



## YAPAY ZEKÂ UYGULAMASI İLE GÜNEŞ PANELİ SİSTEMİ ENERJİ ÜRETİMİ TAHMİNİ

Deniz ÖZER<sup>1</sup>, Bekir AKSOY<sup>2</sup>

<sup>1</sup>Mekatronik Mühendisliği, Isparta Uygulamalı Bilimler Üniversitesi, Isparta, Türkiye

<sup>2</sup>Mekatronik Mühendisliği, Isparta Uygulamalı Bilimler Üniversitesi, Isparta, Türkiye

[denizozer58@gmail.com](mailto:denizozer58@gmail.com), [bekiraksoy@isparta.edu.tr](mailto:bekiraksoy@isparta.edu.tr)

DOI: 10.57120/yalvac.1543369

**ÖZET:** Güneş paneli teknolojisi, güneş enerjisini elektrik enerjisine dönüştürerek sürdürülebilir ve temiz enerji üretimini desteklemektedir. Yapay zekâ, bu süreçte veri analizi, enerji yönetimi ve panel verimliliğinin optimizasyonu gibi alanlarda önemli katkılar sunmaktadır. Bu iki teknolojinin entegrasyonu, enerji üretimi ve tüketiminde daha yüksek verimlilik sağlamayı mümkün kılmaktadır. Bu çalışmada, sensörler aracılığıyla veri toplayarak güneş panellerinin gerçek performansını yapay zekâ tabanlı tahminlerle karşılaştırmak ve makine öğrenmesi yöntemleri ile güneş paneli kurulumu için en uygun alanları belirlemek amaçlanmaktadır. Elde edilen tahminlerin doğruluğu yüksek olduğu takdirde, sensörler ve yapay zekâ kullanılarak güneş paneli kurulumu olmaksızın da potansiyel enerji üretiminin tahmin edilebilmesi hedeflenmektedir. Çalışmada kullanılan yapay zeka modellerinden Gradient Boosting yapay zeka modeli  $R^2$  performans değerlendirme metriğine göre %97.04 doğruluk değeri ile en başarılı model olarak belirlenmiştir.

**Anahtar Kelimeler:** Güneş Paneli, Yapay Zekâ, Makine Öğrenmesi

## SOLAR PANEL SYSTEM ENERGY PRODUCTION ESTIMATION WITH ARTIFICIAL INTELLIGENCE APPLICATION

**ABSTRACT:** Solar panel technology is a key contributor to the production of sustainable and clean energy, facilitating the conversion of solar energy into electrical energy. Artificial intelligence plays a pivotal role in this process, particularly in areas such as data analysis, energy management, and optimization of panel efficiency. The combination of these two technologies facilitates enhanced efficiency in energy production and consumption. This study aims to evaluate the actual performance of solar panels in comparison with artificial intelligence-based predictions, by collating data through sensors, and to ascertain the optimal locations for solar panel installation through machine learning methods. Should the precision of the predicted outcomes be high, the potential energy production without solar panel installation will be estimated through the use of sensors and artificial intelligence. Among the artificial intelligence models used in the study, the Gradient Boosting artificial intelligence model was determined as the most successful model with an accuracy of 97.04% according to the  $R^2$  performance evaluation metric.

**Keywords:** Solar Panel, Artificial Intelligence, Machine Learning

## 1.GİRİŞ

Teknoloji gelişimi ile birlikte nüfus artışı nedeniyle her geçen gün enerji tüketimi artmaktadır [1]. Bu nedenle yenilenebilir enerji kaynaklarına olarak ilgi ve yatırımlar da hızlanmıştır. Yenilenebilir enerji kaynaklarından biri de güneştir. Yaşamın kaynağı olan güneş, doğanın enerjisinin büyük bir bölümünü sağlamaktadır. Güneş enerjisi, güneşin çekirdeğinde hidrojenin helyuma dönüşmesi sonucu ortaya çıkan güçlü bir enerji biçimidir. Güneş ışınları yoluyla dünyamıza ulaşan bu enerji, güneş kolektörleri, güneş santralleri ve fotovoltaik piller gibi farklı teknolojilerle değerlendirilmektedir. Bu teknolojiler, güneş enerjisini doğrudan ısıya veya dolaylı yollardan elektrik enerjisine dönüştürmemize olanak sağlamaktadır [2]. Fotovoltaik paneller, güneş enerjisini elektrik enerjisine üretmek için kullanılan en yaygın teknolojidir [3]. Fotovoltaik panellerden elde edilen elektrik enerjisinin verimliliği, coğrafi konum, iklim koşulları ve kurulum şekline göre farklılık gösterebilmektedir. Bu yüzden, güvenli ve ekonomik güç çıkışı değerlerini tahmin etmek ve sürece etki eden parametreleri belirlemek oldukça önemlidir. Fotovoltaik panellerin yaygınlaşmasıyla birlikte, değişken çevre koşullarına bağlı olarak üretilen enerjinin tahmini ve panel çıkış gücünü etkileyen faktörlerin detaylı bir biçimde incelenmesi oldukça önemlidir [4]. Güneş panellerinin ve diğer bileşenlerin etkin bir şekilde yönetilmesi de bir diğer önemli noktadır. Bu faktörlerin incelenmesinde sıklıkla yapay zekâ yöntemleri kullanılmaktadır. Yapay zekâ bilgisayarın akıl yürütme, problem çözme, anlam çıkarma ve genelleme gibi üst düzey bilişsel beceriler sergilemesi, yani insana özgü davranışları taklit etmesi olarak tanımlanmaktadır. Yapay zekâ fikrini ortaya ilk olarak çıkaran kişi Alan Turing'dir [5]. Alan Turing, sonradan Turing Testi olarak anılacak bir yöntem önererek, bir makinenin konuşma esnasında bir insan gibi davranıp davranmadığını değerlendirme fikrini sunmuştur. Yapay zekâ yöntemleri, robotik alanında da güvenlik sistemlerinin geliştirilmesi için kullanılmaktadır [6]. Bu test, yapay zekânın gelişimini ölçmek için pratik bir kriter olarak kabul edilmiştir [7]. Makine öğrenmesi ve derin öğrenme en temel yapay zekâ yapay zekânın alt kümesidir [8]. Makine öğrenmesi, elde edilen veri seti ve algoritma modeli kullanılarak matematik ve istatistik bilimiyle çıkarımlar yapmayı amaçlayan bir yöntemdir [9].

