 199,6 MWh değeri ile en yüksek seviyesine ulaştı. Enerji üretimi, ışınımına bağlıdır. Ayrıca, enerji üretiminin sıcaklıktaki değişiklikten etkilendiği de gözlenmiştir. Ölçülen enerji değeri ile tahmin edilen enerji arasındaki fark en yüksek Aralık ayında gözlemlenmiştir. Bunun sebebi ise ölçülen ve simülasyonda kullanılan ışınım değerlerinin arasındaki farkın en fazla bu ay olmasından kaynaklanmaktadır.



Şekil 10: Tahmin edilen ve ölçülen şebekeye aktarılan aylık toplam enerji




Şekil 11: Ölçülen ve simüle edilen aylık referans verimi

#### 4.3.2 Referans verim (Y<sub>R</sub>)

Referans verim Y<sub>R</sub>, toplam düzleme gelen güneş ışınım H<sub>T</sub> (kWh/m<sup>2</sup>)'nin standart test koşullarındaki referans ışınım G<sub>STC</sub> (kW/m<sup>2</sup>) değerine bölünmesi ile elde edilir [25]. Şekil 11, ölçülen ve simüle edilen aylık ortalama referans verimi göstermektedir. Ölçülen maksimum referans verim Ağustos ayında yaklaşık 7,55 saat/gün iken tahmini en yüksek referans verim de Ağustos ayında 6,89 saat/gün olarak görülmektedir.

#### 4.3.3 Nihai verim (Y<sub>F</sub>)

Nihai verim Y<sub>F</sub>, üretilen enerjinin normalizasyonuna izin veren ideal bir göstergedir [26]-[27]. Nihai verim Y<sub>F</sub>, üretilen yıllık, aylık veya günlük net enerji olan E<sub>AC</sub>'nin P<sub>DC</sub>'e bölünmesi ile hesaplanır. P<sub>DC</sub>, kurulu FV dizisinin standart test koşullarındaki (1kW/m<sup>2</sup> güneş ışınımı ve 25°C'lik hücre sıcaklığı) nominal gücü olarak tanımlanır. Şekil 12'de, ölçülen ve simüle edilen nihai verim görülmektedir. Ölçülen maksimum nihai verim değeri 6,21 kWh/kWp/gün ile Temmuz ayında iken, simülasyon sonuçlarında 5,50 kWh/kWp/gün ile Ağustos ayında elde edilmiştir. Nihai verimin ışınım ve sıcaklık değerleriyle orantılı olduğu görülmüştür.



Şekil 12: Ölçülen ve simüle edilen nihai verim


#### 4.3.4 Performans oranı (PR)

Performans oranı PR, alınan ışınımın şebekeyi besleyen enerjisi normalleştiren bir göstergedir. Farklı bölgelerde ve farklı zamanlarda FV sistemlerinin performanslarını karşılaştırmak ve değerlendirmek için kullanılır [24], [28]. PR, Güneş Enerjisi Santrallerinin verimliliğini ölçmek için kullanılan en önemli parametrelerden biridir. PR bir sistemin kurulum kalitesini belirtmek için kullanılır, ancak üretilen enerji miktarını belirtmez. Literatürde iyi bir ışınlanma

bölgesinde bulunan düşük PR sisteminin, daha düşük bir ışınlama bölgesinde bulunan yüksek PR sisteminden daha fazla enerji üretme olasılığının olduğu görülmüştür [29]. Başka bir araştırmanın bulguları, PR'nın değerinin artmasıyla güneş enerjisinin elektrik enerjisine dönüşüm oranının arttığını kanıtlamaktadır [30].

Genel olarak, FV sistemlerin performans bozulmasının sadece FV modüllerden kaynaklandığı varsayılmaktadır. Ancak performansı değerlendirirken, sistem ile hava durumu verileri arasındaki dengeye bakılması tavsiye edilir [31]. PR, 0,1 ile 0,99 aralığındadır. PR değerinin 1'e yaklaşması sistem performansının daha iyi olduğunu gösterir. PR değerini 100 ile çarpmak, performans açısından verimlilik yüzdesini verir.

NREL (Uluslararası Yenilenebilir Enerji Laboratuvarı), yeni bir sistemin standart PR'sinin en az %77 olması gerektiğini ve sistemin performansının yıllık bazda yaklaşık %1 azaldığını bildirmiştir [29]. Elazığ ilinde yer alan FV Güneş Enerjisi Santrali için PVsyst programından hesaplanan yıllık ortalama PR %85,61'dir. Şekil 13'de ölçülen ve tahmin edilen aylık ortalama performans oranı grafiği görülmektedir.




Şekil 13: Ölçülen ve simüle edilen performans oranı


#### 4.3.5 Kapasite faktörü (CF)

FV sisteminin kapasite faktörü CF, belli bir zaman dilimi boyunca enerji üretim tesisinin ölçülen çıktısı ile tüm zaman zarfında değerini tam kapasitesinde çalışmış varsayılan potansiyel çıkışı arasındaki orandır [32].

CF, gerçek yıllık enerji çıkışı  $E_{AC}$ 'nin, bir yıl boyunca günde 24 saat tam güçte  $P_{DC}$ 'de çalıştırıldığı takdirde güneş FV sistemin üreteceği enerji miktarına oranı olarak tanımlanır [24]. Simüle edilen ve ölçülen aylık kapasite faktörü Şekil 14'de görülmektedir. Yıllık ortalama kapasite faktörü ölçülen sistemde %17,98 iken, simüle edilen sistemde %17,15 olarak bulunmuştur. Bu parametrede çevresel değişiklikler, yani sıcaklık, ışınım ve FV modüllerin bozulması göz önüne alınmamıştır. Dahası, FV sistemin günde 24 saat güç ürettiğini varsaymaktadır ki bu gerçekte geçerli değildir. Yüksek güneş ışınımının olduğu bölgelerdeki FV sistemlerin % 20,8 ile % 26 arasında CF değerlerine sahip olması beklenir [33].



Şekil 14: Ölçülen ve simüle edilen kapasite faktörü



Şekil 15: Ölçülen ve simüle edilen sistem verimliliği

#### 4.3.5 Sistem verimliliği (n<sub>sys</sub>)

FV sistemlerinin enerji performansı, bu sistemlerde kullanılan ekipmanların genel verimliliğine bağlıdır [34]. Sistem verimliliği  $n_{sys}$ , sistem tarafından üretilen enerjinin FV yüzey oranına yansıyan radyasyon miktarına göre hesaplanır. Yıllık, aylık ve hatta günlük periyotlarda hesaplanabilir [35]. Şekil 15, FV Güneş Enerji Santrali'nin ölçülen ve tahmin edilen sistem verimliliğini göstermektedir. Ortalama ölçülen sistem veriminin (%13,78) simüle edilen sistem veriminden (%14,45) daha az olması bunun Ocak, Ocak ve Şubat aylarında kaydedilen elektrik üretim azlığından kaynaklandığını göstermektedir.

Ayrıca santralin 2018 yılına ait ortalama yıllık ölçülen enerji verimi ise 1575,12 kWh/kWp olup, simüle edilen enerji verimi PVsyst simülasyon programı kullanılarak 1503,95 kWh/kWp olarak bulunmuştur. Ölçülen ve simüle edilen enerji verimi arasındaki farklılıklar PVsyst'teki kayıpların fiili işletme kayıplarından farklı olmasından ve hava durumu tahminlerinin farklılıklarından kaynaklanmaktadır.

## 6. Sonuçlar

FV sistemlerin kullanımı son yıllarda geleneksel fosil yakıtların azalması ve çevre sorunlarının giderek artması sebebiyle hızla artmaktadır. FV teknolojisinin diğer güneş enerjisi teknolojilerine kıyasla kurulumu daha kolay ve ucuzdur. Fakat günümüzde güneş enerjisi ile üretilen elektrik hala dünyanın enerji dağıtımında küçük bir paya sahiptir. Bu nedenle yapılan her çalışmayla FV güneş enerji sistemlerinin dünya üzerinde kurulumunun artmasına ve insanlığın temiz

ve ucuz enerjiye ulaşılma şanslarının artmasına katkıda bulunmaktadır.

İlgili çalışmada Ocak 2018-Aralık 2018 tarihleri arasında Elazığ ilinde yeralan FV Güneş Enerjisi Santralinden toplanan gerçek veriler analiz edilerek tesisin performans parametreleri hesaplanmıştır. Ölçülen değerler ile PVSyst yazılımı kullanılarak elde edilen değerler karşılaştırılmıştır. Simülasyon. Metenorm 7.1 tarafından üretilen meteorolojik uzun vadeli veriler kullanılarak gerçekleştirilmiştir. Karşılaştırma sonuçlarının birbirine yakın çıkması santralin güç üretiminin yakından takip edilmesine ve yeterli bakım planlarının oluşturulmasına imkan sağlayacaktır. Ayrıca gelecekte kurulacak olan FV güneş enerji santrallerinin performans tahminlerinin hesaplanmasında iyi bir referans olacaktır. Bu çalışmadan elde edilen sonuçlar aşağıda özetlenmiştir.

- Ocak 2018-Aralık 2018 arasında ortalama radyasyon değeri ölçülen sistemde 138,57 kWh/m<sup>2</sup> iken Metenorm 7.1 verilerine göre ise 130,09 kWh/m<sup>2</sup> olarak hesaplanmıştır. Ölçülen sistemdeki ortalama radyasyon değerlerinin Metenorm 7.1 verilerine kıyasla %6,52 daha fazla olduğu gözlenmiştir.

