



T.C.
MUŞ ALPARSLAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MUŞ İLİ GÜNEŞ ENERJİSİ
POTANSİYELİNİN MAKİNE ÖĞRENMESİ
İLE TAHMİNİ

İrem Fatma ŞENER

YÜKSEK LİSANS TEZİ

Nükleer Enerji ve Enerji Sistemleri Anabilim
Dalı

Kasım-2024
MUŞ
Her Hakkı Saklıdır



T.C.
MUŞ ALPARSLAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MUŞ İLİ GÜNEŞ ENERJİSİ
POTANSİYELİNİN MAKİNE ÖĞRENMESİ
İLE TAHMİNİ

İrem Fatma ŞENER

YÜKSEK LİSANS TEZİ

Nükleer Enerji ve Enerji Sistemleri Anabilim
Dalı

Danışman: Dr. Öğretim Üyesi İhsan TUĞAL

Jüri Üyesi: Doç. Dr Zeydin PALA

Jüri Üyesi: Dr. Öğr. Üyesi Murat AYDOĞAN

Kasım-2024
MUŞ
Her Hakkı Saklıdır

ÖZET

YÜKSEK LİSANS TEZİ

MUŞ İLİNİN GÜNEŞ ENERJİSİ POTANSİYELİNİN MAKİNE ÖĞRENMESİ İLE TAHMİNİ

İrem Fatma ŞENER

**Muş Alparslan Üniversitesi
Fen Bilimleri Enstitüsü
Nükleer Enerji ve Enerji Sistemleri Anabilim Dalı**

Danışman: Dr. Öğretim Üyesi İhsan TUĞAL

Enerji üretimi tahmini, karar verme süreçleri ve değişken enerji kaynaklarının şebekeye entegrasyonu için kritik öneme sahiptir, çünkü bu tahminler, enerji arzındaki dalgalanmaların farklı zaman ve mekansal ölçeklerde ele alınmasını sağlar. Özellikle güneş enerjisi sektörü, yenilenebilir enerji üretiminde yüksek üretim payına sahiptir. Güneş enerjisi insanlığın enerji ihtiyaçlarını temiz, yenilenebilir ve sürdürülebilir bir şekilde karşılayabilecek potansiyele sahiptir. Fosil yakıtların çevresel etkilerinden kaçınılması ve iklim değişikliği ile mücadelede güneş enerjisi önemlidir. Güneş enerjisi üretimiyle doğrudan ilişkili olan güneş radyasyonu tahmini bu üretim sürecine katkı sağlayacaktır. Türkiye'nin Doğu Anadolu bölgesindeki Muş İli için yapılan bu tez çalışması, İlin güneş enerjisi potansiyeline katkı sağlayacak güneş radyasyonu günlük tahmini için zaman serisi ve regresyon makine öğrenmesi yöntemleri kullanılarak gerçekleştirildi. 2018 ile 2023 yılları arasındaki meteorolojik veriler kullanılarak günlük güneş radyasyonu tahmini yapıldı. Kullanılan yöntemlerle başarılı tahminler yapıldı. Çalışmanın sonuçları Muş'un güneş enerjisi üretimi için önemli bir potansiyele sahip olduğunu göstermektedir.

2024, 45 Sayfa

Anahtar Kelimeler: Güneş Enerjisi, Regresyon, Zaman Serisi, Yapay Zekâ, Muş

ABSTRACT

MS THESIS

PREDICTION OF SOLAR ENERGY POTENTIAL IN MUŞ PROVINCE USING MACHINE LEARNING

İrem Fatma ŞENER

**Muş Alparslan University
Natural and Applied Science
Department of Nuclear Energy and Energy Systems**

Advisor: Assist Prof. İhsan TUĞAL

Energy production forecasting is of critical importance for decision-making processes and the integration of variable energy sources into the grid, as these forecasts allow fluctuations in energy supply to be addressed at different time and spatial scales. In particular, the solar energy sector has a high production share in renewable energy production. Solar energy has the potential to meet humanity's energy needs in a clean, renewable and sustainable way. Solar energy is important in avoiding the environmental impacts of fossil fuels and combating climate change. Solar radiation forecasting, which is directly related to solar energy production, will contribute to this production process. This thesis study for Muş Province in the Eastern Anatolia Region of Turkey was carried out using machine learning methods to determine the solar energy potential of the province. Solar radiation prediction was performed with time series and regression methods using meteorological data between 2018 and 2023. Successful forecasts were made with the methods used. The results of the study show that Muş has a significant potential for solar energy production.

2024, 45 Pages

Keywords: Solar Energy, Regression, Time Series, Artificial Intelligence, Muş

ÖNSÖZ ya da TEŞEKKÜR

Bu çalışmaya beni teşvik eden ve yardımcı olan danışmanım Dr. Öğr. Üyesi İhsan TUĞAL'a her konuda destekçi olduğu için teşekkür ederim. Tahmin için kullandığımız Muş ili meteoroloji verilerini bizimle paylaşan Muş Meteoroloji Müdürlüğü'ne teşekkür ederim.

İrem Fatma ŞENER
MUŞ-2024



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER ve KISALTMALAR.....	viii
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ.....	xi
1. GİRİŞ	1
2. LİTERATÜR.....	4
3. GÜNEŞ ENERJİSİ	9
3.1 Enerji Kavramı.....	9
3.2 Güneş Enerjisi.....	9
3.3 Türkiye’de Güneş Enerjisi	16
3.4 Muş İli Güneş Enerjisi Potansiyeli	17
4. GÜNEŞ ENERJİSİ TAHMİN YÖNTEMLERİ.....	21
4.1 Zaman Serisi ile Tahminleme	21
4.1.1 ARIMA	21
4.1.2 LSTM.....	23
4.2 Regresyon ile Tahminleme	26
4.2.1 MLP	27
4.2.2 Random Forest	28
4.2.3 XGBoost	28
4.2.4 SVM.....	29
4.3 Öğrenme Algoritmalarında Değerlendirme Kriterleri.....	30
4.4 Örnek Üretim Kapasitesi Hesaplama.....	32
5. SONUÇLAR ve DEĞERLENDİRME	33
5.1 Veri Seti	33
5.2 Zaman Serisi Yöntemleri Tahmin Sonuçları	34
5.3 Regresyon Yöntemleri Tahmin Sonuçları	37
5.4 Sonuçlar ve Öneriler	39
KAYNAKLAR	41
ÖZGEÇMİŞ	45

SİMGELER ve KISALTMALAR

Simgeler

GW	: Gigawatt
MW	: Megawatt
GWh	: Gigawatt Saat
kWh	: Kilowatt Saat
PV	: Fotovoltaik
m	: Metre
°C	: Santigrat Derece
%	: Yüzde
N	: Parametre Sayısı
μ	: Ortalama
θ_i	: Hareketli ortalama katsayıları
q	: Geçmiş hata terimlerinin
x_t	: Mevcut zaman noktasındaki güneş enerjisi üretimi
c	: Sabit terim
ϕ_i	: Otoregresif katsayılar
p	: Geçmiş değerlerin sayısı
ε_t	: Hata terimi
P	: AR terimlerinin sayısı
d	: Durağanlık olmayan bileşenin derecesi
q	: MA terimlerinin sayısını belirtir.
x_t	: Mevcut zaman noktasındaki güneş enerjisi üretimi
c	: Bir sabit terim
ϕ_i	: Otoregresif katsayılar
p	: Kullanılacak geçmiş değerlerin sayısı
ε_t	: Hata terimi
μ	: Ortalama
θ_i	: Hareketli ortalama katsayıları
q	: Geçmiş hata terimlerinin sayısı
i_t	: Giriş kapısı
c_t^*	: İkinci bir kapı
t	: Anında bellek durumu
c_t	: Depolanan yeni bilgi
f_t	: Unutma kapısı
b_*	: Bias
σ	: Sigmoid fonksiyonu
$\odot$	: Bileşen bazlı çarpımı

Kısaltmalar

ARIMA	: Otoresif Bütünleşik Hareketli Ortalama
LSTM	: Uzun Kısa Süreli Bellek Ağları ile Tahmin
YSA	: Yapay sinir ağı
KNN	: K-Nearest Neighbors
CBS	: Coğrafi Bilgi Sistemleri
ANN	: Artificial neural networks
MLR	: Multiple linear regression
KNNR	: k-nearest neighbors regression
cm	: Santimetre
GES	: Güneş Enerjisi Santrali
kWp	: Kilowatt peak
MWe	: Megawatt elektrik
MWp	: Megawatt peak
GWh	: Gigawatt-saat
PV-CSP	: Photovoltaic Concentrated Solar Power (Fotovoltaik Konsantre Güneş Enerjisi)
MW	: Megawatt
GEPA	: Güneş Enerjisi Potansiyel Atlası
AR	: Autoregressive
I	: Integrated
MA	: Moving Average
MLP	: Çok Katmanlı Algılayıcı
XGBoost	: eXtreme Gradient Boosting
SVM	: Destek Vektör Makineleri
hPa	: Aktüel basınç
MSE	: Ortalama karesel hata
RMSE	: Kök ortalama karesel hata
MAPE	: Ortalama mutlak yüzde hata
MA	: Moving Average
Relu	: Rectified Linear Unit

ŞEKİLLER DİZİNİ

Şekil 3.1 Doğrudan normal ışınlama	12
Şekil 3.2 Küresel yatay ışınlama	12
Şekil 3.3 Fotovoltaik güç potansiyeli	13
Şekil 3.4 Güneş Panelleri Sisteminin Tasarlanması	14
Şekil 3.5 Örnek CSP Sistemleri	15
Şekil 3.6 Türkiye güneş enerjisi potansiyeli atlası	16
Şekil 3.7 Muş iline ait sıcaklık haritası	18
Şekil 3.8 Muş iline ait güneşlenme süresi haritası	18
Şekil 3.9 2018-2023 Muş ili aylık bazda ortalama günlük güneşlenme süreleri	19
Şekil 3.10 2018 – 2023 Global güneş radyasyonu dağılımı	19
Şekil 4.1 LSTM Yapısı	24
Şekil 4.2 MLP sinir ağı	27
Şekil 4.3 Rastgele Orman Regresyonu	28
Şekil 4.4 XGBoost	29
Şekil 4.5 ϵ -insensitive kayıp fonksiyonuyla regresyon	30
Şekil 5.1 Günlük Toplam Güneş Radyasyonu Zaman Serisi (2018-2023)	33
Şekil 5.2 ARIMA Tahmini	36
Şekil 5.3 LSTM Tahmini	36
Şekil 5.4 Hata ölçütleri değerleri gösterimi	38
Şekil 5.5 Zaman Serisi ve Regresyon yöntemlerinin hata ölçütleri değerleri.....	39

ÇİZELGELER DİZİNİ

Çizelge 5.1 Zaman Serisi Tahmin Yöntemleri Sonuçları	37
Çizelge 5.2 Veri seti istatistiki değerleri	37



1. GİRİŞ

Gelecek kuşaklara, temel ihtiyaçlarının karşılandığı, yaşam kalitesinin yükseldiği ve çevrenin dengeli olduğu, yaşanabilir bir dünya bırakmak en önemli amacımızdır. Sanayi devriminden bu yana, insanlık enerji için fosil yakıtlar kullanarak çevreyi ve atmosferi kirletiyor. Güneş enerjisi, yakıt olarak fosil yakıtlara kıyasla temizdir ve sera gazı emisyonlarını azaltır. Güneş enerjisi, insanlığın enerji ihtiyacını karşılamak için sonsuz bir potansiyele sahip olan temiz, yenilenebilir ve sürdürülebilir bir enerji kaynağıdır. Küresel ısınma ve iklim değişikliği ile mücadelede temiz enerji kaynakları önemli bir rol oynar. Güneşten gelen ışınlar, insanlık tarihi boyunca kullanılabilecek kadar fazla miktarda enerji üretir. Bu, enerji arzının sürekli ve güvenilir olmasını sağlar. Bu yüzden yerli ve çevre dostu yenilenebilir enerji kaynaklarından, özellikle de güneş enerjisinden en iyi şekilde faydalanmak gerekmektedir. Son yıllarda, güneş enerjisinden faydalanma ile ilgili çabalar artmış ve güneş enerjisi üretimi için kullanılan sistemler teknolojik olarak gelişmiş, maliyetleri de azalmaya başlamıştır. Güneş enerjisi enerji ihtiyacımıza temiz bir çözüm olabilir. Bu konuda daha çok çalışmak, araştırmak, daha hızlı yol almamız gerekiyor. Çünkü fosil yakıtlardan kaynaklı sera gazı atmosferimizi çok daha fazla etkilemeye başladı. İklim değişikliği daha çok hissedilmeye başlandı. Enerji kaynaklarımızı yenilenebilir enerji kaynaklarına bir an önce dönüştürmemiz gerekiyor. Ayrıca Güneş, her yerde mevcut olduğu için, ülkeler kendi enerji ihtiyaçlarını karşılamak için kendi güneş kaynaklarını kullanabilirler. Güneş enerjisi, ülkelerin enerji bağımsızlığını artırabilir. Güneş enerjisi, uzak ve kırsal bölgelerdeki topluluklar için de erişilebilir bir enerji kaynağıdır. Elektrik şebekesine ulaşamayan veya sınırlı enerji kaynaklarına sahip olan bölgelerde, güneş enerjisi sistemleri temel enerji ihtiyaçlarını karşılayabilir.

Güneş enerjisi üretimini etkileyen faktörlerin çeşitliliği ve etkileşimi göz önüne alındığında, makine öğrenmesi yaklaşımları güneş enerjisi tahminleri yapmamızı sağlayabilir. Makine öğrenmesi algoritmaları, büyük miktarda veriye dayalı olarak çalışır ve bu verilerden karmaşık ilişkileri belirleyebilir. Bu tahminler çeşitli açılardan büyük öneme sahiptir. Doğru tahminler, güneş enerjisi tesislerinin kapasite planlaması, enerji dağıtımı ve enerji depolama sistemlerinin optimize edilmesi gibi alanlarda önemli katkılarda bulunabilir. Enerji talebinin zaman içinde nasıl değişeceğini anlamak için kullanılabilir. Enerji şebekelerinin verimli bir şekilde yönetilmesine ve enerji arzının

taleple uyumlu hale getirilmesine yardımcı olabilir. İklim değişikliğiyle mücadelede etkili stratejiler geliştirmeye yardımcı olabilir. Sağlıklı tahminler, güneş enerjisi endüstrisinin büyümesini teşvik eder ve bu da ekonomik büyümeye ve istihdama katkı sağlar. Ayrıca, güneş enerjisi sistemlerinin daha yaygın olarak kullanılması, enerji yoksulluğuyla mücadelede ve toplumların enerji erişimine daha eşit şekilde sahip olmasında önemli bir rol oynayabilir.

