



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



DERİN ÖĞRENME İLE GÜNEŞ ENERJİ
SANTRALLERİNDE ÜRETİM TAHMİNİ

Azime İrem KÖKSAL

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Nisan-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Azime İrem KÖKSAL tarafından hazırlanan “Derin Öğrenme İle Güneş Enerji Santrallerinde Üretim Tahmini” adlı tez çalışması 18/04/2024 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi Saim ERVURAL
(KTO Karatay Üniversitesi)

.....

Danışman

Doç. Dr. Rahime CEYLAN
(Konya Teknik Üniversitesi)

.....

Üye

Dr. Öğr. Üyesi Mücahid BARSTUĞAN
(Konya Teknik Üniversitesi)

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Azime İrem KÖKSAL

Tarih:18.04.2024

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME İLE GÜNEŞ ENERJİ SANTRALLERİNDE ÜRETİM TAHMİNİ

Azime İrem KÖKSAL

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı**

Danışman: Doç. Dr. Rahime CEYLAN

2024, 43 Sayfa

Jüri

**Doç. Dr. Rahime CEYLAN
Dr. Öğr. Üyesi Saim ERVURAL
Dr. Öğr. Üyesi Mücahid BARSTUĞAN**

Her geçen gün artan endüstriyel faaliyetler, sürekli artan nüfus ve teknolojik aletlerin kullanımının giderek yaygınlaşması ile enerji tüketiminde de sürekli olarak bir artış meydana gelmektedir. Hem fosil yakıtların tükenmek ile karşı karşıya oluşu hem de doğaya olumsuz etkilerinden dolayı yenilenebilir enerji kaynaklarına olan talep gün geçtikçe artmaktadır. Söz konusu bu artış ile elektrik enerjisinin üretimi ile tüketimi arasındaki dengenin sağlanmasına katkı sunmak amacı ile bu çalışma gerçekleştirilmiştir. Çalışmada güneş enerji santrallerinin üretim tahminlerinde kullanılan dört popüler derin öğrenme modeli olan Uzun Kısa Süreli Bellek (UKSB), Çok Katmanlı Algılayıcılar (ÇKA), Tekrarlayan Sinir Ağları (TSA) ve Kapı Kontrollü Tekrarlayan Birimler (KKTB) yöntemleri incelenmiş ve elde edilen sonuçlar neticesinde TSA ve KKTB modellerinin diğerlerine göre daha yüksek tahmin başarısı sergilediği tespit edilmiştir.

Anahtar Kelimeler: Çok katmanlı algılayıcılar, derin öğrenme, elektrik üretimi, güneş enerji santrali, kapı kontrollü tekrarlayan birimler, tekrarlayan sinir ağları, uzun kısa süreli bellek

ABSTRACT

MS THESIS

DEEP LEARNING FOR PRODUCTION PREDICTION IN SOLAR POWER PLANTS

Azime İrem KÖKSAL

**Konya Technical University
Institute of Graduate Studies
Department of Electrical and Electronics Engineering**

Advisor: Assoc. Prof. Rahime CEYLAN

2024, 43 Pages

Jury

Assoc. Prof. Dr. Rahime CEYLAN

Asst. Prof. Dr. Saim ERVURAL

Asst. Prof. Dr. Mücahid BARSTUĞAN

As industrial activities increase day by day, the population continuously grows, and the use of technological devices becomes more widespread, there is a consistent increase in energy consumption. Due to the impending depletion of fossil fuels and their negative effects on the environment, the demand for renewable energy sources is steadily increasing. This study has been conducted with the aim of contributing to the balance between the production and consumption of electrical energy in light of this increasing demand. The study examines four popular deep learning models used in production forecasts of solar power plants: Long Short-Term Memory (LSTM), Multilayer Perceptrons (MLP), Recurrent Neural Networks (RNN), and Gated Recurrent Units (GRU). The results indicate that the RNN and GRU models demonstrate higher prediction accuracy compared to the others.

Keywords: Multilayer Perceptrons, Deep Learning, Electricity Production, Solar Power Plant, Gated Recurrent Units, Recurrent Neural Networks, Long Short-Term Memory

ÖNSÖZ

Yüksek Lisans tez çalışmam süresince değerli bilgilerini ve yardımlarını esirgemeyen, yol gösteren danışmanım Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik-Elektronik Mühendisliği Bölümü Öğretim Üyesi Sn. Doç. Dr. Rahime CEYLAN 'a, sabırla bana bu süreçte destek çıkan ve yanımda olan eşim Numan KÖKSAL 'a, bu günlere gelmemde emek ve desteklerini hiçbir zaman esirgemeyen ve her zaman yanımda olan babam Alaattin SEZER 'e, annem Habibe SEZER 'e, abim Mustafa Serkan SEZER 'e ve ablam Nuriye SEZER 'e ve biricik yiğenim Ömer Ayberk SEZER'e teşekkürü borç bilirim.

Azime İrem KÖKSAL
KONYA-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
3. MATERYAL VE YÖNTEM.....	5
3.1 Yenilenebilir Enerji Kaynakları	5
3.1.1 Güneş enerjisi	5
3.1.1.1 Fotovoltaik sistemler.....	6
3.1.1.2 Konsantre güneş enerjisi sistemleri	7
3.1.2 Rüzgar enerjisi	7
3.1.3 Hidroelektrik enerjisi	8
3.1.4 Biyokütle enerjisi	8
3.1.5 Jeotermal enerji.....	9
3.1.6 Dalga ve gelgit enerjisi	9
3.2 Türkiye ‘nin Güneş Enerji Potansiyeli ve Hedefleri	10
3.3 Yapay Zeka	11
3.3.1 Makine öğrenmesi.....	12
3.3.1.1 Denetimsiz öğrenme	12
3.3.1.2 Denetimli öğrenme	13
3.3.1.2.1 Yapay sinir ağları.....	13
3.3.1.2.2 Derin öğrenme	14
a. Tekrarlayan Sinir Ağları	14
b. Uzun Kısa Süreli Bellek	16
c. Çok Katmanlı Algılayıcılar	17
d. Kapı Kontrollü Tekrarlayan Birimler	19
3.4 Performans Ölçütleri.....	20
3.4.1. Kök ortalama kare hatası	20
3.4.2. Regresyon toplam kareler	21
3.4.3. Belirleme katsayısı.....	21
3.5 Hiperparametreler	21
3.5.1. Veri setinin boyutu.....	22
3.5.2. Öğrenme oranı	22
3.5.3. Eğitim tur sayısı	23
3.5.4. Unutma oranı	23
3.6 Zaman Serilerinde Durağanlık Analizi	23
3.6.1. Artırılmış Dickey Fuller testi	23

3.7 Veri Seti	24
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	26
4.1. UKSB ile Elde Edilen Sonuçlar.....	26
4.2. ÇKA ile Elde Edilen Sonuçlar	29
4.3. TSA ile Elde Edilen Sonuçlar	31
4.4. KKTB ile Elde Edilen Sonuçlar.....	33
5. SONUÇLAR VE ÖNERİLER	36
5.1 Sonuçlar	36
5.2 Öneriler	37
KAYNAKLAR	39
EKLER	42



SİMGELER VE KISALTMALAR

Simgeler

y	:Tahmin edilen değer
t	:gerçek değer
n	:örüntü sayısı
μ	:ortalama

Kısaltmalar

ADF	:Artırılmış Dickey Fuller
BK	:Belirleme Katsayısı
ÇKA	:Çok Katmanlı Algılayıcılar
KKTb	:Kapı Kontrollü Tekrarlayan Birimler
KOKH	:Kök Ortalama Kare Hatası
RTK	:Regresyon Toplam Kareler
TSA	:Tekrarlayan Sinir Ağları
TTK	:Tüm Toplam Kareler
UKSB	:Uzun Kısa Süreli Bellek
YSA	:Yapay Sinir Ağları
DOK	:Değişken Otomatik Kodlayıcı
MOHO	:Mevsimsel Otoregresif Hareketli Ortalama
FV	:Fotovoltaik
FVGS	:Fotovoltaik Güç Sistemleri

1. GİRİŞ

Her geçen gün artan endüstriyel faaliyetler, teknolojik aletlerin kullanımının giderek yaygınlaşması ve sürekli artan nüfus enerji tüketiminde sürekli olarak bir artış meydana getirmektedir. Enerji tüketimindeki bu artışın büyük bir kısmı fosil yakıtlar ile karşılanmaktadır. Fakat fosil yakıtların hava kirliliği, küresel ısınma, iklimde değişikliklere neden olma gibi doğaya birçok olumsuz etkisi bulunmaktadır. Bu olumsuz etkilerden ve bu kaynakların da bir gün tükeneceğinden ötürü yenilenebilir enerji kaynaklarına yönelmek büyük önem arz etmektedir.

Elektrik enerjisinin elektrik üretimi ile tüketimi arasındaki dengeyi sağlamak ve artan enerji ihtiyacını karşılamak için geleceğe yönelik olarak planlanması, enerjideki dışa bağımlılığımız, küresel ısınma ve çevresel etkiler açısından çok önemlidir.

Enerjinin tasarruflu kullanılmasını sağlamak için önemli yöntemlerden biri de enerji talebini ve üretilen enerjiyi önceden tahmin edebilmektir. Ayrıca elektrik enerjisinin fiyatlandırmasını da kısa dönemli talep tahminleri etkilemektedir. Elektrik enerjisinin tahmininin doğruluk oranının yüksek olması enerji piyasasının verimli olmasını sağlamakla birlikte güç sistemlerinin dengeli olarak çalışması, frekans kontrolü ve enerjinin güvenliği açısından da son derece önem arz etmektedir.

Ülkemizin mevcut coğrafik konumu da göz önüne alındığında güneş enerji santralleri yenilenebilir enerji kaynakları arasında çok önemli bir konuma sahiptir. Artan enerji ihtiyacı ve yenilenebilir enerji kaynaklarıyla üretim santralleri kurulmasına verilen teşviklerle ülkemizde bulunan güneş enerji santralleri giderek artış göstermektedir. Giderek yaygınlaşan güneş enerji santrallerinin üretim tahminlerini gerçekleştirebilmekte bu sebeplerle çok önemli bir hale gelmektedir.

Bu çalışma güneş enerji santrallerinin enerji üretim performanslarının tahmin edilmesi üzerine yoğunlaşmaktadır. Güneş enerji santrallerinde enerji üretimini etkileyen faktörlerin doğru bir şekilde anlaşılması ve tahmin edilmesi, bu enerji kaynağının verimliliğini artırmak ve enerji yönetimi stratejilerini iyileştirmek için hayati öneme sahiptir. Bu bağlamda, yapay zeka ve özellikle derin öğrenme tekniklerinin uygulanması, güneş enerji üretiminin daha doğru ve etkin bir şekilde tahmin edilmesine imkan tanımaktadır. Bu tezde, güneş enerji santrallerinin üretim tahminlerinde kullanılan dört popüler derin öğrenme modeli olan Uzun Kısa Süreli Bellek (UKSB), Çok Katmanlı Algılayıcılar (ÇKA), Tekrarlayan Sinir Ağları (TSA) ve Kapı Kontrollü Tekrarlayan

Birimler (KKTB) incelenmekte ve bu modellerin tahmin başarısı karşılaştırmalı olarak değerlendirilmektedir.



2. KAYNAK ARAŞTIRMASI

Kıymaz (2020), 1 MW kapasiteli güneş enerji santrallerine ait günlük frekanslı iki yıllık üç veri seti ve saatlik frekanslı bir yıllık bir veri seti üzerinde değerlendirme yaparak derin öğrenme yöntemleri ile elektrik üretim analizi gerçekleştirmiştir. Bu çalışmada, Uzun Kısa Süreli Bellek (UKSB) ve Mevsimsel Otoregresif Hareketli Ortalama (MOHO) yöntemleri kullanılarak elektrik üretim analizi gerçekleştirilmiş ve UKSB' nin çoğu durumda daha iyi performans gösterdiği tespit edilmiştir. Bu analiz, derin öğrenme yöntemlerinin güneş enerjisi üretim tahminindeki potansiyelini ortaya koymakta ve diğer çalışmalar için bir temel oluşturmaktadır.

Dairi ve arkadaşları (2020) ise, güneş enerjisi üretiminin kısa vadeli tahminine odaklanmış ve Değişken Otomatik Kodlayıcı (DOK) modelinin kullanımını incelemiştir. Bu çalışma, Kıymaz'ın (2020) sonuçlarını genişleterek, derin öğrenme modellerinin farklı kapasitelerdeki fotovoltaik sistemlerde nasıl etkili olabileceğini göstermektedir. DOK' un esnek ve doğrusal olmayan yapısı sayesinde, tahmin doğruluğu artmış ve derin öğrenme yöntemlerinin bu alandaki üstünlüğü pekiştirilmiştir.

Konstantinou ve arkadaşları (2021) tarafından yapılan çalışma, Yığılmış Uzun Kısa Süreli Bellek Ağları'nın (Yığılmış UKSB) fotovoltaik güç çıkış tahminindeki etkinliğini değerlendirir. Bu çalışma, derin öğrenmenin daha karmaşık yapıları olan Yığılmış UKSB'nin de güneş enerjisi tahminlerinde başarılı olabileceğini göstermektedir. Kısa vadeli tahminler üzerine yoğunlaşarak, derin öğrenme yöntemlerinin zaman serisi verileri üzerindeki güçlü performansını vurgulamaktadır.

Çetin ve Işık (2022), bir enerji firmasına ait bir güneş enerji santralinden alınan verileri kullanarak, UKSB yöntemi ile gelecekteki enerji üretimini tahmin etmişlerdir. Bu çalışma, derin öğrenme yöntemlerinin farklı veri setleri ve çeşitli hata oranları aralıklarında nasıl uygulanabileceğini göstermektedir. Çalışmanın sonuçları, UKSB'nin güneş enerjisi tahmininde güçlü bir araç olabileceğini doğrulamaktadır.

Beigi ve arkadaşlarının (2022) çalışması, meteorolojik verileri kullanarak fotovoltaik güç sistemlerinin (FVGS) enerji çıktılarını tahmin etmeye yönelik yapay sinir ağları (YSA) ve tekrarlayan sinir ağları (TSA) mimarisinin potansiyelini değerlendirir. Araştırmada, FVGS'de enerji üretimini etkileyen önemli faktörler belirlenerek bir TSA modeli eğitilmiş ve bu model, eğitim setinde yer almayan veriler üzerinde test edilmiştir. Model, test verileri üzerinde 0.98 'lik bir regresyon değeri ile yüksek tahmin doğruluğu sergilemiş, örnek bir gün için ortalama kare hatası değeri 0.0248 MJ ve ortalama gerçek çıkış gücü 0.538 MJ olarak bulunmuştur. Bu sonuçlar, TSA'nın FVGS enerji çıktılarını

etkili bir şekilde tahmin edebileceğini göstermektedir ve enerji yönetimi ile planlamasında derin öğrenme tekniklerinin kullanımının önemini vurgulamaktadır

Akhter ve arkadaşlarının (2022) çalışması, polikristalin (p-si), monokristalin (m-si) ve ince film (a-si) teknolojilerine dayalı üç farklı fotovoltaik (FV) tesisi üzerine yoğunlaşmıştır. Bu çalışma, saatlik bazda yıllık güç tahminleri yaparak, rüzgar hızı, modül sıcaklığı, çevre koşulları ve güneş ışıması gibi girdi özelliklerini dikkate almıştır. Gelişmiş bir derin öğrenme metodu olan TSA-UKSB kullanılarak, çeşitli regresyon ve makine öğrenimi teknikleriyle karşılaştırmalı bir değerlendirme yapılmıştır. Bu değerlendirme, TSA-UKSB 'nin kök ortalama kare hatası, ortalama kare hatası, hareketli ortalama hatası, korelasyon (r) ve belirleme (R^2) katsayıları açısından diğer yöntemlere göre daha üstün tahmin doğruluğuna sahip olduğunu göstermiştir. Bu sonuçlar, farklı FV teknolojileri için güç çıkışının tahmininde derin öğrenme metodolojilerinin etkinliğini vurgulamaktadır.

Son olarak, Gün (2023) tarafından yapılan çalışma, güneş enerjisi tahmininde kullanılan yenilikçi ayırıştırma modellerinin ve hibrit modellerin etkinliğini incelemektedir. CEEMDAN-Kernel-ELM yaklaşımının, konvansiyonel ve derin öğrenme tabanlı modellere göre daha iyi sonuçlar verdiği bulunmuştur. Bu çalışma, derin öğrenme ve hibrit modellerin güneş enerjisi tahminindeki potansiyelini göstererek, bu alanda yapılan araştırmaların nasıl gelişebileceğini ortaya koyar.

Gerçekleştirilen kaynak araştırmalarında, derin öğrenme modellerinin güneş enerjisi tahminlerindeki başarısı ve potansiyeli ortaya koyulmuş olup, farklı veri setleri, hata oranları ve enerji çıktıları üzerine odaklanılmıştır. Bu çalışma ise literatüre, özellikle UKSB ve KKTB modellerinin kapsamlı bir şekilde incelenmesiyle ve bu modellerin güneş enerjisi üretim tahminlerinde diğer derin öğrenme yöntemlerine göre üstünlüğünün detaylı bir analiziyle katkıda bulunmaktadır. Bu bakış açısıyla çalışma, güneş enerjisi üretim tahminleri konusunda literatüre önemli bir katkı sağlamakta ve bu alanda gelecekteki araştırmalara yol gösterici olabilmektedir.

3. MATERYAL VE YÖNTEM

3.1 Yenilenebilir Enerji Kaynakları

Yenilenebilir enerji kaynakları, doğal süreçlerin sürekli yenilenmesi ile tükenmeyen ve çevre üzerinde minimal etkiye sahip olan enerji formudur. Kullanılan fosil yakıtların birçoğunda yakın gelecekte rezerv problemi yaşanacağından dünya ülkeleri alternatif enerji arayışlarına yönelmiş ve yenilenebilir enerji kaynakları bir çok ülkenin gündemine girmiştir (Ürün ve Soyu,2016). Yenilenebilir enerji kaynakları, sürdürülebilirliğinin yanında dünyanın her ülkesinde bulunabilmesiyle de çok önemlidir (Kumbur ve Ark.,2005). Yenilenebilir enerjinin geniş çapta kullanımı, enerji güvenliğini artırır, enerji maliyetlerini düşürür. Güneş enerjisi, rüzgâr enerjisi, hidroelektrik enerji, biyokütle enerjisi, jeotermal enerji, dalga ve gelgit enerjisi başlıca yenilenebilir enerji kaynaklarıdır.

3.1.1 Güneş enerjisi

Güneş enerjisi, Güneş'ten yayılan ışık ve ısı enerjisini kullanarak elektrik üretimi yapılabilen sürdürülebilir ve temiz bir enerji kaynağıdır. Güneş enerjisi teknolojileri, esas olarak fotovoltaik sistemler ve konsantre güneş enerjisi sistemleri olmak üzere iki ana kategoride incelenebilir. Güneş enerjisinden doğrudan elektrik üretiminde fotovoltaik paneller kullanılmakta ve fotovoltaik hücreler ile güneş ışınları doğrudan elektrik enerjisine çevrilmektedir (Yolcan ve Köse, 2020). Konsantre güneş enerjisi sistemleri ise güneş ışığını bir noktada toplayarak yüksek sıcaklıklara ulaşır ve bu enerjiyi bir ısı değiştirici aracılığıyla elektrik üretmek için kullanır.

Güneş enerjisi ile elektrik üretimi, karbon emisyonu olmadan, yenilenebilir ve temiz bir enerji kaynağı sağlar. Bu, küresel ısınma ve iklim değişikliğiyle mücadelede önemli bir avantaj sağlar. Ayrıca, güneş enerjisi kaynakları geniş bir coğrafi dağılıma sahiptir, bu da onu enerji güvenliğini artırma potansiyeline sahip kılar ve enerji ithalatına bağımlılığı azaltabilir.

Güneş enerjisinin kolay kullanılabilir olması, potansiyeli, hijyeni, yenilenebilir ve çevre dostu olduğundan diğer yenilenebilir enerji kaynaklarına göre daha kolay yaygınlaşacak haldedir (Taktak ve Ilı, 2018). Güneş enerjisi sistemlerinin yaygınlaştırılması, enerji üretiminde fosil yakıtlara olan bağımlılığı azaltabilir ve uzun vadede enerji maliyetlerini düşürebilir. Ancak, bu teknolojilerin yaygınlaşmasının önünde bazı zorluklar bulunmaktadır. Güneş enerjisi üretimi, güneş ışığının varlığına bağlı olduğu için, geceleyin veya bulutlu havalarda enerji depolama sistemlerine ihtiyaç duyar. Bu nedenle, güneş enerjisi sistemlerinin etkin bir şekilde entegre edilmesi için

gelişmiş enerji depolama çözümleri ve akıllı şebeke teknolojilerine yatırım yapılması gerekmektedir.

3.1.1.1 Fotovoltaik sistemler

Fotovoltaik sistemler, güneşten gelen ışığın enerjisini kullanarak elektrik üretmek için tasarlanmış sistemlerdir. Bu sistemler, temel olarak fotovoltaik hücrelerden oluşan güneş panellerini, inverterleri, kablo ve bağlantı elemanları gibi bileşenleri içerir. Fotovoltaik sistemlerin temel işlevi, güneş ışığını yakalayıp onu elektrik enerjisine dönüştürmek ve bu enerjiyi çeşitli uygulamalar için kullanılabilir hale getirmektir (Adak ve Ark., 2019).

Fotovoltaik sistemlerin temel bileşeni, fotovoltaik hücrelerdir. Bu hücreler genellikle silikon gibi yarı iletken malzemelerden yapılmıştır. Güneş ışığı, fotovoltaik hücreye çarptığında, ışığın enerjisi elektronları harekete geçirir ve bu elektrik akımının oluşmasına yol açar. Bu elektron hareketi, hücreler arası bağlantılar yardımıyla yönetilir ve böylece kullanılabilir elektrik enerjisi elde edilir. Birden fazla fotovoltaik hücre bir araya gelerek bir güneş paneli oluşturur ve bu paneller bir sistemde seri veya paralel bağlanabilir (Sayın ve Koç , 2011).

Fotovoltaik sistemlerde üretilen elektrik genellikle doğru akım formundadır. Ancak, evlerde ve iş yerlerinde kullanılan elektrik alternatif akım formundadır. İnverterler, doğru akımı alternatif akıma çeviren cihazlardır Böylece güneş enerjisi ile üretilen elektrik, elektrik şebekesine dahil edilebilir veya doğrudan tüketim için kullanılabilir hale gelir.

Güneş panellerinin doğru bir şekilde yerleştirilmesi ve maksimum verimlilikle güneş ışığından faydalanabilmesi için montaj sistemlerine ihtiyaç vardır. Bu sistemler, panellerin çatılara, arazilere veya diğer uygun yüzeylere güvenli bir şekilde monte edilmesini sağlar. Kablo ve bağlantı elemanları ise elektrik akımının güvenli bir şekilde taşınmasını ve sistemin diğer bileşenleriyle etkili bir şekilde iletişim kurmasını sağlar.

Güneş ışığının kesintisiz olmaması nedeniyle, fotovoltaik sistemler genellikle enerji depolama birimleri ile birlikte kullanılır. Bu, genellikle bataryalar ve şarj kontrol cihazları aracılığıyla yapılır. Şarj kontrol cihazları, bataryaların aşırı şarj olmasını veya aşırı deşarj olmasını önleyerek ömrünü uzatır. Bataryalar ise güneş ışığının olmadığı zamanlarda, örneğin gece veya bulutlu havalarda, depolanan enerjinin kullanılmasını sağlar. Bataryaların taşınabilirliği ve sisteme entegrasyonunun kolaylığı nedeniyle kullanımları yaygın olarak görülmektedir (Ak ve Usta, 2022).

Fotovoltaik sistemler, konutlardan büyük ölçekli güneş enerjisi santrallerine kadar geniş bir uygulama yelpazesine sahiptir. Bu sistemler, enerji ihtiyacının sürdürülebilir bir şekilde karşılanmasına yardımcı olur.

Devlet destekleri ve mevzuatla ilgili uygulamalar sayesinde gün geçtikçe fotovoltaik sistemler gelişmekte ve yaygınlaşmaktadır. Böylece günümüzde ve gelecekte de enerji üretiminde önemli bir role sahiptir.

3.1.1.2 Konsantre güneş enerjisi sistemleri

Konsantre Güneş Enerjisi sistemleri güneş ışığını, büyük aynalar veya mercekler yardımıyla bir noktada toplayarak yüksek sıcaklıklara ulaşan ve bu sıcaklığı kullanarak elektrik üretimi gerçekleştiren yenilenebilir enerji teknolojileridir. Bu sistemler, güneş enerjisini yoğunlaştırmak için tasarlanmıştır ve toplanan ısı enerjisini bir ısı transfer sıvısı aracılığıyla buhar türbinleri veya diğer jeneratör sistemlerine aktararak elektrik üretirler (Cengiz ve Mamiş, 2016). Konsantre güneş enerjisi sistemlerinin temel bileşenleri ise kolektörler, ısı transfer sıvısı, enerji depolama sistemi ve buhar türbinidir.

Güneş ışığını toplamak ve yoğunlaştırmak için kullanılan aynalara veya merceklerle kolektör ismi verilir. Bu kolektörler parabolik oluklar, kuleler, parabolik çanaklar veya frensel mercekler şeklinde olmaktadır (Hengirmen, 2018). Toplanan ısı enerjisini, enerji depolama sistemi veya buhar jeneratörüne aktaran sıvıya ısı transfer sıvısı denmektedir. Genellikle tuz eriyikleri, su veya yağ kullanılmaktadır. Buhar jeneratörü ve türbin ise ısı enerjisini mekanik enerjiye sonrasında ise elektrik enerjisine dönüştüren sistemlerdir. Üretilen enerji, enerji depolama sistemleri ile depolanarak güneş ışığının olmadığı zamanlarda da enerji üretimine olanak sağlar.

3.1.2 Rüzgar enerjisi

Rüzgar enerjisi, rüzgarın kinetik enerjisini kullanarak elektrik üretimi yapılabilen yenilenebilir bir enerji kaynağıdır. Rüzgar türbinleri adı verilen büyük fanlar aracılığıyla, rüzgarın kinetik enerjisi önce mekanik enerjiye, ardından da jeneratörler yardımıyla elektrik enerjisine dönüştürülür. Bu süreç, fosil yakıtların kullanımına göre çevreye çok daha az zarar verir çünkü rüzgar enerjisi, sera gazı emisyonu üretmez ve hava kalitesini bozacak kirleticiler yaymaz. Rüzgar enerjisi, sürdürülebilir bir enerji kaynağı olarak değerlidir çünkü rüzgar, tükenmez ve sürekli yenilenebilir bir kaynaktır. Rüzgar enerjisi projeleri, genellikle rüzgarın hızının yüksek olduğu açık arazilerde, dağlık alanlarda veya kıyı şeritlerinde kurulur. Rüzgar enerjisinin kullanımı, enerji üretimindeki karbon ayak

izini azaltmaya, enerji güvenliğini artırmaya ve fosil yakıt bağımlılığını azaltmaya yardımcı olur, aynı zamanda yenilenebilir enerji teknolojilerinin gelişimini teşvik eder. Ayrıca kurulum aşamasında yüksek sermaye ve teknoloji gerektiren rüzgar enerjisi, işletme aşamasında hammadde gerektirmez, bu nedenle maliyeti düşük bir enerji kaynağıdır (Aydın, 2013).

3.1.3 Hidroelektrik enerji

Hidroelektrik enerji, suyun potansiyel enerjisini kullanarak elektrik üretmek için bir yöntemdir. Bu enerji üretim süreci genellikle büyük bir barajın inşasıyla başlar. Baraj, nehir üzerinde bir su rezervuarı oluşturarak suyun akışını kontrol altına alır. Su, cebri borular veya tüneller aracılığı ile türbine doğru hareket ettirilir ve suyun kinetik enerjisi türbinler ile mekanik enerjiye dönüştürülür. Türbinlerin dönüş hareketi, onlara bağlı jeneratörler aracılığıyla elektrik enerjisine çevrilir (Şekkel ve Keçecioğlu, 2011). Hidroelektrik enerji santralleri, yenilenebilir enerji kaynakları arasında önemli bir yere sahiptir çünkü su, tükenmez bir kaynaktır ve bu tür santraller, çalıştırdıktan sonra sera gazı veya zararlı emisyonlar üretmez. Ayrıca, hidroelektrik enerji santralleri, elektrik üretiminde yüksek verimlilik oranlarına sahip olabilir ve elektrik üretimindeki talep dalgalanmalarına hızlı bir şekilde yanıt verebilirler. Bu da onları elektrik şebekesi için değerli bir kaynak yapar.

3.1.4 Biyokütle enerjisi

Biyokütle enerjisi, organik malzemelerin yakılması, gazlaştırılması, fermentasyonu veya diğer işlemler aracılığıyla enerji üretmek için kullanılmasını ifade eder. Biyokütle enerjisini klasik ve modern anlamda olmak üzere iki grupta ele alabiliriz. Birincisi, konvansiyonel ormanlardan elde edilen yakacak odun ve yine yakacak olarak kullanılan bitki ve hayvan atıklarından oluşur. İkicisi yani modern biyokütle enerjisi ise, enerji ormancılığı ve orman-ağaç endüstrisi atıkları, tarım kesimindeki bitkisel atıklar, kentsel atıklar ve tarıma dayalı endüstri atıkları olarak sıralanmaktadır (Kaplukan, 2014).

Biyokütle enerjisinin avantajları arasında yenilenebilir oluşu, atık malzemelerin değerlendirilmesi ve fosil yakıt kullanımının azaltılması yer alır. Ancak, sürdürülebilir biyokütle enerjisi üretimi, doğal kaynakların aşırı tüketimine ve biyolojik çeşitliliğin azalmasına yol açmamalıdır. Ayrıca, biyokütle yakma işlemleri sırasında partikül madde ve diğer hava kirleticilerin emisyonlarının kontrol altına alınması gerekmektedir. Bu

nedenle, biyokütle enerjisi projelerinin çevresel ve sosyal etkileri dikkatlice değerlendirilmelidir.

3.1.5 Jeotermal enerji

Jeotermal enerji, Dünya'nın iç kısımlarından kaynaklanan doğal ısı enerjisini ifade eder. Bu enerji, yer kabuğunun altındaki sıcak su ve buharın, jeotermal kuyular aracılığıyla yüzeye çıkarılması ve bu enerjinin elektrik üretimi, ısıtma ve soğutma gibi çeşitli uygulamalar için kullanılmasıyla elde edilir. Jeotermal enerjinin temel kaynağı, Dünya'nın çekirdeğindeki radyoaktif bozunma süreçleridir. Bu süreçler sonucu üretilen ısı, magma hareketleri ve diğer jeolojik aktiviteler aracılığıyla yer kabuğuna iletilir. Jeotermal enerji santralleri, genellikle yer kabuğunun sıcaklığının yüksek olduğu volkanik aktivitenin yoğun olduğu alanlar, sıcak kayaç bölgeleri veya sıcak su rezervuarları gibi jeotermal aktivitenin yüksek olduğu bölgelerde kurulur.

Jeotermal enerjinin en büyük avantajları ihtiyaç duyulması halinde birden fazla amaca hizmet verir, yer altı kaynaklarının rezervuarlardan sürekli beslenmesinden dolayı kendi kendini yenileme özelliğine sahiptir. Ayrıca mevcut diğer enerji kaynaklarına göre doğal ve yerli bir kaynak olmasından dolayı daha ekonomiktir. Hava olaylarından ve mevsimlerden etkilenmediğinden elektrik üretiminde yıl içinde dalgalanma yaşanmasına sebebiyet vermez (Doğan, 2019).

3.1.6 Dalga ve gelgit enerjisi

Dalga ve gelgit enerjisi, okyanus ve denizlerdeki doğal hareketlerden elde edilen yenilenebilir enerji türleridir. Bu enerji kaynakları, suyun kinetik ve potansiyel enerjisini elektrik enerjisine dönüştürmek için kullanılır. Her iki enerji formu da sürdürülebilir ve çevre dostudur. Çünkü enerji üretimi sırasında karbon emisyonu ya da zararlı atıklar üretmezler.


Dalga enerjisi, rüzgarın okyanus yüzeyi üzerinde yarattığı dalgaların enerjisini kullanır. Dalgalar, rüzgarın gücüyle suyun hareketinden kaynaklanır ve bu hareket enerjisi, dalga enerjisi dönüştürücüleri aracılığıyla elektrik enerjisine çevrilebilir. Dalga enerjisi dönüştürücüleri, yüzen veya deniz tabanına monte edilen cihazlar olabilir ve dalgaların yükselip alçalmasını veya ileri geri hareketini mekanik enerjiye, sonrasında ise elektrik enerjisine dönüştürürler. Yenilenebilir enerji portföyünde önemli bir potansiyele sahiptir ve özellikle kıyı bölgelerinde enerji üretimi için cazip seçenekler sunar.

Gelgit enerjisi, Ay ve Güneş'in Dünya üzerindeki yer çekimi etkileri sonucu oluşan gelgit hareketlerinden faydalanır. Bu enerji türü, yüksek ve alçak gelgit arasındaki su seviyesi farkından yararlanarak enerji üretir. Gelgit enerjisi santralleri genellikle bir baraj (gelgit barajı) kullanarak, gelgitler sırasında suyun biriktiği ve boşaldığı bölgeler arasında su akışını kontrol eder. Bu su akışı, türbinleri döndürerek elektrik üretir. Gel-git enerjisinden, bu fiziksel olayın çok belirgin olduğu okyanus kıyılarında yararlanılabileceği için, bu enerjinin Türkiye açısından önemi yoktur. Ancak, Marmara Denizi dışında kıyı uzunluğu yaklaşık 8 200 km'yi bulan ülkemiz için, dalga enerjisinin önemli bir potansiyel oluşturduğu da yadsınamaz bir gerçektir (Örer ve Ark. 2003).

3.2 Türkiye'nin Güneş Enerji Potansiyeli ve Hedefleri

Türkiye, stratejik coğrafi konumu ve geniş güneşlenme süresi sayesinde yüksek güneş enerjisi potansiyeline sahip bir ülkedir. Kuzeyden güneye uzanan geniş coğrafyası, farklı iklim özellikleri ve yılın büyük bir bölümünde güneşli günlerin bulunması, Türkiye'yi güneş enerjisi üretimi için ideal bir yer haline getirir.

Güneş enerjisi alanında gerçekleştirilen çalışmaları desteklemek ve daha verimli bir şekilde güneş enerjisinden yararlanmak için Yenilenebilir Enerji Müdürlüğü tarafından Türkiye Güneş Enerjisi Atlası (TGEA) oluşturulmuştur (Şekil 3.1).



Şekil 3.1 Türkiye Güneş Enerji Atlası (TGEA)

Türkiye Güneş Enerji Atlası'na göre günlük güneşlenme süresi değerinin ortalama 7.5 saat olduğu tespit edilmektedir. TGEA 'ya göre güneydoğunun uç noktası ile güney

batının uç noktaları arasında kalan güney bölgesinde diğer bölgelerimize göre daha fazla güneş ışınımının geldiği görülmektedir.

Türkiye'nin yenilenebilir enerjiye verdiği önem giderek artmaktadır. Bu kapsamda da güneş enerjisine yapılan yatırımlar hız kazanmaktadır. Son yıllarda hem kamu hem de özel sektör tarafından güneş enerji santralleri kurulumu için önemli adımlar atılmış ve bu kapsamda çeşitli teşvikler ve destek programları sunulmuştur.

Enerji Piyasası Düzenleme Kurumu'nun 2024-Ocak dönemine ait yayınlamış olduğu Çizelge 3.1'de bulunan Sektör Raporu'nda enerji ihtiyacımızın %51.76'sının yenilenebilir enerji kaynaklarından karşılandığı açıklanmıştır. Bu oranın %2.84'ü ise güneş enerjisine aittir.

Çizelge 3.1 Enerji Piyasası Düzenleme Kurumu 'nun 2024 – Ocak Dönemine ait Elektrik Piyasası Sektör Raporu

KAYNAK TÜRÜ	TOPLAM KURULU GÜÇ* (MW)				TOPLAM ÜRETİM* (MWh)			
	2023 OCAK	ORAN (%)	2024 OCAK	ORAN (%)	2023 OCAK	ORAN (%)	2024 OCAK	ORAN (%)
HİDROLİK	31.571,02	30,35	31.974,12	29,81	2.950.643,98	10,95	8.346.492,79	28,56
RÜZGÂR	11.397,82	10,96	11.885,90	11,08	2.701.554,86	10,02	4.033.149,25	13,8
GÜNEŞ	9.596,29	9,22	11.838,39	11,04	876.008,06	3,25	831.198,35	2,84
BİYOKÜTLE	1.951,10	1,88	2.078,08	1,94	841.161,60	3,12	870.639,35	2,98
JEOTERMAL	1.691,34	1,63	1.691,34	1,58	1.027.256,32	3,81	1.043.131,10	3,57
YENİLENEBİLİR	56.207,56	54,03	59.467,82	55,44	8.396.624,82	31,15	15.124.610,83	51,76

Güneş enerjisi teknolojilerindeki yenilikler, enerji verimliliğini artırarak maliyetleri düşürmektedir. Fotovoltaik paneller ve konsantre güneş enerjisi teknolojileri güneş enerjisinden elektrik üretiminde verimliliği maksimuma çıkarırken enerji depolama çözümleri, üretilen enerjinin güneşin olmadığı veya talebin çok olduğu zamanlarda kullanılabilmesini mümkün kılmaktadır. Bu teknolojik ilerlemeler, Türkiye'nin güneş enerjisi potansiyelinden daha etkin bir şekilde yararlanmasına olanak sağlamaktadır.

3.3 Yapay Zeka

Yapay zeka, bilgisayar sistemi ile oluşturulan robotların bir insan gibi düşünmesini ve hareket etmesini sağlamak amacı ile oluşturulmuş teknolojidir (Sucu, 2019). Yapay zekanın ana hedefi, insan zekasının işlevselliğini ve işleyişini anlamak ve

bu anlayışı, insanların yerine getirebileceği görevleri otomatize edebilecek akıllı sistemlerin geliştirilmesine uygulamaktır.

3.3.1 Makine öğrenmesi

Makine öğrenmesi, yapay zeka alanının temel bir bileşenidir ve bilgisayarların, veriden öğrenme yeteneğine odaklanır.

Makine öğrenme teknikleri, öğrenme görevindeki farklılıklardan bağımsız olarak, çoğu zaman insanların varoluşundan beri biriktirdiği bilgi ve deneyime dayanarak doğayı taklit etmeye çalışır (Aylak ve Ark., 2020). Makine öğrenmesi, günümüz teknolojisinde giderek artan bir öneme sahip olmuş ve çeşitli endüstrilerde uygulanmıştır.

Makine öğrenmesi, günümüzde bilgi çağının temel taşlarından biri haline gelmiştir. Bu teknoloji, iş süreçlerini otomatize etmekten kişiselleştirilmiş kullanıcı deneyimleri sunmaya kadar geniş bir yelpazede değer katmaktadır. Ancak, bu potansiyelin sorumlu bir şekilde kullanılması ve karşılaşılan zorlukların üstesinden gelinmesi gerekmektedir. Makine öğrenmesi, hem teknik hem de etik açıdan sürekli bir gelişim ve adaptasyon gerektiren dinamik bir alan olarak kalmaya devam edecektir.

3.3.1.1 Denetimsiz öğrenme

Denetimsiz öğrenme makine öğrenmesinin temel bir alt dalı olup, etiketlenmemiş veriler üzerinden öğrenme sürecini ifade eder (Aylak ve Ark., 2021). Bu yaklaşımda, algoritmalar verilen girdi setinden hiçbir dış müdahale veya yönlendirme olmadan yapısal özellikleri, desenleri veya ilişkileri otomatik olarak keşfetmeye çalışır. Denetimsiz öğrenme, veri keşfi, veri sınıflandırması ve örüntü tanıma gibi çeşitli görevlerde uygulama bulmuş olup, veri bilimi ve yapay zeka alanlarında önemli bir yere sahiptir.

Denetimsiz öğrenmenin ana hedefi, etiketlenmemiş veri kümelerindeki gizli yapıları veya desenleri bulmaktır. Bu süreç, herhangi bir etiket veya sınıflandırma bilgisi olmaksızın, veri içerisindeki ilişkileri ve düzenlilikleri otomatik olarak keşfetmeye dayanır. Denetimsiz öğrenme, verileri anlamlandırma ve veri içindeki bilinmeyen yapıları ortaya çıkarma yeteneği sayesinde, büyük ve karmaşık veri setleri üzerinde derinlemesine analiz yapılmasını sağlar.

3.3.1.2 Denetimli öğrenme

Denetimli öğrenme makine öğrenmesinin en yaygın kullanılan alt dallarından biridir ve algoritmaların etiketlenmiş eğitim verileri kullanarak bir girdi ile çıktı

arasındaki ilişkiyi öğrenmesine dayanır. Oluşturulan model, girdi değerine karşılık verilen hedef değerleri arasındaki ilişkiyi öğrenerek verilen hedef değerlerine en yakın çıktıyı sunabilecektir (Aylak ve Ark., 2021).

Denetimli öğrenmede, modelin öğrenme süreci, modeli eğitmek için kullanılan ve her biri için doğru çıktıya sahip olan etiketlenmiş veri setleri tarafından yönlendirilir. Model, girdi verileri ile bu etiketler arasındaki ilişkiyi öğrenmek için eğitilir ve bu öğrenme, modelin yeni, görülmemiş veriler üzerinde doğru tahminler yapabilmesini sağlar.

3.3.1.2.1 Yapay sinir ağları

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilmesi ve keşfetmesi gibi yetenekleri herhangi bir yardım olmadan gerçekleştiren bilgisayar sistemidir (Karakoyun ve Hacıbeyoğlu, 2014). Bu sistemler, çok sayıda birbirine bağlı işlem birimlerinden oluşur ve karmaşık desenleri tanıma, veri sınıflandırma, tahmin yapma ve karar verme gibi görevleri yerine getirebilir. Yapay sinir ağları, özellikle makine öğrenimi ve derin öğrenme alanlarında önemli bir yere sahiptir ve günümüzde birçok farklı uygulamada kullanılmaktadır.

Yapay sinir ağlarının temelinde, insan beyninin sinir hücreleri (nöronlar) arasındaki etkileşimlerden ilham alınmış bir model vardır. Her bir yapay nöron, girdi sinyallerini alır, bu sinyaller üzerinde işlem yapar ve bir çıktı üretir. Bu nöronlar birbiriyle ağırlıklar aracılığıyla bağlantılıdır ve bu ağırlıklar, öğrenme süreci boyunca sürekli olarak güncellenir.

Tek tabaka veya tek eleman içeren bazı başarılı ağlar oluşturulabilmesine rağmen çoğunlukla en az üç tabaka (girdi katmanı, gizli katmanlar ve çıkış katmanı) içeren ağlara ihtiyaç duymaktadır (Ataseven, 2013).

1- Giriş katmanı: Dış dünyadan veri alan ve sisteme ileten katmandır.

2-Gizli Katmanlar: Giriş katmanından alınan verileri işleyen ve birbirine karmaşık bağlantılarla bağlı olan bir veya daha fazla katmandır. Derin öğrenme, bu gizli katmanların sayısının ve karmaşıklığının artırılması ilkesine dayanır.

3- Çıkış katmanı: işlenmiş veriyi sonuç olarak dışarıya veren katmandır.

3.3.1.2.2 Derin öğrenme


Derin öğrenme, makine öğrenmesinin alt dallarından biridir. Bir ya da daha fazla girdisi olan, içerisinde çok sayıda katman bulunan ve en son bir ya da daha fazla çıktısı

olan bir algoritmadır. Her katmanda kendisinden önceki bilgileri birleştirir ve bunlardan kompleks ve anlamlı sonuçları olan değerler üretir. Bu yönüyle diğer sinir ağları algoritmalarından daha tutarlı ve güçlüdür (Arslankaya ve Toprak, 2021). Derin öğrenme modelleri, görüntü ve ses tanıma, doğal dil işleme, otonom araçlar ve çok daha fazlası gibi birçok alanda devrim yaratmıştır.

Derin öğrenme, insan beyninin bilgi işleme şeklini modelleyen yapay sinir ağlarından ilham alır. Yapay sinir ağları, birbiriyle bağlantılı nöronlar (yapay nöronlar) ağıdır ve bu nöronlar, veriden özellikler çıkararak karmaşık işlevleri modelleyebilir. Derin öğrenmede, "derinlik" terimi, ağına içerdiği katman sayısına atıfta bulunur. Çok sayıda gizli katman içeren yapay sinir ağları, veriyi daha derinlemesine işleyebilir ve basit özelliklerden karmaşık özelliklere kadar çeşitli soyutlamalar yapabilir.

a. Tekrarlayan Sinir Ağları (Recurrent Neural Network)

Tekrarlayan Sinir Ağları (TSA), giriş dizilerini işlemek için kullanılan sinir ağlarıdır. Bilgilerin tutulmasına izin veren ağlar içlerinde mevcuttur (Yavuz, 2020). TSA (Şekil 3.2) öğrenme sürecinde eğitim verilerini kullanan temel bir yöntemdir. Bu eğitim verileri, ağına belirli görevler üzerinde nasıl performans göstermesi gerektiğini öğrenmesini sağlar. TSA'ların diğer derin öğrenme yöntemleri arasında öne çıkan en önemli özelliği, geçmiş bilgileri hatırlama kapasitesidir. TSA her bir adım işleminin önceki çıktıya bağlanarak çalıştığı bir mimariye sahiptir (Somuncu ve Atasoy , 2022). Bu yetenek, TSA'ların, özellikle dil işleme, konuşma tanıma ve zaman serisi tahmini gibi alanlarda, sıralı ve zamanla ilişkili veriler üzerinde mükemmel performans göstermelerine olanak tanır. Çıktılarının, giriş dizisindeki önceki öğelerle doğrudan bir bağlantıya sahip olması, bu ağların karmaşık sıralı bağlamları modelleyebilmesinin ve uzun süreli bağımlılıkları öğrenebilmesinin anahtarıdır. Bu, TSA'ların, sadece mevcut girdiye değil, aynı zamanda geçmişteki olayların birikimine de duyarlı olmasını sağlayarak, daha zengin ve bağlamsal olarak ilgili çıktılar üretmesine imkân verir.




Şekil 3.2 Tekrarlayan Sinir Ağlarının (TSA) çeşitli yapıları

TSA 'ların hesaplaması Eşitlik (1) ve (2) 'deki gibi gerçekleştirilmektedir. Eşitlik (1)' de ifade edilen ht gizli durumu, x_t girdiyi, W_h gizli durum ağırlıklarını, W_x girdi ağırlıklarını ve b ağırlık (bias) vektörünü ifade ederek gizli durum güncellemesini gerçekleştirir (Şekil 3.3).

$$ht = \tanh(W_h \cdot h_{t-1} + W_x \cdot x_t + b) \quad (1)$$

$$yt = W_y \cdot h_y + b_y \quad (2)$$


Çıktı hesaplama ise (2)'de belirtildiği şekilde hesaplanır. Burada yt çıktıyı, W_y çıktı ağırlıklarını ve b_y ise çıktı için ağırlık (bias) vektörünü ifade eder.



Şekil 3.3 Tekrarlayan Sinir Ağlarının (TSA) İşleyişi

b. Uzun Kısa Süreli Bellek (Long Short-Term Memory)

Uzun Kısa Süreli Bellek (UKSB) uzun süreli bağımlılıkları öğrenebilen özel bir tekrarlayan sinir ağıdır. UKSB 'ler (Şekil 3.4) TSA 'ların geliştirilmiş halidir. UKSB, geri besleme mantığıyla çalışmaktadır (Çetin ve Ark. ,2022).



Şekil 3.4 Uzun Kısa Süreli Bellek Mimarisi (Kara, 2019)

UKSB mimarisi Şekil 3.4 'de gösterildiği üzere üç temel katmandan oluşur: Unutma, girdi ve çıkış katmanları. Unutma katmanı, ağıın önceki durumlarından hangi bilgilerin korunup hangilerinin atılacağını belirler (Gürlek ve Bilgili, 2023). Bu, belleğin gereksiz bilgilerden arındırılmasını sağlar, böylece modelin verimliliği artar ve sadece önemli bilgiler korunur.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

Eşitlik (3) 'de belirtilen f_t unutma kapısının aktivasyon vektörü, σ fonksiyonu sigmoid fonksiyonu, W_f unutma kapısı ağırlıklarını, h_{t-1} önceki hücre çıktısını, x_t mevcut girdi ve b_f unutma fonksiyon kapısı bias vektörüdür.

Girdi katmanı ise, mevcut girdinin bellekte saklanıp saklanmayacağını ve nasıl saklanacağını kararlaştırır. Bu işlem, UKSB' nin hangi bilginin önemli olduğunu ve uzun vadeli bağlamlarda nasıl kullanılacağını öğrenmesine yardımcı olur.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5)$$

Eşitlik (4)'de bulunan $\hat{I}_t$ giriş kapısının aktivasyon vektörünü, (5) ise hücre durumu için aday vektörünü ifade etmektedir. Bu eşitliklerde sırası ile W_i giriş kapısının ağırlıklarını W_c ise aday hücre durumu ağırlıklarını ifade ederken, b_i ve b_c ise ilgili ağırlık (bias) vektörlerini ifade eder.

Hücre içindeki bilgiyi taşıyan ve zaman içinde ilerlerken bu bilgiyi güncelleyen ve modelin bir nevi belleği olarak işlev gören hücre durumunun hesaplanması ise (6) 'da gösterilmektedir. Buradaki C_t güncellenmiş hücre durumunu ifade ederken C_{t-1} ise önceki durumu ifade eder.

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (6)$$

Son katman olan çıkış katmanı ise hangi bilgilerin sonuç olarak üretileceğine karar verir; bu da modelin, mevcut duruma ve önceki öğrenilmiş bağlamlara bağlı olarak hangi bilgilerin önemli olduğunu belirlemesine olanak tanır ve (7) 'deki gibi hesaplanır. Burada O_t çıkış katmanını, h_t hücre çıktısını, W_o ise çıkış katmanı ağırlıklarını ifade ederken b_o ise çıkış katmanı ağırlık (bias) vektörüdür.

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (8)$$

Bu katmanların bir araya gelmesiyle, UKSB modeli hem kısa vadeli hem de uzun vadeli bağımlılıkları etkili bir şekilde öğrenebilir ve işleyebilir. Bu yapı, dil modelleme, metin üretimi, konuşma tanıma ve daha pek çok karmaşık görevde başarılı bir şekilde kullanılmıştır. UKSB'nin bu özellikleri, onu zamanla değişen sıralı verileri modellemek için son derece uygun bir seçenek haline getirir. Çünkü hem geçmiş bilgileri koruyabilir hem de yeni bilgilerle güncellenebilir. Bu sayede zaman içinde dinamik bir öğrenme ve adaptasyon sağlar.

c. Çok Katmanlı Algılayıcılar (Multi Layer Perceptron)

Çok Katmanlı Algılayıcılar (ÇKA), basit bir yapıya sahip sık kullanılan geleneksel ileri beslemeli yapay sinir ağları arasında çok popülerdir. Tek katmanlı algılayıcılarla doğrusal olaylar tahmin edilebilirken, ÇKA ile doğrusal olmayan olayların tahmini de yapılabilir (Gün, 2023). Çok Katmanlı Algılayıcılar, Şekil 3.5'te gösterildiği gibi üç ana katmandan oluşur: Giriş katmanı, bir veya daha fazla gizli katman ve çıkış katmanı. Giriş katmanı, modele dışarıdan sağlanan verileri alır ve bu verileri ağırlıkla daha

derin katmanlarına iletmek üzere ilk işleme tabi tutar. Girdi katmanından alınan her giriş, girdi katmanı ile gizli katmanlar arasında bulunan bağlantı ağırlıkları ile çarpılır ve bu işlem sonucu elde edilen değerler gizli katmana iletilir. Gizli katmanın matematiksel ifadesi ise Eşitlik (9) ve (10)' de sunulmaktadır.


$$z_l = W_l \cdot a_{l-1} + b_l \quad (9)$$

$$a_l = f_l \cdot z_l \quad (10)$$

Burada her gizli katman l ile ifade edilir ve önceki katmanın çıktılarına W_l ile ifade edilen ağırlıklar ve b_l ile ifade edilen biaslar uygulayarak hesaplanır ve sonrasında bir f_l aktivasyon fonksiyonu kullanılır. a_{l-1} önceki katman çıktısı iken z_l bu katmandaki aktivasyon fonksiyonuna girmeden önceki değeri ifade eder. a_l ise aktivasyon sonrası çıktıyı vermektedir.

Gizli katmanlar, modelin öğrenme kapasitesinin ve karmaşıklığının merkezidir. Buradaki nöronlar, gelen bilgileri toplayıp aktarım fonksiyonları vasıtasıyla işler. Ardından, gizli katman ve çıkış katmanı arasındaki bağlantı ağırlıkları ile çarpılarak elde edilen değerler çıkış katmanına iletilir. Çıkış katmanı, modelin tahminlerini veya sınıflandırmalarını sunar. Bu katmandaki nöronlar, kendilerine iletilen girişleri toplayarak modelin son çıktısını üretir. Çok katmanlı algılayıcıların son katmanında da hesaplama Eşitlik (7) ve (8) 'deki gizli katmanlarda olduğu gibi yapılmaktadır.

Çok katmanlı algılayıcılarda ileri beslemeli – geri yayımlı algoritmalar kullanılır. Bu da soru ile birlikte cevabın da girdi olarak öğrenme aşamasına dahil olması ve etiketleme işleminin probleme uygun olarak yapılmasını sağlar (Kaya ve İnce, 2021).



Şekil 3.5 Çok Katmanlı Algılayıcı Mimarisi

d. Kapı Kontrollü Tekrarlayan Birimler (Gated Recurrent Units)

Kapı Kontrollü Tekrarlayan Birimler (KKTB), UKSB 'ye oldukça benzeyen tekrarlayan bir sinir ağıdır. Her ikisi de benzer şekilde tasarlanmış ve bazı durumlarda eşit derecede başarılı sonuçlar verebilen yapılardır. İkisinde de temel amaç aynıdır (Demirci ve Ark., 2023). KKTB, Şekil 3.6'da gösterildiği üzere, güncelleme kapısı ve sıfırlama kapısı olmak üzere iki temel bileşenden oluşur. Bu kapılar, ağın geçmiş bilgileriyle nasıl etkileşime gireceğini ve yeni bilgilere nasıl tepki vereceğini düzenleyerek, zaman serisi verileri gibi sıralı bilgilerin işlenmesini optimize eder.

Güncelleme kapısı, ağı her adımda hangi bilgilerin korunup hangi bilgilerin güncelleneceğine karar verir. Bu sayede, modelin hem kısa vadeli hem de uzun vadeli bağımlılıkları etkili bir şekilde öğrenmesi sağlanır. Sıfırlama kapısı ise, geçmiş bilgilerin ne kadarının unutulacağını yönetir, bu da modelin gereksiz veya yanıltıcı bilgileri atarak daha etkin bir öğrenme süreci gerçekleştirmesine imkân tanır.

KKTB yapısı, UKSB' ye göre daha az parametreye sahiptir. Bu da modelde meydana gelen karışıklığı azaltarak, hesaplama performansını artırır (Tosun ve Şentürk, 2023). KKTB özellikle sınırlı hesaplama kaynaklarına sahip ortamlarda veya daha küçük veri setleri üzerinde çalışırken avantaj sağlar. Ayrıca, KKTB, karmaşıklığı azaltırken performanstan ödün vermeyen bir yapı sunar, bu da onu geniş bir uygulama yelpazesinde değerli bir araç haline getirir. Bu avantajları sayesinde, KKTB, derin öğrenme ve sıralı veri işleme konularında önemli bir yer tutmaktadır.

Eşitlik (11) 'de ifade edildiği şekilde güncelleme kapısı hesaplanmaktadır. Burada z_t güncelleme kapısının aktivasyon vektörünü, σ sigmoid fonksiyonu, W_z güncelleme kapısı ağırlıklarını, h_{t-1} önceki gizli durumu ifade ederken x_t mevcut girdiyi ve b_z güncelleme kapısı için ağırlık vektörünü ifade etmektedir.

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (11)$$

Sıfırlama kapısının aktivasyon vektörü r_t ile ifade edilirken, sıfırlama kapısı ağırlıkları W_r ve sıfırlama kapısı ağırlık vektörü ise b_r ile ifade edilerek (12) 'deki şekilde sıfırlama kapısı hesaplanmaktadır.


$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (12)$$

Yeni gizli durum hesabı ise Eşitlik (13) 'de belirtildiği gibi hesaplanır. W yeni gizli durum ağırlıklarını, b ise gizli durum için ağırlık vektörünü ifade eder.

$$\tilde{h}_t = \tanh(W \cdot [r_t, h_{t-1}, x_t] + b) \quad (13)$$

$$h_t = z_t \cdot h_{t-1} + (1 - z_t) \cdot \tilde{h}_t \quad (14)$$

Son olarak gizli durum güncellemesi ise Eşitlik (14)'deki gibi hesaplanır. Burada h_t mevcut zaman adımı için gizli durumu ifade ederken $1 - z_t$ güncelleme kapısının tamamlayıcısı olarak görev yapar.



Şekil 3.6 Kapı Kontrollü Tekrarlayan Birimler Mimarisi

3.4 Performans Ölçütleri

Tahmin yöntemlerinin performansı tahmin hatasını tanımlayan çeşitli yöntemlerle ölçülür. Hata değerlerinin yüksek olması tahmin doğruluğunun daha düşük olması anlamına gelmektedir. Bu bölümde tahmin hatası hesaplamak için yaygın olarak kullanılan performans ölçütlerine değinilecektir.

3.4.1 Kök ortalama kare hatası (Root Mean Square Error)

Kök Ortalama Kare Hatası (KOKH), iki veri kümesi arasındaki hata oranını ölçmeye yarayan bir performans ölçüm yöntemidir. Yani tahmin edilen değer ile gerçek değerin karşılaştırılmasıdır. KOKH değeri (15) eşitliğindeki gibi belirlenir. KOKH değeri ne kadar küçülürse tahmin edilen değer ile gerçek değer birbirine o kadar yaklaşır. Eşitlik (15)'de bulunan $\hat{y}$ tahmin edilen değeri, t ise gerçek değeri göstermektedir. n ise veri kümesindeki örüntü sayısını ifade eder.

$$KOKH = \sqrt{\frac{1}{n} \sum_{i=1}^n (t - \hat{y})^2} \quad (15)$$

3.4.2 Regresyon toplam kareler (Residuals Sum of Squares)

Regresyon Toplam Kareler (RTK), regresyon analizinde, bir modelin gerçek değerlerle tahmin ettiği değerler arasındaki farkların karelerinin toplamını gösteren ve eşitlik (16) ile hesaplanan bir metriktir. Başka bir deyişle, modelin hatalarının veya kalıntıların büyüklüğünü ölçer. Modelin performansının bir göstergesi olarak kullanılır; daha düşük RTK değerleri, modelin veriye daha iyi uyduğunu ve hataların daha az olduğunu gösterir. Bu değer, modelin iyiliğini değerlendirirken ve farklı modelleri karşılaştırırken önemli bir metriktir. Eşitlik (16)'de bulunan y tahmin edilen değeri, t ise gerçek değeri göstermektedir.

$$RTK = \sum_{i=1}^n (t - y)^2 \quad (16)$$

3.4.3 Belirleme katsayısı (R^2)


Belirleme Katsayısı (BK), bağımsız değişkenlerin açıklama oranını gösterir. Başka bir ifade ile bağımlı değişkenin bağımsız değişkenler tarafından açıklanan varyans oranını temsil eder. Yani modelin veri setindeki değişkenliği ne kadar iyi açıklayabildiğini ölçer.

Belirleme katsayısı, 0-1 arasında değerler alır. Sıfır olması bağımsız değişkenin bağımlı değişkeni hiç açıklayamadığını, bir olması ise tam olarak açıklayabildiğini ifade etmektedir. Sıfır olması modelin %0, bir olması da modelin %100 açıklayıcılığa sahip olduğunu gösterir. Bu değer %100 e yakın olması istenen durumdur. BK değeri (17) eşitliği ile hesaplanır. Eşitlik (17)'de bulunan y tahmin edilen değeri, t gerçek değeri, μ ise ortalamayı göstermektedir.

$$BK = 1 - \frac{\sum_{i=1}^n (t-y)^2}{\sum_{i=1}^n (t-\mu)^2} \quad (17)$$

3.5 Hiperparametreler

Veriden öğrenen makine öğrenmesi modelleri tasarlanırken, modelde kullanılan algoritma ya da teknikler ne olması gerektiğine karar verilmesi gereken bazı parametreleri de beraberinde getirmektedir. Probleme ve veri setine göre değişiklik gösteren bu parametrelere hiperparametre denilmektedir (Şekil 3.7). Veri seti boyutu, öğrenme oranı, eğitim tur sayısı önemli hiperparametrelerdir.



Şekil 3.7 Hiper-parametreler ve model parametrelerin ilişkisi (Kıymaz,2020)

3.5.1 Veri setinin boyutu

Derin öğrenme uygulamalarında veri setinin büyüklüğü ve çeşitliliği öğrenme için en önemli faktördür. Veri seti ne kadar büyük olursa öğrenme de o oranda daha iyi olur. Ayrıca veri setinin büyüklüğü öğrenme için harcanan zamanı ve öğrenme sonunda elde edilen modelin büyüklüğünü de artırmaktadır. Sadece veri setinin büyüklüğü iyi bir model için yeterli olmaz. Veri çeşitliliği de önemlidir. Çeşitlilik arttığında modelin başarımında da artış gözlenmektedir.

3.5.2 Öğrenme oranı (Learning rate)

Derin öğrenmede parametrelerin güncellenmesi işlemi geri yayılım işlemi ile yapılır. Geri yayılım işleminde bu güncelleme işi geriye doğru türev alınarak farkın bulunması ve bulunan fark değerinin öğrenme oranı parametresi ile çarpılması, çıkan sonucun ağırlık değerlerinden çıkarılarak yeni ağırlık değerlerinin hesaplanması ile yapılır. Bu işlemler esnasında kullanılan öğrenme oranı parametresi sabit bir değer olarak ya da adım adım artan bir değer olarak belirlenebilir. Öğrenme oranı modelin eğitim esnasında ne kadar öğreneceğini belirleyen bir parametredir. Öğrenme oranının doğru seçilmesi modelin eğitim sürecinin başarısı için önemli bir rol oynamaktadır. Öğrenme oranının çok yüksek olması optimum çözüme ulaşmada modelin aşırı atlamalar yapmasına ve hatta optimum çözümü kaçırmaya neden olur. Çok düşük bir öğrenme oranı ise modelin çok yavaş öğrenmesine ve eğitimin uzun sürmesine neden olacaktır.

3.5.3 Eğitim tur sayısı (Epoch)

Model eğitilirken verilerin hepsi aynı anda eğitime katılmaz. Belli sayıda parçalar halinde eğitimde yer alır. İlk parça eğitilir, modelin başarısı test edilir ve başarıya göre geriye yayılım ile ağırlıklar güncellenir. Daha sonra yeni eğitim kümesi ile model tekrar eğitilip ağırlıklar güncellenir. Her bir eğitim adımında bu işlem tekrarlanarak model için en uygun ağırlık değerleri hesaplanmaya çalışılmaktadır. Bu eğitim adımlarının her biri eğitim tur sayısı olarak adlandırılır. Derin öğrenmede eğitim tur sayısı arttıkça başarıda genellikle artar.

3.5.4 Unutma oranı (Dropout)

Unutma oranı, yapay sinir ağlarında ezberlemeyi engellemek için kullanılan bir düzenleme tekniğidir. Eğitim sırasında, sinir ağının katmanlarındaki nöronların bir kısmı rastgele seçilerek geçici olarak devre dışı bırakılır. Bu işlem her eğitim sırasında tekrarlanarak farklı bir alt küme nöronu kullanılmasını sağlar. Bu da nöronlara aşırı bağımlı hale gelmesini engeller. Eğitim tamamlandığında unutma oranı işlemi kaldırılır ve tüm nöronlar kullanılarak tahmin yapılır.

3.6 Zaman Serilerinde Durağanlık Analizi

Zaman serileri analizinde, durağanlık kavramı, verilerin istatistiksel özelliklerinin zamanla sabit kalıp kalmadığını anlamak için kritik bir öneme sahiptir. Zaman serisindeki gözlemlerin ortalaması ve varyansının zamana göre değişmemesi o serinin durağan olduğunu gösterir. Bir zaman serisinin durağan olması modellemesini kolaylaştırmaktadır. Durağanlık, modelin tahmin gücünü ve güvenilirliğini doğrudan etkiler, çünkü durağan olmayan verilerde yapılan tahminler yanıltıcı olabilir. Zaman serilerinin durağanlığını test etmek için yaygın olarak kullanılan yöntemler arasında Augmented Dickey-Fuller (ADF) testi, Phillips-Perron (PP) testi ve Kwiatkowski-Phillips-Schmidt-Shin (KPSS) testi bulunmaktadır (Enders, 2004; Hamilton, 1994).

3.6.1 Artırılmış Dickey-Fuller testi (Augmented Dickey-Fuller – ADF)

Bu çalışmada, zaman serisi verilerinin durağanlığını test etmek için Artırılmış Dickey-Fuller (ADF) testi kullanılmıştır. ADF testi, bir zaman serisinin birim kök içerip içermediğini yani bir zaman serisinin durağan olup olmadığını belirlemek için tasarlanmıştır ve bu, zaman serisi analizinde kritik bir öneme sahiptir. Durağan olmayan zaman serileri zamanla değişen istatistiksel özelliklere sahip olduğundan analizleri ve tahminleri zorlaştırır. Dickey ve Fuller tarafından geliştirilen bu test, bir zaman serisi

modelinin otoregresif terimindeki bir birim kök varlığını null hipotezi olarak kabul eder. (Dickey & Fuller, 1979)

ADF testi sonucunda elde edilen p- değeri, null hipotezin reddedilip reddedilemeyeceğini belirlemektedir. Eğer ADF testi sonucunda p- değeri anlamlılık düzeyinden daha düşükse (genellikle anlamlılık düzeyi %5 (0.05) olarak kullanılır.) bu null hipotezinin reddedilmesi, zaman serisinin bir birim kök içermediği ve durağan olduğu anlamına gelmektedir. Eğer p- değeri belirlenen anlamlılık düzeyinden daha yüksekse null hipotezi reddedilemez bu da zaman serisinin bir birim kök içerdiği ve durağan olmadığı anlamına gelmektedir.


Gerçekleştirilen ADF testi sonuçları Tablo 3.1 'de gösterilmektedir. Test sonuçlarına göre çalışmada kullanılan güneş enerji santrali üretim verilerinde ve rüzgar hızı verilerinde sırasıyla ADF test istatistiği değeri -3.697 ve -7.909 olarak alınmıştır. Bu istatistik sonucu ne kadar olumsuz olursa sıfır hipotezini reddetme olasılığı o kadar yüksektir. Ayrıca p- değeri ≤ 0.05 olduğundan boş hipotez reddedilir bu da zaman serisinin durağan olduğu anlamına gelmektedir.

Tablo 3.1 ADF Test Sonuçları

Güneş Enerji Santrali Üretim Verileri		Hava Durumu (Rüzgar hızı) Verileri	
ADF istatistiği	-3.697	ADF istatistiği	-7.909
p-değeri	0.00415	p-değeri	3.996e-12 (yaklaşık 0)
Kritik Değerler		Kritik Değerler	
1%	-3.439	1%	-3.439
5%	-2.866	5%	-2.865
10%	-2.569	10%	-2.569

3.7 Veri Seti


Bu çalışmada güneş enerji santrali üretim verileri olarak MEDAŞ 'a ait Konya İli Sarayönü ilçesinde bulunan 200 kW gücündeki bir üretim santralinin 2022 yılına ait 1 yıllık elektrik üretim verileri (kWh) kullanılmıştır (Şekil 3.8). Veri seti 8760 adet ölçümü içeren bir zaman serisidir.



Şekil 3.8 2022 yılına ait bir yıllık güneş enerjisi üretim verileri

Güneş üretimini etkileyen faktörlerden biri de rüzgar hızıdır. Güneş panelleri aldıkları güneş ışığını elektriğe dönüştürürken ısı üretir. Panellerin sıcaklığı da verimliliği düşürür. Rüzgar, panellerin yüzeyini soğutarak bu ısıyı uzaklaştırır ve verimliliğini artırır. Rüzgar hızı, enerji üretim tahminlerini yaparken dikkate alınması gereken bir faktördür. Güneş enerji üretim tahmin modellerinde genellikle hava durumu verileri ve dolayısı ile rüzgar hızı bilgileri kullanılır. Bu tahminler, enerji yönetimi ve planlamada önemli bir rol oynar.

Gerçekleştirilen çalışmada Meteoroloji 8. Bölge Müdürlüğünden alınmış olan rüzgar hızı verileri kullanılmıştır. Veriler 2022 yılına ait 8760 ölçüm içeren bir yıllık rüzgar hızı verileridir (Şekil 3.9) Veri setinin %80 'i eğitim %20'si ise test olarak ayrılmıştır.




Şekil 3.9 2022 yılına ait bir yıllık rüzgar hızı verileri

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu çalışmada güneş enerjisi üretim tahmini için UKSB, ÇKA, TSA ve KKTB modellerinin kullanımını önermiştir. Önerilen modellerin güneş enerjisi üretim tahmini üzerine performansını değerlendirmek için güneş enerji santralinden alınan verilerle, Meteoroloji Bölge Müdürlüğü’nden alınan veriler kullanılmıştır. Oluşturulan veri setleri 2022 yılına ait 8760 adet veri içermektedir. Bu modellerin tahmin doğruluklarını kıyaslamak için varyans, Kök Ortalama Kare Hatası (KOKH), Regresyon Toplam Kareler (RTK) hatası ve Belirleme Katsayısı (BK) hata metriklerinden yararlanılmıştır. Gerçekleştirilen çalışmanın blok gösterimi Şekil 4.1’ de sunulmuştur. Kullanılan bütün derin öğrenme modellerinde öncelikle optimum hiperparametreler tespit edilmeye çalışılmıştır. Optimum model parametreleri tespit edildikten sonra ağın elde ettiği tahmin sonucu ile hedef karşılaştırılarak performansı tespit edilmiştir.

Bu çalışmada kullanılan bilgisayara ait işlemci özellikleri Intel(R) Core(TM) i5-9300H CPU @ 2.40GHz iken ekran kartı özellikleri ise NVIDIA GeForce GTX 1650 ‘dir.



Şekil 4.1. Gerçekleştirilen çalışmanın modellenmesi

4.1. UKSB ile Elde Edilen Sonuçlar

Bu çalışmada, enerji üretim tahminlerini gerçekleştirmek için Keras kütüphanesi kullanılarak bir UKSB modeli oluşturulmuştur. Öncelikle UKSB modeli için optimum hiperparametrelerin tespiti için uygulamalar gerçekleştirilmiştir.

Veri setinin %80'i ile model eğitilmiş ve kalan %20'si ile test edilmiştir. Bu model için eğitim süresi 2310.52 saniye iken test süresi 2.92 saniye olarak tespit edilmiştir.

Katmanlarda bulunan optimum nöron sayıları, öğrenme oranı 0.001 ve unutma oranları 0.2 değerlerinde sabit tutularak belirlenmiştir. Gerçekleştirilen deneysel çalışmaların sonuçları Çizelge 4.1'de sunulmuştur. Optimum katman nöron sayıları 128,64,64,1 olarak tespit edilmiştir.

Çizelge 4.1. UKSB modelinde optimum katman nöron sayılarının belirlenmesi

Katmanlar	Varyans	KOKH	RTK	BK (%)
128,64,64,1	0,11	0,10	18,27	91,35
128, 64,32,1	0,12	0,11	19,72	90,57
128,64,16,1	0,11	0,11	20,22	90,34
128,64,8,1	0,11	0,11	19,45	90,71
128,32,64,1	0,11	0,11	20,02	90,43
128,32,32,1	0,12	0,10	18,04	91,28
128,32,16,1	0,11	0,10	17,86	91,27
128,32,8,1	0,10	0,10	17,65	91,17
128,16,64,1	0,11	0,11	19,54	90,66
128,16,32,1	0,11	0,11	19,37	90,74
128,16,16,1	0,12	0,10	17,53	91,22
128,16,8,1	0,11	0,10	18,81	91,01
128,8,64,1	0,12	0,11	19,78	90,55
128,8,32,1	0,12	0,10	17,35	91,21
128,8,16,1	0,12	0,10	18,21	91,28
128,8,8,1	0,12	0,10	17,95	91,24

UKSB modelinde katman nöron sayıları 128,64,64,1 ve öğrenme oranı 0.001 değerlerinde sabit tutularak optimum unutma oranı belirlenerek Çizelge 4.2'de sunulmuştur. Yine aynı modelde katman nöron sayıları 128,64,64,1 ve unutma oranı 0.5 değerlerinde sabit tutularak değerlendirme metrikleri üzerinde analiz yapılmış ve optimum öğrenme oranı Çizelge 4.3'de sunulmuştur. Gerçekleştirilen analizler neticesinde UKSB modeli için öğrenme oranı değeri 0.001 ve unutma oranı 0.5 olarak belirlenmiştir.

Çizelge 4.2. UKSB modelinde optimum unutmama oranının belirlenmesi


Unutmama Oranı	Varyans	KOKH	RTK	BK (%)
0.1	0,11	0,10	20,09	90,40
0.2	0,11	0,10	18,27	91,35
0.3	0,11	0,10	18,19	91,31
0.4	0,10	0,10	18,28	91,26
0.5	0,12	0,10	18,04	91,38
0.6	0,10	0,10	18,44	91,19
0.7	0,11	0,10	18,09	91,35
0.8	0,11	0,10	18,02	91,37

Çizelge 4.3. UKSB modelinde optimum öğrenme oranının belirlenmesi

Öğrenme Oranı	Varyans	KOKH	RTK	BK (%)
0.01	0,11	0,10	18,93	90,95
0.001	0,12	0,10	18,04	91,38
0.0001	0,11	0,10	18,13	91,34
0.00001	0,10	0,14	33,83	83,84

Gerçekleştirilen çalışma sonucunda UKSB modeli, ardışık olarak dört katmandan oluşmaktadır. İlk katmanda, veri girişi için 128 nöron kullanılmıştır. Bu katman, modelin zaman serisine ait verilerin özelliklerini etkin bir şekilde öğrenmesini sağlamak amacıyla tasarlanmıştır. İlk UKSB katmanından sonra gelen unutmama katmanı, %50 oranında nöronları rastgele sıfırlayarak modelin aşırı uyumunu engellemek amacıyla eklenmiştir. Bu işlem, modelin genelleştirme yeteneğini artırarak yeni verilere karşı daha güçlü olmasını sağlamaktadır. İkinci UKSB katmanı 64 nöron içermekte ve sonraki yoğun katmanlara tek bir vektör halinde bilgi aktarımı yapmaktadır. Ardından gelen yoğun katmanlar sırasıyla 64 ve 1 nöron içermekte ve tek bir çıktı üretmektedir.

Modelde, Adam optimizasyon algoritması kullanılarak ortalama kare hatanın minimize edilmesi amaçlanmıştır. 100 eğitim tur sayısı süresince eğitilen model, 168 saatlik bir zaman dilimi içeren test seti üzerindeki tahminlerinin gerçek verilere göre tutarlılığı Şekil 4.2’de sunulmuştur.



Şekil 4.2 Uzun Kısa Süreli Bellek ile Tahmin Sonucu

4.2 ÇKA ile Elde Edilen Sonuçlar

Çalışmada, ikinci aşamada enerji üretim tahminlerini gerçekleştirmek için Keras Kütüphanesi kullanılarak bir ÇKA oluşturulmuştur. Modelin eğitimi için kullanılan veri seti, güneş enerjisi üretimi ve hava durumu verilerinden oluşan iki ayrı kaynaktan ölçeklendirilmiş ve birleştirilmiş verileri içermektedir.

Veri setinin %80'i ile model eğitilmiş ve kalan %20'si ile test edilmiştir. Bu model için eğitim süresi 254.37 saniye iken test süresi 0.33 saniye olarak tespit edilmiştir.

Katmanlarda bulunan optimum nöron sayıları, öğrenme oranı 0.001 ve unutma oranları 0.2 değerlerinde sabit tutularak belirlenmiştir. Gerçekleştirilen deneysel çalışmaların sonuçları Çizelge 4.4'de sunulmuştur. Optimum katman nöron sayıları 128,64,16,1 olarak tespit edilmiştir.

Çizelge 4.4. ÇKA modelinde optimum katman nöron sayılarının belirlenmesi

Katmanlar	Varyans	KOKH	RTK	BK (%)
128,64,64,1	0,10	0,11	22,37	89,31
128, 64,32,1	0,10	0,12	23,29	88,87
128,64,16,1	0,13	0,12	26,72	89,60
128,64,8,1	0,11	0,12	24,55	88,27
128,32,64,1	0,12	0,11	20,90	80,01
128,32,32,1	0,12	0,12	24,49	88,30
128,32,16,1	0,12	0,12	25,63	87,75
128,32,8,1	0,12	0,12	24,53	88,28
128,16,64,1	0,11	0,11	22,58	89,21
128,16,32,1	0,12	0,12	23,16	88,93
128,16,16,1	0,12	0,11	22,23	89,38
128,16,8,1	0,12	0,12	23,31	88,86
128,8,64,1	0,11	0,11	21,16	89,59
128,8,32,1	0,12	0,12	23,04	88,99
128,8,16,1	0,11	0,12	24,01	88,53
128,8,8,1	0,11	0,11	21,41	89,57

ÇKA modelinde katman nöron sayıları 128,64,16,1 ve öğrenme oranı 0.001 değerlerinde sabit tutularak optimum unutma oranı belirlenmiş ve Çizelge 4.5'de sunulmuştur. Yine aynı modelde katman nöron sayıları 128,64,16,1 ve unutma oranı 0.7 değerlerinde sabit tutularak değerlendirme metrikleri üzerinde analiz yapılmış ve optimum öğrenme oranı Çizelge 4.6'da sunulmuştur. Gerçekleştirilen analizler

neticesinde ÇKA modeli için öğrenme oranı değeri 0.001 ve unutma oranı 0.7 olarak belirlenmiştir.

Çizelge 4.5. ÇKA modelinde optimum unutma oranının belirlenmesi


Unutma Oranı	Varyans	KOKH	RTK	BK (%)
0.1	0,11	0,11	23,92	88,57
0.2	0,13	0,12	26,72	89,60
0.3	0,10	0,11	22,53	89,23
0.4	0,11	0,11	23,04	88,99
0.5	0,10	0,11	21,62	89,67
0.6	0,11	0,11	21,32	89,81
0.7	0,12	0,10	19,73	90,84
0.8	0,10	0,10	20,02	90,43

Çizelge 4.6. ÇKA modelinde optimum öğrenme oranının belirlenmesi

Öğrenme Oranı	Varyans	KOKH	RTK	BK (%)
0.01	8,88	0,35	210,74	6,00
0.001	0,12	0,10	19,73	90,84
0.0001	0,08	0,11	23,53	88,76
0.00001	0,09	0,11	22,07	89,45

Yapılan çalışma sonucunda ÇKA modeli, ardışık olarak dört katmandan oluşmaktadır. İlk katmanda 128 nöron kullanılarak verinin karmaşıklığına uygun bir tasarlama yapılmıştır. İlk ÇKA katmanından sonra gelen unutma katmanı, %70 oranında nöronları rastgele sıfırlayarak modelin aşırı uyumunu engellemek amacıyla eklenmiştir. Bu katman, modelin genelleştirme yeteneğini artırarak yeni verilere karşı daha güçlü olmasını sağlamaktadır. Ardından gelen iki yoğun katman, sırası ile 64 ve 16 nöron içermektedir. Son katmanda ise tek bir çıktı üretmek üzere lineer bir aktivasyon fonksiyonu kullanılmıştır.

Modelde, Adam optimizasyon algoritması kullanılarak ortalama kare hatanın minimize edilmesi amaçlanmıştır. 100 eğitim tur sayısı süresince eğitilen modelin, 168 saatlik bir zaman dilimi içeren test seti üzerindeki tahminlerinin gerçek verilere göre tutarlılığı Şekil 4.3’de sunulmuştur.



Şekil 4.3 Çok Katmanlı Algılayıcılar ile Tahmin Sonucu

4.3 TSA ile Elde Edilen Sonuçlar

Güneş enerjisi üretim tahmini için çalışmada önerilen üçüncü model TSA'dır. Model, güneş enerjisi üretimi ve hava durumu verilerini içeren iki farklı veri setini ölçeklendirerek ve birleştirerek hazırlanan bir veri seti üzerinde eğitilmiştir. Veri setinin %80'i ile model eğitilmiş ve kalan %20'si ile test edilmiştir. Bu model için eğitim süresi 799.47 saniye iken test süresi 0.91 saniye olarak tespit edilmiştir.

Katmanlarda bulunan optimum nöron sayıları, öğrenme oranı 0.001 ve unutma oranları 0.2 değerlerinde sabit tutularak belirlenmiştir. Gerçekleştirilen deneysel çalışmaların sonuçları Çizelge 4.7'de sunulmuştur. Optimum katman nöron sayıları 128,64,32,1 olarak tespit edilmiştir.

Çizelge 4.7. TSA modelinde optimum katman nöron sayılarının belirlenmesi

Katmanlar	Varyans	KOKH	RTK	BK (%)
128,64,64,1	0,13	0,11	22,52	89,24
128, 64,32,1	0,11	0,14	32,30	89,57
128,64,16,1	0,10	0,13	30,55	85,41
128,64,8,1	0,12	0,13	27,34	86,94
128,32,64,1	0,10	0,14	33,27	84,11
128,32,32,1	0,11	0,11	21,32	89,51
128,32,16,1	0,11	0,12	25,65	87,74
128,32,8,1	0,10	0,14	34,01	83,75
128,16,64,1	0,12	0,13	27,91	86,67
128,16,32,1	0,10	0,11	21,84	89,56
128,16,16,1	0,12	0,11	22,38	89,30
128,16,8,1	0,10	0,14	34,74	83,41
128,8,64,1	0,11	0,13	27,29	86,96
128,8,32,1	0,10	0,12	25,56	87,79
128,8,16,1	0,12	0,12	26,45	87,37
128,8,8,1	0,11	0,13	30,79	85,29

TSA modelinde katman nöron sayıları 128,64,32,1 ve öğrenme oranı 0.001 değerlerinde sabit tutularak optimum unutm oranı belirlenmiş ve Çizelge 4.8’de sunulmuştur. Yine aynı modelde katman nöron sayıları 128,64,32,1 ve unutm oranı 0.3 değerlerinde sabit tutularak değerlendirme metrikleri üzerinde analiz yapılmış ve optimum öğrenme oranı Çizelge 4.9’da sunulmuştur. Gerçekleştirilen analizler neticesinde TSA modeli için öğrenme oranı değeri 0.0001 ve unutm oranı 0.3 olarak belirlenmiştir.

Çizelge 4.8. TSA modelinde optimum unutm oranının belirlenmesi


Unutm Oranı	Varyans	KOKH	RTK	BK (%)
0.1	0,09	0,12	27,22	87,00
0.2	0,11	0,14	32,30	89,57
0.3	0,11	0,11	21,47	89,74
0.4	0,12	0,12	28,01	86,62
0.5	0,11	0,11	23,45	88,80
0.6	0,10	0,13	31,58	84,91
0.7	0,06	0,22	87,35	58,28
0.8	0,11	0,13	31,44	84,98

Çizelge 4.9. TSA modelinde optimum öğrenme oranının belirlenmesi

Öğrenme Oranı	Varyans	KOKH	RTK	BK (%)
0.01	3,55	0,34	209,75	15,00
0.001	0,11	0,11	21,47	89,74
0.0001	0,11	0,09	16,49	92,12
0.00001	0,11	0,10	18,50	91,16

Çalışma neticesinde TSA modeli, ardışık olarak dört katmandan oluşmaktadır. İlk katmanda, veri girişi için 128 nöron kullanılmıştır. Bu katman, modelin zaman serisi verilerinin ardışık bağımlılıklarını öğrenmesi için tasarlanmıştır. İlk katmandan sonra gelen unutm oranı katmanı, %30 oranında nöronları rastgele sıfırlayarak modelin aşırı uyumunu engellemek amacıyla eklenmiştir. Bu işlem, modelin genelleştirme yeteneğini artırarak yeni verilere karşı daha güçlü olmasını sağlamaktadır. İkinci katman 64 nöron içermekte ve bu katman, sonraki katmanlara tek bir vektör halinde bilgi aktarımı sağlamaktadır. Ardından gelen yoğun katmanlar sırasıyla 32 ve 1 nöron içermekte, ilk yoğun katman ReLU aktivasyon fonksiyonu kullanırken, son katman lineer bir aktivasyon fonksiyonu kullanarak tek bir çıktı üretmektedir.

Modelde, Adam optimizasyon algoritması kullanılarak ortalama kare hatanın minimize edilmesi amaçlanmıştır. 100 eğitim tur sayısı süresince eğitilen modelin, 168 saatlik bir zaman dilimi içeren test seti üzerindeki tahminlerinin gerçek verilere göre tutarlılığı Şekil 4.4’ de sunulmuştur.



Şekil 4.4 Tekrarlayan Sinir Ağları ile Tahmin Sonucu

4.4 KKTB ile Elde Edilen Sonuçlar

Bu çalışmada, enerji üretimi tahminleri için son olarak KKTB modeli önerilmiştir. Modelin eğitimi, güneş enerjisi ve hava durumu verilerinden oluşturulan, önceden ölçeklendirilmiş ve birleştirilmiş bir veri seti üzerinde gerçekleştirilmiştir. Bu verilere dayanarak 168 saatlik gelecek tahmininde bulunabilmesi amaçlanmıştır.

Veri setinin %80’i ile model eğitilmiş ve kalan %20’si ile test edilmiştir. Bu model için eğitim süresi 1885.06 saniye iken test süresi 1.92 saniye olarak tespit edilmiştir.

Katmanlarda bulunan optimum nöron sayıları, öğrenme oranı 0.001 ve unutma oranları 0.2 değerlerinde sabit tutularak belirlenmiştir. Gerçekleştirilen deneysel çalışmaların sonuçları Çizelge 4.10’da sunulmuştur. Optimum katman nöron sayıları 128,16,16,1 olarak tespit edilmiştir.

Çizelge 4.10. KKTB modelinde optimum katman nöron sayılarının belirlenmesi

Katmanlar	Varyans	KOKH	RTK	BK (%)
128,64,64,1	0,11	0,11	21,08	89,93
128, 64,32,1	0,11	0,11	20,36	90,27
128,64,16,1	0,12	0,11	20,51	90,20
128,64,8,1	0,11	0,11	22,30	89,35
128,32,64,1	0,11	0,10	17,45	91,36
128,32,32,1	0,12	0,10	18,46	91,18
128,32,16,1	0,11	0,11	19,00	90,92

128,32,8,1	0,12	0,11	20,84	90,04
128,16,64,1	0,11	0,11	20,32	90,29
128,16,32,1	0,11	0,11	19,44	90,71
128,16,16,1	0,11	0,11	19,71	91,42
128,16,8,1	0,12	0,11	19,18	90,83
128,8,64,1	0,12	0,11	19,64	90,62
128,8,32,1	0,12	0,10	18,48	91,17
128,8,16,1	0,12	0,10	18,71	91,06
128,8,8,1	0,11	0,10	18,38	91,21

KKTB modelinde katman nöron sayıları 128,16,16,1 ve öğrenme oranı 0.001 değerlerinde sabit tutularak optimum unutm oranı belirlenmiş ve Çizelge 4.11’de sunulmuştur. Yine aynı modelde katman nöron sayıları 128,16,16,1 ve unutm oranı 0.6 değerlerinde sabit tutularak değerlendirme metrikleri üzerinde analiz yapılmış ve optimum öğrenme oranı Çizelge 4.12’de sunulmuştur. Gerçekleştirilen analizler neticesinde KKTB modeli için öğrenme oranı değeri 0.001 ve unutm oranı 0.6 olarak belirlenmiştir.

Çizelge 4.11. KKTB modelinde optimum unutm oranının belirlenmesi

Unutm Oranı	Varyans	KOKH	RTK	BK (%)
0.1	0,11	0,10	19,43	90,72
0.2	0,11	0,11	19,71	91,42
0.3	0,11	0,10	19,33	90,76
0.4	0,11	0,10	18,12	91,34
0.5	0,12	0,10	17,91	91,44
0.6	0,11	0,10	17,88	91,45
0.7	0,11	0,10	19,14	90,85
0.8	0,11	0,10	20,39	91,39


Çizelge 4.12. KKTB modelinde optimum öğrenme oranının belirlenmesi

Öğrenme Oranı	Varyans	KOKH	RTK	BK (%)
0.01	0,10	0,13	30,09	85,62
0.001	0,11	0,10	17,88	91,45
0.0001	0,11	0,11	21,58	89,69
0.00001	0,10	0,13	33,07	84,20

Gerçekleştirilen çalışma neticesinde KKTB modeli, ardışık olarak dört katmandan oluşmaktadır. İlk katmanda, veri girişi için 128 nöron kullanılmıştır. Bu katman, modelin zaman serisi verileri üzerindeki uzun ve kısa vadeli bağımlılıkları öğrenmesi için

tasarlanmıştır. İlk KKTB katmanından sonra gelen unutma oranı katmanı, %60 oranında nöronları rastgele sıfırlayarak modelin aşırı uyumunu engellemek amacıyla eklenmiştir. Bu işlem, modelin genelleştirme yeteneğini artırarak yeni verilere karşı daha güçlü olmasını sağlamaktadır. İkinci KKTB katmanı 16 nöron içermekte ve bu katman, sonraki katmanlara tek bir vektör halinde bilgi aktarımı sağlamaktadır. Ardından gelen yoğun katmanlar sırasıyla 16 ve 1 nöron içermekte, ilk yoğun katman ReLU aktivasyon fonksiyonu kullanırken, son katman lineer bir aktivasyon fonksiyonu kullanarak tek bir çıktı üretmektedir.

Modelde, Adam optimizasyon algoritması kullanılarak ortalama kare hatasının minimize edilmesi amaçlanmıştır. 100 eğitim tur sayısı süresince eğitilen modelin, 168 saatlik bir zaman dilimi içeren test seti üzerindeki tahminlerinin gerçek verilere göre tutarlılığı Şekil 4.5’ de sunulmuştur.



Şekil 4.5 Kapı Kontrollü Tekrarlayan Birimler ile Tahmin Sonucu

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Bu çalışma, güneş enerjisi santrali üretim verileri ve rüzgar hızı verilerine dayanarak elektrik üretim tahminleri yapmak amacıyla dört farklı derin öğrenme ağ modelinin performansını karşılaştırmaktadır: Çok Katmanlı Algılayıcılar (ÇKA), Uzun Kısa Süreli Bellek (UKSB), Kapı Kontrollü Tekrarlayan Birimler (KKTB) ve Tekrarlayan Sinir Ağları (TSA).

Çalışmada, öncelikle MEDAŞ' tan alınan 8760 adet güneş enerji santrali üretim verisi ve Meteoroloji Genel Müdürlüğü'nden alınan 8760 adet rüzgar hızı verisi ile veri seti oluşturulmuştur. Her iki veri seti de 2022 yılına ait verileri içermektedir.

Bu veriler, derin öğrenme modellerinin eğitimi için uygun hale getirilmek üzere ölçeklendirilmiştir. Ardından, her bir model kullanılarak enerji üretimi tahminleri gerçekleştirilmiştir. Her modelin performansı varyans, kök ortalama kare hatası (KOKH), regresyon toplam kareler (RTK) ve belirleme katsayısı (R^2) gibi çeşitli istatistiksel metrikler kullanılarak değerlendirilmiştir.

TSA modeli %92.12 'lik BK değeri ile en başarılı performansı göstermiştir. Bu yüksek değer modelin verilerdeki karmaşık zaman bağımlılıklarını ve ilişkilerini çok iyi bir şekilde öğrendiğini ve tahmin ettiğini göstermektedir. KKTB modeli de %91.45'lik BK değeri ile benzer şekilde yüksek bir performans sergilemiş ve enerji üretim tahminlerinde TSA 'ya çok yakın bir başarı sağlamıştır. Her iki modelin bu başarısı, zaman serisi verilerinde uzun vadeli bağımlılıkları ve düzenleri etkili bir şekilde modelleyebilme kabiliyetleriyle ilişkilendirilebilir.

UKSB modeli, %91.38'lik BK değeri elde etmiştir. UKSB 'nin bu başarısı, karmaşık bağımlılıkların varlığında bile yeterli tahmin gücüne sahip olduğunu gösterirken, TSA ve KKTB modellerinin performansının biraz gerisinde kaldığını da göstermektedir

Diğer yandan, ÇKA modeli %90.84'lük BK değeri ile dört model arasında en düşük performansı göstermiştir. Bu, ÇKA 'nın güneş enerjisi üretim tahmini konusunda diğer modellere kıyasla sınırlı kalabileceğine işaret eder. ÇKA, statik veri setlerinde iyi sonuçlar verebilir, ancak zaman serisi verilerindeki uzun vadeli ilişkileri ve eğilimleri yakalama konusunda zorluklar yaşayabilmektedir.

Bu bulgular ışığında, TSA ve KKTB modellerinin güneş enerjisi tahminlerinde, özellikle uzun vadeli ve karmaşık bağımlılıkları olan zaman serisi verilerinde ÇKA ve

UKSB modellerine kıyasla daha güçlü ve güvenilir olduğu sonucuna varılmaktadır. Bu çalışma, tahmin modeli seçiminde modelin veri yapısına uygunluğunun ve bağımlılıkları anlama yeteneğinin ne kadar önemli olduğunu vurgulamaktadır. Derin öğrenme ağ modellerinin seçimi ve uygulaması, tahmin başarısını doğrudan etkileyen faktörlerdendir. Bu modellerin her birinin güçlü ve zayıf yanlarını dikkate almak performansın optimize edilmesi için kritik öneme sahiptir.

Çalışmada kullanılan derin öğrenme modellerinin eğitim ve test süreleri açısından karşılaştırma sonuçları Çizelge 5.1’de sunulmuştur. Hem eğitim hem de test süresi açısından en avantajlı model ÇKA olarak tespit edilmiştir.

Çizelge 5.1 Kullanılan derin öğrenme modellerinin çalışma süreleri

Derin Öğrenme Modelleri	Eğitim Süresi	Test Süresi
UKSB	2310,52	2,92
ÇKA	254,97	0,33
TSA	799,47	0,91
KKTb	1885,06	1,92

5.2 Öneriler

Artan endüstriyel faaliyetler, büyüyen nüfus ve teknolojik cihaz kullanımının yaygınlaşması enerji tüketiminin sürekli artışını beraberinde getirmektedir. Fosil yakıtların azalan rezervleri ve çevresel zararları göz önünde bulundurulduğunda, yenilenebilir enerji kaynaklarına olan ihtiyaç da aynı oranda artmaktadır. Bu bağlamda, enerji üretimi ile tüketimi arasındaki dengenin sağlanması ve yenilenebilir enerji kaynaklarının etkili bir şekilde yönetilmesi için yapılan bu çalışma önem taşımaktadır.

Çalışmada ele alınan dört yapay sinir ağı modeli üzerinden elde edilen sonuçlar, güneş enerjisi santrali üretim tahminlerinin doğruluğunu ve güvenilirliğini artırma potansiyeline işaret etmektedir. Bu modellerin daha iyi sonuçlar elde edebilmesi için gelecekteki çalışmalarda aşağıdaki önerilere yer verilmesi faydalı olacaktır.

Modellerin daha büyük ve çeşitli veri setleri kullanılarak eğitilmesi ve test edilmesi modellerin genelleme kabiliyetlerini artırarak daha doğru tahminler yapmalarını sağlar.

Farklı hava koşulları ve coğrafi bölgelerdeki verilerle yapılan testler modellerin çeşitli çevresel faktörlere olan adaptasyonunu ve performansını değerlendirme imkânı sunacaktır.

Zaman serisine özgü modellerin yanı sıra zaman serisi olmayan verilere de odaklanarak UKSB ve ÇKA ‘nın performansını artırmak için çalışmalar yapılabilir.

Belirtilen önerilerin uygulanması, güneş enerji santrali üretim tahmininin yanı sıra yenilenebilir enerji kaynaklarının yönetimine katkı sağlayarak enerji sektöründe sürdürülebilirlik ve verimlilik hedeflerine ulaşılmasında yardımcı olacaktır.



KAYNAKLAR

- Adak S., Cangi H., Yılmaz A.S., (2019). Fotovoltaik Sistemin Çıkış Gücünün Sıcaklık ve Işımaya Bağlı Matematiksel Modellemesi ve Simülasyonu. *International Journal of Engineering Research and Development*, 11(1), 316-327.
- Ak Ü., Usta Ö. Güneş Enerjili Uçaklarda Farklı Uçuş Durumları için Elektrik Sisteminin Performans Analizi *Electrical System's Performance Analysis of Solar Aircraft Under Different Flight Modes*.
- Akhter M.N., Mekhilef S. Mokhlis H., Almohaimeed Z.M., Muhammad M.A., Khairuddin A.S.M., Akram R. and Hussain M.M. (2022), An Hour-Ahead PV Power Forecasting Method Based on an RNN-LSTM Model for Three Different PV Plants, *MDPI Energies*, 15,2243
- 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.
- Ataseven B. (2013). Yapay Sinir Ağları İle Öngörü Modellemesi. *Öneri Dergisi*, 10(39), 101-115.
- Aydın İ. (2013). Balıkesir’de Rüzgâr Enerjisi. *Doğu Coğrafya Dergisi*, 18(29), 29-50.
- Aylak B. L., Okan O., Yazıcı K. (2021). Yapay zeka ve makine öğrenmesi tekniklerinin lojistik sektöründe kullanımı. *El-Cezeri*, 8(1), 74-93.
- Beigi M., Harchegani H.B., Torki M., Kaveh M., Szymanek M., Khalife E., Dziwulski J.(2022), Forecasting of Power Output of a PVPS Based on Meteorological Data Using RNN Approaches, *MDPI Sustainability*, 14,3104
- Cengiz M. S., Mamiş M. S. (2016). Termal güneş enerjisi kullanımı ve CSP sistemlerin verimlilik analizi. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 5(1).
- Çetin Ö. ve Işık A. (2022), Derin Öğrenme İle Güneş Enerjisi Santrallerinde Aylık Üretim Tahmini, *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 13,382-387.
- Dairi A., Harrou F., Sun Y. Ve Khadraoui S. (2020), Short-Term Forecasting of photovoltaic Solar Power Production Using Variational Auto-Encoder Driven Deep Learning Approach, *MDPI Applied Sciences*.
- Demirci ve Karaatlı (2023), Kripto Para Fiyatlarının LSTM ve GRU Modelleri İle Tahmini, *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10,134-157.

- Dickey D. A., Fuller W. A. (1979), Distribution of the Estimators for Autoregressive Time Series With a Unit Root, *Journal of the American Statistical Association*, 74(366), 427-431.
- Doğan S. (2019). Yenilenebilir enerji kaynakları açısından jeotermal enerji ve istihdam yaratma potansiyelinin değerlendirilmesi: Aydın ili örneği (*Master's thesis, Sosyal Bilimler Enstitüsü*).
- Gün A.R. (2023), Kısa Dönemli Fotovoltaik Güç Tahmini İçin Geliştirilen Yenilikçi Bir Hibrit Modelin Analiz ve Uygulaması, Doktora, *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü*, 28-29.
- Gürlek C., Bilgili M. Aylık Toplam Güneş Işınımının Uzun-Kısa Süreli Bellek (LSTM) Yöntemiyle Tahmini: Sivas İli Örneği. *Sivas Cumhuriyet Üniversitesi Bilim ve Teknoloji Dergisi*, 2(1), 24-30.
- Hamilton J.D. (1994), Time Series Analysis, *Princeton University Press*
- Hengirmen A. O. (2018). Konsantre güneş enerjisi sistemleri için termoklin termal enerji depolama sistem analizi (*Master's thesis, Enerji Enstitüsü*).
- Kapluhan E. (2014). Enerji Coğrafyası Açısından Bir İnceleme: Biyokütle Enerjisinin Dünyadaki Ve Türkiye'deki Kullanım Durumu. *Marmara Coğrafya Dergisi*, (30).
- Kara A. (2019). Uzun-kısa süreli bellek ağı kullanarak global güneş ışıınımı zaman serileri tahmini, *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7(4), 882-892.
- Karakoyun M., Hacıbeyoğlu M. (2014). Biyomedikal Veri Kümeleri İle Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16(48), 30-42.
- Kaya M. S., Kenan İ. (2021). Nesnelerin İnternetinde Çok Katmanlı Algılayıcı Kullanarak Zamanlama Analizi Saldırısı ile Özel Anahtar Tahminlemesi. *Computer Science, (Special)*, 385-390.
- Kıymaz Y. E. (2020), Güneş Enerjisi Santrallerinde Derin Öğrenme Kullanılarak Elektrik Üretimi Tahmininin Yapılması, Yüksek Lisans, *Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü*.
- Konstantinou M., Peratikou S. and Charalambides A.G. (2021), Solar Photovoltaic Forecasting of Power Output Using LSTM Networks, *MDPI Atmosphere*, 12
- Kumbur H., Özer Z., Özsoy H. D., Avcı E. D. (2005). Türkiye'de Geleneksel Ve Yenilenebilir Enerji Kaynaklarının Potansiyeli Ve Çevresel Etkilerinin Karşılaştırılması. *Yeksem 2005, III. Yenilenebilir Enerji Kaynakları Sempozyumu ve Sergisi*, 19-21.

- Örer D. Y. M. Y. G., Gürsel, K. T., Özdamar, A., Özbalta, N. (2003). Dalga Enerjisi Tesislerine Genel Bakış.
- Sayın S., Koç İ. (2011). Güneş Enerjisinden Aktif Olarak Yararlanmada Kullanılan Fotovoltaik (PV) Sistemler Ve Yapılarda Kullanım Biçimleri. *Selçuk Üniversitesi Mühendislik, Bilim Ve Teknoloji Dergisi*, 26(3), 89-106.
- Somuncu E., Atasoy N. A. (2022). Realization of character recognition application on text images by convolutional neural network. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37(1), 17-28.
- Sucu İ. (2019). Yapay zekanın toplum üzerindeki etkisi ve yapay zekâ (AI) filmi bağlamında yapay zekaya bakış. *Uluslararası Ders Kitapları ve Eğitim Materyalleri Dergisi*, 2(2), 203-215.
- Şekkeli M., Keçecioğlu Ö. F. (2011). Hidroelektrik Santrallerin Türkiye'deki Gelişimi ve Kahramanmaraş Bölgesi Örnek Çalışması. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 14(2), 19-26.
- Taktak F., Ilı M. (2018). Güneş Enerji Santrali (GES) Geliştirme: Uşak örneği. *Geomatik*, 3(1), 1-21.
- Tosun M. F., Şentürk A. (2023). Kasislerin Yakıt Tüketimine Etkisinin RNN, LSTM, GRU Tekrarlayan Derin Öğrenme Algoritmaları ile Tespiti. *Journal of Intelligent Systems: Theory and Applications*, 6(1), 12-23.
- Ürün E., Soyu E. (2016). Türkiye'nin Enerji Üretiminde Yenilenebilir Enerji Kaynakları Üzerine Bir Değerlendirme. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 31-45.
- Yavuz E. (2020), Konutlarda Enerji Tüketimi Kestirimi İçin Derin Öğrenme ve Makine Öğrenme Yöntemlerinin Karşılaştırılması, Yüksek Lisans, *İstanbul Üniversitesi Cerrahpaşa Lisansüstü Eğitim Enstitüsü*, 21.
- Yolcan O. O., Ramazan, K. (2020). Türkiye'nin güneş enerjisi durumu ve güneş enerjisi santrali kurulumunda önemli parametreler. *Kırklareli Üniversitesi Mühendislik ve Fen Bilimleri Dergisi*, 6(2), 196-215.
- <https://gepa.enerji.gov.tr/MyCalculator/> [Erişim Tarihi:10 Mart 2024]
- <https://www.epdk.gov.tr/Detay/Icerik/3-0-23/elektrikaylik-sektor-raporlar> [Erişim Tarihi:15 Nisan 2024]
- <https://www.derszamani.net/hidroelektrik-santrallerin-avantajlari-ve-dezavantajlari-nelerdir.html> [Erişim Tarihi:10 Mart 2024]
- <https://www.sektorumdergisi.com/hidroelektrik-enerjisi-kullanim-alanlari/> [Erişim Tarihi:10 Mart 2024]

EKLER

EK-1 Tez çalışmasında kullanılan hava durumu verileri için Meteoroloji Genel Müdürlüğü 8. Bölge Müdürlüğünden alınan izin yazısı

KTUN Gelen Evrak Tarih ve Sayı: 29.11.2023 - 136981



T.C.
ÇEVRE, ŞEHİRCİLİK VE İKLİM DEĞİŞİKLİĞİ BAKANLIĞI
Meteoroloji Genel Müdürlüğü 8. Bölge Müdürlüğü



Sayı : E-46130084-107-273346

Konu : Rasat Bilgisi ve Bilgi İstekleri

DAĞITIM YERLERİNE

İlgi : 27.11.2023 tarihli ve 46665609-100.05.01-E.136392 sayılı yazınız.

İlgide kayıtlı yazımızla istenilen meteorolojik bilgiler ekte verilen bağlantı adreslerinde sunulmuştur.

10 Haziran 2020 tarihli ve 31151 sayılı Resmi Gazete'de yayımlanan "Resmi Yazışmalarda Uygulanacak Usul ve Esaslar Hakkında Yönetmelik" uyarınca resmi yazışmalarda paylaşım saklama işlemleri için elektronik ortam kullanımı esas unsur haline getirilmiştir. Bu kapsamda istemiş olduğunuz meteorolojik veriler, yazımızın tarihi itibarıyla 3 ay süresince verilen ekteki bağlantılar üzerinden indirilebilecektir.

Bilgilerini ve gereğini arz ederim.

Derya ERGÜN
Bölge Müdürü a.
Bölge Müdür Yardımcısı

Ek: <https://bulut.mgm.gov.tr/share/preview/bDEgT3RhRKrbQKp>

Dağıtım:

Gereği:

Konya Teknik Üniversitesi Rektörlüğüne
(Öğrenci İşleri Daire Başkanlığı)

Bilgi:

Meteorolojik Veri İşlem Dairesi Başkanlığına

EK-2 Tez çalışmasında kullanılan güneş enerji santrali verileri için Elektrik Dağıtım Şirketinden alınan izin yazısı

MEDAŞ Evrak Tarih ve Sayısı: 09/01/2024-1073

SAYIN AZİME İREM KÖKSAL



MERAM Elektrik Dağıtım A.Ş.

KANUNİ MERKEZ

Sancak Mahallesi Yeni İstanbul Caddesi No:92 Selçuklu / KONYA

Tel : +90 (850) 251 30 00

Faks : +90 (850) 251 31 00

: +90 (332) 255 00 82

ÇM No : 444 8 186

Web : www.meramedas.com.tr

E-Mail : info@meramedas.com.tr

Kep : meram.dagitim@hs02.kep.tr

Mersis No : 0833 0030 8740 0017

Selçuk VD : 833 003 0874

LÜTFEN İLGİLİ YAZINIZDA AŞAĞIDAKİ REFERANS

NUMARASINI BELİRTİNİZ.

☐ Tarih : 09/01/2024

☐ Referans No : RTGMY_PU_1073

ÖZÜ:ELEKTRİK ÜRETİM VERİLERİ HK.

İlgi: 08.01.2024 tarih 368 sayılı yazı

İlgi yazıda 48412481338 T.C kimlik numaralı Azime İrem KÖKSAL olarak Konya İli Sarayönü ilçesinde yer alan üretim santralinin 2022 yılı üretim verileri talep edilmektedir.

İlgi yazıda talep edilen üretim santraline ait 2022 yılı verileri yazımız ekindedir.

Bilgilerinize sunarız,

Saygılarımızla.

e-imza

Harun Enes GÖKTAŞ
Piyasa Ulaştırma
Başmühendisi

e-imza

Mustafa SAĞLAM
Tüketici Hizmetleri Müdürü



PIN:32703

Bu belge 5070 sayılı elektronik imza kanununa göre güvenli elektronik imza ile imzalanmıştır.

Detaylı Bilgi İçin : Kadir Akgül

Detaylı Bilgi İçin E-posta : kadir.akgul@meramedas.com.tr

Evrak PIN Kodu : 32703

Evrak Doğrulama Linki: https://dys.meramedas.com.tr/enVision/Validate_Doc.aspx?eD=BSPZA0PVJY linkinden yapılabilir.