- Ocak 2018-Aralık 2018 arasında ortalama sıcaklık değeri ölçülen sistemde 15,44°C iken Metenorm 7.1 verilerine göre ise 13,04°C olarak hesaplanmıştır. Ölçülen sistemdeki ortalama sıcaklık değerlerinin Metenorm 7.1 verilerine kıyasla %18,4 daha fazla olduğu gözlenmiştir.

- FV sistemi tarafından Ocak 2018-Aralık 2018 arasında üretilen toplam enerji 1.633,093 MWh iken tahmin edilen üretim değeri ise 1559,3 MWh olmuştur. Dolayısıyla ölçülen sistemdeki toplam enerji değeri simüle edilen sistemdeki enerji üretim değerinden %4,73 daha fazla çıkmıştır. Ölçülen veriler santralin ilk yılına ait sonuçlardır. Dolayısı ile FV modülün en maksimum verimde olduğu çalışma zamanı dikkate alınmış olup zaman içerisindeki modül degradasyonu dikkate alınmamıştır. Bu sebeple gerçek üretim değerleri simülasyon verilerinden daha fazla çıkmıştır.

- Ölçülen ve simüle edilen aylık enerji verimi arasında daha iyi bir karşılaştırma yapmak için sahada ölçülen hava verileri kullanılarak simülasyon yapılmalıdır. Ölçülen hava durumu verilerine göre simülasyon gerçekleştirildiğinde tahmin edilen üretim değeri 1622,8 MWh olup gerçek üretim değeri 1633,093 MWh olan sonuçtan %0,63 daha az olduğu görülmüştür. Dolayısıyla ölçülen hava durumu verileri PVSyst simülasyon programında girdi olarak kullanıldığında üretilen enerji değerinin ölçülen sistemdeki enerji değerlerine daha da yaklaştığı görülmüştür.

- Ocak 2018-Aralık 2018 arasında ortalama performans oranı ölçülen sistemde %83,78 olarak bulunurken. Metenorm 7.1 verilerine göre ise %85,61 olarak hesaplanmıştır. Ölçülen sistemdeki performans oranının simüle edilen sistem verilerine kıyasla %2,18 daha az olduğu gözlenmiştir. Ölçülen yıllık performans oranının Elazığ bölgesinde güneş enerjisi üretimi için güneş potansiyelinin uygun olduğunu göstermektedir.

## 7. Kaynaklar

[1] E. Akcan, M. Kuncan, ve M.R. Minaz, "Pvsyst Yazılımı ile 30 kW Şebekeye Bağlı Fotovoltaik Sistemin Modelenmesi ve Simülasyonu", Avrupa Bilim ve Teknoloji Dergisi, c. 18, ss. 248-261, Mart-Nisan 2020.

[2] Solarist Güneş Enerjisi Portalı, URL: <https://www.solar.ist/wp-content/uploads/2023/01/Aral%CC%8c%CC%A7-Raporu.pdf> (Erişim zamanı; 05, 29, 2023).

[3] T.C Enerji ve Tabii Kaynaklar Bakanlığı, URL: <https://enerji.gov.tr/bilgi-merkezi-enerji-gunes> (Erişim zamanı; 05, 29, 2023).

[4] T.C Enerji ve Tabii Kaynaklar Bakanlığı, URL: <https://gepa.enerji.gov.tr/MyCalculator/pages/23.aspx> (Erişim zamanı; 05, 29, 2023).

[5] PVSyst Tutorials, URL: <https://www.pvsyst.com/wp-content/pdf-tutorials/pvsyst-tutorial-v6-grid-connected-en.pdf> (Erişim zamanı; 07, 18, 2021).

[6] PVSyst Help, URL: <http://files.pvsyst.com/help/> (Erişim zamanı; 07, 18, 2021).

[7] K. Mertens, Photovoltaics: Fundamentals. Technology and Practice, Wiley, UK, 2018.

[8] K. Bakirci, "Evaluation of models for prediction of diffuse solar radiation and comparison with satellite values", Journal of Cleaner Production, c. 374, ss. 133892, Kasım 2022.

[9] L. Queval, "Estimation of the electricity production of a PV installation using PVGIS", Engineering school, CentraleSupélec, France, 2023.

[10] D. D. Milosavljević, T. S. Kevkić ve S. J. Jovanović, "Review and Validation of Photovoltaic Solar Simulation Tools/Software Based on Case Study", Open Physics, c. 20, sayı 1, ss. 431-451, Mayıs 2022.

[11] C. Haydaroglu ve B. Gümüş, "Dicle Üniversitesi Güneş Enerjisi Santralinin Pvsyst ile Simülasyonu ve Performans Parametrelerinin Değerlendirilmesi", Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, c. 7, sayı 3, ss. 491-500, Aralık 2016.

[12] M. R. Sancar ve A. B. Bayram, "Modeling and Economic Analysis of Greenhouse Top Solar Power Plant with Pvsyst Software", International Journal of Engineering and Innovative Research, c. 5, sayı 1, ss. 48-59, Ocak 2023.

[13] A. T. İnan ve A. Şimşek, "Solar Power Plant Efficiency and Economically Analysis in Different Regional Climate for Selected Cities in Turkey", International Journal of Advances in Engineering and Pure Sciences, c. 34, sayı 4, ss. 603-610, Aralık 2022.

[14] C. Bakır ve A. Yılcıncı, "Türkiye'deki Farklı İller İçin Şebekeye Bağlı Arazi ve Çatı Tipi Lisanssız Fotovoltaik Güç Santrallerinin Tekno-Ekonomik Analizi", Mühendis ve Makina, c. 63, sayı 709, ss. 560-584, Aralık 2022.

[15] L. C. Kumruoğlu ve S. B. Ateş, "Türkiye'nin Güneş Enerjisi Potansiyeli ve İskenderun için Örnek Üretim Projeksiyonu", Çukurova Üniversitesi Mühendislik Fakültesi Dergisi, c. 37, sayı 1, ss. 293-305, Nisan 2022.

[16] National Renewable Energy Laboratory, URL: [https://www.nrel.gov/pv/assets/pdfs/2014\\_pvmrw\\_84\\_gostein.pdf](https://www.nrel.gov/pv/assets/pdfs/2014_pvmrw_84_gostein.pdf) (Erişim zamanı; 07, 30, 2021).

[17] B. Marion, J. Adelstein, K. Boyle, H. Hayden, B. Hammond ve T. Fletcher, "Performance Parameters for Grid-Connected PV Systems", Thirty-first IEEE Photovoltaic Specialists Conference, 2005, ss. 1601-1606.

[18] A. Haibaoui, B. Hartiti, A. Elamim, M. Karami ve A. Ridah, "Performance Indicators for Grid-Connected PV Systems: A Case Study in Casablanca, Morocco", IOSR Journal of Electrical and Electronics Engineering, c. 12, sayı 2, ss. 55-65, Mart-Nisan 2017.

[19] F. Cherfa, A.H. Arab, R. Oussaid, K. Abdeladim, ve S. Boychakour, "Performance Analysis of the Mini-Grid Connected Photovoltaics System at Algiers", Energy Procedia, c. 83, ss. 226-236, Aralık 2015.

[20] N. Pearsall, The Performance of Photovoltaic (PV) Systems: Modelling, Measurement and Assessment, Woodhead Publishing, UK, 2016.

- [21] A.F. Minai, T. Usmani, M.A. Alotaibi, H. Malik ve M.E. Nassar, "Performance Analysis and Comparative Study of a 467.2 kWp Grid-Interactive SPV System: A Case Study", *Energies*, c. 15, sayı 3, ss. 1107, Şubat 2022.
- [22] M.E. Başoğlu, A. Kazdaloğlu, T. Erfidan, M.Z. Bilgin, ve B. Çakır, "Performance Analyzes of Different Photovoltaic Module Technologies under Izmit, Kocaeli Climatic Conditions", *Renewable and Sustainable Energy Reviews*, c. 52, ss. 357-365, Aralık 2015.
- [23] M. Diez-Mesiavilla, C. Alonso-Tristan, M.C. Rodriguez-Amigo, T. Garcia-Calderon ve M.I. Dieste-Velasco, "Performance Analysis of PV Plants: Optimization for Improving Profitability", *Energy Conversion and Management*, c. 54, sayı 1, ss. 17-23, Şubat 2012.
- [24] L.M. Ayompe, A. Duffy, S.J. McCormack ve M. Conlon, "Measured Performance of a 1.72 kW Rooftop Grid Connected Photovoltaic System in Ireland", *Energy Conversion and Management*, c. 52, sayı 2, ss. 816-825, Şubat 2011.
- [25] E. Kymakis, S. Kalykakis ve T.M. Papazoglou, "Performance Analysis of a Grid Connected Photovoltaic Park on the Island of Crete", *Energy Conversion and Management*, c. 50, sayı 3, ss. 433-438, Mart 2009.
- [26] A. Al-Otaibi, A. Al-Qattan, F. Fairouz ve A. Al-Mulla, "Performance Evaluation of Photovoltaic Systems on Kuwaiti Schools' Rooftop", *Energy Conversion and Management*, c.95, ss. 110-119, Mayıs 2015.
- [27] A. Allouhi, R. Saadani, T. Kousksou, R. Saidur, A. Jamil ve M. Rahmoune, "Grid-Connected PV System Installed on Institutional Buildings: Technology Comparison. Energy Analysis and Economic Performance", *Energy and Buildings*, c. 130, ss. 188-201, Ekim 2005.
- [28] S. Rehman ve I. El-Amin, "Performance Evaluation of an Off-Grid Photovoltaic System in Saudi Arabia", *Energy*, c. 46, sayı 1, ss. 451-458, Ekim 2012.
- [29] A.A. Babatunde ve S. Abbasoğlu, "Evaluation of Field Data and Simulation Results of a Photovoltaic System in Countries with High Solar Radiation", *Turkish Journal of Electrical & Computer Sciences*, c. 23, sayı 6, ss. 1608-1618, Kasım 2015.
- [30] R. Faranda, M. Gualdoni, S. Leva, M. Monaco ve A. Timidei, "Analysis of a PV System with Single-Axis Tracking Energy Production and Performances", 3rd International Conference on Clean Electrical Power, Ocak 2011, ss. 130-136.
- [31] R. Bohra, Performance Analysis of 1 MW SPV Plant; Temperature Corrected PR, Malpani Group, India, Tech. Report, 2014.
- [32] E.N. Kumi ve A. Brew-Hammond, "Design and Analysis of a 1 MW Grid-Connected Solar PV system in Ghana", *African Technology Policy Studies Network*, 2013, ss. 24.
- [33] R. Gottschalg, T.R. Betts, D.G. Infield ve M.J. Kearney, "The Effect of Spectral Variations on the Performance Parameters of Single and Double Junction Amorphous Silicon Solar Cells", *Solar Energy Materials and Solar Cells*, c. 85, sayı 3, ss. 415-428, Ocak 2005.
- [34] A. Guenounou, A. Malek ve M. Aillerie, "Comparative Performance of PV Panels of Different Technologies Over One Year of Exposure: Application to a Coastal Mediterranean Region of Algeria", *Energy Conversion and Management*, c. 114, ss. 356-363, Nisan 2016.
- [35] M. Adaramola ve E. Vagnes, "Preliminary Assessment of a Small-Scale Rooftop PV Grid Tied in Norwegian Climatic Conditions", *Energy Conversion and Management*, c. 90, ss. 458-465, Ocak 2015.