Bu çalışmanın sonuçları, Türkiye'nin Doğu Anadolu bölgesindeki Muş ilinde güneş enerjisi potansiyelini daha iyi anlamak ve gelecekteki enerji stratejilerini planlamak için değerli bir kaynak olabilir. Meteorolojik özelliklerin değişkenliği nedeniyle lokasyona özgü modellerin geliştirilmesi büyük önem taşımaktadır. Güneş enerjisi tahminin etkileri sadece enerji sektörünü ilgilendirmez. Aynı zamanda çevresel ve sosyal faydalara da sebep olur. Bununla birlikte, çalışmanın sınırlamaları da göz önünde bulundurulmalıdır. Örneğin, kullanılan veri setinin kapsamı ve kalitesi, tahminlerin doğruluğunu etkileyebilir. Ayrıca, meteorolojik koşulların değişkenliği ve güneş enerjisi üretimindeki diğer faktörler de dikkate alınmalıdır.

Bu çalışmada Muş ilinin enerji potansiyelini ortaya koymak için makine öğrenmesi yöntemleri ile geçmiş veriler kullanılarak güneş enerjisi üretim kapasitesini belirlemek için güneş radyasyonu tahmini hedeflenmiştir. Çıkan sonuçlar analiz edilmiştir. Güneş radyasyonu, güneşten gelen elektromanyetik enerjidir. Bu enerji, güneşin çekirdeğinde gerçekleşen nükleer füzyon reaksiyonları sonucunda oluşur ve uzayda ışık hızıyla yayılır. Dünya atmosferine ulaştığında, atmosfer tarafından kısmen emilir, kısmen de yeryüzüne yansır. Güneş radyasyonu, güneş enerjisinin temel kaynağıdır ve hayatın devamı için büyük önem taşır.

Elde edilen sonuçlar, Muş ilinde güneş enerjisi potansiyelinin ortaya konulması için güneş radyasyonu değerlerinin tahmin edilmesinde makine öğrenmesi yöntemlerinin etkili olduğunu göstermiştir. Bu çalışma, bölgedeki güneş enerjisi kaynaklarının daha etkin kullanımı için önemli bir adım olarak değerlendirilebilir. Analiz sonuçları, Muş'un güneş enerjisi üretiminde önemli bir potansiyele sahip olduğunu ve bu potansiyelin değerlendirilmesinin bölgenin enerji ihtiyaçlarının karşılanmasına katkı sağlayabileceğini ortaya koymaktadır.

Bu çalışmada makine öğrenmesi yöntemleri ile günlük ortalama güneş radyasyonu tahmini yapılmaktadır. Bu sonuçlarla Muş ilindeki güneş enerji potansiyeli anlaşılmaya çalışılmıştır. Bu tezin ana hedefleri; Muş ilinin güneş enerjisi kaynaklarını daha iyi anlamak, makine öğrenme algoritmalarını kullanarak Muş ilinin güneş enerjisi

verilerini analiz etmek ve tahmin modelleri oluşturmak, Muş ilinin gelecekteki güneş enerjisi üretimini belirlemek ve enerji planlamasına katkıda bulunmaktır. Bu çalışma kapsamında tahmin yaparken zaman serisi ve regresyon yöntemleri olmak üzere iki tür yaklaşım kullanıldı.

Zaman serisi, belirli bir değişkenin zaman içerisindeki değerlerinin düzenli aralıklarla kaydedildiği bir veri setidir. Zaman serisi verisi, düzenli aralıklarla toplanır (günlük, haftalık, aylık, yıllık vb.). Saatlik veya günlük radyasyon değeri ölçümleri örnek verilebilir. Zaman serisi analizi, bu tür verileri anlamak, desenleri tanımlamak ve gelecekteki eğilimleri tahmin etmek için yapılan analizdir. Bu analiz, özellikle finans, ekonomi, hava durumu tahminleri, pazarlama ve birçok mühendislik alanında yaygın olarak kullanılır. Bu tezde zaman serisi ile tahminlemelerde ARIMA (Oto-regresif Bütünleşik Hareketli Ortalama) ve LSTM (Uzun Kısa Süreli Bellek) yöntemleri kullanıldı. ARIMA, zaman serilerindeki trend ve mevsimselliği modellemek için kullanılan yaygın bir yöntemdir. LSTM, derin öğrenme tabanlı bir modeldir ve özellikle karmaşık zaman serilerini modellemek için kullanılır. Zaman serisi, belirli bir süreçteki geçmiş verilerden öğrenerek gelecekteki verileri tahmin etmek için güçlü bir araçtır. Özellikle tahminleme ve desen tanıma amacıyla sıkça kullanılır.

Regresyon, bağımlı bir değişkenin (hedef değişkenin) bağımsız değişkenlere (girdi değişkenlerine) bağlı olarak nasıl değiştiğini modelleyen istatistiksel bir yöntemdir. Belirli bir matematiksel model aracılığıyla bu ilişkiyi yakalamaya çalışır. Regresyon analizi, birçok alanda karar verme sürecini yönlendirmek için güçlü bir araçtır ve özellikle makine öğrenimi ve istatistikte önemli bir yer tutar. Regresyon ile tahminlemelerde Çok Katmanlı Algılayıcılar (MLP), Random Forest (RF), XGBoost ve Destek Vektör Makineleri (SVM) makine öğrenmesi yöntemleri kullanıldı. Bu tez Giriş, Literatür, Güneş Enerjisi kavramları, Güneş Enerjisi Tahmin Yöntemleri ve Sonuçlar ve Değerlendirme ana başlıklarından oluşmaktadır.

2. LİTERATÜR

Literatürde güneş radyasyonu veya güneş enerjisi üretim tahmini için birçok çalışma yapılmıştır. Tez ile ilgili benzer çalışmalardan bazıları aşağıda verilmiştir.

Voyant ve ark. (2017) yaptıkları derleme çalışmasında, güneş enerjisi sistemlerinin güç tahmininin enerji yönetimi ve şebeke sağlığı için kritik olduğunu belirtmişlerdir. Güneş radyasyonu tahminin, bulut görüntüleri ve fiziksel modellerin birleşimi ya da makine öğrenimi yöntemleriyle yapılabileceğini ifade etmişlerdir. Bu amaçla kullanılan yaygın makine öğrenimi yöntemleri arasında yapay sinir ağları, destek vektör regresyonu, regresyon ağaçları, rastgele orman ve gradient boosting bulunmaktadır. YSA ve ARIMA yöntemlerinin tahmin kalitesi açısından eşdeğer olduğunu söylemişlerdir. Çeşitli veri setleri ve performans göstergeleri nedeniyle bu yöntemlerin karşılaştırılması zor olsa da, hibrit ve topluluk tahmin yöntemleriyle tahmin performansının artırılabilceği ifade edilmiştir.

Solano ve ark. (2022) çalışmalarında, fotovoltaik enerjinin yoğun olduğu sistemlerde güneş ışıınımı tahmininin önemini ve çeşitli makine öğrenimi yöntemleriyle tahmin doğruluğunu artıran bir topluluk özellik seçimi yöntemini ortaya koymaktadır. Yapılan değerlendirmelerde, VOA yöntemi diğer algoritmalarından daha iyi performans göstermiştir.

Aslam ve ark. (2019) çalışmalarında, mikro şebekelerde yenilenebilir enerji kaynaklarının önemini vurgulamakta ve uzun vadeli güneş enerjisi tahmininin mikro şebeke tasarımı için kritik olduğunu belirtmektedir. Çalışmada, bir yıl boyunca güneş radyasyonunu tahmin etmek için GRU, LSTM, RNN gibi derin öğrenme modelleri karşılaştırılmış ve GRU'nun en iyi sonuçları verdiği bulunmuştur. Ayrıca, bu modeller geleneksel yöntemlerle kıyaslandığında, derin öğrenme modellerinin üstün olduğu görülmüştür.

Srivastava ve ark. (2019) çalışmalarında, güneş enerjisi santralleri için güneş radyasyonu tahmininin önemini vurgulamaktadır. Çalışmada, 1 ila 6 gün sonrası için MARS, CART, M5 ve rastgele orman modelleri kullanılarak saatlik güneş radyasyonu tahminleri yapılmıştır. Veriler Hindistan'da bir kaynak merkezinden toplanmış olup, en iyi sonuç rastgele orman modelinden, en düşük sonuç ise CART modelinden elde edilmiştir.

Peng ve ark. (2021) çalışmalarında, güneş enerjisi için doğru güneş radyasyonu tahmininin önemini vurgulamaktadır. Araştırma, BiLSTM, SCA ve CEEMDAN

yöntemlerini kullanarak bir derin öğrenme modeli önermektedir. Bu model, tarihsel verileri alt modlara ayırarak önemli desenleri belirler, BiLSTM ile tahmin yapar ve SCA ile optimize eder. Dört gerçek veri setinde test edilen model, diğer yedi modelle karşılaştırıldığında daha yüksek tahmin doğruluğu sağlamıştır.

Krishnan ve ark. (2023) çalışmalarında, Hindistan'ın farklı iklim bölgeleri için saatlik global yatay ışıınımı tahmin eden bir gradient boosting modeli geliştirmiştir. Bu model, ARIMA, iki katmanlı sinir ağı ve LSTM modelleriyle karşılaştırıldığında daha iyi sonuçlar elde etmiştir. Model, güneş radyasyonu verilerinin sınırlı olduğu bölgelerde pratik bir çözüm sunmakta ve gerçek zamanlı güneş enerjisi tahmini için etkili bir yöntem olarak öne çıkmaktadır.

Kaplan ve Kaplan (2024) çalışmalarında, Weibull dağılım fonksiyonu kullanarak bir güneş radyasyonu tahmin modeli geliştirmiştir. Modelin verileri, Meteoroloji Genel Müdürlüğü'nden alınmış ve beş farklı istatistiksel ölçütü (RPE, MPE, MAPE, SSRE ve t-istatistiği) değerlendirilmiştir. Sonuçlar, modelin kabul edilebilir bir performans sergilediğini göstermektedir ve üç farklı bölgede test edilmiştir,

Mukilan ve ark. (2022) çalışmasında, çatıların üzerindeki büyük fotovoltaik panellerdeki güneş enerjisi potansiyeli makine öğrenmesi yöntemleri kullanılarak tahmin edilmiştir. Tahmin yöntemi olarak Sınırlı Boltzmann Makinesi kullanılmıştır. Model, eğitim verileri ile eğitildikten sonra test verileri ile doğrulanmıştır. Simülasyon sonuçları, R üzerinde çeşitli kütüphaneler kullanılarak gerçekleştirilmiş ve önerilen yöntemin diğer yöntemlere göre daha yüksek tahmin doğruluğu sağladığı, yaklaşık %99 doğruluk oranına ulaştığı belirtilmiştir.

Sehrawat ve ark. (2023) çalışmalarında, yapay zeka ve makine öğrenmesi teknikleri kullanarak güneş ışıınımı tahmini üzerine odaklanmaktadır. Makalede, güneş ışıınımı tahmini için kullanılan çeşitli öğrenme yöntemleri incelenmiş ve sekiz farklı makine öğrenmesi modelini birleştirerek model çeşitliliği sağlayan yeni bir toplu tahmin modeli sunulmuştur. Güneş ışıınımı tahmininde en kritik faktörler sıcaklık, bulutluluk indeksi, bağıl nem ve haftanın günü olarak belirlenmiştir. Önerilen 8-Yığınlamalı Regresyon Çapraz Doğrulama (8 STR-CV) modeli, Hindistan'ın üç farklı iklim bölgesinden elde edilen verilerle test edilmiştir ve modelin Visakhapatnam için %98,8, Nagpur için %98 ve dağlık bölge için %97,8 doğruluk oranına sahip olduğu gösterilmiştir.

Arslan ve ark. (2019) çalışmasında, Nisan 2017 ile Mart 2018 arasında Mersin'de ölçülen günlük toplam güneş radyasyonu değerleri yapay sinir ağları kullanılarak modellenmiş ve literatürdeki yaygın modellerin performansları incelenmiştir. Günlük

ortalama hava sıcaklığı, bağıl nem, rüzgar hızı, güneşlenme süresi ve bulutluluk verileri Türkiye Devlet Meteoroloji İşleri Genel Müdürlüğü'nden alınmış, güneş radyasyonu ise piranometre ile ölçülmüştür. Sonuçlara göre, incelenen modeller arasında en iyi tahmin performansı %83 R^2 metriği olmuştur.

Ariman ve ark. (2021) çalışmalarında, Samsun bölgesinin Mart 2017 ile Şubat 2019 arasındaki günlük güneş radyasyonu değerlerini tahmin etmek için Yapay Sinir Ağı (LeCun, Bengio, & Hinton) kullanılmıştır. ANN modelinde, Levenberg-Marquardt eğitim algoritması, logaritmik sigmoid ve lineer transfer fonksiyonları uygulanmıştır. En iyi model performansı, 9 farklı meteorolojik veriyi (ortalama sıcaklık, ortalama rüzgar hızı, ortalama buhar basıncı, ortalama bulutluluk oranı, güneşlenme süresi, maksimum sıcaklık, minimum sıcaklık, 5 cm derinlikteki toprak sıcaklığı) içeren giriş verileriyle elde edilmiştir. Test verileri için korelasyon katsayısı (R) 0.9603 ve ortalama kare hata (Dinsever, Gümüş, Şimşek, Avşaroğlu, & Mehmet) 0.3516 olarak bulunmuştur. Ayrıca, güneşlenme süresi ANN'ye giriş olarak verildiğinde R^2 değeri 0.9032 olarak ölçülmüştür. Bu sonuçlar, ileri beslemeli ANN modelinin güneş radyasyonu tahmini için yüksek performans sağladığını göstermektedir.

Gabralı & Aslan (2020) Güneş enerjisi potansiyelinin çoklu lineer regresyon ve yapay sinir ağları ile modellenmesi adlı çalışmalarında, İstanbul Büyükçekmece ilçesinin 2016 yılına ait meteorolojik verileri kullanılarak, güneş radyasyonunun kısa ve orta vadeli tahmini yapılmıştır.

Şahan & Okur (2016) çalışmasında, Akdeniz Bölgesi'ndeki on dört yerleşkede aylık ortalama toplam güneş ışıınımı şiddeti, yapay sinir ağı (YSA) modeli kullanılarak tahmin edilmiştir. Tahminde meteorolojik ve coğrafik veriler (örneğin, sıcaklık, nem, bulutluluk) Meteoroloji Genel Müdürlüğü'nden alınmıştır ve tahmin edilen veriler, ölçülen verilerle istatistiksel yöntemlerle karşılaştırılmıştır.