Çalışmada, çalışmaya özgü sıcaklık, nem ve ışık sensörlerinden elde edilen özgün veri seti yapay zekâ algoritmaları ile eğitilerek güneş panellerinin verimliliği ve güç üretim kapasitelerinin analiz edilmesi amaçlanmıştır. Beş farklı makine öğrenme yöntemi kullanılarak sıcaklık, nem ve ışık parametrelerine bağlı olarak güneş panelinin gerilimini belirlemeye çalışılmıştır. Elde edilen eğitim sonuçları test verileri ile analiz edilip performans değerlendirme metriklerine göre değerlendirilerek en başarılı makine öğrenme yöntemi çalışmada kullanılmıştır.

## 2. AKADEMİK LİTERATÜR

Gerçekleştirilen çalışma ile ilgili akademik literatür incelendiğinde;

Turgut, A. ve arkadaşları (2019), çalışmalarında topladıkları verileri Rastgele Orman ve farklı bir yapay zekâ modeli eğitip hava sıcaklığını tahmin etmişlerdir. Kullanmış oldukları yapay zekâ algoritmaları içerisinde Rastgele Orman algoritması ile %87.72 doğruluk oranını tespit etmişlerdir [10]. Akal, D., ve Umut, İ. (2022), çalışmalarında yapay sinir ağları ve K-Nearest Neighbors (KNN) yöntemi kullanarak sensörler aracılığıyla topladıkları verilerin makine öğrenmesi sonucu fotovoltaik panel (PV) çıkış gücünü tahminlemesi yapmışlardır. Yapay sinir ağları (YSA) %98.79 doğruluk değeri ile en başarılı model olarak belirlemişlerdir [4]. Güç, Resul (2016) çalışmasında yapay sinir ağları kullanarak Bilecik ilinin 2013 yılı sıcaklık verilerini %91 doğruluk değeri ile belirlemişlerdir [11]. Gün, Ali Rıza (2023), çalışmasında güneş paneli güç çıkışı tahminlemesi yapmıştır. Çalışma içerisinde Tam Kapsamlı Toplu Ampirik Mod Ayırıştırması ve Uyarlanabilir Gürültü (CEEMDAN) ile Çok Katmanlı Algılayıcı (MLP) ve farklı yapay zekâ modellerini hibrit ve tekil testlere tabi tutmuştur. Testleri sonucunda %91 doğruluk değeri ile en başarılı modeli CEEMDAN-MLP hibrit modeli olarak tespit etmişlerdir [12]. Reşat, H. G. (2020), Oto-Regresif Entegre Hareketli Ortalama (ARIMA) ile YSA yapay zekâ modellerini hibrit olarak kullanarak Levenberg-Marquardt optimizasyon tekniği ile enerji tahminlemesi yapmıştır ARIMA yapay zekâ modelinin YSA algoritması ile hibrit kullanımıyla %99 doğruluk oranına ulaşmıştır [13]. Macit Sezikli, N. (2023), çalışmasında Rastgele Orman ve farklı yapay zekâ modelleri eğiterek ve meteorolojik verileri kullanarak güneş enerjisi üretimi tahmini yapmıştır. Kullandığı yapay zekâ modelleri arasında, en yüksek performans değeri %96.84 oranıyla Rastgele Orman modeliyle elde edilmiştir [14]. Akı, O., & Akal, T. T., çalışmasında Destek Vektör Regresyonu (SVR) ve farklı yapay zekâ modellerine makine öğrenimi yaparak fotovoltaik panellerin haftalık enerji üretimlerini tahmin etmişlerdir. SVR yapay zekâ algoritmasında %93 doğruluk oranı ile en yüksek değeri radyal fonksiyonu ile almışlardır [15]. Yüzer, E. Ve arkadaşları (2023), çalışmalarında YSA modelini kullanarak PV sistemlerin çıkış gücü tahminlemesi yapmışlardır. YSA modelini kullanarak PV sistem çıkış gücü için %96.68 oranında performans değeri elde etmişlerdir [16]. Uğuz, S., Oral, O., & Çağlayan, N. (2019), çalışmalarında Çoklu Doğrusal Regresyon (MLR) ve farklı yapay zekâ modellerini veri seti ile eğitip üretilen güneş paneli elektrik gücünü tahmin etmişlerdir.

Yapılan testler sonucu MLR yapay zekâ modeli ile %95.59 performans değeri elde etmişlerdir [17]. Yukarıda incelenen akademik çalışmalara ait özet bilgiler Tablo 1’de verilmiştir.

**Tablo 1.** İlgili Çalışmalar ile Karşılaştırma Tablosu

<b>İlgili Çalışmaların Karşılaştırması</b>			
<b>Çalışma</b>	<b>Yapay Zekâ Modeli</b>	<b>Performans Değerleri</b>	<b>R<sup>2</sup> Performans Değerlendirme Metrik Sonuçları</b>
Turgut, A., Temir, A., Aksoy, B., Özsoy, K. (2019)	Rastgele Orman	RMSE=0,052, MAE=0,033	87.72%
Akal, D., & Umut, İ. (2022)	YSA	MSE=0.102, MAE=0.012, MAPE= %3.256	98.79%
Güç, Resul. (2016)	YSA	RMSE=0,052, MAE= 0,033	91%
Gün, Ali Rıza. (2023)	CEEMDAN-MLP Hibrit	RMSE=0.345, MSE=0.119, MAE=0.140	91%
Reşat, H. G. (2020)	ARIMA-YSA Hibrit	MSE=0.03	99%
Macit Sezikli, N. (2023)	Rastgele Orman	MAE=0.012, MSE=0.007, RMSE=0.027	96.84%
Akı, O., & Akal, T. T. (2023)	SVR	MAE=0.18, RMSE=0.262, MAPE=%70.54	93%
Yüzer, E. Ve Arkadaşları (2023)	YSA	RMSE=0.757, MAPE=16,067	96.68%
Uğuz, S., Oral, O., & Çağlayan, N. (2019)	MLR	MAE=0.039, MSE=0.002, MedAE=0.031	95.59%
Çalışmada	Gradient Boosting(GBR)	MSE=0.899, RMSE=0.948, MAE=0.517, MAPE=%4.3	97.04%

### 3. MATERYAL ve METOT

#### 3.1 Materyal

Çalışmanın materyal bölümü, güneş paneli ve sensörler, Raspberry Pi 5, veri seti, yapay zekâ modelleri, performans değerlendirme metrikleri olmak üzere beş ana başlık altında toplanmıştır. Bu bileşenlere ait detaylı bilgiler aşağıda verilmiştir.

