



GÜNEŞ IŞINIMI TAHMİNİNE YENİLİKÇİ BİR YAKLAŞIM

YÜKSEK LİSANS TEZİ

Feyza Nur YEŞİL

Danışman

Dr. Öğr. Üyesi Tuba Nur SERTTAŞ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Ocak 2025

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

GÜNEŞ IŞINIMI TAHMİNİNE YENİLİKÇİ BİR YAKLAŞIM

Feyza Nur YEŞİL

Danışman

Dr. Öğr. Üyesi Tuba Nur SERTTAŞ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Ocak 2025

TEZ ONAY SAYFASI

Feyza Nur YEŞİL tarafından hazırlanan “Güneş Işınımı Tahminine Yenilikçi Bir Yaklaşım” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 28 / 01 / 2025 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi Tuba Nur SERTTAŞ

Başkan : Prof. Dr. Ömer Nezh GEREK
Eskişehir Teknik Üniversitesi, Mühendislik Fakültesi

Üye : Prof. Dr. Yüksel OĞUZ
Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi

Üye : Dr. Öğr. Üyesi Tuba Nur SERTTAŞ
Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. Bekir YALÇIN
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

28 / 01 / 2025

Feyza Nur YEŞİL

ÖZET

Yüksek Lisans Tezi

GÜNEŞ IŞINIMI TAHMİNİNE YENİLİKÇİ BİR YAKLAŞIM

Feyza Nur YEŞİL

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Tuba Nur SERTTAŞ

Bu çalışmada iklim değişikliği ile mücadele etmek, güneş enerjisinin istikrarlı ve güvenilir bir şekilde kullanılmasını sağlamak ve güneş enerjisi projeleri için fizibilite çalışmalarını yürütebilmek amacıyla saatlik güneş ışıını tahmin çalışması gerçekleştirilmiştir. Bu bağlamda Afyonkarahisar Meteoroloji Müdürlüğü'nden temin edilen 2018-2022 yılları arası saatlik olarak ölçülen güneş ışıını değerleri ile bir zaman serisi oluşturulmuştur. Tahmin modeli için, güneş ışıını zaman serisindeki doğrusal ilişkileri etkili bir şekilde açıklayan SARIMA yöntemi ile doğrusal olmayan bağımlılıkları yakalamada başarılı olan LSTM derin sinir ağını birleştiren mevsimsel-eğilim ayrıştırması (STL) tabanlı bir hibrit yaklaşım geliştirilmiştir. Özellikle yüksek mevsimsel değişkenliğe sahip zaman serileri için etkili olan STL metodu, güneş ışıını zaman serisinin alt bileşenlerinin ayrı olarak modellenmesi imkânı sağlamıştır. Güneş ışıını verilerine 10-katlı çapraz doğrulama uygulanarak geliştirilen hibrit modelin tüm mevsimsel dönemlerdeki kararlılığı ve tahmin yeteneği değerlendirilmiştir.

2025, ix + 76 sayfa

Anahtar Kelimeler: Güneş Işını Tahmini, Mevsimsel Otoregresif Entegre Hareketli Ortalama, Uzun Kısa Süreli Bellek, Mevsimsel-Eğilim Ayrıştırması.

ABSTRACT

M.Sc. Thesis

A NOVEL APPROACH TO SOLAR RADIATION FORECASTING

Feyza Nur YEŞİL

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Supervisor: Asst. Prof. Tuba Nur SERTTAŞ

In this study, an hourly solar radiation forecasting approach was developed to combat climate change, ensure the stable and reliable use of solar energy, and conduct feasibility studies for solar energy projects. For this purpose, a time series was constructed using hourly solar radiation measurements recorded between 2018 and 2022, obtained from the Afyonkarahisar Meteorology Service. The proposed forecasting model employs a hybrid approach based on Seasonal-Trend Decomposition (STL), combining the SARIMA method, which effectively captures linear relationships in the solar radiation time series, and the Long Short-Term Memory (LSTM) neural network, known for its ability to model nonlinear dependencies. The STL method, particularly effective for time series with high seasonal variability, enables the decomposition of the solar radiation series into distinct components for separate modeling. The stability and predictive performance of the developed hybrid model were evaluated across all seasonal periods using 10-fold cross-validation applied to the solar radiation data.

2025, ix + 76 pages

Keywords: Solar Radiation Forecasting, Seasonal Autoregressive Integrated Moving Average, Long Short Term Memory, Seasonal-Trend Decomposition.

TEŐEKKÜR

Bu arařtırmanın konusu, deneysel alıřmaların ynlendirilmesi, sonuların deęerlendirilmesi ve yazımı ařamasında yapmıř olduęu byk katkılarında dolay tez danıřmanım Sayın Dr. ęr. yesi Tuba Nur SERTTAŐ'a, arařtırma ve yazım sresince yardımlarını esirgemeyen her konuda neri ve eleřtirileriyle yardımlarını grdęm hocalarıma ve arkadařlarıma teőekkr ederim.

Bu arařtırma boyunca maddi ve manevi tm itenlięiyle desteęinden dolay bařta sevgili eřim Mevlt Bey olmak zere btn aileme teőekkr ederim.

Feyza Nur YEŐİL
Afyonkarahisar 2025

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	iix
ÇİZELGELER DİZİNİ.....	xi
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	5
2.1 Görüntü Tabanlı Tahmin Modelleri.....	5
2.2 Sayısal Hava Tahmin (NWP) Modelleri.....	7
2.3 İstatiksel Tahmin Modelleri.....	8
2.4 Yapay Zekâ Tabanlı Tahmin Modelleri.....	10
2.5 Hibrit Tahmin Modelleri.....	15
3. MATERYAL ve METOT	19
3.1 Toplam Küresel Güneş Işınımı	19
3.2 Zaman Serisi K-katlı Çapraz Doğrulama.....	20
3.3 Mevsimsel-Eğilim Ayrıştırması (STL).....	22
3.4 Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA) Modeli.....	25
3.5 Uzun-Kısa Süreli Bellek (LSTM) Modeli	27
3.6 SARIMA-LSTM Hibrit Modeli.....	31
4. BULGULAR	34
4.1 Değerlendirme Metrikleri	34
4.2 SARIMA Model Tasarımı	35
4.2.1 Zaman Serisi Durağanlık Testi.....	36
4.2.2 Otokorelasyon ve Kısmi Otokorelasyon Grafikleri	37
4.2.3 Model Tanımlaması	41
4.3 LSTM Model Tasarımı	42
4.3.1 Hiperparametre Değerlerinin Ayarlanması	43
4.4 Hibrit Model Tasarımı	47
4.4.1 Hibrit Model Tahmin Performansı.....	48

4.4.2 Farklı Mevsim Koşulları Altında Hibrit Model Tahmin Performansı	51
5. TARTIŞMA ve SONUÇ	62
6. KAYNAKLAR.....	65



SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

°C	Santigrat
%	Yüzde
°	Derece
W	Watt
MW	Megawatt
MJ	Megajoul
kWh	Kilowatt saat
m ²	Metrekare
R ²	Determinasyon Katsayısı
≤	Küçük Eşittir
≥	Büyük Eşittir

Kısaltmalar

ABC	Yapay Arı Kolonisi
ACCESS	Dünya Sistemi Simülatörü
ACF	Otokorelasyon Grafiği
ADF	Dickey-Fuller Birim Kök Testi
AFT	Dikkatsiz Dönüştürücü
AIC	Akaike Bilgi Kriteri
ANFIS	Adaptif Sinirsel Bulanık Mantık Çıkarımı
ANN	Yapay Sinir Ağları
AR	Otoregresif
ARMA	Otoregresif Hareketli Ortalama
ARIMA	Otoregresif Entegre Hareketli Ortalama
ASI	Tüm Gökyüzü Görüntüleyici
AQI	Hava Kalitesi İndeksi
BIC	Bayes Bilgi Kriteri
BP	Geri Yayılım
BPNN	Geri yayılım Sinir Ağı
BA	Boruta Algoritması
BAT	Yarasa Optimizasyon Algoritması
Bi-GRU	Çift Yönlü Kapılı Birim
CMV	Bulut Hareket Vektörü
CNN	Evrişimli Sinir Ağı
CV	Çapraz Doğrulama
DE	Diferansiyel Evrim
DHI	Dağınık Güneş Işınımı
DL	Derin Öğrenme
DNI	Doğrudan Normal Güneş Işınımı
DRNN	Derin Tekrarlayan Sinir Ağları
DT	Karar Ağacı
ELM	Ekstrem Öğrenme Makinesi
FFNN	İleri Beslemeli Sinir Ağı
FL	Bulanık Mantık

GA	Genetik Algortima
GB	Gradyan Artırma
GEPA	Türkiye Güneş Enerjisi Potansiyeli Atlası
GFS	Küresel Tahmin Sistemi
GHI	Küresel Güneş Işınımı
GRU	Kapılı Tekrarlayan Birimler
GOA	Çekirge Optimizasyon Algortiması
GOES	Operasyonel Çevre Uydusu
GPR	Gauss İşlem Regresyonu
IPCC	Hükümetler arası İklim Değişikliği Paneli
k-NN	K-en en yakın Komşu
KPSS	Kwiatkowski-Phillips-Schmidt-Shin
LightGBM	Işık Gradyan Güçlendirmesi
LR	Doğrusal Regresyon
LSSVM	En Küçük Kareler Destek Vektör Makinesi
LSTM	Uzun-Kısa Süreli Bellek
Loess	Yerel Olarak Tahmin Edilen Dağılım Grafiği Yumuşatma
MA	Hareketli Ortalama
MAE	Ortalama Mutlak Hatası
MAPE	Ortlama Mutlak Yüzde Hata
MARS	Çok Değişkenli Uyarlamalı Regresyon Eğrileri
MBE	Ortalama Sapma Hatası
ML	Makine Öğrenimi
MLP	Çok Katmanlı Algılayıcı
MLR	Çoklu Doğrusal Regresyon
NAR	Otoregresif Sinir Ağı
NRMSE	Normalize Edilmiş Kök Ortalama Kare Hatası
NWP	Sayısal Hava Tahmin
PACF	Kısmi Otokorelasyon Grafiği
PFI	Permütasyon Özellik Önemi
PSO	Parçacık Sürüsü Optimizasyonu
PV	Fotovoltaik
RF	Rastgele Orman Ağacı
RLMD	Yerel Ortalama Ayırıştırması
RMSE	Kök Ortalama Kare Hatası
RNN	Tekrarlayan Sinir Ağları
RTP	Işınım Transfer Parametresi
SARIMA	Mevsimsel Otoregresif Entegre Hareketli Ortalama
SARIMAX	SARIMAX
SEVIRI	Meteosat İkinci Nesil Jeostatik Uydusu Kızılötesi Görüntüleyici
SHAP	Shapley Eklemeli Açıklamalar
STL	Mevsimsel Eğilim Ayırıştırması
SVM	Destek Vektör Makinesi
TEİAŞ	Türkiye Elektrik İletim A.Ş
TSI	Bütünsel Gökyüzü Görüntüleyici
XGBoost	Aşırı Gradyan Artırma
WOA	Balina Optimizasyonu Algortiması

WPD
WRF
WSI

Dalgacık Paket Ayrıştırması
Hava Durumu Araştırması ve Tahmini
Tüm Gökyüzü Görüntüleyici



ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1 Türkiye geneli küresel güneş ışınımı dağılımı	2
Şekil 3.1 Afyonkarahisar iline ait saatlik olarak ölçülen küresel güneş ışınımı zaman serisi.....	20
Şekil 3.2 Zaman serisi K-katlı CV metodu gösterimi	21
Şekil 3.3 Basit bir RNN ağı modeli.....	28
Şekil 3.4 Temel bir LSTM hücrenin unut kapısı, giriş kapısı ve çıkış kapısı	29
Şekil 3.5 Aday hücre kullanılarak yeni bir bellek hücrenin oluşum süreci	30
Şekil 3.6 LSTM hücreinde bilgi akış süreci	31
Şekil 3.7 Önerilen SARIMA-LSTM hibrit modelin akış diyagramı.....	33
Şekil 4.1 2018-2022 yılları arası ölçülen güneş ışınımı zaman serisinin aylık kutu grafiği	35
Şekil 4.2 Fark ve mevsimsel fark sonrası güneş ışınımı zaman serisi	37
Şekil 4.3 Güneş ışınımı zaman serisinin ACF ve PACF grafikleri.....	38
Şekil 4.4 Birinci derece fark alma sonrası güneş ışınımı zaman serisinin ACF ve PACF grafikleri	39
Şekil 4.5 Birinci derece mevsimsel fark alma sonrası güneş ışınımı zaman serisinin ACF ve PACF grafikleri.....	40
Şekil 4.6 LSTM-1, LSTM-2, LSTM-3 ve LSTM-4 modellerin hata kayıp grafikleri ...	45
Şekil 4.7 LSTM-5, LSTM-6, LSTM-7 ve LSTM-8 modellerin hata kayıp grafikleri ...	46
Şekil 4.8 Güneş ışınımı zaman serisinin STL ayrıştırması sonucu elde edilen zaman serileri	47
Şekil 4.9 Hibrit, SARIMA ve LSTM modellerinin ortalama metrik sonuçlarının sütun grafiği	49
Şekil 4.10 Hibrit, SARIMA ve LSTM modellerinin korelasyon grafikleri	50
Şekil 4.11 Hibrit, SARIMA ve LSTM modellerinin histogram grafikleri	50
Şekil 4.12 Hibrit, SARIMA ve LSTM modellerinin Q-Q grafikleri.....	51
Şekil 4.13 2018 yılında üç mevsim günü için saatlik güneş ışınımı tahmin grafikleri ..	56
Şekil 4.14 2019 yılında farklı mevsim günleri için saatlik güneş ışınımı tahmin grafikleri - 1	57
Şekil 4.15 2019 yılında farklı mevsim günleri için saatlik güneş ışınımı tahmin grafikleri - 2	57
Şekil 4.16 2020 yılında farklı mevsim günleri için saatlik güneş ışınımı tahmin grafikleri - 1	58

Şekil 4.17 2020 yılında farklı mevsim günleri için saatlik güneş ışıınıımı tahmin grafikleri - 2	58
Şekil 4.18 2021 yılında farklı mevsim günleri için saatlik güneş ışıınıımı tahmin grafikleri - 1	59
Şekil 4.19 2021 yılında farklı mevsim günleri için saatlik güneş ışıınıımı tahmin grafikleri - 2	59
Şekil 4.20 2022 yılında farklı mevsim günleri için saatlik güneş ışıınıımı tahmin grafikleri - 1	60
Şekil 4.21 2022 yılında farklı mevsim günleri için saatlik güneş ışıınıımı tahmin grafikleri - 2	60



ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1 Zaman serisi K-katlı çapraz doğrulanmış zaman serisi için eğitim ve test verileri tarih aralığı	22
Çizelge 4.1 Çalışmada kullanılan performans değerlendirme metrikleri.....	34
Çizelge 4.2 Orijinal güneş ışınımı zaman serisi için ADF ve KPSS test sonuçları	37
Çizelge 4.3 Fark ve mevsimsel fark sonrası güneş ışınımı zaman serisi için ADF ve KPSS test sonuçları.....	37
Çizelge 4.4 SARIMA Model kombinasyonları için AIC ve BIC değerleri	42
Çizelge 4.5 SARIMA(3,1,2)x(3,1,1) ₂₄ modelin parametre sonuçları	42
Çizelge 4.6 Belirlenen LSTM modellerinin hiperparametre değerleri.....	44
Çizelge 4.7 LSTM modellerinin eğitim sonucu	44
Çizelge 4.8 Çalışmada kullanılan LSTM modelin parametre değerleri	46
Çizelge 4.9 Hibrit, SARIMA ve LSTM modellerinin her K iterasyonu için metrik sonuçları.....	48
Çizelge 4.10 Yaz mevsimi günleri için güneş ışınımı tahmin sonuçları	52
Çizelge 4.11 Sonbahar mevsimi günleri için güneş ışınımı tahmin sonuçları	53
Çizelge 4.12 Kış mevsimi günleri için güneş ışınımı tahmin sonuçları	54
Çizelge 4.13 İlkbahar mevsimi günleri için güneş ışınımı tahmin sonuçları	55
Çizelge 4.14 Literatürdeki güneş ışınımı çalışmaları ile mevcut çalışmanın karşılaştırılması.....	63

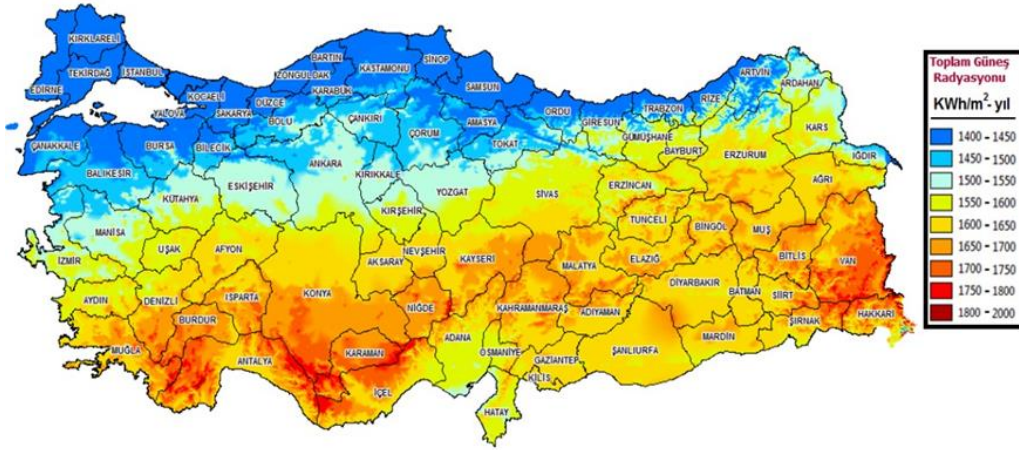
1. GİRİŞ

Dünya, son yüzyılda 0,99 °C ısınarak 21. yüzyılın en çok tartışılan sorunlarından birine konu olmaktadır. Bilimsel bir gerçek olarak kabul edilen küresel ısınma ve iklim değişikliği yalnızca ekolojik bir tehdit değil sağlık sektörü, gıda güvenliği, su kıtlığı ve siyasi istikrara kadar uzanan global bir risk unsurudur (Fu ve Waltman 2022). Hükümetler arası İklim Değişikliği Paneli (IPCC) raporu, karalar ve okyanusların üzerindeki değişimlerde insan faaliyetlerinin doğrudan etkisi olduğunu ortaya koymaktadır. Antroposen çağı olarak ifade edilen bu sürecin sanayi devrimi ile başladığı kabul edilmektedir (Polat ve Kahraman 2021). Dünya nüfusunun artması, sanayileşme, teknolojik gelişmeler ve refah seviyesinin yükselmesi büyük bir enerji talebini oluşturmaktadır. Petrol, kömür, doğalgaz gibi geleneksel olarak kullanılan fosil yakıt ve türevleri, karbon salınımı sebebiyle hava kirliliği ve küresel ısınmaya neden olan sınırlı ve tükenmekte olan enerji kaynaklarıdır. 2050 yılına kadar enerji tüketiminin %50 artacağı öngörülmektedir (Kahan 2019). Bu nedenle rüzgâr, güneş, jeotermal, hidroelektrik ve biyokütle gibi temiz ve sürdürülebilir enerji kaynakları iyi bir alternatif olmaktadır.

Yenilenebilir enerji küresel ısınma ve iklim değişikliği etkilerinin azaltılmasında önemli bir rol oynar. Fosil yakıtların aksine karbon salınımını minimum seviyede tutarak hava ve su kirliliğini büyük ölçüde azaltmaktadır. Bu kaynaklar doğası gereği ekolojik döngüye bağlı olarak kendini yenileyerek uzun vadede güvenli ve sürdürülebilir bir enerji imkanı sunmaktadır. Birçok ülke enerji bağımsızlığına ulaşmak amacıyla yenilenebilir enerji projelerine yatırım yapmaktadır. Enerji sektöründe oluşan yeni iş istihdamları küresel ve yerel ekonomiye katkı sağladığı gibi yerel kaynakların kullanımı sayesinde enerji arzını çeşitlendirerek arz-talep dengesini de korumaktadır.

Yenilenebilir enerji kaynakları arasında güneş enerjisi en çok tercih edilen enerji kaynağıdır. Doğrudan güneşten elde edilen bir enerji olduğu için tükenmeyen uzun vadeli bir enerji türüdür. Geleneksel enerji kaynaklarının aksine sera gazı üretimi oldukça az, çevre dostu bir enerjidir. Dünya yüzeyine ulaşan güneş ışınımının %70'i absorbe edilirken, %30'u uzaya geri yansıtılır. Absorbe edilen toplam güneş enerjisi miktarı petrol

ve kömür rezervlerinin toplamından daha fazladır. Bu sayede güneş ışınımını elektrik veya termal enerjiye dönüştüren Fotovoltaik (PV) sistemler enerji sektöründe önemli bir yere sahip olmaya başlamıştır (Ryabushev 2022). Türkiye, güneş enerjisi potansiyeli bakımından oldukça avantajlı bir coğrafi konuma sahiptir. Türkiye Güneş Enerjisi Potansiyeli Atlası'na (GEPA) göre, ülkemizde güneşlenme süresi yıllık ortalama 2741 saat olarak belirlenmiştir. Bu süre, yıl boyunca günlük yaklaşık 7,5 saat güneş alınabildiğini göstermektedir. Ayrıca, ülkemizin ortalama yıllık toplam güneş ışınımı 1527,46 kWh/m² olarak hesaplanmıştır. Bu da Türkiye'nin geniş coğrafi alanlarında güneş enerjisi potansiyelinin yüksek olduğunu ve güneş enerjisinden elektrik üretimi için uygun şartlar sunduğunu göstermektedir. Şekil 1.1'de Türkiye'nin aylık ortalama küresel güneş ışınımı dağılımı gösterilmektedir. Özellikle Güneydoğu Anadolu ve Akdeniz Bölgesi güneş enerjisi alanında yüksek potansiyele sahiptir. Türkiye Elektrik İletim A.Ş. (TEİAŞ) verilerine göre, Şubat 2024 itibari ile elektrik üretiminde yenilenebilir enerjinin payı %51,03 olarak belirlenmiştir. Türkiye'nin güneş enerjisi kurulu gücü ise 12425 MW olmuştur. 2035 yılına kadar güneş enerjisi alanında her yıl 3500 MW kurulu güç artışı hedeflenmektedir.



Şekil 1.1 Türkiye geneli aylık küresel güneş ışınımı dağılımı (İnt. Kyn. 1)

PV panelinin ürettiği güç, güneş ışınımı ile doğrudan ilişkili olduğu için değişkenlik gösterir. Bir PV santralının toplam enerji üretimini tahmin etmek için kullanılan temel parametrelerden biri, zaman içindeki güneş ışınımı değerlerinin ölçülmesidir. Güneş enerjisinin kesintili yapısı ve hava koşullarındaki mevsimsel veya günlük değişimler PV sistemlerinin çıkış gücünün tahmin edilmesini zorlaştırır. Güneş panellerinin verimliliği

bulut, yağmur ve kar gibi olumsuz hava koşulları nedeniyle azalabilir. Bu durum elektrik üretiminde kesintilerine ve dalgalanmalara sebebiyet vermektedir. Bu nedenle güneş enerjisine dayalı sistemlerde enerji arz-talep dengesini sağlamak, fizibilite çalışmalarını yürütmek için güneş ışınım tahmini kritik bir rol oynar (Chodakowska vd. 2023). İyi bir güneş ışınımı tahmini enerji üretiminin önceden planlanabilir olmasını sağlar ve zaman dilimlerine göre enerji talebinin oluşturulmasına imkân vererek PV sistemlerinin depolama ve şebeke maliyetlerini azaltır. Bu nedenle enerji üretimini öngörülebilir, istikrarlı ve sürdürülebilir hale getirmek için güneş ışınımı tahmini büyük önem arz etmektedir.

Literatürde güneş tahmini, hem tahmin ufku hem de kullanılan yöntemler açısından kategorize edilebildiği gibi, güneş ışınımının ölçülen bileşenleri olan küresel güneş ışınımı (GHI), dağınık güneş ışınımı (DHI) ve doğrudan normal güneş ışınımı (DNI) temelinde de sınıflandırılabilir. Tahmin ufku ise çok kısa vadeli (Birkaç saniye–bir saat), kısa vadeli (Bir saat–birkaç saat), orta vadeli (Birkaç gün–bir hafta) ve uzun vadeli (Bir hafta–bir yıl) olmak üzere ayrılır. Tahmin ufku ve kullanılan model arasındaki bağlantı dikkate alındığında, güneş ışınımı tahmini için Sayısal Hava Tahmin Modelleri (NWP), görüntü tabanlı tahmin modelleri, istatistiksel tahmin modelleri ve yapay zekâ tabanlı tahmin modelleri olmak üzere dört temel yaklaşım öne çıkmaktadır. Birden fazla yaklaşımı birleştiren hibrit tahmin modelleri de kullanılan yöntemler arasındadır. Bu yöntemler, tahmin süresine bağlı olarak farklı avantajlar sunmaktadır. Sayısal tahmin yöntemleri fiziksel bir olguyu yeniden üretme ilkesine dayanırken, görüntü tabanlı tahmin modelleri ise gökyüzü görüntülerine ve geçmiş zaman serisi analizinden türetilen uydu tabanlı tekniklerini kullanmaktadır. İstatistiksel tahmin yöntemleri, zaman serisi analizine dayalı metotları içermektedir. Yapay zekâ tabanlı tahmin modelleri ise makine öğrenimi ve derin öğrenme yaklaşımlarını kapsamaktadır (Diagne vd. 2013).

Bu bağlamda gerçekleştirilen tez çalışmasında saatlik güneş ışınımı tahmini için Mevsimsel Otoresif Entegre Hareketli Ortalama (SARIMA) ve Uzun-Kısa Süreli Bellek (LSTM) derin sinir ağını içeren bir hibrit model geliştirilmiştir. Yapılan çalışmada Afyonkarahisar Meteoroloji Müdürlüğü'nden alınan saatlik küresel güneş ışınımı verileri kullanılmıştır. Güneş ışınımı verilerinden oluşturulan zaman serisi Mevsimsel-Eğilim

Ayrıştırması (STL) tekniği ile mevsimsel, eğilim ve düzensizlik bileşenlerine ayrıştırılmıştır. Mevsimsel-eğilim zaman serisi için SARIMA modeli, düzensizlik zaman serisi içinde LSTM derin sinir ağı güneş ışıını tahmini gerçekleştirmiştir. Hibrit yaklaşımın tahmin güvenilirliğini artırmak için güneş ışıını verilerine zaman serisi k-katlı çapraz doğrulama (K-katlı CV) uygulanmıştır ve modelin her dönemde tahmin performansı ve kararlılığı değerlendirilmiştir. Önerilen SARIMA-LSTM hibrit modelinin tahmin yeteneği ve etkinliği performans değerlendirme metrikleri kullanılarak Box-Jenkins ve derin öğrenme yöntemleri ile karşılaştırmalı analizi yapılmıştır.

Tez çalışmasının yapısı şu şekilde organize edilmiştir: İlk bölümde, literatürdeki mevcut çalışmalar ele alınmış ve bu çalışmalara dair önemli bilgilere yer verilmiştir. İkinci bölümde, materyal ve metot kapsamında SARIMA, LSTM, STL, zaman serisi K-katlı CV yöntemleri anlatılmıştır. Daha sonra, deneysel çalışmalar ve bu çalışmalardan elde edilen bulgular paylaşılmıştır. Son bölümde ise çalışmanın genel değerlendirmesi yapılmış ve sonuçlarla birlikte kısıtlamalardan bahsedilerek gelecek çalışmalar için öneriler sunulmuştur.