## Özgeçmişler



**Zeynep Tanış**, Marmara Üniversitesi Elektrik-Elektronik Mühendisliği (%100 İngilizce) Bölümü lisans eğitimini 2010-2015 yılları arasında tamamladı. Lisans eğitimini tamamladıktan sonra Solvo Solar Enerji firmasında Proje Mühendisi olarak 2019 tarihine kadar çalıştı. Çalışma hayatının yanısıra Yıldız Teknik Üniversitesi Elektrik Mühendisliği Bölümü, Elektrik Makinaları ve Güç Elektroniği Anabilim Dalı'nda yüksek lisansını 2016-2019 yılları arasında tamamladı. Şu anda 2019 yılında başladığı Yıldız Teknik Üniversitesi Elektrik Mühendisliği Bölümü, Elektrik Makinaları ve Güç Elektroniği Anabilim Dalı'nda doktora eğitimine devam etmektedir.



**Nihan Altıntaş**, lisans, yüksek lisans ve doktora eğitimini Yıldız Teknik Üniversitesi, Elektrik Mühendisliği Bölümü'nde tamamlamıştır. 2015 yılında Wisconsin Medison Üniversitesinde post-doktora çalışmalarında bulunmuştur. Halen Yıldız Teknik Üniversitesi Elektrik Mühendisliği Bölümü'nde Dr.Öğr.Üyesi olarak görev yapmakta ve Güç Elektroniği alanında eğitim-öğretim ve araştırma faaliyetlerinde bulunmaya devam etmektedir. Başlıca çalışma konuları, DC-DC dönüştürücüler, Yumuşak anahtarlama, Güç faktörü düzeltme, Endüksiyonla ısıtma, Elektrikli araçlar ve Yenilenebilir enerji sistemleridir. Güç elektroniği alanında çok sayıda dergi ve konferans makalesi bulunmaktadır.



# Kablosuz Ağlarda Farklı Gölgeleyen Kanallar Üzerinden Enerji-Verimli Veri İletimi için Makine Öğrenmesi-temelli Su-Doldurma Algoritması

## Performance of Machine Learning-based Water-Filling Algorithm for Energy Efficient Data Transmission over Different Fading Channels in Wireless Networks

 Ömer Melih Gül

Bilgisayar Mühendisliği Bölümü  
Bahçeşehir Üniversitesi, İstanbul, Türkiye  
Email: omermelih.gul@bau.edu.tr

**Özetçe**—Bu çalışmada, kablosuz ağlarda çoklu gölgeleyen kanallar üzerinden bir kaynak tahsisi problemi ele alınmaktadır. Bu çalışmada önceki çalışmalardan farklı olarak, anlık veri iletim hızı sadece ayrık bir kümedeki veri iletim hızı değerlerinden birini alabilir. Bu probleme makine öğrenmesi-temelli çevrimiçi su doldurma algoritmaları önerilmiştir. Çevrimiçi ve en iyi çevrimdışı politikaların görece performansı, çeşitli tiplerde (Rayleigh, Rician, Nakagami, Weibull) gölgeleyen kanallar için çeşitli zaman ufuklarında değerlendirilmektedir. Sayısal sonuçlar, özellikle daha uzun zaman ufukları için bu çevrim içi su doldurma algoritmalarının çevrim dışı su doldurma algoritmalarına yakın performansı olduğunu göstermektedir.

**Anahtar Kelimeler** — Su-Doldurma, Makine Öğrenmesi, Çoklu Erişim Haberleşmesi, Çevrimiçi Politika

**Abstract**—In this paper, we tackle a resource allocation problem over multiple fading channels in wireless networks. Differing from previous studies, the data transmission rate can take a value out of a discrete set of data transmission rates in this work. We propose machine-learning-based online waterfilling algorithms for this problem. The relative performance of the online and optimal offline policies are evaluated for various types of fading channels (Rayleigh, Rician, Nakagami, Weibull) over various time horizons. The numerical results demonstrate these online waterfilling algorithms shows close performance to offline waterfilling algorithms especially for longer time horizons.

**Keywords** — Water-Filling, Machine Learning, Multi-access Communications, Online Policy

### I. GİRİŞ

Bu kısımda, öncelikle incelenen problemin güdülenmesi verilmektedir. Sonraki alt kısımda, problemin ilgili literatüründeki yakın çalışmalardan bahsedilmiştir. Daha sonraki alt kısımda, bu makalede literatüre yapılan ana katkılar özetlenmiştir. Son alt kısımda, makalenin geriye kalan kısmının teşkili verilmiştir.

### A. Güdüleme

Sıfır gecikme süresi, daha yüksek güvenilirlik ve yüksek hızlara sahip olacak beşinci nesil iletişimin (5G) bir sonucu olarak gezici ekosistemlerin yeni yollarla genişleyeceği tahmin edilmektedir. Qualcomm'un internet sitesine [1] göre 5G, sayısallaştırılmış lojistik, uzaktan sağlık, hassas tarım ve daha güvenli ulaşım sağladığı için neredeyse tüm işletmeleri etkileyecektir. Doğrudan iletişim, 5G teknolojisinin önemli bir bileşeni olacaktır. Gezici stratejiler düşünüldüğünde, gelişen dönem ulaşımı ve yaygınlaşan gezici hizmetler, önemli miktarda enerji kullanımına yol açmakta ve bu da cihazdan cihaza iletişimin gerçekleşmesini engellemektedir. Sınırlı menzili nedeniyle veri aktarımı, yeni gezici uygulamalar ve iş modellerine olanak sağlayacaktır [2].

Haberleşme sistemlerinde veri iletiminin verimliliğini en yükseltmek için su doldurma algoritmaları mutlak bir gerekliliktir. Bu algoritmalar, diğer şeylerin yanı sıra kablosuz haberleşme sistemlerinin tasarımını, ağ eniyileştirmesini ve kaynak tahsisini etkiler [3], [4], [5], [6], [7], [8], [9], [10], [11]. Bunlar, genellikle çok boyutlu haberleşme sistemlerinde kaynakların tahsisi süreci için gereklidir. Son on yılda kablosuz sistemlerin gelişmesiyle birlikte farklı fiziksel sınırlamalar ve performans ihtiyaçları ortaya çıkmıştır. Bu durum, tek su seviyeli çözümlerden çoklu su seviyeli çözümlere ve ideal kanal durum bilgisi (KDB)-tabanlı çözümlerden gürbüz çözümlere kadar çeşitli su doldurma politikalarına yol açmaktadır [12].

### B. İlgili Literatür

Bu alt kısımda benzer problemlere su-doldurma algoritmaları öneren, kullanan çalışmalar sunulmaktadır.

[13]'teki makale, dikey frekans bölmeli çoklama (DFBC) tabanlı bilişsel radyo sistemlerinde güç tahsisi için düşük karmaşıklıkta bir su doldurma algoritması sunmaktadır. Bilişsel radyo ile ortaya çıkan bu güç sınırlamalarının üstesinden gelmek için anlık güç artırma

veya güç azaltma su doldurma işlemi kullanılarak yapılabilir. Bu güç sınırlamaları, geleneksel su doldurma algoritmaları ile çözülememektedir. Sayısal sonuçlar, bu makalede önerilen su doldurma algoritmasının gücü en iyi şekilde yeniden dağıtabildiklerini ve bunu yinelemeli su doldurma algoritmalarından daha uygun bir şekilde yaptığını göstermektedir.

[14]'te bu problemleri Karush-Kuhn-Tucker koşullarına dayalı doğrusal olmayan bir sistem çözülerek bir yaklaşım önerilmiş ve bu önerilen su doldurma algoritmasının en iyiliği gösterilmiştir. Sayısal sonuçlar, önerilen yöntemin sağlam, ileri görüşlü ve düşük karmaşıklıkta olduğunu göstermektedir.

[15]'te benzetim ortamında DFBC tabanlı bir bilişsel radyo sisteminde kullanılmak üzere tekdüze, su doldurma, yetersiz ve en iyi algoritmalar gibi çeşitli güç dağıtım algoritmaları incelemektedir. Sayısal bulgular, önerilen algoritmaların geleneksel su doldurma algoritmalarına ve tekdüze su doldurma algoritmalarına göre daha yüksek iletim sağlama yeteneğine sahip olduğunu göstermektedir.