##### 3.1.1 Güneş Paneli ve Sensörler

Güneş enerjisini elektrik enerjisine dönüştüren fotovoltaik panelin güç çıkışını ölçmek için özel bir deney düzeneği hazırlanmıştır. Düzenekte voltaj sensörü ile fotovoltaik panelin voltaj verisi toplanmıştır. Ayrıca sıcaklık ve nem, ışık sensörü ile veri toplanmıştır. Sensörlerden elde edilen verilerin analog olarak okunması için Arduino Uno mikroişlemcisi kullanılmıştır.

##### 3.1.1.1 Güneş Paneli


Çalışmada sadece gerilimini ölçmek kaydıyla 25 watt (20,70 Volt × 1,21 Amper) gücünde 36 hücreli monokristal bir fotovoltaik panel kullanılmıştır. Panelin görseli aşağıdaki Şekil 1’de verilmiştir.




Şekil 1. 25 watt(W) monokristal güneş paneli

### 3.1.1.2 Sensörler


Çalışmada sıcaklık ve nem sensörü, ışık sensörü, voltaj sensörü olmak üzere 3 adet sensör kullanılmıştır. Sensörlerin görselleri aşağıdaki Şekil 2-4'de verilmiştir.



Şekil 2. DHT-22 Sensörü



Şekil 3. LDR-11-LM393 Işık Sensörü



Şekil 4. Voltaj Sensörü Sıcaklık ve Nem

### 3.1.2 Raspberry Pi Tek Kartlı Bilgisayar

Arduino Uno mikroişlemcisinin kontrolü ve güç beslemesi, ana bilgisayar ile uzaktan bağlantı ve veri toplama işlemi için Raspberry pi tek kartlı bilgisayar kullanılmıştır. Ek olarak uzaktan bağlantı olmasına rağmen internet erişimi kısıtlandığında saat ve tarih ayarlarının değişmemesi için real time clock (RTC) yani gerçek zamanlı saat modülü kullanılıp sistemi yakından kontrol etmek için LCD ekran eklenmiştir. Raspberry Pi 5, Arduino Uno , RTC zaman modülü, LCD ekran görselleri aşağıda bulunan Şekil 5-8'de verilmiştir.



Şekil 5. Raspberry Pi 5



Şekil 6. Arduino UNO R3



Şekil 7. I2C LCD Ekran



Şekil 8. RTC Modülü

### 3.1.3 Veri Seti

Çalışmada kullanılan sistemde 12.07.2024 ile 12.08.2024 tarihi arasında düzenli olarak panelden ve sensörlerden toplanan değerler kaydedilerek Raspberry Pi 5 tek kartlı bilgisayarına aktarılmıştır. Düzenli olarak sık aralıklarda voltaj, sıcaklık, nem, ışık düzeyine ait toplam 634641 adet veri toplanmıştır.

### 3.1.4 Yapay Zekâ Modelleri

Çalışmada veri tahmini için kullanılan Lineer Regresyon, Ridge Regresyon, Lasso Regresyon, Rastgele Orman Regresyon, Gradient Boosting yapay zekâ modelleri ve bu modellere ait detaylı bilgiler aşağıda verilmiştir.

#### 3.1.4.1 Lineer Regresyon (Linear Regression)

Lineer Regresyon, Amacı, bağımlı değişkenin bağımsız değişkenlerle olan lineer ilişkisini modelleyerek gelecekteki değerleri tahmin etmektir. Bu model, bağımlı değişkenin, bağımsız değişkenlerin katsayılarıyla çarpımının toplamı olarak ifade edilebileceği varsayımına dayanır. Katsayılar, bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerini gösterir [14].

#### 3.1.4.2 Ridge Regresyon (Ridge Regression)

Ridge Regresyon'da amaç, hata kareleri toplamını en aza indiren katsayıları belirlemektir. Düzenleme şiddeti alpha parametresi ile ayarlanır. Alpha değeri arttıkça düzenleme etkisi artar, bu da modelin daha basit ve düzgün hale gelmesini sağlar. Ancak, alpha değeri azaldığında daha fazla özellik devreye girer ve bu da modelin karmaşıklığını artırır [14].

#### 3.1.4.3 Lasso Regresyon (Lasso Regression)

Lasso Regresyon, doğrusal regresyon modellerinde çoklu bağlantı sorununu çözmek ve Ridge regresyonun tüm değişkenleri modelde tutma dezavantajını ortadan kaldırmak amacıyla üretilmiştir. Lasso Regresyon'da temel hedef, hata kareleri toplamını en aza indiren katsayıları belirlemektir [18].

#### 3.1.4.4 Rastgele Orman Regresyon (Random Forest Regressor)

Rastgele Orman Regresyon, makine öğrenmesinde yaygın olarak kullanılan bir algoritmadır ve hem sınıflandırma hem de regresyon problemlerinde yüksek doğruluk sağlar. Bu model, karar ağaçlarını bir araya getirir ve bu modelleri sırasıyla ekleyerek kayıp fonksiyonunu minimize eder. Sınıflandırma işlemlerinde, veriyi belirli bir sınıfa atamak veya her sınıfın olasılığını hesaplamak amacıyla kullanılır. Regresyon problemlerinde ise, sayısal değerlerin tahmininde etkili bir araçtır [14].

#### 3.1.4.5 Gradient Boosting (GBR)

Gradient Boosting her yeni model, önceki modellerin hatalarını düzeltmeye çalışır. Bu süreç, her iterasyonda hatayı azaltarak güçlü bir tahminleyici oluşturur. Hem regresyon hem de sınıflandırma problemlerinde etkili olan bu teknik, düşük hata oranları ve yüksek yorumlama sağlar [19].