2. LİTERATÜR BİLGİLERİ

Bu bölümde literatürde yapılan güneş ışınımı tahmin çalışmaları yöntemler bakımından sınıflandırılarak incelenmiştir. Bölüm 2.1'de, gökyüzü ve uydu görüntülerinin kullanıldığı görüntü tabanlı tahmin modelleri sunulmuştur. Bölüm 2.2'de, Sayısal Hava Tahmin (NWP) modelinin kullanıldığı araştırmalara yer verilmiştir. Bölüm 2.3'de Box-Jenkins yöntemlerinin kullanıldığı istatistiksel tahmin modelleri paylaşılmıştır. Bölüm 2.4'de, yapay sinir ağları (ANN), makine öğrenimi (ML), derin öğrenme (DL) tekniklerinin kullanıldığı çalışmalar ele alınmıştır. Son olarak hibrit tahmin modellerinin kullanıldığı çalışmalar ise Bölüm 2.5'de sunulmaktadır. Özetlenen bazı çalışmalara ait Kök Ortalama Kare Hatası (RMSE), Ortalama Sapma Hatası (MBE), Ortalama Mutlak Hatası (MAE), Ortalama Mutlak Yüzde Hatası (MAPE) ve Korelasyon Katsayısı (R^2) değerlendirme metrik sonuçlarına yer verilmiştir.

2.1 Görüntü Tabanlı Tahmin Modelleri

Bulutlar dinamik olduklarından konumları nedeniyle güneşi engelleyebilme potansiyeline sahiptir. Bu nedenle bulut hareketi güneş ışınımı tahmin modellerinin geliştirilmesinde kritik bir rol oynar (Kumar vd. 2010). Yer tabanlı gökyüzü kameraları ve uydu görüntülerinden elde edilen bulut hareketi verileri genellikle kısa vadeli tahminlerde temel girdi olarak belirlenir (Bosch ve Kleissl 2013). Uydu görüntüleyicileri, belirli zaman aralıkları ile görüntüleri yakalar. Zamansal ve uzaysal olarak kaydedilen bu görüntülerden türetilen Bulut Hareket Vektörü (CMV) güneş tahmini için kullanılır (Wang vd. 2019).

Güneş ışınımının ölçülemediği veya kesintiye uğradığı bölgelerde tahmin doğruluğu olumsuz etkilenmektedir. Yang vd. (2019), bu problemi ele aldıkları çalışmada farklı hava koşulları altında Kuzeybatı Çin bölgesindeki GHI tahmini için FY-4A uydusundan gelen verileri kullanmışlardır. Bu yöntem, geçmiş ve gözlemsel verilere ihtiyaç duymadan tahmin yapabilen bulut endeksi metodolojisine dayanmaktadır. Böylece çöl, tepelik gibi ölçümlerin her zaman yapılamadığı bölgelerde güneş tahminlerinin yapılabileceğini ortaya koymuşlardır. Wang vd. (2019), Hollanda bölgesi için yaptıkları

DNI ve GHI tahmin çalışmasında Meteosat İkinci Nesil Jeostatik Uydusu'ndaki Kızılötesi Görüntüleyici'den (SEVIRI) elde ettikleri bulutların fiziksel özelliklerini kullanarak CMV türetmişlerdir. 0-240 dakikalık bir tahmin ufku belirledikleri çalışmada yaz mevsimi dönemi için SEVIRI tahmin modelinin 96 RMSE W/m^2 değeri ile NWP modelinden daha iyi sonuçlar elde ettiğini göstermişlerdir. Myers vd. (2020), güneş ışınımı tahmini için Solis-Heliosat adı verilen uydu tabanlı bir tahmin modeli önermişlerdir. Geliştirdikleri tahmin modeli ile uydu tabanlı modellerin yüksek enlemlerde güneş enerjisi endüstrisi için uygulanabilir olduğunu göstermişlerdir.

Gökyüzü koşulları, güneş ışınımı tahmininin doğruluğunu etkilemekte ve özellikle bulutlu havalarda tahmin doğruluğu düşmektedir. Mouhamet vd. (2018), Fransız Guyanası'ndaki bulutlu gökyüzü koşullarında tahmin doğruluğunu artırmak için Işınım Transfer Parametresi (RTP) kullanmışlardır. Bu parametre sayesinde, Jeostatik Operasyonel Çevre Uydusu (GOES) ve Heliosat-2 uydularından elde edilen yerel bulut özellikleri ayrıntılı bir şekilde analiz edilmiştir.

Gökyüzü kameralı tahmin modelleri güneşin konumunu, bulut hareketi, hava koşulları gibi yerel gökyüzü bilgilerini uydu tabanlı tahmin modellerine kıyasla daha hassas tespit edebilir (Wang vd. 2020). Tüm Gökyüzü Görüntüleyicisi (WSI) ve Bütünsel Gökyüzü Görüntüleyicisi (TSI) gibi yer tabanlı gökyüzü kameraları balıkgözü lensleri sayesinde tüm gökyüzünü kapsayarak bulutların optik özelliklerini analiz etmeye imkân sağlar (Manandhar vd. 2023).

Görüntü tabanlı tahmin çalışmalarında karşılaşılan problemlerden biri de bulut ve gökyüzü tiplerinin hatalı sınıflandırılması ve bulut özelliklerinin yetersiz çıkarılmasıdır. Wu vd. (2024), bulut-gökyüzü tanımlama sürecini daha etkili hale getirmek için bir kümeleme ve sınır düzeltme algoritması önermişlerdir. Önerdikleri algoritma ile bölgesel ve küresel özellikler dâhil olmak üzere tüm gökyüzü görüntülerinden çok boyutlu özellikler çıkarmayı amaçlamışlardır. Caldas vd. (2019), Uruguay, Salto'da bulutların ortalama hareketini dikkate alarak çok kısa vadeli bir tahmin ufku gerçekleştirmişlerdir. Yaptıkları çalışmada gerçek zamanlı ışınım ve tüm gökyüzü görüntü değerlerini

birleştiren bir yöntem sunarak güneşli hava koşulları altında 25,5 MBE W/m² değeri elde etmişlerdir.

Farklı irtifalarda bulunan bulutların hızı aynı olmadığı için sadece bulutların ortalama hızını almak iyi bir tahmin performansı için yeterli gelmez. Bu nedenle, Dissawa vd. (2021) Avustralya'nın Wollongong şehri için yürüttükleri çalışmada, bulutların ortalama hızını hesaplamak yerine, bulutların bireysel hareketleri, yerden yükseklikleri ve bulut kalınlıklarını dikkate alarak bir model geliştirmişlerdir. Geliştirdikleri modelin farklı katmanlardaki bulut hızlarını tespit ederek 1 dakikalık bir tahmin ufku için %81'lik bir doğruluk elde ettiğini gözlemlemişlerdir. Bulutların seviyelerine göre sınıflandırılması ve bulutların bireysel hareketinin izlenmesi tahmin performansını büyük oranda iyileştirdiği sonucunu ortaya koymuşlardır. Chu vd. (2022), Tayvan bölgesi için kısa vadeli GHI tahmin çalışmasında önerdikleri yeni bulut özelliği çıkarma yöntemi ile bulut dağılımının ve bulut kalınlığı girdilerinin güneş tahmininde belirleyici parametreler olduğunu vurgulamışlardır.

Tüm gökyüzü görüntüleyici (ASI) kamera özellikleri, algoritmaları ve güneş tahmini yaklaşımları bakımından farklılık gösterir. Logothetis vd. (2022), İspanya'da kısa vadeli GHI tahmini için farklı yöntemlere dayanan dört adet ASI kullanmışlardır. Tüm ASI modelleri %6,9 ile %18,1 arasında değişen bir RMSE değeri ile tahmin gerçekleştirmiştir. Liu vd. (2023), gökyüzü görüntülerinden uzaysal-zamansal bilgi çıkarımı üzerinde durmuşlardır. Gri tonlamalı gökyüzü görüntülerinin uzaysal-zamansal özelliklerini tanımlamak için bir küboid yöntemi önerilerek bilgi havuzu oluşturulmuştur. Dinamik ve statik olarak çıkarılan uzaysal-zamansal özellikler sayesinde, diğer nesne algılama yöntemlerine kıyasla üstün bir tahmin performansı elde etmişlerdir.

2.2 Sayısal Hava Tahmin (NWP) Modelleri

Atmosferde meydana gelen değişiklikleri fiziksel olarak tanımlayan denklemlerin matematiksel analizi NWP modellerinin temel prensibi olarak ifade edilebilir. (Lorenz vd. 2012). Kısa vadeli tahmin ufku için NWP modeller iyi bir seçenektir. Yalnız bulutlu gökyüzü şartlarında NWP modelleriyle DNI tahmini güçleşmektedir. Kısa vadeli DNI

tahmin doğruluğunu artırmaya yönelik Xie vd. (2022), Hava Durumu Araştırması ve Tahmini (WRF-Solar) tabanlı bir model geliştirmişlerdir. Önerilen modelin bulut bilgilerindeki belirsizliği önemli ölçüde azalttığı sonucuna varmışlardır. Verbois vd. (2018), bir başka kısa vadeli GHI tahmini çalışmasında önerdikleri WRF model ile LSTM modeli karşılaştırmışlardır. Önerilen WRF model %19 daha az hata değeri ile tahmin gerçekleştirmiştir. Kademeli değişken seçimi, boyut azaltma gibi istatistiksel öğrenme teknikleri ile birleştirilen WRF modelin tahmin doğruluğunu iyileştirdiğini gözlemlemişlerdir. Yang vd. (2022), Kaya çölü bölgesinde, 1 ile 12 saat arasında değişen bir tahmin ufku için yüksek çözünürlüklü modeller kullanmışlardır. Geliştirdikleri tahmin modeli %14,0-33,7'lik bir RMSE değeri ile en iyi tahmin performansı göstermiştir. Uzun merkezleri ve hava durumu tahmin ajansları tarafından üretilen sayısal hava durumu tahmin bilgilerinin kullanımının güneş enerjisi uygulamalarında çok önemli olduğunu vurgulamışlardır.

Huang vd. (2018), Avustralya'daki saatlik GHI tahmini için yaptıkları çalışmada ise Dünya Sistemi Simülatörü (ACCESS) ve Küresel Tahmin Sistemi (GFS) kullanan NWP modellerinin tahmin yeteneklerini incelemişlerdir. Zhang vd. (2022), kısa vadeli GHI tahmini için kullanılan NWP bilgilerini saatlik olarak güncellemişlerdir. Bu çalışmaya yenilik olarak, NWP modelinin doğal yanlılık etkilerini ortadan kaldırmak için bir kalman filtresi kullanmışlardır. Sonuçlar, kalman filtresi ile desteklenen NWP modelinin daha düşük hata değeriyle tahmin yapabildiğini ortaya koymaktadır.

2.3 İstatistiksel Tahmin Modelleri

Farklı tahmin ufukları için tercih edilen istatistiksel tahmin modelleri, güneş ışıını zaman serisinin gelecekteki eğilimlerini belirlemek amacıyla ışıını değerlerinin geçmiş verilerini kullanır. Yüksek doğrulukta bir güneş ışıını tahmini için en az 1 seneyi içeren veri seti gerekmektedir. Shadab vd. (2019), Hindistan Delhi'de aylık GHI tahmini için SARIMA modeli önermişlerdir. 1984 ile 2015 yılları arası toplam 34 yıla ait aylık güneş ışıını değerleri girdi parametresi olarak kullanmışlardır. Aynı araştırmacıların sonraki çalışmalarında ise, yüksek güneş potansiyeline sahip bölgeleri belirlemek ve enerji

yatırımcılarına fikir vermek amacıyla Delhi şehrinin birden fazla bölgesi için SARIMA modeli geliştirmişlerdir (Shadab vd. 2020).

Farklı iklim koşulları altında güneş potansiyelini incelemek için Chodakowska vd. (2023) birbirine zıt iklimlere sahip olan Ürdün ve Polonya için aylık GHI tahmini gerçekleştirmişlerdir. Çalışmalarında önerdikleri Ototregresif Entegre Hareketli Ortalama (ARIMA) modelleri %85 üzerinde R^2 değeri elde etmiştir. Sansa vd. (2020), kış mevsiminde Kuzey Barselona için günlük GHI tahmin çalışmasında geliştirdikleri Ototregresif Hareketli Ortalama (ARMA) modelin güneş ışınımı değerlerindeki sapmaları etkili bir şekilde yakaladığını ortaya koymuşlardır. İstatiksel tahmin modellerinin performansı, mevsimsel koşulların yanı sıra gün içindeki hava koşullarındaki değişikliklerden de etkilenmektedir. El Alani vd. (2022) Fas, Missouri şehri için dört farklı hava koşulunu dikkate alarak saatlik GHI tahmini gerçekleştirmişlerdir. Kullanılan SARIMA modelinin açık ve daha az değişken hava koşullarında etkili bir performans gösterdiğini 28,58 RMSE W/m^2 ve 0,94 R^2 değeri ile sunmuşlardır.

Haider vd. (2022), Pakistan, İslamabad'da günlük ve aylık GHI tahmini için çoklu girdi değerleri kullanarak SARIMA modelinin genişletilmiş hali olan SARIMAX modelini önermişlerdir. Önerilen modelin 0,95 R^2 değeri elde ettiğini gözlemlemişlerdir. Mishra vd. (2022), ARIMA ve Bulanık Mantık (FL) modellerini, saatlik DNI tahmini için önermişlerdir. Performans değerlendirme metrikleri ile karşılaştırıldıklarında, FL modeli daha az hata ile yüksek doğrulukta güneş tahmini gerçekleştirmiştir. Santos vd. (2022), Brezilya için saatlik GHI tahmininde, önerdikleri ARIMA modelinin ML tabanlı modellere göre daha düşük bir tahmin performansı sergilediğini ortaya koymuşlardır. Wathmini vd. (2018), Sri Lanka için yaptıkları DNI tahmini çalışmasında ise, geliştirdikleri ARIMA modelin, ANN, Rastgele Orman Ağacı (RF), Destek Vektör Makinesi (SVM) ve Doğrusal Regresyon (LR) modellerinden 29,64 RMSE W/m^2 değeri ile daha iyi tahmin performansı gösterdiğini aktarmışlardır. Bu çalışma ML modellerinin Box-Jenkins yöntemlerinden iyidir varsayımının her zaman doğru olmadığını göstermektedir. Belmahdi vd. (2021), saatlik GHI tahmin modeli olarak önerdikleri ARIMA modelinin de 22,014 RMSE W/m^2 değeri elde ederek SVM ve K-En Yakın

Komşu (k-NN) ML modellerinden daha iyi bir tahmin kabiliyetine sahip olduğunu ileri sürmüşlerdir.

ARIMA modellerinin performansı, girdi değişkenine, tahmin ufkuna ve mevsimsel özelliklere bağlı olarak negatif veya pozitif yönde etkilenebilir. Paulescu vd. (2019), hiçbir modelin en iyi olarak nitelendirilemeyeceğini, ancak, bir modelin diğerlerine kıyasla üstün performansına katkıda bulunan özelliklerin tartışmalı olduğunu savunarak çalışmalarında bu durumu belirtmişlerdir.

2.4 Yapay Zekâ Tabanlı Tahmin Modelleri

Güneş enerjisi uygulamalarında en çok tercih edilen yaklaşımlardan biri olan yapay zekâ, ileri besleme ve geri besleme yayılımı gibi algoritmalar kullanarak tahmin gerçekleştirir (Qazi vd. 2015).

Arora vd. (2021) Hindistan, Chandigarh'da aylık GHI tahmini için Elman Geri Yayılım (BP) algoritması ile eğitilmiş ANN tabanlı model önermişlerdir. Veri hazırlama için ondalık normalizasyon tekniği kullanmışlardır. Elman-BPNN modeli ile İleri Beslemeli Sinir Ağı (FFNN) modelini karşılaştırarak önerilen modelin daha iyi tahmin performansı gösterdiğini ortaya koymuşlardır. Mohamed vd. (2019), geri yayılım türlerinden biri olan momentum ve öğrenme katsayılı BP algoritması ile eğitilen bir sinir ağı modelini Mısır'ın Asvan şehri için günlük GHI tahmini gerçekleştirmek üzere önermişlerdir. Önerilen model standart BPNN modelinden daha az hatayla tahmin gerçekleştirmiştir. Kurniawan vd. (2021), Endonezya, Surabaya şehrinde saatlik GHI tahmini için Levenberh-Marquand BP algoritmasını geliştirmişlerdir. Levenberg-Marquand BPNN modeli, 0,983 R² değeriyle tahmin performansı göstermiştir.

Literatürde, güneş ışınımı tahmini için deneylere ve gözlemlere dayalı doğrusal modeller de geliştirilmiştir. Arslan vd. (2019) Türkiye, Mersin'de günlük GHI tahmini için geliştirdikleri Angström-Prescott tipi doğrusal model ile Levenberg-Marquand BP algoritması ağ yöntemini karşılaştırmışlardır. Şahan vd. (2021), aynı şekilde başka bir çalışmada Türkiye, Antakya şehri için aylık GHI tahmini gerçekleştirmek üzere

Angström-Prescott tipi doğrusal model ile Levenberg-Marquand BP yöntemini karşılaştırmışlardır. Her iki çalışmada da önerilen BPNN modelinin daha iyi bir tahmin sonucu elde ettiğini ortaya koymuşlardır. Antonopoulos vd. (2019), Kuzey Yunanistan bölgesi için önerdikleri BPNN modeli 3,166 RMSE MJ/m² ve 0,88 R² değeri ile LR modelinden daha yüksek doğrulukta tahmin gerçekleştirdiği sonucuna ulaşmışlardır.

Chaibi vd. (2021) ML modellerinin tahminlerini açıklamak ve iyileştirmek için permütasyon özellik önemi (PFI) ve Shapley eklemeli açıklamalar (SHAP) yorumlama tekniklerini kullanmışlardır. Fas, Fez şehri için gerçekleştirdikleri GHI tahmini çalışmasında Işık Gradyan Güçlendirmesi (LightGBM), Çok Katmanlı Algılayıcı (MLP), Çoklu Doğrusal Regresyon (MLR) ve SVM modellerini karşılaştırmalı olarak incelemişlerdir. Tahmin modelinin nasıl çalıştığını ve hangi özelliklerin tahminler üzerinde etkisi olduğunu belirlemişlerdir. Sonuçlar, LightGBM tahmin modelinin daha yüksek doğrulukta tahmin performansı ile diğer modelleri geride bıraktığını göstermiştir.

Benali vd. (2019), Fransa'nın Odeillo bölgesinde güneş ışınımının üç bileşeninin (GHI, DNI, DHI) saatlik değerlerini tahmin etmek için bir ANN modeli geliştirerek, ML yöntemlerinden biri olan RF modeli ile karşılaştırmışlardır. Yüksek meteorolojik değişkenlik dönemlerinde, RF modeli daha iyi bir tahmin performansı gösterdiği sonucuna ulaşmışlardır. Ancak, bu her zaman kabul edilen bir olgu değildir. Marzouq vd. (2020), Fas için saatlik bir GHI tahmininde, önerdikleri ANN modelinin, RF modelinden daha iyi bir tahmin performansı sergilediğini göstermişlerdir. Aynı araştırmacılar, başka bir çalışmada Fas'ın Fez bölgesinde GHI tahmini için Levenberg-Marquardt BPNN modelini önermişlerdir. Önerilen modelin 0,97 R² değeri ile anlamlı bir tahmin sonucu elde ettiğini ifade etmişlerdir (Marzouq vd. 2018).

Shuvho vd. (2019), Bangladeş, Dakka için aylık güneş ışınımı tahmininde FL modeli ile İleri Beslemeli BPNN modelini karşılaştırmalı olarak analizini sunmuşlardır. Bulgular, önerdikleri sinir ağı modelinin %98,78 doğrulukla daha iyi tahmin performansı sergilediğini göstermektedir. Ağbulut vd. (2021), günlük GHI tahmini için geliştirdikleri BPNN modelinin tahmin sonuçlarını k-NN, SVM ve DL modellerinin performansı ile karşılaştırmalı olarak incelemişlerdir. Sonuçlara göre, k-NN modelin en kötü tahmin

performansı gösterdiğini, BPNN modelinin ise en iyi tahmin yeteneğine sahip olduğu elde edilmiştir.

ANN modellerinin tahmin performansını etkileyen faktörlerden biri, giriş parametrelerinin özellikleri ve sayısıdır. Arıman vd. (2021), farklı giriş parametreleri kullanarak oluşturdukları ANN modellerini, günlük GHI tahmini için karşılaştırmışlardır. En iyi güneş ışımasını tahmin edebilecek değişkenleri belirlemeyi amaçlamışlardır. Giriş parametrelerine bir önceki günün güneş ışıması değerinin eklenmesinin tahmin performansını iyileştirdiğini gözlemlemişlerdir.

Li vd. (2019) Çin, Hong Kong'da saatlik GHI tahmini için birden fazla bağımlı ve bağımsız değişkeni birlikte değerlendirebilen Çok Değişkenli Uyarlamalı Regresyon Eğrileri (MARS) tekniğini geliştirmişlerdir. Giriş değişkenlerinin farklı birleşimleri ile oluşturulan 16 MARS modelinin performansını analiz etmişlerdir. Wanxiang vd. (2018), SVM tabanlı modelleri, Çin'in Pekin kentinde günlük GHI tahmini için önermişlerdir. Araştırmacılar yüzey sisi ve pusunun güneş ışımasını tahmini üzerindeki etkisini gözlemlemişlerdir. Giriş değişkenlerine ek olarak Hava Kalitesi İndeksi (AQI) parametresini dâhil etmişlerdir. Modellerin tahmin performansını karşılaştırdıklarında AQI giriş parametresine sahip SVM modelinin, RMSE değerini düşürerek tahmin performansını iyileştirdiğini ortaya koymuşlardır.

Fan vd. (2018), sınırlı meteorolojik veriler kullanarak Çin bölgesinde günlük ışıma tahmini için Aşırı Gradyan Artırma (XGboost) ve SVM modellerinin tahmin performansını değerlendirmişlerdir. XGBoost modeli daha düşük hata değeri elde ederek SVM modelinden daha iyi bir tahmin yeteneğine sahip olduğunu göstermiştir.

Meteorolojik değişkenlere ek olarak, bulut ve gökyüzü görüntüleri de giriş verisi olarak kullanılabilir. Pedro vd. (2018), Folsom, Kaliforniya'da saatlik GHI tahmini için geliştirdikleri Gradyan Artırma (GB) ve k-NN tekniklerinin tahmin performansını karşılaştırmalı olarak analiz etmişlerdir. Önerilen GB modelinin, giriş parametrelerine gökyüzü görüntülerinin eklenmesiyle daha etkili bir performans gösterdiğini ifade etmişlerdir.

Giriş parametrelerinin sayısı ve özellikleri, SVM yönteminin verimliliği üzerinde önemli bir etkiye sahiptir ve bu parametrelerin optimize edilmesi de tahmin doğruluğunu etkileyebilir. Fan vd. (2020), Çin, Pekin'de günlük GHI tahmini için önerdikleri SVM tabanlı modeli, Parçacık Sürüsü (PSO), Yarasa (BAT) ve Balina (WOA) algoritmalarını kullanarak optimize etmişlerdir. Sezgisel algoritmaların SVM modelinin tahmin performansını büyük ölçüde iyileştirdiğini vurgulamışlardır. Huang vd. (2021), Çin'in Ganzhou kentinde aylık ve günlük GHI tahmini gerçekleştirmek üzere 12 ML tekniğini karşılaştırmalı analizini sunmuşlardır. GB tekniği günlük güneş ışınımı tahmininde başarılı bir tahmin performansı gösterirken, XGBoost tekniği aylık ışınım tahmininde başarılı bir tahmin performansı göstermiştir.

Demir vd. (2023), Ekstrem Öğrenme Makineleri (ELM), SVM, Gauss İşlem Regresyonu (GPR), k-NN ve LSTM olmak üzere beş farklı ML yöntemini kullanarak aylık GHI tahmini için bir çalışma yürütmüşlerdir. Çalışmada, Türkiye genelindeki çeşitli iklimlerde bulunan toplam 163 meteoroloji istasyonundan parametreler kullanılmıştır. LSTM ve GPR modellerinin kurak ve yarı kurak iklimler için daha etkili olduğunu ortaya koymuşlardır. Ayko vd. (2021) Türkiye, Eskişehir şehrinde aylık GHI tahmini için 45 ML modelini karşılaştırmışlardır. Değerlendirme metrik sonuçlarına göre en iyi yedi model sırası ile RF, Ekstra Ağaçlar, HistGB, Karar Ağacı (DT), Bagging Ağacı, LightGBM olarak elde etmişlerdir. Takilalte vd. (2022) kısa vadeli güneş ışınımı tahmini için doğrusal olmayan otoregresif sinir ağı (NAR), SVM ve RF modellerini karşılaştırmalı olarak incelemişlerdir. Çalışma bölgesi olarak akdeniz ve kurak iklim olmak üzere iki farklı bölge seçmişlerdir. RF modelin her iki iklim tipinde de en iyi tahmin sonuçları ortaya koyduğunu göstermişlerdir.

Hiyerarşik öğrenme olarak da bilinen DL, ML ve ANN'nin birden fazla gizli katmanı olan belirli bir alanıdır (Ongsulee vd. 2017). LSTM, Tekrarlayan Sinir Ağı (RNN), Derin Tekrarlayan Sinir Ağı (DRNN) ve Evrişimli Sinir Ağı (CNN), derin sinir ağı modellerinden bazılarıdır. RNN modelinin eğitim aşamasındaki gradyan kaybolması ve bellek sorunlarını ele almak için araştırmacılar, bellek hücreleri ve kapı mekanizmasına sahip LSTM mimarisini ve Kapılı Tekrarlayan Birimler (GRU) mimarisini geliştirmişlerdir (Hu vd. 2018).

Chandola vd. (2020), Thar çölünün Bikaner bölgesindeki saatlik GHI tahmini için LSTM modeli tasarlamışlardır. Önerdikleri model, farklı zaman aralıkları için 0,0995 RMSE W/m^2 ile en düşük hata değerine ulaşmıştır. Wentz vd. (2022), Kaliforniya'daki Folsom şehrinde 1, 15 ve 60 dakikalık tahmin ufukları için önerdikleri ANN ve LSTM modellerin tahmin performansını karşılaştırmışlardır. LSTM modelin, %1,63 daha düşük bir MAPE değeriyle ANN modelinden daha yüksek doğrulukta tahmin gerçekleştirdiği sonucunu ortaya koymuşlardır. Qing vd. (2018), Santiago, Cape Verde'de saatlik GHI tahmini için BP algoritması ile eğitilen ANN modelini LSTM modeli ile karşılaştırarak bir tahmin çalışması gerçekleştirmişlerdir. 5 yıllık veri kullanıldığında, LSTM modeli BPNN modelinden %18,34 daha fazla bir doğruluk elde ederken, 10 yıllık veri kullanıldığında, %42,9 daha yüksek bir doğruluk elde ettiğini göstermişlerdir.

Yu vd. (2019), RNN ve LSTM modellerini karşılaştırarak saatlik ve günlük GHI tahmini gerçekleştirmişlerdir. Bulutlu günlerde tahmin performansını artırmak için netlik indeksi parametresi bir girdi olarak eklenmiştir. RNN modelinin, bellek sorunu nedeniyle LSTM kadar etkili tahmin kabiliyetine sahip olmadığını vurgulamışlardır. Wojtkiewicz vd. (2019), Phoenix, Arizona için gerçekleştirdikleri saatlik GHI tahmini çalışmasında GRU ve LSTM modellerini karşılaştırmalı olarak incelemişlerdir. LSTM modeli, 66,75 RMSE W/m^2 değeri ile daha iyi bir tahmin yeteneğine sahip olduğunu göstermiştir.