[16]'da Devasa Çok Girdili Çok Çıktılı (ÇGÇÇ) için mümkün olan en yüksek enerji verimliliği seviyesine ulaşmasını sağlayacak bir güç tahsisi yöntemi önerilmiştir. Bu basitleştirilmiş ifadeye dayalı olan en iyi güç tahsisi stratejisini geliştirmek için yeni bir yöntem sağlamakta ve sonra bu yöntemi geleneksel yöntemle karşılaştırmaktadır. Hem enerji hem de çalışma (spektral) bant genişliği açısından mümkün olan en büyük tasarrufu elde etmek için, bu çalışmanın yazarları gelişmiş bir su doldurma tekniği önermekte ve güç tahsisi algoritmasına dahil etmektedir. Benzetimin sonuçları, inen bağlantı iletiminin enerji verimliliğinin ve spektrum verimliliğinin, geleneksel yöntemlerle karşılaştırıldığında önemli ölçüde arttığını ortaya koymaktadır.

[17]'teki çalışma, bir geliştirilmiş güç tahsisi su doldurma politikası önermektedir. Bu politika, geleneksel su doldurma politikasının gerektirdiği yinelemeli hesaplamalara olan ihtiyacı ortadan kaldırmaktadır. Ek olarak, bu politika, hesaplama sayısını azaltan politikayı etkili bir şekilde sadeleştirir. DFBC'ye dayalı bir güç tahsisi stratejisi [18]'deki çalışmada önerilmiştir. Sonra, bilişsel radyo ağındaki sönmülenen (gölgelenen) kanallar boyunca su akışı olarak bilinen bir mekanizma kullanılmaktadır. Bu politika, ağır kanal performansını önemli ölçüde iyileştirme potansiyeline sahiptir. Ek olarak, [19]'daki çalışmada belirtildiği gibi, çok taşıyıcı çıkın-bağlantı dikey-olmayan çoklu erişim (DOÇE) ağlarında kaynak tahsisi probleminin çözümü için su doldurma stratejisi kullanılabilir. [20]'de makalede [21]'de makalede önerilen MAPEL yöntemi ile çözülebilecek yüksek karmaşıklıkta ağırlıklı verihacmi enyükseltmesi problemi ele alınmaktadır. MAPEL hesaplamaları için gereken süreyi azaltmak için, en önemlisi en iyileştirme probleminde en az veri hızı gerekliliğini dikkate alarak, bir dizi farklı yöntemlerden yararlanmaktadır. Ayrıca ilave kaynak blokları üzerinden

tahsisat yapılması gerektiğinde her kullanıcı için en fazla güç kullanılabilir; bu güç miktarı gözetilerek su doldurma prensibi eniyileştirme sürecine dahil edilmiştir.

[22]'de bu yöntem, dışbükey bir eniyileştirme problemi oluşturarak gerçekleştirilir. Elde edilen kelimelerin ortalama karesel hatasının sınırlarına bağlı olarak hızı maksimize etme, enerjiyi minimuma indirme ve enerji-gecikme ürününü eniyileştirme kriterlerini dikkate alır. Bu çalışmada ele alınan eniyileştirme problemleri sırasıyla geleneksel su doldurma problemleri, zemin düzleştirme ve su doldurma problemleri ve kum dökme ve su doldurma problemleri olarak kabul edilebilir. Buna göre, açgözlü algoritmalar, en iyi şekilde ayrı salınımlar elde etmek için bir yöntem olarak sunulmuştur.

[23]'te sıfır zorlama, en büyük olabilirlik ve minimum karesel ortalama hatası eşitleme teknikleriyle su doldurma algoritmaları uygulayıp ÇGÇÇ sistemlerinin uzay-zaman blok kodu (UZBK), Dikey-UZBK ve kanal kapasitesi geliştirme çerçevelerinin bit hata oranını inceler. Bu çalışmanın sonuçları bir tablo şeklinde sunulmuştur.

[24]'teki makalede geliştirilmiş bir su doldurma tekniği önerilmiştir. Bu algoritma, iletim enterferansının (girişiminin) sıcaklık sınırını en iyileştirmek için signum işlevini kullanmaktadır. Bu, hem kanal taramanın esnekliğini geliştirmekte, hem de iletişim ağının sığasını (kapasitesini) da etkili bir şekilde en iyileştirmektedir.

[25]'de yapılan çalışmada, birçok sönmüleme kanalı içeren kablolu ağlarda bir kaynak tahsisi probleminin çözümü üzerine çalışılmaktadır. Burada veri iletim hızının sürekli bir değer alabileceği kabul edilmektedir. Ele alınan probleme önce çevrimdışı bir yaklaşım uygulanmaktadır ve sorunu tüm farklı sönmüleme kanallarında bir bütün olarak değerlendirilip çevrimdışı bir su doldurma tekniğini uygulanarak, tüm sönmüleme kanalları üzerinden bu soruna en uygun çözüm önerilmesi hedeflenmiştir. Sonra birçok sönen kanalın olduğu durumu çevrimiçi olarak ele alınıp geçmişe dayalı bir su doldurma politikası önerilmiştir.

İlgili araştırmalarda, bu politikaların genellikle yüksek düzeyde hesaplama karmaşıklığına sahip olmasına rağmen, çeşitli sistemlerde meydana gelen çeşitli problemler için çok sayıda farklı su doldurma politikası sunulmaktadır. Sonuç olarak, bu sorunu ele almak için, özellikle hem pratik hem de daha güvenilir ve etkili su doldurma algoritmaları gerekir. Ayrık veri hızı kümesi düşünülerek bu problemde veri iletimi için gelecekteki su seviyesine karar vermek için makine öğrenmesi kullanmanın etkisi, bildiğimiz kadarıyla araştırılmamıştır.

### C. Önemli Katkıları

Bu makalenin literatüre ana katkıları şu şekildedir:

- Bu çalışmada, birçok sönmüleme kanalı içeren kablolu ağlarda bir kaynak tahsisi probleminin çözümü üzerine çalışılmaktadır. Bu problem, farklı sönmüleme kanallarında bir bütün olarak ele alınıp incelenmektedir.

- Bu problemin önceki çalışmamızda [25] incelenen probleme göre en önemli farkı, önceki çalışmada anlık veri iletim hızı sürekli bir değer alabilirken bu çalışmada anlık veri iletim hızı sadece ayrıık bir kümedeki veri hızı değerlerinden birini alabilir (IEEE 802.11 WiFi protokolleri gibi ayrıık veri iletim hızı kümesi düşünenin problemi daha gerçekçi ve pratik bir probleme dönüştürdüğü söylenebilir).
- Ayrıık bir veri iletim hızı seti düşünülerek bu veri hızlarını göz önünde bulunduran (sınıflandırma kullanan) makine öğrenmesine dayalı bir çevrimiçi su doldurma politikası önerilmektedir.

#### D. Teşkil

Makalenin geri kalan kısımları takip eden şekilde yapılandırılmıştır. Bölüm II'de, ele alınan sistemin modeli sunulmuştur ve sonra incelenen problem tanımlanmıştır. Bölüm III'te, su doldurma yöntemi hakkında kısa arka plan bilgileri verilmiştir. Bölüm IV'te, bu problem için makine öğrenmesine dayalı çevrimiçi algoritmalar önerilmiştir. Bölüm V'te, çeşitli sönümlenme koşulları altında elde edilen sayısal sonuçları sunulmaktadır. Bölüm VI'da, makalenin sonuçları sunulmaktadır.

## II. SİSTEM MODELİ VE PROBLEM TANIMI

Bu kısımda, öncelikle göz önünde bulundurulan haberleşme sisteminin modeli verilmektedir. Daha sonra, bu sistemde ele alınan problemin tanımı yapılmaktadır.

### A. Sistem Modeli

Bu çalışma kapsamında, kablosuz ağlarda çok sayıda sönümlenme kanalı hesaba katılırken verileri etkili bir şekilde iletmenin zorluğu araştırılmaktadır.

Bu sistemle veriler, kanalları olan bir vericiden sadece bir kanalı olan alıcıya iletir. Kanalların birbirine diklik kabulüne göre enterferans (girişim) ihmal edilecektir.

Burada kanal sayısını  $K$  ile gösterilmektedir; zaman ufku ise  $T$  ile gösterilmektedir. Her kanal üzerinden gerçekleşen veri iletimi aşağıdaki gibi modellenilebilir:

$$y_k[n] = h_k[n] \cdot x_k[n] + w_k[n], \quad k = 1, \dots, K; \quad n = 1, \dots, T \quad (1)$$

burada,  $y_k[n]$ ,  $x_k[n]$ , ve  $w_k[n]$  sırasıyla zaman dilimindeki alt kanaldaki çıkış sinyalini, giriş sinyalini ve gürültü sinyalini temsil eder.  $h_k[n]$ , her bir alt kanal için kanal kazançını temsil eder.

Bir DFBC kanalı ile en fazla güvenilir iletişim hızı için, her alt kanaldaki iletim gücünün olduğu varsayılmaktadır.  $n$ . zamanında  $k$ . kanalının veri hızı şu şekildedir:

$$C_k[n] = B \cdot \log_2 \left( 1 + \frac{P_k[n] \cdot |h_k[n]|^2}{N_0} \right) \text{ bit/sn} \quad (2)$$

Burada  $N_0$ , gürültü gücü yoğunluğudur;  $B$ , bant genişliğidir.

Bu çalışmada amaç, iletim güçlerini mümkün olan en verimli şekilde atayarak, zaman ufku boyunca aktarılan toplam veri miktarını en üst düzeye çıkarmaktır.