Dinsever ve ark. (2021) çalışmasında, Adıyaman ve Gaziantep istasyonlarına ait sıcaklık, nem, basınç, rüzgar, açık gün sayısı ve takvim ayı gibi verileri kullanarak ortalama güneşlenme şiddeti tahmin edilmiştir. Tahminler, Destek Vektör Makineleri yönteminin radyal, lineer ve polinom kernel fonksiyonları kullanılarak yapılmıştır.

Macit Sezikli (2023) tez çalışmasında, güneş enerji panellerinden elde edilen enerji tahminleri, meteorolojik veriler kullanılarak makine öğrenmesi yöntemleriyle yapılmıştır. Kullanılan yöntemler arasında Rastgele Orman, Karar Ağaçları, K-En Yakın Komşu, Çoklu Doğrusal Regresyon, Ridge Regresyon, Lasso Regresyon ve Doğrusal Regresyon bulunmaktadır.

Kaya (2020), güneş ışınlam şiddetinin tahmini için istatistiksel, fiziksel, makine öğrenmesi ve hibrit yaklaşımlar çalışmasında incelenmiş ve yapay sinir ağları (YSA) ile hibrit modeller önerilmiştir. Bu yöntemlerin kısa dönemli güneş ışınlam tahmini için güçlü araçlar olduğu vurgulanmıştır.

İzmirli Ayan (2018) Fotovoltaik sistemin yapay zeka algoritması ile güç tahmini adlı tez çalışmasında, çevresel faktörler (radyasyon, panel sıcaklığı, ortam sıcaklığı, rüzgar hızı, rüzgar soğuğu, nem) kullanılarak yapay sinir ağları algoritması ile fotovoltaik panellerin güç tahmini yapılmıştır. Sekiz farklı yapay sinir ağı eğitim algoritması test edilerek başarıları karşılaştırılmıştır.

Demolli ve ark. (2019) tarafından yapılan çalışmada, Niğde ili için güneşlenme şiddeti ve sıcaklık verileri kullanılarak gelecek yıl güneş panellerinden alınacak güç tahmini yapılmıştır. Tahmin için k-En Yakın Komşu, Destek Vektör Makinesi ve Lasso Regresyon makine öğrenmesi algoritmaları kullanılmıştır.

Demolli (2020) tarafından yapılan başka çalışmada, Türkiye'de 125 farklı bölgeye kurulması planlanan PV santrallerinin üreteceği elektrik gücü, makine öğrenmesi modelleriyle tahmin edilmiştir. Bu amaçla yapay sinir ağları, çoklu doğrusal regresyon (MLR) ve k-en yakın komşu regresyonu (KNNR) yöntemleri kullanılmıştır.

Göksu ve ark. (2018) tarafından yapılan İzmir Körfezi'ndeki hava durumu değişiklikleri dikkate alınarak güneş panellerinden elde edilebilecek enerji tahminleri, Yapay Sinir Ağları ve Bulanık Mantık yöntemleri ile karşılaştırılmıştır.

Geçmez ve Gençer (2020) çalışmasında, Elazığ'ın Şahinkaya Mevkii'nde bulunan 8 MW kapasiteli güneş enerji santralının üretim değerleri, meteorolojik verilere dayalı yapay zeka yöntemleri kullanılarak tahmin edilmiştir.

Eyvazov (2019) yüksek lisans tezinde, Ankara Meteoroloji İşleri Genel Müdürlüğü İstasyonu verileri kullanılarak güneş enerjisi potansiyeli tahmin edilmiş ve güneş panellerinin verimliliği analiz edilmiştir. 2013-2018 yıllarına ait günlük güneş radyasyonu verileriyle yıllık ve mevsimsel tahminler yapılmıştır. Tahminler Yapay Sinir Ağları (YSA) modeliyle gerçekleştirilmiş, Levenberg-Marquardt (LM), Bayesian Regularization (BR) ve Ölçekli Eşlenik Eğitim (ÖEE) algoritmaları kullanılarak elde edilen sonuçlar karşılaştırılmıştır. En iyi performans, $MSE = 1.11$ ile LM algoritmasından elde edilmiştir. Ayrıca, ilkbahar mevsiminde en düşük hata oranı $MSE = 1.02$ olarak bulunmuştur. Tezin uygulama bölümünde güneş panellerinin verimliliği üzerine iki pilot çalışma gerçekleştirilmiştir.

Kumruoğlu ve Ateş (2022) tarafından yapılan çalışmada güneş ışıını ve Türkiye'nin güneş enerjisi potansiyeline dair araştırmalar ele alınmış; ayrıca İskenderun Teknik Üniversitesi Kampüsü'ndeki bir bina çatısına 60 kWp kapasiteli bir güneş enerji sistemi tasarlanarak, çeşitli yazılımlar kullanılarak tahmini elektrik üretimleri hesaplanmıştır.



3. GÜNEŞ ENERJİSİ

3.1 Enerji Kavramı

Çağımızda önemli bir yere sahip olan enerji, ekonomik gelişmişlik seviyesinin göstergelerinden biri olarak kabul görülmüştür (Gülay, 2008). Geçmiş ve günümüzün toplumlarının önemli amaçlarından biri de enerji kaynaklarına sahip olabilmektir. Bu bölümde enerjinin kavramsal değerlendirmesini yapıp enerji kaynaklarından bahsedilecektir.

Enerji, kelime anlamı olarak "iş yapabilme kapasitesi" anlamına gelir ve günümüzde elektrikli cihazlar, makineler ve günlük hayatımızı kolaylaştıran birçok aletin çalışması için gerekli olan bir kavramdır (Adıyaman, 2012). Farklı formlarda bulunabilir, örneğin kinetik enerji, potansiyel enerji, ısı enerjisi, elektrik enerjisi ve kimyasal enerji gibi. Bu özellikleriyle enerji, hem doğadaki olayların hem de teknolojik süreçlerin temel bir bileşenidir. İnsanlığın başından beri yaşamın devamlılığı için enerji vazgeçilmez bir kaynaktır. Geçmişten günümüze toplumlardaki değişimler gelişen ve kullanılan enerji kaynaklarına bağlı olmuştur.

İnsanlar ilk başlarda iş yapabilmek için kendi gücünü kullanırken ilerleyen zamanlarda hayvan gücünden yararlanarak daha fazla iş üretmişlerdir. İlk zamanlarda bulunan ateş enerji kaynakları için yetersiz kaldığından odun ve kömür kullanılmış olup sonrasında buhar gücünden yararlanılmaya başlanmıştır. Günümüzde ise birden fazla enerji kaynağı vardır (Cihan, 2019). Enerji, yaşamsal ihtiyaçların en önemlilerinden biri haline gelmiştir. Üretim süreçlerinde enerji, malzemelerin işlenmesi, şekillendirilmesi, taşınması ve paketlenmesi gibi pek çok aşamada kullanılır. Üretimde gittikçe artan talepler ve gelişmiş üretim süreçleri, enerjiye duyulan ihtiyacı artırmıştır. Bir ülkenin sosyal ve ekonomik ilerlemesi için enerji önemli bir yere sahiptir. Enerji kaynaklarına erişim, bir ülkenin üretim kapasitesini ve uluslararası rekabet gücünü doğrudan etkiler. Sanayi sektöründe ilerleme, ülkedeki nüfusun artışı ve şehirleşme sonucunda artan tüketim ile enerjiye olan ihtiyaç günden güne artmaktadır (Sarıbaş, 2015).

3.2 Güneş Enerjisi

Yenilenemeyen enerji kaynakları, yer altı kaynaklarından elde edilen ve insanlığın endüstriyel devrimden bu yana enerji ihtiyaçlarını karşılamak için kullandığı temel kaynaklardır. Ancak, bu kaynaklar sınırlıdır ve zamanla tükenme riski taşırlar. Bu kaynaklar genellikle fosil yakıtlar olarak bilinir ve kömür, petrol ve doğalgaz gibi çeşitli

türlerde bulunurlar. Yenilenemeyen enerji kaynaklarının avantajlarından bahsedecek olursak yenilenemeyen enerji kaynakları, dünya genelinde yaygın olarak bulunur ve erişimi kolaydır. Gelişmiş altyapı ve teknoloji sayesinde, yenilenemeyen enerji kaynakları genellikle ekonomik fiyatlarla temin edilebilir. Yenilenemeyen enerji kaynaklarının dezavantajlarından bahsedecek olursak yenilenemeyen enerji kaynakları, sonsuz değildir ve zamanla tükenme riski taşırlar. Kaynakların tükenmesi veya azalması, enerji arzı ve fiyatlarında belirsizliklere neden olabilir. Yenilenemeyen enerji kaynaklarının çıkarılması, işlenmesi ve kullanılması da çevresel kirliliğe ve ekosistem tahribatına neden olabilir. Sonuç olarak artan çevresel endişeler ve iklim değişikliği ile yenilenemeyen enerji kaynaklarının geleceği belirsiz hale gelmiş olup yenilenebilir enerji kaynaklarına yönelik ilginin artmasını tetiklemiştir (Shahsavaria ve ark.) (Hussain ve ark., 2022)

Yenilenebilir enerji, doğal kaynaklardan sürekli olarak yenilenen ve tükenmeyen enerji türüdür. Yenilenebilir enerji kaynakları, fosil yakıtların aksine çevreye daha az zarar verir, sera gazı emisyonlarını azaltır ve iklim değişikliğiyle mücadeleye katkı sağlar. Ayrıca, bu kaynaklar sürekli olarak doğada mevcut olduğundan uzun vadede enerji güvenliğini de artırır. Günümüzde fosil yakıtların yerini, yenilenebilir enerji kaynaklarının alması yenilenebilir enerji teknolojilerin gelişmesine yön vermiştir. En çok kullanılan yenilenebilir enerji kaynakları; jeotermal enerjisi, biyokütle enerjisi, hidroelektrik enerjisi, rüzgâr enerjisi ve güneş enerjisidir.

Türkiye, yenilenebilir enerji kaynaklarının zenginliği ve çeşitliliği açısından oldukça önemli bir ülkedir. Türkiye, birçok ülkede olmayan jeotermal enerji kaynağında dünyanın %8'ne, coğrafi olarak genel konumundan dolayı önemli bir güneş enerjisi potansiyeline, yer şekilleri sebebiyle hidroelektrik enerji kaynağına ve rüzgâr enerjisi bakımından oldukça önemli bir paya sahiptir (Yılmaz, 2012) (Owusu ve Asumadu-Sarkodie, 2016)

Güneş enerjisi, dünyanın en bol ve sürekli yenilenebilir enerji kaynaklarından biridir. Güneşin, dünyaya her saniye gönderdiği enerji, insanlığın enerji ihtiyaçlarını karşılamak için büyük bir potansiyel taşır. Güneş enerjisi, panellerin güneşten gelen ışık ve ısı enerjisini kullanarak elektrik enerjisi üretmek veya ısıtmak için kullanılan bir enerji kaynağıdır. Güneş, her gün dünyaya muazzam miktarda enerji gönderir ve bu enerji, güneş panelleri aracılığıyla yakalanabilir ve çeşitli amaçlar için kullanılabilir.


Güneş enerjisi, kaynağı güneş ve güneşin çekirdeğinde olan hidrojen gazını helyuma dönüştüren füzyon reaksiyonu sonucu oluşan ışıma enerjidir. Bu reaksiyon

sonucu oluşan güneş ışınlarının çok azı da olsa dünyaya gelmektedir. Bu enerjiden güneş kollektörleri, güneş santralleri ve güneş pilleri gibi teknolojiler geliştirilerek yararlanılmıştır. Bahsi geçen bu teknolojiler sayesinde güneş enerjisi ısı enerjisi biçiminde ya da elektrik enerjisine çevrilerek dolaylı da kullanılmaktadır (Erdem ve Kadir, 2015).

Güneş enerjisinin avantajlarına değinecek olursak güneş enerjisi, sonsuz ve sürdürülebilir bir enerji kaynağıdır. Güneş, insanlığın yaşam süresinden çok daha uzun süre var olmaya devam edecek olan bir kaynaktır. Güneş enerjisi, karbon salınımını azaltarak çevreye zarar vermez. Fosil yakıtlara kıyasla, güneş enerjisi üretimi sırasında atmosfere zararlı emisyonlar salınmaz. Güneş enerjisi sistemlerinin işletme maliyetleri genellikle düşüktür. Güneş ışığı ücretsizdir ve bakım maliyetleri, diğer enerji kaynaklarına kıyasla oldukça düşüktür. Güneş enerjisi, bireylerin ve toplumların enerji bağımsızlığını artırır. Güneş enerjisi sistemleri, uzak bölgelerde elektrik sağlamak veya elektrik kesintilerinden etkilenmemek için kullanılabilir. Gelecekte güneş enerjisi, dünya genelinde enerji üretiminin önemli bir parçası haline gelmeye devam edecektir. Teknolojik gelişmeler ve artan talep, güneş enerjisi sistemlerinin daha verimli, daha ucuz ve daha yaygın hale gelmesine yol açacaktır.


Sonuç olarak, güneş enerjisi, temiz, sürdürülebilir ve geleceğin vazgeçilmez enerji kaynağı olmaya adaydır. Güneş enerjisi, enerji güvenliğini artırırken çevreye zarar vermeden insanlığın enerji ihtiyaçlarını karşılamak için büyük bir potansiyele sahiptir. Gelecek nesiller için daha temiz ve daha yaşanabilir bir dünya için güneş enerjisine yatırım yapmak önemlidir (Strielkowski ve ark., 2021).

Aşağıdaki Şekil 3.1, Şekil 3.2 ve Şekil 3.3'te dünyaya ait "Doğrudan normal ışınlama", "Küresel yatay ışınlama" ve "Fotovoltaik güç potansiyeli" ile ilgili görseller bulunmaktadır.




Şekil 3.1 Doğrudan normal ışınlama (GlobalSolarAtlas, 2024)

Dünya üzerindeki güneş enerjisi potansiyeli, yeryüzünün farklı bölgelerine ve coğrafi koşullarına bağlı olarak değişkenlik gösterir. Bazı bölgelerde güneş ışığının yoğunluğu ve süresi, diğer bölgelere göre daha yüksektir. Bu bölgeler, güneş enerjisi üretimi için daha elverişli koşullara sahiptir. Örneğin Şekil 3.1'e bakıldığında doğrudan normal ışınlamanın yoğun olduğu bölgeler Afrika, Avrupa'nın güney kısmı ve Avusturalya olarak görülmektedir. Doğrudan normal ışınlama (DNI), güneşten gelen ışınların atmosfere girip dağılmadan, doğrudan yeryüzüne ulaşmasını ifade eder. Bu tür güneş ışınları, özellikle güneş enerjisi sistemlerinde, özellikle konsantre güneş enerjisi (CSP) teknolojilerinde büyük öneme sahiptir. CSP sistemleri, aynalar kullanarak doğrudan güneş ışığını bir noktada yoğunlaştırarak ısı enerjisi üretir ve bunu elektrik üretimi için kullanır.