Aslam vd. (2019) gerçekleştirdikleri bir başka GRU ve LSTM karşılaştırma çalışmasında saatlik ve günlük güneş ışınımı tahmininde GRU modelinin daha yüksek tahmin doğruluğu elde ettiğini göstermişlerdir. Brahma vd. (2020), Hindistan'daki bir bölgede günlük GHI tahmini için LSTM, Çift Yönlü LSTM, GRU, Dikkat-LSTM modelleri geliştirmişlerdir. 3,16 RMSE W/m^2 ve 0,88 R^2 değeri ile en iyi metrik sonuçları veren tahmin modelinin LSTM olduğunu ortaya koymuşlardır.

Kara (2019) Türkiye, Çorum ili için günlük GHI tahmini çalışmasında, RF, k-NN, GB ve DT modelleri LSTM modeliyle karşılaştırmıştır. LSTM modeli 15,87 MAE W/m^2 değeri ile en iyi tahmin sonucunu verirken, DT modeli en kötü tahmin performansını göstermiştir. Bamisile vd. (2021), üç geleneksel ML modeli (RF, SVM, Polinom Regresyonu) ve üç DL modelini (CNN, ANN, RNN) Nijerya, Borno için güneş ışınımı

tahmininde karşılaştırmalı olarak analiz etmişlerdir. DL modellerinin aksine, ML yöntemlerinden biri olan RF modelinin daha iyi bir tahmin performansı elde ettiğini göstermişlerdir. Burada belirtilen sonucun aksine, Mishra vd. (2023), Penn State'te saatlik GHI tahmini için önerdikleri LSTM modelinin tahmin yeteneğini geleneksel ML yöntemlerine kıyasla %71,5 oranında iyileştirdiğini ortaya koymuşlardır.

Mukhoty vd. (2019), GB modelini, Hindistan'da güneş ışıınımı tahmini üzerine yapılan bir çalışmada LSTM modeliyle karşılaştırmışlardır. Metrik sonuçlarına göre, LSTM modeli 18,1 MAE W/m² daha az hata değeri ile tahmin performansı göstermiştir. Yapılan çalışmada modelin tahmin performansının giriş değişkenlerinin sayısına göre değişmesine dikkat çekmişlerdir. Yakın bölgenin meteorolojik bilgilerini hesaba katan LSTM modeli, yalnızca geçmiş ışıınım değerlerine dayalı olarak geliştirilen LSTM modelinden daha doğru sonuçlar elde ettiğini göstermişlerdir. Huang vd. (2020), saatlik GHI tahmini için geliştirdikleri LSTM modelinin tahmin yeteneğini farklı parametreler kullanarak incelemişlerdir. Ertesi gün için hava durumu bilgilerini giriş parametrelerine dâhil eden LSTM modelinin 75,22 RMSE W/m² değeri elde ettiği sonucuna ulaşmışlardır.

2.5 Hibrit Tahmin Modelleri

Güneş tahmini üzerinde çalışan araştırmacılar, hassas ve doğru tahminler elde etmek için verileri iyi bir şekilde analiz etme yeteneğine sahip olan hibrit modeller geliştirmişlerdir (Hou vd. 2018). Hibrit modeller doğrusal, doğrusal olmayan ve hem doğrusal hem de doğrusal olmayan olmak üzere üç şekilde kullanılır (Diagne vd. 2013).

Alvarado vd. (2021), uygun parametreleri elde etmek için PSO ve GA gibi optimizasyon algoritmalarıyla hibrit bir şekilde oluşturulmuş SVM modellerini inceleyerek tahmin hatasını en aza indirmeyi amaçlamışlardır. Halabi vd. (2018), güçlü bir tahmin çıkarımı elde etmek için ANN ve FL yöntemlerinin avantajlarını birleştiren ANFIS modelini Malezya'da aylık GHI tahmini için kullanmışlardır. Önerdikleri ANFIS modelini, Diferansiyel Evrim (DE) algoritmaları, GA, PSO kullanarak optimize etmişlerdir. Metrik sonuçlar karşılaştırıldığında, ANFIS-PSO hibrit yöntemi 0,306 RMSE MJ/m² değeri ile

daha iyi bir tahmin performansı elde ettiği sonucuna ulaşmışlardır. Alrashidi vd. (2021) SVM modelini, Çekirge Optimizasyon Algoritması (GOA) ve Boruta tabanlı özellik seçimi algoritmasıyla (BA) birleştirerek Suudi Arabistan'ın farklı bölgelerindeki saatlik güneş ışıını tahmini için kullanmışlardır. Önerilen modelin bağımsız SVM modellerinden %32,15-39,69 oranında daha iyi bir tahmin performansı sergilediğini göstermişlerdir. Guermouni vd. (2021), En küçük kareler destek vektör makinesi (LSSVM) ve yapay arı kolonisi (ABC) algoritmasının birleştirerek saatlik güneş ışıını tahmini için bir hibrit model geliştirmişlerdir. Önerdikleri modelin korelasyon katsayısı ve hata metrikleri bakımından iyi bir tahmin sergilediğini ortaya koymuşlardır.

Belmahdi vd. (2020), hibrit yöntemi tek değişkenli zaman serisi tahmin analizinde kullanılan ARIMA modelinin performansını artırmak için kullanmışlardır. Fas bölgesi için günlük GHI tahmini gerçekleştirmek üzere ARIMA modeli, ANN modeli ile hibrit olarak birleştirilmiştir. Önerilen hibrit model 0,98 R² değeri ile anlamlı bir tahmin performansı göstermiştir. Aynı araştırmacılar bir başka çalışmalarında ARIMA modelini FFBP-ANN ile hibrit olarak önermiştir. Fas bölgesi için gerçekleştirdikleri günlük GHI tahmininde hibrit model 0,99 R² değeri elde etmiştir (Belmahdi vd. 2023).

El Alani vd. (2021), MLP modelini kısa vadeli güneş ışıını tahmini için CNN ile birlikte hibrit olarak kullanmışlardır. CNN yöntemi gökyüzü görüntülerinden özellikler çıkararak MLP ağına bu bilgileri güneş ışıını ile hava koşulları arasında bir ilişki kurması için girdi olarak vermektedir. Si vd. (2020), uydu görüntülerini içeren hibrit bir CNN modeli kullanarak saatlik GHI tahmini gerçekleştirmişlerdir. Burada, bulut konumlarının güneş ışıını tahmininin performansı üzerindeki etkisi araştırılmıştır. Uydu görüntüleri ve gökyüzü görüntüleri kullanılan bir başka çalışmada Paletta vd. (2023), Fransa'da saatlik GHI tahmininde 134,9 RMSE W/m² değeri elde etmişlerdir.

Kumari vd. (2021), Kaliforniya bölgesi için saatlik GHI tahmini gerçekleştirmek üzere LSTM-CNN hibrit modelini tasarlamışlardır. Geliştirdikleri model, çeşitli hava koşulları altında 42,89 RMSE W/m² değeri ile en iyi tahmin sonucunu vermiştir. Yan vd. (2020), kısa vadeli güneş tahmini için hibrit bir GRU-Dikkat-LSTM modeli önermişlerdir. Basit

yapısı ve daha hızlı yüksek eğitim süresi avantajlarına sahip olan hibrit model 0,99 R² değeri elde etmiştir.

Zhu vd. (2025), farklı iklim özelliklerine sahip üç ayrı bölge için kısa vadeli güneş ışınımı tahmini gerçekleştirmek üzere U-net mimarisinden esinlenerek LSTM-AFT hibrit modelini geliştirmişlerdir. AFT dikkat mekanizması, zaman serisi verilerindeki gürültüyü azaltarak modelin tahmin yeteneğini önemli ölçüde optimize eder. Bu sayede önerdikleri hibrit modelin güneş ışınımı verilerinin uzaysal-zamansal özelliklerini daha iyi yakalayabildiği ve tahminin doğruluğunu ve sağlamlığını iyileştirdiğini ortaya koymuşlardır.

Huang vd. (2021), Dalgacık Paket Ayırıştırması, CNN, LSTM ve MLP modellerini birleştirerek yeni bir hibrit derin sinir ağı modeli önermişlerdir. Orijinal güneş ışınımı zaman serisini Dalgacık Paket Ayırıştırması (WPD) ile dört alt seriye ayırmışlardır. Elde ettikleri alt serileri sırası ile CNN, LSTM ve MLP modeline girdi olarak kullanmışlardır. Önerdikleri modelin, geleneksel modellerin eksikliklerinin üstesinden geldiğini ve daha doğru bir tahmin sonucu elde ettiğini ortaya koymuşlardır.

Ajith ve Ramon (2023), mekânsal ve zamansal özellik çıkarımı yapabilen çoklu görüntülü hibrit bir MICNN-LSTM modeli önermişlerdir. Geliştirdikleri modelin tahmin yeteneğini zaman serisi ve görüntü tabanlı modeller ile karşılaştırmalı olarak incelemişlerdir. Ayrıca çalışmalarında en iyi tahmin sonucunu elde eden MICNN-LSTM modeli için harici bir özellik çıkarımına gerek olmadığını göstermişlerdir.

Zang vd. (2020) güneş ışınımı tahmin doğruluğunu artırmak için zamansal ve mekânsal özellik çıkarımı yapabilen CNN-LSTM hibrit modeli geliştirmişlerdir. Önerdikleri modeli 1 yıl boyunca farklı mevsimsel koşullar altında test etmişlerdir. Bulgulara göre, kısa vadeli güneş ışınımı için iyi bir alternatif sağladığını göstermişlerdir. Huynh vd. (2021), çok kısa vadeli güneş ışınımı tahmin çalışması için Yerel Ortalama Ayırıştırma metodu (RLMD) ile ML modelini hibrit olarak kullanmışlardır. Elde edilen bulgular önerilen metodun gerçek zamanlı enerji yönetimi ve yenilenebilir enerjinin bir elektrik

şebekesine entegrasyonuna yönelik işlemler için potansiyel bir tahmin yöntemi olabileceğini göstermiştir.

Literatürde bireysel modellerin daha iyi tahmin performansı gösterdiğini belirten çalışmalar da vardır. Jaihuni vd. (2020), ARIMA ve Çift Yönlü Kapılı Birim (Bi-GRU) modellerini Güney Kore'de kısa vadeli güneş ışınımı tahmini için hibrit olarak kullanmışlardır. Önerilen hibrit model, bireysel modellere kıyasla 0,84 R^2 değeri ile daha düşük tahmin performansı sergilemiştir. Bu sonuç, hibrit yöntemlerin her zaman tek başına kullanılan modellerden üstün olacağı varsayımının her durumda geçerli olmadığını ortaya koymaktadır.



3. MATERYAL ve METOT

Bu bölümde tez çalışmasında kullanılan veri seti ve geliştirilen yöntemlere dair ayrıntılı bilgilere yer verilmiştir. İlk olarak, Toplam Küresel Güneş Işınımı hakkında bilgi verilerek çalışmada kullanılan veri bilgileri sunulmuştur. Ardından bu verilere uygulanan zaman serisi K-katlı CV tekniği ele alınmıştır. Son olarak güneş ışınımı tahmini amacıyla geliştirilen modellere ilişkin açıklamalar yapılmış ve önerilen hibrit yöntem detaylandırılarak aktarılmıştır.

3.1 Toplam Küresel Güneş Işınımı

Güneş ışınımı, birim alana düşen güneş enerji akısını tanımlamaktadır ve watt/m^2 olarak ölçülür. Küresel Güneş Işınımı (GHI), belirli bir zaman dilimi içinde yatay bir yüzeye ulaşan güneş enerji akısı miktarını ifade eder. Bu değer, hem doğrudan güneş ışığından gelen ışınımı hem de atmosfer tarafından saçılan ışınımı içermektedir (Paulescu vd. 2023). Doğrudan Normal Işınımı (DNI), güneşten doğrudan dünyaya ulaşan ve yatay düzlemde ölçülen güneş enerjisi akısını ifade eder. DNI, θz zenit açısı olmak üzere denklem (3.1) de yer alan kosinüs yasası ile tanımlanır:

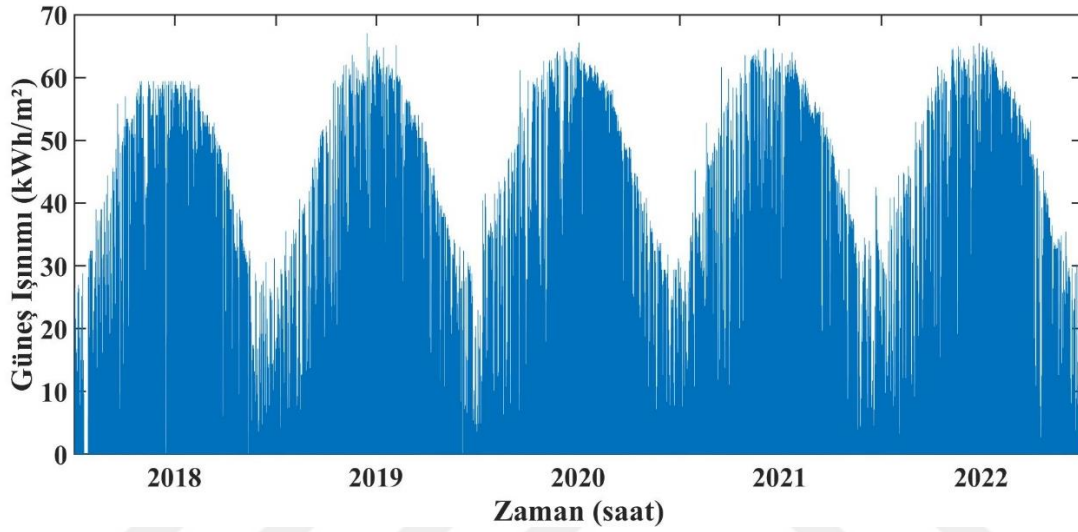
$$DNI \times \cos(\theta z) \quad (3.1)$$

Dağınık Güneş Işınımı (DHI) atmosferdeki bileşenler tarafından saçılan fakat yine de dünya yüzeyine ulaşan güneş ışınımını ifade eder. Küresel güneş ışınımı dağınık ve doğrudan ışınım bileşenlerinin toplamı olarak denklem (3.2) ile ifade edilmektedir.

$$GHI = DNI \times \cos(\theta z) + DHI \quad (3.2)$$

Tez çalışmasında Afyonkarahisar Meteoroloji Müdürlüğü'nden elde edilen Afyonkarahisar iline ait saatlik küresel güneş ışınım verileri kullanılmıştır. Şekil 3.1, Afyonkarahisar iline ait, 2018-2022 yılları arasında ölçülen saatlik güneş ışınım verilerinden oluşturulmuş zaman serisi grafiğini göstermektedir. Küresel Güneş Işınımı değeri birimi kWh/m^2 olarak belirlenmiştir. Bu metrik, bir yüzeyin birim alanına bir saat

süre boyunca düşen ve biriken toplam enerjiyi ifade eder. Güneş ışıını veri seti için zaman serisi 10-katlı CV tekniđi uygulandıđından eğitim ve test veri setleri deđişmektedir. Eğitim süreci için veri setinin 1 Ocak 2018 – 18 Temmuz 2022 tarihleri arası 39840 saati sırası ile kullanılırken, geliştirilen modellerin ve hibrit yöntemin tahmin yeteneđini test etmek için ise 16 Haziran 2018 – 31 Aralık 2022 tarihleri arası 3984 saatlik dönemler kullanılmıştır.



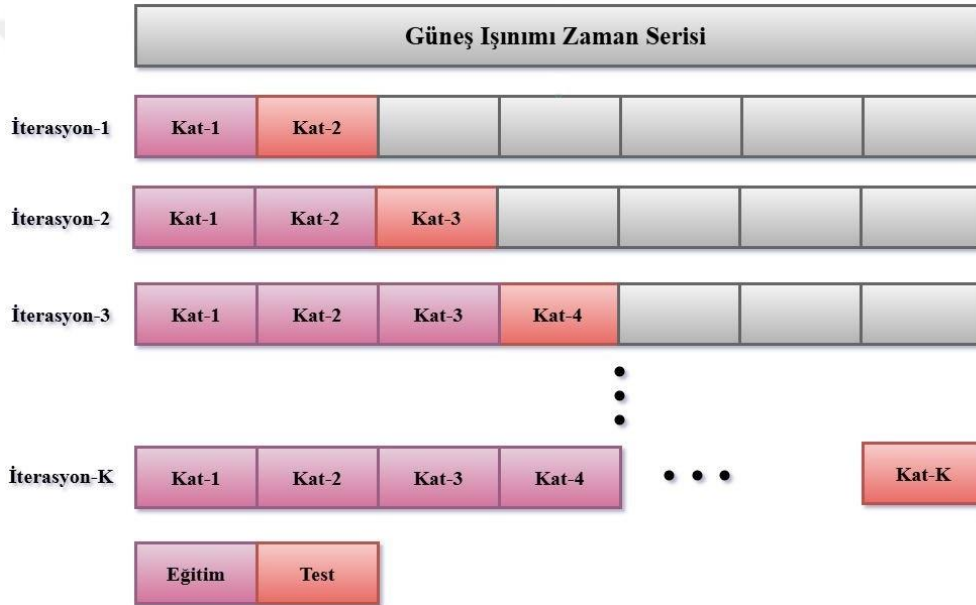
Şekil 3.1 Afyonkarahisar iline ait saatlik olarak ölçülen küresel güneş ışıını zaman serisi

Güneş ışıını zaman serisi incelendiđinde gece saatlerinde ve kış mevsiminin bazı zaman dilimlerinde sıfır olarak ölçüm kaydedildiđi görülmektedir. Mevsimler arası geçişlerde ışıını deđerleri artış ve azalış eğilimlerini takip ederek mevsimsel bir hareket sergilemektedir. Tez çalışmasında herhangi bir veri düzenlemesi yapılmadan ham veri üzerinde uygulama gerçekleştirilmiştir. Ham veri üzerinde çalışılması, güneş ışıını deđerlerinin zamana göre ilişkisini ve birbirleri ile bađıntısını gerçek bir yaklaşım ile ortaya koymaktadır.

3.2 Zaman Serisi K-katlı Çapraz Doğrulama

K-katlı Çapraz Doğrulama (K-katlı CV), makine öğrenimi alanında bir modelin genelleme yeteneđini deđerlendirmek için kullanılan bir tekniktir. Modelin, eğitim verisinde öğrenilen bilgileri test verisinde ne kadar iyi uygulayabildiđini görmek

amacıyla verilerin farklı alt kümelerine ayırarak modelin performansını ölçer (Kohavi 1995). Zaman serileri kronolojik olarak ardışık verilerden oluştuğu için zaman bağımlılığı bozulmadan çapraz doğrulama uygulanması gereklidir. Doğası gereği gelecek tahmin verileri ile geçmiş veriler arasında zamansal bağımlılık bulunduğu için klasik K-katlı CV yöntemi yanıltıcı olmaktadır. Zaman serisi K-katlı CV, geleneksel yöntemin zaman serisine adapte edilmiş halidir. Bu teknik ile büyük veri setlerindeki aşırı uyum problemi en aza indirilir ve farklı zaman dilimleri için model tekrar test edilerek genelleme yeteneği değerlendirilir (Bergmeir vd. 2018). Şekil 3.2’de Zaman serisi K-katlı CV metodu gösterilmektedir.



Şekil 3.2 Zaman serisi K-katlı CV metodu gösterimi

Zaman serisi kronolojik sırayı bozmadan K eşit büyüklükte alt kümelere bölünür. K-1 alt küme eğitim verisi olarak kullanılmaktadır. İlk katmanda en eski veriler eğitim veri seti olarak seçilir. Her K-katmanında eğitim veri seti genişletilerek her bir test veri seti üzerinden tahmin gerçekleştirilir. K değeri, n gözlem sayısı için 2 ile n arasında herhangi bir tam sayı olarak seçilebilir. K, n değerine yaklaştıkça hesaplama maliyetinin artmasının yanı sıra tahmin yeteneğini olumsuz etkileyen yüksek varyansa sebebiyet verebilir. Bu nedenle literatürde veri setinin büyüklüğü göz önüne alınarak genellikle K değeri 5 veya 10 olarak tercih edilmektedir (Hastie vd. 2005). Bu çalışmada 43824 saatlik güneş ışınım zaman serisi kullanıldığı için K değeri 10 seçilmiştir. Çizelge 3.1’de her K-katı için

ayrılan eğitim ve test verilerinin tarih aralığı sunulmuştur. Geliştirilen modellerin tahmin yeteneği her döngüde belirlenen test verisi üzerinden değerlendirilmiştir. Böylelikle tüm zaman dilimleri için mevsimsel etkiler göz önünde bulundurularak her modelin kararlılığı ve genelleme yeteneği analiz edilmiştir.

Çizelge 3.1 Zaman serisi K-katlı çapraz doğrulanmış zaman serisi için eğitim ve test verileri tarih aralığı

Döngü	Eğitim Veri Seti	Test Veri Seti
1.	1 Ocak 2018 – 15 Haziran 2018	16 Haziran 2018 – 28 Kasım 2018
2.	1 Ocak 2018 – 28 Kasım 2018	29 Kasım 2018 – 13 Mayıs 2019
3.	1 Ocak 2018 – 13 Mayıs 2019	14 Mayıs 2019 – 26 Ekim 2019
4.	1 Ocak 2018 – 26 Ekim 2019	27 Ekim 2019 – 9 Nisan 2020
5.	1 Ocak 2018 – 9 Nisan 2020	10 Nisan 2020 – 22 Eylül 2020
6.	1 Ocak 2018 – 22 Eylül 2020	23 Eylül 2020 – 7 Mart 2021
7.	1 Ocak 2018 – 7 Mart 2021	8 Mart 2021 – 20 Ağustos 2021
8.	1 Ocak 2018 – 20 Ağustos 2021	21 Ağustos 2021 – 2 Şubat 2022
9.	1 Ocak 2018 – 2 Şubat 2022	3 Şubat 2022 – 18 Temmuz 2022
10.	1 Ocak 2018 – 18 Temmuz 2022	19 Temmuz 2022 – 31 Aralık 2022

3.3 Mevsimsel-Eğilim Ayırıştırması (STL)

Mevsimsel-Eğilim ayırıştırması (STL), bir zaman serisini eğilim, mevsimsellik ve dğzensizlik bileşenlerine ayırmak için kullanılan Yerel olarak tahmin edilen dağılım grafiği yumuşatma (Loess) eğrisine dayalı bir istatistiksel yöntemdir. Özellikle mevsimselliğin değişken olduğu zaman serilerini uzun vadede incelemede etkilidir. Loess eğrisi $\hat{g}(x)$ olup, belirli bir nokta etrafındaki komşu veri noktalarını dikkate alarak düzleştirme işlemi gerçekleştirir. x_i ve y_i 'nin $i = 1$ 'den n 'ye kadar sırasıyla bağımsız ve bağımlı değişkenlerin ölçümleri olduğunu varsayılır. Daha sonra x 'e en yakın olan değerlerin sayısını temsil eden q olarak adlandırılan bir tam sayısı seçilir. Ardından, $q \leq n$ olduğunda, x_i ve x arasındaki mesafeye göre bir komşuluk ağırlığı belirlenir (Cleveland vd. 1990). Loess eğrisi yönteminde veri noktaları arasında mesafeye bağlı olarak ağırlıklandırma, üçlü-küp (Tri-cube) fonksiyonu ile gerçekleştirilir. W üçlü-küp bir ağırlık fonksiyonunu ifade eder ve denklem (3.3) ile açıklanır. Üçlü-küp fonksiyonu,

ağırlıklandırma işlemi sırasında komşu veri noktalarının etkisini önemli ölçüde azaltarak, yerel tahminlerde daha başarılıdır. (Cleveland ve William 1979).

$$W(u) = \begin{cases} (1 - u^3)^3, & 0 \leq u < 1 \\ 0, & u \geq 1 \end{cases} \quad (3.3)$$

Burada u , gözlem noktası ile hedef nokta arasındaki normalize edilmiş mesafeyi ifade eder. Gözlem noktası hedef noktaya yaklaştıkça, üçlü-küp fonksiyonu ağırlığı artırırken, mesafe arttıkça ağırlığı hızla sıfıra indirir. Böylelikle, daha yakın gözlemlerin model üzerinde daha fazla etkisi olmasını sağlar. Tahmin değeri $\hat{g}(x)$ denklem (3.4) de verilen, x_i 'nin komşuluk ağırlığı olan $v_i(x)$ ile elde edilir. $\lambda_q(x)$ ise x_i ve x arasındaki mesafeyi temsil etmektedir.

$$v_i(x) = W(|x_i - x|) / \lambda_q(x) \quad (3.4)$$

STL, iç döngü ve dış döngü olmak üzere iki aşamadan oluşur. İç döngü evresinde önceki dönemlerden elde edilen bilgilerin işlenmesi ile mevsimsel ve eğilim düzleştirme gerçekleştirilir. Burada elde edilen mevsimsel ve eğilim bileşenler dış döngü evresinde düzensizlik bileşenlerini elde etmek için kullanılır. Aşağıda k 'nıncı dönem için iç döngü adımları sırası ile verilmiştir.

Adım 1: Zaman serisinin orijinal değerleri Y_v 'den eğilim değerleri T_v^k çıkarılarak yeni bir seri elde edilir. Bu adım, eğilimden arındırma (detrending) olarak adlandırılır.

Adım 2: Eğilimden arındırma adımından elde edilen her döngü alt serisi, bir Loess eğrisi kullanılarak düzleştirilir ve C_v^{k+1} elde edilir.

Adım 3: C_v^{k+1} üzerine düşük geçişli filtre uygulanır. Filtreleme işleminden sonra, bir Loess eğrisi kullanılarak düzgünleştirme yapılır ve L_v^{k+1} elde edilir.

Adım 4: Mevsimsel seri S_v^{k+1} , C_v^{k+1} 'den L_v^{k+1} 'nin çıkarılmasıyla elde edilir. Bu, başka bir eğilimden arındırma adımını oluşturur.

Adım 5: Mevsimsellikten arındırılmış seri, orijinal seri Y_v 'den S_v 'nin çıkarılmasıyla elde edilir.

Adım 6: Mevsimsellikten arındırılmış seriye Loess eğrisi uygulandıktan sonra düzgünleştirilmiş eğilim serisi T_v^{k+1} elde edilir. Bu işlem, eğilim düzleştirme adımı olarak adlandırılır.

Dış döngü adımında ise düzensizlik serisi R_v , iç döngüde elde edilen T_v ve S_v değerleri kullanılarak aşağıda verilen denklem (3.5) ile ifade edilir.

$$R_v = Y_v - T_v - S_v \quad (3.5)$$

Son olarak, aykırı değerlerin etkisini azaltmak için güvenilirliği artırmak amacıyla sağlamlaştırma (robust) yöntemleri kullanılır. Bu yöntemler, verilerdeki aşırı veya anormal değerlerin neden olduğu bozulmaların etkisini azaltarak, daha güvenilir ve sağlam sonuçların elde edilmesine yardımcı olur (Huber 1992).

$$h = 6 \text{median}(|R_v|) \quad (3.6)$$

$$\rho_v = B(|R_v|)/h \quad (3.7)$$

Denklem (3.6) de verilen h , düzensizlik serisi R_v 'nin medyan değerine dayalı bir ölçeklendirme sabiti olarak kullanılır ve R_v değerlerinin medyanının altı katı olarak tanımlanır. Sağlamlaştırma süreci için bir referans noktası işlevi görür. Ağırlık ρ , R_v 'nin sağlamlığını değerlendirmek için tanımlanmıştır. Denklem (3.7), v zamanı için tanımlanan sağlamlaştırma ağırlığı ρ_v 'yi ifade eder.