### 3.1.5 Performans Değerlendirme Metrikleri

Çalışma içerisinde kullanılan beş farklı makine öğrenme algoritmasından elde edilen sonuçların değerlendirilebilmesi için Mean Squared Error (MSE), Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE), MAE, Median Absolute Error (MedAE), R-Squared ( $R^2$ ) performans metrikleri kullanılmıştır. Çalışmada kullanılan MAPE,  $R^2$ , MSE, RMSE [20], MAE, MedAE [21] performans değerlendirme metriklerinin denklemleri sırasıyla, Denklem (1-6)'te verilmiştir.

$$MSE = \frac{1}{m} \sum_{i=1}^m (Y_i - \hat{Y}_i)^2 \quad (1)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (Y_i - \hat{Y}_i)^2} \quad (2)$$

$$MAPE = \frac{100}{m} \sum_{i=1}^m \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (3)$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |Y_i - \hat{Y}_i| \quad (4)$$

$$MedAE = median(|Y_i - \hat{Y}_i|) \quad (5)$$

$$R^2 = 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y})^2} \quad (6)$$

Denklemlerde kullanılan ifadeler aşağıda belirtilmiştir;

$Y_i$ : Gerçek Değer

$\hat{Y}_i$ : Tahmin Edilen Değer

$\bar{Y}$ : Gerçek Değerlerin Ortalaması

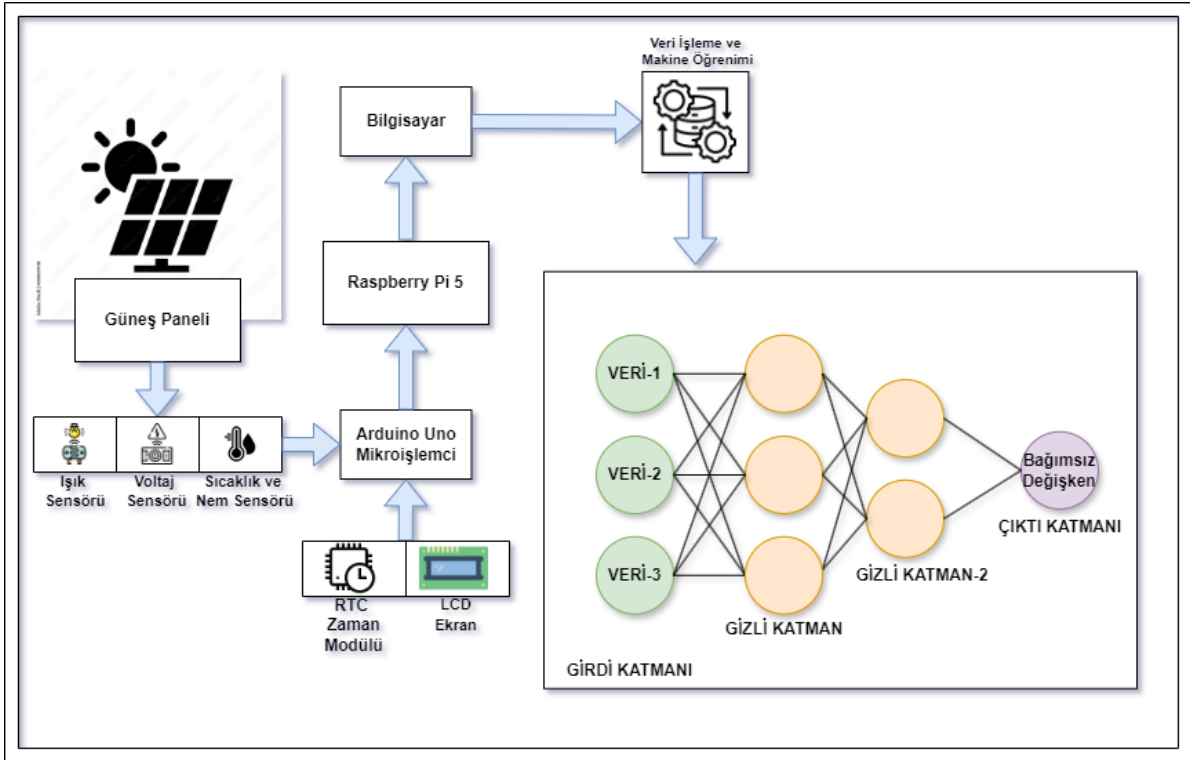
$m$ : Toplam Veri Noktası

$i$ : Index

### 3.2. Metot

#### 3.2.1 İş Akış Diyagramı

Çalışmanın iş akış diyagramı Şekil 9'da verilmiştir. Ayrıca iş akış diyagramı açıklanmıştır.



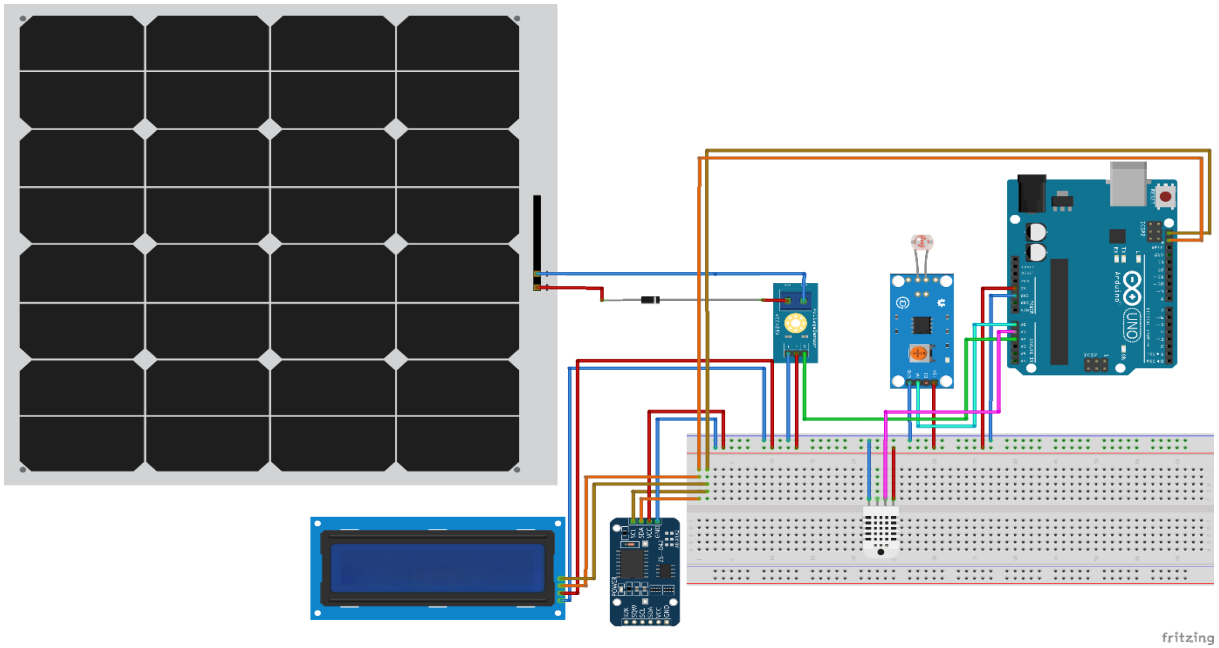
Şekil 9. Sistem Akış Diyagramı

Şekil 9'da görüldüğü gibi çalışmanın ilk aşamasında güneş enerjisini elektrik enerjisine dönüştürmek için fotovoltaik panel tasarlanmıştır. Tasarlama işlemi tamamlandıktan sonra çevre koşullarının verilerini analog olarak okumak için ışık, sıcaklık ve nem sensörü; fotovoltaik panelin ürettiği elektrik enerjisini analog olarak okumak