Şekil 3. 2 Küresel yatay ışınlama (GlobalSolarAtlas, 2024)

Küresel yatay ışınlama (Global Horizontal Irradiance - GHI), güneş ışığının bir yüzeye yatay olarak düşen toplam miktarını ifade eder. Güneş enerjisi sistemlerinin tasarımında, özellikle fotovoltaik (PV) sistemler için, GHI değerleri kullanılarak enerji üretim potansiyeli hesaplanır. Güneş radyasyonunun tüm bileşenlerini bir araya getiren bu ölçüm, dünya genelinde farklı bölgelerdeki güneş enerjisi potansiyelinin değerlendirilmesinde yaygın olarak kullanılır. Şekil 3.2 incelendiğinde Dünyada Küresel Yatay Işınlama potansiyeli, ekvator çevresindeki tropikal bölgelerde ve çöl iklimlerinin yaygın olduğu alanlarda daha yüksek olduğu görülmektedir. GHI potansiyelinin en iyi olduğu bölgeler genellikle bol güneş alan, az bulutlu yerlerdir.




Şekil 3.3 Fotovoltaik güç potansiyeli (GlobalSolarAtlas, 2024)

Fotovoltaik güç potansiyeli, bir bölgedeki güneş enerjisi kaynaklarının ne kadar verimli bir şekilde elektrik enerjisine dönüştürülebileceğini gösterir. Şekil 3.3'te görülebilen yüksek fotovoltaik potansiyeli olan bölgeler, güneş enerjisi projeleri için daha uygun ve karlı alanlardır. Güneş ışınlamı, fotovoltaik sistemlerin verimliliğini doğrudan etkileyen en önemli faktördür. Yüksek güneş ışınlamı alan bölgelerde fotovoltaik potansiyel daha yüksektir.

Dünyada güneş enerjisinden elektrik enerjisi üretiminde farklı yöntemler mevcuttur. Bu yöntemlerden bir tanesi fotovoltaik (PV) sistemlerdir. PV, güneş ışığını doğrudan elektrik enerjisine dönüştüren teknolojilerdir. Şekil 3.4'te PV sistemlerine örnek bir yapı vardır. Güneş panelleri, güneş enerjisini elektriğe dönüştüren fotovoltaik hücrelerden yapılır. Bu dönüşüm, yarı iletken malzemelerden yapılmış güneş panelleri aracılığıyla gerçekleşir. Fotovoltaik kelimesi, "foto" (ışık) ve "voltaik" (elektrik) kelimelerinin birleşiminden gelir, yani güneş ışığından elektrik üretimini ifade eder.


Güneş panelleri, güneşten gelen fotonları (ışık parçacıkları) yakalar. Paneller genellikle silikon gibi yarı iletken malzemelerden üretilir. Yarı iletken malzemenin üzerine gelen fotonlar, malzemedeki elektronları uyarır ve serbest bırakır. Bu serbest elektronlar, elektrik akımını oluşturur. Bu, elektrik üretmek için gereken akımı yaratan fotoelektrik etki olarak bilinir. Güneş panelleri doğru elektrik akımı üretir. Bu daha sonra bir invertörden geçirilerek alternatif akıma dönüştürülür ve bu akım şebekeye yönlendirilir veya panelleri kurulu evler ve işyerleri tarafından kullanılır. Elektrik depolamak için bataryalar kullanılabilir. Bataryalar, gece veya bulutlu günlerde enerjiye erişim sağlar, böylece elektrik kesintileri sırasında bile enerji sağlanabilir. Bu sistemlerin ilk kurulum maliyetleri yüksek olabilir. Güneş ışığına bağlı oldukları için bulutlu veya yağmurlu havalarda enerji üretimi düşebilir. Fotovoltaik sistemler, yenilenebilir enerji üretiminin temel taşlarından biri olarak, dünya genelinde temiz enerjiye geçişin önemli bir parçası haline gelmiştir (Hussain ve ark., 2022).



Şekil 3.4 Güneş Panelleri Sisteminin Tasarlanması (Köroğlu, 2010)

Başka bir yöntem ise Yoğunlaştırılmış Güneş Enerjisi (CSP- Concentrated Solar Power) sistemleridir. Bu sistemlerin farklı yaklaşımları Şekil 3.5'te gösterildi. Güneş

ışığını aynalar ve merceklerle odaklayarak yoğunlaştıran ve bu yoğunlaştırılmış ışığı ısı enerjisine dönüştüren bir teknolojidir. Odaklanan ışık, genellikle bir ısı taşıyıcı sıvıyı ısıtır. Bu ısı taşıyıcı sıvı yüksek sıcaklıklara ulaşır ve buhar elde edilir. Bu ısı enerjisi daha sonra buhar türbinleri veya diğer mekanizmalar aracılığıyla elektrik enerjisine çevrilir. CSP teknolojileri, genellikle büyük ölçekli güneş enerjisi projelerinde kullanılır ve günümüzde güneş enerjisinden elektrik üretiminde önemli bir rol oynamaktadır. Bazı CSP sistemlerinde, ısı depolama teknolojisi kullanılarak enerjinin gece veya güneşin olmadığı saatlerde de kullanılabilmesi sağlanır. Bu depolama genellikle erimiş tuz gibi malzemelerle yapılır, çünkü bu malzemeler yüksek sıcaklıkta enerjiyi uzun süre depolayabilir. CSP sistemlerinin kurulumu, PV sistemlere göre daha karmaşık ve maliyetlidir. CSP sistemleri doğrudan güneş ışığına ihtiyaç duyduğundan, sadece çok güneşli bölgelerde etkili olur. Bulutlu veya soğuk bölgelerde verimsiz hale gelebilir (Alami ve ark., 2023).



Şekil 3.5 Örnek CSP Sistemleri (Rodat ve Thonig, 2024)


Fotovoltaik ve yoğunlaştırılmış güneş enerjisi sistemlerinin bir arada kullanıldığı PV-CSP Hibrit Sistemlerde mevcuttur. Her iki teknolojinin avantajlarını bir araya getirerek güneş enerjisi üretiminde daha yüksek verimlilik ve esneklik sağlamak amacıyla yapılan hibrit sistemlerdir. PV-CSP hibrit sistemleri, güneş enerjisinden elektrik üretimini

optimize etmek için tasarlanmıştır ve her iki teknolojinin de güçlü yönlerinden yararlanır (Ju ve ark., 2017).

3.3 Türkiye’de Güneş Enerjisi

Türkiye gibi güneş ışınlarının bol olduğu bir ülke için, güneş enerjisi potansiyeli oldukça yüksektir. Türkiye, coğrafi konumu ve iklim özellikleri nedeniyle güneş enerjisi için uygun bir ortama sahiptir. Özellikle Akdeniz ve Güneydoğu Anadolu bölgeleri, yıl boyunca güneş ışınlarına daha fazla maruz kalmaktadır. Ülkenin çoğu bölgesinde güneş ışınları yoğun ve sürekli. Bu durum, Türkiye'nin güneş enerjisi üretimi için ideal bir ortam sunduğunu göstermektedir. Şekil 3.6’da Türkiye Güneş Enerjisi Potansiyeli Atlasına yer verilmiştir. Şekilde görüldüğü üzere Türkiye’nin güney kısımlarında güneş enerjisi potansiyelinin yüksek olduğu görülmektedir.

Yenilenebilir Enerji Genel Müdürlüğü verilerine göre Türkiye'nin ortalama yıllık toplam güneşlenme süresi 2640 saat, ortalama toplam ışıınım şiddeti 1311 KWh/m²-yıl olduğu tespit edilmiştir. Türkiye'nin yaklaşık 56,000 MW’lık bir termik santral kapasitesine eşdeğer güneş enerjisi kapasitesine sahip olduğu ve bu potansiyelin hayata geçirilmesi halinde, yıllık ortalama 380 milyar kWh elektrik enerjisi üretme imkanı olduğu belirlenmiştir.



Şekil 3.6. Türkiye güneş enerjisi potansiyeli atlası (GlobalSolarAtlas, 2024)

Türkiye, güneş enerjisi sektöründe önemli adımlar atmıştır. Özellikle son yıllarda, devlet destekli teşvikler ve yenilenebilir enerjiye olan talebin artmasıyla birlikte güneş enerjisi kurulumları hızla artmıştır. Büyük ölçekli güneş enerjisi santralleri (GES) ülke

genelinde kurulmuş ve faaliyete geçmiştir. Ayrıca, çatı üstü güneş enerjisi sistemleri de özellikle endüstriyel tesisler ve konutlar için giderek daha popüler hale gelmektedir.


3.4 Muş İli Güneş Enerjisi Potansiyeli

Muş, Türkiye'nin Doğu Anadolu Bölgesi'nde yer alan bir şehirdir. Coğrafi konumu ve iklim özellikleri nedeniyle güneş enerjisi için oldukça uygun bir ortama sahiptir. Muş, genellikle karasal iklim özelliklerine sahiptir. Yazları sıcak ve kurak, kışları ise soğuk ve kar yağışlı bir iklim görülür. Ancak, buna rağmen Muş genellikle güneşli gün sayısı oldukça fazladır. Bu durum, şehrin güneş enerjisi potansiyelini artırır (Tugal ve Sevgin, 2023).

Muş'un coğrafi konumu ve iklim özellikleri, güneş enerjisi potansiyelini artırmaktadır. Özellikle yaz aylarında uzun ve güneşli günler, güneş panellerinin verimli bir şekilde enerji üretmesini sağlar. Muş'un güneş enerjisi potansiyeli, güneş ışınlarının bol olduğu zamanlarda yüksektir ve bu da şehri güneş enerjisi yatırımları için cazip hale getirir. Muş'ta güneş enerjisi sektörü henüz gelişme aşamasındadır. Ancak, son yıllarda Türkiye genelinde olduğu gibi Muş'ta da güneş enerjisi projeleri ve kurulumları artmaktadır. Özellikle tarımsal sulama sistemlerinde güneş enerjisi kullanımı yaygınlaşmaktadır. Ayrıca, bazı endüstriyel tesisler ve kamu binaları da çatı üstü güneş enerjisi sistemleri kurmaktadır. Muş'ta güneş enerjisi potansiyelinin farkına varılmasıyla birlikte, yerel yönetimler ve enerji şirketleri güneş enerjisi projelerini teşvik etmek için çaba göstermektedir. Bu çabaların artmasıyla birlikte, Muş'un güneş enerjisi sektöründe daha da büyümesi beklenmektedir.


Muş ilinin yıllık güneşlenme süresi 3247 saattir (Ozcelik, 2022). Günlük bazda hesaplandığında yaklaşık ortalama 9 saate denk gelmektedir. Güneş Enerjisi Potansiyel Atlası (GEPA) verilerine göre ise Muş ilinde ortalama günlük güneşlenme süresi 7,36 saate sahiptir (GEPA, 2024). Bu değerler, Muş ilinin hem yıllık güneşlenme süresinin ülke ortalamasının üzerinde olduğunu göstermektedir.

Şekil 3.7'de Muş iline ait sıcaklık haritası gösterilmektedir. Açık yeşil ile gösterilen alanlarda sıcaklık değerlerinin yüksek olduğu görülmektedir. Sarı ile gösterilen alanlarda orta düzeyde sıcaklık değerleri, kırmızı ile gösterilen alanlarda sıcaklık değerlerinin düşük olduğu görülmektedir.



Şekil 3.9 2018-2023 Muş ili aylık bazda ortalama günlük güneşlenme süreleri

Şekil 3.10’da Muş ili 2018- 2023 yıllarına ait ölçüm sonuçlarına göre global güneş radyasyonu dağılımı gösterilmektedir.



Şekil 3.10 2018 – 2023 Global güneş radyasyonu dağılımı

Potansiyeline göre enerji yatırımları Muş İlinde beklentinin altındadır. Muş ilinde lisans alınmış ve ekonomiye katkı sağlayan güneş enerjisi yatırımları azdır. Bunlardan ikisi CS grup bünyesinde yatırımlardır. Yurt Çimento’nun 2016 yılında kurduğu güneş enerjisi santrali 2.20 MWp gücündedir. Yine aynı grup şirketi Ado Enerji firması

tarafından 5.50 MWp gücündeki GES, 2021 yılında devreye alınmıştır. Korkut İlçesinde özel bir işletme tarafından 20 dönüm araziye kurulan 1 MW kapasiteli GES vardır. Korkut'ta Muş Belediyesinin hayata geçirdiği Lale GES projesi 123 bin metrekare alan üzerinde kurulu ve 4.6 MW enerji üretim kapasitesine sahiptir. Hayata geçirilmesi düşünülen Alparslan GES projesi ise 62,74 hektar alanda ve 41,9916 megawatt (MW) maksimum güç kapasitesine sahip olacaktır (Özer, 2023).



4. GÜNEŞ ENERJİSİ TAHMİN YÖNTEMLERİ

4.1 Zaman Serisi ile Tahminleme

Zaman serileri, belirli bir zaman aralığında gözlemlenen veri noktalarının bir dizisidir. Finansal piyasalardan hava durumuna, tıbbi verilere kadar birçok alanda zaman serileri kullanılır. Bu verileri analiz etmek ve gelecekteki değerleri tahmin etmek, çeşitli alanlarda bilimsel ve iş kararlarını desteklemek için önemlidir. Zaman serisi tahminleme, belirli bir zaman diliminde meydana gelen gözlemlerin analizi ve bu gözlemlerden gelecekteki değerleri tahmin etme yöntemidir. Zaman serisi verileri, genellikle belirli bir zaman aralığında düzenli olarak kaydedilen verilerdir. Bu veriler, genellikle tarihsel verilerden oluşur ve zamanla değişen trendleri, mevsimsellikleri ve döngüsel hareketleri içerebilir (Chatfield ve Xing, 2019). Bu tezde güneş radyasyonu tahmini için LSTM ve ARIMA zaman serisi tahmin yöntemleri kullanılmıştır. Bu yöntemlerin başarısı, güneş enerjisi kaynaklarının daha etkin bir şekilde kullanılması ve Muş ilinin enerji ihtiyaçlarının karşılanmasına katkı sağlayacaktır. Muş ilindeki güneş enerjisi potansiyelini daha iyi anlamamıza ve gelecekteki enerji stratejilerini planlamamıza yardımcı olacaktır.

4.1.1 ARIMA (Otoregresif Bütünleşik Hareketli Ortalama)

ARIMA (Autoregressive Integrated Moving Average) modeli, zaman serilerinin istatistiksel analizi ve tahmini için yaygın olarak kullanılan bir araçtır. ARIMA modeli, zaman serilerinin istatistiksel analizi ve tahmini için güçlü bir araçtır. Doğru parametrelerle uygun şekilde uygulandığında, gelecekteki değerleri tahmin etmede ve veri analizinde değerli bir araç sağlar (Hyndman ve Athanasopoulos, 2018).