Zaman serisi verileri, beklenmedik veya aşırı uç değerler içerebilir ve bu değerler analiz edilirken daha düşük değerler ile ağırlıklandırılır. Çift-kare (Bisquare) ağırlık fonksiyonu aykırı değerlerin etkisini azaltmak amacıyla kullanılan bir sağlamlaştırma yöntemidir. Aykırı değerler, bu fonksiyon ile neredeyse etkisiz hale gelmektedir (Cleveland vd. 1988). Çift-kare ağırlık fonksiyonu denklem (3.8) de verilen formül ile açıklanır. Bu

sağlamlaştırma yöntemi, STL ile bir zaman serisinin mevsimsel, eğilim ve düzensizlik bileşenlerine doğru ve güvenilir bir şekilde ayrıştırılmasını sağlar.

$$B(u) = \begin{cases} (1 - u^2)^2, & 0 \leq u < 1 \\ 0, & u \geq 1 \end{cases} \quad (3.8)$$

3.4 Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA) Modeli

Zaman serisi, belirli bir zaman diliminde düzenli aralıklarla gözlemlenen verilerin kronolojik olarak sıralanması ile elde edilir (Chatfield ve Xing 2019). Zaman serisi tahmini ise geçmişte gözlemlenen verilerin eğilimleri ile gelecek nokta için bir çıkarım oluşturulmasıdır. Box-Jenkins yöntemi, zaman serisi verilerini modellemek ve tahmin etmek için kullanılan istatistiksel bir yöntemdir. Bu yöntem, serinin eşit zaman aralıklarında elde edilen gözlemlerden oluştuğunu ve bunun yanı sıra kesikli ve durağan olduğunu varsayar. Durağan bir zaman serisi, zamanla değişmeyen ortalama ve varyansa sahiptir. Bu nedenle, Box-Jenkins yöntemi lineer stokastik modeller olarak da bilinir. Lineer durağan stokastik tahmin modelleri; Otoregresif (AR), Hareketli Ortalama (MA) ve Otoregresif Hareketli Ortalama (ARMA) modellerini içerir.

AR modeli, bir zaman serisinin herhangi bir dönemdeki gözlem değeri ile geçmiş gözlemler arasındaki doğrusal ilişkiyi kullanır. Zaman serisinin geçmiş değerlerinin, belirli bir gecikme ile birlikte mevcut değeri üzerinde etkili olduğunu varsayar. Bu model, p gecikmeli değeri içeriyorsa, p -inci dereceden model olarak tanımlanır ve AR(p) modeli denklem (3.9) ile gösterilir. Burada y_t ve ε_t , t zamanında sırası ile gerçek değer ve normal dağılım hata değeridir. Önceki zaman dönemlerinde $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ gözlem değerleridir. AR katsayıları ise $\phi_1, \phi_2, \dots, \phi_p$ olarak ifade edilir.

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (3.9)$$

MA modeli, bir zaman serisinin herhangi bir dönemdeki gözlem değeri ile geçmiş hata terimlerinin arasındaki ilişkiyi tanımlar. Bu model, q geçmiş hata terimini içeriyorsa, q -uncu dereceden model olarak adlandırılır ve MA(q) modeli denklem (3.10) ile gösterilir.

Burada $e_{t-1}, e_{t-2}, \dots, e_{t-q}$ önceki dönem hata değerleridir. MA katsayısı ise $\theta_1, \theta_2, \dots, \theta_q$ olarak sembolize edilir.

$$y_t = \varepsilon_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (3.10)$$

ARMA modeli ise AR ve MA bileşenlerinin birleşimi olarak, zaman serisi analizinde hem geçmiş gözlemleri hem de geçmiş hata terimlerini dikkate alarak mevcut değeri tahmin eder. ARMA(p, q) modeli, p gecikme değeri ve q geçmiş hata terimi sayısını içeren bir modeldir ve denklem (3.11) ile gösterilir.

$$y_t = \varepsilon_t + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (3.11)$$

Zaman serileri sahip olduğu bazı özellikler veya çevresel sebeplerden ötürü durağanlık özelliği bozulabilir. Zaman serisi verileri uzun vadede artma veya azalma eğilimi gösteriyorsa, seri bir eğilime sahiptir ve serinin ortalamasını zamanla değiştirir. Durağanlık özelliğini bozan bir diğer özellik, mevsimsellikdir. Zaman serilerinde aylık, yıllık gibi belirli dönemlerde düzenli olarak tekrarlanan desenler kendini gösterebilir. Bu desenler, zaman serisinin varyans ve ortalamasını dönemsel olarak etkiler. Mevsimsel olmayan fakat periyodik olarak meydana gelen dalgalanmalar da durağanlığı bozan sebeplerdendir. Doğal afet, salgın hastalıklar, ekonomik kriz gibi dışsal olaylarda zaman serisinin yapısında ani değişimlere yol açarak düzensiz hareketlere sebebiyet verebilir (Hamilton 2020). Durağan olmayan zaman serilerinin analizi için serinin durağan hale getirilmesi gerekmektedir. Durağanlaştırma, serinin uygun derecede farkını alarak sağlanır. Bu işlem $I(d)$ ile gösterilir ve d, fark alma derecesini temsil etmektedir. Durağan olmayan zaman serileri için kullanılan Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli, geçmiş gözlem değerlerini, geçmiş hata terimlerini ve fark alma işlemini birleştirir. AR katsayısı p, MA katsayısı q olan ve d kez farkı alınmış bir ARIMA(p,d,q) modeli denklem (3.12) ile gösterilir. Denklem (3.13) de verilen ifadede, $\nabla^d x_t$, d-inci farkı alınmış zaman serisidir, y_t durağan zaman serisi ve B gecikme operatörüdür.

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 e_{t-1} + \dots + \theta_q e_{t-q} \quad (3.12)$$

$$\nabla^d x_t = y_t = (1 - B)^d x_t \quad (3.13)$$

Mevsimsel hareketlere sahip zaman serilerini daha iyi analiz etmek için ARIMA modelinin genişletilmiş bir yöntemi olan Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA) modeli kullanılmaktadır. SARIMA, ARIMA modelindeki bileşenlerin yanı sıra mevsimsel bileşenleri (P, D, Q, s) de içerir. P, Mevsimsel AR katsayısını, D mevsimsel I sırasını ve Q mevsimsel MA sırasını temsil eder. Mevsimsel döngünün uzunluğu s parametresi ile gösterilir. Mevsimsel zaman serisi, ardışık yıllardaki aynı ayların gözlem değerleri arasındaki ilişkiyi açıklar. SARIMA(p,d,q)x(P,D,Q)_s ifadesi çarpanlı model olarak da bilinir ve denklem (3.14) ile gösterilir.


$$\phi_p(B)\Phi_P(B^s)\nabla^d\nabla_s^D x_t = \theta_q(B)\Theta_Q(B^s)\varepsilon_t \quad (3.14)$$

Bu denklem ifadesinde $\phi_p(B)$ ve $\theta_q(B)$ polinom ifadeleri sırasıyla AR ve MA bileşenlerini temsil ederken $\Phi_P(B^s)$ ve $\Theta_Q(B^s)$ polinomları sırasıyla mevsimsel AR ve mevsimsel MA bileşenlerini temsil eder. $\nabla_s^D x_t$, mevsimsel D-inci farkı alınmış zaman serisidir.

3.5 Uzun-Kısa Süreli Bellek (LSTM) Modeli

Tekrarlayan Sinir Ağları (RNN), sıralı verileri modelleyebilmek ve analiz edebilmek için tasarlanmış bir derin sinir ağı türüdür. RNN yapısı, bilgiyi önceki katmanlardan alarak bir sonraki katmana taşıyabilen döngüsel bir sisteme sahiptir. Bu sistemi oluşturan gradyanlar, geçmiş hücre bilgisini sonraki hücreye aktararak ardışık verilerdeki bağımlılıkların öğrenilmesini sağlar. Bu sayede RNN model, bu bilgileri kullanarak tahmin çıkarımında bulunur (Rumelhart vd. 1986). Şekil 3.3'de basit bir RNN ağın modeli gösterilmektedir. Burada t zamanındaki gizli durum H_t , mevcut giriş X_t ve önceki gizli durum H_{t-1} 'in bir fonksiyonu olarak işlenmektedir. Böylece gizli durumun güncellenmesi, hem mevcut verinin hem de geçmiş bilgilerin birleşimiyle gerçekleştirilir. Yalnız, uzun vadeli sıralı verilerde RNN modelin derin katmanlarına doğru gradyanlar küçülür ve kaybolur. Ortaya çıkan bu hafıza problemi, önceki katmanların

güncellenmesini zorlaştırdığı için ağıın öğrenme yeteneğini azaltır ve uzun süreli bağımlılıkları modellemeyi güçleştirir.

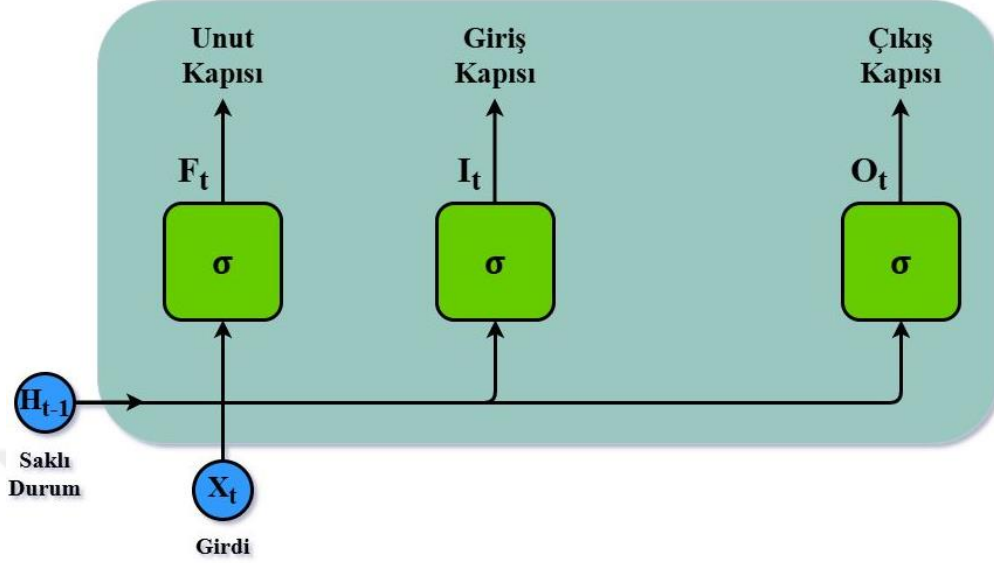


Şekil 3.3 Basit bir RNN ağı modeli

LSTM ağı RNN'lerde karşılaşılan gradyan kaybolması ve bellek problemlerini çözmek için geliştirilen özelleştirilmiş bir RNN türüdür. LSTM ağı, geçmiş dönemdeki önemli bilgileri belleğinde daha uzun süre saklayabilme yeteneğine sahiptir. Bu sayede zaman serisi tahminlerinde ve uzun süreli karmaşık işlemlerde hızlı ve etkili bir performans göstermektedir (Hochreiter 1997). LSTM ağı bilgi akışını kontrol etmek için hücrelerinde bulunan unutmama, giriş ve çıkış kapılarını kullanır. Temel bir LSTM hücresi mimarisi Şekil 3.4'de gösterilmektedir. Bu kapılar sayesinde hangi bilgilerin tutulacağı veya silineceği belirlenmektedir.

Mimarideki ilk aşama olan unutma kapısı, önceki gizli durumu ve giriş verilerini kullanarak saklanılması gereken ilgili bilgileri belirler. Önceki gizli durum H_{t-1} ve giriş verileri X , sigmoid aktivasyonu σ ile işlenir ve $[0,1]$ arasında değişen bir çıktı vektörü elde edilir. Unutmama kapısı ilgisiz bilgiler için 0'a yakın, ilgili bilgiler için ise 1'e yakın bir değer üreterek filtreleme görevi görür. Bu işlemler denklem (3.15) ile formüle edilmiştir. Daha sonra bu çıktı değerleri önceki hücre durumu ile çarpılarak alakasız bilgilerin sonraki adımlarda etkisi azaltılır. İkinci aşama giriş kapısını ve aday bellek ağını içerir. Bu süreç Şekil 3.5'de gösterilmektedir.

$$F_t = \sigma(W_{f,x} * X_t + W_{f,h} * H_{t-1} + b_f) \quad (3.15)$$



Şekil 3.4 Temel bir LSTM hücresinin unut kapısı, giriş kapısı ve çıkış kapısı

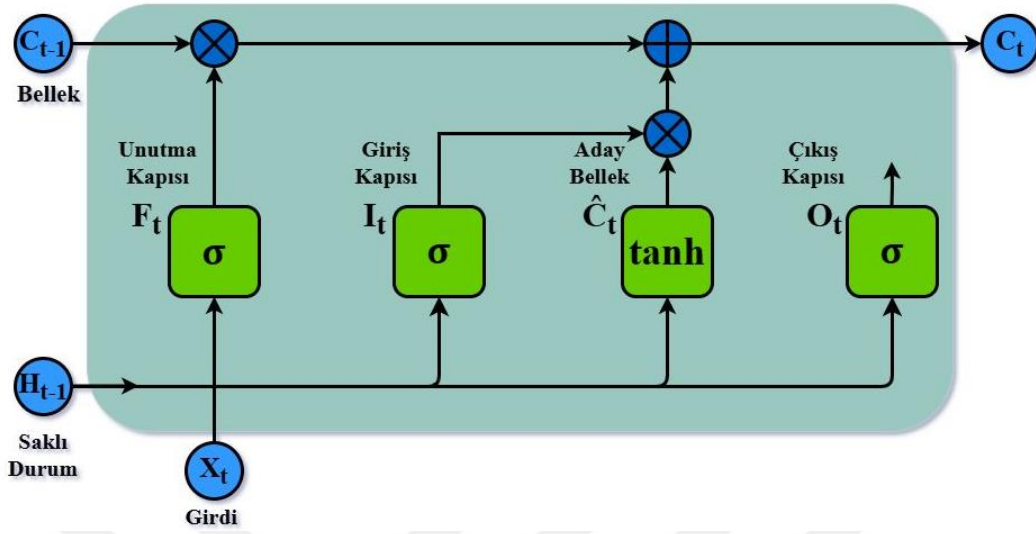
Burada, önceki gizli durum ve giriş verileri kullanılarak ağın uzun vadeli belleğine dâhil edilecek yeni bilgiler belirlenir. İlk olarak giriş kapısı, sigmoid aktivasyonu (σ) kullanarak değerleri $[0,1]$ arasında değişen bir çıktı vektör elde eder. Unutma kapısındaki sürece benzer şekilde giriş kapısından 0'a yakın bir çıkış değeri bilginin güncellenmemesi gerektiği anlamına gelmektedir.

Aday bellek ağı önceki gizli durum ile giriş verilerini kullanarak \tanh aktivasyon fonksiyonunu ile yeni bir bellek güncelleme vektörü oluşturur. \tanh Fonksiyonu değerleri $[1,-1]$ aralığında olduğu için negatif değer üretimi hücre durumundaki bir bilginin etkisinin azaltılmasını sağlar. Yeni bellek güncelleme vektörü ile giriş kapısının ürettiği çıktı vektörü noktasal olarak çarpılarak hücre durumu güncellenir. Bu aşamalar sırası ile denklem (3.16), denklem (3.17) ve denklem (3.18) ile gerçekleştirilir.

$$I_t = \sigma(W_{i,x} * X_t + W_{i,h} * H_{t-1} + b_i) \quad (3.16)$$

$$\tilde{C}_t = \tanh(W_{c,x} * X_t + W_{c,h} * H_{t-1} + b_c) \quad (3.17)$$

$$C_t = C_{t-1} * F_t + I_t * \tilde{C}_t \quad (3.18)$$



Şekil 3.5 Aday hücre kullanılarak yeni bir bellek hücreninin oluşum süreci

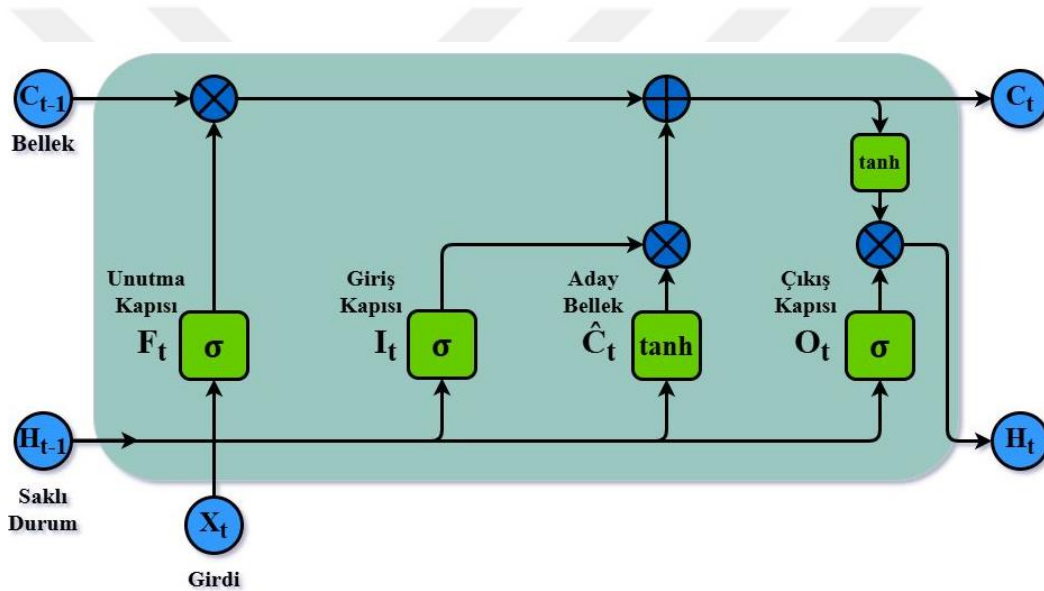
Son aşama olan çıkış kapısı, önceki gizli durum ve mevcut giriş verisini kullanarak sigmoid aktivasyon fonksiyonu işlenir. [0,1] arasında üretilen değerler hangi bilginin çıkış olarak aktarılacağını belirler. Daha sonra hücre durumundaki bilgiler \tanh aktivasyon fonksiyonu kullanılarak [-1,1] arasında bir değere dönüştürülür. \tanh Fonksiyonundan gelen hücre durumu değeri, çıkış kapısının belirlediği değerle çarpılarak son çıkış değeri elde edilir. Çıkış kapısı, hangi bilginin dışarıya aktarılacağını denetleyerek modelin daha hassas ve etkili sonuçlar elde etmesini sağlar (Xiao vd. 2019). Bu sürece ait işlemler denklem (3.19) ve denklem (3.20) de verilmiştir. Bu denklemlerde 'W' ve 'b' sırasıyla ağırlık ve yanlılık parametrelerini temsil etmektedir. LSTM modelindeki tüm kapı işlemleri, bilgiyi unutma, bellekte tutma ve çıktıyı oluşturma süreçleri Şekil 3.6'da gösterilmektedir.

$$O_t = \sigma(W_{o,x} * x_t + W_{o,h} * H_{t-1} + b_o) \quad (3.19)$$

$$H_t = o_t * \tanh(C_t) \quad (3.20)$$

LSTM ağlarının çeşitli uygulamalarda esneklik sağlamak ve performansı artırmak için farklı çeşitleri geliştirilmiştir. Standart LSTM modeli, bir ileri bir geri yönde bilgi

aktarımını sağlayan temel modeldir. Eğer LSTM hücreleri birden fazla katman halinde oluşturulmuş ise bu yapı Katmanlı LSTM olarak bilinir. Çift yönlü LSTM ağları, giriş verisini hem ileri hem geri yönde işleyerek geçmiş ve gelecek verileri aynı anda değerlendirme imkânı sunar. Konvolüsyonel LSTM (ConvLSTM) ağları uzaysal ve zamansal özellikleri işlemek için özel olarak geliştirilmiş bir modeldir. ConvLSTM, veriler üzerinde yalnızca zamansal bağımlılıkları değil, aynı zamanda mekânsal örüntüleri de öğrenebilmek için konvolüsyonel işlemler kullanır. Dikkat Mekanizmalı LSTM ağları ise girdi verisinde hangi bileşenlerin daha önemli olduğunu belirlemek için dikkat mekanizması eklemektedir. Kullanılacak LSTM modeli, girdi veri dizisinin türüne, görev tanımına ve hedef doğrultusuna göre değişmektedir.



Şekil 3.6 LSTM hücresinde bilgi akış süreci

Bu çalışmada tek boyutlu bir zaman serisi üzerinde tahmin gerçekleştirildiği için Standart LSTM ağı tercih edilmiştir. Özellikle belli bir desene sahip tek değişkenli zaman serisi tahminlerinde başarılı olan Standart LSTM ağı karmaşık işlemler gerektirmez ve bu da modelin uygulanabilirliğini artırarak esneklik sağlar. Daha az katman sayısı ve parametre içerdiği için eğitim süresi daha hızlıdır ve hesaplama maliyeti düşüktür.

3.6 SARIMA-LSTM Hibrit Modeli

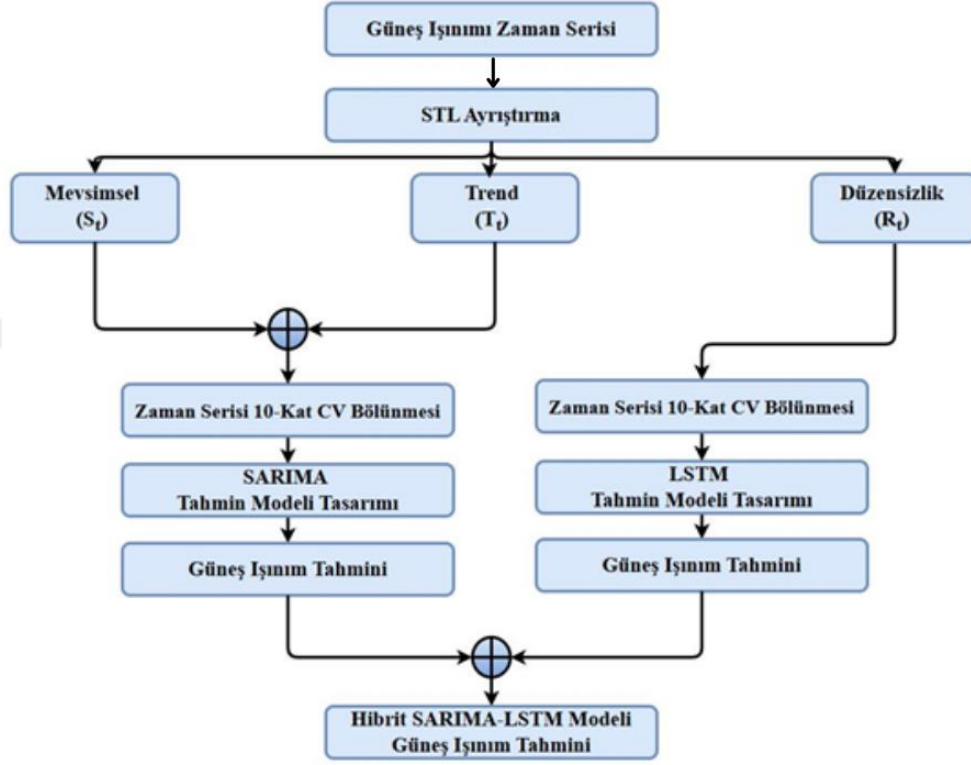
Bu tez çalışmasında saatlik güneş ışınımını tahmini için hibrit bir yaklaşım geliştirilmiştir.

Önerilen hibrit model, istatistiksel yöntemlerden biri olan SARIMA ve DL yöntemlerinden biri olan LSTM ağlarını birleştiren bir tahmin modelidir. Bir zaman serisi hem doğrusal hem de doğrusal olmayan özellikler sergilediğinden, tek bir tahmin modeli yerine hibrit bir model kullanmak tahmin performansı artırır (Diagne vd. 2013). Hibrit metot seçiminde SARIMA ve LSTM modellerin zaman serisinin doğrusal ve doğrusal olmayan bileşenleri üzerindeki tahmin yetenekleri göz önünde bulundurulmuştur. SARIMA, bir zaman serisinin hem mevsimsel hem de eğilim bileşenlerini dikkate alarak daha doğru bir şekilde modelleme yapabilir. Düzenli periyotlara sahip verilerde mevsimsel değişimlerin etkilerini açıkça ortaya koyar (Dabral vd. 2017). Gerçek dünya zaman serisi verileri genellikle geleneksel tahmin yöntemlerinin doğru tahminler yapmasını engelleyen karmaşıklıklara sahip doğrusal olmayan desenlerden oluşur. LSTM ağları uzun ve kısa vadeli bağımlılıkları dikkate alarak bu desenleri yakalamayı öğrenme ve zaman serisi tahmininin doğruluğunu artırma yeteneğine sahiptir (Abbasimehr ve Paki, 2021). Tek bir yöntem kullanmak, zaman serisinin güneş ışınımı değerleri arasındaki ilişkileri yakalamak için yetersiz kalabilir. Mevcut çalışmada kullanılan güneş ışınım zaman serisi mevsimsellik, eğilim ve düzensiz hata değerleri içermektedir. Bu bağlamda tahmin doğruluğunu artırmak için bireysel metotların avantajlarını birleştiren STL tabanlı bir hibrit model geliştirilmiştir. Mevsimsel-Trend Ayırıştırması (STL) başlığı altında elde edilen denklem (3.3) ifadesi yeniden düzenlenerek denklem (3.21) olarak aşağıda verilmiştir.

$$Y_t = S_t + T_t + R_t \quad (3.21)$$

Burada Y_t zaman serisini, S_t mevsimselliği, T_t eğilimi (trend) ve R_t düzensizlik bileşenini temsil etmektedir. Hibrit metot, zaman serinin bu bileşenlerinin ayrı olarak modellenmesi ile oluşturulmuştur. STL tekniği ile ayırıştırılmış zaman serisinde, SARIMA modeli mevsimsel ve eğilim bileşenleri için, LSTM ağı ise düzensizlik bileşeni için tahmin gerçekleştirir. Bu tahminlerin toplamı hibrit modelin sonucunu vermektedir. Önerilen hibrit modelin akış diyagramı Şekil 3.7'de gösterilmektedir. Aşırı öğrenmeyi önlemek, modelin her dönem için kararlılığını ve tahmin performansını değerlendirmek için zaman serisi 10-katlı CV tekniği uygulanarak her döngü için ayrı eğitim ve test verisi belirlenmiştir. Mevsimsellik ve eğilim içeren zaman serisi verileri için geliştirilen

SARIMA modeli, güneş ışıını zaman serisinin doğrusal bileşenleri arasındaki ilişkiyi açıklama yeteneğine sahipken, düzensizlik zaman serisi verileri için geliştirilen LSTM modeli lineer olmayan ilişkileri açıklamada iyi bir performansa sahiptir.



Şekil 3.7 Önerilen SARIMA-LSTM hibrit modelin akış diyagramı

Hibrit metot bu iki avantajı birleştirerek tahmin doğruluğunu yükseltmeyi hedefler. Hem SARIMA hem de LSTM model tasarımları için parametre değerleri orijinal zaman serisi verileri kullanılarak belirlenmiştir. Son olarak hibrit model için tahmin süreci denklem (3.22) de verilmiştir. Mevsimsel ve eğilim verileri için elde edilen SARIMA tahmini ile düzensizlik bileşenler için elde edilen LSTM tahmin değerlerinin toplamı hibrit modelin tahmin değerini vermektedir.

$$\text{HİBRİT}_{\text{tahmin}} = \text{SARIMA}(T_t + S_t)_{\text{tahmin}} + \text{LSTM}(R_t)_{\text{tahmin}} \quad (3.22)$$

4. BULGULAR

Bu bölümde çalışmada önerilen hibrit modelin tasarım süreci ve model değerlendirilmesi sunulmuştur. Hibrit modelin farklı mevsim koşulları altında tahmin performansını incelemek için dört mevsimi temsil eden günler seçilerek değerlendirme metrikleri ile karşılaştırmalı olarak analiz edilmiştir. Tanısal kontrol grafikleri model genelleme yeteneği ve kararlılığı test edilmiştir.

4.1 Değerlendirme Metrikleri

Çalışmada geliştirilen hibrit, SARIMA ve LSTM modellerinin tahmin performansını değerlendirmek için kullanılan Kök Ortalama Kare Hatası (RMSE), Normalize Edilmiş Kök Ortalama Kare Hatası (NRMSE), Ortalama Mutlak Hata (MAE) ve Determinasyon Katsayısı (R^2) metrikleri Çizelge 4.1’de sunulmuştur.

Çizelge 4.1 Çalışmada kullanılan performans değerlendirme metrikleri

Ölçüt	İsim	Eşitlik
RMSE	Kök Ortalama Kare Hata	$\sqrt{\frac{\sum_{i=1}^N (Y_{gerçek,i} - Y_{tahmin,i})^2}{N}}$
NRMSE	Normalize Edilmiş Kök Ortalama Kare Hata	$\frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{gerçek,i} - Y_{tahmin,i})^2}}{\mu}$
MAE	Ortalama Mutlak Hata	$\frac{1}{N} \sum_{i=1}^N Y_{gerçek,i} - Y_{tahmin,i} $
R^2	Determinasyon Katsayısı	$1 - \frac{\sum_{i=1}^N (Y_{gerçek,i} - Y_{tahmin,i})^2}{\sum_{i=1}^N (Y_{gerçek,i} - \mu)^2}$

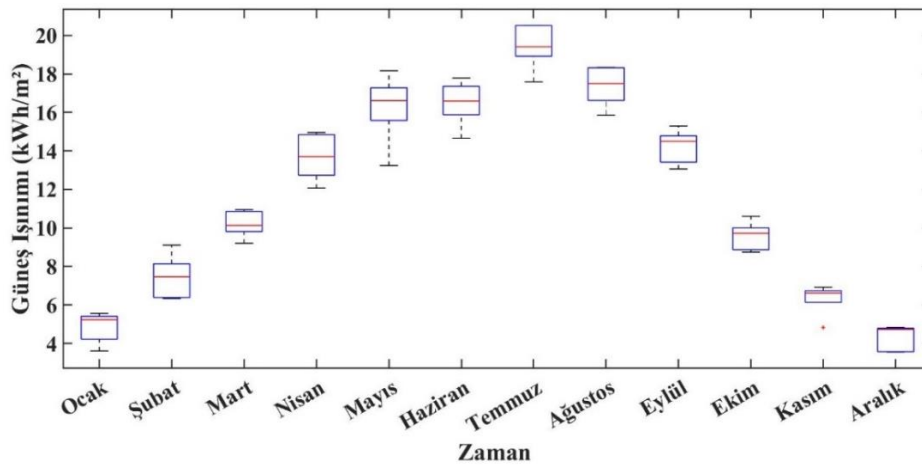
Burada, $Y_{gerçek,i}$ gerçek değeri, $Y_{tahmin,i}$ tahmin değerini, μ gerçek değerlerin ortalamasını ve N değerlendirilecek veri noktalarının sayısını temsil etmektedir.

Bu ölçütler modellerin doğruluğunu ölçmek için kullanılan istatistiksel bir metriktir.

RMSE, gerçek ve tahmin edilen değerler arasındaki farkların karelerinin ortalamasının karekökü olarak ifade edilir. RMSE, kısa dönemli güneş ışınımı tahminlerinde etkili bir değerlendirme aracıdır ve değeri sıfıra yaklaştıkça modelin performansı iyileşir. NRMSE, tahmin edilen değerler ile gerçek değerleri karşılaştıran RMSE değerinin normalize edilmesiyle elde edilen bir metriktir. Normalize edilmesi hatanın mutlak büyüklüğünü modelin ölçülen veri aralığına göre daha anlamlı bir şekilde karşılaştırılmasını sağlar. MAE, tahmin edilen ve gerçek değerler arasındaki mutlak farkların ortalamasıdır. Düşük bir MAE değeri, güçlü bir tahmin performansını gösterir. R^2 skoru tahmin değerlerinin gerçek değerlere ne kadar yakın olduğunu ölçen bir metriktir. Bu, gerçek ve tahmin edilen değerler arasındaki doğrusal ilişkiyi gösterir. R^2 skoru $[0,1]$ arasında değişir ve 1'e daha yakın olması, modelin tahmin performansının daha iyi olduğunu göstermektedir.

4.2 SARIMA Model Tasarımı

Tez aşamasının bu bölümünde zaman serisinin mevsimsel-eğilim bileşenleri üzerinde tahmin gerçekleştirmek üzere SARIMA model tasarımı ele alınmıştır. SARIMA modeli geliştirilirken sırası ile zaman serisi durağanlık testi, otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) grafiklerinin incelenmesi, model parametrelerinin öngörülmesi, Akaike ve Bayes bilgi kriterlerinin elde edilmesi ve gelecek tahmini aşamaları takip edilmiştir. Şekil 4.1, güneş ışınımı zaman serisinin aylık kutu grafiğini göstermektedir.



Şekil 4.1 2018-2022 yılları arası ölçülen güneş ışınımı zaman serisinin aylık kutu grafiği

Güneş ışınımı değerleri beklendiği şekilde Haziran, Temmuz ve Ağustos aylarında belirgin bir şekilde yüksektir ve geniş bir dağılım göstermektedir. Aralık, Ocak ve Şubat aylarında ise güneş ışınımı değerleri en düşük değerlerini almıştır. Kış aylarında güneş ışınım değerleri daha dar bir dağılım göstermiştir. Geçiş dönemi olan bahar (Mart, Nisan, Mayıs) ve sonbahar (Eylül, Ekim, Kasım) aylarında ise güneş ışınımı seviyelerinin orta seviyede bir dağılımı elde edilmiştir. Bu grafik güneş ışınımı zaman serisinin sahip olduğu mevsimsel farklılıkları net bir şekilde ortaya koymaktadır.

4.2.1 Zaman Serisi Durağanlık Testi

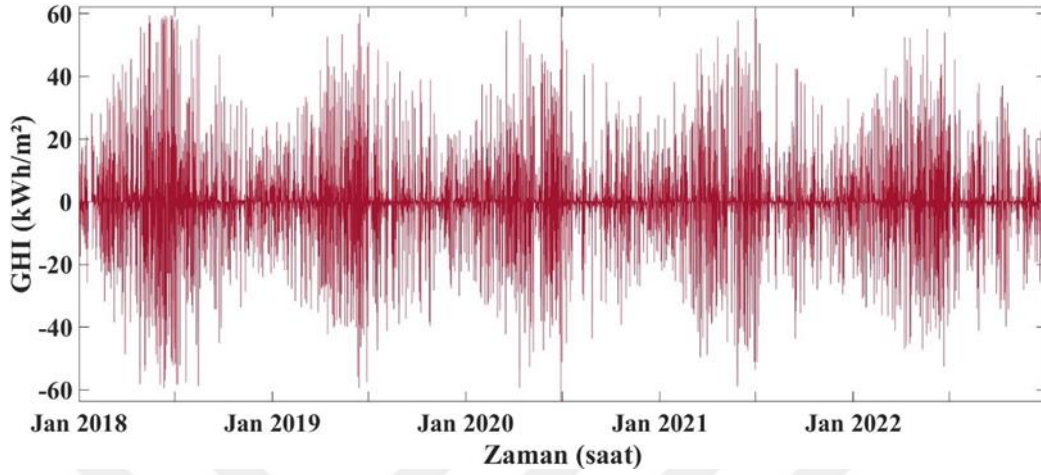
Box-Jenkins yöntemlerinin kullanılabilmesi için zaman serisinin durağan olması gerekmektedir. Durağanlık, serinin sabit bir ortalamaya ve varyansa sahip olması ve iki veri noktası arasındaki kovaryansın sıfır olması anlamına gelir. Zaman serisinin durağanlığını analiz etmek için istatistiksel testler bulunmaktadır. Literatürde, zaman serilerinin stokastik özelliklerini analiz etmek için Dickey-Fuller birim kök testi (ADF) (Dickey ve Fuller 1979) ve Kwiatkowski-Phillips-Schmidt-Shin (KPSS) testi (Kwiatkowski vd. 1992) yaygın olarak kullanılmaktadır. ADF testi, “Zaman serisi birim kök içerir.” şeklindeki sıfır hipotezini (H_0) öne sürerken, KPSS testi, “Zaman serisi durağandır.” şeklindeki sıfır hipotezini (H_0) öne sürer. P-değeri anlamlılık düzeyi 0.05 değerinden daha küçükse, H_0 reddedilir. Çizelge 4.2 orijinal zaman serisi için ADF ve KPSS testlerinin sonuçlarını göstermektedir. Her iki test sonucunda p-değeri 0.05 değerinden daha küçük olarak elde edilerek H_0 'ın reddedilmesini sağlar. Bu sonuç, orijinal zaman serisinin birim kök içermediğini ancak durağan olmadığını göstermektedir.

Çizelge 4.2 Orijinal güneş ışınımı zaman serisi için ADF ve KPSS test sonuçları

Test	H_0 reddedildi	P-değeri	Test istatistiği	Kritik değer	Anlamlılık düzeyi
ADF	Doğru	0,001	-35,918	-1,9416	0,05
KPSS	Doğru	0,01	4,2140	0,1460	0,05

Güneş ışınımı zaman serisinin mevsimsel hareket ve eğilim içermesi durağanlığı bozmaktadır. Bu nedenle durağanlığı sağlamak için güneş ışınımı verilerine fark ve

mevsimsel fark alma işlemleri uygulanır. Fark alma işlemlerinden sonra elde edilen zaman serisi grafiği Şekil 4.2’de verilmiştir.



Şekil 4.2 Fark ve mevsimsel fark sonrası güneş ışıını zaman serisi

Grafikteki dalgalanmaların, zaman içinde sabit bir ortalama etrafında dağılım gösterdiği ve belirli bir değişim aralığına sahip olduğunu gözlemlenmektedir. Dönüştürülmüş zaman serisi verileri için ADF ve KPSS test sonuçları Çizelge 4.3’de sunulmaktadır. KPSS test sonucunda p-değerinin 0.05 değerinden daha yüksek elde edilmesi, H_0 ’ın reddedilemeyeceği anlamına gelmektedir. Bu durum güneş ışıını zaman serisinin durağan haline geldiğini göstermektedir. Böylelikle SARIMA modeli parametreleri için fark ve mevsimsel fark derecesi 1 olarak belirlenmiştir ($d=1$ ve $D=1$).

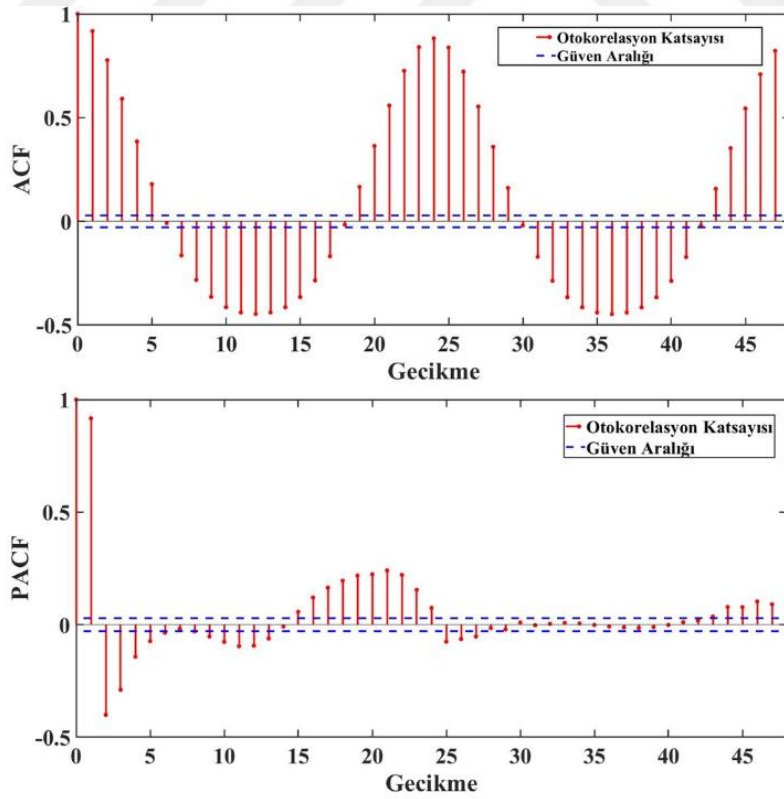
Çizelge 4.3 Fark ve mevsimsel fark sonrası güneş ışıını zaman serisi için ADF ve KPSS test sonuçları

Test	H_0 reddedildi	P-değeri	Test istatistiği	Kritik değer	Anlamlılık düzeyi
ADF	Doğru	0,001	-94,7804	-1,9416	0,05
KPSS	Yanlış	0,1	0,0081	0,1460	0,05

4.2.2 Otokorelasyon ve Kısmi Otokorelasyon Grafikleri

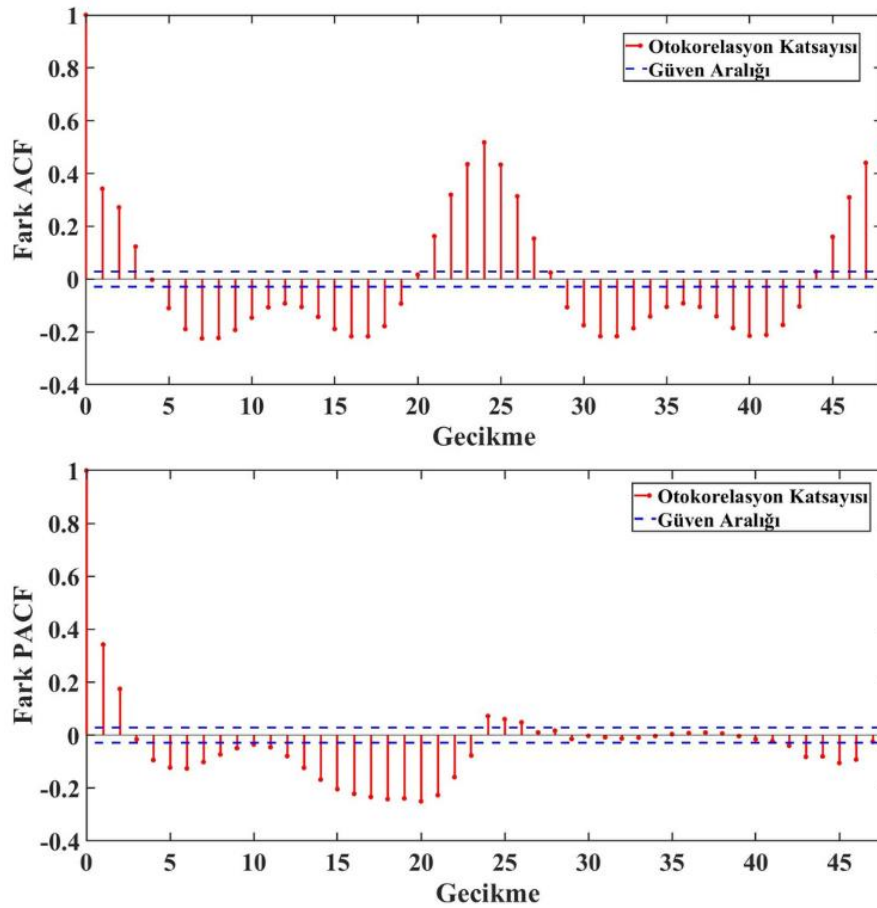
Otokorelasyon (ACF) ve Kısmi Otokorelasyon (PACF) grafikleri, model tanımlama için başlangıç düzeyinde bir öngörü sağlar. ACF grafiği, gözlemlenen değer ile önceki

değerleri arasındaki ilişkiyi gösterirken, PACF grafiği, önceki gecikmelerin etkilerini dikkate almaksızın iki gözlem noktası arasındaki ilişkiyi analiz eder. ACF grafiği yavaşça azalırken, PACF grafiği hızlı bir düşüş gösteriyorsa, bir AR modeli seçilir. Tersine, PACF grafiği yavaşça azalırken ACF grafiği ani bir düşüş gösteriyorsa, bir MA modeli tercih edilir. Hem ACF hem de PACF grafikleri kademeli bir azalma gösteriyorsa, bir ARMA modeli uygundur. Şekil 4.3 güneş ışınımı zaman serisinin ACF ve PACF grafiklerini göstermektedir. Her iki grafikte de gecikme arttıkça otokorelasyon katsayılarında hızlı bir azalma görülmemektedir. Bu zaman serisinin eğilim içerdiğini göstermektedir. Ayrıca ACF grafiğinde pozitif ve negatif yönde kendini tekrar eden tekrarlı desenlerin olduğu gözlemlenmektedir. Bu tekrarlı desenler zaman serisinin mevsimsel bileşenlerinden kaynaklanmaktadır. Özellikle 24. ve 48. gecikmelerde yüksek bir sıçrama görülmektedir. PACF grafiğinde ise 1 ile 27 arasındaki gecikmeler anlamlı otokorelasyon göstermektedir. Kademeli bir şekilde azalma zaman serisinin durağan olmadığını ifade etmektedir. Bundan dolayı fark alma işlemi uygulanması gerekir. ACF ve PACF grafikleri bu şekilde zaman serisinin durağanlık analizi için de kullanılabilir.




Şekil 4.3 Güneş ışınımı zaman serisinin ACF ve PACF grafikleri

Güneş ışınımı zaman serisinin birinci derece farkı ($d=1$) alındıktan sonraki ACF ve PACF grafikleri Şekil 4.4'de gösterilmektedir. PACF grafiğinde, üçüncü gecikmedeki düşüş, $AR\{3\}$ modelinin uygun olduğunu göstermektedir. Çünkü parametre düzeyleri belirlenirken güven aralığı içinde kalana kadar geçen anlamlı gecikme sayısına bakılmaktadır. Ayrıca kademeli bir azalma yerine ani bir düşüş gözlemlenmesi zaman serisinin eğilimden arındırıldığını ifade etmektedir. Yalnız ACF grafiğinde ise tekrarlı desenler devam etmektedir. Aynı şekilde 24. ve 48. gecikmelerde yükselme görülmektedir. Bu zaman serisinin halen mevsimselliğin etkisinde olduğunu gösterir. Bu nedenle ARIMA modeli yerine SARIMA modeli kullanılması daha uygundur. Ayrıca ACF grafiğinde güven aralığı dışında kalan anlamlı otokorelasyon sayısı oldukça fazladır. Bu nedenle düşük katsayılı olacak şekilde $MA\{0\}$, $MA\{1\}$, $MA\{2\}$ modelleri tercih edilebilir.



Şekil 4.4 Birinci derece fark alma sonrası güneş ışınımı zaman serisinin ACF ve PACF grafikleri

Mevsimsel parametre değerlerinin belirlenmesi için güneş ışınımı zaman serisine son olarak mevsimsel fark alma işlemi uygulanarak ACF ve PACF grafikleri incelenmelidir. Şekil 4.5 birinci derece mevsimsel fark (D=1) alındıktan sonraki güneş ışınımı zaman serisinin ACF ve PACF grafiklerini vermektedir. ACF grafiğinde birden fazla gecikme değeri anlamlı olduğu için düşük katsayılı olacak şekilde Mevsimsel MA{0}, Mevsimsel MA{1}, Mevsimsel MA{2} modelleri tercih edilebilir. 24. ve 48. gecikmelerde aynı şekilde yükselme görüldüğü için mevsimsel periyot parametresi (s) 24 olarak seçilir. PACF grafiğinde ise 3. gecikmede otokorelasyon katsayıları tamamen güven aralığı içerisine girmektedir. Bundan dolayı Mevsimsel AR{3} modeli tercih edilebilir. Bu grafikler parametre belirlenmesinde bir öngörü oluşturmaktadır. Bu nedenle parametre seçiminde farklı model kombinasyonları ile belirli ölçütlere göre değerlendirme yapılması model doğruluğu için daha uygun olacaktır.



Şekil 4.5 Birinci derece mevsimsel fark alma sonrası güneş ışınımı zaman serisinin ACF ve PACF grafikleri

4.2.3 Model Tanımlaması

Model parametreleri, çoğunlukla tercih edilen Akaike Bilgi Kriteri (AIC) ve Bayes Bilgi Kriteri (BIC) temel alınarak belirlenmiştir. Bu iki kriter, modelin uyumu ve karmaşıklığı hakkında bilgi sunmaktadır. Japon istatistikçi Hirotugu Akaike tarafından geliştirilen AIC, modelin karmaşıklığı ile veriye uyumunu dengelemek için kullanılır; daha düşük AIC değeri, daha iyi bir modeli gösterir (Akaike 1974). Verilen denklemlerde, k modeldeki parametre sayısını, L modelin maksimum olasılık fonksiyonunu, n ise veri setindeki gözlem sayısını temsil etmektedir. AIC denklem (4.1) ile ifade edilmektedir:

$$AIC = 2k - 2 \ln(L) \quad (4.1)$$

Gideon E. Schwarz tarafından geliştirilen Bayes Bilgi Kriteri (BIC), hem model uyumunu hem de karmaşıklığını değerlendirir. Ancak, özellikle daha basit modelleri tercih etme eğilimindedir (Schwarz 1978). BIC denklem (4.2) kullanılarak açıklanır:

$$BIC = \ln(n)k - 2 \ln(L) \quad (4.2)$$

Bu nedenle, en uygun model tanımlaması yapabilmek amacıyla ACF ve PACF grafik incelemesinde belirlenen olası parametre değerleri ile çeşitli SARIMA model senaryoları tasarlanmıştır. AR ve mevsimsel AR katsayısı 3 olarak alınmıştır. MA ve mevsimsel MA katsayıları sırası ile 0, 1 ve 2 olacak şekilde dikkate alınmıştır. Fark alma ve mevsimsel fark derecesi 1'dir. ($d=1$ ve $D=1$). Periyot s , ise grafiklerdeki 24 gecikmede bir yükselme görüldüğü ve saatlik veri kullanıldığı için 24 olarak belirlenmiştir. Bu parametreler doğrultusunda geliştirilen modellerin AIC ve BIC değerleri Çizelge 4.4'de sunulmaktadır. Bu bağlamda en düşük AIC ve BIC değerini veren model SARIMA(3,1,2)_x(3,1,1)₂₄ olarak tanımlanmıştır. Çizelge 4.5 seçilen SARIMA(3,1,2)_x(3,1,1)₂₄ modelin parametre sonuçlarını göstermektedir. Her bir parametre için değer, standart hata, t-istatistiği ve p-değeri verilmiştir. Sabit terimin modelde anlamlı bir katkısı yoktur. AR ve MA terimleri istatistiksel olarak anlamlıdır ve kısa vadeli ilişkilerin yapısını yakalamaktadır. SAR ve SMA terimleri ise uzun vadede güçlü bir mevsimsel hareketi ifade eder. 24 saatlik ve 72 saatlik mevsimsel döngüler, modelde anlamlı etkiler göstermektedir. Varyans değeri ise

modeldeki hata terimlerinin dağılımını temsil eder ve istatistiksel olarak anlamlı bir değer elde edilmiştir.

Çizelge 4.4 SARIMA Model kombinasyonları için AIC ve BIC değerleri

Model	AIC	BIC
SARIMA(3,1,0)x(3,1,0) ₂₄	2,7297e+05	2,7304e+05
SARIMA(3,1,0)x(3,1,1) ₂₄	2,6625e+05	2,6633e+05
SARIMA(3,1,1)x(3,1,0) ₂₄	2,7552e+05	2,7558e+05
SARIMA(3,1,1)x(3,1,1) ₂₄	2,6159e+05	2,6168e+05
SARIMA(3,1,2)x(3,1,0) ₂₄	2,6820e+05	2,6828e+05
SARIMA(3,1,2)x(3,1,1)₂₄	2,6155e+05	2,6165e+05
SARIMA(3,1,3)x(3,1,1) ₂₄	2,6155e+05	2,6166e+05
SARIMA(3,1,3)x(3,1,2) ₂₄	2,6155e+05	2,6166e+05

Çizelge 4.5 SARIMA(3,1,2)x(3,1,1)₂₄ modelin parametre sonuçları

Parametre	Değer	Standart Hata	t-İstatistik	p-değeri
Sabit	0	0	-0,0327	0,9740
AR{1}	1,4291	0,0690	20,6981	0
AR{2}	-0,4631	0,0485	-9,5431	0
AR{3}	-0,0483	0,0026	-18,774	0
SAR{24}	0,0662	0,0020	32,5541	0
SAR{48}	-0,0004	0,0021	-0,1766	0,8598
SAR{72}	0,0267	0,0021	12,5239	0
MA{1}	-1,7347	0,0690	-25,1321	0
MA{2}	0,7356	0,0688	10,6898	0
SMA{24}	-0,9396	0,0011	-861,7929	0
Varyans	22,8699	0,0566	404,2915	0

4.3 LSTM Model Tasarımı

Tez çalışmasının bu bölümünde zaman serisinin düzensizlik bileşenleri için tahmin gerçekleştirmek üzere LSTM model tasarımı ele alınmıştır. LSTM model geliştirilirken

sırası ile veri hazırlığı, eğitim ve test verilerinin belirlenmesi, veri setinin yeniden şekillendirilmesi, LSTM modelin oluşturulması, modelin derlenmesi, modelin eğitimi ve model performansının değerlendirilmesi adımları takip edilir. Hibrit yöntemde kullanılacak LSTM ağının özelliklerini belirlemek için orijinal güneş ışınımı zaman serisi kullanılmıştır. İlk olarak giriş parametrelerini anlamlı bir şekilde ölçeklendirme gerekmektedir. Güneş ışınımı zaman serisi verileri için minimum-maksimum normalizasyon tekniği uygulanmış ve her bir veri noktası [0-1] aralığında ölçeklendirilmiştir. Modeli eğitmek için 2018-2021 yılları arası saatlik güneş ışınımı değerleri eğitim verisi olarak ayrılmıştır. Model değerlendirmesi için test verisi olarak 2022 yılına ait saatlik güneş ışınımı verileri kullanılmıştır. Veri yapısı yeniden şekillendirilirken LSTM ağının girdi verisi olarak kullanacağı ardışık veri noktası sayısı belirlenmiştir. Mevcut çalışmada zaman adımı 24 seçilmiştir. Bu, her tahmin noktası için önceki 24 saatin verilerinin kullanıldığı anlamına gelmektedir. Oluşturulan Standart LSTM modeli için bir LSTM katmanı, bir Dense katmanı geliştirilmiştir. Döngü sayısı 100 belirlenerek her döngüde modelin derlenmesi ve eğitimi için gerekli optimizasyon algoritmaları, öğrenme katsayısı ve yığın boyutu gibi hiperparametre değerleri model kayıp grafiklerine bakılarak seçilmiştir.

4.3.1 Hiperparametre Değerlerinin Ayarlanması

LSTM ağı için doğru hiperparametre değerlerini belirlemek, modelin doğruluğunu ve genelleme yeteneğini önemli ölçüde etkilemektedir. Uygun olmayan değerlerin seçilmesi modelin eğitim verisine aşırı uyum sağlamasına ya da tam tersi modelin yetersiz kalmasına sebebiyet verebilmektedir. Farklı hiperparametre değerleri ile oluşturulan LSTM modelleri Çizelge 4.6'da sunulmaktadır. Yığın sayısı ve öğrenme oranı modelin eğitim süresini etkilerken; katman sayısı, nöron sayısı veya aşırı uyumu azaltmak için kullanılan seyreltme oranı modelin öğrenme yeteneği üzerinde etkilidir. Farklı hiperparametre değerlerine sahip LSTM modellerin performans yeteneğini incelemek için eğitim veri seti ve doğrulama veri seti hata kayıp grafikleri incelenmiştir. Çizelge 4.7 LSTM modellerinin eğitim sonuçlarını göstermektedir. Farklı optimizasyon algoritmaları ile oluşturulan LSTM-1, LSTM-2, LSTM-3 ve LSTM-4 modellerinin hata kayıp grafikleri Şekil 4.6'da verilmektedir.