için voltaj sensörü kullanılmıştır. Ayrıca olası internet erişim problemleri için tarih ve saat ayarlarında herhangi bir problem yaşanmaması için RTC modülü ve sistemi yakından kontrol etmek için LCD ekran kullanılmıştır. Üçüncü aşamada analog verilerin okunması için Arduino Uno mikroişlemcisi kullanılıp Raspberry Pi 5 gönderilmiştir. Dördüncü aşamada ise Raspberry Pi 5 kartı üzerinde depolanan özgün veri seti hazırlanmıştır. Ayrıca Arduino Uno mikroişlemcisinin yazılım ayarları yapıp ana bilgisayar ile uzaktan bağlantı gerçekleştirilmiştir. Böylece sistemin uzaktan kontrolü de sağlanmıştır. Son aşamada ise elde edilen özgün veri seti verilerin %80 (507712 adet) eğitim %20 (126928 adet) test olacak şekilde rastgele ayrılarak Lineer Regresyon, Ridge Regresyon, Lasso Regresyon, Rastgele Orman, Gradient Boosting yapay zekâ algoritmaları kullanılarak 200 epoch boyunca eğitilmiştir. Eğitim işleminden sonra yapay zekâ modelleri test verileri ile analiz edilerek elde edilen sonuçlar MSE, MAPE, RMSE, MAE, MedAE,  $R^2$  performans değerlendirme metriklerine göre değerlendirilmiştir.

### 3.2.2 Elektronik Devre Tasarımı

Çalışmanın elektronik devre tasarımı Şekil 10'da verilmiştir. Ayrıca elektronik devre tasarımı açıklanmıştır.



Şekil 10. Elektronik Devre Tasarımı

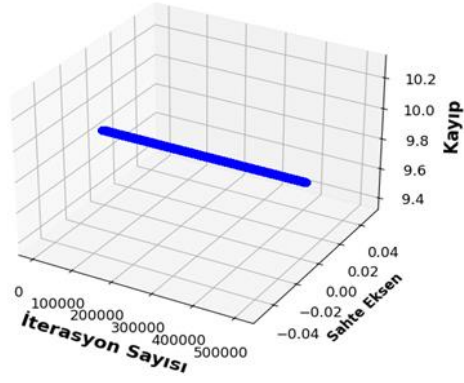
İlk olarak Şekil 10'da görüldüğü üzere fotovoltajik panel, güneşten aldığı ışın enerjisini elektrik enerjisine dönüştürmektedir. Dönüştürülen elektrik enerjisinin değerini okumak için voltaj sensörüne bağlanmıştır. Ayrıca ışık, sıcaklık ve nem değerini ölçmek için kullanılan LDR-11-LM393 ışık sensörü ve DHT-22 sıcaklık ve nem sensörü de çevreden veri toplamaktadır. Bu üç sensör, sistemi yakından kontrol etmek için kullanılan LCD ekran ve olası internet erişim problemleri için tarih ve saat ayarlarında herhangi bir problem yaşanmaması için kullanılan RTC modülü breadboard aracılığı ile Arduino Uno mikroişlemcisine bağlanmıştır. Sıcaklık ve nem sensörü, ışık sensörü ve voltaj sensörünün sinyal ucu sırasıyla A0, A1, A2 analog girişlerine bağlanmıştır. LCD ekran ve RTC modülünün sinyal uçları da SLA ve SCL uçlarına bağlanmıştır.

## 4. ARAŞTIRMA BULGULARI

### 4.1 Kayıp Grafikleri


Çalışmada ışık, voltaj, sıcaklık ve nem parametreleri giriş, üretilen elektrik enerjisi miktarı çıkış parametresi olmak üzere toplam 634641 veriler beş farklı makine öğrenme algoritması ile eğitilmiştir. Eğitilen yapay zekâ modellerine ait kayıp grafikleri Şekil 11-14'te gösterilmiştir.

**Lineer Regresyon - Kayıp (Loss) Grafiği (3D)**



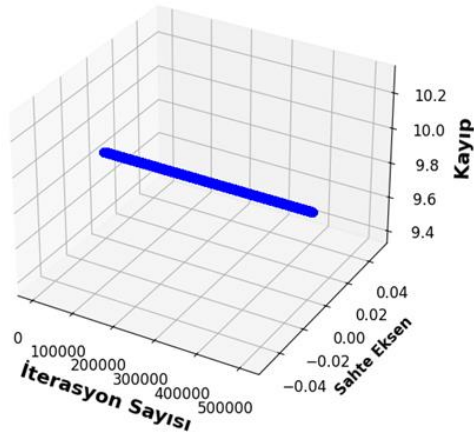
Şekil 11. Lineer Regresyon Kayıp Grafiği

**Ridge Regresyon - Kayıp (Loss) Grafiği (3D)**



Şekil 12. Ridge Regresyon Kayıp Grafiği

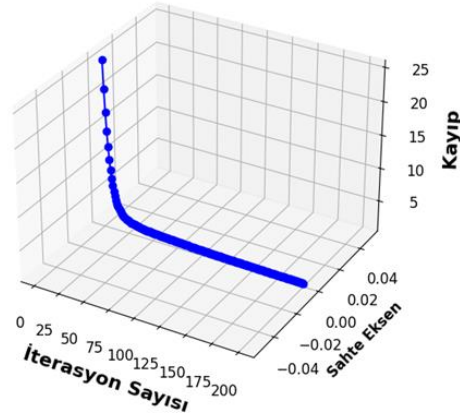
**Lasso Regresyon - Kayıp (Loss) Grafiği (3D)**



Şekil 13. Lasso Regresyon Kayıp Grafiği



### Gradient Boosting - Kayıp (Loss) Grafiği (3D)




Şekil 14. Gradient Boosting Kayıp Grafiği


Rastgele Orman yapay zekâ modelinin eğitim sürecinde kaybın nasıl değiştiğini izlemek, modelin doğası gereği mümkün değildir. Çünkü eğitim süreci iteratif değildir ve her bir ağacın kaybı bağımsız olarak değerlendirilir. Çalışmada, Rastgele Orman algoritması haricindeki diğer algoritmalar olan Lineer Regresyon, Ridge Regresyon, Lasso Regresyon algoritmalarını kayıp grafiklerinde herhangi bir değişim gözlenmediğinden dolayı net bir biçimde sonuçlar izlenememiştir. Ancak Gradient Boosting algoritmasının grafiğinde 200 katmandan sonra kaybın olmadığı kayıp değerinin neredeyse sifra yakın bir değer olduğu tespit edilmiştir.