ARIMA modeli, üç ana bileşen olan AR (Autoregressive), I (Integrated) ve MA (Moving Average) bileşenlerini birleştirir (Jenkins ve Box, 1976). Her bir bileşen, zaman serisinin farklı özelliklerini modellemek için kullanılır.

AR (Autoregressive): AR bileşeni, bir zaman serisinin önceki dönem değerlerine bağlı olduğunu varsayar. Bir ARIMA (p, d, q) modelinde, p terimi, p adet önceki dönem değerinin kullanıldığını belirtir (Chatfield ve Xing, 2019).

I (Integrated): I bileşeni, zaman serisinin durağan olmadığını belirtir. Zaman serisinin durağan hale getirilmesi için fark alma işlemine işaret eder. Bir zaman serisi durağan değilse (yani, ortalama veya varyans zamanla değişiyorsa), ARIMA modeli, farklarının alınmış bir versiyonunu kullanarak durağan hale getirir (Jenkins & Box, 1976).

MA (Moving Average): MA bileşeni, mevcut dönem değerinin rastgele gürültüler (hata terimleri) tarafından etkilendiğini varsayar. MA terimi, önceki dönem hata terimlerinin bir lineer kombinasyonu olarak ifade edilir (Chatfield ve Xing, 2019).

ARIMA yönteminin güneş enerjisi üretim tahmini için düşünüldüğünü varsayalım. AR bileşeni, geçmiş güneş enerjisi üretim verilerinin mevcut değerlerini tahmin etmek için kullanılır. Denklem 4.1 ile ifade edilebilir (Jenkins ve Box, 1976).

$$x_t = c + \sum_{i=1}^p \phi_i x_{t-i} + \varepsilon_t \quad (4.1)$$

Burada x_t mevcut zaman noktasındaki güneş enerjisi üretimi, c bir sabit terim, ϕ_i otoregresif katsayılar yani model parametreleri, p kullanılacak geçmiş değerlerin sayısı ve ε_t ise gürültü veya hata terimidir.

MA bileşeni, geçmiş hataların mevcut değerleri tahmin etmek için kullanılır. Denklem 4.2 ile ifade edilebilir (Box ve ark., 2015).

$$x_t = \mu + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (4.2)$$

Burada μ ortalama, θ_i hareketli ortalama katsayıları ve q geçmiş hata terimlerinin sayısıdır. Entegrasyon bileşeni, zaman serisinin durağan olup olmadığını belirler. Eğer durağan değilse, bir dereceye kadar fark alarak durağan hale getirilir. Bu formüller, ARIMA modelinin temel bileşenlerini temsil eder. Güneş enerjisi tahmininde kullanılırken, bu bileşenler uygun şekilde uyarlanır ve modelin belirlenmesi için çeşitli istatistiksel yöntemler kullanılır.

ARIMA modelinin temel parametreleri, p , d ve q 'dur. p , AR terimlerinin sayısını belirtir. d , durağanlık olmayan bileşenin derecesini belirtir. Bu, fark alma işleminin kaç kez gerçekleştirileceğini ifade eder. q ise, MA terimlerinin sayısını belirtir. Bu parametreler, modelin zaman serisine ne kadar iyi uyduğunu ve gelecekteki değerleri ne kadar doğru tahmin edebileceğini belirler (Jenkins ve Box, 1976).

ARIMA modelinin uygulanması genellikle şu adımları içerir (Hyndman & Athanasopoulos, 2018). Zaman serisi verileri görsel olarak incelenir ve gerektiğinde ön işleme adımları uygulanır (eksik verilerin doldurulması, aykırı değerlerin düzeltilmesi vb.). ARIMA modeli, veriye uygun parametrelerle uyum sağlamalıdır. Bu, parametrelerin deneme yanılma yöntemiyle seçilmesini veya otomatik model seçimi tekniklerinin

kullanılmasını içerebilir. Seçilen ARIMA modeli, veriye ne kadar iyi uyduğunu ve gelecekteki değerleri ne kadar doğru tahmin ettiğini değerlendirmek için uygun metriklerle değerlendirilir. Model, gelecekteki değerleri tahmin etmek için kullanılır. Tahminlerin güven aralıkları genellikle hesaplanır ve tahminlerin ne kadar güvenilir olduğunu gösterir.


ARIMA modelleri, çok yönlülüğü ve basitliği nedeniyle enerji sistemleri alanında yaygın olarak kullanılmaktadır. Başarılı ve kaliteli tahmin becerisinden dolayı ARIMA modelleri enerji endüstrisindeki zaman serisi değerlerini tahmin etmede en popüler yaklaşımlar arasındadır. Ancak modelin yeterliliğinin mevcut verilerle kontrol edilmesi oldukça önemlidir (Chodakowska ve ark., 2023).

4.1.2 LSTM (Uzun Kısa Süreli Bellek)

Derin öğrenme, makine öğrenmesi alanında büyük bir devrim yaratan ve birçok karmaşık problemi çözmeye yardımcı olan bir alan olarak ortaya çıktı. LSTM (Long Short Term Memory), zaman serileri, doğal dil işleme ve diğer birçok alanda kullanılan önemli bir derin öğrenme modelidir (Hochreiter ve Schmidhuber, 1997).

LSTM, RNN (Recurrent Neural Network - Tekrarlayan Sinir Ağı) ailesine aittir ve özellikle zaman serileri gibi zamanla değişen verilerle çalışırken karşılaşılan sorunları çözmek için tasarlanmıştır. Standart RNN'ler, kısa vadeli bağımlılıkları modelleme konusunda iyidir, ancak uzun vadeli bağımlılıkları başarılı bir şekilde yakalayamazlar. LSTM, bu tür problemleri çözmek için tasarlanmış özel bir RNN türüdür (Greff ve ark., 2016).

LSTM, zaman serileri ve doğal dil işleme gibi alanlarda uzun vadeli bağımlılıkları başarılı bir şekilde modelleyen güçlü bir derin öğrenme modelidir (Goodfellow ve ark., 2016). Karmaşık ilişkileri yakalayabilme yeteneği, çeşitli uygulamalarda LSTM'nin yaygın bir şekilde kullanılmasını sağlar. Ancak, büyük veri setleri ve karmaşık yapılar gerektirebileceği için eğitim süreci bazen zaman alabilir.



Şekil 4.1 LSTM Yapısı (Wang ve ark., 2022)

LSTM'nin ana bileşenleri şunlardır:

Hücre Durumu (Cell State): LSTM'nin merkezinde bulunan bilgi taşıyıcısıdır. Hücre durumu, ağın her biriminde taşınır ve bilginin akışını kontrol eder.

Kapılar (Gates): LSTM'nin en önemli özelliği, kapıların kullanılmasıdır. Kapılar, bilginin akışını kontrol eder ve hangi bilginin hücre durumuna ekleneceğini veya çıkarılacağını belirler. Üç ana kapı vardır. Unutma Kapısı (Forget Gate), hücre durumuna hangi bilgilerin eklenmeyeceğini belirler. Girdi Kapısı (Input Gate), yeni bilgilerin hücre durumuna eklenmesini belirler. Çıkış Kapısı (Output Gate), hücre durumundan hangi bilgilerin çıkacağını belirler.

Hücresel Aktivasyon Fonksiyonları: LSTM'de kullanılan aktivasyon fonksiyonları, diğer sinir ağı modellerinde olduğu gibi, girişleri ve çıkışları non-lineer hale getirir.

Bir LSTM ağı, birbirine bağlı birçok LSTM hücresinden oluşur. Her bir hücre, önceki zaman adımlarından gelen girdileri ve hücre durumunu alır, bu girdileri işler ve yeni hücre durumunu ve çıkışı üretir. Bu yapı, uzun vadeli bağımlılıkları başarılı bir şekilde yakalayabilen karmaşık ilişkileri modellemek için kullanılır.

LSTM'nin birçok uygulaması vardır, bunlardan bazıları şunlardır. LSTM, geçmiş zaman serisi verilerine dayanarak gelecekteki değerleri tahmin etmek için kullanılabilir. Özellikle hisse senedi fiyatları, hava durumu gibi zamanla değişen verilerde etkilidir. LSTM, dil modelleri oluşturmak, metin sınıflandırması yapmak, duygu analizi gibi doğal dil işleme görevlerinde kullanılır. Metin verilerinin uzun vadeli bağımlılıklarını başarılı bir şekilde modelleyebilir. LSTM, zamanla değişen bir sensör verisi alındığında, belirli

bir hareket veya aktivite tespiti gibi görevlerde kullanılabilir (Hochreiter ve Schmidhuber, 1997).

LSTM modelleri, genellikle birden fazla katmandan oluşur ve bu katmanlar modelin öğrenme kapasitesini artırmak için ardışık olarak bağlanabilir. Tek katmanlı bir LSTM modeli, veriyi doğrudan girişten çıkışa işler ve temel zaman serisi tahminleri için yeterli olabilir. Ancak, daha karmaşık zaman serilerinde derin LSTM modelleri tercih edilir. Bu modellerde, birden fazla LSTM katmanı ardışık olarak eklenir ve her katmanın çıktısı bir sonraki katmanın girdisi olarak kullanılır. Derin LSTM modelleri, daha kompleks veri yapılarını öğrenme kapasitesine sahiptir, ancak daha fazla hesaplama gücü ve daha uzun eğitim süreleri gerektirir. Giriş kapısı i_t ikinci bir kapı c_t^* ile birlikte, t anında bellek durumuna c_t depolanan yeni bilgiyi kontrol eder. Unutma kapısı f_t , $t - 1$ anında bellek hücresinde kaybolması veya tutulması gereken geçmiş bilgiyi kontrol ederken, çıkış kapısı o_t bellek hücresinin çıktısı için hangi bilginin kullanılabileceğini kontrol eder. Aşağıdaki denklemler LSTM birimlerinin yaptığı işi göstermektedir.

$$i_t = \sigma(U_i x_t + W_i h_{t-1} + b_i) \quad (4.3)$$

$$f_t = \sigma(U_f x_t + W_f h_{t-1} + b_f) \quad (4.4)$$

$$c_t^* = \tanh(U_c x_t + W_c h_{t-1} + b_c) \quad (4.5)$$

$$c_t = g_t \odot c_{t-1} + i_t \odot c_t^* \quad (4.6)$$

$$o_t = \sigma(U_o x_t + W_o h_{t-1} + b_o) \quad (4.7)$$

Burada x_t girişi, W_* ve U_* ağırlık matrislerini, b_* bias teriminin vektörlerini, σ sigmoid fonksiyonunu ve $\odot$ operatörü bileşen bazlı çarpımı belirtir. Bellek hücresinin çıktısını oluşturan gizli durum h_t şu şekilde hesaplanır.

$$h_t = o_t \odot \tanh(c_t) \quad (4.8)$$

LSTM hücrelerinde çoğunlukla sigmoid ve tanh fonksiyonları tercih edilir çünkü bu fonksiyonlar bilgi akışının kontrol edilmesinde etkin rol oynar. Her LSTM katmanının hem bellek durumu c_t hem de gizli durumu h_t bir sonraki LSTM katmanına girdi olarak iletilir. LSTM modelinin her bir hücresinde kullanılan aktivasyon fonksiyonları, modelin çıktılarını ve bilgi akışını kontrol eder (Livieris ve ark., 2020).

Sigmoid Fonksiyonu, kapı mekanizmalarının (unutma, giriş ve çıkış kapıları) kararlarını belirlemek için kullanılır. Sigmoid fonksiyonu, her kapının çıkışını 0 ile 1 arasında sınırlar. Bu sayede, hücreye girecek ya da çıkacak bilginin ne kadarının kullanılacağı belirlenir. Örneğin, unutma kapısında 0 değeri, önceki hücre durumunun tamamen unutulacağını, 1 değeri ise tüm bilginin korunacağını ifade eder.

Tanh (Hyperbolic Tangent) Fonksiyonu, LSTM hücresinin durumunu güncellerken kullanılır. Tanh fonksiyonu, giriş vektörlerini -1 ile 1 arasında dönüştürerek hücreye eklenecek yeni bilgilerin ölçeklendirilmesini sağlar. Bu fonksiyon, serinin eğilimlerini yumuşatır ve hücre durumunun daha dengeli bir şekilde güncellenmesine yardımcı olur. Bazı durumlarda, LSTM'nin çıktısında ReLU (Rectified Linear Unit) gibi diğer aktivasyon fonksiyonları da kullanılabilir.

LSTM modelinin kurulumu sırasında, modelin öğrenme kapasitesini belirleyen önemli parametreleri arasında hücre sayısı (nöronlar) ve geri yayılım algoritması yer alır. Modelin eğitimi sırasında, zaman serisi verisinin uzun vadeli özelliklerini öğrenmek için genellikle Adam gibi optimize edici algoritmalar kullanılır. Ayrıca, modelin overfitting yapmasını önlemek için dropout gibi düzenleme teknikleri kullanılabilir. Modelin çıktı katmanında, genellikle lineer aktivasyon fonksiyonu kullanılarak zaman serisi tahmini yapılır.

4.2 Regresyon ile Tahminleme

Regresyon, bir değişkenin (bağımlı değişken) diğer bir veya daha fazla değişkenle (bağımsız değişkenler) olan ilişkisini modelleyerek, bu ilişkiden yola çıkarak tahminler yapma yöntemidir. Bağımlı değişken, tahmin edilmek istenen değişkendir. Bağımsız değişkenler, bağımlı değişkenin tahmininde kullanılan değişkenlerdir. Regresyon analizi, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi temsil eden matematiksel bir model oluşturur. Regresyon analizi, özellikle sayısal veriler üzerinde çalışarak, değişkenler arasındaki ilişkiyi anlamak ve bu ilişkiyi kullanarak gelecekteki değerleri tahmin etmek için yaygın olarak kullanılır. Veriler arasındaki ilişkiyi anlamak ve bu ilişkilerden yola çıkarak tahminlerde bulunmak için güçlü bir araçtır. Doğru uygulandığında, karar alma süreçlerini destekler ve çeşitli alanlarda etkili çözümler sunar. Güneş enerjisi sistemlerinin verimliliğini artırabilir ve enerji üretiminde sürdürülebilir çözümler sunar.


Güneş enerjisi tahmininde regresyon, güneş radyasyonu, sıcaklık, nem, rüzgar hızı gibi meteorolojik değişkenleri kullanarak güneş enerjisi potansiyelini tahmin etme

sürecinde kullanılabilir. Bu yöntem, geçmiş verilerden yola çıkarak gelecekteki güneş enerjisi üretimini öngörmeyi amaçlar. Bağımsız değişkenlerimiz sıcaklık, nem, rüzgar hızı ve bağımlı değişkenimiz güneş radyasyonu olsun. Bu durumda gelecekteki güneş radyasyonu değerleri regresyon yöntemleri ile tahmin edilebilir.

