

**DOKUZ EYLÜL ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**MAKİNE ÖĞRENİMİ TEKNİKLERİ İLE GÜNEŞ**  
**İŞİNİMİ VE GÜÇ KESTİRİMİ**

**Can Yunus Erözden**

**Ekim, 2023**

**İZMİR**

# MAKİNE ÖĞRENİMİ TEKNİKLERİ İLE GÜNEŞ IŞINIMI VE GÜÇ KESTİRİMİ

Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi

İstatistik Anabilim Dalı, Veri Bilimi Programı

Can Yunus Erözden

Ekim, 2023

İZMİR

## YÜKSEK LİSANS TEZİ SINAV SONUÇ FORMU

**CAN YUNUS ERÖZDEN**, tarafından **PROF. DR. SELMA GÜRLER** yönetiminde hazırlanan “**MAKİNE ÖĞRENİMİ TEKNİKLERİ İLE GÜNEŞ IŞINIMI VE GÜÇ KESTİRİMİ**” başlıklı tez tarafımızdan okunmuş, kapsamı ve niteliği açısından bir Yüksek Lisans tezi olarak kabul edilmiştir

Prof. Dr. Selma GÜRLER

Danışman

Prof.Dr. Özlem EGE ORUÇ

Jüri Üyesi

Dr. Öğr. Üyesi Erdiñç ÖNER

Jüri Üyesi

Prof.Dr. Okan FISTIKOĞLU

Müdür

Fen Bilimleri Enstitüsü

## TEŞEKKÜR

Bu tez çalışması sürecinde bilgi, deneyim ve rehberliği ile destek olarak çalışmayı yönlendiren ve bu süreçte devamlı motivasyonumu yüksek tutarak beni ileriye taşıyan danışman hocam Prof. Dr. Selma GÜRLER'e teşekkür ve saygılarımı sunarım. Yüksek lisans eğitimim boyunca aldığım dersler ve projelerde bana kattıkları teorik ve pratik bilgilerle veri bilimi alanında kendimi geliştirmemi ve bu alana daha da fazla ilgi duymamı sağlayan hocalarıma sonsuz teşekkür ederim.

Bütün eğitim hayatım boyunca beni her konuda destekleyerek bugünlere gelmemi sağlayan, çalışkanlık ve azimleriyle bana örnek olan aileme teşekkür ederim.

Can Yunus Erözden

# MAKİNE ÖĞRENİMİ TEKNİKLERİ İLE GÜNEŞ IŞINIMI VE GÜÇ KESTİRİMİ

## ÖZ

Son yıllarda iklim değişikliği ve özellikle küresel ısınmanın etkileri görüldükçe, enerji tasarrufu ve yenilenebilir enerjinin önemi giderek artmıştır. Yenilenebilir enerji alanında başta güneş enerjisi ve rüzgar enerjisi olmak üzere jeotermal, biyokütle, dalga ve hidroelektrik enerji gibi pek çok enerji sistemi uygulaması mevcuttur. Yenilenebilir enerji sistemleri kurulmadan önce ekonomik ve çevresel sürdürülebilirliklerinin incelenmesi sistemlerden optimum verim elde etmek amacıyla önem taşımaktadır. Bu doğrultuda yenilenebilir enerji sistemlerinde güvenilirlik ve enerji tahmini çalışmaları sürdürülebilirlik bağlamında etkili çalışma alanları arasına girmektedir. Enerji sistemlerin geleceğe yönelik güvenilirlik ve enerji tahmininde makine öğrenimi metotları kullanılmaktadır. Yapılan çalışmada da kurulması planlanan bir güneş enerjisi sisteminin enerji tahmininde güneş ışıınımı tahmini için Yapay Sinir Ağları, LightGBM (Hafif Gradyan Artırma Makineleri) ve LSTM (Uzun Kısa Zamanlı Bellek) gibi makine öğrenimi modelleri kullanılmıştır. Kullanılan makine öğrenimi modellerinin tahmin performansları çeşitli hata metrikleri ile karşılaştırılarak en başarılı sonuçları veren LightGBM modeli seçilmiştir. Seçilen modelin test verisi üzerinde Ortalama Mutlak Hata Yüzdesi (MAPE) değeri %21,29 olmuştur. Seçilen LightGBM modeli üzerinden yapılan güneş ışıınımı tahminleri kullanılarak belirli parametrelerdeki bir güneş paneli sisteminin sonraki güne ait saatlik güç ve günlük enerji üretim kestirimi yapılmıştır.

**Anahtar kelimeler:** Güneş Işıınımı, güneş enerjisi sistemleri, güç kestirimi, makine öğrenimi, yapay sinir ağları, lightgbm, lstm

# **PREDICTION OF SOLAR RADIATION AND POWER USING MACHINE LEARNING TECHNIQUES**

## **ABSTRACT**

In recent years, as the impacts of climate change and particularly global warming have become more evident, the significance of energy efficiency and renewable energy has grown substantially. In the field of renewable energy, there are numerous applications of energy systems, including solar energy and wind energy, as well as geothermal, biomass, wave, and hydropower energy. Examining the economic and environmental sustainability before the installation of renewable energy systems is crucial to achieve optimal efficiency from these systems. In this context, reliability and energy forecasting studies in renewable energy systems have emerged as effective areas of research within the context of sustainability. Machine learning methods are employed for reliable energy forecasting and assessment in energy systems. In the conducted study, various machine learning models such as Artificial Neural Networks, LightGBM (Light Gradient Boosting Machines), and LSTM (Long Short-Term Memory) have been employed for the energy prediction of a solar energy system planned to be installed. The machine learning models used were compared by evaluating their prediction performance using various error metrics, and the LightGBM model, which yielded the most successful results, was selected. The selected model achieved a Mean Absolute Percentage Error (MAPE) value of 21.29% on the test data. Using the predictions made with the chosen LightGBM model for solar irradiance, hourly power output and daily energy production estimates for a solar panel system under specific parameters were conducted for the following day.

**Keywords:** Solar irradiation, solar energy systems, power prediction, machine learning, artificial neural network, lightgbm, lstm

## İÇİNDEKİLER

|                                                                  | Sayfa     |
|------------------------------------------------------------------|-----------|
| SINAV SONUÇ FORMU .....                                          | ii        |
| TEŞEKKÜR .....                                                   | iii       |
| ÖZ .....                                                         | iv        |
| ABSTRACT .....                                                   | v         |
| ŞEKİLLER LİSTESİ .....                                           | viii      |
| TABLolar LİSTESİ .....                                           | x         |
| <b>BÖLÜM BİR – GİRİŞ .....</b>                                   | <b>1</b>  |
| 1.1 Tezin Ana Hatları .....                                      | 5         |
| <b>BÖLÜM İKİ – MAKİNE ÖĞRENİMİ YÖNTEMLERİ.....</b>               | <b>7</b>  |
| 2.1 Yapay Sinir Ağları(ANN) .....                                | 7         |
| 2.2 Hafif Gradyan Artırma Makineleri(LightGBM) .....             | 12        |
| 2.3 Uzun Kısa Zamanlı Bellek(LSTM) .....                         | 17        |
| <b>BÖLÜM ÜÇ – GÜNEŞ IŞINIMI TAHMİNİ.....</b>                     | <b>21</b> |
| 3.1 Veri Ön İşleme .....                                         | 26        |
| 3.2 Öznitelik Mühendisliği .....                                 | 28        |
| 3.3 Öznitelik Ölçeklendirme .....                                | 30        |
| 3.4 Model Doğrulama Yöntemi.....                                 | 32        |
| 3.5 Öznitelik Seçimi.....                                        | 32        |
| 3.6 Hiperparametre Optimizasyonu .....                           | 36        |
| 3.7 Model Performans Metrikleri .....                            | 38        |
| 3.8 Tahmin Performansı Karşılaştırmaları.....                    | 38        |
| 3.9 LightGBM Güneş Işınımı Tahmin Modeli ile Güç Kestirimi ..... | 42        |
| <b>BÖLÜM DÖRT – SONUÇLAR VE TARTIŞMA.....</b>                    | <b>49</b> |

|                |    |
|----------------|----|
| KAYNAKLAR..... | 50 |
|----------------|----|





## ŞEKİLLER LİSTESİ

### Sayfa

|            |                                                                            |    |
|------------|----------------------------------------------------------------------------|----|
| Şekil 1.1  | Literatürde Yenilenebilir Enerji Çalışma Yüzdeleri Lai ve diğer. (2020) .. | 1  |
| Şekil 2.1  | Yapay Sinir Ağı Algoritması.....                                           | 10 |
| Şekil 2.2  | Yapay Sinir Ağı Modeli Rodríguez ve diğer. (2018) .....                    | 11 |
| Şekil 2.3  | LightGBM Algoritması .....                                                 | 14 |
| Şekil 2.4  | Seviye odaklı büyüme stratejisi.....                                       | 15 |
| Şekil 2.5  | Yaprak odaklı büyüme stratejisi .....                                      | 15 |
| Şekil 2.6  | LSTM Bellek bloğunun mimarisi Xiao & Yin (2019) .....                      | 17 |
| Şekil 2.7  | LSTM Algoritması.....                                                      | 19 |
| Şekil 3.1  | Saat ve aylara göre güneş ışıınımı grafiği.....                            | 22 |
| Şekil 3.2  | Değişkenlerin Histogram Grafikleri.....                                    | 23 |
| Şekil 3.3  | Özniteliklerin Korelasyon Isı Grafiği.....                                 | 24 |
| Şekil 3.4  | Güneş Işınımı Kutu Grafiği .....                                           | 25 |
| Şekil 3.5  | Rüzgar Hızı ve Rüzgar Yönü 2 Boyutlu Histogram Grafiği.....                | 26 |
| Şekil 3.6  | Rüzgar Vektörü 2 Boyutlu Histogram Grafiği .....                           | 27 |
| Şekil 3.7  | Rüzgar Vektörü Histogram Grafikleri .....                                  | 28 |
| Şekil 3.8  | Güneş Işınımı Gecikme Değişkenleri .....                                   | 29 |
| Şekil 3.9  | Min-Maks Ölçeklendirme.....                                                | 31 |
| Şekil 3.10 | Zaman Serisi Çapraz Doğrulama.....                                         | 32 |
| Şekil 3.11 | Otokorelasyon Grafiği.....                                                 | 33 |
| Şekil 3.12 | Kısmi Otokorelasyon Grafiği .....                                          | 34 |
| Şekil 3.13 | Özyinelemeli Öznitelik Seçimi Grafiği .....                                | 35 |
| Şekil 3.14 | Rfecv ile Seçilen Öznitelikler .....                                       | 36 |
| Şekil 3.15 | Mevsimlere göre algoritmaların MSE değerleri.....                          | 40 |
| Şekil 3.16 | LightGBM modeli ilkbahar için tahmin karşılaştırma grafiği .....           | 41 |
| Şekil 3.17 | LightGBM modeli kış için tahmin karşılaştırma grafiği .....                | 41 |
| Şekil 3.18 | LightGBM modeli sonbahar için tahmin karşılaştırma grafiği .....           | 42 |
| Şekil 3.19 | LightGBM modeli yaz için tahmin karşılaştırma grafiği .....                | 42 |
| Şekil 3.20 | 28 Ocak 2022 - 2 Şubat 2022 Güneş Işınımı - Güç Grafiği.....               | 43 |

|                                                                               |    |
|-------------------------------------------------------------------------------|----|
| Şekil 3.21 28 Ocak 2022 Enerji Grafiği .....                                  | 44 |
| Şekil 3.22 29 Ocak 2022 Enerji Grafiği .....                                  | 45 |
| Şekil 3.23 13 Haziran 2021 - 18 Haziran 2021 Güneş Işınımı - Güç Grafiği..... | 46 |
| Şekil 3.24 13 Haziran 2021 Enerji Grafiği .....                               | 47 |
| Şekil 3.25 16 Haziran 2021 Enerji Grafiği .....                               | 48 |




## TABLÖLAR LİSTESİ

|                                                                  | Sayfa |
|------------------------------------------------------------------|-------|
| Tablo 3.1 Nasa veri tabanından çekilen öz nitelikler.....        | 21    |
| Tablo 3.2 World weather online meteorolojik tahmin verileri..... | 22    |
| Tablo 3.3 Görüş mesafesi frekansları .....                       | 25    |
| Tablo 3.4 LSTM hiper-parametreleri ve arama aralıkları.....      | 36    |
| Tablo 3.5 ANN hiper parametreleri ve arama aralıkları .....      | 37    |
| Tablo 3.6 LigthGBM hiper parametreleri ve arama aralıkları ..... | 37    |
| Tablo 3.7 Tahmin performans karşılaştırması.....                 | 39    |

## BÖLÜM BİR

### GİRİŞ

Geçmişten günümüze enerji tüketimi petrol, kömür ve doğal gaz gibi fosil yakıtlar ile gerçekleşmektedir. Ancak son yıllarda fosil yakıtların rezervlerinin artan enerji tüketimi sebebiyle azalması ile birlikte alternatif enerji kaynakları aranmaktadır. Fosil yakıtların rezervlerinin sonlu olmasının yanı sıra, doğaya ve atmosfere verdikleri zararlar küresel ısınma ve iklim değişikliğinin hızlanmasına sebep olmaktadır. Bu yüzden daha çevre dostu ve yenilenebilir enerji kaynaklarına yönelim artmıştır. Bu bağlamda en çok bilinen güneş ve rüzgar enerjisi başta olmak üzere biyokütle, jeotermal ve dalga enerjisi gibi pek çok yenilenebilir enerji kaynağı alternatifi vardır.