#### 4.2 Yapay Zekâ Modellerinin Performans Değerlendirme Metrikleri


Çalışmanın ikinci aşamasında ise beş farklı yapay zekâ algoritmasının eğitimlerinden elde edilen sonuçlar MSE, MAPE, RMSE, MAE, MedAE,  $R^2$  performans değerlendirme metriklerine göre grafikler oluşturularak aşağıdaki sonuçlar Şekil 15-19'da verilmiştir.



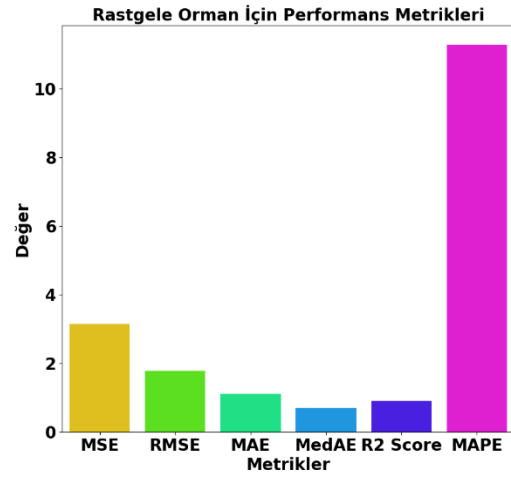
Şekil 15. Lineer Regresyon İçin Performans Metrikleri




Şekil 16. Ridge Regresyon İçin Performans Metrikleri



Şekil 17. Lasso Regresyon İçin Performans Metrikleri



Şekil 18. Rastgele Orman İçin Performans Metrikleri



Şekil 19. Gradient Boosting İçin Performans Metrikleri

Çalışmada ilk olarak Lineer Regresyon yapay zekâ modeli eğitilerek performans değerlendirme metriklerine göre sonuçları Şekil.15’de gösterilmiştir. Şekil.15 incelendiğinde Lineer Regresyon modelinin MSE değeri 9.86, RMSE değeri 3.14, MAE değeri 2.56, Medyan mutlak hata değeri 2.27, MAPE %25.54, R<sup>2</sup> değeri %67,93 olarak elde edilmiştir. Lineer Regresyon modelinden elde edilen matematiksel ifade Denklem (7)’de gösterilmiştir.

$$Panel\ Voltajı = -5.74 + 0.20 \times Sıcaklık + 0.03 \times Nem + 0.02 \times Işık\ Değeri \quad (7)$$

Denklem incelendiğinde bütün sensörlerin pozitif etki yaptığı tespit edilmiştir. Tahmin etkisini en yüksek sıcaklık katsayısı (0.20) verirken en düşük etkiyi ışık değeri katsayısı (0.02) sağlamıştır.

Çalışmada ikinci olarak Ridge Regresyon yapay zekâ modeli eğitilerek performans değerlendirme metriklerine göre sonuçları Şekil.16’da gösterilmiştir. Şekil.16 incelendiğinde Ridge Regresyon modelinin MSE değeri 9.86, RMSE değeri 3.14, MAE değeri 2.56, MedAE değeri 2.27, MAPE değeri %25.54, R<sup>2</sup> değeri %67.93 olarak elde edilmiştir. Ridge Regresyon modelinden elde edilen matematiksel ifade Denklem (8)’de gösterilmiştir.

$$Panel\ Voltajı = -5.74 + 0.20 \times Sıcaklık + 0.03 \times Nem + 0.02 \times Işık\ Değeri \quad (8)$$

Çalışmada üçüncü olarak Lasso Regresyon yapay zekâ modeli eğitilerek performans değerlendirme metriklerine göre sonuçları Şekil.17’de gösterilmiştir. Şekil.17 incelendiğinde Lasso Regresyon modelinin MSE değeri 9.86,

RMSE değeri 3.14, MAE değeri 2.56, MedAE değeri 2.26, MAPE değeri %25.53, R<sup>2</sup> değeri %67.91 olarak elde edilmiştir. Lasso Regresyon modelinden elde edilen matematiksel ifade Denklem (9)'de gösterilmiştir.

$$\text{Panel Voltajı} = -3.97 + 0.16 \times \text{Sıcaklık} + 0.02 \times \text{Nem} + 0.02 \times \text{Işık Değeri} \quad (9)$$

Çalışmada dördüncü olarak Rastgele Orman yapay zekâ modeli eğitilerek performans değerlendirme metriklerine göre sonuçları Şekil.18'de gösterilmiştir. Şekil.18 incelendiğinde Rastgele Orman modelinin MSE değeri 3.13, RMSE değeri 1.77, MAE değeri 1.11, MedAE değeri 0.70, MAPE değeri %11.27, R<sup>2</sup> değeri %89,80 olarak elde edilmiştir. Veriler incelendiğinde Rastgele Orman modelinin önceki 3 modelden çok daha yüksek doğrulukta tahminlerde bulunduğu görülmektedir.

Rastgele Orman yapay zekâ modelinde karar ağacı tabanlı yöntemler kullanıldığı için doğrusal bir denklem yazmak mümkün değildir. Çünkü bu yapay zekâ modeli verinin karmaşık ve doğrusal olmayan ilişkilerini yakalamak için tasarlanmıştır. Bu sebeple bu modelin üzerinde makine öğrenimi için kullanılan özelliklerin önem derecesi Tablo 2'de listelenmiştir.

**Tablo 2.** Rastgele Orman Önem Derecesi

Işık Değeri	Nem	Sıcaklık
0.8926	0.0538	0.0536

Rastgele Orman modelinin analizine göre, 'Işık Değeri' özelliği, tahminlerde belirleyici bir rol oynamaktadır ve bu özelliğin önemi '0.8926' olarak ölçülmüştür. Buna karşın, 'Nem' ve 'Sıcaklık' özelliklerinin önemi sırasıyla '0.0538' ve '0.0536' olarak bulunmuş, bu da bu iki özelliğin modelin tahminlerinde nispeten düşük etkiye sahip olduğunu göstermektedir.

Çalışmada beşinci olarak Gradient Boosting yapay zekâ modeli eğitilerek performans değerlendirme metriklerine göre sonuçları Şekil.19'da gösterilmiştir. Şekil.19 incelendiğinde Rastgele Orman modelinin MSE değeri 0.90, RMSE değeri 0.95, MAE değeri 0.52, MedAE değeri 0.27, MAPE değeri %4.35, R<sup>2</sup> değeri %98.04 olarak elde edilmiştir.