Çizelge 4.6 Belirlenen LSTM modellerinin hiperparametre değerleri


Model	Optimizasyon Algoritması	Nöron Sayısı	Yığın Boyutu	Öğrenme Katsayısı	Seyreltme Oranı
LSTM-1	RMSprop	32	64	0,001	-
LSTM-2	Adagrad	32	64	0,001	-
LSTM-3	SGD	32	64	0,001	-
LSTM-4	Adam	32	64	0,001	-
LSTM-5	Adam	64	64	0,001	-
LSTM-6	Adam	32	32	0,001	-
LSTM-7	Adam	32	64	0,001	0,2
LSTM-8	Adam	32	64	0,01	-

Çizelge 4.7 LSTM modellerinin eğitim sonucu

Model	Eğitim Süresi	Eğitim Veri Seti Hata Kaybı	Doğrulama Veri Seti Hata Kaybı	Test Veri Seti RMSE
LSTM-1	56,5 s	0,0047	0,0045	4,16
LSTM-2	53,8 s	0,0077	0,0078	5,31
LSTM-3	56,1 s	0,0074	0,0074	5,73
LSTM-4	58,6 s	0,0045	0,0045	4,12
LSTM-5	1 d 5,5 s	0,0043	0,0045	4,09
LSTM-6	2 d 34 s	0,0045	0,0046	4,15
LSTM-7	1 d 0,4 s	0,0059	0,0046	4,10
LSTM-8	58,4 s	0,0045	0,0045	4,86

LSTM-1 modelinde doğrulama eğrisi eğitim eğrisinin altında kalmaktadır. Bu eğitim verisinin doğrulama verisine göre daha zor modellendiğini göstermektedir. LSTM-2 ve LSTM-3 modellerinde ise eğitim ve doğrulama eğrileri birbiri ile uyumlu bir hizalanma gösterse de daha yüksek bir hata kayıp değeri elde etmişlerdir. Ayrıca test verisi üzerinden yapılan değerlendirme de en yüksek RMSE değerine sahip ilk iki modeldir. LSTM-4 modelinde ise hata kayıp değeri daha düşük elde edilmiş ve eğitim eğrisi ile doğrulama eğrisi birbirine uyumlu bir şekilde azalma eğilimi göstererek aynı seviyede hizalanma göstermiştir. Ayrıca test veri için yapılan değerlendirmede 4,12 RMSE değerinin elde edilmesi modelin hedef çıktığı doğru tahmin edebildiğini ve veri üzerinde iyi bir


genelleme yeteneğine sahip olduğunu ifade etmektedir. Bu nedenle LSTM modeli oluşturulurken Adam optimizasyon algoritması tercih edilmiştir.



Şekil 4.6 LSTM-1, LSTM-2, LSTM-3 ve LSTM-4 modellerin hata kayıp grafikleri

LSTM-5, LSTM-6, LSTM-7 ve LSTM-8 modellerinin hata kayıp grafikleri Şekil 4.7’de sunulmaktadır. LSTM-5 modeli için doğrulama eğrisi döngünün sonuna doğru eğitim eğrisinin üzerinde bir eğilim göstermiştir. Aynı şekilde LSTM-6 modelinde de oluşan hata kayıp grafiğinde doğrulama eğrisi döngü sonlarına doğru yükselişe geçmiştir. LSTM-7 modelinde ise seyreltme katmanının eklenmesi doğrulama eğrisinin tüm döngü boyunca eğitim eğrisinin altında kalmasına neden olmuştur. Bu modelin verileri iyi bir şekilde modelleyemediğini ve genelleme yeteneğinin zayıf kaldığını göstermektedir. Bundan dolayı modelden seyreltme katmanı çıkarılmıştır. Ayrıca LSTM-5, LSTM-6 ve LSTM-7 modelleri en uzun eğitim süresine sahip ilk üç modeldir. LSTM-8 modeli için doğrulama ve eğitim hata kayıp değerleri düşük ve birbiri ile tam olarak uyumlu elde edilmiştir. Ancak hata kayıp grafiği incelendiğinde doğrulama eğrisinin yüksek

değişkenlikte ve salınım eğiliminde olduğu görülmektedir. Model daha yüksek öğrenme katsayısı ile verileri iyi bir şekilde optimize edememiştir. Bu nedenle öğrenme kat sayısı 0,001 olarak seçilmiştir. Mevcut çalışmada kullanılmak üzere oluşturulan modellerden LSTM-4 modeli seçilmiştir. Tek katmanlı standart LSTM modelin parametre değerleri Çizelge 4.8’de özetlenmektedir. Her K katmanı için bu parametre değerleri kullanılmıştır.



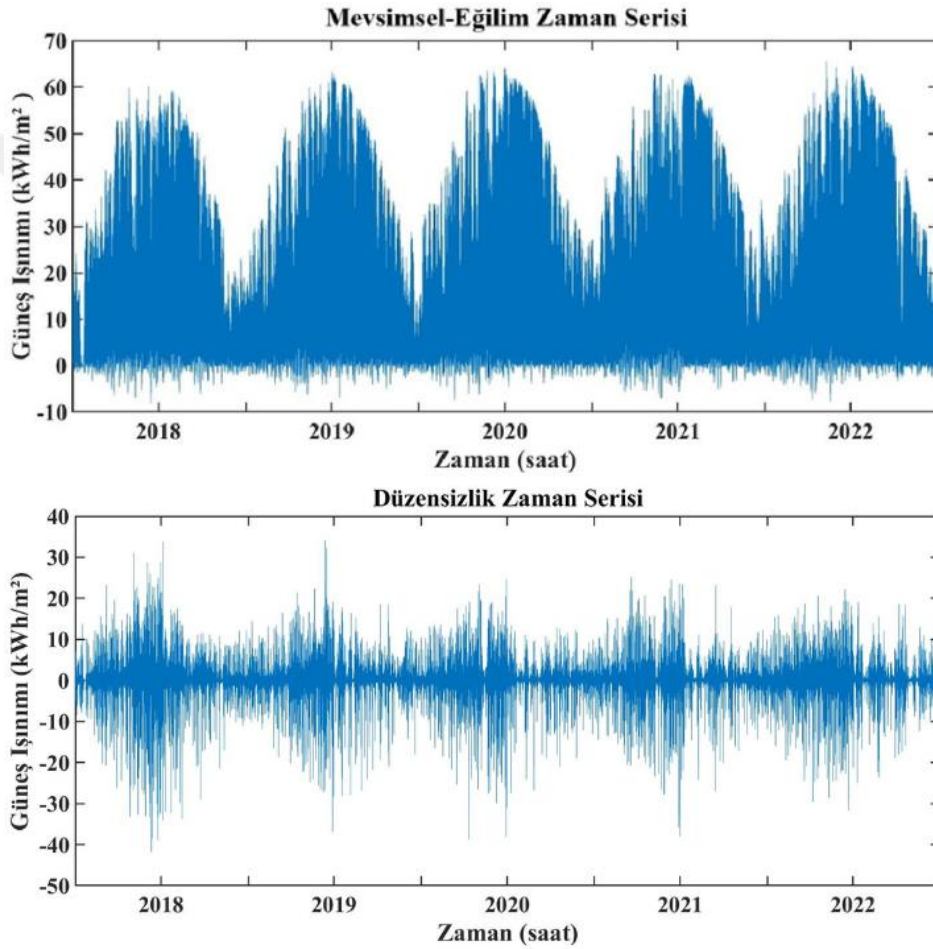
Şekil 4.7 LSTM-5, LSTM-6, LSTM-7 ve LSTM-8 modellerin hata kayıp grafikleri

Çizelge 4.8 Çalışmada kullanılan LSTM modelin parametre değerleri

Parametre	Değer
Optimizasyon Algoritması	Adam
Aktivasyon Fonksiyonu	ReLU
Öğrenme Katsayısı	0,001
1.Katman	64 hücre
Dense Katmanı	1 hücre
Döngü Sayısı	100
Yığın Boyutu	64

4.4 Hibrit Model Tasarımı

Hibrit yöntem, orijinal güneş ışınımı zaman serisinin STL tabanlı ayrıştırılması metoduna dayalı olarak oluşturulmuştur. Bu bağlamda STL ayrıştırması sonucu Şekil 4.8’de gösterilen mevsimsel ve eğilim verilerini içeren zaman serisi ile düzensizlik verileri içeren zaman serisi elde edilmiştir. Elde edilen zaman serileri zaman serisi 10-Katlı CV ile ayrılmıştır.



Şekil 4.8 Güneş ışınımı zaman serisinin STL ayrıştırması sonucu elde edilen zaman serileri

SARIMA(3,1,2) \times (3,1,1)₂₄ modeli mevsimsel-eğilim zaman serisi katmanları için tahmin gerçekleştirirken, LSTM-4 modeli ise düzensizlik zaman serisi katmanları için tahmin gerçekleştirmiştir. Elde edilen tahmin sonuçlarının toplamı hibrit modelin tahminini vermektedir.

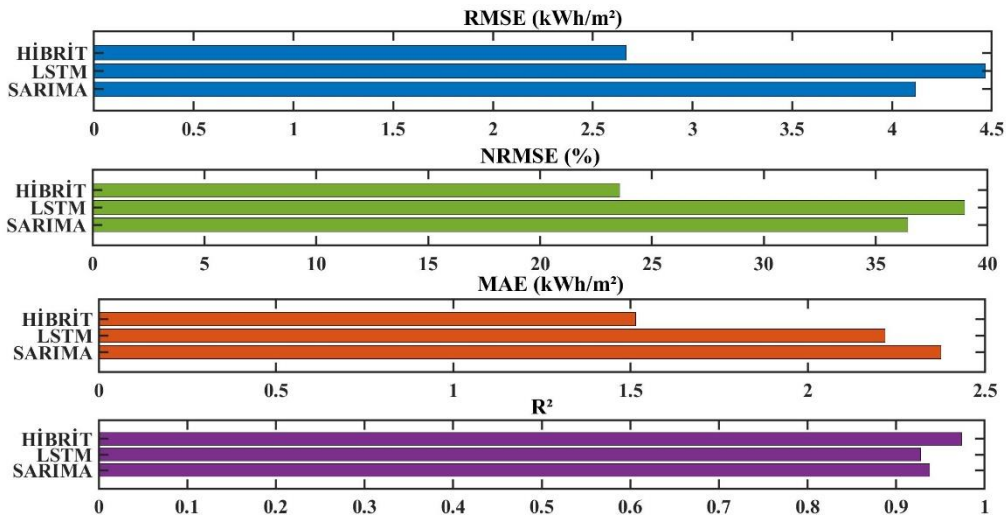
4.4.1 Hibrit Model Tahmin Performansı

Bu bölümde hibrit modelin korelasyon, histogram ve normal Q-Q grafiği diğer tahmin modelleri ile karşılaştırmalı olarak incelenmiştir. Bu grafikler, modelin doğruluğunu ve uygunluğu hakkında bilgi sağlar. İlk olarak 10-Katlı zaman serisi CV uygulandığından dolayı her K iterasyonu için hibrit ve diğer tahmin modellerinin performans değerlendirme metrik sonuçları Çizelge 4.9’da sunulmaktadır.

Çizelge 4.9 Hibrit, SARIMA ve LSTM modellerinin her K iterasyonu için metrik sonuçları

K-KATLI CV	MODEL	RMSE (kWh/m ²)	NRMSE (%)	MAE (kWh/m ²)	R ²
1. İTERASYON	SARIMA	4,5950	36,50	2,5827	0,9316
	LSTM	6,5319	52,46	3,0492	0,8659
	HİBRİT	3,6644	29,43	1,8705	0,9565
2. İTERASYON	SARIMA	3,9062	48,61	2,5366	0,9159
	LSTM	4,0203	50,03	2,3003	0,9113
	HİBRİT	2,5765	32,06	1,6015	0,9640
3. İTERASYON	SARIMA	4,7028	29,77	2,7114	0,9450
	LSTM	5,4899	34,75	2,6711	0,9256
	HİBRİT	3,086	19,53	1,6976	0,9765
4. İTERASYON	SARIMA	3,4752	48,65	2,1567	0,9178
	LSTM	3,4485	48,27	1,7322	0,9191
	HİBRİT	2,2541	31,55	1,3193	0,9671
5. İTERASYON	SARIMA	4,3976	25,29	2,4271	0,9573
	LSTM	5,4248	31,20	2,6260	0,9349
	HİBRİT	3,0702	17,65	1,6618	0,9796
6. İTERASYON	SARIMA	2,8965	38,70	1,7811	0,9442
	LSTM	3,1503	42,09	1,5887	0,9358
	HİBRİT	1,8645	24,91	1,1204	0,9772
7. İTERASYON	SARIMA	5,2265	32,55	3,1538	0,9347
	LSTM	5,4398	33,88	2,6372	0,9290
	HİBRİT	3,2378	20,16	1,8924	0,9751
8. İTERASYON	SARIMA	3,2629	37,69	1,6913	0,9477
	LSTM	3,0027	34,69	1,5074	0,9567
	HİBRİT	1,8945	21,88	1,0839	0,9824
9. İTERASYON	SARIMA	5,3593	37,30	2,9931	0,9224
	LSTM	5,1948	36,16	2,5728	0,9271
	HİBRİT	3,1860	22,17	1,9158	0,9726
10. İTERASYON	SARIMA	3,3431	29,30	1,7239	0,9625
	LSTM	2,9812	26,13	1,4869	0,9707
	HİBRİT	1,8503	16,22	0,9856	0,9885

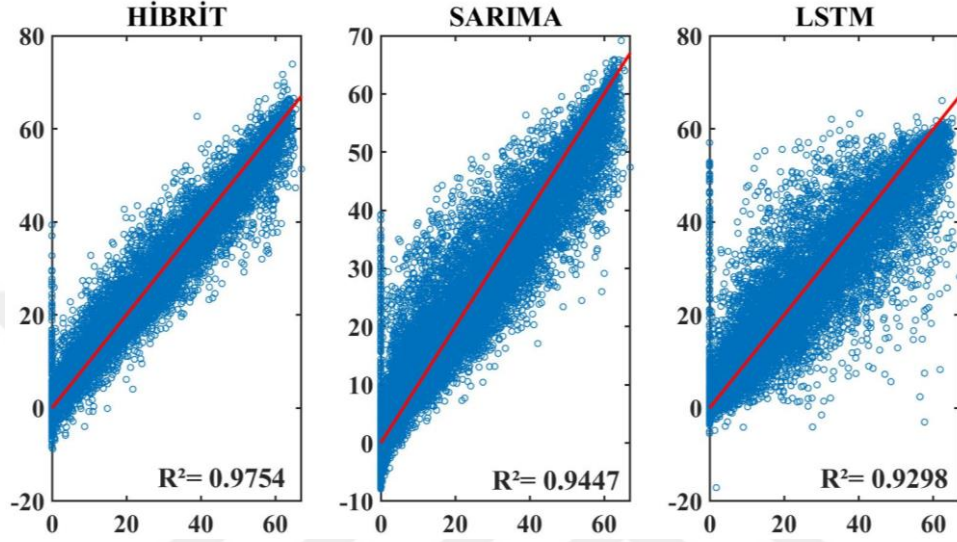
Her iterasyonda 3960 adet veri içeren test dönemleri için değerlendirme yapılmıştır. Metrik sonuçlara göre hibrit model tüm iterasyonlarda en düşük RMSE, NRMSE ve MAE değeri ile en yüksek R^2 değerine sahiptir. Tüm iterasyonların ortalaması alındığında sırası ile SARIMA model 4,1165 RMSE, 36,44 NRMSE, 2,3758 MAE ve 0,9379 R^2 değeri, LSTM model 4,4684 RMSE, 38,97 NRMSE, 2,2172 MAE ve 0,9276 R^2 değeri elde edilmiştir. Hibrit model ise 2,6684 RMSE, 23,56 NRMSE ve 1,5149 MAE ile en düşük hata değerlerini verirken, 0,9740 R^2 değeri ile en yüksek determinasyon katsayısına ulaşmıştır. Tahmin modellerin metrik karşılaştırma grafikleri Şekil 4.9’da gösterilmektedir. Önerilen hibrit model SARIMA tahmin modeline göre %35,18 oranında RMSE değerini, %35,35 oranında NRMSE değerini, %36,24 oranında MAE değerini azaltırken R^2 değerini ise %3,85 oranında iyileştirmiştir. LSTM tahmin modeline göre ise %40,28 oranında RMSE değerini, %39,55 oranında NRMSE değerini, %31,68 oranında MAE değerini azaltırken R^2 değerini ise %5 oranında iyileştirmiştir.



Şekil 4.9 Hibrit, SARIMA ve LSTM modellerinin ortalama metrik sonuçlarının sütun grafiği

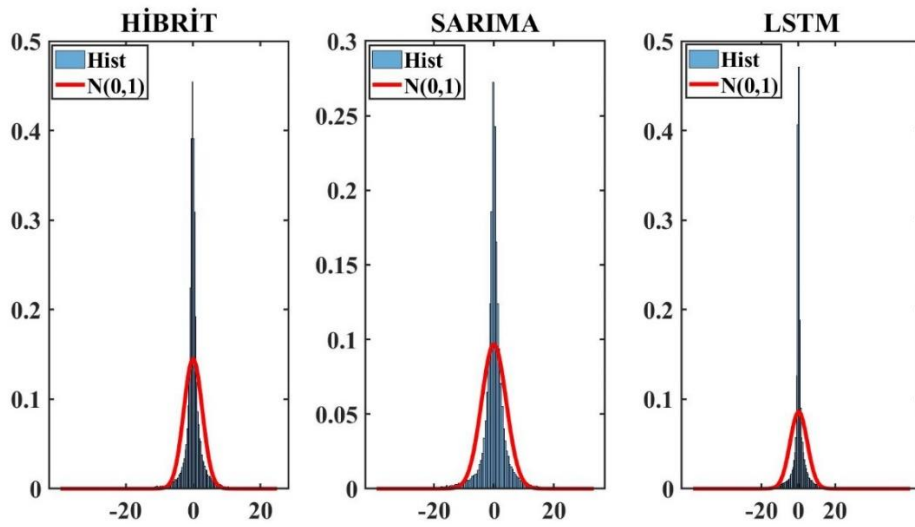
Model değerlendirmesi için gerekli olan tanısal grafikler tüm veri seti üzerinden gerçekleştirilmiştir. Hibrit, SARIMA ve LSTM modellerinin tahmin edilen güneş ışınımı değerleri ile gerçek güneş ışınımı değerleri arasındaki ilişkiyi gösteren korelasyon grafikleri Şekil 4.10’da verilmiştir. Bu grafik modelin veriler üzerinde genelleme yeteneği hakkında bilgi verir. Hibrit model 0,9754 R^2 değeri ile oldukça güçlü bir doğruluk oranına sahiptir. Kırmızı ile gösterilen doğrusal çizgi etrafında veriler sıkı bir

şekilde konumlanmıştır. SARIMA ve LSTM modelleri de gerçek verilere uygun güneş ışınımı tahmini gerçekleştirmiştir ancak hibrit modelin gerisinde kalmıştır. Veriler doğrusal çizgi etrafında kümelenmiş olsa da sapmalar daha fazla görülmektedir. SARIMA model LSTM modeline göre daha yüksek bir korelasyon değeri elde etmiştir.



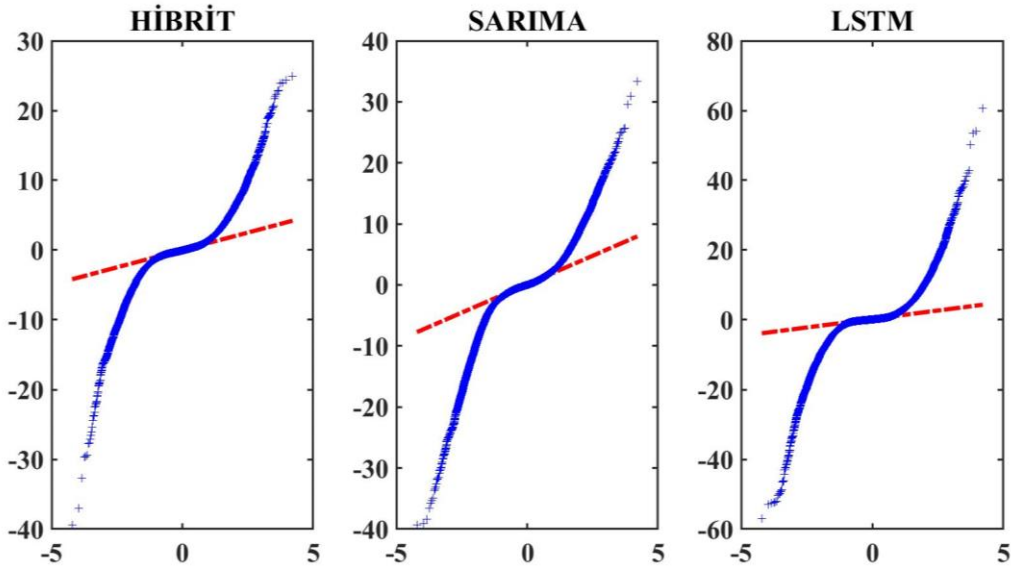
Şekil 4.10 Hibrit, SARIMA ve LSTM modellerinin korelasyon grafikleri

Çalışmada kullanılan modellerin histogram grafikleri Şekil 4.11’de gösterilmektedir. Histogram grafiği modellerin hata dağılımının normal dağılım eğrisi (N(0,1)) ile ne kadar uyumlu olduğu hakkında bir fikir sunar.



Şekil 4.11 Hibrit, SARIMA ve LSTM modellerinin histogram grafikleri

Hibrit modelin hata dağılımı $N(0,1)$ eğrisine yakın bir yapı sergilemiştir, bu durum önerilen modelin dengeli bir tahmin performansına sahip olduğunu göstermektedir. SARIMA ve LSTM modelleri de hibrit modele kıyasla biraz daha geniş bir aralıkta hata dağılımı göstermiştir. Her iki modelde de uç değerlerdeki sapmalar tahmin performansını olumsuz etkilemektedir. Tahmin modelleri için oluşturulan Q-Q grafikleri ise Şekil 4.12’de sunulmaktadır. Bu grafikler modellerden elde edilen hata değerlerin normal dağılıma (kırmızı kesikli çizgi) ne kadar uygun olduğunu değerlendirmek için kullanılır. İdeal bir durumda noktalar düz bir 45° çizgi üzerinde sıralanarak veri setini teorik bir normal dağılım ile karşılaştırır. Tez çalışması kapsamında önerilen hibrit modelin hata değerleri normal dağılıma en uygun şekilde sıralanmıştır. Bu hibrit modelin tutarlı ve istatistiksel olarak anlamlı bir şekilde hata dağılımı gösterdiğini ifade etmektedir. SARIMA ve LSTM modelleri ise yalnız başlarına kullanıldığında hibrit modele kıyasla daha zayıf bir tahmin performansı göstermiştir. Özellikle uç değerlerde daha fazla sapma görülmekte normal dağılımdan uzaklaşmaktadır.



Şekil 4.12 Hibrit, SARIMA ve LSTM modellerinin Q-Q grafikleri

4.4.2 Farklı Mevsim Koşulları Altında Hibrit Model Tahmin Performansı

Bu bölüm, hibrit modelin tahmin performansını farklı mevsim koşulları altında değerlendirmek üzere yapılan deneysel çalışmaların sonuçlarını sunmaktadır. 17.06.2018 – 31.12.2022 tarihleri arasını kapsayan tahmin aralığı içerisinde dört mevsimi temsil

eden günler belirlenmiştir. Çizelge 4.10 yaz mevsimi günleri, Çizelge 4.11 sonbahar mevsimi günleri, Çizelge 4.12 kış mevsimi günlerini, Çizelge 4.13 ise ilkbahar mevsimi günleri için gerçekleştirilen saatlik güneş ışınımı tahmini sonuçlarını vermektedir. Kullanılan performans değerlendirme metriklerinin tümünde hibrit model daha iyi bir tahmin performansı göstermiştir. Tahmin performansını sırası ile SARIMA ve LSTM modeli takip etmektedir.

Çizelge 4.10 Yaz mevsimi günleri için güneş ışınımı tahmin sonuçları

Tahmin Edilen Gün	Model	RMSE (kWh/m ²)	NRMSE (%)	MAE (kWh/m ²)	R ²
Ağustos 20, 2018	SARIMA	1,3476	7,54	1,5753	0,9979
	LSTM	2,0408	11,42	1,2845	0,9949
	HİBRİT	0,9505	5,32	0,6373	0,9980
Ağustos 12, 2019	SARIMA	1,0534	5,13	0,8961	0,9994
	LSTM	2,4827	12,08	1,6375	0,9968
	HİBRİT	0,4259	2,07	0,3880	0,9998
Ağustos 2, 2020	SARIMA	0,8768	2,15	0,4494	0,9986
	LSTM	2,0572	10,10	1,2116	0,9957
	HİBRİT	0,5054	1,85	0,3611	0,9996
Ağustos 4, 2021	SARIMA	0,7625	3,76	0,6731	0,9990
	LSTM	0,9702	4,79	0,6591	0,9989
	HİBRİT	0,4588	2,26	0,3753	0,9998
Temmuz 25, 2022	SARIMA	0,5497	2,54	0,4378	0,9996
	LSTM	1,3278	6,15	0,8983	0,9987
	HİBRİT	0,4451	2,06	0,3753	0,9997

Yaz mevsimi için ortalama metrik sonuçlarına göre Hibrit model 0,5571 RMSE, 0,4274 MAE ve 2,71 NRMSE ile en düşük hata değerini elde etmiştir. SARIMA modeli 0,9180 RMSE, 4,22 NRMSE ve 0,8063 MAE elde ederken, LSTM modeli 1,7757 RMSE, 8,91 NRMSE ve 1,1382 MAE değeri elde etmiştir. En yüksek R² değerine ise 0,9994 ile Hibrit model ulaşmıştır. Yaz günleri içerisinde en düşük hata değerine ve en yüksek determinasyon katsayısına 12 Ağustos 2019 günü için hibrit model tarafından kaydedilmiştir.