### B. Problem Tanımı

Bu makalede bu problem çevrimiçi olarak incelenir.

Denklem (2)'ye göre, güç tahsisi bu en iyileştirme probleminin çözümüdür. Problem şu şekilde ifade edilir:

$$\min_{\{C_k[n]\}_{n=1}^T \in R} \sum_{n=1}^T \sum_{k=1}^K P_k[n] \quad (3)$$

Öyle ki

$$\sum_{n=1}^T \sum_{k=1}^K P_k[n] \leq E \quad (3a)$$

$$C_k[n] \in R = \{R_1, \dots, R_L\} \quad (3b)$$

$$C(K, T) = \sum_{n=1}^T \sum_{k=1}^K C_k[n] \quad (3c)$$

Burada, (3)'teki eniyileştirme problemi, (3a), (3b) ve (3c) kısıtları altında sınırlı bir eniyileştirme problemi olarak ifade edilmiştir.

$E$  iletim gücünün toplamı olan enerji miktarını gösterir; ve  $P_k[n] \geq 0, k = 1, \dots, K, n = 1, \dots, T$ .

$R = \{R_1, \dots, R_L\}$ ,  $L$  sayıda veri hızını içeren bir ayrıık veri kümesidir.

Burada problem, (3c) kısıtıyla aynı miktarda veriyi toplamda en az enerji ile iletim problemine dönmüştür.

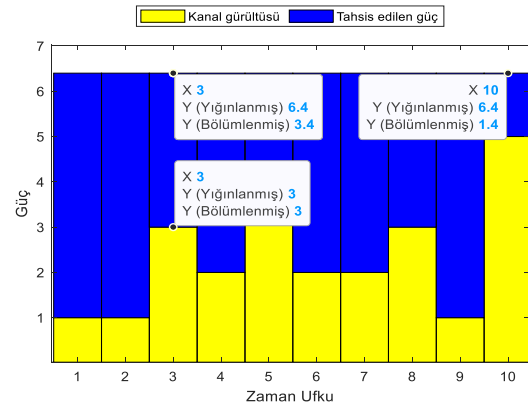
## III. SU DOLDURMA POLİTİKASINA KISA BİR GİRİŞ

Bu bölümde, Denklem (3)'te bulunabilen en iyi su doldurma politikasına kısa bir genel bakış sunulmaktadır. Tüm en iyi güç seviyeleri, su doldurma sistemi tarafından aşağıdaki yollarla elde edilebilir:

$$P_k[n] = \left[ \frac{1}{K \cdot T} \left( E + \sum_{n=1}^T \sum_{k=1}^K \frac{1}{|h_k[n]|^2} \right) - |h_k[n]|^2 \right]^+ \quad (4)$$


Burada, eğer  $A > 0$  ise  $[A]^+ = A$ . Diğer yandan, eğer  $A \leq 0$  ise  $[A]^+ = 0$ .

Şekil 1 ve Şekil 2, iki farklı su doldurma stratejisini gösteren tek kanallı örneklerdir. İlki 40 birime eşit  $E$ 'ye sahiptir ve ikincisi 20 birime eşit  $E$ 'ye sahiptir. Şekil 1, verilerin her zaman diliminde iletildiğini gösterir, ancak Şekil 2, verinin zaman dilimi 10'da iletmediğini gösterir.



Şekil 1,  $T=10$  zaman diliminde  $E=40$  değerinde su doldurmayı göstermektedir.

Şekil 1'de, X, Y(Bölümlenmiş) ve Y(Yığılanmış) değişkenleri, sırasıyla zamanın geçişi, kanal kazancı miktarını ve ayrılan iletim gücünün kanal kazancıyla çarpımını göstermektedir. İletim olmadığı zaman dilimi 10'daki Y(Yığılanmış) değeri, Şekil 2'de gösterildiği gibi Y(Bölümlenmiş) değeri ile aynıdır.



Şekil 2.  $T=10$  zaman diliminde  $E=20$ 'yle su doldurma

#### IV. ÖNERİLEN SU DOLDURMA POLİTİKASI

Bu bölümde, ilgili literatür ve önceki çalışmamız [25]'ten farklı olarak (sürekli yerine) ayrık bir veri iletim hızı setini düşünerek eldeki probleme Makine Öğrenmesine dayalı çevrimiçi bir çözüm önerilmektedir.

Bu yönetime göre önce ayrık veri iletim hızı kümesini ve sürekli bir kümeden değer alan kanal kazançlarını düşünerek bir makine öğrenmesi algoritması olan k-means kümeleme ve sınıflandırma algoritmasını uygulanır. Burada kanal kazançlarının her birini bir değere eşlenir. Sonra geçmişin bir bölümüne dayalı bir su doldurma seviyesi oluşturmak için geçmişten yararlanır. Zamanla algoritma dinamik biçimde öğrenip güncel su seviyesini ne kadar verinin iletilmesi gerektiğini hesaplar. Bu çevrimiçi politikanın amacı, önceki zaman dilimlerinde kanalın özelliklerinden sonuçlar çıkararak veri iletimini en iyi politika kadar verimli hale getirmektir.

Bu makalede makine öğrenmesi uygulayarak sürekli (sonsuz sayıda değer alabilen) veri iletim hızı seti yerine birkaç veri iletim hızı seti ile pratik bir yaklaşım sergileyen bir su-doldurma algoritması önerilmektedir. K-means burada sürekli bir veri iletim hızı kümesi seçmek yerine ayrık bir veri iletim hızı kümesini en iyi şekilde seçmeye yaramaktadır. Aslında bir bakıma ayrıklaştırma yapmamızı sağlamaktadır. Bu ayrık veri iletim hızı kümesini seçmeyi düşündüğümüzde sürekli veri iletim hızı kümesine göre performans kaybı beklenmektedir. Burada en iyi ayrık veri iletim hızı kümesini seçerek sürekli veri iletim hızı kümesine göre oluşan fazladan enerji tüketiminin en aza indirilmesi hedeflenmektedir.

Bu makalede aynı zaman diliminde aynı enerji ile ne kadar fazla veri yollanabileceği problemini değil aynı zamanda aynı miktarda veriyi ne kadar az enerji ile yollanabileceği ele alınmaktadır. Bunun üzerine Şekil 3'teki Makine Öğrenmesi Tabanlı Su-Doldurma Algoritma önerilmiştir.

#### Algorithm 1 Makine Öğrenmesi Tabanlı Su-Doldurma Politikası

**Girdiler:**  $D(K, T)$ ,  $T$  zaman dilimlik zaman ufku boyunca  $K$  kanalı boyunca iletilecek veri miktarıdır.  $h_k[n]$ ,  $n$ . zaman dilimi içindeki  $k$ . kanal kazancıdır.

**Baslangic:**  $WFL_{max}$ ,  $WFL_{min}$ ,  $\epsilon$ , sırasıyla maksimum su-doldurma seviyesi, minimum su doldurma seviyesi ve toleransidir.

1)  $K \times M$  Su-doldurma seviyesi matrisi  $WFL$ , şöyle başlatılmaktadır:  
 $WFL \leftarrow \left( \frac{WFL_{max} + WFL_{min}}{2} \right)$

2)  $K \times T$  kanal kazancı matrisi  $G$ , su şekilde başlatılmaktadır:

$G(k, n) = \frac{h_k[n]}{|h_k[n]|^2} \forall k \in \{1, \dots, K\}, \forall n \in \{1, \dots, T\}$

3) Kanal sığası (kapasitesi) teoreminden  $K \times T$  veri hızı matrisi, su şekilde tanımlanmaktadır:  $C(K, T) \triangleq B \cdot \log_2(1 + 10^{(WFL-G)})$

**Prosedur:**

Ayrık veri iletim hızı kümesini düşünülerek k-means makine öğrenmesi algoritması uygulanmaktadır. Burada kanal kazançlarının herbiri bir değere eşlenmektedir (mapping). Buna göre su-doldurma seviyesi algoritmasını takip eden şekilde uygulanmaktadır.

# Yorum: Bu dongu, sadece kanal kapasitesi ve iletilecek veri miktarı arasındaki fark çok az ( $\epsilon$ 'dan az) olunca sonlanmaktadır.

Suresince  $(|C(K, M) - D(K, T)| * \frac{M}{T}) > \epsilon$  yap

eger  $C(K, M) < D(K, T) * \frac{M}{T}$  ise  
 $WFL_{min} \leftarrow \frac{WFL_{max} + WFL_{min}}{2}$

degilse  
 $WFL_{max} \leftarrow \frac{WFL_{max} + WFL_{min}}{2}$

son eger  
 $WFL \leftarrow \left( \frac{WFL_{max} + WFL_{min}}{2} \right)$

# Yorum: Su doldurma seviyesi ve kanal kazancı arasındaki farkın pozitif olup olmadığını kontrol ederek her bir zaman diliminde her kanal kazancı değeri için kanal kapasitesi hesaplanmaktadır.

$C(K, M) \leftarrow B \cdot \log_2(1 + 10^{\min(WFL-G, 0)})$

son suresince

# Yorum: Pratik bir algoritma için  $M$  ( $M \leq T$ ) zaman dilimlik bir geçmiş ele alınabilir. Böylece, elde edilen su doldurma seviyelerini (ve buna göre tüm kanallardaki tüm anlık veri iletim güçlerini) içeren  $WFL$  daha rahat uygulanabilir.

**Çikti:** Geri Dondur  $WFL$

#### Şekil 3. Makine Öğrenmesi (MÖ) Tabanlı Çevrimiçi Su Doldurma Algoritması.

Bu algoritmanın çıktısı su doldurma seviyesine bağlı tüm kanallarda tüm anlık iletim güçlerini içeren bir matristir. Böylece zaman ufku boyunca tüm kanallarda veri iletimi için harcanan toplam enerjiyi enazaltmak amaçlanır.