Gradient Boosting yapay zekâ modelinde karar ağacı tabanlı yöntemler kullanıldığı için doğrusal bir denklem yazmak mümkün değildir. Çünkü bu yapay zekâ modeli verinin karmaşık ve doğrusal olmayan ilişkilerini yakalamak için tasarlanmıştır. Bu sebeple bu modelin üzerinde makine öğrenimi için kullanılan özelliklerin önem derecesi Tablo 3'de listelenmiştir.

**Tablo 3.** Gradient Boosting Önem Derecesi

Işık Değeri	Nem	Sıcaklık
0.8427	0.0825	0.0748

Gradient Boosting modelinin analiz sonuçlarına göre, 'Işık Değeri' özelliği tahminlerde en yüksek öneme sahip olup, bu özelliğin önemi '0.8427' olarak hesaplanmıştır. Buna karşılık, 'Nem' ve 'Sıcaklık' özelliklerinin önem dereceleri sırasıyla '0.0748' ve '0.0825' olarak bulunmuş, bu da bu özelliklerin model tahminlerinde daha az etkili olduğunu göstermektedir.

#### 4.3 Çalışmada Kullanılan Yapay Zekâ Modelleri Karşılaştırması

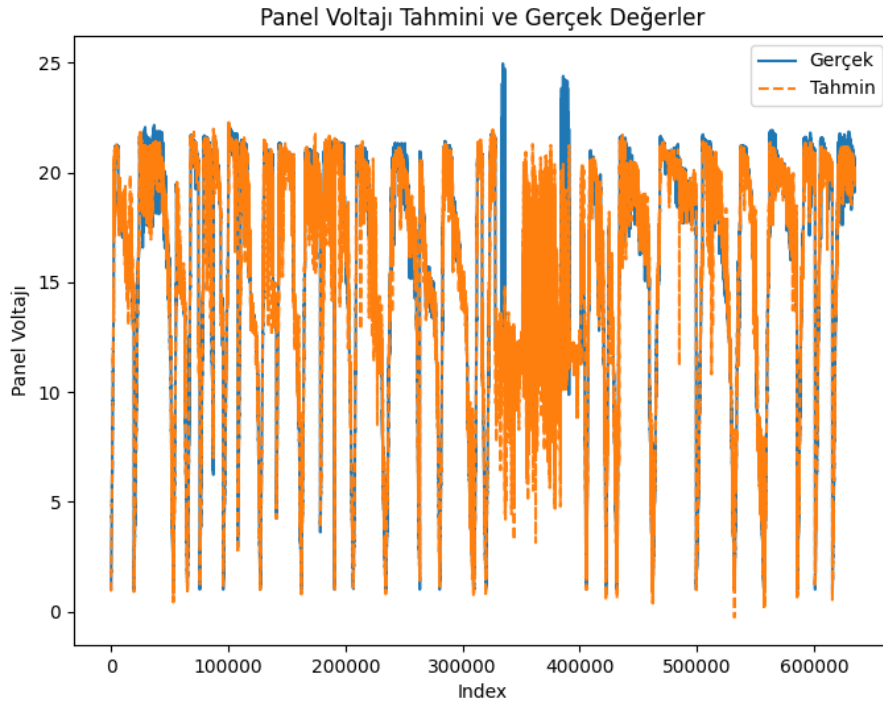
Çalışmada kullanılan beş makine öğrenme algoritmasından elde edilen sonuçlar Tablo 4'de verilmiştir. Tablo 4 incelendiğinde en başarılı modelin R<sup>2</sup> performans değerlendirme metriğine göre %97,04 doğruluk oranı ile Gradient Boosting algoritması olduğu tespit edilmiştir.

**Tablo 4.** Yapay Zekâ Modelleri-Performans Metrikleri Karşılaştırma Grafiği

Yapay Zekâ Modelleri- Performans Metrikleri Karşılaştırma Tablosu						
	MSE	RMSE	MAE	MedAE	MAPE	R <sup>2</sup> DEĞERİ
<b>Lineer Regresyon</b>	9,8613	3,1402	2,5652	2,2739	25,541	67,93%
<b>Ridge Regresyon</b>	9,8613	3,1402	2,5652	2,2739	25,541	67,93%
<b>Lasso Regresyon</b>	9,8677	3,1412	2,5683	2,2671	25,5316	67,91%
<b>Rastgele Orman</b>	3,1361	1,7709	1,1182	0,7002	11,2761	89,80%
<b>Gradient Boosting</b>	0,9098	0,9538	0,5233	0,2728	4,3506	97,04%

#### 4.4 Panel Voltajı Tahmini ve Gerçek Voltaj Değeri Grafiği

Çalışmada en başarılı yapay zekâ yöntemi olarak belirlenen Gradient Boosting yapay zekâ algoritması için örnek bir aya ait gerçek veriler ile tahmin değerlerine ait grafik Şekil 20’de verilmiştir.

**Şekil 20.** Panel voltajı Tahmini ve Gerçek Değerler Karşılaştırma Tablosu

## 5. SONUÇ

Günümüzde çevre kirliliği dünyanın en önemli problemlerinden birisidir. Özellikle elektrik enerji üretiminde yenilenebilir enerji kaynaklarına olan ihtiyaç gün geçtikçe artmaktadır. Önemli yenilenebilir enerji kaynaklarından birisi de güneşten elde edilen elektrik enerjisidir. Çalışmada prototip düzeyde hazırlanan bir sistem ile güneş enerjisinden elektrik elde edilerek üretim esnasındaki ısı, ışık, nem verileri toplanarak üretilen elektrik enerjisindeki etkin parametreler yapay zekâ yöntemleri ile belirlenmeye çalışılmıştır. Çalışmaya özgü oluşturulan özgü veri seti beş farklı yapay zekâ algoritması ile eğitilerek elde edilen sonuçlar MSE, MAPE, RMSE, MAE, MedAE, R<sup>2</sup> performans değerlendirme metriklerine göre değerlendirilmiştir. Çalışmada kullanılan beş farklı yapay zekâ yönteminden Gradient Boosting yapay zekâ algoritması R<sup>2</sup> performans değerlendirme metriğin %97,04

doğruluk oranı en başarılı model olarak tespit edilmiştir. Ayrıca bu doğruluk oranına ait matematiksel önem değerleri elde edilerek üretilen elektrik enerjisi miktarına giriş parametre etkisi belirlenmiştir. Bu parametrelerden ışık değerinin üretilen elektrik enerjisi değerine en çok etki eden parametre olduğu belirlenmiştir.