Çizelge 4.11 Sonbahar mevsimi günleri için güneş ışınlamı tahmin sonuçları

Tahmin Edilen Gün	Model	RMSE (kWh/m ²)	NRMSE (%)	MAE (kWh/m ²)	R ²
Ekim 6, 2018	SARIMA	1,4553	3,32	1,1834	0,9948
	LSTM	1,8876	4,31	1,3118	0,9966
	HİBRİT	0,7035	1,61	0,4928	0,9984
Ekim 14, 2019	SARIMA	0,7560	1,70	0,5651	0,9986
	LSTM	0,9262	2,09	0,6572	0,9971
	HİBRİT	0,4455	1,00	0,3262	0,9993
Eylül 10, 2020	SARIMA	1,0122	1,87	0,8098	0,9988
	LSTM	1,8411	3,41	1,3209	0,9937
	HİBRİT	0,6512	1,21	0,5660	0,9993
Ekim 3, 2021	SARIMA	0,9626	6,83	0,6738	0,9973
	LSTM	1,503	10,66	0,8491	0,9965
	HİBRİT	0,53	3,76	0,4011	0,9993
Eylül 15, 2022	SARIMA	0,3233	1,97	0,2541	0,9999
	LSTM	1,1130	6,78	0,8666	0,9982
	HİBRİT	0,2480	1,51	0,2167	0,9999

Sonbahar mevsimi için elde edilen ortalama metrik değerlerine göre, hibrit model 0,5156 RMSE, 1,82 NRMSE ve 0,4006 MAE ile en düşük hata değerlerini sağlamıştır. LSTM modeli 1,4542 RMSE, 5,45 NRMSE ve 1,0011 MAE değeri ile hibrit modele kıyasla daha yüksek hata değeri göstermiştir. SARIMA modeli ise 0,9019 RMSE, 3,14 NRMSE ve 0,6972 MAE değerleriyle LSTM modele kıyasla daha iyi bir tahmin performansı gösterirken hibrit modelin tahmin performansını yakalayamamıştır. Modeller arasındaki karşılaştırmada, en yüksek determinasyon katsayısı ise 0,9992 R² değeriyle hibrit model tarafından elde edilmiştir. 15 Eylül 2022, günü için gerçekleştirilen saatlik güneş ışınlamı tahmininde ise tüm dönemlerin tahmin performansı içerisinde en düşük hata değerleri elde edilmiştir.

Kış mevsimi için elde edilen metrik sonuçların ortalaması alındığında modellerin tahmin doğruluğu en yüksekten en düşüğe doğru sırası ile 0,5698 RMSE, 8,35 NRMSE ve 0,4198 MAE değerine sahip hibrit modeli, 1,1885 RMSE, 19,50 NRMSE ve 0,8901 MAE değeri ile SARIMA modeli 1,7073 RMSE, 23,69 NRMSE ve 1,1335 MAE değeri ile LSTM

modeli gelmektedir. 0,9975 R² değeri ile hibrit model daha başarılı bir tahmin yeteneği göstermektedir. Kış günleri içerisinde en düşük hata değeri 6 Aralık 2020 günü hibrit model tarafından elde edilmiştir.

Çizelge 4.12 Kış mevsimi günleri için güneş ışımasını tahmin sonuçları

Tahmin Edilen Gün	Model	RMSE (kWh/m ²)	NRMSE (%)	MAE (kWh/m ²)	R ²
Aralık 15, 2018	SARIMA	2,3687	51,49	1,8271	0,9693
	LSTM	1,9827	43,10	1,2262	0,9465
	HİBRİT	0,8255	17,95	0,6085	0,9920
Şubat 19, 2019	SARIMA	0,6255	5,74	0,5061	0,9985
	LSTM	2,3688	21,75	1,7734	0,9815
	HİBRİT	0,5549	5,10	0,4217	0,9988
Aralık 6, 2020	SARIMA	1,1237	17,63	0,9489	0,9973
	LSTM	1,5326	24,04	0,9061	0,9904
	HİBRİT	0,3979	6,24	0,3077	0,9989
Şubat 23, 2021	SARIMA	0,6991	5,60	0,4989	0,9984
	LSTM	1,4853	11,90	1,0127	0,9977
	HİBRİT	0,5290	4,24	0,4378	0,9994
Aralık 29, 2022	SARIMA	1,1254	17,03	0,6696	0,9960
	LSTM	1,1671	17,66	0,7491	0,9924
	HİBRİT	0,5418	8,20	0,3231	0,9986

İlkbahar mevsimi için modellerin tahmin yetenekleri incelendiğinde hibrit model için 0,709 RMSE, 3,62 NRMSE ve 0,5257 MAE değerleri elde edilmiş ve en yüksek R² değeri 0,9993 seviyesine ulaşılmıştır. SARIMA model 1,3931 RMSE, 7,17 NRMSE ve 1,0571 MAE değeri ile başarı sıralamasını takip ederken, 2,2622 RMSE, 11,89 NRMSE ve 1,4002 MAE değerine sahip LSTM modeli son sırada yer almaktadır. En yüksek tahmin doğruluğuna 15 Mayıs 2020 günü için hibrit model tarafından ulaşılmıştır.

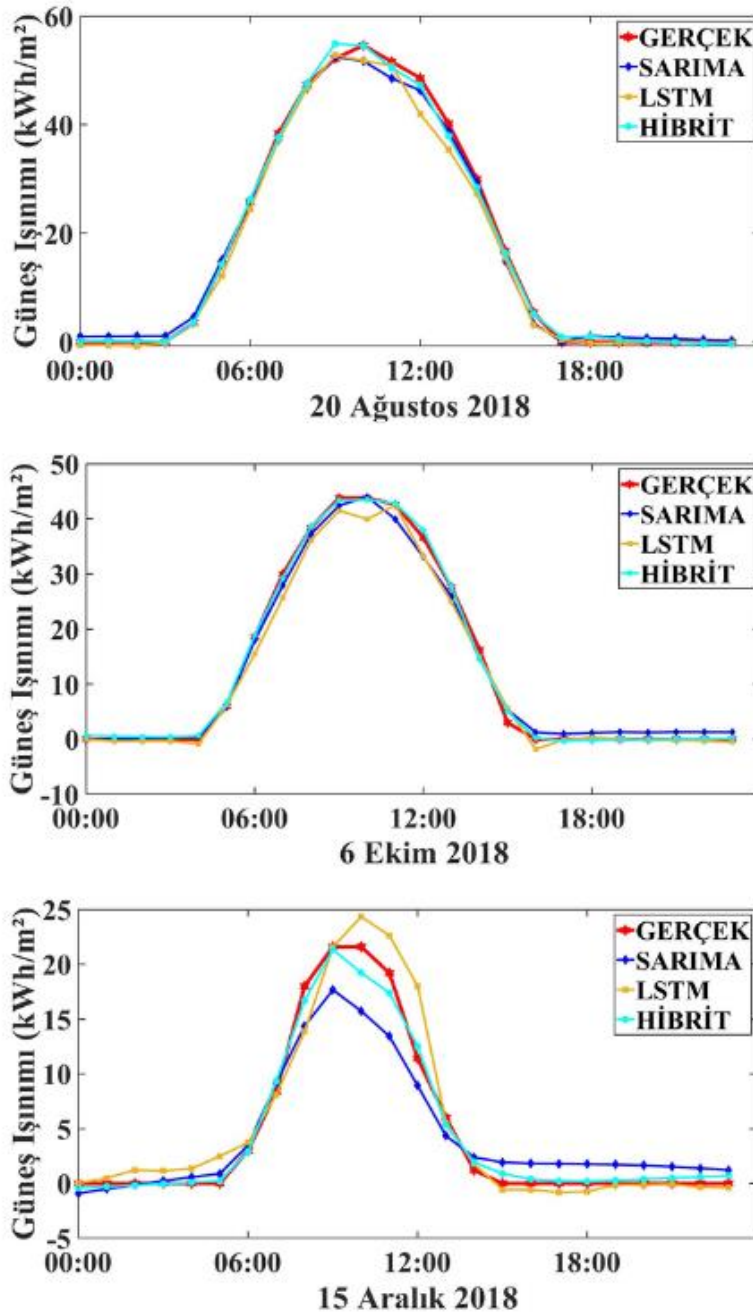
Çalışmada kullanılan hibrit, SARIMA ve LSTM modelleri için tahmin grafikleri Şekil 4.13 – Şekil 4.21 arası sunulmaktadır. Seçilen günler, 2018'den 2022'ye kadar olan dört mevsimin her birini temsil etmektedir. Her modelin tahmin değerleri çeşitli renklerde gösterilirken, gerçek güneş ışımasını değerleri kırmızı ile gösterilmiştir.

Çizelge 4.13 İlkbahar mevsimi günleri için güneş ışınımı tahmin sonuçları

Tahmin Edilen Gün	Model	RMSE (kWh/m ²)	NRMSE (%)	MAE (kWh/m ²)	R ²
Mart 25, 2019	SARIMA	1,0894	6,82	0,7180	0,9936
	LSTM	2,3038	14,42	1,9027	0,9937
	HİBRİT	0,4715	2,95	0,3798	0,9996
Mayıs 15, 2020	SARIMA	0,5260	2,59	0,4392	0,9996
	LSTM	2,0008	9,87	1,1687	0,9952
	HİBRİT	0,4686	2,31	0,3695	0,9998
Mayıs 14, 2021	SARIMA	1,3456	6,08	1,1048	0,9992
	LSTM	1,3432	6,07	0,8867	0,9988
	HİBRİT	0,7191	3,25	0,5197	0,9996
Nisan 24, 2022	SARIMA	2,6116	13,21	1,9665	0,9962
	LSTM	3,4009	17,21	1,6427	0,9850
	HİBRİT	1,1769	5,95	0,8336	0,9982

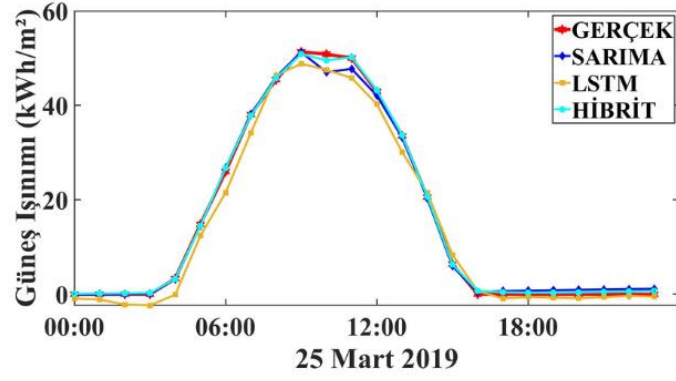
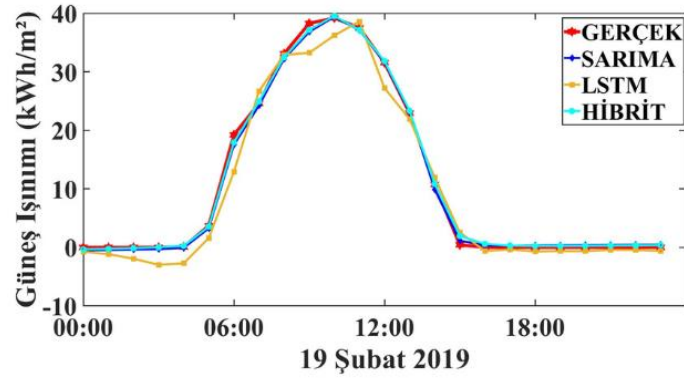
Şekil 4.13, 2018 yılı içerisinde seçilen yaz, sonbahar ve kış günlerinin tahmin grafiklerini göstermektedir. Güneş ışınımı veri setinde test dönemi 16 Haziran 2018 günü itibari ile başladığı için ilkbahar mevsimini temsil eden gün seçilememiştir ve üç mevsimsel gün üzerinden değerlendirme yapılmıştır. Grafikler incelendiğinde, önerilen hibrit modelin tahmin eğrisi gerçek değerlerin eğrisine yakın hizalandığı görülmektedir. Diğer modellerden farklı olarak, hibrit yöntem ani artış ve azalış eğilimlerini daha iyi yakalamıştır. SARIMA modeli kış ve yaz günü için güneş ışınımı tahmininde gerçek değerlerin altında bir eğilim göstermiştir. LSTM modeli ise yaz ve sonbahar günü tahmininde gerçek değerlerin altında kalırken, kış günü tahmininde gerçek değerlerin üzerine çıkarak bir sapma göstermiştir.

Şekil 4.14 ve Şekil 4.15, 2019 yılı için seçilen farklı mevsim günlerinin güneş ışınım tahmin grafiğini göstermektedir. Grafikler incelendiğinde tüm mevsim günleri için LSTM modelinin tahmin eğrisi gerçek değerlerden daha uzak bir hizalanma göstermiştir. Hibrit ve SARIMA tahmin modeli ise gerçek değerlerin eğrisine oldukça yakın bir tahmin üretmiştir. Ancak ilkbahar günü tahmininde SARIMA modeli de gerçek değerlerin altında kalmıştır.

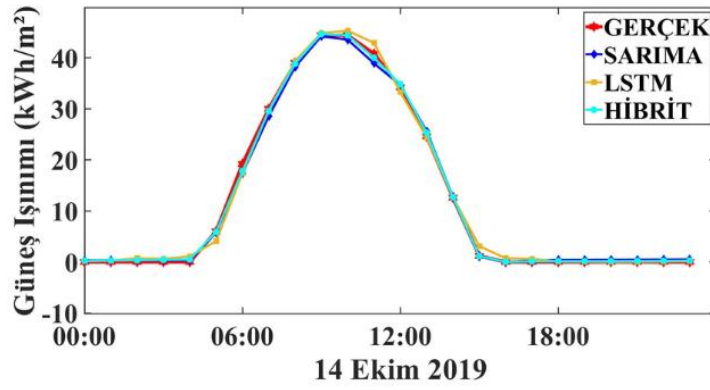
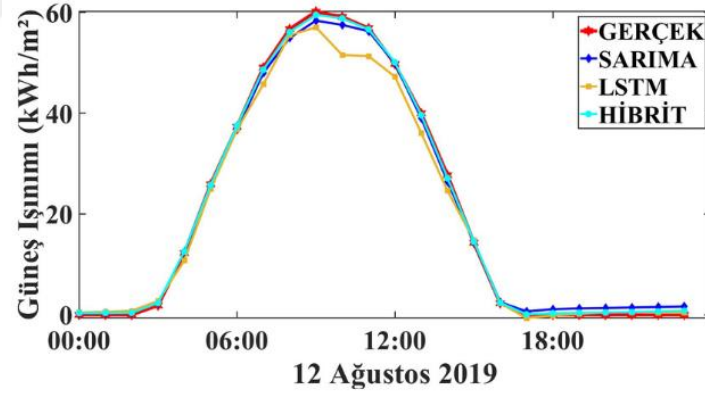


Şekil 4.13 2018 yılında üç mevsim için saatlik güneş ışıını tahmin grafikleri

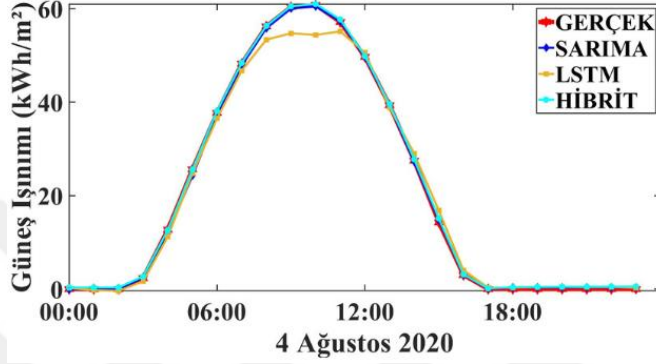
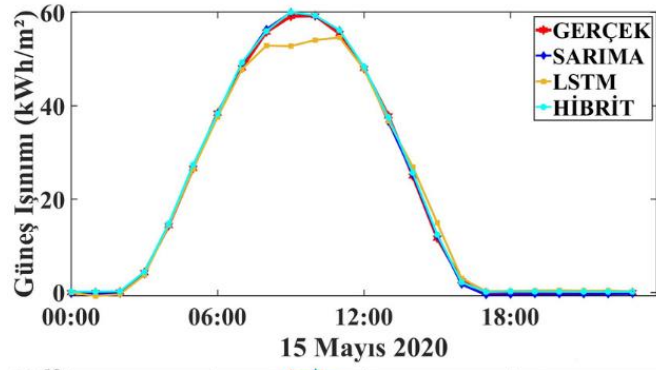
Şekil 4.16 ve Şekil 4.17, 2020 yılı için seçilen farklı mevsim günlerinin güneş ışıını tahmin grafiğini göstermektedir. Grafikler incelendiğinde LSTM modeli tüm mevsim günleri için gerçek değerlerin altında bir çıktı üretmiştir. Hibrit model tüm mevsim günleri için gerçek değerlere en yakın tahmin gerçekleştirirken, SARIMA modeli ise sadece kış günü tahmini için gerçek değerlerin eğrisinden belirgin bir sapma göstermiştir.



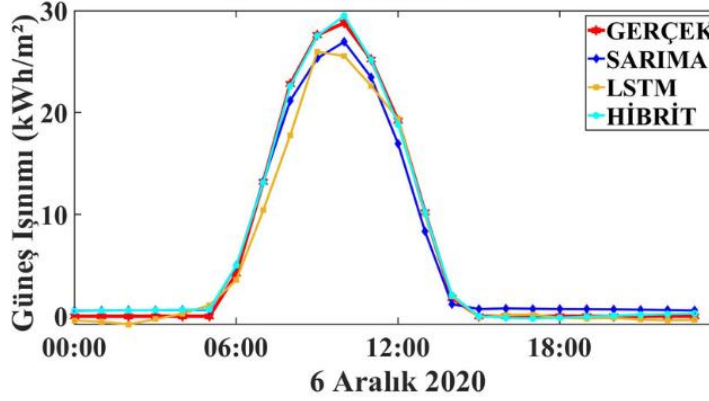
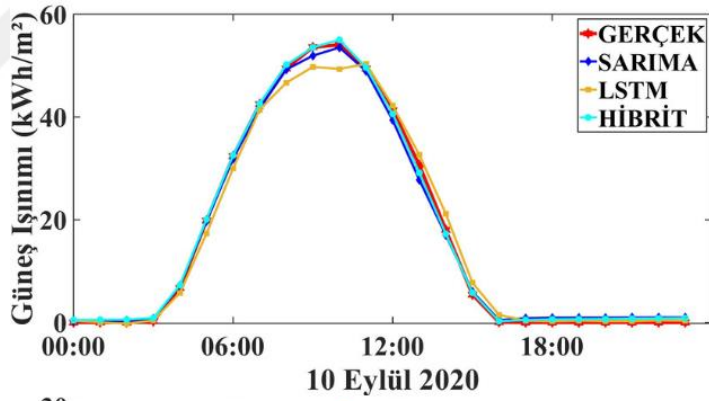
Şekil 4.14 2019 yılında farklı mevsim günleri için saatlik güneş ışıını tahmin grafikleri-1



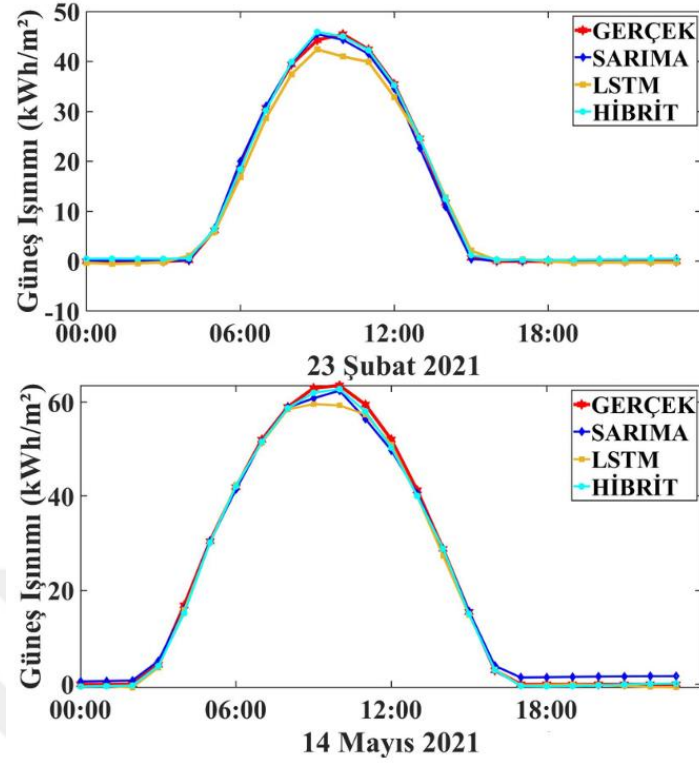
Şekil 4.15 2019 yılında farklı mevsim günleri için saatlik güneş ışıını tahmin grafikleri-2




Şekil 4.16 2020 yılında farklı mevsim günleri için saatlik güneş ışınmını tahmin grafikleri-1



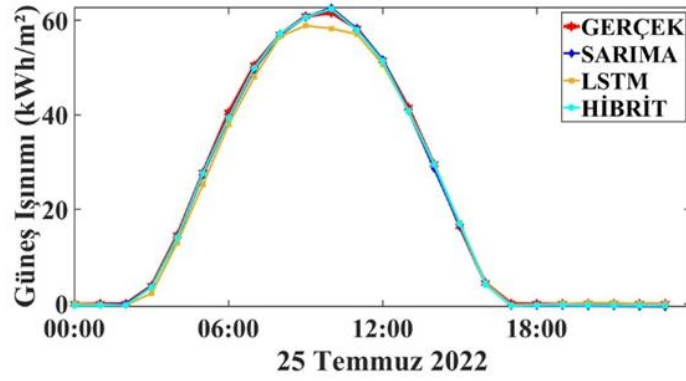
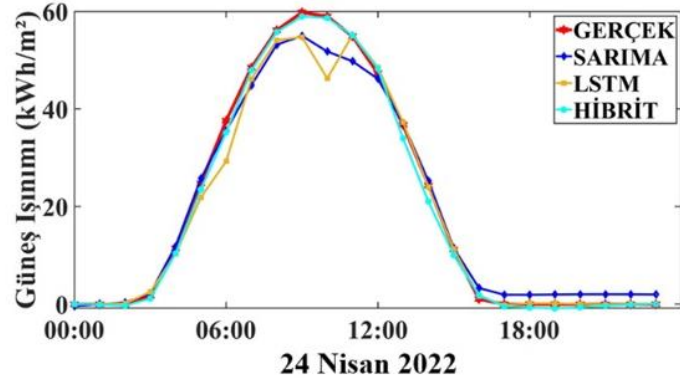
Şekil 4.17 2020 yılında farklı mevsim günleri için saatlik güneş ışınmını tahmin grafikleri-2



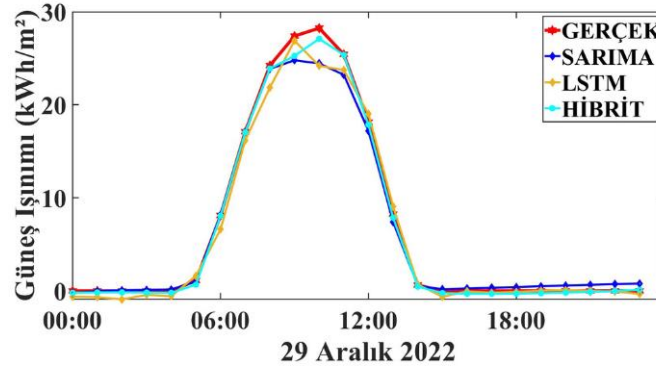
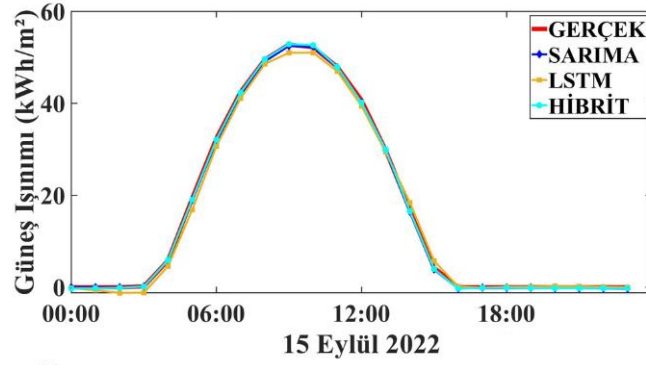
Şekil 4.18 2021 yılında farklı mevsim günleri için saatlik güneş ışıını tahmin grafikleri-1



Şekil 4.19 2021 yılında farklı mevsim günleri için saatlik güneş ışıını tahmin grafikleri-2



Şekil 4.20 2022 yılında farklı mevsim günleri için saatlik güneş ışınmı tahmin grafikleri-1



Şekil 4.21 2022 yılında farklı mevsim günleri için saatlik güneş ışınmı tahmin grafikleri-2

Şekil 4.18 ve Şekil 4.19, 2021 yılı için seçilen farklı mevsim günlerinin güneş ışıının tahmin grafiğini göstermektedir. Grafikler incelendiğinde tüm mevsim günleri için hibrit ve SARIMA modelin gerçek güneş ışıını değerlerine en yakın hizalanma gösterdiğini ancak LSTM modelin gerçek değerlerin eğrisinin altında kaldığı görülmektedir.

Son olarak Şekil 4.20 ve Şekil 4.21, 2022 yılı için seçilen farklı mevsim günlerinin güneş ışıının tahmin grafiğini göstermektedir. Tüm mevsim günleri için hibrit ve SARIMA modeli gerçek güneş ışıını değerlerine yakın bir tahmin gerçekleştirmiştir. LSTM modeli ise ilkbahar, yaz ve kış günleri tahmini için belirgin bir sapma göstermiştir.

Geliştirilen hibrit model, güneş ışıının değerlerindeki ani düşüş ve yükselişleri, mevsimsel geçişleri, gece saatlerindeki kesintiyi etkili bir şekilde yakalamıştır. Hibrit modelin tahmin yeteneğinin sadece belirli bir zaman dilimi için değil tekrar eden dört mevsimi içeren dönemler için değerlendirilmesi model kararlılığı ve performansı hakkında bilgi sağlamıştır. Tanısal kontrol grafikleri ise veri genelleme ve veriler arasındaki ilişkiyi açıklayabilme yeteneği ile en uygun yaklaşımın önerilen hibrit model olduğunu ortaya koymaktadır.

5. TARTIŞMA ve SONUÇ

Güneş ışıını tahmini iklim deęişikliğine karşı önlem alınması dâhil yenilenebilir enerji kaynaklarının etkili bir şekilde kullanımı ve planlanması bakımından büyük önem arz etmektedir. Son yıllarda popüler hale gelen derin öğrenme tabanlı modeller sıklıkla tercih edilmesine rağmen, tahmin sürecinde tek bir yöntem kullanmak her zaman yeterli olmayabilir. Bu bağlamda gerçekleştirilen tez çalışmasında Afyonkarahisar ili için saatlik güneş ışıını tahmin modellemesinde, literatürde kullanılan doğrusal ve doğrusal olmayan yöntemler birleştirilerek hibrit bir yaklaşım geliştirilmiştir. Tez çalışmasında, girdi parametresi olarak Afyonkarahisar Meteoroloji Müdürlüğü'nden alınan 2018-2022 yılları arasına ait zaman serisi formunda saatlik güneş ışıını verileri kullanılmıştır. Orijinal güneş ışıını verileri üzerinde herhangi bir işlem yapılmadan ham veri olarak kullanılmıştır.

Önerilen hibrit yöntem, güneş ışıını zaman serisinin STL ile ayrıştırılma prensibine dayanmaktadır. Veriler arasındaki doğrusal ilişkiyi daha iyi açıklayabilen SARIMA ile doğrusal olmayan ilişkileri açıklama yeteneğine sahip LSTM yönteminin birleşimi şeklinde tasarlanmıştır. Bu sayede, veri içerisindeki hem doğrusal hem de doğrusal olmayan bileşenler, daha doğru tahmin edilmiştir. Önerilen hibrit modelin tüm zaman dilimindeki tahmin performansını ve kararlılığını değerlendirebilmek için verilere zaman serisi 10-Katlı CV tekniği uygulanmış ve model 17.06.2018 – 31.12.2024 tarihleri arası test edilmiştir. Ayrıca geliştirilen modelin farklı mevsim koşulları altında tahmin yeteneğini incelemek üzere test verisi içerisindeki zaman diliminden dört mevsimi temsil eden belirli günler seçilmiştir.

Hibrit model performans değerlendirme metrik sonuçlarına göre ortalama olarak %37,84 oranında RMSE değerini, %37,45 oranında NRMSE değerini, %34,03 oranında MAE değerini azaltmıştır. Korelasyon katsayısını ise %4,42 oranında iyileştirmiştir. Bulgulara göre tahmin performans başarısını sırası ile SARIMA ve LSTM modeli takip etmektedir. Farklı mevsimsel koşullara sahip günler için modellerin tahmin performansı değerlendirildiğinde aynı şekilde hibrit modelin tahmin doğruluğu daha yüksek elde edilmiştir. Çizelge 4.14, önerilen hibrit yaklaşımın literatürdeki diğer kısa vadeli güneş

ışınımı tahmin çalışmaları ile NRMSE ve R^2 metrikleri bakımından karşılaştırmasını sunmaktadır.

Çizelge 4.14 Literatürdeki güneş ışıınımlı çalışmaları ile mevcut çalışmanın karşılaştırılması

Çalışma	Yöntem	Çalışma Bölgesi	NRMSE (%)	R^2
Takilalte vd. (2022)	RF	Cezayir	26,50	0,675
Huang vd. (2021)	WPD-CNN-LSTM-MLP	Denver, ABD	23,91	0,985
Zang vd. (2020)	CNN – LSTM	Teksaş, ABD	28,41	0,951
Benali vd. (2019)	RF	Odeillo, Fransa	27,78	-
Ajith ve Ramon (2023)	MICNN-LSTM	Yeni Meksika, ABD	30,12	0,94
Myers vd. (2020)	Solis-Heliosat	Kumpula, Finlandiya	25,09	-
Huynh vd. (2021)	RLMD-SVR	Central Highlands, Vietnam	29	0,967
Guermouni vd. (2021)	ABC-LS-SVM	Gardaya, Cezayir	24,13	0,943
Tez Çalışması	STL-SARIMA-LSTM	Afyon, Türkiye	23,56	0,974

Takilalte vd. (2022), yaptıkları kısa vadeli güneş ışıınımlı tahmin çalışmasında giriş parametresi olarak sadece geçmiş güneş ışıınımlı değerlerini kullanmışlardır. Veri seti içerisinde gece saatleri çıkarılarak filtrelenmiştir. Huang vd. (2021) ise saatlik güneş ışıınımlı tahmini için önerdikleri hibrit modele girdi verisi olarak saatlik güneş ışıınımlı, sıcaklık, bağıl nem ve rüzgâr hızı parametrelerini kullanmışlardır. Zang vd. (2020), gerçekleştirdikleri çalışmada gece saatlerini dâhil etmeden saatlik güneş ışıınımlı, çiğ noktası sıcaklığı, güneş zenit açısı, rüzgâr hızı, rüzgâr yönü, bağıl nem parametrelerini giriş verisi olarak kullanmışlardır. Önerdikleri CNN-LSTM hibrit modelin mevsimsel performansını değerlendirmek için test aralığı içerisinde dört mevsimsel gün seçmişlerdir. Benali vd. (2019), çalışmada kullandıkları saatlik güneş ışıınımlı verilerini makine öğrenim sürecine dâhil etmeden önce temizleme ve filtreleme işlemi uygulamışlardır. Gece saati ve aykırı verileri çıkardıktan sonra gün doğumu ve gün

batımına yakın güneş ışınım verilerini de kaldırmışlardır. Ajith ve Ramon (2023) yaptıkları saatlik tahmin çalışmasında girdi verisi olarak güneş ışınımı zaman serisi ve gökyüzü görüntülerini kullanmışlardır. Eğitime girmeden önce girdi verilerine gürültü giderme ve kenar yumuşatma filtreleme işlemleri uygulamışlardır. Myers vd. (2020) daha doğru bir tahmin elde edebilmek için güneş zenit açısının 80° veya altında olduğu dönemleri dikkate almışlardır. Huynh vd. (2021), gerçekleştirdikleri çalışma için yalnızca gün ışığı saatlerinde elde edilen güneş ışınımı verilerini kullanmışlardır. 30 dakikalık zaman aralıkları ile oluşturulmuş zaman serisi için ön işlem yapılarak eksik veriler tamamlanmıştır. Guermouni vd. (2021), saatlik güneş ışınımı tahmini için sezgisel optimizasyon algoritması kullanmışlardır. Literatürdeki çalışmalar incelendiğinde mevcut çalışmanın ön işlemsiz ham veri kullanarak anlamlı ve yeterli doğrulukta tahmin gerçekleştirdiği görülmektedir. Tahmin çalışmasını etkileyen kısıtlamalar ve gelecek çalışmalar için yapılabilecek planlamalar aşağıda özetlenmiştir.

Mevcut çalışmada sadece güneş ışınım değerlerinden oluşturulan tek boyutlu zaman serisi kullanılmıştır. Ancak sıcaklık, nem ve bulut hareketi gibi meteorolojik faktörler güneş ışınımını tahminini etkileyen parametrelerdir. Ayrıca zaman serisi oluşturulurken ham veri kullanılması tercih edilmiş olup herhangi bir veri ön işlemi yapılmamıştır. Gece saatlerinde ölçüm alınamaması veya öngörülemeyen zaman noktalarında doğan aykırı değerler tahmin performansı üzerinde olumsuz etkilere neden olabilir. Ayrıca SARIMA ve LSTM modelleri için orijinal zaman serisi özelliğine göre belirlenen parametre değerleri hibrit model tasarımında da aynı kullanılmıştır.

Gelecek çalışmalar için diğer meteorolojik bilgilerinin eklenmesi ile girdi veri sayısının artırılması ve ham veriler üzerinde kalite kontrol tekniklerinin kullanılması düşünülmektedir. Ayrıca hibrit modelin parametrelerinin seçilmesinde orijinal zaman serisi yerine STL ile ayrıştırma sonucu elde edilen zaman serileri dikkate alınarak belirlenmesi planlanmaktadır. Son olarak önerilen STL tabanlı hibrit metot, farklı coğrafi koşullar altında güneş tahmini çalışmaları için farklı model birleşimleri ile geliştirilebilen ve ilerletilebilen bir yaklaşım olarak araştırmacılara fikir sunmaktadır.

6. KAYNAKLAR

- Abbasimehr H, Paki R, 2022, Improving time series forecasting using LSTM and attention models, *Journal of Ambient Intelligence and Humanized Computing*, 13(1), 673-691.
- Ağbulut Ü, Gürel A E, Biçen Y, 2021, Prediction of daily global solar radiation using different machine learning algorithms: Evaluation and comparison, *Renewable and Sustainable Energy Reviews*, 135, 110114.
- Ajith M, Martínez-Ramón M, 2023, Deep learning algorithms for very short term solar irradiance forecasting: A survey. *Renewable and Sustainable Energy Reviews*, 182, 113362.
- Akaike H, 1974, A new look at the statistical model identification, *IEEE transactions on automatic control*, 19(6), 716-723.
- Álvarez-Alvarado J M, Ríos-Moreno J G, Obregón-Biosca S A, Ronquillo-Lomelí G, Ventura-Ramos Jr E, Trejo-Perea M, 2021, Hybrid techniques to predict solar radiation using support vector machine and search optimization algorithms: a review, *Applied Sciences*, 11(3), 1044.
- Alrashidi M, Alrashidi M, Rahman S, 2021, Global solar radiation prediction: Application of novel hybrid data-driven model, *Applied Soft Computing*, 112, 107768.
- Antonopoulos V Z, Papamichail D M, Aschonitis V G, Antonopoulos A V, 2019, Solar radiation estimation methods using ANN and empirical models, *Computers and Electronics in Agriculture*, 160, 160-167.
- Arıman S, Taflan G Y, Çelik E, 2021, Samsun Bölgesi için Güneş Radyasyonunun Yapay Sinir Ağı ile Tahmini, *Avrupa Bilim ve Teknoloji Dergisi*, 25, 680-687.
- Arslan G, Bayhan B, Yaman K, Mersin/Türkiye için Ölçülen Global Güneş Işınımının Yapay Sinir Ağları ile Tahmin Edilmesi ve Yaygın Işınım Modelleri ile Karşılaştırılması, *Gazi University Journal of Science Part C: Design and Technology*, 7(1), 80-96.

- Arora I, Gambhir J, Kaur T, 2021, Data normalisation-based solar irradiance forecasting using artificial neural networks, *Arabian Journal for Science and Engineering*, 46, 1333-1343.
- Aslam M, Lee J M, Kim H S, Lee S J, Hong S, 2019, Deep learning models for long-term solar radiation forecasting considering microgrid installation: A comparative study, *Energies*, 13(1), 147.
- Ayko O, Keser S B, 2021, A comparison of machine learning algorithms for forecasting solar irradiance in Eskişehir Turkey, *International Journal of Applied Mathematics Electronics and Computers*, 9(4), 103-109.
- Bamisile O, Oluwasanmi A, Ejayi C, Yimen N, Obiora S, Huang Q, 2022, Comparison of machine learning and deep learning algorithms for hourly global/diffuse solar radiation predictions, *International Journal of Energy Research*, 46(8), 10052-10073.
- Belmahdi B, Louzazni M, Bouardi A E, 2020, A hybrid ARIMA–ANN method to forecast daily global solar radiation in three different cities in Morocco, *The European Physical Journal Plus*, 135, 1-23.
- Belmahdi B, Louzazni M, Marzband M, El Bouardi A, 2023, Global solar radiation forecasting based on hybrid model with combinations of meteorological parameters: Morocco case study, *Forecasting*, 5(1), 172-195.
- Belmahdi B, Louzazni M, El Bouardi A, 2022, Comparative optimization of global solar radiation forecasting using machine learning and time series models, *Environmental Science and Pollution Research*, 29(10), 14871-14888.
- Benali L, Notton G, Fouilloy A, Voyant C, Dizene R, 2019, Solar radiation forecasting using artificial neural network and random forest methods: Application to normal beam, horizontal diffuse and global components, *Renewable energy*, 132, 871-884.
- Bergmeir C, Hyndman R J, Koo B, 2018, A note on the validity of cross-validation for evaluating autoregressive time series prediction, *Computational Statistics & Data Analysis*, 120, 70-83.

- Bosch J L, Kleissl J, 2013, Cloud Motion Vectors From A Network of Ground Sensors in A Solar Power Plant, *Solar Energy*, 95, 13-20.
- Brahma B, Wadhvani R, 2020, Solar irradiance forecasting based on deep learning methodologies and multi-site data, *Symmetry*, 12(11), 1830.
- Caldas M, Alonso-Suárez R 2019, Very short-term solar irradiance forecast using all-sky imaging and real-time irradiance measurements, *Renewable energy*, 143, 1643-1658.
- Chaibi M, Benghoulam E M, Tarik L, Berrada M, Hmaidi A E, 2021, An interpretable machine learning model for daily global solar radiation prediction, *Energies*, 14(21), 7367.
- Chandola D, Gupta H, Tikkiwal V A, Bohra M K, 2020, Multi-step ahead forecasting of global solar radiation for arid zones using deep learning, *Procedia Computer Science*, 167, 626-635.
- Chatfield C, Xing H, 2019, *The analysis of time series: an introduction with R*. Chapman and hall/CRC.
- Chodakowska E, Nazarko J, Nazarko Ł, Rabayah H S, Abendeh R M, Alawneh R, 2023, Arima Models in Solar Radiation Forecasting in Different Geographic Locations, *Energies*, 16, 5029.
- Chu T P, Guo J H, Leu Y G, Chou L F, 2023, Estimation of solar irradiance and solar power based on all-sky images, *Solar Energy*, 249, 495-506.
- Cleveland R B, Cleveland W S, McRae J E, Terpenning I, 1990, STL: A seasonal-trend decomposition, *J. off. Stat*, 6(1), 3-73.
- Cleveland W S, 1979, Robust locally weighted regression and smoothing scatterplots, *Journal of the American statistical association*, 74(368), 829-836.
- Cleveland W S, Devlin S J, 1988, Locally weighted regression: an approach to regression analysis by local fitting, *Journal of the American statistical association*, 83(403), 596-610.
- Dabral P P, Murry M Z, 2017, Modelling and forecasting of rainfall time series using SARIMA, *Environmental Processes*, 4(2), 399-419.

- De O Jr S, Domingos S, De Mattos Neto S, De Oliveira J F, Siqueira H V, Barchi T M, vd., 2022, Solar Irradiance Forecasting Using Dynamic Ensemble Selection, *Applied Sciences*, 12(7), 2076-3417.
- Demir V, Citakoglu H, 2023, Forecasting of solar radiation using different machine learning approaches, *Neural Computing and Applications*, 35(1), 887-906.
- Diagne M, David M, Lauret P, Boland J, Schmutz N, 2013, Review of Solar Irradiance Forecasting Methods and A Proposition for Small-Scale Insular Grids, *Renewable and Sustainable Energy Reviews*, 27, 65-76.
- Dickey D A, Fuller W A, 1979, Distribution of the estimators for autoregressive time series with a unit root, *Journal of the American statistical association*, 74(366a), 427-431.
- Dissawa L H, Godaliyadda R I, Ekanayake P B, Agalgaonkar A P, Robinson D, Ekanayake J B, vd., 2021, Sky Image-Based Localized Short-Term Solar Irradiance Forecasting for Multiple PV Sites via Cloud Motion Tracking, *International Journal of Photoenergy*, 2021(1), 9973010.
- El Alani O, Abraim M, Ghennioui H, Ghennioui A, Ikenbi I, Dahr F E, 2021, Short term solar irradiance forecasting using sky images based on a hybrid CNN–MLP model, *Energy Reports*, 7, 888-900.
- El Alani O, Hajjaj C, Ghennioui H, Ghennioui A, Blanc P, Saint-Drenan Y M, vd., 2023, Performance assessment of SARIMA MLP and LSTM models for short-term solar irradiance prediction under different climates in Morocco, *International Journal of Ambient Energy*, 44(1), 334-350.
- Fan J, Wang X, Wu L, Zhou H, Zhang F, Yu X, vd., 2018, Comparison of Support Vector Machine and Extreme Gradient Boosting for predicting daily global solar radiation using temperature and precipitation in humid subtropical climates: A case study in China, *Energy conversion and management*, 164, 102-111.
- Fan J, Wu L, Ma X, Zhou H, Zhang F, 2020, Hybrid support vector machines with heuristic algorithms for prediction of daily diffuse solar radiation in air-polluted regions, *Renewable Energy*, 145, 2034-2045.

- Fu H Z, Waltman L, 2022, A Large-Scale Bibliometric Analysis of Global Climate Change Research Between 2001 and 2018, *Climatic Change*, 170, 36.
- Guermoui M, Gairaa K, Boland J, Arrif T, 2021, A novel hybrid model for solar radiation forecasting using support vector machine and bee colony optimization algorithm: review and case study, *Journal of Solar Energy Engineering*, 143(2), 020801.
- Hamilton J D, 2020, *Time series analysis*, Princeton university press.
- Haider S A, Sajid M, Sajid H, Uddin E, Ayaz Y, 2022, Deep learning and statistical methods for short-and long-term solar irradiance forecasting for Islamabad, *Renewable Energy*, 198, 51-60.
- Halabi L M, Mekhilef S, Hossain M, 2018, Performance evaluation of hybrid adaptive neuro-fuzzy inference system models for predicting monthly global solar radiation, *Applied energy*, 213, 247-261.
- Hastie T, Tibshirani R, Friedman J, Franklin J, 2005, The elements of statistical learning: data mining, inference and prediction, *The Mathematical Intelligencer*, 27(2), 83-85.
- Huang J, Rikus L J, Qin Y, Katzfey J, 2018, Assessing model performance of daily solar irradiance forecasts over Australia, *Solar Energy*, 176, 615-626.
- Huang X, Li Q, Tai Y, Chen Z, Zhang J, Shi J, vd., 2021, Hybrid deep neural model for hourly solar irradiance forecasting, *Renewable Energy*, 171, 1041-1060.
- Huang X, Zhang C, Li Q, Tai Y, Gao B, Shi J, 2020, A Comparison of Hour-Ahead Solar Irradiance Forecasting Models Based on LSTM Network. *Mathematical Problems in Engineering*, 2020, 4251517.
- Huber P J, 1992, Robust estimation of a location parameter. In *Breakthroughs in statistics: Methodology and distribution*, 492-518, New York.
- Hu Y, Huber A, Anumula J, Liu S C, 2018, Overcoming the vanishing gradient problem in plain recurrent networks.
- Huynh A N L, Deo R C, Ali M, Abdulla S, Raj N, 2021, Novel short-term solar radiation hybrid model: Long short-term memory network integrated with robust local mean decomposition, *Applied Energy*, 298, 117193.

- Hochreiter S, 1997, Long Short-term Memory, Neural Computation MIT-Press.
- Hou M, Zhang T, Weng F, Ali M, Al-Ansari N, Yaseen Z M, 2018, Global solar radiation prediction using hybrid online sequential extreme learning machine model, *Energies*, 11(12), 3415.
- Jaihuni M, Basak J K, Khan F, Okyere F G, Arulmozhi E, Bhujel A, vd., 2020, A partially amended hybrid bi-GRU-ARIMA model (PAHM) for predicting solar irradiance in short and very-short terms, *Energies*, 13(2), 435.
- Kahan A, 2019, EIA Projects Nearly 50% Increase in World Energy Usage by 2050 Led by Growth in Asia, EIA
- Kallio-Myers V, Riihelä A, Lahtinen P, Lindfors A, 2020, Global horizontal irradiance forecast for Finland based on geostationary weather satellite data, *Solar Energy*, 198, 68-80.
- Kara A, 2019, Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini, *Gazi University Journal of Science Part C: Design and Technology*, 7(4), 882-892.
- Kohavi R, 1995, A study of cross-validation and bootstrap for accuracy estimation and model selection, Morgan Kaufman Publishing.
- Kumar D S, Yagli G M, Kashyap M, Srinivasan D, 2020, Solar Irradiance Resource and Forecasting: A Comprehensive Review, *IET Renewable Power Generation*, 14(10), 1641-1656.
- Kumari P, Toshniwal D, 2021, Long short term memory–convolutional neural network based deep hybrid approach for solar irradiance forecasting, *Applied Energy*, 295, 117061.
- Kurniawan A, Koenhardono E S, Kusuma I R, Prananda J, Sarwito S, Masroeri A A, 2021, An Estimation of hourly average solar radiation using artificial neural network in the city of Surabaya, In *IOP Conference Series: Materials Science and Engineering*, 1052.

- Kwiatkowski D, Phillips P C, Schmidt P, Shin Y, 1992, Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root, *Journal of econometrics*, 54(1-3), 159-178.
- Li D H, Chen W, Li S, Lou S, 2019, Estimation of hourly global solar radiation using Multivariate Adaptive Regression Spline (MARS)—A case study of Hong Kong, *Energy*, 186, 115857.
- Liu J, Zang H, Ding T, Cheng L, Wei Z, Sun G, 2023, Harvesting spatiotemporal correlation from sky image sequence to improve ultra-short-term solar irradiance forecasting, *Renewable Energy*, 209, 619-631.
- Logothetis S A, Salamalikis V, Wilbert S, Remun J, Zarzalejo L F, Xie Y, vd., 2022, Benchmarking of solar irradiance nowcast performance derived from all-sky imagers, *Renewable Energy*, 199, 246-261.
- Lorenz E, Kühnert J, Heinemann D, 2012, Short term forecasting of solar irradiance by combining satellite data and numerical weather predictions, In *Proceedings of the 27th European PV Solar Energy Conference*, 2428p, Frankfurt.
- Marzouq M, Bounoua Z, Mechaqrane A, Fadili H E, Lakhliai Z, Zenkour K, 2018, ANN-based modelling and prediction of daily global solar irradiation using commonly measured meteorological parameters, In *IOP Conference Series: Earth and Environmental Science*, 161.
- Marzouq M, El Fadili H, Zenkour K, Lakhliai Z, Amouzg M, 2020, Short term solar irradiance forecasting via a novel evolutionary multi-model framework and performance assessment for sites with no solar irradiance data, *Renewable Energy*, 157, 214-231.
- Mishra S, Palanisamy P, 2019, An integrated multi-time-scale modeling for solar irradiance forecasting using deep learning.
- Mukhoty B P, Maurya V, Shukla S K, 2019, Sequence to sequence deep learning models for solar irradiation forecasting, In *2019 IEEE Milan PowerTech*, 1-6.
- Manandhar P, Temimi M, Aung Z, 2023, Short-term solar radiation forecast using total sky imager via transfer learning, *Energy Reports*, 9, 819-828.

- Mishra M, Mahajan P, Garg R, 2022, Comparison and Analysis of Solar Irradiance Forecasting Techniques, In 2022 IEEE Delhi Section Conference, 1-5, New Delhi.
- Mohamed Z E, 2019, Using the artificial neural networks for prediction and validating solar radiation, Journal of the Egyptian Mathematical Society, 27(1), 1-13.
- Mouhamet D, Tommy A, Primerose A, Laurent L, 2018, Improving the Heliosat-2 method for surface solar irradiation estimation under cloudy sky areas, Solar Energy, 169, 565-576.
- Muhammad A, Lee J M, Hong S W, Lee S J, Lee E H, 2019, Deep learning application in power system with a case study on solar irradiation forecasting, In 2019 International Conference on Artificial Intelligence in Information and Communication, 275-279.
- Ongsulee P, 2017, Artificial intelligence, machine learning and deep learning, In 2017 15th international conference on ICT and knowledge engineering, 1-6.
- Paletta Q, Arbod G, Lasenby J, 2023, Omnivision forecasting: Combining satellite and sky images for improved deterministic and probabilistic intra-hour solar energy predictions, Applied Energy, 336, 120818.
- Paulescu M, Paulescu E, 2019, Short-term forecasting of solar irradiance, Renewable energy, 143, 985-994.
- Paulescu E, Paulescu M, 2023, Minute-Scale Models for the Diffuse Fraction of Global Solar Radiation Balanced between Accuracy and Accessibility, Applied Sciences, 13(11), 6558.
- Pedro H T, Coimbra C F, David M, Lauret P, 2018, Assessment of machine learning techniques for deterministic and probabilistic intra-hour solar forecasts. Renewable Energy, 123, 191-203.
- Polat E, Kahraman S, 2021, Antroposen Çağı'nda Pandemi ve Kentlerin Durumu. Antropoloji, 41, 21–31.
- Qazi A, Fayaz H, Wadi A, Raj R G, Rahim N A, Khan W A, 2015, The artificial neural network for solar radiation prediction and designing solar systems: a systematic literature review, Journal of cleaner production, 104, 1-12.

- Qing X, Niu Y, 2018, Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM, *Energy*, 148, 461-468.
- Rumelhart D E, Hinton G E, Williams R J, 1986, Learning representations by back-propagating errors, *nature*, 323(6088), 533-536.
- Ryabushev Y A, 2022, Solar Energy as Alternative Energy Source: Advantages and Disadvantages.
- Sansa I, Boussaada Z, Mazigh M, Bellaaj N M, 2020, Solar radiation prediction for a winter day using ARMA model, In 2020 6th IEEE International Energy Conference, 326-330.
- Schwarz G, 1978, Estimating the dimension of a model, *The annals of statistics*, 461-464.
- Shadab A, Ahmad S, Said S, 2020, Spatial forecasting of solar radiation using ARIMA model, *Remote Sensing Applications: Society and Environment*, 20, 100427.
- Shadab A, Said S, Ahmad S, 2019, Box–Jenkins multiplicative ARIMA modeling for prediction of solar radiation: a case study, *International Journal of Energy and Water Resources*, 3, 305-318.
- Sharika W, Fernando L, Kanagasundaram A, Valluvan R, Kaneswaran A, 2018, Long-term solar irradiance forecasting approaches-a comparative study, In 2018 IEEE International Conference on Information and Automation for Sustainability, 1-6.
- Shuvho M B A, Chowdhury M A, Ahmed S, Kashem M A, 2019, Prediction of solar irradiation and performance evaluation of grid connected solar 80KWp PV plant in Bangladesh, *Energy Reports*, 5, 714-722.
- Si Z, Yu Y, Yang M, Li P, 2020, Hybrid solar forecasting method using satellite visible images and modified convolutional neural networks, *IEEE Transactions on Industry Applications*, 57(1), 5-16.
- Şahan M, 2021, Yapay sinir ağları ve Angström-Prescott denklemleri kullanılarak Gaziantep Antakya ve Kahramanmaraş için global güneş radyasyonu tahmini, *Süleyman Demirel University Faculty of Arts and Science Journal of Science*, 16(2), 368-384.

- Takilalte A, Harrouni S, Mora J, 2022, Forecasting global solar irradiance for various resolutions using time series models-case study: Algeria, Energy sources, part A: Recovery, utilization, and environmental effects, 44(1), 1-20.
- Wang F, Xuan Z, Zhen Z, Li Y, Li K, Zhao L, vd., 2020, A minutely solar irradiance forecasting method based on real-time sky image-irradiance mapping model, Energy Conversion and Management, 220, 113075.
- Wang P, Van Westrhenen R, Meirink J F, Van Der Veen S, Knap W, 2019, Surface Solar Radiation Forecasts by Advecting Cloud Physical Properties Derived From Meteosat Second Generation Observations, Solar Energy, 177, 47-58.
- Wentz V H, Maciel J N, Gimenez Ledesma J J, Ando Junior O H, 2022, Solar irradiance forecasting to short-term PV power: Accuracy comparison of ann and LSTM models, Energies, 15(7), 2457.
- Wu X, Zhen Z, Zhang J, Wang F, Xu F, Ren H, vd., 2024, Multidimensional Feature Extraction Based Minutely Solar Irradiance Forecasting Method on Using All-sky Images, IEEE Transactions on Industry Applications.
- Wojtkiewicz J, Hosseini M, Gottumukkala R, Chambers T L, 2019, Hour-ahead solar irradiance forecasting using multivariate gated recurrent units, Energies, 12(21), 4055.
- Xiao Y, Yin Y, 2019, Hybrid LSTM neural network for short-term traffic flow prediction, Information, 10(3), 105.
- Xie Y, Yang J, Sengupta M, Liu Y, Zhou X, 2022, Improving the prediction of DNI with physics-based representation of all-sky circumsolar radiation, Solar Energy, 231, 758-766.
- Verbois H, Huva R, Rusydi A, Walsh W, 2018, Solar irradiance forecasting in the tropics using numerical weather prediction and statistical learning, Solar Energy, 162, 265-277.
- Yang D, Wang W, Bright J M, Voyant C, Notton G, Zhang G, vd., 2022, Verifying operational intra-day solar forecasts from ECMWF and NOAA, Solar Energy, 236, 743-755.

- Yang L, Gao X, Li Z, Jia D, Jiang J, 2019, Nowcasting of Surface Solar Irradiance Using FengYun-4 Satellite Observations Over China, *Remote Sensing*, 11(17), 1984.
- Yan K, Shen H, Wang L, Zhou H, Xu M, Mo Y, 2020, Short-term solar irradiance forecasting based on a hybrid deep learning methodology, *Information*, 11(1), 32.
- Yao W, Zhang C, Hao H, Wang X, Li X, 2018, A support vector machine approach to estimate global solar radiation with the influence of fog and haze, *Renewable Energy*, 128, 155-162.
- Yu Y, Cao J, Zhu J, 2019, An LSTM short-term solar irradiance forecasting under complicated weather conditions, *IEEE Access*, 7, 145651-145666.
- Zang H, Liu L, Sun L, Cheng L, Wei Z, Sun G, 2020, Short-term global horizontal irradiance forecasting based on a hybrid CNN-LSTM model with spatiotemporal correlations, *Renewable Energy*, 160, 26-41.
- Zhang G, Yang D, Galanis G, Androulakis E, 2022, Solar forecasting with hourly updated numerical weather prediction, *Renewable and Sustainable Energy Reviews*, 154, 111768.
- Zhu L, Huang X, Zhang Z, Li C, Tai Y, 2025, A novel U-LSTM-AFT model for hourly solar irradiance forecasting, *Renewable Energy*, 238, 121955.

İnternet Kaynakları

- 1- <https://enerji.gov.tr/bilgi-merkezi-enerji-gunes>, 21.10.2024