#### V. SAYISAL SONUÇLAR

Bu çalışmada, bir iletişim sistemi içindeki bir dizi sönümleme kanalı aracılığıyla verileri enerji verimli bir şekilde iletmenin zorluğu araştırılmaktadır [7]. Bu bölümde, makine öğrenmesine dayalı çevrimiçi su doldurma politikasının performansını çevrimdışı doldurma politikasının performansıyla iki farklı şekilde karşılaştırılmaktadır: 1) Özellikle 1000 ve 10000 zaman dilimli zaman ufkuları. 2)  $k=2$  ile Rayleigh sönümleme, Nakagami sönümleme, Rician sönümleme,  $m=2$  ile Weibull sönümleme olarak çeşitli sönümleme kanalları. Farklı kanal tiplerinin (kanal sönümleme modellerinin) farklı olasılıksal dağılımı vardır. Bu da farklı sönümleme altında farklı kanal kazançlarının olduğunu gösterir ki bu da algoritmanın performansını etkilemektedir.

Makine öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından kullanılan toplam iletim enerjisi, En İyi Çevrimdışı Su Doldurma Politikası tarafından kullanılan enerji miktarıyla karşılaştırılmaktadır.


Çevrimiçi Su Doldurma Politikasının gelişimi, her biri zaman ufkunun %10'a eşit bir oranını gösteren bir dizi zaman bölümü olarak sunulur. Örneğin,  $T=1000$  zaman dilimiyse, 4 zaman bölümü için geçmişin uzunluğu 4 çarpı 1000 zaman diliminin %10'udur, bu da 400 zaman dilimine eşittir. Ancak,  $T=10000$  zaman dilimine eşitse, 4 zaman bölümü için geçmişin uzunluğu 4 çarpı 10000 zaman diliminin %10'udur, 4000 zaman dilimine eşittir.

## A. Zaman Ufku

Çevrimiçi ve en iyi çevrimdışı stratejilerin görelî performansı, 1000 ve 10000 zaman dilimi zaman ufku boyunca çeşitli sönümlenme kanalları için bu altbölümde incelenir.

### 1. Rayleigh Sönümlenen Kanal

Rayleigh sönümlenen kanallar için çevrimiçi ve çevrimdışı politikaların görelî performansı 1000 ve 10000 zaman diliminde zaman ufuklarında incelenmektedir. Tablo I, Rayleigh sönümlenme kanalı için Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikasına göre toplam iletim enerjisinin En iyi Çevrimdışı Su Doldurma Politikasına oranının genel eğilimlerini gösteren Şekil 4'ten daha kesin (hassas) sonuçlar göstermektedir. Şekil 4, Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikasına göre toplam iletim enerjisi oranının genel eğilimlerini göstermektedir.



Şekil 4. Rayleigh Sönümlenen Kanal'da Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından sağlanan toplam iletim enerjisinin Çevrimdışı Su Doldurma Politikası tarafından sağlanana oranı.

Şekil 4'e bakıldığında, çevrimdışı doldurma politikası ile Makine Öğrenmesine tabanlı çevrimiçi doldurma politikası arasındaki toplam enerji kullanımındaki farkın, 1000 zaman dilimi durumunda, 10000 zaman dilimi durumunda yaklaşık 3 kat daha fazla olduğu açıktır.

TABLO I. BU TABLO, MAKİNE ÖĞRENMESİNE DAYALI ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN ÜRETİLEN RAYLEİGH SÖNÜMLENEN KANAL İÇİN TOPLAM İLETİM ENERJİSİNİN EN İYİ ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN ÜRETİLENE ORANINI GÖSTERMEKTEDİR. M=1, MAKİNE ÖĞRENMESİ TABANLI ALGORİTMANIN T=1000 ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİRKEN M=2, T=10000 ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİR.

C	0.1T	0.2T	0.3T	0.4T	0.5T	0.6T	0.7T	0.8T	0.9T	1.0T
M1	1.35	1.25	1.20	1.17	1.14	1.13	1.13	1.12	1.12	1.11
M2	1.11	1.09	1.08	1.07	1.06	1.06	1.06	1.05	1.05	1.04

Tablo I'e göre, toplam zaman ufkunun (veya 0,1 T) %10'unu temsil eden yalnızca bir zaman diliminin geçmişi düşünüldüğünde, çevrimiçi politika, 10000 zaman dilimindeki çevrimdışı politikadan %35 daha fazla enerji

kullanır, çevrimdışı yöntemle göre %11 daha fazla enerji kullanır.

5 zaman bölümü geçmişi kullanıldığında (zaman ufkunun yarısı veya 0,5 T), çevrimiçi politika 500 zaman dilimindeki çevrimdışı politikadan %14 daha fazla enerji kullanır, ancak 5000 zaman dilimindeki çevrimdışı algoritmadan yalnızca %6 daha fazla enerji kullanır. Bu fark, çevrimiçi algoritmanın 0,5 T kullanması ile açıklanabilir.


Altıdan fazla farklı zaman dilimini içeren bir geçmişi kullanmak, çevrimiçi veya çevrimdışı politikalar için önemli bir etki (yaklaşık %2) oluşturmaz.

### 2. Nakagami Sönümlenen Kanal

Nakagami sönümlenen kanallar için çevrimiçi ve çevrimdışı politikaların görelî performansı 1000 ve 10000 zaman dilimi zaman ufuklarında incelenmektedir.

Şekil 5, Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından sağlanan toplam iletim enerjisinin, Nakagami sönümlenme kanalı için En iyi Çevrimdışı Su Doldurma Politikası tarafından sağlanan oranın genel eğilimini gösterir. Tablo II, Şekil 7'den daha kesin sonuçlar sağlar.

Şekil 5'e bakıldığında, çevrimdışı doldurma politikası ile Makine Öğrenmesine dayalı çevrimiçi doldurma politikası arasındaki toplam enerji kullanımındaki eşitsizliğin, 1000 zaman dilimi durumunda, 10000 zaman dilimi durumunda olduğundan yaklaşık 3 kat daha fazla olduğu açıktır.



Şekil 5. Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikasına göre toplam iletim enerjisinin, k=2 ile Nakagami Sönümlenen Kanal için Çevrimdışı Su Doldurma Politikasına oranına oranı.

Tablo II'ye göre, zaman ufkunun %10'unu (veya 0,1 T) temsil eden yalnızca bir zaman diliminin geçmişi düşünüldüğünde, çevrimiçi politika 100 zaman diliminde çevrimdışı politikadan %15 daha fazla enerji kullanır, ancak çevrimiçi algoritma yalnızca 1000 zaman diliminde çevrimdışı politikadan %6 fazla enerji kullanmaktadır.

**TABLO II.** BU TABLO, MAKİNE ÖĞRENMESİNE DAYALI ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASININ ÜRETTİĞİ  $K=2$  İLE NAKAGAMI SÖNÜMLENEN KANAL İÇİN TOPLAM İLETİM ENERJİSİNİN EN İYİ ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN ÜRETİLENE ORANINI GÖSTERMEKTEDİR.  $M=1$ , MAKİNE ÖĞRENMESİ TABANLI ALGORİTMANIN  $T=1000$  ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİRKEN  $M=2$ ,  $T=10000$  ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİR.

C	0.1T	0.2T	0.3T	0.4T	0.5T	0.6T	0.7T	0.8T	0.9T	1.0T
M1	1.15	1.11	1.09	1.08	1.07	1.07	1.06	1.06	1.05	1.04
M2	1.06	1.05	1.04	1.03	1.03	1.03	1.03	1.02	1.02	1.02


Beş zaman dilimi geçmişi kullanıldığında (zaman ufkunun yarısı veya  $0,5 T$ ), çevrimiçi politika 500 zaman diliminde çevrimdışı politikadan %7 daha fazla enerji kullanırken, 5000 zaman diliminde çevrimdışı algoritmadan yalnızca %3 daha fazla enerji kullanır. Bu fark, çevrimiçi algoritmanın beş zaman dilimi geçmişi kullanması ile açıklanabilir.

Altıdan fazla farklı zaman dilimini içeren bir geçmişi kullanmak, çevrimiçi veya çevrimdışı politikalar için önemli bir etki (yaklaşık %3) oluşturmaz.

### 3. Rician Sönümlenen Kanal

Rician sönümlenen kanallar için çevrimiçi ve çevrimdışı politikaların görelî performansı 1000 ve 10000 zaman dilimi zaman ufklarında incelenmektedir.

Şekil 6, Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından sağlanan toplam iletim enerjisinin Rician sönümleme kanalları için En iyi Çevrimdışı Su Doldurma Politikası tarafından sağlanana karşılaştırmasının genel eğilimlerini göstermektedir. Tablo III, Şekil 6'dan daha kesin sonuçlar vermektedir.



**Şekil 6.** Rician Sönümlenen Kanal'da Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından yönetilen toplam iletim enerjisi miktarının, Çevrimdışı Su Doldurma Politikası tarafından yönetilen ile karşılaştırılması

Şekil 6'dan, Makine Öğrenmesine dayalı çevrimiçi su doldurma politikası ile çevrimdışı doldurma politikası arasındaki toplam enerji tüketimi farkının 1000 zaman dilimi durumunda 10000 zaman dilimi durumunda olduğundan yaklaşık 3 kat daha fazla olduğu sonucuna varmak mümkündür.