İlerleyen akademik çalışmalarda güneş enerjisinden elde edilen elektrik enerjisi için aşağıda maddeler halinde verilen öneriler dikkate alınarak yeni çalışmalar yapılması hedeflenmektedir.

- Modelin genelleme yeteneğini değerlendirmek için daha fazla farklı veri setleri üzerinde test yapılmalıdır.
- Çapraz doğrulama yöntemi kullanarak modelin verileri sadece ezberleme, ya da aşırı öğrenme(overfitting) yapıp yapmadığı kontrol edilebilir.
- Çalışmada kullanılan bağımsız değişkenlerin etkisi daha ayrıntılı bir şekilde incelenmeli ve modelin tahminlerini yönlendiren önemli faktörler belirlenmelidir.
- Modelin zaman içindeki performans değişimini anlamak için dinamik bir analiz yapılabilir.
- Bu öneriler, regresyon modelinin pratik uygulamalardaki etkinliğini daha da artırmak ve gelecekteki araştırmalara temel teşkil etmek amacıyla sunulmuştur.

## 6. TEŞEKKÜR

Çalışmanın gerçekleşmesinde 1919B012303682 numaralı proje ile maddi destek sağlayan TÜBİTAK'a teşekkür ederiz.

## 7. KAYNAKLAR

[1] Çetin, Ö., & Isık, A. H. (2022). Derin Öğrenme ile Güneş Enerjisi Santrallerinde Aylık Elektrik Üretim Tahmini. Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 13(Ek (Suppl.) 1), 382-387.

[2] Koç, E., & Kaya, K. (2015). Enerji kaynakları–yenilenebilir enerji durumu. Mühendis ve Makina, 56(668), 36-47.

[3] Mastar, E. (2011). Güneş panelleri için güneş takip mekanizmasının tasarımı (Master's thesis, Bursa Uludağ University (Turkey)).

[4] Akal, D., & Umut, İ. (2022). Fotovoltaik Panellerde Güç Tahminlenmesi için Yapay Zekâ Yöntemlerinin Kullanılması. Tekirdağ Ziraat Fakültesi Dergisi, 19(2), 435-445.

[5] Pirim, A. G. H. (2006). Yapay zekâ . Yaşar Üniversitesi E-Dergisi, 1(1), 81-93.

[6] Ozkahraman, M., Yılmaz, C., & Livatyali, H. (2021). Design and validation of a camera-based safety system for fenceless robotic work cells. Applied Sciences, 11(24), 11679.

[7] Akoglan, C. (2024). Dil, Düşünce ve Turing: Davidson'ın Makine Zekâ sının Sınırlarına İlişkin Görüşleri. Felsefe Dünyası (79), 147-164.

[8] Aylak, B. L., & Oral, O. (2021). Yapay zekâ ve makine öğrenmesi tekniklerinin lojistik sektöründe kullanımı. El-Cezeri, 8(1), 74-93.

[9] Arslankaya, S., & Toprak, Ş. (2021). Makine Öğrenmesi ve Derin Öğrenme Algoritmalarını Kullanarak Hisse Senedi Fiyat Tahmini. International Journal of Engineering Research and Development, 13(1), 178-192.

[10] Turgut, A., Temir, A., Aksoy, B., & Özsoy, K. (2019). YAPAY ZEKÂ YÖNTEMLERİ İLE HAVA SICAKLIĞI TAHMİNİ İÇİN SİSTEM TASARIMI VE UYGULAMASI. International Journal of 3D Printing Technologies and Digital Industry, 3(3), 244-253.

[11] Güç, R. (2016). Bilecik ili için güneş enerjisi analizi ve yapay sinir ağları ile hava sıcaklığı tahmini (Master's thesis, Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü).

- [12] Gün, Ali Rıza. (2023). Kısa Dönemli Fotovoltaik Güç Tahmini İçin Geliştirilen Yenilikçi Bir Hibrit Modelin Analizi ve Uygulaması. (Yayımlanmamış Doktora Tezi). Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Bilecik.
- [13] Reşat, H. G. (2020). Sürdürülebilir enerji yönetimi için yapay sinir ağları ve ARIMA metotları kullanılarak melez tahmin modelinin tasarlanması ve geliştirilmesi: Tütün endüstrisinde vaka çalışması. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 35(3), 1129-1140.
- [14] Macit Sezikli, N. (2023). Makine öğrenmesi yöntemiyle yenilenebilir güneş enerjisi üretiminin meteorolojik veriler kullanılarak tahmin analizi (Master's thesis, İstanbul Gelişim Üniversitesi Lisansüstü Eğitim Enstitüsü).
- [15] Akı, O., & Akal, T. T. DESTEK VEKTÖR REGRESYON (SVR) YÖNTEMİ KULLANILARAK HAFTALIK DÖNEMDE FOTOVOLTAİK PANEL ENERJİ TAHMİNİ.
- [16] Yüzer, E. Ö., Bozkurt, A., & Barutçu, İ. Ç. (2023). FOTOVOLTAİK SİSTEM ÇIKIŞ GÜCÜNÜN YAPAY SİNİR AĞLARI VE MATLAB/SİMULİNK MODELLERİNİN ENTEGRASYONU İLE BELİRLENMESİ. Mühendislik Bilimleri Ve Tasarım Dergisi, 11(2), 551-563.
- [17] Uğuz, S., Oral, O., & Çağlayan, N. (2019). PV Güç Santrallerinden Elde Edilecek Enerjinin Makine Öğrenmesi Metotları Kullanılarak Tahmin Edilmesi. International Journal of Engineering Research and Development, 11(3), 769-779.
- [18] Aslan, S., & Yıldız, T. (2022). Makine öğrenmesinde rastgele oran ve sıralı küme örnekleme yöntemlerinin doğrusal regresyon modellerine etkisi. Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 24(70), 29-36.
- [19] Wang, F. K., & Mamo, T. (2020). Gradient boosted Regresyon model for the degradation analysis of prismatic cells. Computers & Industrial Engineering, 144, 106494.
- [20] Çetiner, H., & Kara, B. (2022). Recurrent neural network based model development for wheat yield forecasting. Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi, 9(16), 204-218.
- [21] Shcherbakov, M. V., Brebels, A., Shcherbakova, N. L., Tyukov, A. P., Janovsky, T. A., & Kamaev, V. A. E. (2013). A survey of forecast error measures. World applied sciences journal, 24(24), 171-176.