Şekil 1.1 Literatürde Yenilenebilir Enerji Çalışma Yüzdeleri Lai ve diğer. (2020)

Şekil 1.1’de 2020 yılında yapılan çalışma sonucunda yenilenebilir enerji kaynakları ile ilgili yakın zamanlı 130 makalenin konularının pasta grafiği gösterilmiştir. Buna göre yenilenebilir enerji kaynakları konusunda en çok çalışma yapılan alan %44 ile güneş enerjisidir. Güneş enerjisini %39 ile rüzgar enerjisi takip etmektedir. Biyokütle, jeotermal, dalga ve hidroelektrik enerjileri konularındaki çalışmaların toplamının yüzdesi ancak %17 seviyesindedir Lai ve diğer. (2020).

Yenilenebilir enerji kaynaklarının önem kazanmasıyla birlikte bu alanda yapılan bilimsel çalışmalar da artmaktadır. Bu alanda enerji tahmini, güvenilirlik tahmini ve enerji optimizasyonu gibi konularda çalışmalar yapılmaktadır. Yapılan çalışmada da güneş enerjisi tahmini konusu ele alınacaktır.

Güneş enerjisi sistemleri, güneş enerjisini elektrik enerjisine dönüştürerek kullanılabilir enerji sağlarlar. Güneş enerjisi sistemleri, güneş panelleri, inverterler ve bataryalar gibi temel bileşenlerden oluşur. Güneş panelleri, güneş ışınlarını yakalayarak DC elektrik akımı üretirler. Inverterler, DC elektrik akımını AC elektrik akımına dönüştürürler ve bataryalar, enerjinin depolanması için kullanılırlar. Güneş enerjisi sistemleri, sıfır emisyonlu ve sürdürülebilir bir enerji kaynağı olarak kabul edilirler ve son yıllarda dünya genelinde kullanımı giderek artmaktadır Timilsina ve diğer. (2011).

Makine öğrenimi, güneş ışıını tahmininde yaygın olarak kullanılan bir teknolojidir. Güneş ışıını tahmini, güneş enerjisi sistemlerinin performansını optimize etmek için kritik öneme sahiptir. Makine öğrenimi modelleri, güneş ışıını tahmininde kullanılan verileri analiz ederek gelecekteki güneş ışıını seviyelerini tahmin etmek için kullanılır. Bu modeller genellikle yapay sinir ağları, karar ağaçları ve destek vektör makineleri gibi teknikleri kullanır. Bu nedenle, makine öğrenimi teknikleri, güneş enerjisi sistemlerinin tasarımı ve performansının iyileştirilmesi için önemli bir araçtır.

Makine öğrenimi teknikleri, güneş ışıını tahmini için çeşitli verilerin kullanımına dayanmaktadır. Örneğin, meteorolojik veriler (sıcaklık, nem, rüzgar hızı, bulutluluk vb.) ile güneş ışıını arasındaki ilişkiler incelenebilir. Bunun yanı sıra, güneş ışıınının çeşitli yerlerde ve farklı zamanlarda nasıl değiştiği gibi veriler de kullanılabilir. Ayrıca, güneş panelinin konumuna ve açısına ilişkin veriler de önemlidir, çünkü bu faktörler güneş ışıınının yoğunluğunu etkiler.

Rodríguez ve diğer. (2018) yaptıkları çalışmada mevcut tez çalışmasına oldukça benzer bir alana yoğunlaşmışlardır. Makalelerinde, Yapay Sinir Ağları (YSA)

kullanarak güneş enerjisi üretim tahmini yapmak için bir yöntem sunmuşlardır. Çalışmalarında, gerçek zamanlı hava tahminleri kullanılarak bir mikro şebekedeki güneş enerjisi üretim tahminleri yapmışlardır. Makalede, YSA modelinin eğitilmesi için kullanılan veri seti ve bu verilerin ön işleme süreci ayrıntılı olarak açıklanmıştır. YSA modeli, hem girdi özelliklerinin hem de modelin hiperparametrelerinin optimizasyonu için birçok deneme yapılarak en iyi performansı elde etmek üzere eğitilmiştir. Çalışmalarının sonucunda, YSA modelinin mikro şebekede güneş enerjisi tahmini yapmak için yüksek doğruluk oranları sağladığı gösterilmiştir. Ayrıca, bu çalışmada sunulan yöntem, gerçek zamanlı hava tahminleri kullanarak güneş enerjisi üretim tahminlerinin yapılabilmesi için etkili bir yol olarak öne çıkmaktadır. Mevcut tez çalışmasından farkları çalışmalarında sadece Yapay Sinir Ağları Modeli kullanılmış ve farklı makine öğrenimi modelleri karşılaştırılmamıştır.

Jebli ve diğer. (2021) çalışmalarında Fas'ta yarı çöl iklimi olan Errachidia bölgesindeki meteoroloji verilerini kullanarak güneşten elde edilecek enerji çıktısını tahmin etmişlerdir. Çalışmalarında modeldeki önemli meteorolojik öznitelikleri belirlemek için Pearson korelasyon katsayısı kullanmışlardır. Enerji tahmini için Rassal Orman, Doğrusal Regresyon, Destek Vektör Regresyonu ve Yapay Sinir Ağları gibi algoritmaları kullanmışlardır. Elde ettikleri bulgulara göre hem gerçek zamanlı hem de kısa vadeli tahminlerde Yapay Sinir Ağları diğer algoritmalara göre daha az hatalı tahminler üretmiştir.

Ferrero Bermejo ve diğer. (2019) çalışmalarında fotovoltaik enerji tahmininde Yapay Sinir Ağları yönteminin kullanımını incelemiştir. 2000 ile 2018 yılları arasında yapılan ve güneş enerjisi konusunda Yapay Sinir Ağları metodu kullanılan 20 adet bilimsel çalışmayı detaylıca incelenmiştir. Bu çalışmaların hepsinde de Yapay Sinir Ağlarının bu alanda kullanımı başarılı sonuçlar vermiştir. Çalışmaların 16 tanesinde ise diğer tahmin modellerine göre Yapay Sinir Ağlarının daha başarılı tahminler yaptığı gösterilmiştir. Çalışmaların 4 tanesinde de Yapay Sinir Ağları ile yapılan analizin diğer tekniklerle tamamlanması önerilmiştir.

Oral ve diğer. (2019) yaptıkları çalışmada fotovoltaik santrallerin üreteceği güç

tahmini için makine öğrenimi yöntemlerini kullanmışlardır. Türkiye'nin 125 farklı bölgesi için çeşitli tiplerdeki fotovoltaik santrallerin kurulması durumunda üretilen yıllık elektrik enerjisi çıktısı araştırılmıştır. Bu hedef doğrultusunda fotovoltaik santraller için güneş ışınlamı tahmininde Çoklu Doğrusal Regresyon, k-En Yakın Komşu Regresyon ve Yapay Sinir Ağları gibi makine öğrenimi yöntemleri kullanılmıştır. Sonuç olarak da güneş ışınlamı tahmininde üç model de 0,95'in üstünde  $R^2$  değerine ulaşmış ve birbirine yakın sonuçlar vermiştir. Üç model içinde en başarılı sonucu veren Yapay Sinir Ağları modeli olmuştur.

Pan ve diğer. (2020) yaptıkları çalışmada fotovoltaik güç tahmini için veri ön işleme tabanlı ultra kısa vadeli fotovoltaik güç tahmin modeli önermiştir. İşlenmiş veriyi kullanarak, Destek Vektör Makineleri modeli oluşturulmuş ve bu modelin hiper parametrelerinin optimizasyonu için Karınca Kolonisi Optimizasyon algoritması kullanılmıştır. Sonuç olarak mantıklı veri ön işleme prosesi ile modelin  $R^2$  değeri %6,8 artmıştır. Bu şekilde modelin  $R^2$  değeri 0,997'ye kadar çıkmıştır.

Najeebullah ve diğer. (2015) çalışmalarında rüzgar enerjisi tahmini için çeşitli tahmin modelleri kullanmışlardır. Modellerin performansları karşılaştırılmış ve Destek Vektör Regresyonunun (SVR) ve özel olarak, SVR'ye dayalı bir hibrit öğrenme modelinin, çoklu doğrusal regresyona (MLR) kıyasla daha iyi performans sunduğunu gözlemlemişlerdir. Ek olarak kısa vadeli rüzgar enerjisi tahmini için yeni bir metodoloji olan makine öğrenimi tabanlı kısa vadeli rüzgar gücü tahmini için bir yöntem önerilmiştir. Bu yaklaşım, öz nitelik seçimi ve regresyon için makine öğrenimi (ML) tekniklerinin bir kombinasyonunu kullanır. Bu yaklaşım öz nitelik seçimi ve tahmin için Destek Vektör Regresyonunu kullanan bir hibrit makine öğrenimi modelidir. Ayrıca tahmin sürecinde geliştirilmiş parçacık sürüsü optimizasyonu ve bir hibrit sinir ağı kullanılmıştır.

Hong & Rioflorido (2019) yaptıkları çalışmada 24 saatlik süreçte rüzgar enerjisi üretimi tahmini için bir hibrit derin öğrenme sinir ağı sunmuşlardır. Önerilen yeni yöntem, aktivasyon fonksiyonu Çift Gauss Fonksiyonu (DGF) olan Radyal Temelli Fonksiyon Sinir Ağı (RBFNN) ile basamaklandırılmış bir Evrimsel Sinir Ağı'na

(CNN) dayanmaktadır. Önerilen yöntemi, TensorFlow ve Keras kütüphanelerini kullanarak gerçekleştirmişlerdir. Önerilen yöntemin tahmin performansı Çoklu İleri Beslemeli Yapay Sinir Ağları gibi yöntemlerle karşılaştırılmıştır. Çalışmada simülasyon sonuçları, önerilen yöntemin 24 saatlik süreçteki rüzgar enerjisi tahmini için geleneksel yöntemlerden daha doğru olduğunu göstermiştir.

Ağbulut ve diğer. (2021) çalışmalarında Türkiye’de farklı güneş ışıınımı dağılımına sahip dört il için (Kırklareli, Tokat, Nevşehir, Karaman) günlük güneş ışıınımını tahmin etmişlerdir. Tahmin için Yapay Sinir Ağları, K-En Yakın Komşu, Derin Öğrenme ve Destek Vektör Makinesi gibi dört farklı makine öğrenmesi algoritmasını kullanmışlardır. Algoritmaların eğitimi için Meteoroloji Genel Müdürlüğü’nden aldıkları iki yıllık veri seti kullanılmıştır. Veride illerin günlük minimum ve maksimum sıcaklıkları, bulut yoğunluğu, günlük atmosfer yüzeyindeki güneş radyasyonu öznitelikleri kullanılmıştır. Her yöntem için tahmin doğrulukları  $R^2$ , RMSE ve MAPE gibi metrikler ile karşılaştırılmış ve dört yöntem arasında en başarılı tahmin, Yapay Sinir Ağları modelinin yaptığı görülmüştür.

## 1.1 Tezin Ana Hatları

Bu tez, yenilenebilir enerji sistemlerinin ekonomik ve çevresel sürdürülebilirliği ve enerji tahmini açısından makine öğrenimi modellerinin kullanımının önemini vurgulamaktadır. Ayrıca, olası bir yenilenebilir enerji sisteminde enerji tahmini yapmak için hangi makine öğrenimi modellerinin en iyi performansı sergilediği konusunda bilgi sağlamaktadır. Bu tez, yenilenebilir enerji alanında çalışan mühendisler ve araştırmacılar için yararlı olacaktır. Bu bölümde, tezin amacı ve önemi vurgulanarak, yenilenebilir enerji sistemlerinin dünya enerji talebindeki artan rolü ve çevresel etkileri ele alınmaktadır. Ayrıca, makine öğrenimi modellerinin enerji tahminindeki rolüne yönelik genel bir bakış sunularak, bu alanda önceki çalışmaların ve literatürdeki temel bulguların analizi yapılmaktadır. Bölüm 2’de çalışmada kullanılan temel makine öğrenimi modelleri ve algoritmaları ayrıntılı bir şekilde açıklanmıştır. Yapay Sinir Ağları, LightGBM, LSTM gibi modellerin çalışma



prensipieri ve enerji tahminindeki uygulamaları hakkında bilgi verilmiştir. Bölüm 3'te, geçmiş meteorolojik veriler kullanılarak önerilen güneş ışıını tahmini modeli ayrıntılı bir şekilde açıklanmıştır. Modelin doğruluğu ve etkinliğı test edilir ve güneş enerjisi üretim tahminlerinin yapılması için modelin tahmin çıktıları kullanılmıştır. Ayrıca, güneş enerjisi hesaplamaları ve üretim potansiyeli değerlendirmeleri bu bölümde sunulmuştur. Bölüm 4'te elde edilen sonuçlar değerlendirilerek tezin ana hedeflerine ulaşılp ulaşılmadığı tartışılmıştır. Ayrıca, gelecekte yapılacak çalışmalar için öneriler ve olası iyileştirmeler belirtilmiştir.