**TABLO III.** AŞAĞIDAKİ TABLO, MAKİNE ÖĞRENMESİNE DAYALI ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN OLUŞTURULAN RİCIAN SÖNÜMLENEN KANAL İÇİN TOPLAM İLETİM ENERJİSİNİN EN İYİ ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN OLUŞTURULANA ORANINI KARŞILAŞTIRMAKTADIR.  $M=1$ , MAKİNE ÖĞRENMESİ TABANLI ALGORİTMANIN  $T=1000$  ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİRKEN  $M=2$ ,  $T=10000$  ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİR.

C	0.1T	0.2T	0.3T	0.4T	0.5T	0.6T	0.7T	0.8T	0.9T	1.0T
M1	1.36	1.30	1.29	1.26	1.25	1.23	1.23	1.22	1.22	1.21
M2	1.18	1.15	1.15	1.14	1.13	1.13	1.12	1.12	1.11	1.11

Tablo III'e göre, tüm zaman ufkunun %10'una (veya  $0,1 T$ 'ye) tekabül eden yalnızca bir zaman diliminin geçmişi düşünülünce, çevrimiçi politika, 100 zaman diliminde çevrimdışı politikadan %36 daha fazla enerji kullanırken, 10000 zaman diliminde çevrimdışı yöntemle göre %18 fazla enerji kullanır.


5 zaman bölümü geçmişi kullanıldığında (zaman ufkunun yarısı veya  $0,5 T$ ), çevrimiçi politika 500 zaman diliminde çevrimdışı politikadan %25 daha fazla enerji kullanır, ancak 5000 zaman diliminde çevrimdışı algoritmadan yalnızca %13 daha fazla enerji kullanır. Bu fark, çevrimiçi algoritmanın  $0,5 T$  kullanması ile açıklanabilir.

6'dan fazla farklı zaman bölümünü içeren bir geçmişi kullanmak, çevrimiçi veya çevrimdışı politikalar için önemli bir etki (yaklaşık %2) oluşturmaz.

### 4. Weibull Sönümlenen Kanal

Weibull sönümlenen kanallar için çevrimiçi ve çevrimdışı politikaların görelî performansı 1000 ve 10000 zaman dilimi zaman ufklarında incelenir.

Şekil 7, Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından sağlanan toplam iletim enerjisinin Rayleigh sönümleme kanalı için En iyi Çevrimdışı Su Doldurma Politikası tarafından sağlanana oranının genel eğilimlerini göstermektedir. Sonuçlar, Şekil 7'de daha genel sunulurken Tablo IV'te daha kesin bir şekilde sunulmaktadır.



**Şekil 7.**  $m=2$  ile Weibull Sönümlenen Kanal'da Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından yönetilen toplam iletim enerjisinin, Çevrimdışı Su Doldurma Politikası tarafından yönetilen toplam iletim enerjisine oranı.

Şekil 7'ye bakıldığında, Makine Öğrenmesine dayalı çevrimiçi su doldurma politikası ile çevrimdışı su doldurma stratejisi arasındaki toplam enerji tüketimindeki farkın, 1000 zaman dilimi durumunda 10000 zaman dilimi durumunda olduğundan yaklaşık 2 kat daha fazla olduğu açıktır.

TABLO IV. BU TABLO, MAKİNE ÖĞRENMESİNE DAYALI ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN ÜRETİLEN  $M=2$  İLE WEIBULL SÖNÜMLENEN KANAL İÇİN TOPLAM İLETİM ENERJİSİNİN EN İYİ ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN ÜRETİLENE ORANINI GÖSTERMEKTEDİR.  $M=1$ , MAKİNE ÖĞRENMESİ TABANLI ALGORİTMANIN  $T=1000$  ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİRKEN  $M=2$ ,  $T=10000$  ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİR.

C	0.1T	0.2T	0.3T	0.4T	0.5T	0.6T	0.7T	0.8T	0.9T	1.0T
M1	1.11	1.09	1.08	1.07	1.06	1.05	1.05	1.04	1.04	1.04
M2	1.05	1.04	1.04	1.04	1.04	1.03	1.03	1.02	1.02	1.02

Tablo IV'e göre, zaman ufkunun %10'u veya 0,1 T tek bir zaman bölümü geçmiş olarak kullanıldığında, çevrimiçi politika 100 zaman diliminde çevrimdışı politikadan %11 daha fazla enerji kullanırken, 1000 zaman diliminde sadece %5 fazla enerji kullanmaktadır.

Bazen zaman ufkunun yarısı veya 0,5 T olarak bilinen 5 zaman bölümü geçmişle çevrimiçi politika, 1000 zaman dilimindeki çevrimdışı politikadan %4 daha fazla enerji tüketmektedir, ama çevrimiçi politika çevrimdışına göre yalnızca %2 daha fazla enerji harcamaktadır.

6'dan fazla zaman bölümünü (0.6T) içeren bir geçmiş kullanmak, çevrimiçi ve çevrimdışı politikaların performansı için önemli bir fark oluşturmaz (sadece %1).

#### B. Diğer Açıklamalar

Bu alt bölümde, Şekil 4-7 ve Tablo I-IV kullanılarak çevrimiçi politikanın göreceli performansı, bir dizi farklı sönümlenme kanalı altında 1000 zaman dilimi ve 10000 zaman dilimi zaman ufkuları üzerinden incelenmektedir. Bu sönümlenme kanalları Rayleigh sönümlenme, Nakagami sönümlenme, Rician sönümlenme ve Weibull sönümlenme ile içermektedir.

1000 zaman dilimli zaman ufkunda, Makine Öğrenmesine dayalı bir çevrimiçi su doldurma politikası ile bir çevrimdışı su doldurma politikası arasındaki toplam enerji tüketimindeki eşitsizliğin,  $k=2$  ile Nakagami ve  $m=2$  ile Weibull altında sifira yaklaştığını çıkarmak mümkündür. Çevrimdışı su doldurma politikasının toplam enerji tüketiminin %6'sine eşit olan 0,1-T geçmişsel senaryosu dışında, fark %5'den küçüktür. Geçmişin uzunluğu 0.4T=400 zaman diliminden az ise, çevrim içi politika ile çevrim dışı politika arasındaki (yaklaşık %25 oranında) farkın bir sonucu olarak tüketilen enerji miktarında farkı nedeniyle Weibull sönümlenme Nakagami sönümlenmesine tercih edilir. Hem  $k=2$  olan Nakagami modeli hem de  $m=2$  olan Weibull modeli,  $T=1000$  zaman dilimi geçmiş olduğu, çevrim içi politika ile çevrim dışı politika arasındaki farkın %5'e eşit olacağını öngörmektedir. Rayleigh ve Rician sönümlenme kanalları altında, 0,1 T=100 zaman dilimi (zaman ufkunun %10'u)

geçmişine sahip bir Çevrim içi Su Doldurma Politikası, en iyi çevrim dışı politikadan %35 daha fazla enerji tüketimi ile aynı performansı elde etmektedir. Diğer yandan, geçmişin uzunluğu 0,5T=500 zaman diliminden (zaman ufkunun yarısından) büyükse, bir çevrim içi politika ile çevrim dışı bir politika tarafından tüketilen enerji miktarı arasındaki fark, Rayleigh sönümlenmesi altında Rician sönümlenmesine kıyasla yaklaşık 40% oranında azaltılır.

10000 zaman dilimi zaman ufkunda, Nakagami modelinde  $k=2$  ve Weibull modelinde  $m=2$  olduğunda, Makine Öğrenmesine dayalı bir çevrim içi su doldurma politikası ile çevrim dışı bir su doldurma politikası arasındaki toplam enerji tüketimindeki eşitsizliğin sifira yaklaştığını Tablo I, II, III, IV'ten çıkarmak mümkündür. Aralarındaki fark, %0.2'den daha azdır ve bu, çevrim dışı su doldurma politikasının toplam enerji tüketiminin %1'ine eşittir. Geçmişin uzunluğu 0,4T=4000 zaman diliminden az veya 0,7 T=7000 zaman diliminden büyükse, çevrim içi politika tarafından tüketilen enerji miktarı ile çevrim dışı politika tarafından tüketilen enerji arasındaki fark, hem Weibull sönümlenmesi hem de Nakagami sönümlenmesi altında aynıdır. Hem  $k=2$  olan Nakagami modeli hem de  $m=2$  olan Weibull modeli, geçmiş 0,8T=8000 zaman diliminden uzun olduğunda, çevrimiçi politika ile çevrimdışı politika arasındaki farkın yaklaşık birbirine eşit olması tahmin edilebilir (%2 fark). Rayleigh sönümlenme ile çevrimiçi su doldurma politikası ile en iyi çevrim dışı politika arasında tüketilen enerji farkı, Rician sönümlenmesine göre yaklaşık iki kat azalır.

$m=2$  ile Weibull sönümlenmesi altında, çevrim içi su doldurma politikasının performansı, en iyi çevrim dışı politikaninkine çok yaklaşmıştır.  $k=2$  ile Nakagami sönümlenme modeli altında, çevrimiçi politika genel olarak en iyi ikinci performansa ulaşır. Rician sönümlenme gerçekleştiğinde, çevrim içi politika ile çevrim dışı politika arasındaki enerji farkı en yüksek seviyededir. Performanstaki fark, öncelikle çeşitli sönümlenme modellerinin olasılıksal (stokastik) dağılımlarındaki farklılıkları nedeniyle ortaya çıkabilir.

Başka bir gözlemse, aynı oranda (örneğin, 0,1 T) geçmişin uzunluğunun zaman ufkunun uzunluğuyla orantılı olarak genişlemesidir. Geçmiş uzunluğunun zaman ufkunun uzunluğuna oranı aynı kalsa bile (örneğin, zaman ufkunun %10'u 0,1 T), çevrim içi politika daha uzun zaman ufkuları için daha iyi performans elde edebilir.

#### VI. SONUÇLAR VE SONRAKİ ARAŞTIRMA ÖNERİLERİ

Bu makalede, çoklu sönümlenme kanalları arasında kaynak tahsisini içeren bir problem araştırılmaktadır. Bu problem tüm çoklu sönümlenme kanallarında çevrimdışı bir şekilde bir bütün olarak ele alınmaktadır. Bu problem tüm çeşitli sönümlenme kanallarında aynı anda çevrimiçi bir şekilde ele alınmaktadır. Bu probleme tüm sönümlenme kanallarını düşünerek en iyi bir çözüm aranmaktadır. Bundan sonra, bu probleme makine öğrenmesine dayalı bir çevrimiçi su doldurma algoritması sunulmaktadır.

Su doldurma algoritmasının bilgi kuramında da verilen genel mantığına göre sürekli veri iletim hızı kümesi ile en iyi enerji yakalanabilir. Ayrık veri iletim hızı kümesi ise sürekli veri iletim hızı kümesi yakalanabilecek su doldurma seviyesinin ya üstünde ya da altında tercih yapacaktır; bu da sürekli veri kümesi kabulü altında bir tane en iyi çözümü olan problemin aslında en iyi-altı çözümünü elde edebileceğini gösterir ki bu da ayrık veri kümesi ile en iyi çözümdür. Bu makalede ayrık veri kümesi altında en iyi çözümün sürekli veri kümesi altındaki en iyi çözüme göre performansını incelenmekte ve genel olarak farkın az olmasından dolayı bu makalede önerilen algoritma başarılı bulunmaktadır.

Sayısal sonuçlara göre, makine öğrenmesine dayalı çevrimiçi su doldurma algoritmasının performansı, özellikle uzun zaman ufuklarında çevrimdışı su doldurma algoritmasının performansına yakın performans gösterir.

İleride yapılacak çalışmalarda gecikme, seçirme gibi çeşitli kısıtlar eklenerek bu problemin farklı durumları incelenebilir. Etkili ve güvenilir bir çözüm üretmek için farklı bakış açıları gerekir, problemin her bir durum için yenilikçi ve pratik stratejilerin kullanılması gerekecektir.

#### KAYNAKLAR

- [1]Qualcomm. Everything you need to know about 5G. Available at <https://www.qualcomm.com/5g/what-is-5g>
- [2]Nazir, M., Sabah, A., Sarwar, S. et al. (2021). Power and Resource Allocation in Wireless Communication Network. *Wireless Pers Commun* 119, 3529-3552.
- [3]Boyd, S. and Vandenberghe, L. (2004). *Convex Optimization*. Cambridge University Press.
- [4]Cover, T. and Thomas, J. (2006). *Elements of Information Theory*, 2nd Edition. Wiley&Sons.
- [5]Dai, M., Zhang S., Chen, B., Lin, X., &Wang, H. (2014). A refined convergence condition for iterative waterfilling algorithm. *IEEE Communications Letters*, 18(2), 269-272.
- [6]Gai, Y.& Krishnamachari, B. (2012). Online Learning Algorithms for Stochastic Water-Filling. *IEEE Information Theory and Applications Workshop (ITA)*, 1-6.
- [7]Goldsmith, A. (2005). *Wireless Communications*. Cambridge University Press.
- [8]Goldsmith, A., &Varaiya, P. P. (1996). Capacity, mutual information, and coding for finite-state Markov channels. *IEEE Transactions on Information Theory*, 42 (3), 868-886.
- [9]Tse, D. & Viswanath, P. (2005). *Fundamentals of Wireless Communication*. Cambridge University Press.
- [10] Teletar, E. (1995). Capacity of multi-antenna Gaussian channels. AT&T Bell Labs Internal Tech. Memo.
- [11] Yang, J. and Roy, S. (1994). On joint transmitter and receiver optimization for multiple-input-multiple-output (MIMO) transmission systems. *IEEE Transactions on Communications*, 42(12), pp. 3221-3231.
- [12] Xing, C., Jing, Y., Wang, S., Ma, S. & Poor, H. V. (2020). New Viewpoint and Algorithms for Water-Filling Solutions in Wireless Communications. in *IEEE Transactions on Signal Processing*, 68, 1618-1634.
- [13] Ajitsinh. N., Jadhav1 and Sakib. R. Mujawar. (2017). Different power loading allocation schemes for ZF based cognitive radio system. *International Journal of Latest Trends in Engineering and Technology*, 8 (1), 350-359.
- [14] Qi Q, Minturn A., and Yang Y. L. (2012). An Efficient Water-Filling Algorithm for Power Allocation in OFDM-Based Cognitive Radio Systems. *2012 International Conference on Systems and Informatics*, 2069-2073.
- [15] P. He, L. Zhao, S. Zhou, Z. Niu, (2013). Water-Filling: A Geometric Approach and its Application to Solve Generalized Radio Resource Allocation Problems. *IEEE Transactions on Wireless Communications*, 12 (7), 3637-3647.
- [16] Noor Shahida M. K, Nordin R. and Ismail. M. (2017). Improved Water-Filling Power Allocation for Energy-Efficient Massive MIMO Downlink Transmissions. *Intl Journal of Electronics& Telecommunications*, vol. 63, no. 1, pp. 79-84.
- [17] Yu S., Daoxing G., Lu L., and Xiaopei D., "A modified water-filling algorithm of power allocation," in *Information Technology, Networking, Electronic &Automation Control Conf.*, IEEE, 2016.
- [18] Wael C. B. A, Armi N., Miftahushudr M. T., Muliawarda D., and Sugandi G., "Power Allocation in OFDM-Based Cognitive Radio Networks for Fading Channel," in *2017 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET)*, 2017.
- [19] Zeng M., Nguyen N. P., Dobre O. A., Ding Z., and Poor H. V., "Spectral- and Energy-Efficient Resource Allocation for Multi-Carrier Uplink NOMA Systems,"  *Vehicular Technology, IEEE Transactions on*, 2019.
- [20] Elgarhy O. and Reggiani L., "Application of the Water Filling Algorithm to the Sum Rate Problem with Minimum Rate and Power Constraint," *2018 Advances in Wireless and Optical Communications (RTUWO)*, 2018, pp. 12-16.
- [21] Qian L. P., Zhang Y. J., and Huang J., "MAPEL: Achieving global optimality for a non-convex wireless power control problem," *IEEE Trans. on Wireless Communications*, vol. 8, no. 3, pp. 1553-1563, Mar. 2009.
- [22] Kim Y.; Kang M.; Varshney L. R.; Shanbhag N. R., (2018). Generalized Water-Filling for Source-Aware Energy-Efficient SRAMs. *IEEE Trans. on Communications*, 66 (10), 4826-4841.
- [23] Gurdasani H., Ananth, A. G., Thangadurai N. (2021). Channel Capacity Enhancement of MIMO System using Water-Filling Algorithm. *Turkish Journal of Computer and Mathematics Education*.12 (12), 192-201.
- [24] Wei S., Zheng Z. and Wu, C., Channel Power Allocation Optimization Based on Water-filling Algorithm in 5G. *J. Phys.: Conf. Ser.* 1871 012082.
- [25] Gul, O. M. (2022). Performance of History-based Water-Filling Algorithm for Energy-Efficient Data Transmission over Different Fading Channels . *Avrupa Bilim ve Teknoloji Dergisi*, (41) , 118-125 . DOI: 10.31590/ejosat.1112389.



## Özgeçmiş



**Ömer Melih Gül** (S'17, M'21), Orta Doğu Teknik Üniversitesi (ODTÜ) Elektrik ve Elektronik Mühendisliği Bölümü'nden lisans, yüksek lisans ve doktora derecelerini sırasıyla 2012, 2014 ve 2020 yıllarında aldı. Bu esnada aynı bölümde araştırma görevlisi olarak da görev yaptı. Uluslararası yayınları 11 dergi makalesi, 16 konferans bildirisi ve 4 kitap bölümünü kapsarken ulusal yayınları 3 dergi makalesi ve 3 konferans bildirisini kapsamaktadır.

IEEE Computer Society tarafından 2019 Lance Stafford Larson Üstün Öğrenci Makale Ödülü'nde (2019 Lance Stafford Larson Outstanding Student Paper Award) üçüncülük ödülüne layık görülmüştür. 2021 IEEE Rising Stars Global Konferansı'nda poster yarışmasında üçüncülük ödülüne layık görülmüştür. 2022 yılında Kanada'da Ottawa Üniversitesi Elektrik Mühendisliği ve Bilgisayar Bilimleri Okulu'nda doktora sonrası araştırmacı olarak çalıştı. 2022 yılında 48. Kablosuz Dünya Araştırma Forumu'nda (WWRF) en iyi konferans bildirisi ödülünü aldı. Mevcut durumda, İstanbul'da Bahçeşehir Üniversitesi Bilgisayar Mühendisliği Bölümü'nde Dr. Öğr. Üyesi olarak görev yapmaktadır.

2021'den bu yana IEEE Computer Society'de Region 8 (Avrupa, Orta Doğu ve Afrika Bölgesi) Koordinatörü olarak görev yapmaktadır. Nisan 2023'ten beri IEEE Computer Society Member&Geographic Activities (MGA) Board'da Özel Üye (Member-at-Large) olarak görev yapmaktadır. 2022 IEEE MGA Genç Profesyoneller Başarı Ödülü'ne (2022 IEEE MGA Young Professionals Achievement Award) layık görülmüştür. 2020-2021 yıllarında başkanlığını yaptığı IEEE Türkiye Genç Profesyonel Grup ile 2021 IEEE Region 8 Outstanding Young Professionals Affinity Group Award ve 2022 IEEE MGA Young Professionals Hall of Fame Honorable Mention ödülleri kazanmıştır.