4.2.1 MLP (Çok Katmanlı Algılayıcı)

MLP, en az bir gizli katmana sahip olan ve genellikle en az bir giriş ve bir çıkış katmanı bulunan yapay sinir ağlarının bir türüdür. Her katman, birbirine bağlı nöronlar içerir ve bu nöronlar arasındaki bağlantılar ağırlıklarla belirlenir. MLP, çeşitli makine öğrenimi görevlerinde kullanılabilir (Goodfellow ve ark., 2016)

Giriş katmanı, verilerin doğrudan ağı girdiği yerdir. Çıkış katmanı, ağın sonucunu üreten katmandır. Gizli katmanlar, giriş ve çıkış katmanları arasında bulunan ve genellikle problemi çözmek için karmaşık ilişkileri öğrenmek için kullanılan katmanlardır (Nielsen, 2015).



Şekil 4.2 MLP sinir ağı (Al-Aboodi ve ark., 2017)

Bir MLP, eğitim veri setini kullanarak ağırlıklarını ve bias değerlerini ayarlayarak öğrenir. Geriye yayılım algoritması, genellikle bu eğitim sürecinde kullanılan bir tekniktir. Bu algoritma, ağın ürettiği çıktı ile gerçek çıktı arasındaki hatayı minimize etmek için ağı geriye doğru (çıkıştan girişe doğru) hareket ettirir (Rumelhart ve ark., 1986).


MLP, derin öğrenme alanında önemli bir role sahiptir. Bu ağlar, çeşitli makine öğrenimi problemlerinde kullanılabilir ve yeterli veri ve uygun yapılandırma ile yüksek performans sergileyebilirler. Ancak, aşırı uyum gibi bazı zorluklarla karşılaşabilirler, bu

nedenle dikkatli bir şekilde eğitilmeleri ve yapılandırılmaları önemlidir (LeCun ve ark., 2015).

4.2.2 Random Forest (Rasgele Orman)

Random Forest, birçok karar ağacının bir araya gelmesiyle oluşturulan bir topluluk öğrenme modelidir (Breiman, 2001). Her bir karar ağacı, rastgele seçilen alt örneklem veri kümesi ve rastgele seçilen özelliklerle eğitilir. Bu, her ağacın birbirinden farklı olmasını sağlar. Ardından, sınıflandırma görevlerinde, her ağacın sınıflandırma tahminleri toplanarak veya regresyon görevlerinde ortalama alınarak birleştirilir (Liaw ve Wiener, 2002).

Random Forest'ün temel prensibi, birçok zayıf tahminciyi (karar ağaçları) bir araya getirerek güçlü bir tahminci oluşturmaktır. Her bir karar ağacı, veri setinin bir alt kümesi üzerinde eğitilir ve belirli bir alt küme içinde rastgele seçilen özelliklerle oluşturulan ağaçlar, aşırı uyum riskini azaltır. Topluluk öğrenme prensibi, bu zayıf tahmincilerin bir araya getirilerek daha sağlam ve genelleştirilebilir bir tahmincinin oluşturulmasını sağlar (Hastie ve ark., 2009).




Şekil 4.3 Rastgele Orman Regresyonu (Sohal ve ark., 2023)

4.2.3 XGBoost (eXtreme Gradient Boosting)

Makine öğrenimi alanında hızla popülerlik kazanan XGBoost, özellikle sınıflandırma ve regresyon problemleri için etkili bir tahminleme aracı olarak öne çıkıyor. GBoost, bir tür topluluk (ensemble) yöntemidir ve bu yöntemde birden fazla zayıf öğrenici (örneğin karar ağaçları) ardışık olarak eğitilir. Her adımda hatalar düzeltilir ve

her yeni model, bir önceki modelin hatalarına odaklanarak eğitilir. Amaç, her adımda hatayı azaltmak ve böylece güçlü bir öğrenici oluşturmaktır. XGBoost, hatayı minimize etmek için gradyan iniş yöntemini kullanır. Gradyan iniş, bir kayıp fonksiyonuna (örneğin ortalama karesel hata - MSE) dayalı olarak tahmin hatalarını azaltmaya çalışır. XGBoost (eXtreme Gradient Boosting), düşük hata oranlarına sahip modeller oluşturmak için sıklıkla tercih edilen bir algoritmadır. Hem hızlı çalışması hem de yüksek performansı ile öne çıkar (Chen & Guestrin, 2016).

XGBoost'un temelini oluşturan " Gradyan Artırma - Gradient Boosting" yöntemi, zayıf tahminleyicileri (genellikle karar ağaçları) bir araya getirerek güçlü bir tahminleyici oluşturma fikrine dayanır. Bu yöntem, bir önceki tahminleyicinin hatalarını düzeltmeye odaklanır. Yani, ardışık olarak yeni tahminleyiciler ekleyerek, her bir tahminciden sonra kalan hataları azaltmaya çalışır (Friedman, 2001). XGBoost regresyon, güçlü bir algoritma olup, veri setlerinin büyüklüğüne ve karmaşıklığına rağmen yüksek doğruluk ve performans sunar.




Şekil 4.4 XGBoost (Piraei ve ark., 2023)

4.2.3. SVM (Destek Vektör Makineleri)

SVM (Support Vector Machines), özellikle sınıflandırma problemleri için geliştirilmiş bir makine öğrenimi algoritmasıdır. SVM'nin temel amacı, veri noktalarını farklı sınıflara ayırmak için bir karar sınırı oluşturmaktır. Bu karar sınırı, veri noktalarını sınıflar arasında mümkün olan en geniş bir boşluk (margin) ile ayırmaya çalışır. SVM, bu amaçla destek vektörlerini kullanır. SVM, verileri ayıran bir düzlem veya hiperdüzlem oluşturur. Bu hiperdüzlem, sınıflar arasında maksimum marj (margin) oluşturarak, iki sınıfı en iyi şekilde ayırır. Veriler lineer olarak ayrılamıyorsa, SVM çekirdek

fonksiyonları kullanarak verileri daha yüksek boyutlu bir uzaya dönüştürür. Bu, karmaşık sınırların oluşturulmasını sağlar. Seçilen çekirdek fonksiyonu ile model, eğitim verileri üzerinde eğitilir. SVM, optimizasyon algoritmaları kullanarak en iyi hiperdüzlemi belirler. SVM regresyon problemleri için de kullanılabilir. Support Vector Regression (SVR) olarak adlandırılır. SVM'in temel prensiplerine dayanarak, SVR veriler arasında bir sınırlayıcı hiper-düzlem yerine verilerin doğrusal veya doğrusal olmayan bir fonksiyonla tahmin edilmesini sağlar. Bu fonksiyon, verilerin çoğunun içine sığıdığı bir tolerans bandı etrafında tanımlanır. SVR, tahmin edilen ve gerçek değerler arasındaki farkın belli bir tolerans (ϵ) içinde olmasını sağlar. Yani, model bu bandın içine düşen küçük hataları göz ardı eder ve bu tolerans bandı dışındaki veriler için cezalar (slack variables) devreye girer. SVR'de, destek vektörleri bu tolerans bandının dışında kalan ve modelin tahmin fonksiyonunu etkileyen veri noktalarıdır (Miyama, 2016).



Şekil 4.5 ϵ -insensitive kayıp fonksiyonuyla regresyon (Belaid, S. ve Mellit, A. (2016)

4.3 Öğrenme Algoritmalarında Değerlendirme Kriterleri

Makine öğrenmesi alanındaki hızlı ilerlemeler, farklı öğrenme algoritmalarının geliştirilmesine ve uygulanmasına olanak tanımıştır. Bu algoritmaların performansını değerlendirirken, belirli ölçütler ve metrikler kullanmak gereklidir. Etkili bir değerlendirme süreci, algoritmaların güvenilirliği, doğruluğu ve genel başarısını anlamamıza yardımcı olur. Bu kapsamda, bir öğrenme algoritmasının başarı düzeyini belirlemede kullanılan başlıca kriterler arasında Ortalama Kare Hatası (MSE), Kök Ortalama Kare Hatası (RMSE), Ortak Mutlak Hata (MAE) ve R^2 Determinasyon Katsayısı gibi metrikler yer almaktadır.

Ortalama Kare Hatası (MSE)

MSE, tahminlerin gerçek değerlere ne ölçüde uyduğunu belirleyen bir ölçüm aracıdır ve bir modelin yaptığı tahminlerin hatalarının karelerinin ortalamasını hesaplar (Baydarakçı, 2023). Daha düşük bir MSE değeri, modelin performansının daha iyi olduğunu gösterir. Bu nedenle, MSE, modelin tahminlerinin doğruluğunu ve hata miktarını değerlendirmek için kritik bir rol oynamaktadır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.9)$$

Kök Ortalama Kare Hatası (RMSE)

RMSE, model tahminlerinin gerçek değerlere ne kadar yakın olduğunu ölçmek için kullanılır ve modelin performansını değerlendirir (Baydarakçı, 2023). Daha düşük RMSE değerleri, daha iyi bir model performansı anlamına gelir. Bu ölçüt, regresyon modellerinin başarısını belirlemede kritik bir rol oynar ve hata karelerinin ortalamasının karekökü ile hesaplanır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.10)$$

Ortak Mutlak Hata (MAE)

MAE, bir modelin tahminlerinin gerçek değerlerden ne kadar saptığını mutlak değerlerle ölçer ve modelin performansını değerlendirmede faydalı olabilir (Baydarakçı, 2023). Ancak, her hata pozitif veya negatif olsa da büyüklükleri aynıdır, bu da modelin performansını yavaş değerlendirebilir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.11)$$

R² Determinasyon Katsayısı

R², bir modelin bağımlı değişkenin varyansını ne kadar iyi açıkladığını ölçen bir istatistiktir ve modelin gerçek verilere uyumunu değerlendirir. Yüksek R² değeri, modelin iyi olduğu anlamına gelmez; çünkü model karmaşıklığını artırarak bu değeri yapay olarak yükseltmek mümkündür. R², modelin açıklayıcılığını ve genel uyumunu anlamaya yardımcı olur.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.12)$$

Burada $\bar{y}$ gerçek değerlerin ortalamasıdır. Yorumlanması genellikle daha kolaydır, çünkü 0 ile 1 arasında bir değer alır.

4.4 Örnek Üretim Kapasitesi Hesaplama

Güneş enerjisi üretiminin güneş radyasyonu değerleri üzerinden tahmin edilmesi basit anlamda şu şekilde hesaplanabilir. Panellerin 180° güney açısı ve 32° eğim aldığı bir ortam olduğunu düşünelim. Değerlerimiz;

–Günlük Güneş Radyasyonu (*GGR*): 10 kWh/m^2

–Toplam Modül Sayısı (*MS*): 4000

–Her Bir Modül Kapasitesi (*MK*): $250 \text{ W} = 0.25 \text{ kW}$

–Sistem Verimliliği (*SV*): %80

Bu değerlere göre toplam sistem kapasitesi yani toplam güç değeri modül sayısı ve her bir modülün kapasitesi çarpılarak bulunabilir.

$$\text{Toplam Güç (TG)} = MS * MK = 4000 * 250 \text{ W} = 1.000.000 = 1 \text{ MWp}$$

Günlük enerji üretimi, sistem kapasitesi ile radyasyon miktarının çarpılmasıyla hesaplanır. Verimliliğin de hesaba katılması gerekiyor. Güneş radyasyonu 10 kWh/m^2 , modüller toplamda 1 MWp gücünde ve sistem verimliliği % 80 olduğunu varsayalım.

$$\text{Günlük Enerji Üretimi} = TG * GGR * SV = 1 \text{ MW} * 10 \text{ kWh/m}^2 * 0.80 = 8 \text{ MWh/gün}$$

Günlük radyasyon tahmini ile elde edilen değerler üzerinden yapılan bu hesaplama ile bir güneş enerjisi sistemi günlük enerji üretim kapasitesi doğru şekilde tahmin edilebilir. Günlük üretim tahminleri, yatırım geri dönüş süresinin hesaplanmasına katkıda bulunur. Ne kadar enerji üretileceğini bilmek, enerji satış gelirlerini ve maliyet etkinliğini anlamak açısından önemlidir. Ayrıca, şebekeye ne kadar enerji verileceğinin veya hangi yüklerin karşılanacağını belirlenmesine yardımcı olur. Güneş radyasyon tahminleri sayesinde bir PV sisteminin verimliliği ve performansı izlenebilir. Bu tez çalışmasında günlük radyasyon tahmini için modeller oluşturulmuş ve modellerin çıktıları kullanılarak günlük güneş enerji üretim tesislerinin Muş İlinde üretim kapasitelerinin ne kadar olacağını hesaplamalarına destek olunmuştur. Muş'un enerji üretim potansiyelini ortaya koymak için kullanabilecekleri yapay zeka yaklaşımları değerlendirilmiştir.


5. DEĞERLENDİRMELER ve SONUÇLAR

5.1 Veri Seti

Muş Meteoroloji İl Müdürlüğü'nden Muş Merkez için iki istasyonlarındaki meteorolojik veriler alındı. Bunlar Muş/Berce Alparslan Tarım İşletmesi ve İl Müdürlüğü yerleşkesindeki istasyonlardı. Muş/Berce Alparslan Tarım İşletmesi'nden günlük toplam global güneş radyasyonu (kwsaat/m²) verileri alındı. Veriler 2016 ile 2023 tarihleri arasındaki değerleri barındırıyordu. İl Müdürlüğü yerleşkesinden günlük ortalama aktüel basınç (hPa), günlük ortalama nispi nem (%), günlük ortalama sıcaklık (°C), günlük maksimum rüzgar hızı (m/sn) verileri alındı. Veriler 1964 ile 2023 tarihleri arasındaki değerleri barındırıyordu. Bu istasyonda güneş ile ilgili veri toplanmamıştı. Bu yüzden farklı istasyondaki değerleri beraber kullanmamız gerekti. Güneş radyasyonu ile ilgili 2016 ile 2017 yılları verileri anormallikler barındırıyordu. Bu yüzden 2018 ile 2023 arasındaki değerler üzerinden veri seti oluşturuldu.

Kullanılan veri setinin kapsamı ve kalitesini etkileyen çeşitli faktörler vardır. Cihazların teknik sıkıntılarından kaynaklı ölçüm yapılmamış zaman aralıkları vardı. Bu eksik veriler uzun zaman aralığındaki ortalama değerler ile dolduruldu. Verideki her yılın mevcut günlerindeki değerlerin ortalaması alınarak eksik veri kısımları tamamlandı. Çevresel ve teknik sebeplerden dolayı verilerin yanlış ölçümleri de mutlaka olmuştur. Bu değerlerin tespiti zor olduğundan mevcut haliyle kullanıldı.