## **BÖLÜM İKİ**

### **MAKİNE ÖĞRENİMİ YÖNTEMLERİ**

Makine öğrenimi temelde denetimsiz öğrenme ve denetimli öğrenme olarak ikiye ayrılır. Denetimli öğrenmede yanıt değişkeni olan girdi verileri vardır. Bilgisayar girdi verilerindeki özniteliklerin aldığı değerlere göre yanıt değişkeninin değişimini öğrenerek yeni gelen verilerin yanıt değişkenini tahmin eder. Denetimsiz öğrenmede ise yanıt değişkeni yoktur. Bilgisayar eldeki verileri birbirlerine benzerliklerine göre kümeler ayırır. Makine öğrenimi günümüzde görüntü işleme, doğal dil işleme ve müşteri segmentasyonu gibi değişik pek çok alanda kullanılmaktadır. Özellikle son yıllarda yenilenebilir enerjinin popülerliğinin de artmasıyla yenilenebilir enerji tahmini alanında da makine öğrenimi yöntemleri kullanılmaktadır.

#### **2.1 Yapay Sinir Ağları(ANN)**

Yapay Sinir Ağları, insanın öğrenme becerisinin bilgisayarlaştırılmasına dayanan bir yapay zeka yöntemidir. İnsan beyninin çalışma şekli, geleneksel bilgisayarlara göre çok daha karmaşıktır. İnsan beyninin bu karmaşık, doğrusal olmayan ve paralel işleyişi, özellikle örüntü tanıma ve algılama ile ilgili olarak belirli alanlarda en iyi geleneksel bilgisayarlardan bile daha iyi performans göstermesini sağlar Rodríguez ve diğer. (2018).

Yapay Sinir Ağları konusundaki ilk sistematik çalışma McCulloch ve Pitts tarafından 1943 yılında yayınlanmıştır McCulloch ve Pitts (1943). Çalışmalarında nöronların davranışlarına odaklanmışlardır.

Hebb (1949) “The Organization of Behavior” adlı kitabında “Hebbian öğrenme” adı verilen nörofizyolojik kuramı geliştirdi. Bu kurama göre beraber ateşlenen nöronlar birbirine bağlanır ve iki nöron her iletişim kurduğunda aralarındaki bağlantı kuvvetlenir. Hebbian öğrenme kuramının geliştirilmesinden sonraki yıllarda bu kuramdan faydalanarak yapay sinir ağının gücünü artırıcı çalışmalar yapılmıştır.

Rosenblatt (1958) tek katmanlı eğitilebilen ve tek bir çıkışa sahip olan yapay sinir ağı olan Perceptron kavramını literatüre sunmuştur. Perceptron'un keşfinden itibaren de yapay sinir ağı alanındaki çalışmalar hız kazanmıştır. Widrow ve Hoff (1960) yaptıkları çalışmada yapay sinir ağlarının mühendislikteki ilk uygulamaları olan ADALINE (Adaptive Linear Neuron) ve MADALINE modellerini geliştirmişlerdir. Fukushima (1980) yaptığı çalışma ile görsel örüntü tanıma mekanizması için Neocognitron adı verilen bir sinir ağı modelini önermiştir. Ağın yapısı omurgalı canlıların görsel sinir sisteminden esinlenerek kurgulanmıştır. Oluşturulan model el yazısı karakter tanıma ve diğer örüntü tanıma işlevleri için kullanılmış olup, evrişimli sinir ağlarının öncülü olmuştur. Hopfield (1982) Hopfield (1984) tarafından yapılan çalışmalarda ağların matematiksel temelleri ele alınmıştır. Bu çalışmalar sonucunda yapay sinir ağlarının genelleştirilebileceği ve yazılımlar ile çözülmesi zor olan problemlere çözüm üretebileceği gösterilmiştir. Rumelhart ve diğer. (1986) geriye yayımlı öğrenme algoritmasını literatüre sunmuşlardır. Bu algoritma günümüzde de yapay sinir ağlarında yaygın olarak kullanılmaktadır. Cervone ve diğer. (2017) çalışmalarında 72 saatlik deterministik ve olasılıksal fotovoltaik güç tahmininde Yapay Sinir Ağları(ANN) ve Analog Topluluk(AnEn) metodolojisi önermişlerdir. Tahmin modelleri için girdi olarak nümerik hava tahmin modeli ve hesaplanmış astronomik değişkenler kullanmışlardır. ANN ve AnEn modellerini ayrı ayrı ve kombine edilmiş bir şekilde kullanmışlardır. Çalışmalarının sonucunda kombine edilmiş ANN ve AnEn modelinin en başarılı tahmin sonuçlarını ürettiğini göstermişlerdir. Geetha ve diğer. (2022) yaptıkları çalışmada saatlik güneş ışıınımı tahmininde farklı algoritmalar ile Yapay Sinir Ağı modellerini incelemişlerdir. Eğitim seti olarak Hindistanın Tamil Nadu şehrinin 6 farklı bölgesinden bir yıllık meteorolojik veri kullanmışlardır. Çalışmalarında aynı zamanda tahmin modelleri için gerekli gizli katman ve nöron sayılarını bulmayı amaçlamışlardır. Mellit ve diğer. (2014) yaptıkları çalışmada büyük ölçekli fotovoltaik tesisin üreteceği gücün tahmininde Yapay Sinir Ağları modelleri kullanmışlardır. Güneşli, parçalı bulutlu ve bulutlu hava durumları için güneş ışıınımı, solar hücre sıcaklığı ve tesisin güç çıktısı değişkenlerini kullanarak üç ayrı Yapay Sinir Ağı modeli üretmişlerdir. Cornaro ve diğer. (2015) yaptıkları çalışmada saatlik güneş ışıınımı tahmininde Yapay Sinir ağları

modelleri kullanmışlardır. Modeller en iyi nöron sayılarını seçmek için ana optimizasyon sürecinden geçirilerek oluşturulmuştur. Rana ve diğer. (2016) yaptıkları çalışmada kısa vadeli fotovoltaiik güç tahmininde Yapay Sinir Ağları ve Destek Vektör Regresyonu modellerini kullanmışlardır. Geçmiş fotovoltaiik güç verisi ve geçmiş meteorolojik verileri kullanarak 5 ile 60 dakikalık periyotlarda fotovoltaiik güç çıktısı tahmini yapmışlardır. Çalışmanın sonucunda Yapay Sinir Ağı modellerinin daha isabetli tahminler yaptığını göstermişlerdir. Ghimire ve diğer. (2019) yaptıkları çalışmada günlük güneş ışıınımı tahmininde çeşitli makine öğrenimi modelleri kullanmış bu modellerin tahmin performanslarını istatistiksel yöntemler ile karşılaştırmışlardır. Çalışmanın sonucunda Yapay Sinir Ağı modellerinin en başarılı tahmin sonuçlarını ürettiğini göstermişlerdir. Ghenai ve diğer. (2022) yaptıkları çalışmada çift taraflı solar panel sistemlerinin performanslarını değerlendirirken bu sistemlerin güç çıktısı tahmininde Yapay Sinir Ağları modellerini kullanmışlardır. Amrouche & Le Pivert (2014) yaptıkları çalışmada günlük küresel yatay güneş ışıınımı tahmininde Yapay Sinir Ağı modeli kullanmışlardır. Tahmin modellerinde eğitim seti olarak günlük hava tahmini değerlerini kullanmışlardır. Tahmin sonuçlarını gerçekleşen değerler ile karşılaştırdıklarında günlük güneş ışıınımını başarılı bir şekilde tahmin ettiklerini göstermişlerdir. Pazikadin ve diğer. (2020) yaptıkları çalışmada 2014 ile 2019 yılları arasında güneş ışıınımı hesaplama alanında yapılan çalışmaları incelemişlerdir. Çalışmalarının sonucunda güneş enerjisi tahmininde Yapay sinir ağları uygulamalarının giderek arttığını göstermişlerdir.

Şekil 2.1 Yapay Sinir Ağları algoritmasının genel hatlarıyla algoritma akışını göstermektedir. Yapay Sinir Ağı modellerinde girdi katmanı, çıktı katmanı bu katmanlar arasında gizli katmanlar bulunur. Öğrenme sürecindeki işlemlerin önemli bir kısmı bu gizli katmanlarda gerçekleşir. Gizli katmanlardaki nöronların değerleri bir önceki katmandaki nöronlar ile arasındaki ağırlıklara ve aktivasyon fonksiyonuna göre belirlenir. Şekil 2.2’de görüleceği üzere sinir ağındaki nöronlara gelen girdilerin ilgili bağlantı ağırlıklarıyla çarpılıp toplamları alınır. Denklem 2.1 bunu ifade etmektedir. Denklem 2.2’de ise Denklem 2.1’de alınan toplamlara yanlılık değerleri eklenerek aktivasyon fonksiyonundan geçirilip nöronun çıktı değeri hesaplanır. Bu

---

**Algoritma 1: Yapay Sinir Ağı Algoritması**

---


```
Eğitim veri setini yükle;  
Ağı başlat;  
while Belirli sayıda epoch için do  
    foreach Her bir eğitim veri örneği do  
        Giriş değerlerini ağa besle;  
        İleri yayılım yap;  
        Çıktı değerini hesapla;  
        Hata değerini hesapla;  
        Geri yayılım yap;  
        Ağı güncelle;  
    end  
end
```

---

Şekil 2.1 Yapay Sinir Ağı Algoritması

değer bağlı bir sonraki nörona girdi olarak aktarılır. Bu işlemler ileri yayılım prosesini temsil etmektedir.

Denklem 2.3’de nöronun hata gradyanı  $\delta_k$  hesaplanmaktadır.  $E$  ağıın çıktı hata fonksiyonunu,  $u_k$  nöronun ağırlıklı girişini,  $y_k$  nöronun çıktısını ifade etmektedir. Denklem 2.4 yanlılık (bias) değerindeki güncelleme miktarı  $\Delta b_k$  hesaplanmaktadır.  $\eta$  öğrenme oranını temsil eder ve nöronun hata gradyanı ile çarpılarak yanlılık değerindeki güncelleme miktarı hesaplanır. Denklem 2.5 ile nöronlar arası bağlantı ağırlığının güncelleme miktarı  $\Delta w_{kj}$ , nöronun girdi değeri yanlılık değeri ile çarpılarak hesaplanır. Denklem 2.6 ile gizli katmanların geri yayılım gradyanları  $\delta_j$  hesaplanmaktadır. Bir katmandaki her bir nöronun hata gradyanı, bir sonraki katmandaki nöronlar ile arasındaki bağlantı ağırlıkları ile çarpılıp toplanarak ilgili katmanın geri yayılım gradyanı hesaplanır. Denklem 2.7’de öğrenme oranı ile katmanın geri yayılım gradyanı çarpılarak nöronların girdi değerlerindeki güncelleme miktarı hesaplanmaktadır. Denklem 2.3 ile Denklem 2.7 arasındaki bu formülasyon, geri yayılım algoritmasının adımlarını ve güncelleme miktarlarını matematiksel olarak göstermektedir.



Şekil 2.2 Yapay Sinir Ağı Modeli Rodríguez ve diğer. (2018)

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.1)$$

$$y_k = \varphi(u_k + b_k) \quad (2.2)$$

$$\delta_k = \frac{\partial E}{\partial u_k} = \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial u_k} \quad (2.3)$$

$$\Delta b_k = -\eta \cdot \delta_k \quad (2.4)$$

$$\Delta w_{kj} = -\eta \cdot \delta_k \cdot x_j \quad (2.5)$$

$$\delta_j = \frac{\partial E}{\partial u_j} = \sum_{k=1}^n \frac{\partial E}{\partial u_k} \cdot \frac{\partial u_k}{\partial u_j} = \sum_{k=1}^n \delta_k \cdot w_{kj} \quad (2.6)$$

$$\Delta x_j = -\eta \cdot \delta_j \quad (2.7)$$

## 2.2 Hafif Gradyan Artırma Makineleri(LightGBM)

Hafif Gradyan Artırma Makinesi, Gradyan Artırıcı Karar Ağacının(GBDT) farklı ve verimli özellikler eklenmiş bir uygulamasıdır. Gradyan Artırma kavramı Friedman (2001) çalışmasından gelmektedir. Gradyan artırma makinelerinde zayıf öğrenici adı verilen çoklu karar ağaçlarından gelen tahminler kullanılarak nihai tahmin oluşturulur. Ke ve diğer. (2017) yaptıkları çalışmada LightGBM modelini literatüre sunmuşlardır. Çalışmanın sonucunda ise LightGBM algoritmasının makine öğrenimi problemlerinde tahmin başarısını artırdığını ve eğitim süresini azalttığını göstermişlerdir.

LightGBM algoritmasının eğitim süresinin ve hafıza kullanımının benzer algoritmalara göre daha düşük olmasını sağlayan histogram tabanlı bir algoritma olmasıdır. Sıralı özellik değerlerinde ayırım noktalarını bulmak yerine, histogram tabanlı algoritma sürekli özellik değerlerini ayrık bölmelere ayırır ve eğitim sırasında bu bölmeleri kullanarak özellik histogramlarını oluşturur Ke ve diğer. (2017). Bu yöntemde eğitim setindeki sürekli değişkenler kesikli değişkenlere dönüştürülür ve bu sayede modelin zaman ve hafıza kullanım maliyeti azalır.

LightGBM algoritması, Gradient Boosting yöntemine dayanırken, aynı zamanda algoritmayı verimlilik açısından optimize eden iki önemli yaklaşımı destekler: GOSS (Gradient-based One-Side Sampling) ve EFB (Exclusive Feature Bundling).GOSS, gradyan tabanlı tek taraflı örnekleme yöntemidir. Geleneksel gradyan tabanlı artırma algoritmalarında, her bir eğitim örneği aynı derecede dikkate alınır. Ancak GOSS, daha hızlı eğitim süresi ve daha düşük bellek tüketimi sağlamak için gradyan değerlerine dayalı bir örnek seçimi yapar. GOSS'un adımlarında ilk olarak tüm eğitim örnekleri, gradyanlarının mutlak değerine göre sıralanır. Büyük gradyan değerlerine sahip örneklerin bir kısmı (yani en önemli örnekler) korunurken, küçük gradyan değerlerine sahip örneklerin bir kısmı rastgele atılır. Bu şekilde, eğitim

süresini ve bellek tüketimini azaltarak, modelin daha hızlı bir şekilde eğitilmesi ve daha iyi genelleştirme yapması hedeflenir. EFB ise, özellik gruplandırma yöntemidir ve LightGBM'in bellek kullanımını optimize etmek için tasarlanmış bir özelliğidir. Genellikle, bir veri setinde benzer özellikler bir araya getirilerek gruplandırıldığında, modelin performansı artabilir. Ancak bu gruplandırma, geleneksel algoritmalarda önceden tanımlanır ve sabittir. EFB'de ilk olarak özelliklerin özgünlüğünü koruyarak, benzer özellikler gruplandırılır. Bu gruplandırma, LightGBM modelinin bellek kullanımını azaltarak daha hızlı çalışmasını sağlar. Gruplandırma sonucunda, modeldeki ağaç sayısı ve derinliklerinde azalma olabilir, bu da hızlı ve daha verimli bir model oluşturmayı sağlar. GOSS ve EFB, LightGBM'in performansını artırmak ve verimliliğini optimize etmek için kullanılan özel tekniklerdir. Bu teknikler, daha hızlı eğitim süreleri, daha düşük bellek tüketimi ve daha iyi genelleştirme yetenekleri sağlayarak, LightGBM'i diğer gradyan artırma tabanlı algoritmalarından ayıran önemli özelliklerdir. LightGBM algoritmasının genel hatları ile Şekil 2.3'te gösterilmiştir.



---

**Algorithm 1: LightGBM Algoritması**

---

**Girdi:** Eğitim verisi:  $D = \{(\chi^1, y^1), (\chi^2, y^2), \dots, (\chi^N, y^N)\}, \chi^i \in \chi, \chi \subseteq R,$

$$y_i \in \{-1, +1\};$$

kayıp fonksiyonu:  $L(y, \theta(\gamma))$ ;

iterasyon sayısı:  $M$ ;

büyük gradyan verisi örnekleme oranı:  $a$ ;

küçük gradyan verisi örnekleme oranı:  $b$

**İterasyonlar:**

$\chi$  içinde bir arada bulunamayan özellikleri (yani aynı anda sıfırdan farklı değer kabul etmeyen özellikleri) EFB (Exclusive Feature Bundling) tekniğiyle birleştir;

$$\theta_0(\chi) = \arg \min_c \sum_1^N L(y_i, c) \text{ olarak ayarla;}$$

**for**  $m = 1$  **to**  $M$  **do**

    Gradyanın mutlak değerlerini hesapla;;

$$r_i = \left| \frac{\partial L(y_i, \theta(x_j))}{\partial \theta(x_i)} \right|_{\theta(x) = \theta_{m-1}(x)}, i = \{1, \dots, N\};$$

    Gradyan tabanlı tek taraflı örnekleme (GOSS) işlemiyle veri setini yeniden

        örnekle:  $\text{top } N = a \times \text{len}(D)$   $\text{randN} = b \times \text{len}(D)$ ;

$\text{sıralanmış} = \text{GetSortedIndices}(\text{abs}(r))$ ;

$A = \text{sıralanmış}[1; \text{top } N]$ ;

$B = \text{RandomPick}(\text{sıralanmış}[\text{top } N : \text{len}(D)], \text{randN})$ ;

$D = A + B$ ;

    Bilgi kazançlarını hesapla:

$$V_j(d) = \frac{1}{n} \left( \frac{(\sum_{x_i \in A_l} r_i + \frac{1-a}{b} \sum_{x_i \in E_l} r_i)^2}{n_l^J(d)} + \frac{(\sum_{x_i \in A_r} r_i + \frac{1-a}{b} \sum_{x_i \in E_r} r_i)^2}{n_r^J(d)} \right);$$


    Yeni bir karar ağacı  $\theta_w(x)$ ' oluştur ve bunu  $D'$  üzerinde eğit;

$\theta_m(x) = \theta_{m-1}(\chi) + \theta_w(x)$  olarak güncelle;

**end**


---

Şekil 2.3 LightGBM Algoritması



Şekil 2.4 Seviye odaklı büyüme stratejisi

Karar ağaçlarında seviye odaklı ve yaprak odaklı olmak üzere iki farklı büyüme stratejisi vardır. Şekil 2.4’de görüldüğü üzere seviye odaklı büyüme stratejisinde ağacın dengesi korunur. Şekil 2.5’te gösterilen yaprak odaklı stratejide ise ağacın dengesi göz önünde bulundurulmadan tahmin hatasını azaltan yapraklar bölünerek büyüme süreci devam eder. Bu strateji modelin öğrenme hızını artırır ve tahmin hatasını azaltır.




Şekil 2.5 Yaprak odaklı büyüme stratejisi

Chen ve diğer. (2021) yaptıkları çalışmada enerji şebekelerinin arz tarafı ile binaların talep tarafı arasındaki enerji dengesini sağlamak amacıyla kısa vadeli yük tahmini için çeşitli algoritmalar kullanmışlardır. Bir binanın bir günlük tüketeceği yükü tahmin etmek için binanın geçmiş yük tüketimi verilerini, çeşitli meteorolojik verileri ve günün takvim bilgilerini elde etmişlerdir. Mevcut veriler ile LightGBM, Yapay Sinir Ağları, Destek Vektör Regresyonu ve Rassal Ormanlar modellerini

eğiterek tahmin başarılarını Kök Hata Karesi, Ortalama Mutlak Hata ve Ortalama Mutlak Yüzde Hatası gibi çeşitli metrikler üzerinden karşılaştırmışlardır. LightGBM modeli diğer bütün modellerden daha başarılı tahmin sonuçları elde etmiştir. Hao ve diğer. (2022) yaptıkları çalışmada çimento klinkerlerindeki f-CaO içeriğinin tahmini için zaman serisi giriş penceresine dayalı LightGBM modeli önermişlerdir. Modelde hiperparametre ayarlaması gerçekleştirmek için Bayes optimizasyon algoritması kullanılmışlardır. Deneysel sonuçları, Destek Vektör Regresyonu, Yapay Sinir Ağları, Gradyan Artırma Karar Ağacı, Aşırı Gradyan Artırma (XGBoost) ve LightGBM ile karşılaştırdıklarında, LightGBM'nin daha iyi tahmin doğruluğu, sağlamlığı ve genelliği sağladığını göstermişlerdir. Laifa ve diğer. (2021) yaptıkları çalışmada yolcu trenlerinin varış gecikmesi ile demiryolu sisteminin çeşitli özellikleri arasındaki ilişkiyi yakalayan bir makine öğrenimi modeli önermişlerdir. Tren gecikmelerinin tahmininde LightGBM, Support Vector Machine, Random Forest, XGBoost ve Yapay Sinir Ağı modelleri kullanmışlardır. Bu modellerin tahmin performanslarını R-kare, RMSE ve RME metrikleri üzerinden karşılaştırdıklarında, LightGBM'nin diğer modellerden daha iyi performans gösterdiğini ve diğer modellere göre daha hızlı sonuç verdiğini ifade etmişlerdir. Ren ve diğer. (2022) yaptıkları çalışmada CNN-LSTM-LightGBM tabanlı kısa vadeli rüzgar enerjisi tahmin yöntemi önermektedir. Çalışmada iki farklı model oluşturmuşlardır. İlk model CNN, LSTM, Dense ve Dropout katmanları içeren bir CNN-LSTM modelidir. İkinci model ise bir LightGBM modelidir. Bu iki modeli MAPE-RW algoritması ile doğrusal olarak birleştirerek nihai birleşik tahmin modeli oluşturmuşlardır. Thongthammachart ve diğer. (2022) hava kirliliği tespiti için yaptıkları çalışmada NO<sub>2</sub> ve PM<sub>2.5</sub> seviyelerinin tahmininde LightGBM, XGBoost ve Random Forest modeli kullanmışlardır. Model performanslarını karşılaştırdıklarında LightGBM'in diğer iki modele göre daha başarılı tahmin sonuçları elde ettiğini göstermişlerdir. Fan ve diğer. (2019) yaptıkları çalışmada meteorolojik veri kullanarak günlük Referans Evapotranspirasyon tahmininde LightGBM yöntemini kullanmışlardır. LightGBM modelinin tahmin performansının M5Tree ve Random Forest modellerinden daha başarılı olduğunu göstermişlerdir.

### 2.3 Uzun Kısa Zamanlı Bellek(LSTM)

LSTM, tekrar eden sinir ağılar mimarisinin özel bir türü olarak Hochreiter & Schmidhuber (1997) tarafından geliştirilmiştir. LSTM, kaybolan/patlayan gradyan problemlerinin üstesinden gelmek için tekrarlayan katmanda bellek bloğu adı verilen özel birimler sunar.



Şekil 2.6 LSTM Bellek bloğunun mimarisi Xiao & Yin (2019)

Şekil 2.6'da gösterildiği üzere LSTM bellek mimarisi sıralı olarak birbirini yineleyen bloklardan oluşmaktadır. Bu yapıda 3 adet kapı bulunmaktadır. Girdi kapısı: Bellek hüresine bilgi akışının miktarını kontrol eder. Çıktı kapısı: Ağların geri kalanına mevcut bilgi akışının miktarını kontrol eder. Unut kapısı: önceki andaki hücre durumunu seçer ve bilginin bir kısmını mevcut ana uyarlanabilir şekilde tutar.  $f_t$  unutma kapısını,  $i_t$  giriş kapısını ve  $o_t$  çıkış kapısını belirtir. Bu kapılar da geçmiş ve geleceğe dair bilgi taşıyan  $C_t$  hüresel durumunu kontrol eder.  $x_t$  ve  $h_t$  sırasıyla LSTM biriminin girdi ve çıktı bilgisini ifade eder.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.8)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.9)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (2.10)$$

$$C_t = f_t * C_t - 1 + i_t * \tilde{C}_t \quad (2.11)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.12)$$

$$h_t = o_t * \tanh(C_t) \quad (2.13)$$

Denklem 2.8 unutmama kapısını ifade eder. Bu değer hesaplanırken hücrenin  $t$  zamanındaki durumunun ağırlıklı toplamı, hücrenin  $t - 1$  zamanındaki çıktısı ve  $t$  zamanındaki girdi sigmoid aktivasyon fonksiyonuna girdi olarak verilir. Denklem 2.9'de girdi kapısı ifade edilmiştir. Girdi kapısı hesaplamasındaki parametreler ve kullanılan mantık Denklem 2.8 ile aynıdır. Denklem 2.10,  $t$  zamanındaki bellek biriminin aday değerini hesaplar, buradaki aktivasyon fonksiyonu bir tanh fonksiyonu veya bir lojistik sigmoid fonksiyonu olabilir. Denklem 2.11 geçmiş ve mevcut belleği birleştirir. Denklem 2.12'de girdi kapısı ifade edilmiştir. Girdi kapısı hesaplamasındaki parametreler ve kullanılan mantık Denklem 2.8 ile aynıdır. Denklem 2.13, hücre çıktısının ifadesidir, burada kullanılan aktivasyon fonksiyonu genellikle tanh fonksiyonudur.  $W$  ağırlık vektörü,  $b$  ise yanlılığı temsil eder Xiao & Yin (2019). Şekil 2.7 ile LSTM algoritmasının genel hatları ile algoritma akışı gösterilmiştir.

Wang ve diğer. (2023) yaptıkları çalışmada fotovoltaiik güç hesaplamada LSTM modeli kullanmışlardır. Modelin hiper parametrelerini Bayesian Optimizasyonu ile ayarlamışlardır. LSTM modelinin tahmin performansının Destek Vektör Makinaları ve k-En Yakın Komşu modellerinden daha başarılı olduğunu göstermişlerdir. Ghimire ve diğer. (2022) yaptıkları çalışmada günlük güneş ışınlamı tahmininde hibrit CNN-LSTM-MLP modeli kullanmışlardır. Modelin özneteliklerini seçerken Slime-Mould algoritmasından faydalanmışlardır. Liu ve diğer. (2022) yaptıkları çalışmada bulut örtüsü ve görünürlük dahil olmak üzere çeşitli meteorolojik verilere dayanan fotovoltaiik güç tahmin modeli önermişlerdir. Güç tahmininde iyileştirilmiş

---

**Algoritma 3: LSTM Algoritması**

---

```
Parametreleri ayarla;  
Veri setini yükle;  
Modeli başlat;  
for Belirli sayıda epoch için do  
    foreach Her bir eğitim veri örneği do  
        İleri Yayılım;  
        Giriş verisini LSTM hücresine besle;  
        LSTM hücresinde gizli durumu ve hücre durumunu güncelle;  
        Geri Yayılım;  
        Hedef değişkenin tahminini kullanarak hata hesapla;  
        Geri yayılım algoritmasıyla gradyanı hesapla;  
        LSTM hücresinde gradyanı güncelle;  
    end  
    Ağı Güncelle;  
    LSTM hücrelerinin ağırlıklarını ve parametrelerini güncelle;  
end
```

---

Şekil 2.7 LSTM Algoritması

LSTM modeli kullanmışlardır. Tahmin modelinin özneliliklerini seçerken Maksimal Bilgi Katsayısı yöntemini kullanmışlardır. Zheng ve diğer. (2020a) yaptıkları çalışmada güneş enerjisi tahmininde LSTM modeli kullanmışlardır. Tahmin modelinin parametre optimizasyonu için Parçacık Sürü Optimizasyonu yönteminden faydalanmışlardır. Önerdikleri tahmin modelinin tahmin performansının Yapay Sinir Ağları ve XGBoost yöntemlerinden daha başarılı olduğunu göstermişlerdir. Wang ve diğer. (2019) yaptıkları çalışmada fotovoltaiik güç tahmininde Evrişimli Sinir Ağları, LSTM ve hibrit CNN-LSTM modellerini kullanmışlardır. Huimin ve diğer. (2022) yaptıkları çalışmada kısa vadeli güneş ışıınımı tahmininde LSTM modeli kullanmışlardır. Modelin parametreleri Bayesian Optimizasyonu ile ayarlanmıştır. Wang ve diğer. (2020) yaptıkları çalışmada günlük fotovoltaiik güç tahmininde LSTM-RNN modeli kullanmışlardır. Qu ve diğer. (2021) yaptıkları çalışmada saatlik

fotovoltaik güç tahmininde ALSM, LSTM ve MRTPP yöntemlerini kullanmışlardır. Agga ve diğer. (2022) yaptıkları çalışmada kısa vadeli fotovoltaik güç tahmininde LSTM-CNN yöntemi önermişlerdir. Önerdikleri yöntemin standart makine öğrenimi ve derin öğrenme modellerinden daha başarılı tahminler yaptığını göstermişlerdir. Bui ve diğer. (2022) yaptıkları çalışmada kısa vadeli fotovoltaik güç tahmininde Güç/Küresel Yatay Işınım(GHI) katsayısı ile LSTM modeli kullanmışlardır. Chen & Chang (2021) yaptıkları çalışmada fotovoltaik güç tahmininde LSTM modelini kullanmışlardır. Tahmin modelinde gereksiz öznitelikleri elemek için Pearson korelasyon katsayısını kullanmışlardır. Zheng ve diğer. (2020b) yaptıkları çalışmada güneş gücü tahmininde LSTM yöntemini kullanmışlardır. LSTM modelinin parametrelerini optimize etmek için Parçacık Sürü Optimizasyonu algoritmasını kullanmışlardır. Çalışmalarının sonucunda önerdikleri LSTM modelinin tahmin performansının Yapay Sinir Ağları ve XGBoost modellerine göre daha başarılı olduğunu göstermişlerdir.

## BÖLÜM ÜÇ

### GÜNEŞ IŞINIMI TAHMİNİ

Çalışmanın bu bölümünde Dokuz Eylül Üniversitesi Tınaztepe kampüsüne kurulacak olası bir güneş enerji sisteminin üreteceği enerjinin tahmin edilmesi amaçlanmıştır. Bu süreçte NASA POWER veritabanından geçmiş meteorolojik veriler ve World Weather Online API üzerinden alınan geçmiş meteorolojik tahmin veriler güneş ışıınımı tahmininde kullanılmıştır. Güneş ışıınımı tahmini bir sonraki gün için saatlik bazda yapılmıştır.

Veriseti 2008 - 2022 yılları arasında saatlik meteorolojik verileri içermektedir. Toplam 120553 adet gözlem bulunmaktadır.


Tablo 3.1 Nasa veri tabanından çekilen öznitelikler

| Öznitelik      | Birim             |
|----------------|-------------------|
| Güneş Işınımı  | Wh/m <sup>2</sup> |
| Sıcaklık       | °C                |
| Bağıl Nem      | %                 |
| Basınç         | kPa               |
| Bulut Örtüsü   | %                 |
| Görüş Mesafesi | km                |
| Rüzgar Hızı    | m/s               |
| Rüzgar Yönü    | Derece            |

Tablo 3.1’de Nasa POWER projesinin veritabanından ve World Weather Online API üzerinden alınan değişkenler ve bu değişkenlerin birimleri gösterilmiştir.

Şekil 3.1’deki üç boyutlu grafikte güneş ışıınım değerlerinin saat ve aylara göre değişimi görülmektedir. Buna göre güneş ışıınım değerlerinin Haziran - Ağustos ayları arasında öğlen saatlerinde maksimum değere ulaştığı söylenebilir.





Şekil 3.1 Saat ve aylara göre güneş ışınlımı grafiği


Tablo 3.2 World weather online meteorolojik tahmin verileri

| Değişken       | Ortalama | Standart Sapma | Minimum | Medyan  | Maksimum |
|----------------|----------|----------------|---------|---------|----------|
| Güneş Işınımı  | 202,45   | 282,80         | 0,00    | 10,87   | 1004,95  |
| Sıcaklık       | 16,59    | 10,01          | -9,62   | 15,75   | 44,28    |
| Bağıl Nem      | 64,60    | 24,68          | 4,62    | 67,44   | 100,00   |
| Bulut Örtüsü   | 22,39    | 28,50          | 0,00    | 9,00    | 100,00   |
| Basınç         | 1014,03  | 5,93           | 991,00  | 1013,00 | 1037,00  |
| Görüş Mesafesi | 9,74     | 0,99           | 0,00    | 10,00   | 10,00    |
| Rüzgar Yönü    | 138,63   | 106,13         | 0,00    | 134,00  | 360,00   |
| Rüzgar Hızı    | 14,09    | 7,30           | 0,00    | 13,00   | 72,00    |


Tablo 3.2’de değişkenlerin tanımlayıcı istatistikleri gösterilmektedir. Bu istatistikler ve Şekil 3.2’deki histogram grafikleri incelendiğinde bağımlı değişken

olan Güneş Işınımı, Bulut Örtüsü, Rüzgar Yönü ve Rüzgar Hızı değişkenlerinin sağa çarpık bir dağılım gösterdiği görülmektedir. Basınç ve Sıcaklık değişkenleri de normal dağılıma yakın bir dağılım göstermektedir. Görüş Mesafesi ve Bağıl Nem değişkenleri de sola çarpık bir dağılım göstermektedir. Bunun yanında Görüş Mesafesi değişkeninin değerlerinin belirli seviyelerde kümелendiği görülebilir. Tablo 3.3'te ordinal bir değişken olan Görüş Mesafesi değişkeninin aldığı değerlerin frekansları gösterilmiştir. Tablodan da görüleceği üzere Görüş Mesafesi değişkenindeki 10 değeri toplam değerlerin %89,58'ini oluşturmaktadır.


### Değişkenlerin Histogram Grafikleri



Şekil 3.2 Değişkenlerin Histogram Grafikleri



Şekil 3.3 Özniteliklerin Korelasyon Isı Grafiği



Şekil 3.4 Güneş Işınımı Kutu Grafiği

Tablo 3.3 Görüş mesafesi frekansları


| Değerler | Frekans |
|----------|---------|
| 0        | 22      |
| 1        | 8       |
| 2        | 228     |
| 3        | 169     |
| 4        | 208     |
| 5        | 541     |
| 6        | 488     |
| 7        | 1588    |
| 8        | 1089    |
| 9        | 3511    |
| 10       | 67478   |

Şekil 3.3'te veri setindeki öznelitliklerin korelasyon ısı grafiği gösterilmiştir.

Grafiğe bakarak Bağımlı değişken olan Güneş Işınımının korelasyonunun en yüksek olduğu değişkenler Sıcaklık(pozitif korelasyon) ve Bağıl Nem(negatif korelasyon) olduğu görülmektedir. Güneş Işınımı ile korelasyonu en düşük değişkenler de Görüş Mesafesi, Rüzgar Hızı ve Basınç değişkenleri olmuştur. Sıcaklık ile Bağıl Nem değişkenlerinin de negatif yönde 0,82 değerinde korelasyonu olduğu görülmektedir. Şekil 3.4’de veri setindeki değişkenlerin kutu grafikleri gösterilmiştir. Bağımlı değişken olan Güneş Işınımı, Sıcaklık, Bağıl Nem ve Rüzgar Yönü değişkenlerinde aykırı değer olmadığı görülmektedir. Bulut Örtüsü, Basınç ve Rüzgar Hızı değişkenlerinde ise aykırı değerler mevcuttur. Görüş Mesafesi değişkenlerinin ise belirli değerlerde yoğunlaştığı ve kesikli değişken özelliklerine sahip olduğu görülmektedir.


### 3.1 Veri Ön İşleme

Veri setinde Rüzgar Yönü değişkeni derece cinsindendir ve bu tahmin modeli için yorumlanması zor bir değişkendir. Örneğin  $0^\circ$  ve  $360^\circ$  'ye yakın değerlerin birbirine yakın olması gerekmektedir.



Şekil 3.5 Rüzgar Hızı ve Rüzgar Yönü 2 Boyutlu Histogram Grafiği

Şekil 3.5'te Rüzgar Hızı ile Rüzgar Yönü değişkenlerinin 2 boyutlu histogram grafiği görülmektedir. Rüzgar Yönü değişkeninin maksimum ve minimum değerlerinin birleştirilmesi gerekmektedir. Rüzgar Hızı ve Rüzgar Yönü değişkenlerinin birbirleri ile olan ilişkileri de göz önünde bulundurularak bu iki değişken Denklem 3.1 - 3.3 ile Rüzgar Yönünün Vektörü Olarak birleştirilmiştir. Denklem 3.1 derece cinsinden rüzgar yönünün radyan cinsine dönüştürülmesini ifade eder. Denklem 3.2 ve Denklem 3.3 ile radyan cinsinden rüzgar yönünün rüzgar hızı ile çarpılarak yatay ve dikey eksenlerinin değerleri hesaplanmıştır.




Şekil 3.6 Rüzgar Vektörü 2 Boyutlu Histogram Grafiği

$$wr = wd * (\pi/180) \quad (3.1)$$

$$wv_x = ws * \cos(wr) \quad (3.2)$$

$$wv_y = ws * \sin(wr) \quad (3.3)$$

Şekil 3.6 ve Şekil 3.7 'deki Rüzgar vektörü yatay ve dikey eksenlerini iki boyutlu ve ayrı ayrı histogram grafikleri incelendiğinde Rüzgar Hızı ve Yönünün vektör haline getirildikten sonra daha belirgin bir patern oluşturduğu söylenebilir.



Şekil 3.7 Rüzgar Vektörü Histogram Grafikleri

Görüş mesafesi değişkeninin 0 ile 10 arasında değişen kesikli değerler aldığı görülmektedir. Fakat bu değişkenin ordinal bir karakteri olup, birbiri ile ardışık değerler arasında büyüklük küçüklük ilişkisi olduğundan değişken tipi numerik'ten kategoriğe dönüştürülmemiştir.

### 3.2 Öznitelik Mühendisliği

Bir sonraki güne ait saatlik güneş ışınlamı tahmininde sonraki günün gerçekleşen meteorolojik verilerine sahip olmayacağımız için makine öğrenimi modeline girdi olarak mevcut bağımlı ve bağımsız değişkenlerin geçmiş değerlerinin istatistiklerinin verilmesi gerekmektedir. Bu değerler bağımlı değişkenin gecikme değerleri ile bağımlı ve bağımsız değişkenlerin çeşitli zaman pencerelerindeki istatistiklerinden oluşmaktadır.

Güneş ışıının gecikme deęerleri, gemiř saatlerdeki ışıınım yoğunluęunu modele dahil ederek, gelecekteki ışıınım deęerlerinin tahmin edilmesine yardımcı olabilir. Bu gecikme deęerleri, zaman serisi modellerinde kullanılan bir znitelik trdr. Gneř ışıının gecikme deęerleri, gemiř saatlerdeki veya gemiř gnlerdeki ışıınım deęerleri modele dahil edilerek, gelecekteki ışıınım deęerlerinin daha doęru bir řekilde tahmin edilmesine yardımcı olur.

Zeng & Qiao (2013), Liao ve dięer. (2022) ve Rodrguez ve dięer. (2018) alıřmalarında gneř ışıını ve rzgar tahmininde tahmin edilecek deęiřkenlerin gecikme deęerleri tahmin modellerinde girdi olarak kullanılmıřtır.

řekil 3.8’de gsterildięi gibi  $t$ . gnn saatlik Gneř ışıını deęerlerini tahmin etmek iin nmerik meteorolojik deęiřkenlerin  $t-1$ ,  $t-2$ , ...,  $t-n$  gn nceki o saate ait gecikme deęerleri girdi olarak kullanılmaktadır. Son 30 gnlk gneř ışıını gecikme deęerleri oluřturulmuřtur.

|                     | Gneř ışıını | Gneř ışıını Gecikme(1) | Gneř ışıını Gecikme(2) |
|---------------------|--------------|-------------------------|-------------------------|
| 2022-04-01 15:00:00 | 283.50       | 285.20                  | 294.60                  |
| 2022-04-01 14:00:00 | 297.44       | 302.75                  | 310.37                  |
| .                   | .            | .                       | .                       |
| .                   | .            | .                       | .                       |
| .                   | .            | .                       | .                       |
| 2022-03-31 15:00:00 | 285.20       | 294.60                  | 290.82                  |
| 2022-03-31 14:00:00 | 302.75       | 310.37                  | 309.41                  |

řekil 3.8 Gneř ışıını Gecikme Deęiřkenleri

Ayrıca benzer řekilde  $t$  gnne ait yapılacak tahminler iin meteorolojik deęiřkenlerin son  $n$  gnlk ortalama ve standart sapma deęerleri makine ęrenimi modellerinde girdi olarak kullanılmaktadır. Deęiřkenlerin farklı periyotlardaki



trendlerini yakalayabilmek için son 1, 5, 10, 30 ve 60 günlük zaman pencerelerinde değişkenlerin hareketli ortalama ve standart sapma istatistikleri oluşturulmuştur.

Güneş ışıınımı değerlerinin gün içindeki değişimlerinin ve yıllık döngüsellüğünün modellenebilmesi için Saat ve Ay kategorik değişkenleri oluşturulmuştur.

Zaman bilgilerinin, güneş ışıınımı tahmin modeline katkısı oldukça önemlidir. Saat ve ay gibi zaman bilgileri, güneş ışıınımının günün saatlerine göre değişimini yakalamak için kritik öneme sahiptir. Güneş ışıınımı, yeryüzünde gün içinde değişken bir şekilde dağılır ve bu da zaman bilgilerinin modele eklenmesiyle daha doğru tahminler yapılmasını sağlar. Örneğin Şekil 3.1’de de görüleceği üzere, günün saatine göre değişen güneş ışıınımı nedeniyle, özellikle öğle saatlerinde ışıınımı yüksek değerler alırken, sabah ve akşam saatlerinde daha az değerler almaktadır. Benzer şekilde kış aylarında güneş ışıınımı, yaz aylarına göre daha az değerler almaktadır . Bu nedenle, saat ve ay bilgilerinin modelde kullanılması, güneş ışıınımının gün içindeki ve yılın farklı aylarındaki değişkenliğinin öğrenilebilmesini sağlar.

### 3.3 Öznitelik Ölçeklendirme

Öznitelik ölçeklendirme, makine öğrenimi algoritmalarında veri setinin ölçeğini değiştirerek algoritmanın daha iyi performans göstermesine yardımcı olan bir yöntemdir. Bu işlem, öznitelikleri aynı ölçekte olacak şekilde değiştirerek, algoritmanın ağırlıklarının ve yanlılığının daha tutarlı ve etkili bir şekilde hesaplanmasına olanak sağlar. Öznitelik ölçeklendirme yöntemleri arasında en yaygın olanları standartlaştırma ve min-max ölçeklendirme yöntemleridir. Standartlaştırma, özelliklerin ortalamasını 0 ve standart sapmasını 1’e getirerek ölçeklendirir. Min-max ölçeklendirme yöntemi, verileri belirli bir aralığa (genellikle [0,1] veya [-1,1]) sığdırmak için kullanılan bir yöntemdir. Bu yöntem, verilerin minimum ve maksimum değerlerini hesaplar ve bu değerler arasında kalan verileri belirtilen aralığa sığdırır.

Yapılan çalışmaya benzer konulu bir çalışma olan Rodríguez ve diğer. (2018) çalışmasında makine öğrenimi ile güneş ışıınımı tahmini yapılırken min-max ölçeklendirme yöntemi kullanılmıştır. Benzer şekilde, mevcut çalışmada da min-max ölçeklendirme yöntemini kullanılmış olup, veriler doğru bir şekilde ölçeklendirilerek, modelin daha doğru sonuçlar elde edilmesi amaçlanmıştır.

Min-max ölçeklendirme yöntemi, Denklem 4.4'te gösterildiği üzere öznitelikleri 0 - 1 aralığına sıkıştırarak ölçeklendirdiği için verilerin dağılımını korur ve en yaygın kullanılan yöntemlerden biridir. Şekil 3.9'da min-maks ölçeklendirilmiş bir öznitelik örneği gösterilmiştir.

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.4)$$

Öznitelik

| X1  |
|-----|
| 150 |
| 300 |
| 225 |
| 70  |
| 200 |
| 250 |

Ölçeklendirilmiş Öznitelik

| X1                  |
|---------------------|
| $(150-70)/(300-70)$ |
| $(300-70)/(300-70)$ |
| $(225-70)/(300-70)$ |
| $(70-70)/(300-70)$  |
| $(200-70)/(300-70)$ |
| $(250-70)/(300-70)$ |


=

| X1    |
|-------|
| 0,347 |
| 1     |
| 0,673 |
| 0     |
| 0,565 |
| 0,782 |

Şekil 3.9 Min-Maks Ölçeklendirme

### 3.4 Model Doğrulama Yöntemi

Çapraz doğrulama, verileri birden fazla eğitim ve test alt kümesine ayırarak yapılan bir örnekleme işlemidir. Tahmin edicilerin genel performansı, tüm test alt kümelerindeki tahmin doğruluğu ölçümlerine bakarak elde edilir. Özellikle küçük veri örneklerinde tahmin modellerinin doğrulanması için zaman serisi çapraz doğrulama önemli bir adımdır. Sharadga ve diğer. (2020) yaptıkları çalışmalarında LSTM yöntemi ile güneş enerjisi tahmininde model doğrulama kısmında zaman serisi çapraz doğrulama yöntemini kullanmışlardır. Bu çalışmada da, tahmin edicilerin performansı değerlendirilirken kayan pencere çapraz doğrulama yöntemi kullanılmaktadır. Bu yöntem Şekil 3.10'da gösterilmiştir. Eğitim, doğrulama ve test setlerinin boyutu sabit olarak belirlenmiş olup %70 eğitim, %15 doğrulama ve %15 oranında da test verisi kullanılmıştır.




Şekil 3.10 Zaman Serisi Çapraz Doğrulama


### 3.5 Öznitelik Seçimi

Modellerde kullanılacak geçmişe dönük Lag(gecikme) sayısına karar vermek için Liao ve diğer. (2022) çalışmasında olduğu gibi otokorelasyon ve kısmi otokorelasyon grafikleri incelenmiştir. Kısmi otokorelasyon fonksiyonu (PACF), güneş ışınlamı

değerlerinin otokorelasyonunu hesaplamak için kullanılabilir. Bu fonksiyon, gerçek değer ile gecikme değerleri arasındaki doğrudan ilişkiyi diğer kısa vadeli gecikme değerlerinin etkisini ortadan kaldırarak açıklar. Güneş ışıınımı değerlerinin otokorelasyon analizi sayesinde, mevcut güneş ışıınımı değerleri ile geçmiş değerler arasındaki ilişki belirlenebilir ve makine öğrenimi modellerinde girdi olarak kullanılacak uygun gecikme sırası seçilebilir. Şekil 3.11 ve Şekil 3.12 , saatlik güneş ışıınımı değerlerinin önceki 30 güne kadar olan Otokorelasyon ve Kısmi Otokorelasyon grafiklerini göstermektedir. Lag sırasıyla arttıkça, Otokorelasyon değerleri yavaşça azalmakta ve sabit bir şekilde devam etmektedir. Kısmi Otokorelasyon değerlerinin ise, 16. günlük lag'den itibaren hızlı bir şekilde azaldığı görülmektedir. Bu nedenle, güneş ışıınımı değerlerinin 16 günlük lag değerlerinin güçlü otokorelasyona sahip olduğu belirgin hale gelmektedir.



Şekil 3.11 Otokorelasyon Grafiği




Şekil 3.12 Kısmi Otokorelasyon Grafiği

Özyinelemeli öznelilik eleme (ÖÖE), makine öğrenmesinde kullanılan bir öznelilik seçim yöntemidir. Bu yöntemde, önce tüm özneliliklerin kullanıldığı bir model oluşturulur ve her öznelilik için bir önem puanı hesaplanır. Daha sonra, en az önem puanına sahip öznelilik çıkarılarak yeni bir model oluşturulur ve önem puanları tekrar hesaplanır. Bu işlem, istenen sayıda öznelilik kalmayana kadar devam eder. ÖÖE yöntemi, istenen öznelilik alt kümesi boyutu gibi bir parametre kullanarak ayarlanabilir.

Yapılan çalışmada, sklearn kütüphanesi feature\_selection modülünden RFECV class'ını kullanarak ÖÖE yöntemi uygulanmıştır. Bu sınıf, Recursive Feature Elimination (RFE) yöntemini uygular ve aynı zamanda çapraz doğrulama kullanarak öznelilik seçimini optimize eder. Öğrenme algoritması olarak GradientBoostingRegressor'ı seçilmiştir çünkü bu algoritma, yüksek doğruluk oranları sağlayan bir öğrenme algoritmasıdır ve aynı zamanda öznelilik önem derecelerini hesaplamak için kullanılabilir. Ayrıca, 5-fold çapraz doğrulama


kullanarak modelin güvenilirliği sağlanmıştır. Bu sayede, daha genel bir model elde edilerek aşırı öğrenme engellenmiştir.



Şekil 3.13 Özyinelemeli Öznitelik Seçimi Grafiği

Özyinelemeli öznitelik seçimi sonucunda 80 adet öznitelik arasından en başarılı sonucu veren öznitelik alt kümesi seçilmiştir. Güneş Işınımı gecikme öznitelikleri dışında 23 adet öznitelik seçilmiştir. Şekil 3.13’de seçilen öznitelikler ve Şekil 3.14’te de öznitelik önem düzeyleri gösterilmiştir.

Sonuç olarak Özyinelemeli öznitelik seçimi ile seçilen 23 değişken ve Otokorelasyon grafikleri ile belirlenen son 16 günlük gecikme değişkenleri ile toplamda 39 değişken modellerde girdi olarak kullanılmak üzere belirlenmiştir. Makine öğrenimi algoritmalarında seçilen 39 öznitelik girdi olarak kullanılacaktır.



Şekil 3.14 Rfev ile Seçilen Öznitelikler

### 3.6 Hiperparametre Optimizasyonu

LSTM modeli hiper parametrelerinin seçiminde Grid Search Cross Validation yöntemi kullanılmıştır. Parametre gridini belirlemek için, Bounoua & Mechaqrane (2023) makalesindeki parametre gridinden de faydalanılmıştır. Bu makale, güneş ışınlı tahmini yapmak için LSTM yöntemini kullanarak başarılı sonuçlar elde eden bir çalışmadır.

Tablo 3.4 LSTM hyper-parametreleri ve arama aralıkları

| Hiper Parametre | Arama Aralığı | Değer |
|-----------------|---------------|-------|
| optimizer       | Adam, RMSprop | Adam  |
| layers          | 1-5           | 3     |
| units           | 10-100        | 30    |
| Epochs          | 10-100        | 50    |
| learning rate   | 0,0001-0,01   | 0,01  |
| Dropout rate    | 0-0,5         | 0,1   |

LSTM modelinin GridSearchCV ile seçilen parametreleri Tablo 3.4'te

gösterilmiştir. Buna göre optimizasyon algoritması olarak Adam, layer sayısı 3, layer’lardaki unit sayıları 30, Epoch sayısı 50, öğrenme oranı 0,01 ve Dropout oranı 0,1 olarak belirlenmiştir.

Tablo 3.5 ANN hiper parametreleri ve arama aralıkları

| Hiper Parametre | Arama Aralığı | Değer |
|-----------------|---------------|-------|
| optimizer       | Adam, RMSprop | Adam  |
| layers          | 1-5           | 5     |
| units           | 10-100        | 100   |
| Epochs          | 10-100        | 70    |
| learning rate   | 0,0001-0,01   | 0,01  |
| Dropout rate    | 0-0,5         | 0,2   |

Yapay Sinir Ağı modelinin GridSearchCV ile seçilen parametreleri Tablo 3.5’te gösterilmiştir. Parametrelerin aralıkları sezgisel olarak ve deneme yanılma yöntemi ile belirlenmiştir. Buna göre optimizasyon algoritması olarak Adam, layer sayısı 5, layer’lardaki unit sayıları 100, Epoch sayısı 70, öğrenme oranı 0,01 ve Dropout oranı 0,2 olarak belirlenmiştir.

LightGBM modelinin GridSearchCV ile seçilen parametreleri Tablo 3.6’te gösterilmiştir. Parametrelerin aralıkları sezgisel olarak ve deneme yanılma yöntemi ile belirlenmiştir.

Tablo 3.6 LightGBM hiper parametreleri ve arama aralıkları

| Hiper Parametre  | Arama Aralığı | Değer |
|------------------|---------------|-------|
| Number of Leaves | 5-15          | 12    |
| learning rate    | 0,0001-0,1    | 0,01  |
| Max Depth        | 5-10          | 7     |
| Lambda L1        | 0-0,5         | 0,1   |
| Lambda L2        | 0-0,5         | 0,1   |
| Feature Fraction | 0,2-1         | 0,7   |



### 3.7 Model Performans Metrikleri

Yapılan çalışmada oluşturulan modellerin performanslarını değerlendirmek için MSE (Ortalama Kare Hatası), RMSE (Kök Ortalama Kare Hatası), MAE (Ortalama Mutlak Hata) ve MAPE (Ortalama Mutlak Yüzde Hata) metrikleri kullanılmıştır. MSE (Ortalama Kare Hatası), Denklem 3.5’de gösterildiği üzere bir öğrenme modelinin tahminleri ile gerçek değerler arasındaki farkların karelerinin ortalamasını hesaplar.

$$MSE = \frac{1}{N} \sum_{i=1}^N (o_i - p_i)^2 \quad (3.5)$$

RMSE (Kök Ortalama Kare Hatası, Denklem 3.6’de gösterildiği üzere MSE’nin karekökünü alarak, tahmin hatalarının standart sapmasını hesaplar.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (o_i - p_i)^2}{N}} \quad (3.6)$$

MAE (Ortalama Mutlak Hata), Denklem 3.7’de gösterildiği üzere bir öğrenme modelinin tahminleri ile gerçek değerler arasındaki farkların karelerinin ortalamasını hesaplar.

$$MAE = \frac{1}{N} \sum_{i=1}^N |o_i - p_i| \quad (3.7)$$

MAPE (Ortalama Mutlak Yüzde Hata), Denklem 3.8’de gösterildiği üzere bir öğrenme modelinin tahminleri ile gerçek değerler arasındaki mutlak yüzde farkların ortalamasını hesaplar.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{o_i - p_i}{o_i} \right| \quad (3.8)$$

### 3.8 Tahmin Performansı Karşılaştırmaları

Tablo 3.7’de GridSearchCV ile en iyi parametre dizilimleri seçilen ANN, LSTM ve LightGBM modellerinin test verisindeki tahmin performansları MAE, MSE, RMSE ve MAPE metrikleri üzerinden karşılaştırılmıştır. Sonuç olarak bütün metriklerdeki tahmin başarısı en yüksek model LightGBM, ikinci sırada LSTM ve


son sırada da ANN modeli olduğu görülmektedir. Yapılacak güneş enerjisi hesaplamalarında Tablo 3.7'daki sonuçlara göre LightGBM algoritmasının kullanılmasına karar verilmiştir.

Tablo 3.7 Tahmin performans karşılaştırması

| <b>Algoritma</b> | <b>MAE</b> | <b>MSE</b> | <b>RMSE</b> | <b>MAPE</b> |
|------------------|------------|------------|-------------|-------------|
| LightGBM         | 40,12      | 5214,242   | 72,209      | 21,29%      |
| ANN              | 46,16      | 6278,292   | 81,167      | 23,1%       |
| LSTM             | 45,617     | 5785,669   | 76,063      | 22,2%       |


Şekil 3.15'teki grafikte, algoritmaların mevsimlere göre MSE skorları gösterilmiştir. Grafiğin sol tarafında, ilkbahar, yaz, sonbahar ve kış olarak dört mevsim yer almaktadır. Grafiğin alt tarafında ise LightGBM, LSTM ve ANN olarak güneş ışıınımı tahmininde kullanılan üç farklı algoritma yer almaktadır. Grafiğin sağ tarafında, MSE skorları yer almaktadır.

Grafiğe bakıldığında, Tablo 3.7'da da görüleceği üzere LightGBM algoritmasının diğer algoritmalara göre daha düşük MSE değerlerine sahip olduğu görülmektedir. ANN algoritması ise genellikle en yüksek MSE değerlerine sahiptir. Ayrıca, sonbahar mevsiminin diğer mevsimlere göre daha düşük MSE skorlarına sahipken ilkbahar mevsiminin üç algortmada da en yüksek MSE değerlerine sahip olduğu görülmektedir.




Şekil 3.15 Mevsimlere göre algoritmaların MSE değerleri


Şekil 3.16, Şekil 3.17, Şekil 3.18 ve Şekil 3.19'deki grafiklerde farklı mevsimlere ait 8 günlük gerçekleşen güneş ışınlamı ve tahmin değerleri görülmektedir. Dört grafik incelendiğinde Şekil 3.15'teki mevsimlere göre hata değerlerine benzer sonuçlar olduğu söylenebilir. Tahminler ile gerçekleşen değerler arasındaki en düşük fark yaz ve sonbahar mevsimlerine ait Şekil 3.19 ve Şekil 3.18'deki grafiklerde gerçekleşmiştir. Bu mevsimleri Şekil 3.17'daki kış ayı takip ederken, en büyük fark Şekil 3.16'teki ilkbahar mevsimine ait grafikte görülmektedir.




Şekil 3.16 LightGBM modeli ilkbahar için tahmin karşılaştırma grafiği



Şekil 3.17 LightGBM modeli kış için tahmin karşılaştırma grafiği



Şekil 3.18 LightGBM modeli sonbahar için tahmin karşılaştırma grafiği



Şekil 3.19 LightGBM modeli yaz için tahmin karşılaştırma grafiği


### 3.9 LightGBM Güneş Işınımı Tahmin Modeli ile Güç Kestirimi

Tahmin edilen güneş ışıınımı değęerleri ve bir sonraki güne ait sıcaklık değęerleri kullanılarak belirli parametrelerdeki bir güneş panelinin fotovoltaiik güç çıktıısı


Denklem 5.1’de hesaplanmıştır.  $P_S$  elektriksel güç üretimidir (W),  $\eta$  dönüşüm verimlilik katsayısıdır,  $S$  modülün alanıdır ( $m^2$ ),  $I$  güneş ışıdır ( $W/m^2$ ) ve  $t_0$  ölçülen sıcaklıktır ( $^{\circ}C$ ). Elektriksel güç üretimini hesaplamak için, parametreleri  $\eta = 17,59\%$  ve  $S = 1,6767 m^2$  olan bir adet PV güneş paneli seçilmiştir Rodríguez ve diğer. (2018).

$$P_S = \eta SI(1 - 0,005(t_0 - 25)) \quad (3.9)$$


Şekil 3.21, Şekil 3.22, Şekil 3.24 ve Şekil 3.25’deki grafiklerdeki güç değerleri Denklem 3.9 ile hesaplanmıştır. Denklemdeki güneş ışıdır değerleri LightGBM modeli ile tahmin edilen değerlerdir, Sıcaklık değerleri ise POWER veritabanından alınan gerçekleşen saatlik sıcaklık değerleridir.



Şekil 3.20 28 Ocak 2022 - 2 Şubat 2022 Güneş Işınımı - Güç Grafiği



Şekil 3.21 28 Ocak 2022 Enerji Grafiği




Şekil 3.22 29 Ocak 2022 Enerji Grafiği

Şekil 3.20’de 28 Ocak 2022 ile 2 Şubat 2022 tarihleri arasındaki saatlik güneş ışınlamı ve hesaplanan güç değerleri gösterilmiştir. Şekil 3.21’de 28 Ocak 2022 tarihine ait bulutluluk oranının yüksek olduğu bir güne ait güneş panelinin saatlik güç çıktısı ve günlük kümülatif enerji üretimi grafiği gösterilmiştir. Şekil 3.22’de 29 Ocak 2022 tarihli bulutluluk oranının düşük olduğu bir güne ait grafik gösterilmiştir. Bu iki grafiğe baktığımızda 28 Ocak 2022 tarihinde toplam 776 Wh enerji üretilmesi tahmin edilmişken bir sonraki gün 1148 Wh enerji üretimi tahmin edilmiştir. Bu da iki gün arasında % 47 enerji farkı olduğu anlamına gelmektedir.


Şekil 3.23’de 13 Haziran 2021 - 18 Haziran 2021 tarihleri arasındaki saatlik güneş ışınlamı ve hesaplanan güç değerleri gösterilmiştir. Şekil 3.24’de 13 Haziran 2021 tarihine ait bulutluluk oranının yüksek olduğu bir güne ait güneş panelinin saatlik güç çıktısı ve günlük kümülatif enerji üretimi grafiği gösterilmiştir. Şekil 3.25’de 16 Haziran 2021 tarihli bulutluluk oranının düşük olduğu bir güne ait grafik




gösterilmiştir. Bu iki grafiğe baktığımızda 13 Haziran 2021 tarihinde toplam 2158 Wh enerji üretilmesi tahmin edilmişken bir sonraki gün 1644 Wh enerji üretimi tahmin edilmiştir. Bu da üç gün arayla üretilen günlük enerji miktarında % 23 azalma olduğu anlamına gelmektedir.



Şekil 3.23 13 Haziran 2021 - 18 Haziran 2021 Güneş Işınımı - Güç Grafiği



Şekil 3.24 13 Haziran 2021 Enerji Grafiği



Şekil 3.25 16 Haziran 2021 Enerji Grafiği

Güneş ışınımına bağlı olarak güneş panelinin üreteceği günlük enerji farklılıklarının bu derece yüksek olması günlük fotovoltaik güç ve enerji tahmininin ne kadar kritik bir öneme sahip olduğunu göstermektedir. Güneş panelinin bir sonraki gün üreteceği enerji miktarının önceden tahmin edilmesi, enerji talebinin karşılanması için gerekli önlemler alınması ve güç kesintileri veya enerji dalgalanmalarının önlenerek güç sistemlerinin istikrarının sağlanabilmesine katkı sağlayabilir. Enerji sisteminin bakımı için üretilecek enerji potansiyelinin düşük olduğu günler seçilebilir. Mevsimsel eğilimler, elektrik piyasasında oluşacak fiyat tahminleri, ekipmanın durumu ve teknisyen mevcudiyeti gibi diğer faktörlere üretim tahminlerini eklemek, enerji üreticileri için çok yararlı olmaktadır. Ayrıca ticari amaçlar ile kurulan güneş enerjisi sistemleri için gün öncesi piyasasında optimum fiyat tekliflerinin verilmesi için de o güne ait üretilecek enerjinin tahmin edilmesi kritik düzeyde önemlidir.

## **BÖLÜM DÖRT**

### **SONUÇLAR VE TARTIŞMA**

Bu çalışmada, belirli parametrelerdeki bir güneş paneli sistemi için bir sonraki güne ait saatlik güneş ışıınımı tahmini yapılarak, sonraki güne ait saatlik güç ve günlük enerji üretimini tahmini yapan bir model sunulmuştur. Saatlik güneş ışıınımı tahmini yapılırken geçmiş günlere ait meteorolojik değişkenlerin istatistikleri kullanılmıştır. Güneş ışıınımı tahmini için, Yapay Sinir Ağları, LSTM ve LightGBM gibi üç farklı makine öğrenimi modeli karşılaştırılarak en başarılı sonuçları veren LightGBM modeli seçilmiştir. Seçilen modelin test verisi üzerinde Ortalama Mutlak Hata Yüzdesi (MAPE) değeri %21,29 olmuştur. Elde edilen modelin yaz ve sonbahar mevsimlerinde kış ve ilkbahar mevsimlerine göre çok daha başarılı tahminler yaptığı gösterilmiştir. Bu model üzerinden yapılan güneş ışıınımı tahminleri ile hesaplanan sonraki güne ait saatlik güç ve günlük enerji değerlerinin kısa vadelerdeki değişimleri gösterilmiş ve bu bilgilerin hangi amaçlar ile kullanılabileceği açıklanmıştır.

Literatürdeki çalışmaların büyük çoğunluğunda 1 saatten daha kısa vadeli tahmin periyotları mevcuttur. Saatlik tahmin yapılan çalışmalarda da sadece bir sonraki saat tahmin edilmiştir. Buna karşın yapılan çalışmada saatlik olarak bir sonraki güne ait güneş ışıınımı tahmini yapılarak tahmin periyodu daha uzun tutulmuştur. Yapılan çalışmada kullanılan meteorolojik değişkenlerin sadece geçmiş değerlerinin istatistikleri kullanılmış olması ve gecikme, hareketli ortalama ve hareketli standart sapma gibi farklı istatistiklerin kullanılmış olması da mevcut çalışmanın literatürdeki çalışmalardan farklılaştırmaktadır.

İlerleyen çalışmalarda halihazırda kurulu bir güneş enerjisi sisteminin verileri kullanılarak tahmin edilen güneş enerjisi değerleri de sistemin ürettiği enerji değerleri ile karşılaştırılarak tahmin değerlerinin güvenilirliği ölçülebilir hale getirilebilir. Güneş ışıınımı tahmininde farklı meteorolojik değişkenler tahmin modelinde kullanılabilir. Ayrıca mevcut modelin kış ve ilkbahar mevsimlerindeki tahmin performansı düşüklüğü analiz edilip iyileştirilebilir.

## KAYNAKLAR

- Ağbulut, Ü., Gürel, A. E., & Biçen, Y. (2021). Prediction of daily global solar radiation using different machine learning algorithms: Evaluation and comparison. *Renewable and Sustainable Energy Reviews*, 135, 110114.
- Agga, A., Abbou, A., Labbadi, M., Houm, Y. E., & Ou Ali, I. H. (2022). Cnn-lstm: An efficient hybrid deep learning architecture for predicting short-term photovoltaic power production. *Electric Power Systems Research*, 208, 107908.
- Amrouche, B., & Le Pivert, X. (2014). Artificial neural network based daily local forecasting for global solar radiation. *Applied Energy*, 130, 333-341.
- Bounoua, Z., & Mechaqrane, A. (2023). Hourly and sub-hourly ahead global horizontal solar irradiation forecasting via a novel deep learning approach: A case study. *Sustainable Materials and Technologies*, 36, e00599.
- Bui, L. D., Nguyen, N. Q., Doan, B. V., & Sanseverino, E. R. (2022). Forecasting energy output of a solar power plant in curtailment condition based on lstm using p/ghi coefficient and validation in training process, a case study in vietnam. *Electric Power Systems Research*, 213, 108706.
- Cervone, G., Clemente-Harding, L., Alessandrini, S., & Delle Monache, L. (2017). Short-term photovoltaic power forecasting using artificial neural networks and an analog ensemble. *Renewable Energy*, 108, 274-286.
- Chen, H., & Chang, X. (2021). Photovoltaic power prediction of lstm model based on pearson feature selection. *Energy Reports*, 7, 1047-1054. 2021 International Conference on Energy Engineering and Power Systems.
- Chen, Z., Chen, Y., Xiao, T., Wang, H., & Hou, P. (2021). A novel short-term load forecasting framework based on time-series clustering and early classification algorithm. *Energy and Buildings*, 251, 111375.
- Cornaro, C., Pierro, M., & Bucci, F. (2015). Master optimization process based on neural networks ensemble for 24-h solar irradiance forecast. *Solar Energy*, 111, 297-312.

- Fan, J., Ma, X., Wu, L., Zhang, F., Yu, X., & Zeng, W. (2019). Light gradient boosting machine: An efficient soft computing model for estimating daily reference evapotranspiration with local and external meteorological data. *Agricultural Water Management*, 225, 105758.
- Ferrero Bermejo, J., Gómez Fernández, J. F., Olivencia Polo, F., & Crespo Márquez, A. (2019). A review of the use of artificial neural network models for energy and reliability prediction. a study of the solar pv, hydraulic and wind energy sources. *Applied Sciences*, 9(9).
- Friedman, J. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29, 1189-1232.
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4), 193–202.
- Geetha, A., Santhakumar, J., Sundaram, K. M., Usha, S., Thentral, T. T., Boopathi, C., Ramya, R., & Sathyamurthy, R. (2022). Prediction of hourly solar radiation in tamil nadu using ann model with different learning algorithms. *Energy Reports*, 8, 664-671. 2021 The 8th International Conference on Power and Energy Systems Engineering.
- Ghenai, C., Ahmad, F. F., Rejeb, O., & Bettayeb, M. (2022). Artificial neural networks for power output forecasting from bifacial solar pv system with enhanced building roof surface albedo. *Journal of Building Engineering*, 56, 104799.
- Ghimire, S., Deo, R. C., Casillas-Pérez, D., Salcedo-Sanz, S., Sharma, E., & Ali, M. (2022). Deep learning cnn-lstm-mlp hybrid fusion model for feature optimizations and daily solar radiation prediction. *Measurement*, 202, 111759.
- Ghimire, S., Deo, R. C., Downs, N. J., & Raj, N. (2019). Global solar radiation prediction by ann integrated with european centre for medium range weather forecast fields in solar rich cities of queensland australia. *Journal of Cleaner Production*, 216, 288-310.

- Hao, X., Zhang, Z., Xu, Q., Huang, G., & Wang, K. (2022). Prediction of f-cao content in cement clinker: A novel prediction method based on lightgbm and bayesian optimization. *Chemometrics and Intelligent Laboratory Systems*, 220, 104461.
- Hebb, D. O. (1949). The organization of behavior: A neuropsychological theory.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9, 1735-80.
- Hong, Y.-Y., & Rioflorido, C. L. P. P. (2019). A hybrid deep learning-based neural network for 24-h ahead wind power forecasting. *Applied Energy*, 250, 530-539.
- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, 79(8), 2554-2558.
- Hopfield, J. J. (1984). Neurons with graded response have collective computational properties like those of two-state neurons. *Proceedings of the National Academy of Sciences*, 81(10), 3088-3092.
- Huimin, Z., Qiu, J., Jia, Y.-H., Wang, Q., & Li, F.-F. (2022). Ten-minute prediction of solar irradiance based on cloud detection and a long short-term memory (lstm) model. *Energy Reports*, 8, 5146-5157.
- Jebli, I., Belouadha, F.-Z., Kabbaj, M. I., & Tilioua, A. (2021). Prediction of solar energy guided by pearson correlation using machine learning. *Energy*, 224, 120109.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. In *Proceedings of the 31st International Conference on Neural Information Processing Systems, NIPS'17*, ( 3149–3157)., Red Hook, NY, USA. Curran Associates Inc.
- Lai, J.-P., Chang, Y.-M., Chen, C.-H., & Pai, P.-F. (2020). A survey of machine learning models in renewable energy predictions. *Applied Sciences*, 10(17).
- Laifa, H., khcherif, R., & Ben Ghezalaa, H. H. (2021). Train delay prediction in tunisian railway through lightgbm model. *Procedia Computer Science*, 192,

- 981-990. Knowledge-Based and Intelligent Information & Engineering Systems: Proceedings of the 25th International Conference KES2021.
- Liao, S., Tian, X., Liu, B., Liu, T., Su, H., & Zhou, B. (2022). Short-term wind power prediction based on lightgbm and meteorological reanalysis. *Energies*, 15(17).
- Liu, R., Wei, J., Sun, G., Muyeen, S., Lin, S., & Li, F. (2022). A short-term probabilistic photovoltaic power prediction method based on feature selection and improved lstm neural network. *Electric Power Systems Research*, 210, 108069.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115–133.
- Mellit, A., Massi Pavan, A., & Lughi, V. (2014). Short-term forecasting of power production in a large-scale photovoltaic plant. *Solar Energy*, 105, 401-413.
- Najeebullah, Zameer, A., Khan, A., & Javed, S. G. (2015). Machine learning based short term wind power prediction using a hybrid learning model. *Computers & Electrical Engineering*, 45, 122-133.
- Oral, O., Caglayan, N., & Uğuz, S. (2019). Estimation of energy to be obtained from pv power plants using machine learning methods. - pv güç santrallerinden elde edilecek enerjinin makine öğrenmesi metotları kullanılarak tahmin edilmesi., 769-779.
- Pan, M., Li, C., Gao, R., Huang, Y., You, H., Gu, T., & Qin, F. (2020). Photovoltaic power forecasting based on a support vector machine with improved ant colony optimization. *Journal of Cleaner Production*, 277, 123948.
- Pazikadin, A. R., Rifai, D., Ali, K., Malik, M. Z., Abdalla, A. N., & Faraj, M. A. (2020). Solar irradiance measurement instrumentation and power solar generation forecasting based on artificial neural networks (ann): A review of five years research trend. *Science of The Total Environment*, 715, 136848.
- Qu, J., Qian, Z., & Pei, Y. (2021). Day-ahead hourly photovoltaic power forecasting using attention-based cnn-lstm neural network embedded with multiple relevant and target variables prediction pattern. *Energy*, 232, 120996.



- Rana, M., Koprinska, I., & Agelidis, V. G. (2016). Univariate and multivariate methods for very short-term solar photovoltaic power forecasting. *Energy Conversion and Management*, 121, 380-390.
- Ren, J., Yu, Z., Gao, G., Yu, G., & Yu, J. (2022). A cnn-lstm-lightgbm based short-term wind power prediction method based on attention mechanism. *Energy Reports*, 8, 437-443. ICPE 2021 - The 2nd International Conference on Power Engineering.
- Rodríguez, F., Fleetwood, A., Galarza, A., & Fontán, L. (2018). Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control. *Renewable Energy*, 126, 855-864.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65 6, 386-408.
- Rumelhart, E., D., McClelland, J., & L., J. (1986). *Parallel distributed processing: explorations in the microstructure of cognition. Volume 1. Foundations*.
- Sharadga, H., Hajimirza, S., & Balog, R. S. (2020). Time series forecasting of solar power generation for large-scale photovoltaic plants. *Renewable Energy*, 150, 797-807.
- Thongthammachart, T., Araki, S., Shimadera, H., Matsuo, T., & Kondo, A. (2022). Incorporating light gradient boosting machine to land use regression model for estimating no2 and pm2.5 levels in kansai region, japan. *Environmental Modelling & Software*, 155, 105447.
- Timilsina, G. R., Kurdgelashvili, L., & Narbel, P. A. (2011). A review of solar energy: Markets, economics and policies. *World Bank Policy Research Working Paper*, 5845.
- Wang, F., Xuan, Z., Zhen, Z., Li, K., Wang, T., & Shi, M. (2020). A day-ahead pv power forecasting method based on lstm-rnn model and time correlation modification under partial daily pattern prediction framework. *Energy Conversion and Management*, 212, 112766.

- Wang, K., Qi, X., & Liu, H. (2019). A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network. *Applied Energy*, 251, 113315.
- Wang, L., Mao, M., Xie, J., Liao, Z., Zhang, H., & Li, H. (2023). Accurate solar pv power prediction interval method based on frequency-domain decomposition and lstm model. *Energy*, 262, 125592.
- WIDROW, B., & HOFF, M. E. (1960). Adaptive switching circuits.
- Xiao, Y., & Yin, Y. (2019). Hybrid lstm neural network for short-term traffic flow prediction. *Information*, 10(3).
- Zeng, J., & Qiao, W. (2013). Short-term solar power prediction using a support vector machine. *Renewable Energy*, 52, 118-127.
- Zheng, J., Zhang, H., Dai, Y., Wang, B., Zheng, T., Liao, Q., Liang, Y., Zhang, F., & Song, X. (2020a). Time series prediction for output of multi-region solar power plants. *Applied Energy*, 257, 114001.
- Zheng, J., Zhang, H., Dai, Y., Wang, B., Zheng, T., Liao, Q., Liang, Y., Zhang, F., & Song, X. (2020b). Time series prediction for output of multi-region solar power plants. *Applied Energy*, 257, 114001.
- Zheng, J., Zhang, H., Dai, Y., Wang, B., Zheng, T., Liao, Q., Liang, Y., Zhang, F., & Song, X. (2022). Short-Term Wind Power Prediction Based on LightGBM and Meteorological Reanalysis *Energies*, 15, 6287.