2191 günlük veri ile analizler yapıldı. Verilerin %80'i eğitim için, %20'si test için kullanıldı. 01.01.2018 ile 05.06.2022 arasındaki değerler eğitim verisi olarak kullanıldı. 06.06.2022 ile 31.12.2023 tarihleri arasındaki değerler tahmin için kullanıldı.



Şekil 5.1 Günlük Toplam Güneş Radyasyonu (kwsaat/m²) Zaman Serisi (2018-2023)

Güneş radyasyonu ile ilgili 2016 yılından itibaren Berce İstasyonunda ölçüm değerleri alınmaya başlanmıştır. Fakat 2018 yılına kadar olan verilerin ölçüm değerlerinin ortalamasının üzerinde olduğu gözlemlendi. Bu yüzden tahmin için 01.01.2018 yılından itibaren olan ölçüm değerleri kullanıldı. Nitekim regresyon ölçümleri için kullandığımız değerlerde 2018'ten itibaren kullanılacağı için bir anlamda kullanılan veri aynı zaman aralığını kapsadı. Günlük veriler dikkate alındı ve analizin içeriği 2018-2023 dönemine ait toplam günlük kWh/m² cinsinden zaman serisi değeridir. Şekil 5.1'de görüldüğü üzere radyasyon ölçüm değerleri yıllara göre benzer davranış göstermiştir. Seri değerlerinin tekrarlanabilirliğini sağlayan güçlü mevsimsellik barındırır.

Farklı modelleri karşılaştıran ve yeni hibrit yaklaşımlar öneren çok sayıda makale, güneş enerjisi üretimini tahmin etmenin sürekli bir zorluk olduğunu ve elde edilen sonuçların birçok faktöre bağlı olması nedeniyle uygun tahmin yönteminin seçilmesinin hala çözülmemiş bir görev olduğunu göstermektedir. Çoğu durumda yöntemler ortalama karesel hata (Dinsever ve ark., 2021), kök ortalama karesel hata (RMSE) ve ortalama mutlak yüzde hata (MAPE) ile karşılaştırılır (Chodakowska ve ark., 2023).

5.2 Zaman Serisi Yöntemleri Tahmin Sonuçları

Zaman serisi tahmin yöntemleri olarak LSTM ve ARIMA kullanıldı. İki yöntemle elde edilen tahmin sonuçları birbirine yakın çıktı. İki modelinde çözüm için kullanılabileceği görüldü. Çözüm için önerilen modellerin yapısı şu şekildedir.


Tahmin için kullanılan LSTM modeli Python Keras kütüphanesi kullanılarak oluşturulmuştur. Model, iki LSTM katmanı barındırıyor. İlk LSTM katmanında 50 adet hücre kullanıldı. Bu hücreler, zaman serisindeki verilerin uzun vadeli bağımlılıklarını öğrenmeye yardımcı olur. Bu katmanın tüm zaman adımlarındaki çıktıları sonraki katmana aktarıldı. Her bir zaman adımında tek bir özellik kullanıldı. İkinci ve son LSTM katmanı 50 hücreden oluşturuldu. Bu katman yalnızca son zaman adımının çıktısını döndürür. Bu katmanın çıktısı sonraki bir yoğun (dense) katmana iletildi. Tek bir nöron içeren yoğun bir katman eklendi. Bu katman LSTM katmanlarından çıktıyı alıp, tahmin yaptı. Modelin ağırlıklarının optimizasyonu adam algoritması ile yapıldı. Adam, adaptif öğrenme oranlarını kullanan bir optimizasyon algoritmasıdır. Kayıp fonksiyonu olarak ortalama kare hata kullanıldı. Eğitim veri seti modele 100 kez (epoch) sunuldu. Veri seti 64 örnekten oluşan gruplar (batch_size) halinde modele sunuldu. Doğrulama veri seti kullanılarak aşırı uyum (overfitting) önlenmeye çalışıldı. Yapılan farklı denemeler sonucunda yöntemin bu parametrelerle daha iyi sonuçlar verdiği görüldü.

Muş ili güneş radyasyonu tahminleri ARIMA modeli kullanarak gerçekleştirildi ve bu tahminlerin doğruluğunu değerlendirmek için Çizelge 5.1'deki hata metrikleri kullanıldı. Ayrıca tahmin sonuçları Şekil 5.2'de görselleştirilerek anlaşılır kılındı. Elde edilen sonuçlar oldukça olumlu oldu, çünkü hata metrik değerleri kabul edilebilir seviyelerde sonuçlar verdi. Tahmin için kullanılan ARIMA modeli test veri setindeki her gözlemi sırayla tahmin eder. Modelde p, d, q parametreleri önemlidir ve doğru seçilmesi gerekir. p=5 olarak seçildi. Bu AR (Auto-Regressive) yani gecikme sayısını ifade eder. d=1 olarak seçilen değer I (Integrated) kısmında kullanılır ve seriyi stasyoner hale getirmek amaçlanır. MA (Moving Average) değeri q=0 olarak verildi. Gecikme sayısını ifade eder. Her yeni tahmin, önceki tahminlerde elde edilen bilgileri içerir ve model her adımda güncellenir.

ARIMA modelleri, esneklikleri ve nispeten basit yapıları nedeniyle enerji yönetiminde geniş uygulama alanı bulmuştur. Araştırma bulguları, ARIMA modellerinin güneş radyasyonu tahmini için uygun olduğunu ve güneş enerjisinin sistemlerine uzun vadeli istikrarlı entegrasyonuna katkıda bulunabileceğini göstermektedir. Bu, önerilen modelin geçmiş güneş radyasyonu verilerini başarıyla analiz ettiğini ve gelecek dönemler için güvenilir tahminler yapabildiğini göstermektedir. Düşük hata metrik değerleri, Muş ilindeki güneş radyasyonu seviyelerini tahmin etmede ARIMA modelinin etkinliğini ve doğruluğunu vurgulamaktadır. Bu sonuçlar, Muş ilindeki güneş radyasyonu seviyelerini tahmin etmek için ARIMA modelinin güvenilir bir araç olarak kullanılabileceğini göstermektedir. Bu sonuçlar, Muş ilinin güneş enerjisi potansiyeli hakkında daha fazla bilgi edinilmesine ve bölgedeki güneş enerjisi projelerinin planlanması ve yönetilmesinde daha güvenilir kararlar alınmasına yardımcı olacaktır.


Çizelge 5.1 Zaman Serisi Tahmin Yöntemleri Sonuçları

	MSE	MAE	RMSE
LSTM	1.313	0.863	1.140
ARIMA	1.342	0.852	1.159



Şekil 5.2 ARIMA Tahmini

Muş ilinde güneş radyasyonu ölçümlerini LSTM modeli kullanarak tahmin edildiğinde, modelin oldukça başarılı sonuçlar verdiği Şekil 5.3'te ve Çizelge 5.1 hata metrikleri değerlerinden görülebilir. Modelin tahminleri, ölçülen güneş radyasyonu değerleriyle oldukça uyumlu bir şekilde çıktı. Hata metrikleri değerlerinin düşük olması ve tahminlerin zaman serisi grafiklerine bakıldığında, modelin güneş radyasyonunun mevsimsel ve günlük değişimlerini başarıyla yakaladığı görüldü.



Şekil 5.3 LSTM Tahmini

Ayrıca, modelin belirli zaman dilimlerindeki güneş radyasyonu değerlerindeki ani değişiklikleri ve anomalileri tespit etmede etkili olduğu görüldü. Bu ölçümler ile

beklenmeyen hava koşulları veya diğer faktörlerden kaynaklanan güneş radyasyonu dalgalanmaları belirlenebilir ve karar süreçlerinde kullanılabilir.


5.3 Regresyon Yöntemleri Tahmin Sonuçları

Regresyon yöntemleri ile tahmin yapmak zaman serisi ile benzer değildir. Bu yüzden Merkez İstasyondan alınan Nem, Rüzgar Hızı, Sıcaklık ve Basınç değerleri kullanıldı. Bu değerler üzerinden Güneş Radyasyonu tahmini yapıldı. Bu değerlerin istatistiki değerleri Çizelge 5.2’de verildi. Elde edilen tahmin sonuçları hata metrikleri RMSE, MAE, MSE ve R^2 ile gösterildi. Tahmin sonuçları Şekil 5.4’te verildi.

Çizelge 5.2. Veri seti istatistik bilgileri

	Nem	Rüzgâr hızı	Sıcaklık	Basınç	Güneş Radyasyonu
Sayı	2191	2191	2191	2191	2191
Ortalama	57,47	5,26	12,16	868,68	4,68
Standart Sapma	23,98	2,52	10,82	4,69	2,46
Minimum	13,5	0,5	-19,6	852,7	0
25%	34	3,6	3,2	865,2	2,6
50%	57,2	4,6	12,4	868,6	4,9
75%	79,5	6,7	21,6	872,1	6,8
Maksimum	99,6	18,5	31,6	883	12,6

Önerilen tahmin modellerinin hiper parametre ayarları şu şekilde yapıldı. MLP, SVM ve Random Forest için sklearn kütüphanesi kullanıldı. Yazılımda hiper parametrelerin varsayılan değerleri değiştirilmedi. Hangi hiper parametrelerin kullanıldığı sklearn kütüphanesinden bakılabilir. MLP modeli iki gizli katmandan oluşturuldu ve her katmanda 50 nöron bulundu. Her nöronun çıkışı hesaplamak için ‘relu’ (Rectified Linear Unit) aktivasyon fonksiyonu kullanıldı. Relu, nöronların pozitif değerlerini tutarken negatif değerleri sıfırlar. Sinir ağındaki ağırlıkları optimize etmek için adam optimizasyon yöntemi kullanıldı. SVM modelinin kernel fonksiyonu ‘rbf’ olarak seçildi. Doğrusal olmayan ilişkileri modellemek için kullanılan bir kernel fonksiyonudur. Random Forest modelindeki önemli parametre karar ağacı sayısıdır. Modelde bu değer 100 olarak tanımlandı. XGBoost’ta kayıp fonksiyonu olarak ‘squarederror’ seçildi. Hata karelerinin ortalamasını minimize etmeye çalışır. Her bir modelin bu parametreleri, modelin nasıl çalıştığını ve performansını doğrudan etkiler. Parametreler modelin eğitim sürecinde optimize edilerek en iyi performansı sağlayacak hale getirildi.



Şekil 5.4 Hata ölçütleri değerleri gösterimi


R^2 değeri, modelin bağımsız değişkenlerdeki varyansın ne kadarını açıkladığını gösterir. Bu değer ne kadar yüksekse, model o kadar iyi performans gösterir. Tahmin sonuçlarına göre, MLP ve SVM modelleri en yüksek R^2 değerlerine sahiptir, yani bağımsız değişkenlerdeki varyansın büyük bir kısmını açıklamada daha başarılı olmuşlardır. RMSE ve MSE değerleri, tahmin edilen değerlerin gerçek değerlerden ne kadar sapma gösterdiğini gösterir. Düşük RMSE ve MSE değerleri, daha iyi tahmin performansını temsil eder. MLP ve SVM modellerinin RMSE ve MSE değerleri diğerlerine göre daha düşüktür, yani tahminlerinin gerçek değerlere daha yakın olduğunu gösterir. Random Forest ve XGBoost modelleri ise daha düşük R^2 değerlerine ve daha yüksek RMSE ve MSE değerlerine sahiptir, bu da onların tahmin performansının diğerlerine göre biraz daha zayıf olduğunu gösterir. MAE değeri, tahminlerin gerçek değerlerden ortalama olarak ne kadar sapma gösterdiğini gösterir. MLP ve SVM'nin değerleri MAE için neredeyse eşit çıktı.

Muş ili güneş radyasyonu değerlerini tahmin etmek için kullanılan modellerin sonuçları incelendiğinde başarılı tahminler yapıldığı görülmektedir. Tahmin edilen değerlerin gerçek ölçümlerle uyumlu olduğu ve modellerin doğru tahminler yaptığı söylenebilir. Model parametreleri üzerinde yoğunlaşırsa tahmin sonuçları daha da iyileştirilebilir.

Zaman serisi ve regresyon yöntemlerini beraber değerlendirdiğimizde ise LSTM, MSE ve RMSE değerlerinde en düşük sonuçlara sahip, bu da büyük ve küçük hatalarda çok başarılı olduğunu gösterir. Zaman serisi verilerinde derin öğrenme tabanlı modellerin güçlü performans gösterdiğini buradan görebiliriz. ARIMA, en düşük MAE değerine

sahip. Yani, genel olarak mutlak hatalar açısından daha istikrarlı tahminler üretiyor. LSTM'nin zaman serilerindeki uzun süreli bağımlılıkları öğrenme kapasitesi, ARIMA gibi lineer modellere kıyasla avantaj sağlar.

MLP ve SVM, MSE, MAE ve RMSE açısından birbirine yakın performans sergiliyorlar, ancak LSTM ve ARIMA'ya göre daha yüksek hatalara sahipler. Yani, hem mutlak hatalarda hem de büyük hatalarda biraz daha kötü performans gösteriyorlar. Random Forest ve XGBoost, her üç hata metriğinde de en yüksek değerlere sahip çıktı. Bu, bu modellerin tahminlerinin diğer modellere göre daha hatalı olduğunu gösterir. Ensemble modeller genelde karmaşık veri setlerinde güçlüdür, ancak bu veri setinde diğer modellere göre daha düşük performans göstermişlerdir.



Şekil 5.5 Zaman Serisi ve Regresyon yöntemlerinin hata ölçütleri değerleri gösterimi

5.4 Sonuçlar ve Öneriler

Bu tez çalışması, güneş enerjisinin temiz, yenilenebilir ve sürdürülebilir bir enerji kaynağı olarak insanlığın enerji ihtiyaçlarını karşılamadaki potansiyelini vurgulamaktadır. Fosil yakıtların çevresel etkilerinden kaçınmak ve iklim değişikliği ile mücadele etmek amacıyla güneş enerjisinin önemi vurgulanmıştır. Güneş enerjisi, sürekli gelişen teknolojilerle maliyetlerinin düşmesi ve enerji verimliliğinin artması yoluyla enerji sektöründe ve diğer endüstrilerde ilerlemeyi teşvik etmektedir.

Çalışma, Türkiye'nin Doğu Anadolu bölgesindeki Muş ilinde güneş enerjisi potansiyelini belirlemek için makine öğrenmesi yöntemlerinin kullanıldığı bir analiz sunmaktadır. Bu yöntemler, geçmiş verilere dayalı olarak güneş enerjisi tahminlerini yapmak için ARIMA (Otoregresif Bütünleşik Hareketli Ortalama) ve LSTM (Uzun Kısa

Sürekli Bellek Ağları ile Tahmin) gibi zaman serisi yöntemleri ile MLP, Random Forest, XGBoost ve SVM gibi regresyon tekniklerini içermektedir.

Elde edilen sonuçlar, Muş ilinin güneş enerjisi üretimi için önemli bir potansiyele sahip olduğunu göstermektedir. Bu analizler, bölgenin enerji ihtiyaçlarının karşılanması ve enerji bağımsızlığının artırılması konularında önemli fırsatlar sunduğunu ortaya koymaktadır. Makine öğrenmesi yöntemlerinin kullanımı, özellikle tahminlerin doğruluğunu artırmak için bölgeye özgü meteorolojik koşulları dikkate almak açısından önemlidir. Ayrıca, çalışmanın sınırlamalarının ve kullanılan veri setlerinin kapsamının gelecekteki benzer araştırmalar için önemli bir odak noktası olduğunu belirtmek gerekir.

Sonuç olarak, bu çalışma güneş enerjisi potansiyelinin değerlendirilmesi ve gelecekteki enerji stratejilerinin planlanmasında değerli bir kaynak olarak kabul edilebilir ve aynı zamanda gelecekteki araştırmalar için yol gösterici olabilir. Güneş enerjisi tahminlerinin doğruluğu, enerji yönetimi ve çevresel sürdürülebilirlik gibi alanlarda etkili kararlar alınmasına yardımcı olabilir, bu da ekonomik büyümeye ve toplumsal refaha katkı sağlayabilir.

Gelecek çalışmalarda güneşlenme şiddeti, bulut hareketleri gibi meteorolojik veriler kullanılarak çalışmaya farklı boyutlar eklenebilir. Gelecekteki araştırmalar, daha kapsamlı veri setleri ve daha sofistike makine öğrenmesi yöntemlerinin kullanılmasıyla bu alandaki bilgiyi daha da geliştirebilir. Ayrıca Muş İlinde güneş santrali, rüzgar santrali kurulacak bölgelerde veya enerji potansiyelinin yüksek olduğu bölgeler tespit edilerek bu konumlarda ölçümler yapılarak daha derin öngörüler ortaya konulabilir.

KAYNAKLAR

- Adıyaman, Ç. (2012). Türkiye'nin yenilenebilir enerji politikaları. Niğde Üniversitesi,
- Alami, A. H., Olabi, A. G., Mdallal, A., Rezk, A., Radwan, A., Rahman, S. M. A., Abdelkareem, M. A. 2023. Concentrating solar power (CSP) technologies: Status and analysis. *International Journal of Thermofluids*, 18, 100340.
- Al-Aboodi, A. H., Al-Abadi, A. M., and Ibrahim, H. T. 2017. A Committee Machine with Intelligent Systems for Estimating Monthly Mean Reference Evapotranspiration in an Arid Region. *Research Journal of Applied Sciences Engineering and Technology*, 14(10), 386–398.
- Aslam, M., Lee, J. M., Kim, H. S., Lee, S. J., and Hong, S. 2019. Deep learning models for long-term solar radiation forecasting considering microgrid installation: A comparative study. *Energies*, 13(1), 147.
- Baydarakçı, M. (2023). Su altı otonom araçlarda navigasyon ve yol planlama çözümleri (Yüksek lisans), *Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü*, 38-40.
- Belaïd, S., and Mellit, A. 2016. Prediction of daily and mean monthly global solar radiation using support vector machine in an arid climate. *Energy Conversion and Management*, 118, 105-118.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., and Ljung, G. M. 2015. Time series analysis: forecasting and control: *John Wiley and Sons*.
- Breiman, L. 2001. Random forests. *Machine learning*, 45, 5-32.
- Chatfield, C., and Xing, H. 2019. The analysis of time series: an introduction with R: *Chapman and hall/CRC*.
- Chen, T., and Guestrin, C. 2016. Xgboost: A scalable tree boosting system. *22nd acm sigkdd international conference on knowledge discovery and data mining*.
- Chodakowska, E., Nazarko, J., Nazarko, Ł., Rabayah, H. S., Abendeh, R. M., and Alawneh, R. 2023. Arima models in solar radiation forecasting in different geographic locations. *Energies*, 16(13), 5029.
- Cihan, E. (2019). Yenilenebilir enerji ve Türkiye'de güneş enerjisi. *Hasan Kalyoncu Üniversitesi, Fen Bilimleri Enstitüsü*.
- Demolli, H., Dokuz, A., Gokcek, M., ve Ecemiş, A. (2019). Makine Öğrenmesi Algoritmalarıyla Güneş Enerjisi Tahmini: Niğde İli Örneği. *International Turkic World Congress on Science and Engineering*.
- Demolli, H. (2020). Makine öğrenmesi teknikleri kullanarak yenilenebilir enerji güç üretim tahmini ve optimum hibrit güç sistemi tasarımı, *Niğde Ömer Halisdemir Üniversitesi / Fen Bilimleri Enstitüsü*.
- Dinsever, L. D., Gümüş, V., Şimşek, O., Avşaroğlu, Y., & Mehmet, K. (2021). Adıyaman ve Gaziantep İstasyonlarındaki Güneşlenme Şiddetinin Destek Vektör Makineleri ile Tahmini. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 8(2), 753-769.
- Erdem, K., ve Kadir, K. 2015. Enerji Kaynakları–Yenilenebilir Enerji Durumu. *Mühendis ve Makina*, 56(668), 36-47.

- Eyvazov, A. (2019). Yapay Sinir Ağları ile Güneş Enerjisi Potansiyelinin Modellenmesi ve Güneş Pilleri Verim Analizi. *İAÜ Fen Bilimleri Enstitüsü*, İstanbul.
- Friedman, J. H. 2001. Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189-1232.
- Geçmez, A., and Gençer, Ç. 2020. Güneş Enerji Santrali Üretim Verilerinin Meteorolojik Verilere Bağlı olarak Yapay Zeka Yöntemleri ile Tahmini, *Gce Publishing* , 39.
- GEPA. (2024), Erişim Tarihi:11.03.2024.
- GlobalSolarAtlas. (2024), Erişim Tarihi:11.04.2024.
- Goodfellow, I., Bengio, Y., and Courville, A. 2016. Deep learning: *MIT press*.
- Göksu, B., Bayraktar, M., Sevgili, C., and Hazar, C. 2018. İzmir İli İçin Güneş Enerjisi Potansiyeli Tahmini Solar Power Potential Estimation for İzmir, 2. *Uluslararası Şehir Çevre Sağlık Kongresi*, 2.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., and Schmidhuber, J. 2016. LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 28(10), 2222-2232.
- Gülay, A. N. (2008). Yenilenebilir enerji kaynakları açısından Türkiye'nin geleceği ve Avrupa Birliği ile karşılaştırılması. *DEÜ Sosyal Bilimleri Enstitüsü*.
- Hassan, S., Rubab, S., Saadat, S., Gardezi, S. Q. A., Khan, M. A., Alasiry, A., . . . Masood, A. 2023. Real-Time Investigation of Cross-Technology Interference in Heterogeneous IoT Networks, *IEEE Access*.
- Hastie, T., Tibshirani, R., Friedman, J. H., and Friedman, J. H. (2009). The elements of statistical learning: data mining, inference, and prediction (Vol. 2): *Springer*.
- Hochreiter, S., and Schmidhuber, J. 1997. Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hussain, M., Sultan, M., Uzma, F., Longsheng, C., Malik, M. Y., Butt, A. R., . . . Imran, M. 2022. A comparative analysis of renewable and non-renewable energy generation to relegate CO2 emissions and general costs in household systems. *Environmental Science and Pollution Research*, 29(52), 78795-78808.
- Hyndman, R. J., and Athanasopoulos, G. 2018. Forecasting: principles and practice: *OTexts*.
- İzmirli Ayan, S. M. (2018). Fotovoltaik sistemin yapay zeka algoritması ile güç tahmini. *Kırklareli Üniversitesi, Fen Bilimleri Enstitüsü*.
- Jenkins, G. M., and Box, G. E. 1976. Time series analysis: forecasting and control, *Wiley Series in Probability and Statistics*, 5. Baskı.
- Ju, X., Xu, C., Han, X., Zhang, H., Wei, G., and Chen, L. 2017. Recent advances in the PV-CSP hybrid solar power technology, *AIP Conference Proceedings*.
- Kaplan, A. G., and Kaplan, Y. A. 2024. Using of the Weibull distribution in developing global solar radiation forecasting models. *Environmental Progress & Sustainable Energy*, e14380.
- Kaya, D. (2020). Güneş ışınım şiddetinin akıllı hibrit yaklaşımlar ile tahmini. *Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü*.

- Köroğlu, T., Teke, A., Bayındır, K.Ç., Tümay M. 2010. Güneş Panelleri Sisteminin Tasarlanması, *Elektrik Mühendisliği Odası*, 439. sayı.
- Krishnan, N., Kumar, K. R., and Inda, C. S. 2023. How solar radiation forecasting impacts the utilization of solar energy: A critical review. *Journal of Cleaner Production*, 388, 135860.
- Kumruoğlu, L. C., and Ateş, S. B.2022. Türkiye'nin güneş enerjisi potansiyeli ve İskenderun için örnek üretim projeksiyonu. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(1), 293-305.
- LeCun, Y., Bengio, Y., and Hinton, G. 2015. Deep learning. *Nature*, 521(7553), 436-444.
- Liaw, A., & Wiener, M. 2002. Classification and regression by randomForest. *R news*, 2(3), 18-22.
- Livieris, I. E., Pintelas, E., and Pintelas, P. 2020. A CNN–LSTM model for gold price time-series forecasting. *Neural Computing and Applications*, 32(23), 17351–17360.
- Macit Sezikli, N. (2023). Makine öğrenmesi yöntemiyle yenilenebilir güneş enerjisi üretiminin meteorolojik veriler kullanılarak tahmin analizi, *İstanbul Gelişim Üniversitesi Lisansüstü Eğitim Enstitüsü*.
- Miyama, M. 2016. Fast Face Detection with Multi-Scale Window Search Free from Image Resizing Using SGI Features. *Journal of Computer and Communications*, 4(10), 22.
- Mukilan, K., Thaiyalnayaki, K., Dwivedi, Y. D., Samson Isaac, J., Poonia, A., Sharma, A., . . . Kassa, A. 2022. Prediction of rooftop photovoltaic solar potential using machine learning. *International Journal of Photoenergy*, 2022(1), 1541938.
- Nielsen, M. A. 2015. Neural networks and deep learning (Vol. 25): *Determination press San Francisco, CA, USA*.
- Owusu, P. A., & Asumadu-Sarkodie, S. 2016. A review of renewable energy sources, sustainability issues and climate change mitigation. *Cogent Engineering*, 3(1), 1167990.
- Ozcelik, M. (2022). Muş İlinde Güneş Enerjisi Potansiyelinin Analitik Hiyerarşi Süreci Yöntemi (AHP) İle Belirlenmesi, *Muş Alparslan Üniversitesi, Fen Bilimleri Enstitüsü*,
- Özer, S. 2023. Muş İlindeki Alternatif Enerji Kaynakları Potansiyeli, Karbon Azaltımına ve Ekonomiye, Katkısı. *Farklı Boyutlarıyla Muş Ekonomisi*, 66.
- Peng, T., Zhang, C., Zhou, J., and Nazir, M. S. 2021. An integrated framework of Bi-directional long-short term memory (BiLSTM) based on sine cosine algorithm for hourly solar radiation forecasting. *Energy*, 221, 119887.
- Piraei, R., Afzali, S. H., and Niazkar, M. 2023. Assessment of XGBoost to estimate total sediment loads in rivers. *Water Resources Management*, 37(13), 5289-5306.
- Rodat, S., and Thonig, R. 2024. Status of Concentrated Solar Power Plants Installed Worldwide: Past and Present Data. *Clean Technologies*, 6(1), 365-378.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. 1986. Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.

- Sarıbaşı, E. (2015). Türkiye'deki enerji kaynakları ve izlenen enerji politikaları. *Niğde Üniversitesi, Fen Bilimleri Enstitüsü*.
- Sehrawat, N., Vashisht, S., and Singh, A. 2023. Solar irradiance forecasting models using machine learning techniques and digital twin: A case study with comparison. *International Journal of Intelligent Networks*, 4, 90-102.
- Shahsavaria, A., Karimia, A., Akbarib, M., and Noughania, M. A., 2024, Environmental Impacts and Social Cost of Non-Renewable and Renewable Energy Sources: A Comprehensive Review, *Journal of Renewable Energy and Environment*, 11(1), 12-27.
- Sohal, J. S., Hegde, V., and Smitha, B. 2023. Solar Power probabilistic prediction using random forest regressor. In *Renewable Energy Optimization, Planning and Control: Proceedings of ICRTE 2022* (123-135). Springer Nature Singapore.
- Solano, E. S., Dehghanian, P., and Affonso, C. M. 2022. Solar radiation forecasting using machine learning and ensemble feature selection, *Energies*, 15(19), 7049.
- Srivastava, R., Tiwari, A. N., and Giri, V. K. 2019. Solar radiation forecasting using MARS, CART, M5, and random forest model: A case study for India. *Heliyon*, 5(10).
- Strielkowski, W., Civin, L., Tarkhanova, E., Tvaronavičienė, M., and Petrenko, Y. 2021. Renewable energy in the sustainable development of electrical power sector: A review, *Energies*, 14(24), 8240.
- Tekin, P. (2022). Çukurova Bölgesi için Kısa Vadeli Yapay Zeka Tabanlı Rüzgar Güç Tahmini, *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(4), 1143-1154.
- Tugal, I., and Sevgin, F. 2023. Analysis and forecasting of temperature using time series forecasting methods a case study of Mus. *Thermal Science*, 27(4 Part B), 3081-3088.
- Wang, X., Huang, T., Zhu, K., and Zhao, X. 2022. LSTM-based broad learning system for remaining useful life prediction. *Mathematics*, 10(12), 2066.
- Voyant, C., Notton, G., Kalogirou, S., Nivet, M. L., Paoli, C., Motte, F., and Fouilloy, A. 2017. Machine learning methods for solar radiation forecasting: A review. *Renewable energy*, 105, 569-582.
- Yılmaz, M. (2012). Türkiye'nin enerji potansiyeli ve yenilenebilir enerji kaynaklarının elektrik enerjisi üretimi açısından önemi. *Ankara Üniversitesi Çevre Bilimleri Dergisi*, 4(2), 33-54.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : İrem Fatma ŞENER

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: TOBB Anadolu Öğretmen Lisesi, Merkez, Muş	2015
Üniversite	: Tekirdağ Namık Kemal Üniversitesi, Süleymanpaşa, Tekirdağ	2019

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2021-?	Karlıova Mesleki ve Teknik Anadolu Lisesi	Öğretmen

UZMANLIK ALANI

YABANCI DİLLER

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR