

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**KISA DÖNEMLİ FOTOVOLTAİK GÜÇ TAHMİNİ İÇİN GELİŞTİRİLEN
YENİLİKÇİ BİR HİBRİT MODELİN ANALİZİ VE UYGULAMASI**

DOKTORA TEZİ

ALİ RİZA GÜN

TEZ DANIŞMANI
PROF. DR. MEHMET KURBAN

İKİNCİ TEZ DANIŞMANI
DOÇ. DR. EMRAH DOKUR

BİLECİK, 2023

10586448

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**KISA DÖNEMLİ FOTOVOLTAİK GÜÇ TAHMİNİ İÇİN GELİŞTİRİLEN
YENİLİKÇİ BİR HİBRİT MODELİN ANALİZİ VE UYGULAMASI**

DOKTORA TEZİ

ALİ RİZA GÜN

TEZ DANIŞMANI
PROF. DR. MEHMET KURBAN

İKİNCİ TEZ DANIŞMANI
DOÇ. DR. EMRAH DOKUR

BİLECİK, 2023

10586448

BEYAN

“ Kısa Dönemli Fotovoltaik Güç Tahmini İçin Geliştirilen Yenilikçi Bir Hibrit Modelin Analizi ve Uygulaması” adlı doktora tezinin hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.			
DESTEK ALINMIŞTIR		☐	DESTEK ALINMAMIŞTIR
☒			
Destek alındı ise;			
Destekleyen Kurum:			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)	☐		
2- TÜBİTAK	☐		
3- Diğer:	☐		
ETİK KURUL Onayı ☐			
ETİK KURUL karar tarih/sayı			

Ali Rıza GÜN

Tarih

.....

İmza

.....

ÖNSÖZ

Lisansüstü eğitimim boyunca katkılarını esirgemeyen danışman hocam Prof.Dr. Mehmet KURBAN'a, tez çalışmamın tüm aşamalarında ilgisiyle ve değerli katkılarıyla desteğini hiçbir zaman esirgemeyen ikinci Tez Danışmanım Doç. Dr. Emrah DOKUR'a, tez çalışmam boyunca deneyimlerini paylaşarak çalışmalarına yön veren tez izleme komitesi üyesi hocalarım Prof. Dr. Uğur YÜZGEÇ, Prof. Dr. Yüksel OĞUZ'a ve desteğini her zaman hissettiğim arkadaşım Dr. Öğr. Üyesi Telat TÜRKYILMAZ'a katkı ve emekleri için teşekkürlerimi sunarım.

Ayrıca desteklerini hiçbir zaman esirgemeyen tüm aileme, özellikle eşim ve çocuklarıma çok teşekkür ederim.

Ali Rıza GÜN

2023

ÖZET

KISA DÖNEMLİ FOTOVOLTAİK GÜÇ TAHMİNİ İÇİN GELİŞTİRİLEN YENİLİKÇİ BİR HİBRİT MODELİN ANALİZİ VE UYGULAMASI

Günümüzde hızla artan enerji ihtiyacına paralel olarak üretilen enerjinin temiz ve sürdürülebilir olması mevcut ve gelecek nesiller adına büyük öneme sahiptir. Bu kapsamda yenilenebilir enerji kaynaklarının kullanımı çevre bilincine ve sürdürülebilir kalkınma politikasına katkı sağlamaktadır. Yenilenebilir enerji kaynaklarının en önemlilerinden biri olan güneş enerjisinin kullanımında bu alanda hızla yaygınlaşmaktadır. Fotovoltaik panellerden (PV) elde edilen enerjinin şebekeye entegrasyonunda, güç sistemlerinin güvenilirliği ve istikrarı açısından bu sistemlerden elde edilecek olan enerjinin tahmin edilmesi büyük öneme sahiptir. Ancak güneş ışınımının aralıklı doğasının etkisi, doğru tahmin modellerinin geliştirilmesini zorlaştırmaktadır. Bu tez çalışması kısa dönemli güneş enerjisi güç tahmini için hibrit tahmin modeli analizi önermekte ve farklı ayrıştırma metotlarının performansını analiz etmektedir. Bu kapsamda BŞEÜ yenilenebilir enerji laboratuvarından 2021 yılından itibaren alınan veriler kullanılmıştır. Tez çalışmasının ilk aşamasında Görgül Kip Ayrışımı (Empirical Mode Decomposition, EMD), Topluluk Görgül Kip Ayrışımı,(Ensemble Empirical Mode Decomposition, EEMD), Geliştirilmiş Ampirik Mod Ayrıştırma,(Improved Empirical Mode Decomposition, IEMD), Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayrışımı,(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN) ve Sürü Ayrıştırma,(Swarm Decomposition, SWD) gibi literatürde kullanılan güncel ve yenilikçi ayrıştırma modellerinin performansı çok katmanlı ağ (Multi-Layer Perceptron, MLP) yapılarıyla ayrı ayrı mevsimsel olarak analiz edilmiş ve karşılaştırmalı olarak sonuçları sunulmuştur. Tezin ikinci aşamasında ise CEEMDAN yaklaşımı ile Kernel-ELM modeli hibrit olarak önerilmiş bu kapsamda elde edilen veriler ayrıştırma adımıyla CEEMDAN ile alt bileşenlerine ayrıştırılmıştır. Ayrıştırma adımıyla birlikte elde edilen daha durağan veriler ile tahmin modeline uygulanan alt bileşenler ile daha hassas doğrulukta kısa dönemli tahmin sonucu elde edilmiştir. Önerilen modelin performansı farklı hata performans metrikleri ile karşılaştırmalı olarak sunulmuştur. Bu kapsamda farklı ayrıştırma metodu içeren hibrit modeller ve derin öğrenme tabanlı model ile önerilen model karşılaştırılarak üstünlüğü ele alınmıştır. Kök ortalama kare hatası değeri dikkate alındığında tüm mevsimsel alınan aylar bazında önerilen hibrit model en yakın başarımları gösteren modele göre %22,69 ile %44,56 arasında model başarımlarını artırmıştır. Buna ek olarak Taylor Diyagramı ile de modellerin performansı son adımda istatistiksel olarak karşılaştırmalı olarak sunulmuştur. Tüm yapılan

analizler sonucunda yenilikçi bir yaklaşım olarak önerilen CEEMDAN-Kernel-ELM yaklaşımının kısa dönemli güneş enerjisi tahmini için diğer konvansiyonel hibrit modellere ve derin öğrenme tabanlı modellere göre daha iyi sonuç verdiği gözlemlenmiştir.

Anahtar Kelimeler: Ayırıştırma, ELM, Güneş Enerjisi, Hibrit Model, Tahmin.



ABSTRACT

APPLICATION AND ANALYSIS OF INNOVATIVE HYBRID MODEL FOR SHORT-TERM PHOTOVOLTAIC POWER FORECASTING

In today's era of surging energy demand, it is imperative for current and future generations that energy production is both clean and sustainable. Embracing renewable energy resources aligns with environmental awareness and sustainable development goals. Among these resources, solar energy stands out as a rapidly expanding source. Integrating energy generated from photovoltaic panels (PV) into the power grid necessitates accurate energy estimation to ensure grid reliability and stability. However, the intermittent nature of solar radiation presents challenges for precise prediction models. This thesis introduces a hybrid forecasting model for short-term solar energy power prediction and evaluates various decomposition methods. Utilizing data from the BSEU renewable energy laboratory up to 2021, we first assess the performance of existing decomposition models, including EMD, EEMD, IEMD, CEEMDAN, and SWD, when combined with multi-layer neural network (MLP) structures. In the second phase, we propose a hybrid approach combining the Kernel-ELM model with CEEMDAN. We decompose the data into its subcomponents using CEEMDAN, resulting in more stable data for our forecasting model. This approach yields short-term forecasts with greater accuracy. We compare the performance of our proposed model with different error metrics and discuss its superiority over conventional hybrid and deep learning-based models. In terms of the Root Mean Square Error performance metric, the proposed hybrid model decreased performance ranging from 22.69% to 44.56% when compared to the highest model performance, across all seasonal months. Our results demonstrate that the CEEMDAN-Kernel-ELM approach outperforms other hybrid and deep learning-based models in short-term solar energy forecasting, as confirmed by statistical analysis and the Taylor Diagram.

Keywords: Decomposition, ELM, Solar Energy, Hybrid Model, Forecasting.

İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	i
ÖZET.....	ii
ABSTRACT	iv
İÇİNDEKİLER.....	v
TABLolar LİSTESİ.....	vii
ŞEKİLLER LİSTESİ.....	viii
KISALTMALAR LİSTESİ.....	x
1. GİRİŞ.....	1
1.1. Literatür Araştırması.....	5
2. GÜNEŞ ENERJİSİ.....	11
2.1. Türkiye’de Güneş Enerjisi Potansiyeli.....	16
2.2. Fotovoltaik Paneller ile Elektrik Enerjisi Üretimi	19
3. METODOLOJİ	21
3.1. Veri Ayırıştırma Metotları	23
3.2. Görgül Kip Ayırışımı (Empirical Mode Decomposition, EMD)	24
3.3. Topluluk Görgül Kip Ayırıştırması (Ensemble Empirical Mode decomposition, EEMD).....	25
3.4. Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayırıştırması (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise CEEMDAN).....	26
3.5. Sürü Ayırıştırma (Swarm Decomposition, SWD)	27
3.6. Yapay Zeka Tabanlı Tahmin Modelleri.....	28
3.6.1. Çok Katmanlı Algılayıcı (Multilayer Perceptron, MLP)	28
3.6.2. Kernel Tabanlı Aşırı Öğrenme Makinesi (KELM).....	31
4. UYGULAMA	34
4.1. Sistem Altyapısı ve Veri Seti Elde Edilmesi.....	34
4.2. Mevsimsel Bazlı Veri Analizleri.....	43
4.2.1. MLP Tabanlı Tahmin Analizleri ve Sonuçları.....	43
4.2.2. Kernel ELM tabanlı Hibrit Tahmin Model Sonuçları ve Analizleri.....	54

5. SONUÇLAR VE ÖNERİLER.....	60
KAYNAKÇA	61



TABLÖLER LİSTESİ

	Sayfa
Tablo 2.1. Avrupa Birliği (AB) ülkelerinin birincil enerji tüketim değerleri.....	12
Tablo 2.2. Dünya yenilenebilir enerji kapasiteleri (GW).	12
Tablo 2.3. 2018–2021 (TWh) için yenilenebilir kaynaklardan elektrik üretimi.	12
Tablo 4.1. Ocak Ayı Tüm Hibrit Modellerin Karşılaştırmalı Hata Performans Metrikleri Sonuçları.....	51
Tablo 4.2. Nisan Ayı Tüm Hibrit Modellerin Karşılaştırmalı Hata Performans Metrikleri Sonuçları.....	51
Tablo 4.3. Temmuz Ayı Tüm Hibrit Modellerin Karşılaştırmalı Hata Performans Metrikleri Sonuçları.....	52
Tablo 4.4. Eylül Ayı Tüm Hibrit Modellerin Karşılaştırmalı Hata Performans Metrikleri Sonuçları.....	52
Tablo 4.5. Güneş Enerjisi Veri Setleri İçin Önerilen Modelin Tahmin Sonuçlarının Karşılaştırmalı Analizi.....	57

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. Küresel temiz enerji yatırımlarındaki artış	3
Şekil 2.1. Yıllara göre dünya yenilenebilir enerji yatırımı (milyar \$)	13
Şekil 2.2. 2027’de yenilenebilir enerjide beklenen artış	13
Şekil 2.3. Yakıta Göre Birincil Enerji Tüketimi	14
Şekil 2.4. Dünyanın enerji ihtiyacı fosil yakıtlı enerji kaynağı arzı ve güneş enerjisinin karşılaştırılması.....	15
Şekil 2.5. Meteorolojik şartlara göre güneş enerjisinin Dünya’ya ulaşma miktarı	16
Şekil 2.6. Dünya’nın güneş enerjisi potansiyel haritası	16
Şekil 2.7. Türkiye’nin yıllık güneş ışıınımı haritası.....	17
Şekil 2.8. Türkiye’nin aylık ortalama küresel radyasyon dağılımı	17
Şekil 2.9. Türkiye’nin Haziran 2022 sonu itibariyle güneş enerjisine dayalı elektrik kurulu gücü	18
Şekil 2.10. 2010 ve 2022 yılları arasındaki enerji üretim ve 2026 hedef değerleri	18
Şekil 2.11. Ülkemizde alana göre yılbaşına PV yapısına göre üretilebilecek enerji değişimi Tipi- Alan-Üretilebilecek Enerji (KWh-Yıl).....	20
Şekil 3.1. İki yaklaşımla PV güç tahmini oluşturmak için gerekli girdileri ve genel adımlar .	22
Şekil 3.2. Ayırıştırma tabanlı modellerin yapıları.....	23
Şekil 3.3. EEMD Akış Şeması	26
Şekil 3.4. MLP’nin genel yapısı.....	29
Şekil 3.5. MLP sıklıkla kullanılan bazı aktivasyon fonksiyonları a)Sigmoid, b)Hiperbolik- Tanjant, c) Doğrusal d)Adım aktivasyon fonksiyonları.	30
Şekil 3.6. ELM'nin Temel Yapısı.....	31
Şekil 4.1. BŞEÜ Yenilenebilir Enerji Laboratuvarı.....	34
Şekil 4.2. Enerji panosu	35
Şekil 4.3. Çift yönlü sayaç panosu	36

Şekil 4.4. Depolama birimleri (a)Ultra Kapasitörler (b) Batarya Grubu.	37
Şekil 4.5. Üç fazlı invertör montaj görüntüsü, devre şeması ve verimlilik grafiği	38
Şekil 4.6. Devreye alınan uzaktan erişim izleme sistemi.....	39
Şekil 4.7. Arayüzdeki diğer sistem eleman bileşenlerinin değerleri.....	39
Şekil 4.8. Sistemden elde edilen ön işlemez 5 dakikalık örnek verilere ilişkin toplam çıktı görüntüsü	40
Şekil 4.9. Ocak-Eylül 2021 tarihleri arasında 5'er dakikalık zaman ufku için izlenen veri seti ve mevsimlere göre değişimleri.	41
Şekil 4.10. Tez çalışmasında kullanılan kaydırmalı pencereleme tekniği.	42
Şekil 4.11. Ocak ayı için EMD tabanlı ayrıştırma sonuçları	44
Şekil 4.12. Nisan ayı için EEMD tabanlı ayrıştırma sonuçları	45
Şekil 4.13. Temmuz ayı için CEEMDAN tabanlı ayrıştırma sonuçları.....	46
Şekil 4.14. Eylül ayı için SWD tabanlı ayrıştırma	47
Şekil 4.15. Ocak ayı zaman serisine ilişkin karşılaştırmalı tahmin sonuçları.....	48
Şekil 4.16. Temmuz ayı zaman serisine ilişkin karşılaştırmalı tahmin sonuçları	49
Şekil 4.17. Temmuz ayı zaman serisine ilişkin karşılaştırmalı tahmin sonuçları	53
Şekil 4.18. Önerilen modelin akış şeması.	54
Şekil 4.19. Temmuz zaman serisi için test sonuçlarının tahmin edilmesi	56
Şekil 4.20. Güneş verileri tahmin modellerinin Taylor diyagramı.	59

KISALTMALAR LİSTESİ

AB : European Union (Avrupa Birliği)

AC : Alternative Current (Alternatif Akım)

AI : Artificial Intelligence (Yapay Zeka)

ANN : Artificial Neural Network (Yapay Sinir Ağı)

ARIMA : Auto Regressive Integrated Moving Average (Otomatik Regresyonlu Entegre Hareketli Ortalama)

ARMA : Autoregressive Moving Average (Oto regresif Hareketli Ortalama)

CEEMD : Complementary Ensemble Empirical Mode Decomposition (Tamamlayıcı Topluluk Ampirik Mod Ayrıştırma)

CEEMDAN : Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayrışımı)

CNN : Cellular Neural Network (Hücresel Sinir Ağı)

CNN1D : One-Dimensional Conventional Neural Network (Tek Boyutlu Konvansiyonel Sinir Ağı)

DBN : Dynamic Bayesian Network (Dinamik Bayesian Ağı)

DC : Direct Current (Doğru Akım)

DL : Deep Learning (Derin Öğrenme)

DLNN : Deep Learning Neural Network (Derin Öğrenme Sinir Ağı)

EEMD : Ensemble Empirical Mode Decomposition (Topluluk Görgül Kip Ayrışımı)

EİE : Elektrik İşleri Etüt İdaresi Genel Müdürlüğü

ELM : Extreme Learning Machine (Aşırı Öğrenme Makinesi)

EMD : Empirical Mode Decomposition (Görgül Kip Ayrışımı)

EWMA : Exponentially Weighted Moving Average (Üstel Ağırlıklı Hareketli Ortalama)

EWT : Empirical Wavelet Transform (Ampirik Dalgacık Dönüşümü)

FNN : Feed Forward Network (İleri Beslemeli Ağ)

GEPA : Güneş Enerjisi Potansiyel Atlası

GES : Güneş Enerji Santrali

GPR : Gaussian Process Regression (Gauss Süreci Regresyon)

GRU : Gated Repetitive Unit (Geçitli Tekrarlayan Birim)

GTOE : Gigatonne Equivalent Oil (Gigaton Eşdeğer Petrol)

IEMD : Improved Empirical Mode Decomposition (Geliştirilmiş Ampirik Mod Ayrıştırma)

IMF : Intrinsic Mode Function (İçsel Mod Fonksiyonunu)

KTS : Küresle Tahmin Sistemi

LM : Levenberg Marquardt

LSTM : Long Short Term Memory (Uzun Kısa Süreli Bellek)

MAE : Mean Absolute Error (Mutlak Hata)

MDLPF : Multi-Dimensional Linear Prediction Filter Models (Çok Boyutlu Doğrusal Tahmin Filtresi)

ML : Machine Learning (Makine Öğrenimi)

MLP : Multi-Layer Perceptron (Çok Katmanlı Algılayıcı)

MSE : Mean Squared Error (Ortalama Kare Hatası)

NWP : Numerical Weather Prediction (Sayısal Hava Tahmini)

PSO : Particle Swarm Optimization (Parçacık Sürü Optimizasyonu)

PV : Fotovoltaik

RMSD : Root Mean Square Deviation (Ortalama Kare Sapma Kökü)

RMSE : Root Mean Square Error (Kök Ortalama Kare Hatası)

RNN : Recurrent Neural Networks (Yinelenen Sinir Ağları)

SVR : Support Vector Regression (Destek Vektör Gerileme)

SWD : Swarm Decomposition (Sürü Ayırışması)

SWF : Sliding window filtering (Kayan Pencere Filtreleme)

SVM : Support Vector Machine (Destek Vektör Makinesi)

VMD : Variational Mode Decomposition (Varyasyonel Mod Ayırıştırma)

WD : Wavelet Decomposition (Dalgacık Ayırıştırma)

1. GİRİŞ

Günümüzde artan nüfus ve gelişen teknolojiye bağlı olarak küresel ısınma ve çevre kirliliği konusundaki endişeler sebebiyle enerjinin sürdürülebilir ve temiz kullanımına yönelik çalışmalar hızla önem kazanmaktadır. Doğada var olan enerji kaynaklarının etkin ve verimli kullanımı konusunda insanlar hayatlarını kolaylaştırmanın yollarını tarih boyunca aramışlardır. Geçmişten günümüze ateş ile ısınmış, yemeklerini pişirmiş, rüzgar ile gemileri hareket ettirerek su enerjisi ile de buğdaylarını öğütmüşlerdir. Buhar enerjisinin kullanımı ile birlikte ulaşım ve sanayide büyük gelişmeler gözlemlenmiştir. Ülkelerin ekonomik büyümeleri üretime, üretim ise enerjiye bağımlı olduğu açıktır. Bununla birlikte üretim maliyetlerindeki ana unsur enerji maliyetleri olduğu görülmektedir. Fosil enerjinin elde edilmesi işlenmesi, taşınması, depolanması ise enerji birim maliyetlerini arttırmaktadır. Maliyet kavramı ile birlikte bu konvansiyonel enerji kaynaklarının kısıtlılığı ve yerel noktalardaki çeşitliliği ülkelerin bu bölgelerde, savaşlarda dahil olmak üzere rekabetine neden olmuştur.

Sanayi devrimi ile birlikte artmaya başlayan kömür, petrol ve benzeri fosil yakıtların tüketimi, karbondioksit (CO₂) emisyonlarının büyük bölümünü oluşturmaktadır. 1751'den bu yana fosil yakıt tüketimi ve çimento üretiminden atmosfere 400 milyar tondan fazla karbon salınmış olup bu CO₂'nin yarısı 1980'lerin sonundan beri atmosfere bırakıldığı gözlemlenmiştir (Çağlar, 2020:1). Küresel ısınma ve çevre kirliliği konusundaki bu gibi endişeler sebebiyle Avrupa Birliği sera gazı emisyonlarını 2050 yılına kadar %80-95 oranında azaltmak için uzun vadeli bir plan geliştirmiştir (Dokur vd.,2022:1). Fosil yakıtlar gibi konvansiyonel enerji kaynaklarının kullanımı ile birlikte küresel ısınma ve çevre kirliliğini azaltmak için günümüzde yeni ve yenilenebilir enerji kaynaklarının kullanımı kilit rol oynamaktadır. 2030 yılına gelene kadar Avrupanın enerji ihtiyacının %32'sinin yenilenebilir enerjiden karşılanması öngörülmektedir (Lichtenegger vd, 2020:2).

Enerji sektörünün çevre üzerindeki olumsuz etkilerini azaltmanın yanı sıra, yenilenebilir enerji üretim teknolojileri yeni zenginlikler yaratmakta ve 21. yüzyıl için önemli istihdam yaratıcıları haline gelmektedir. Küresel enerji geçişi süresince istihdam yaratma, dünya çapında politika sonuçları olabilecek, keşfedilmesi gereken önemli bir husustur. Paris Anlaşması tarafından belirlenen hedeflere ulaşmak için 2050 yılına kadar dünyanın elektriğinin %100'ünü yenilenebilir kaynaklardan elde etmesini sağlayan yenilenebilir elektrik üretiminin hızlandırılmış alımının istihdam üzerindeki etkisine odaklanmaktadır. 2015'ten 2050'ye enerji geçişi sırasında güneş enerjisi, piller ve rüzgar enerjisi başlıca teknolojilerdir. Sonuçlar, küresel

bir enerji geişinin, d nyadaki ekonomilerin gelecekteki istikrarı ve b y mesi  zerinde genel olarak olumlu bir etkiye sahip olacaėını g stermektedir (Ram vd, 2020:1).


G  sistemlerinin y k talebinin b y k bir kısmı CO₂ emisyonuna neden olan ve sınırlı kaynaėa sahip konvansiyonel  retim santrallerinden saėlanması karřın yenilenebilir enerji kaynaklarının  retimdeki payı hızla artıř g stermektedir. K resel ısınma, kirlilik, enerji kıtlıėı, ekonomik politikalar da yenilenebilir enerji kaynaklarının kullanımını g n m zde pop ler hale getirmiřtir. D ř k bakım maliyeti, g neř ıřınımının doėal mevcudiyeti, g neř enerjisi  retim sistemlerinin yenilenebilir enerji kaynakları arasındaki payını  nemli  l de artırmıřtır (G n vd, 2023:1).

D nya genelinde řebeke baėlantılı g neř enerjisi santrallerinin kurulu g  kapasitesi 2020 yılı sonunda 707 495 MW'a ulařırken,  in 253 834 MW kurulu g  kapasitesi ile bu alanda  nc  durumdadır (Liu vd, 2021:3). T rkiye ise 2023 hedefleri doėrultusunda g neř enerji santrallerinin kurulu g teki payını 300 000 MW seviyesine getirmeyi hedeflemiřtir (Melikoėlu, 2016:12). Y kselen emtia fiyatları nedeniyle mevcut y ksek yatırım maliyetlerine raėmen, řebeke  leėinde g neř enerjisi d nya apındaki  lkelerin  nemli bir oėunluėunda yeni elektrik  retilimi iin en az maliyetli seenektir. Binalardaki atı g neř enerjisi gibi daėıtılmıř g neř enerjisi PV'si de, daha y ksek perakende elektrik fiyatları ve t keticilerin enerji faturalarında tasarruf etmelerine yardımcı olmak iin artan politika desteėinin bir sonucu olarak daha hızlı b y mektedir. G neř enerjisi PV teknolojileri bug n 2050'ye Kadar Net Sıfır Emisyon (NSE) Senaryosu ile yola ıkan tek yenilenebilir enerji teknolojisi olduėu g r lmektedir. Uluslararası Enerji Ajansı (IEA) 2022'de g neř, r zgar, su, jeotermal ve okyanus kaynaklı yenilenebilir enerji arzı %8'e yakın arttıėı bu da bu teknolojilerin toplam k resel enerji arzındaki payının yaklaşık y zde 0,4 artarak %5,5'e ulařtıėı g r lmektedir. 2022'de modern biyoenerjinin payı 0,2 puan artarak %6,8'e ulařmıřtır. 2022'de yenilenebilir elektrik kapasitesindeki rekor artıřlar ve hidroelektrik mevcudiyetindeki artıř, biyoenerji dıřı yenilenebilir enerji kaynaklarının tarihteki en y ksek ikinci pay artıřına ulařmasını saėlamıřtır (IEA, 2023:1).

 lkemizin son yirmi yıldaki hızlı ekonomik ve n fus artıřı, yalnızca enerji talebini g l  bir řekilde artırmakla kalmadı, aynı zamanda ithalata baėımlılıėı da artırdıėı g zlemlenmiřtir.  lkemizdeki enerji talebindeki b y meyi rasyonelize etmek, t keticiler iin enerji fiyatlarını d ř rmek ve ithalat artıř hızını yavaşlatmak amacıyla enerji sistemini temiz ve s rd r lebilir enerji kaynaklarının kullanımı politikası ile yeniden yapılandırma yoluna gitmiřtir (IEA, 2023:1).

Türkiye, petrol ve gaz ithalatına olan yüksek bağımlılığı nedeniyle, enerji stratejisinin temel direklerinden biri olarak enerji arz güvenliğini önceliklendirmiştir. Politika, yerel petrol ve gaz arama ve üretimini artırmayı, petrol ve gaz tedarik kaynaklarını ve ilgili altyapıyı çeşitlendirmeyi, yenilenebilir enerji üretimini artırmayı ve enerji verimliliğini iyileştirmeyi içermektedir. Türkiye, son on yılda enerji karışımında önemli bir çeşitlilik gördü. Özellikle yenilenebilir enerji, son on yılda yenilenebilir elektrik üretiminin üç kat artmasıyla etkileyici bir büyüme kaydetti (IEA, 2023:2).

IEA Dünya Enerji Yatırımı 2023 raporuna göre, küresel enerji krizinin tetiklediği satın alına bilirlilik ve güvenlik endişeleri daha sürdürülebilir seçeneklerin arkasındaki ivmeyi güçlendirdiğinden, temiz enerji teknolojilerine yapılan yatırım, fosil yakıtlara yapılan harcamaları önemli ölçüde geride bırakmıştır. Yıllık temiz enerji yatırımının, aynı dönemde fosil yakıt yatırımındaki %15'lik artışa kıyasla, yenilenebilir enerji kaynakları ve elektrikli araçlar sayesinde 2021 ile 2023 arasında %24 artması bekleniyor. Şekil 1.1.'de küresel temiz enerji yatırımlarındaki artış görülmektedir (IEA, 2023:3).



Şekil 1.1. Küresel temiz enerji yatırımlarındaki artış

Kaynak: (IEA, 2022)

Enerji arzının güvenilirliği, hizmet kalitesinin en önemli konularından biridir. Bir yandan, müşterilerin genellikle hizmet güvenilirliği ve fiyatı için farklı beklentileri var iken öte yandan, yük noktalarında farklı düzeyde güvenilirlik sağlamak, sistem operatörleri için bir zorluk haline gelmiştir (Akhavain, 2011:7).

Günümüzde bu hızlı kurulu güç kapasitesindeki artışa paralel olarak güneş enerji sistemlerinin güç sistemlerine entegrasyonu, bu enerji sistemlerinden elde edilecek olan gücün hassas bir doğrulukta tahminin gerekliliğini de beraberinde getirmiştir. Enerji piyasaları, şebeke

yönetim sistemleri, güç sistemlerinin güvenilirliği ve kararlılığı gibi çeşitli alanlarda; rüzgar, güneş gibi kesikli ve kaotik yapıdaki yenilenebilir enerji kaynaklarından elde edilecek olan enerjinin yüksek doğrulukta tahmini büyük önem taşımaktadır.

Çok kısa, kısa, orta ve uzun dönem olmak üzere dört farklı zaman ufku için araştırmalar bu alanda yapılmaktadır. Güç sistemi işletimi için karar vermede kısa vadeli tahmin önemli olmasına karşın, bakım ve planlama için orta ve uzun dönemli tahminler yapılmaktadır. Enerji depolama kontrolü, elektrik piyasası yönetimi açısından ise çok kısa dönemli tahmin yaklaşımları öne çıkmaktadır (Das, 2021:39).

Literatürde güneş enerji tahminine yönelik olan yaklaşımlar fiziksel ve istatistiksel metotlar olmak üzere iki ana başlık olmak üzere incelenir. Fiziksel yöntemler rüzgar, güneş, ışıınımı, sıcaklık, basınç vb. atmosferik verileri kullanarak PV güç üretiminin tahminini gerçekleştirirken, istatistiksel yöntemlerde ise PV sistemlerden alınan geçmiş güç verileri kullanılarak modellemeler yapılmaktadır. Fiziksel yöntemlerde farklı meteorolojik verilere olan bağımlılık bu veri setlerinde ki farklı zaman dilimlerinde oluşabilecek olası veri kayıpları durumlarına neden olabileceği dezavantaj oluştururken, bunun yanında büyük veri setlerinin yöntemlerdeki hesaplama hızlarını da etkilemesi ayrıca beklenebilir. Bu sebeple geçmiş PV verileriyle oluşturulacak yapay zeka (AI) tabanlı yaklaşımlar bu alanda kullanımı oldukça popüler hale gelmiştir. ARIMA gibi geleneksel zaman serisi analiz metotlarının aksine, SVM (Zeng, 2013:52).ELM (All-dahidi vd., 2018:11).MLP (Han vd., 2019:84), RBFNN (Huang vd.,2015:9), vb. yöntemlerin kullanımı durağan olmayan zaman serisi verilerini doğru bir şekilde tahmin edilebilmesinde başarı sağlamaktadır. Günümüzde hibrit akıllı yaklaşımların son dönemde bu alanda kullanımın oldukça popüler olduğu görülmektedir. Metasezgisel yaklaşımlar ile oluşturulan hibrit modellerin kullanımının yanı sıra ayırıştırma metotları ile de gerçekleştirilen yöntemlerde yer almaktadır. Araştırmacılar tarafından WT-PSO-SVM (Eseyevd., 2019:118), GA-SVM (Van Deventer vd., 2019:140), PSO-ELM (Behera vd., 2019:21), hibrit yaklaşımlarda meta-sezgisel yöntemlerin güneş enerjisi tahmininde önerilmiştir.

Son zamanlarda yapılan çalışmalarda güneş enerjisi tahmini için farklı doğrusal olmayan sinyal ayırıştırma metotlarının kullanıldığı hibrit yaklaşımlar popüler hale gelmiştir. Son yıllarda EMD-LSTM (Lin vd., 2020:1), MODWT-SARIMA-RVFL (Kushwaha vd., 2019:124), SWD-FNNN (Dokur, 2020:79),hibrit yaklaşımlarında ayırıştırma modellerinin kullanıldığı görülmektedir. 2021 yılında yayınlanan çalışmada Sohu vd., (Sahu vd, 2021:10), gelecek çalışma önerisi içerisinde ayırıştırma modellerinin kullanımının uygun olabileceğini

sunması bu alandaki çalışmaların hala popülerliğini ayrıca göstermektedir. Buna karşın bu sinyal ayrıştırma tekniklerinin aynı veri seti içerisinde ve aynı AI tekniği ile hibrit yapıdaki model analizlerinin detaylı sunulmadığı görülmektedir. EMD tabanlı farklı yaklaşımların kendi içinde karşılaştırıldığı hibrit yayınlar ele alınmışken buna ek olarak bu ayrıştırma metodlarının SWD ile karşılaştırıldığı bazı sınırlı çalışmalarda mevcuttur (Monjoly vd, 2017:119).

Güneş enerjisinin gün içerisinde değişken özellik göstermesi, bulutlanma ve diğer meteorolojik durumlar nedeni ile PV panellerden üretilen elektrik enerjisinin stabil olmamasına neden olmaktadır. Bu değişken durumlar PV panellerden üretilecek enerjinin önceden bilinmesi santral kurulumu, işletme ve bakım açısından büyük önem arz etmektedir. Araştırmacılar bu konuda farklı tahmin yöntemleri geliştirmişlerdir. Yapılan literatür çalışmalardan bazılarına ilişkin detaylar yıllara göre aşağıda verilmektedir.

1.1. Literatür Araştırması

Bacher ve Ark. (2009), çalışmalarında yalnızca gecikmeli PV değerlerine sahip AR, NWP'li LM ve NWP'li ARX ve gecikmeli P modeli önermişlerdir.

Hassanzadeh ve Ark. (2010), deterministik bir bileşenin ve bir Gauss gürültü sinyalinin ve Kalman filtrelemenin toplamı aracılığıyla GHI modellemesi ve GHI-P PV performans modeli önermişlerdir.

Lorenz ve Ark. (2011), PV güç tahmininde doğru sonuçlar elde etmek için temsili alt kümenin uygun şekilde seçilmesi fikrini vurgulamışlar ve coğrafi konumu (enlem) hesaba katan bir yükseltme tekniğini detaylandırmışlardır.

Al-Messabi vd. (2012), çalışmalarında giriş olarak yalnızca PV gerçek güç verilerini ve 80 dakikaya kadar gecikmeli güç değerlerini kullanarak 10 ve 60 dakika ilerisini tahmin etmek için dinamik sinir ağlarını kullanmışlardır.

Pedro ve Coimbra (2012), tarafından geliştirilen çalışma, tahmin tekniklerinin eksiksiz bir değerlendirmesini temsil etmektedir. Yalnızca geçmiş güç çıkışı kayıtlarını kullanarak ARIMA, k-NN, ANN ve GA-ANN'yi 1-2 saatlik tahmin ufukları için karşılaştırma yapmışlardır.

Mills vd. (2013) çalışmalarında Arizona'da güneş tahmininin ekonomik etkilerine odaklanan ilk çalışmalardan birini gerçekleştirmişlerdir. Tek bir güç sistemini analiz ederek istikrarı ve optimum taahhüdü korumak için gerekli rezervleri ve yenilenebilir enerjileri ve ekonomik durumları incelemişlerdir.

Monteiro ve Ark. (2013), çalışmalarında tarihsel benzerliğe dayalı bir model oluşturmuş ve nokta tahminini vermenin yanı sıra bununla ilişkili belirsizliği de göstermişlerdir. Güç çıkışını, incelenen tesisten olası tüm güç çıkışlarını kapsayacak şekilde farklı güç aralıklarında gruplamışlar, daha sonra, PV güç üretiminin her bir güç aralığına dahil edilmesinin gerçekleşme olasılığını gösteren sonuçları sunmuşlardır. Belirli bir saat için iki ardışık aralık olasılığın çoğunu topluyorsa, o nokta tahmininin belirsizliğinin düşük olduğunu belirtmişlerdir

Bosch ve Kleissl (2013), çalışmalarında bir PV tesisinde bulut hareket vektörleri ile ışıınım ve güç ölçümleri arasında bir ilişki kurmuşlardır.

Brancucci Martínez-Anido ve Ark. (2014), güneş enerjisi tahminlerinin %25 güneş enerjisi entegrasyonu temelinde iyileştirilmesinin etkisini göz önünde bulundurarak ekonomik çıkarımlara ilişkin araştırmalar yapmışlardır.

Almeida ve Ark. (2015), uygun bir eğitim veri setinin seçimi, geliştirilen modelin doğruluğu açısından çok önem arzettiğini ve nihai sonuçtaki girdi seti seçiminin ilişkisini incelemişlerdir.

Bessa ve Ark. (2015), tahmin için akıllı bir şebekede dağıtılmış PV sistemlerinin uzamsal-zamansal korelasyonlarını kullanmışlardır. Deterministik analizde (medyan değerden türetilen), 1 ile 6 saat arasındaki tahmin ufukları için sırasıyla %6,5 ve %3,3 arasında değişen iyileştirmeler elde ederken, olasılık analizinde 4 ile 6 saat arasındaki süreler için negatif CRPS iyileştirmeleri elde etmişlerdir.

Rana ve Ark. (2015), iki boyutlu tahmin kullanarak, gelecekteki bir zaman aralığı için bir dizi beklenen değer sağlamışlar ve orada, dağılımın üst ve alt sınırları tarafından tanımlanan olası güneş enerjisi değerleri aralığını elde etmişlerdir.

Lin ve Pai. (2015), Tayvan'daki PV güç çıkışının aylık tahmini için evrimsel mevsimsel ayrıştırma LS-SVR modelini önermişlerdir.

Chu ve Ark. (2015), değişkenlerin 30 dakikaya kadar olan gecikmeli değerlerini dikkate alarak 5-15 dakikalık ufuktaki tahminlerin iyileştirilebileceğini göstermişlerdir.

Gensler vd. (2016), MLPNN ve fiziksel tahmin modellerinden daha iyi performans gösteren AE ve LSTM'den oluşan hibrit bir DL algoritması geliştirmişlerdir. Karşılaştırmada ayrıca DBF ve derin LSTM üzerindeki üstünlüğünü belirtmişlerdir.

Antonanzas vd. (2016), tahminlerin doğruluğunun şebeke üzerindeki etkisinin ekonomik bir değerlendirmesini yapmışlardır. Daha sonra, güneş enerjisi tahmin çalışmalarının

en güncel derlemesini temsil eden, tahmin ufuklarına ve girdilerin kaynağına göre bir sınıflandırması yapılmıştır.

Şahan ve Okur. (2016), çalışmalarında MGM“den (Meteoroloji Genel Müdürlüğü) uzun yıllara (1993-2010) ait meteorolojik ve coğrafik verileri ile yapay sinir ağı (YSA) modeli kullanarak Akdeniz Bölgesinden seçilen on dört yerleşke yerine ait aylık ortalama toplam güneş ışıınım şiddetini tahmin çalışmaları yapmışlardır.

Wang ve Ark. (2017), BPNN, SVM ve SVM entegre WT yöntemleri üzerinden tahmin yeteneğini geliştirmek için WT, DCNN ve QR'yi birleştiren hibrit bir yaklaşım kullanmışlardır.

Alzahrani vd. (2017), DRNN, Çalışmalarında güneş ışıınımını tahmin etmek için . bulut örtüsü, güneş ışığının saçılması, bulutlu gökyüzü ve açık gökyüzü veri kümelerini kullanarak Model, SVR ve FFNN yaklaşımlarından daha iyi performans gösterdiğini belirlemişlerdir.

Haixiang ve Ark. (2018), kısa vadeli PV çıktı tahmini için, DCNN'ye dayalı hibrit bir yaklaşım, bir varyasyon modu ayrıştırma tekniği ve evrişim çekirdekleri aracılığıyla hem günlük hem de saatlik zaman ölçeklerini ilişkilendiren iki boyutlu veri kümeleri oluşturmak için verilerden farklı frekansları çıkarmışlardır. Model, SVR, GPR ve RFR tekniklerinden daha iyi performans gösterdiğini belirtmişlerdir.

Srivastava ve Lessmann (2018), LSTM ile bir DNN, uydu verilerinden gün öncesi küresel yatay ışıınımı tahmin etmişlerdir. Model, kalıcılık modeline göre ortalama %52,2'lik bir tahmin becerisiyle Gradient Boosting Regresyon, FFNN ve Kalıcılık yöntemlerinden daha iyi performans gösterdiğini belirtmişlerdir.

Zhang ve Ark. (2018), üç DNN analiz ederek, dakika ölçeğinde PV çıktısının tahmini açısından derin MLPNN, DCNN ve derin LSTM. LSTM tabanlı modelin en iyi performansı gösterdiğini belirtmişlerdir.

Akarşlan ve Hocaoglu. (2018), çalışmalarında, Afyon Kocatepesi Üniversitesi kampüs alanına tesis edilmiş bir güneş enerji üretim tesisinden toplanan bir yıllık verileri kullanarak ve modelleme için çok boyutlu doğrusal tahmin filtreleri (MDLPPF) kullanarak, saatlik olarak toplanan bir yıllık sıcaklık, üretim ve güneş ışıınımı verileri, satırları günlere, sütunları saatlere karşılık gelen resimlere çevrilmiş ve uygun filtre şablonu kullanılarak güç sisteminin üretimi modellenmiştir. Elde edilen sonuçlar MDLP filtrelerin güç sisteminin üretimini modellemedeki başarısını ortaya koymuşlardır.

Lee ve Ark. (2018), PV invertörlerinden ve ulusal hava durumu merkezi raporlarından elde edilen zaman serisi verilerinden gün öncesi güneş enerjisi tahmini oluşturmak için Twin DNN modelini oluşturmuşlardır. Farklı filtre boyutlarına sahip iki DCNN, kısa süreli yerel kalıpları çıkararak ve bir LSTM, verilerdeki uzun süreli özellikleri yakalamıştır. Yaklaşım doğrusal regresyon, RFR, SVR ve diğer geleneksel modellerden daha iyi performans gösterdiğini belirtmişlerdir

Siddiqui ve Ark. (2019), iki aşamalı bir DNN modeli, bulut örtüsü videolarından güneş ışımasını tahmin etmişlerdir. İlk aşamada, gökyüzü görüntülerini kodlayan bir DCNN, ardından, ikinci aşama olarak LSTM, tahminler için metrolojik parametreleri kullanılmıştır. Modelin, GFS ve ECMWF'den daha iyi performans gösterdiği sonucuna varmışlardır.

Wen ve Ark. (2019), bir mikro şebekede yükü ve PV çıkışını tahmin etmek için birleştirilmiş bir DNN-LSTM yaklaşımı kullanmışlardır. Daha iyi tahmin için girdileri PSO ile optimize etmişlerdir. Hibrit yöntemin, toplam tahmin maliyeti ve güvenilirlik açısından MLPNN ve SVM'den daha iyi olduğu sonucuna varmışlardır.

Rafat vd. (2020), çalışmalarında, girdilerin kalitesini iyileştiren tahmin doğruluğunu artıran yüksek boyutlu çok kısa vadeli güneş enerjisi tahmini için yeni bir yöntem sunmuşlardır. Önerilen tek değişkenli modelin performansını değerlendirmek için dört tahmin modeli kullanmışlardır: Destek Vektörü Regresyonu (SVR) , Rastgele Ormanlar (RF), NN Ensemble , PM ve SPM.

Ahmed R. vd. (2020), yapay sinir ağları topluluklarının, kısa vadeli fotovoltaik güç tahminini için en iyi olduğu ve uyarlanabilir ağlar için çevrimiçi sıralı aşırı öğrenme makinesi olduğunu belirlemişlerdir. Bootstrap tekniği belirsizliği tahmin etmek için optimum iken, evrimsel sinir ağı bir modelin altında yatan doğrusal olmayan girdi-çıkı ilişkilerini ortaya çıkarmada mükemmel olduğu sonucuna varmışlardır.

Mellit vd. (2021), İtalya Trieste Üniversitesi'nde kurulu olan PV panellerden üretilen gücün kısa vadeli (1 dakika, 5 dakika, 30 dakika ve 60 dakika) güç tahmini için derin öğrenme sinir ağı (DLNN) algoritması geliştirmişlerdir. Uzun Kısa Süreli Bellek (LSTM), Çift Yönlü LSTM (BiLSTM), Geçitli Tekrarlayan Birim (GRU), Çift Yönlü GRU (BiGRU), Tek Boyutlu Konvansiyonel Sinir Ağı (CNN1D) ve ayrıca CNN1D-LSTM ve CNN1D-GRU gibi hibrit yapılar ile geliştirdikleri modeli karşılaştırmışlar, önerdikleri modelin doğruluk oranının %98 olduğunu belirtmişlerdir.

Rafati vd. (2021), yazarlar bu çalışmalarında, çok kısa vadeli PV elektrik enerjisi tahmininin doğruluğunu artırmak için yeni bir tek değişkenli veri odaklı yaklaşıma dayalı basit bir hibrit yöntem önererek çok kısa vadeli güneş enerjisi tahmin doğruluğunu iyileştirmişlerdir. Bu yöntem SPF-RRF-NN olarak adlandırılır ve büyük güç sistemlerinde yüksek boyutlu güneş enerjisi tahmini için basitçe uygulanabilir olduğunu belirtmişlerdir.

Rai vd. (2021), makalelerinde kısa süreli güneş enerjisi tahmini için verimli bir derin öğrenme modeli geliştirmeyi amaçlamışlardır. Çalışmada diğer DL modellerinden, yani CNN, LSTM, GRU, CNN-LSTM ve CNN-GRU'dan daha iyi performans gösteren AE-GRU tabanlı bir güneş enerjisi tahmin yöntemi önermişlerdir. Önerilen modelin kapsamlı bir şekilde doğrulanması için, üç performans hatası kıyaslamasında 24 saat, 48 saat ve 15 günlük güneş enerjisi tahmininin farklı zaman aralıkları için farklı DL modelleri ile karşılaştırılmıştır. Uygulanan algoritmalar, tüm DL modellerine eşit zemin sağlayan aynı hiper parametrelere sahiptir. DL modellerini Keras yazılımında uygulamışlardır

Ghodusinejad vd. (2022), çalışmalarında, farklı iklim koşullarına sahip İran'ın beş farklı şehrinde bir PV sisteminin performansını değerlendirmişlerdir. Matematiksel bir model kullanılarak, sıcaklık ve radyasyonun PV sistem performansı üzerindeki etkisini araştırmışlardır.

Yuhao Nie vd. (2023), çalışmalarında farklı güneş tahmini modellerini değerlendirmek ve karşılaştırmak, ayrıca görüntü tabanlı güneş tahmini gökyüzü görüntüsü segmentasyonu, bulut türü sınıflandırması ve bulut hareketi tahmini amaçla, farklı gökyüzü koşulları için farklı türde modeller kullanmanın tahmin doğruluğunu artırabileceğini belirtmişlerdir.

Putri Nor Liyana Mohamad Radzi vd. (2023), çalışmalarında denetimli makine öğreniminin kapsamlı bir incelemesini yapmışlardır Farklı sinir ağı türleri uygulanırken PV sistemi tarafından üretilen çıkış gücünün doğruluk performansını incelemişlerdir. Tahmin yöntemlerinin çoğu, geleneksel yöntemlere kıyasla hibrit olduğunu ve bu, hibrit modellerin tahminde daha iyi performans gösterdiğini kanıtlanmıştır.

Tüm literatür çalışmaları incelendiğinde hibrit yaklaşımların model performanslarının tekil modellere göre daha iyi sonuç verdiği gözlemlenmiştir. Yapılan çalışmalarda özellikle derin öğrenme tabanlı yaklaşımların hata performans kriterlerinin daha düşük olduğu özellikle ayrıştırma tabanlı yaklaşımlar ile de model performanslarının artırılabilirdiği gözlemlenmiştir. Buna karşın güneş enerjisi tahmininde CEEMDAN tabanlı ayrıştırma metotlarının kullanıldığı gözlemlenmesine karşın Kernel tabanlı ELM mimarisi ile hibrit model

analizlerinin yapılmadığı görülmektedir. Özellikle literatürde yapılan çalışmalar gözönüne alındığında ELM gibi hızlı model performansına sahip olan yaklaşımların kullanımı çok kısa ve kısa dönemli tahmin çalışmalarında önem kazanmaktadır. Tüm değerlendirmeler ve literatür çalışmaları güneş enerjisi güç sistemlerinin şebeke entegrasyonunda güç sistem yönetimi, kararlılık ve sistem kontrolü açısından kısa dönemli güneş enerjisi tahmininin hassas doğrulukta olması gerekliliğini göstermektedir. Bu sebeple günümüzde bu sistemlerde tahmin performansını artırabilmek için güncel yapay zeka tekniklerinin uygulama çalışmaları hala devam etmektedir.

Bu tez çalışmasının ana motivasyonu kısa dönemli güneş enerjisi tahmini için yenilikçi CEEMDAN-Kernel-ELM tabanlı hibrit bir tahmin modelinin önerilmesidir. Bu kapsamda BŞEÜ yenilenebilir enerji laboratuvarından 2021 itibariyle alınan veriler kullanılmıştır. Tez çalışması kapsamında bir önceki adımda yer alan geçmiş verilerin gelecek veriler ile olan ilişkisi ele alınarak veriye dayalı mevsimsel kısa dönemli tahmin modelleri oluşturulmuştur. İlk yapılan analizlerde farklı güncel ve geleneksel ayrıştırma metotlarının model performansları değerlendirilmiştir. EMD, SWD, EEMD, IEMD ve CEEMDAN ayrıştırma modellerinin performansını geleneksel çok katmanlı ağ (MLP) yapılarıyla olan hibrit model performansları analiz edilmiştir. Yapılan mevsimsel analizlerde her bir mevsimden olan aylar için ayrı ayrı tahmin model sonuçları karşılaştırmalı olarak analiz edilmiştir. Burada ayrıştırma metotlarının birbirlerine göre üstünlükleri incelenmiş olup, lineer ve durağan olmayan sinyallerin daha durağan ve lineer hale getirilerek tahmin modellerine girişlerine uygulanıp model performanslarının artırılması hedeflenmiştir. Tezin ikinci aşamasında ise model performansının yüksek olduğu güncel CEEMDAN yaklaşımının Kernel-ELM modeli ile hibrit yapısı önerilmiştir. Tez çalışması kapsamında önerilen hibrit modelin performansı hem hibrit modeller ile hemde derin öğrenme tabanlı güncel modelle karşılaştırılarak model performans metrikleri ile karşılaştırmalı olarak sunulmuştur. Buna ek olarak istatistiksel olarak Taylor diagramı ile de önerilen modelin performansı sunulmuş ve yorumlanmıştır.

Tez çalışmasının devamında ikinci bölümde Dünyada ve Türkiye'deki güneş enerjisinin durumu üçüncü bölümde ise gerek ayrıştırma metotlarını gerekse tahmin modellerini içeren metodoloji sunulmuştur. Dördüncü bölümde verilerin temini, araştırmanın bulguları ve önerilen hibrit modelin sonuçları ele alınmıştır. Son bölümde tez çalışmasının genel sonuçları ve yapılabilecek gelecek çalışma önerileri vurgulanmıştır.

2. GÜNEŞ ENERJİSİ

Sanayi kuruluşlarının çoğalması, her geçen gün elektrikli taşıtların sayısının ve elektrik ile çalışan cihaz kullanımındaki artışlarla beraber elektrik enerjisine olan ihtiyaç gün geçtikçe artış göstermektedir. Fosil enerji kaynaklarının kullanımı ekosistem üzerindeki olumsuz etkilerinden dolayı, artan elektrik enerjisi talebinin karşılanmak için yenilenebilir ve temiz enerji kaynaklarının kullanımı büyük önem taşımaktadır (Dokur,2017:7).

Güneş enerjisinin kullanımının M.Ö. 400'lü yıllara dayandığını söyleyebiliriz. Güneş cephelerine göre evlerin tasarımının yapılması Sokrates tarafından önerilmiş ve bu sayede ısı ve ışıktan yararlanılması sağlanmıştır. Merceğin Galile tarafından bulunmasıyla birlikte 1600'lü yıllarda güneşin kullanımı konusunda farklı bir adıma geçilmiştir. Su pompasının güneş enerjisi ile çalışan bir yapıda tasarımı 1725 yılında Belidor tarafından icat edilmiş olup farklı alanlarda güneş enerjisinin kullanımının yıllara göre değişimi mevcut olmaktadır (Ekolojist, 2017:1).

Güneş enerjisi dünyamızın ısı ve ışık kaynağı olması yönüyle yenilenebilir enerji kaynakları içerisinde ana kaynak etmen olarak görülmektedir. Dünya üzerindeki yaşamın oluşması ve devam etmesindeki temel ögesidir. Bitkiler güneş enerjisini kullanarak fotosentez yaparlar ve bunun sonucunda besin üretirler. Üretilen bu besin dünyadaki tüm canlıların gıda ihtiyacını karşılar. Güneş enerjisi sistemleri çevreye zarar vermeyen, tükenmeyen bir enerji türüdür. Bu nedenle kullanımı gün geçtikçe artmaktadır.

Yenilenebilir enerji kaynakları ile ilk zamanlarda su pompalanması, güneşin ısısı ile ürünlerin kurutulması, rüzgar ve su değirmenlerinde tahıl öğütme, rüzgar gücü ile yelkenli gemilerin hareket ettirilmesi gibi işlemlerde faydalanılmıştır. Sanayi devrimi ile buhar gücü ile çalışan makinelerin icadı, sonrasında içten yanmalı motorların keşfi ile yenilenebilir enerji kaynaklarının önemini kaybetmesine neden olmuştur.

Her ülke sahip olduğu yerli yenilenebilir enerji kaynaklarından faydalandığında enerjide dışa bağımlılığını en aza indirecektir. Artan çevre bilinci, iklim değişiklikleri ve gelecek nesillere yaşanılabilir bir Dünya bırakma düşüncesi yenilenebilir enerji kaynaklarının kullanımının artmasını sağlamıştır (Türkyılmaz, 2020:1).

Dünya enerji verileri değerlendirildiğinde, belirlenen dönemde yenilenebilir enerjinin kurulu gücünde ve tüketiminde önemli artışlar olduğu gözlemlenmiştir. Ayrıca, dünya çapında yenilenebilir enerji kullanımı ve tüketimi düzenli olarak artmaktadır. 2012 yılında dünyanın birincil enerji tüketiminin 0,24 Giga ton eşdeğer petrol'ü (Gtoe) yenilenebilir enerji

kaynaklarından karşılanırken, 2021 yılında bu değer 0,95 Gtoe'e yükseldi. Ayrıca 2016 yılında dünyadaki toplam elektrik üretiminin yaklaşık %7,4'ü yenilenebilir enerji kaynaklarından karşılanmış; bu oran 2021'de %12,8'e yükselmiştir. Tablo 2.1'de Avrupa Birliği ülkelerinin birincil enerji tüketim değerleri görülmektedir.

Tablo 2.1. Avrupa Birliği (AB) ülkelerinin birincil enerji tüketim değerleri

Yıllar	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
OECD	5.54	5.59	5.54	5.56	5.59	5.63	5.72	5.67	5.26	5.49
OECD dışı	7.08	7.25	7.44	7.53	7.69	7.90	8.19	8.36	8.21	8.72
AB	1.51	1.50	1.44	1.46	1.48	1.49	1.50	1.48	1.36	1.44
Dünya	12.62	12.84	12.98	13.09	13.28	13.53	13.91	14.03	13.47	14.21

Değerler incelendiğinde, küresel Covid-19 pandemisi nedeniyle 2020 yılında birincil enerji tüketim değerlerinde keskin bir düşüş gözleniyor. Dünya birincil enerji tüketimi 10 yılda 12,62 Gtoe'den 14,21 Gtoe'ye ulaşırken, AB ülkelerinde birincil enerji tüketimi aynı dönemde 1,51 Gtoe'den 1,44 Gtoe'ye geriledi. Dünya yenilenebilir kapasiteleri Tablo 2.2'de gösterilmektedir.

Tablo 2.2. Dünya yenilenebilir enerji kapasiteleri (GW).


Yıllar	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
biyo.	83	88	101	106	114	122	131	139	133	143
CSP	2.5	3.4	4.3	4.8	4.8	4.9	5.6	6.2	6.2	6.0
Geo.	11.5	12	12.9	13.2	12.1	12.8	13.2	13.9	14.2	14.5
PV	100	139	177	227	303	402	512	627	767	942
Rüzgâr	283	318	370	433	487	539	591	651	745	845
Toplam	480	560	665	785	922	1081	1252	1437	1672	1945

Tablo 2.3'te, rüzgar, güneş ve diğer (jeotermal, biyokütle ve diğer yenilenebilir enerji kaynakları) yenilenebilir enerji kaynaklarından elektrik üretim değerlerini göstermektedir.

Tablo 2.3. 2018–2021 (TWh) için yenilenebilir kaynaklardan elektrik üretimi.

Yıllar		2018	2019	2020	2021
OECD	Rüzgâr	745.4	841.8	935.4	976.7
	Güneş	329.9	387.2	442.5	523.3
	Diğer	367	387.8	388.2	410.1
	Rüzgâr	524.7	587.9	661.1	885.2
OECD dışı	Güneş	252.8	336.9	403.8	509.2
	Diğer	248	264	315.7	352.7
	Rüzgâr	376.9	430.7	397.3	389.5
	Güneş	127.5	138.4	143.3	160.6
AB	Diğer	196.4	199.1	170	180.1
	Rüzgâr	1270.2	1429.6	1596.4	1861.9
	Güneş	582.8	724.1	846.2	1032.5
	Diğer	615	651.8	703.9	762.8


Şekil 2.1’de yıllara göre Dünya’daki yenilenebilir enerji yatırımlarındaki artış görülmektedir (Yolcan, 2023:2).



Şekil 2.1. Yıllara göre dünya yenilenebilir enerji yatırımı (milyar \$)

Kaynak: (Yolcan, 2023)

PV'nin kurulu güç kapasitesi, 2027 yılına kadar kömürü geçerek dünyanın en büyüğü haline gelmeye hazırlandığı görülmektedir. Kümülatif güneş enerjisi kapasitesi, üç katına çıkarak, dönem boyunca yaklaşık 1.500 GW artarak, 2026'da doğal gazı ve 2027'de kömürü aşması beklenilmektedir. Şekil 2.2’de 2015-2027 yılları arasında yenilenebilir enerjide beklenen artış görülmektedir.



Şekil 2.2. 2027’de yenilenebilir enerjide beklenen artış

Kaynak: (World Energy Outlook, 2022)


Ülkemizin elektrik sisteminde mevcut durumda sahip olduğu ve önümüzdeki dönemde sahip olabileceği esneklik imkanları ve yenilenebilir enerji potansiyeli dikkate alınarak, rüzgar ve güneş gibi kesintili yenilenebilir enerji kaynaklarının toplam elektrik üretimi içindeki paylarının yükseltilmesi planlanmıştır.

Bu doğrultuda 2035 yılında kurulu güç,

- Rüzgar enerjisinde 29,6 GW (24,6 GW kara, 5 GW deniz),
- Güneş enerjisinde 52,9 GW düzeyine yükselmektedir.

Diğer yenilenebilir enerji kaynakları için kurulu güç hidroelektrik santrallerde 35,1 GW, jeotermal ve biyokütle enerji santrallerinde toplam 5,1 GW seviyesine yükselmektedir (EİE, 2022:2).

Ülkemizin 2020 yılı birincil enerji tüketimi 147,2 Megaton eşdeğer petrol (Mtep) olarak gerçekleşmiştir. 2035 yılına kadar birincil enerji tüketimi 205,3 Mtep'e yükselmektedir. 2000-2020 döneminde yıllık ortalama %3,1 oranında artış göstermiş olan birincil enerji tüketimi, 2020-2035 döneminde %2,2 düzeyinde artmaktadır. 2020 yılında 1,7 tep/kşi olan kişi başı birincil enerji tüketimi 2,1 tep/kşi düzeyine çıkmaktadır. 2020 yılında %16,7 olan birincil enerji tüketimi içindeki yenilenebilir enerji kaynaklarının payı 2035 yılına kadar %23,7 bandına yükselmektedir. Nükleer enerji ise 2035 yılına kadar %5,9'luk paya ulaşmaktadır. 2020 yılında %83,3 olan fosil kaynakların payı 2035 yılına kadar %70,4 olarak gerçekleşmektedir. Kömürün payı %21,4'e inerken, petrol %26,5, doğalgaz %22,5'e gerilemektedir. Şekil 2.3.'te yakıta göre birincil enerji tüketimi görülmektedir (EİE, 2022:3).



Şekil 2.3. Yakıta Göre Birincil Enerji Tüketimi

Kaynak: (EİE, 2022)

Tüm bunlara karşın güneş enerjisinin avantajlı olmayan durumları aşağıdaki gibi sıralanabilir:

-Güneş enerjisinin yoğunluğu bölgesel olarak değişkenlik gösterebilir ve zamana bağlı lineer bir süreklilik göstermeyebilir. İstenilen anda istenilen yoğunlukta bulunamayabilir.


-Güneş enerjisinden yararlanmak için yapılması gereken düzeneklerin yatırım giderleri teknolojik açıdan yüksektir.

-Güneşten gelen enerji miktarı bizim isteğimize bağlı değildir ve kontrol edilemez.

-Birçok kullanım alanının, enerji arzı ile talebi arasındaki zaman farkı ile karşılaşılmaktadır.

-Güneş enerjisinden elde edilen ısıtım talebinin yoğun olduğu zamanlarda kullanılmak üzere depolanmasını gerektirir.


Dünyadaki enerji kaynaklarının ve güneş enerjisinin arzı ile ilgili bir karşılaştırma Şekil 2.4.'te gösterilmiştir (Kurban ve Gün, 2011:18).



Şekil 2.4. Dünyanın enerji ihtiyacı fosil yakıtlı enerji kaynağı arzı ve güneş enerjisinin karşılaştırılması

Kaynak: (Bölat, 2015)


Güneş ışığının %80'nin emilmesine karşın yeryüzüne düşen ortalama günlük 250-300 W/m²'lik bir güce sahiptir. Meteorolojik şartlara göre güneş enerjisinin Dünyamıza ulaşma miktarı Şekil 2.5 'te görülmektedir



Şekil 2.5. Meteorolojik şartlara göre güneş enerjisinin Dünya'ya ulaşma miktarı

Kaynak: (Alternative Energy Tutorials)

Dünyamızın küre şeklinde olması ve eksenin de eğik olmasından dolayı Dünyanın her bölgesi güneş enerjini farklı miktarlarda almaktadır. Şekil 2.6 'da Dünyamızın güneş enerji potansiyel haritası görülmektedir.




Şekil 2.6. Dünya'nın güneş enerjisi potansiyel haritası

Kaynak: (IEA,2022)

2.1. Türkiye'de Güneş Enerjisi Potansiyeli

Ülkemiz, coğrafi konumu itibarıyla sahip olduğu güneş enerjisi potansiyeli açısından birçok ülkeye göre avantajlı durumdadır. EİE tarafından yapılan çalışmaya göre, Türkiye'nin


ortalama yıllık toplam güneşlenme süresi 2741 saat, bu da günlük toplam 7.5 saate eşittir. Ortalama yıllık toplam ışıınım ışıınım değeri 1.527,46 kWh/m² bu da günlük toplam 4.18 kWh/m² ye eşittir. Şekil 2.7’de Türkiye’nin yıllık ışıınım haritası görölmektedir.



Şekil 2.7. Türkiye’nin yıllık güneş ışıınımı haritası

Kaynak: (EİE, 2022)


GEPA’da yer alan genel potansiyel görünümü ve aylık ortalama küresel radyasyon dağılımı aşağıda yer almaktadır. Türkiye’nin aylık ortalama radyasyon miktarı Şekil 2.8’de görölmektedir.



Şekil 2.8. Türkiye’nin aylık ortalama küresel radyasyon dağılımı

Kaynak: (E.İ.E, 2022)


Haziran 2022 sonu itibariyle güneş enerjisine dayalı elektrik kurulu gücümüz 8,479 MW, toplam kurulu güç içerisindeki oranı %8,35 olup yıllara göre kurulu güç değişimi ve toplam kurulu güç içerisindeki oranı Şekil 2.9’daki grafiklerde yer almaktadır.



Şekil 2.9. Türkiye'nin Haziran 2022 sonu itibarıyla güneş enerjisine dayalı elektrik kurulu gücü

Kaynak: (EİE, 2022)

Son yıllarda fosil yakıtlardan elektrik enerjisi üretimi azalma eğilimi gösterirken en büyük artış güneş enerjisinde olduğu görülmektedir. Şekil 2.10'da 2010 ve 2022 yılları arasındaki enerji üretim ve 2026 hedef değerleri görülmektedir. Tüm bu istatistiklerden görülebileceği üzere günümüzde ve gelecekte güneş enerjisinin kullanımı hızla artış gösterecektir.



Şekil 2.10. 2010 ve 2022 yılları arasındaki enerji üretim ve 2026 hedef değerleri

Kaynak: (IEA, 2022)

2.2. Fotovoltaik Paneller ile Elektrik Enerjisi Üretimi

Küresel güneş enerjisi kurulu gücü, 2021 yılına göre yüzde 25 rekor kurulum artışıyla 2022 sonunda 1,2 TW yükselmiştir. Fotovoltaik güneş teknolojilerinin en temel aksamı olan güneş modülleri, güneş enerjisini doğrudan elektrik enerjisine çevirmektedir.

1839 yılında ilk defa Fransız bilim adamı Edmond Becquerel tarafından ortaya konan fotovoltaik olay, iletken bir sıvıdaki elektrotun ışık yayması ile keşfedilmiştir. Nitekim 1877 yılında W. G. Adams ve R.E. Day tarafından katılaştırılmış selenyumda fotovoltaik etki gözlemlenmiştir. Bu gelişmeyi 1883 yılından C. Fritts tarafından geliştirilen ve %1'in altında bir verimliliğe sahip ince bir altın tabakası üzerinde yer alan selenyum güneş hücresi takip etmiştir. Bu gelişmelerin akabinde ise W. Hallwachs bakır ve bakır oksit kullanarak yarıiletken eklemli bir güneş hücresi tasarlamıştır. 1904 yılında A. Einstein tarafından kuantum açısından ele alınan fotoelektrik olay makalesi ile bu etki daha iyi anlaşılmaya başlanmıştır. 1954 yılında Bell laboratuvarları tarafından üretilen ilk Si p-n eklemli güneş hücresi ile başlayan güneşten elektrik üretimi günümüze kadar ulaşarak büyük gelişmelere ve yapılan birçok çalışmaya konu olmuştur (E.İ.E., 2022:1).


Fotovoltaik güneş teknolojilerindeki temel ilke fotovoltaik dönüşümdür. Bu dönüşüm iki aşamada oluşmaktadır. Birinci aşamada, pozitif- negatif akım taşıyıcıları olan yük çiftlerinin oluşturulması, ikinci aşamada da çiftlerin bir elektrik alanı ile birbirinden ayrılmasıdır. PN eklemi oluşturulurken içerisinde fazla elektron bulunan n-tipi yarı iletken madde ile fazla pozitif yük bulunan p-tipi yarı iletken madde yan yana getirilir. Bu ekleme yapısal olarak oluşturulmuş bir elektriksel alan mevcuttur. Tüm enerji dönüşüm olayları bu bölgede olmaktadır. Bu ekleme gelen güneş fotonları, enerjisini bu eklemdaki elektronlara verir ve bu enerji ile oluşan negatif-pozitif yükler, var olan elektriksel alan ile birbirlerinden ayrılır. Böylece devrede doğru akım üretilmiş olur. Üretilen bu doğru akım istenildiğinde bir akü grubunda depolanabilmekte veya DC/AC invertörler üzerinden şebekeye verilebilmektedir.

Fotovoltaik güneş teknolojilerinde en çok kullanılan malzeme silisyum elementidir. Yarı iletken özellik gösteren birçok madde arasında güneş hücresi üretmek için en elverişli olanlar, silisyum, kadmiyum sülfür, galyum arsenit, kadmiyum tellür gibi maddelerdir.

Güneş hücreleri, kristaller ve amorfolar olmak üzere ikiye ayrılır. En yaygın olan silisyum güneş hücreleri; tek (mono) kristalli, çok (poli) kristalli, ince film ve şerit şeklinde olan değişik teknolojilerdeki yapılarda üretilirler. Yüzeyleri kare, dikdörtgen, daire şeklinde

biçimlendirilen güneş hücresinin alanı genellikle 100 cm² civarında, kalınlıkları ise 0,2–0,4 mm arasındadır (E.İ.E., 2022:2).

Güneş hücrelerinin bir araya getirilmesi ile güneş modülleri oluşturulmaktadır. Günümüzde elektrik enerjisi üretimi amaçlı kullanılan güneş modüllerin yüzey alanları 2,1 m² ve güçleri ise 675 Wp değerlerine ulaşmış durumdadır. Güneş modüllerinin bir araya getirilmesi ile birlikte yüksek güçlerde güneş panelleri ve güneş elektrik santralleri (GES) tesis edilebilmektedir. Günümüz teknolojileri ve kurulumun şekline (sabit sistem, güneşi takip eden sistemler) bağlı olarak 13-25 dönüm büyüklüğündeki bir alana 1 MWe kapasitesinde GES kurulabilmektedir. Özellikle, binaların çatı ve cephelerine kurulan GES'ler ile ihtiyaç duyulan elektrik enerjisi tüketim noktalarında üretilebilmektedir. Şekil 2.11.'de Türkiye PV tipi-alan-üretilebilecek enerji (kWh-yıl) miktarları görülmektedir (E.İ.E., 2022:2).



Şekil 2.11. Ülkemizde alana göre yılbaşına PV yapısına göre üretilebilecek enerji değişimi
Tipi-Alan-Üretilebilecek Enerji (KWh-Yıl)

Kaynak: (EİE, 2022)

3. METODOLOJİ

Güneş enerjisi sistemlerinden elektrik enerjisi üretimi, değişken meteorolojik şartlara bağlıdır. Enterkonnekte sistemin üretim planlaması ve güç sisteminin yönetimi açısından güneş enerjisi sistemlerinden üretilecek elektrik enerjisinin anlık, kısa, orta ve uzun ölçekte tahmin edilmesi gerekmektedir. Bu sebeple en az hata oranı ile güneş enerjisinin gelecek bir zaman dilimi içerisinde farklı zaman ölçeklerinde tahmin edilmesi gerekmektedir. Değişken elektrik enerjisi talebinin hangi yenilenebilir kaynak tarafından ne zaman karşılanacağını belirlenmesi için enerji üretiminin önceden tahmin edilmesi bu zorlukların en önemlilerindendir (Demirtaş vd., 2020:13).


Anlık tahminler güneş enerji santralinin kontrolü için kullanılan ve bir kaç dakika için yapılan tahminleri içerirken, çok kısa süreli tahminler 0-6 saat arası için yapılan ve güç sisteminin yönetimi için kullanılan tahminlerdir. 0-72 saat arası yapılan tahminler ise üretim planlaması ve enerji borsası için kullanılan kısa süreli tahminleri içerir. 0-7 gün veya daha fazla zaman aralıklarında yapılan orta ve uzun süreli tahminler ise bakım onarım planlaması amacıyla yapılmaktadır (Dokur, 2020:4). Tez çalışmasının giriş bölümünde de ele alınan bir çok literatür çalışmasında farklı modellerin bu alanda uygulandığı görülmektedir.

3.1. PV Güç Tahmin Modelleri

Farklı yöntemler: fiziksel, sezgisel, istatistiksel ve makine öğrenimi, PV güç tahmininde yaygın olarak kullanılır. Yöntemler, PV güç tahminini oluşturmak için iki ana yaklaşıma dayanmaktadır. Birincisi, hava durumu verilerinin gerekliliği ile birlikte bir PV sisteminin meta verileri ve PV malzeme özellikleri hakkında ön bilgi gerektiren fiziksel yaklaşımdır. İkincisi, daha sonra tahminleri oluşturmak için kullanılan modellerin katsayılarını eğitmek/kalibre etmek için operasyonel verilere ihtiyaç duyan veriye dayalı yaklaşımdır. Bu, veriye dayalı bir yaklaşımın yalnızca belirli bir PV modülü veya sistemi kullanıma açıldıktan ve modelleri eğitmek için yeterli veri mevcut olduktan sonra uygulanabileceği anlamına gelir. Aksine, PV sistemi henüz devreye alınmamış olsa bile fiziksel bir yaklaşım uygulanabilir (Kaaya ve Ascencio, 2020:3).

Şekil 3.1’de iki yaklaşımla PV güç tahmini oluşturmak için gerekli girdileri ve genel adımları göstermektedir. Açık olan şey, her iki yaklaşımın da girdi olarak hava durumu verilerini (esas olarak güneş ışıınımı) gerektirmesidir. Bu nedenle, güneş ışıınımı tahmini, her iki yaklaşımı kullanarak PV güç tahmini için oldukça önemli bir adımdır. Veriye dayalı yaklaşımın aksine, fiziksel yaklaşım fiziksel varsayımlara dayalıdır ve bu nedenle, PV üretimini etkileyen

fiziksel parametrelerin bilgisi gereklidir. Şekil 3.1’de PV güç tahminini oluşturan adımlar görülmektedir.



Şekil 3.1. İki yaklaşımla PV güç tahmini oluşturmak için gerekli girdileri ve genel adımlar

Kaynak: (Kaaya ve Ascencio, 2020)

Modeller, yapılarına bağlı olarak altı sınıfa ayrılmıştır: klasik istatistiksel modeller, makine öğrenimi tekniklerine dayalı modeller (ML), yer veya uydu verilerine dayalı bulut hareket izleme modelleri, sayısal hava tahmini modelleri ve hibrit modeller olarak görülmektedir (Blaga vd., 2018:6).


Hem ARIMA hem de YSA modelleri kendi doğrusal veya doğrusal olmayan alanlarında başarılar elde etmiştir. Ancak hiçbirisi her koşula uygun evrensel bir model değildir. ARIMA modellerinin karmaşık doğrusal olmayan problemlere yaklaşımı yeterli olmayabilir. Öte yandan, doğrusal problemleri modellemek için YSA'ları kullanmak karışık sonuçlar vermiştir. Örneğin, benzetilmiş verileri kullanan Denton (Denton, 1995:17), verilerde aykırı değerler veya çoklu doğrusallık olduğunda, sinir ağlarının doğrusal regresyon modellerinden önemli ölçüde daha iyi performans gösterebileceğini ele almıştır. Markham ve Rakes ayrıca doğrusal regresyon problemleri için YSA'ların performansının örneklem büyüklüğüne ve gürültü seviyesine bağlı olduğunu bulmuştur. Bu nedenle, YSA'ları herhangi bir veri türüne doğrudan

uygulamak doğruluğu azaltabilir. Gerçek bir problemde verilerin özelliklerini tam olarak bilmek zor olduğundan, hem doğrusal hem de doğrusal olmayan modelleme yeteneklerine sahip hibrit metodoloji pratik kullanım için iyi bir strateji olarak görülebilir. Farklı modelleri birleştirerek, altta yatan kalıpların farklı yönleri bu sayede yakalanabileceği öngörülmektedir.

Yapay zeka tabanlı hibrit modeller yukarıda belirtildiği gibi zaman serileri ile birlikte oluşturulabileceği gibi ayrıştırma metotları ve sezgisel optimizasyon yöntemleri ile birlikte kullanılarak da oluşturulabilmektedir. Ayrıştırma metotları ile gerçekleştirilen hibrit modellerde verilerin nitelikleri alt bileşenlere ayrılarak daha hassas tahmin modellerinin oluşturulmasına olanak sağlamaktadır. Sezgisel optimizasyon yöntemlerinin yapay zeka modellerine entegrasyonunda ise tahmin modeli parametrelerinin en optimal şekilde belirlenerek model performanslarının artırılması hedeflenir (G.Peter Zhang, 2003:4).

3.1. Veri Ayrıştırma Metotları

Genel olarak, literatürde Şekil 3.2 'de gösterildiği gibi ayrışmaya dayalı modellerin üç yapısı görülmektedir. Ayrıştırmaya dayalı hibrit modellerin çekirdeği, rüzgar hızı/güç zaman serisini, sonraki işlemlerden önce nispeten durağan özelliklere sahip birkaç alt seriye ayrıştırmaktır. Yapı 1, farklı modeller kullanarak her bir alt diziyi analiz eder ve tahmin eder. Yapı 2'de ayrıştırılan alt seriler, ikincil ayrıştırma yöntemi kullanılarak daha durağan alt serilere ayrıştırılır, ardından her bir alt seri Yapı 1'deki gibi tahmin edilir. Nihai sonuçlar, Yapı 1 ve Yapı 2 için her bir alt seriden tahminlerin birleştirilmesiyle elde edilir. Sırasıyla her bir alt seriyi tahmin etmekten farklı olarak, Yapı 3'te girdileri ayrıştırılmış alt serilerden seçilen yalnızca bir tahmin modeli oluşturulur (Qian vd, 2019:2).



Şekil 3.2. Ayrıştırma tabanlı modellerin yapıları.

Kaynak: (Qian vd, 2019)

3.2. Görgül Kip Ayrışımı (Empirical Mode Decomposition, EMD)

Ampirik Mod Ayrıştırması (EMD), doğrusal olmayan ve durağan olmayan sinyallerin analizinde kullanılmaktadır. EMD'nin ana fikri, orijinal zaman serisi verilerini, kısa süreli karakteristik zaman ölçeğine dayalı olarak sonlu salınım modlarına ayırmaktır. EMD yöntemi, orijinal sinyalden IMF'leri ve artık sinyal R_n 'yi çıkarmak için Hilbert Huang Dönüşümü (HHT) algoritmasının çok önemli bir parçasıdır. HHT de, doğrusal olmayan ve durağan olmayan sinyalleri analiz etmek için kullanılır. İçsel mod fonksiyonu (IMF) teorisinin öncülüğü, doğrusal olmayan problemler ve Hilbert Dönüşümü üzerine araştırma yapan Norden E. Huang ve arkadaşları tarafından önerilmiştir. Huang ve arkadaşları tarafından önerilen EMD sadece sinyal ayrıştırmasını benzersiz kılmakla kalmaz, aynı zamanda hem zaman alanında hem de frekans alanında iyi yerel özelliklere sahiptir. EMD yöntemi güç sisteminde de geniş uygulama alanına sahiptir.

EMD algoritması orijinal bir sinyali birkaç IMF olarak nitelendirilen alt bileşenlerine ayırır. Eleme işlemiyle iteratif olarak ilerleyen alt bileşenlerde sıfır geçişler arasında yalnızca bir uç nokta içeren özelliklere sahiptir ve ortalama değeri sıfırdır. Orijinal PV üretimi veya yük talebi zaman serisi $x(t)$ olarak tanımlanmak üzere, EMD'nin işlem adımları aşağıdaki gibi açıklanmaktadır.

Adım 1: $x(t)$ sinyalindeki tüm yerel ekstremler bulunur. Daha sonra üst $x_u(t)$ zarfı tüm yerel maksimumların birleştirilmesiyle elde edilir kübik bir spline çizgisi ve alt zarf kullanarak $x_l(t)$ yerel minimumlar için aynı işlem uygulanarak oluşturulur.

Adım 2: Zarfların ortalaması alınır ve farkı hesaplanır. Gerçek zamanlı seri verileri ile ortalama $m(t)$ arasındaki ilişki sırasıyla denklem (3.1) ve denklem (3.2)'de gösterilmektedir.

$$m(t) = \frac{x_u(t) + x_l(t)}{2} \quad (3.1)$$

$$d(t) = x(t) - m(t) \quad (3.2)$$

Adım3: $d(t)$ IMF oluncaya kadar denklem (3.3)'teki koşula göre süreç devam eder.

$$\sum_{t=1}^l \frac{[d_{j-1}(t) + d_j(t)]^2}{[d_{j-1}(t)]^2} \leq \delta \quad (j = 1, 2, \dots; t = 1, 2, \dots, l), \quad (3.3)$$

Burada l sinyal uzunluğu ve j yineleme sayısıdır eleme işlemi. δ sabit bir değer olarak seçilir genellikle 0,2 ila 0,3 arasındadır.

Adım4: İlk üç adım, tüm IMF'ler ve ayrıntılı sinyaller gelene kadar geçerlidir elde edildi. Son olarak, orijinal zaman serisi $x(t)$ IMF $c_i(t)$ ve tek kalıntının toplamı olarak ifade edilebilir $R_n(t)$ denklem (3.4)'te verildiği gibi aşağıdaki gibidir (Akil vd., 2022:3).

$$x(t) = \sum_{i=1}^N c_i(t) + R_n(t) \quad (3.4)$$

3.3. Topluluk Görgül Kip Ayırıştırması (Ensemble Empirical Mode decomposition, EEMD)

EEMD yöntemi gürültü destekli bir EMD tabanlı ayırıştırma yöntemi olup aşağıdaki adımlardan oluşmaktadır:

- i. İlk önce orijinal sinyale bir gürültü eklenir.
- ii. Elde edilen sinyal, EMD kullanılarak IMF'lerine ayırıştırılır.
- iii. (i) ve (ii) adımları önceden tanımlanmış topluluk deneme sayısı kadar tekrarlanır. Her tekrarda farklı rastgele gürültü sinyali eklenir.

iv. Son olarak ayırıştırılmalara karşılık gelen IMF'lerin topluluk araçlarını hesaplanır. EEMD ayırıştırma yöntemine ait matematiksel denklemler aşağıda verilmiştir. n. denemede $x(t)$ giriş sinyaline $u_n(t)$ gürültü eklenmesi eşitlik (3.5)'de gösterilmektedir.

$$Y_n(t) = x(t) + u_n(t), n = 1, 2, \dots, N \quad (3.5)$$


Gürültünün eklenmiş olduğu $Y_n(t)$ sinyali IMF'lere ayırıştırılmasına ait denklem (6) da görülebilir. Bu denklemde $Y_n(t)$ ait her bir ayırıştırma ile sonuçlanan IMF'lerin toplam sayısı $M-1$, $IMF_M^{(n)}$ m. IMF ve $r_M^{(n)}$ n. denemede elde edilen kalıntı olmak üzere aşağıdaki gibi ifade edilmektedir.

$$Y_n(t) = \sum_{m=1}^{M-1} IMF_m^{(n)} + r_M^{(n)}(t) \quad (3.6)$$

Yukarıdaki iki denklem sırayla N kere tekrarlanır. N deneme sonucunda ortalama IMF_m^{ave} elde edilir;

$$IMF_m^{ave}(t) = \frac{1}{N} \sum_{n=1}^N IMF_m^{(n)}(t) \quad (3.7)$$

Şekil 3.3'te EEMD Akış Şemasının bölümleri ve her aşaması ayrıntılı olarak ele alınmıştır (Lei vd., 2013:5).



Şekil 3.3. EEMD Akış Şeması

Kaynak: (Lei vd., 2013)

3.4. Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayırıştırması (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise CEEMDAN)

CEEMDAN, EEMD yönteminin gürültü eklenmiş farklı bir varyasyonudur. CEEMDAN’da orijinal sinyalin tam olarak yeniden yapılandırılması ve IMF’lerin daha iyi bir spektral ayrılması hedeflenmektedir. CEEMDAN ayırıştırma yönteminin adımları aşağıdaki gibi sıralanabilir.

i. $x(t)$ giriş sinyali, $v_i(t)$ gürültü ve ε_0 genlik olmak üzere yeni sinyal aşağıdaki gibi hesaplanır

$$x^i(t) = x(t) + \varepsilon_0 v^i(t) \quad (3.8)$$

ii. EMD ile $x^i(t)$ ayrıştırılıp ilk IMF₁ aşağıdaki eşitlikle hesaplanır.

$$\overline{IMF}_1(t) = \frac{1}{I} \sum_{i=1}^I IMF_1^i(t) \quad (3.9)$$

iii. $r(t)$ ilk artık olmak üzere aşağıdaki eşitlikle hesaplanır.

$$r_1(t) = x(t) - \overline{IMF}_1(t) \quad (3.10)$$

iv. İlk IMF elde edilene kadar $r_1(t) + \varepsilon_0 E(v^i(t))$ ayrıştırılır ve ikinci IMF aşağıdaki gibi belirlenir.

$$\overline{IMF}_2(t) = \frac{1}{I} \sum_{i=1}^I E_1(r_1(t) + \varepsilon_1 E_1(v^i(t))) \quad (3.11)$$

v. $k=2, \dots, N$ olmak üzere k . artık (r) değeri hesaplamak için 3. adım tekrarlanır ve $(k+1)$ IMF aşağıdaki eşitliklerle elde edilir.

$$r_k(t) = r_{k-1}(t) - \overline{IMF}_k(t) \quad (3.12)$$

$$\overline{IMF}_{(K+1)}(t) = \frac{1}{I} \sum_{i=1}^I E_1(r_k(t) + \varepsilon_k E_K(v^i(t))) \quad (3.13)$$

vi. Elde edilen artık değer monoton (artmayan veya azalmayan değer) olana kadar 4. adım tekrarlanır. Sonuç $x(t)$ sinyali aşağıda gösterilen ifade ile hesaplanır (Yüzgeç vd., 2012:3).

$$x(t) = \sum_{k=1}^K \overline{IMF}_k + R(t) \quad (3.14)$$

3.5. Sürü Ayrıştırma (Swarm Decomposition, SWD)

Apostolidis ve Hadjileontiadis tarafından sürü ayrıştırma olarak isimlendirilen durağan olmayan sinyallerin analizi için akıllı bir yaklaşım önerilmiştir. Sürü-avı avlanma yaklaşımıyla çalışan ve bir eleman giriş verisinden salınımlı bileşenler (OC'ler) üreten sürü filtreleme (SWF) bu yöntemin temel yapısını oluşturmaktadır. OC'lerin her biri, orijinal sinyalin gerçek bir bileşeni olarak kabul edilebilir. Swarm-prey hunting başarılı olması için itici ve birleştirici güç olmak üzere iki etkileşim kuvveti içerir. i ve n sırasıyla üye sayısı ve adım sayısı olmak üzere itici kuvvet $F_{dr}(n,i)$ aşağıdaki gibi tanımlanır.

$$F_{dr}(n,i) = P_{prey}(n) - P_i(n-1) \quad (3.15)$$

Burada av (prey)'in konum bilgisi P_{prey} olarak temsil edilmektedir. Sürünün tüm bireyleri için indüklenmiş bir kohezyon kuvveti $F_{coh}(n,i)$ olarak aşağıdaki gibi tanımlanır.

$$F_{Coh,i}^n = \frac{1}{M-1} \sum_{j=1, j \neq i}^M f(P_i[n-1] - P_j(n-1)) \quad (3.16)$$

$$f(d) = -sgn(d). \ln\left(\frac{|d|}{d_{cr}}\right) \quad (3.17)$$

Burada sign function and logarithmic function $sign(.)$ ve $\ln(.)$ olarak sırasıyla gösterilmiştir. Üyeler arasındaki mesafe ve kritik mesafe sırasıyla d ve d_c ile belirtilmiştir. M sürü sayısını ifade eder. Sürü avını izlemek için her seferinde konum ve hız bilgisini aşağıdaki gibi günceller:

$$V_i[n] = V_i[n-1] + \delta. (F_{Dr,i}^n + F_{Coh,i}^n) \quad (3.18)$$

$$P_i[n] = P_i[n-1] + \delta. (V_i[n]) \quad (3.19)$$

SWD'de en önemli adımlardan biri sürülerin esnekliğini kontrol eden δ parametresidir. SWF'nin çıktısı denklem (3.20)'de sunulmuştur.

$$y[n] = \beta \cdot \sum_{i=1}^M P_i \quad (3.20)$$

Burada β sürü sayısını etkileyen ölçek parametresidir $\beta=0.005$ en küçük makul değer olarak belirlenebilir. Farklı sinyal tiplerine göre bu parametrelerin uygun değerlerini belirlemek için aşağıdaki kriter izlenmelidir.

$$\arg_{\delta,M} \min \sum_k \left\{ \left| Y_{\delta,M}[k] - |S[k]| \right| \right\}^2 \quad (3.21)$$

Burada $Y_{\delta,M}[n]$ ve $S[n]$ için orijinal serinin ayırık fourier dönüşümünün genlikleri $Y_{\delta,M}[k]$ ve $S[k]$ ile gösterilmektedir. δ ve M parametrelerine sahip SWF çıktısı $Y_{\delta,M}[n]$ ile temsil edilmektedir. $S[n]$ durağan olmayan tek bileşenli sinyali içerir. Bu sürecin temel amacı δ ve M parametrelerini optimal düzeyde bulabilmektedir. SWF, bu parametreleri kullanarak onları durağan olmayan sinyalle karşılaştırarak salınımlı bileşenlerdeki benzerliği tanır. Sürü parametrelerinin her bir frekansla ilişkisi Apostolidis ve diğerleri tarafından aşağıdaki gibi verilmiştir.

$$M(\hat{\omega}) = [33.46\hat{\omega}^{-0.735} - 29.1] \quad (3.22)$$

$$\delta(\hat{\omega}) = -1.5\hat{\omega}^2 + 3.454\hat{\omega} - 0.01 \quad (3.23)$$

Burada $\hat{\omega}$ normalize frekansı gösterir. M ise iteratif olarak yuvarlama işleme ile belirlenir. SWF yinelemeli olarak sürdürülür ve artık giriş sinyali yeterli enerjiye sahip herhangi bir salınım moduna sahip olmadığında algoritma sonlandırılır. SWD adımımda Savitzky–Golay (SG) filtresi ayrıştırma adımımda uygulanması avantaj sağlamaktadır. Sonuç olarak orijinal sinyalden elde edilen bileşenler ve kalıntı sinyali farklı modlara göre akıllı bir yaklaşım olan SWD tekniği ile elde edilmektedir (Apostolidis vd., 2017:3).


3.6. Yapay Zeka Tabanlı Tahmin Modelleri

3.6.1. Çok Katmanlı Algılayıcı (Multilayer Perceptron, MLP)

Esnek ve başarılı makine öğrenme yöntemlerinden olan Yapay sinir ağları (YSA) insan beyninin çalışmasından esinlenerek geliştirilmiştir. YSA, klasik yöntemlerle çözülmesi zor olan problemlerde etkin bir alternatif oluşturmaktadır. MLP yapay sinir ağı, basit bir yapıya sahip sık kullanılan ve geleneksel ileri beslemeli YSA'lar arasında oldukça popülerdir. Tek katmanlı

algılayıcılarla doğrusal olaylar tahmin edilebilirken, MLP ile doğrusal olmayan olayların tahmini de yapılabilmektedir.

MLP, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı olmak üzere birkaç katmandan meydana gelmektedir. Bu katmanlar Şekil 3.4'te gösterilmiştir.



Şekil 3.4. MLP'nin genel yapısı

Kaynak: (Pérez-Enciso vd., 2019)


MLP'nin matematiksel ifadeleri aşağıda gösterilmiştir. Denklemlerde; X giriş, H gizli katmanın çıkışı (gizli katman değişkeni olarak da ifade edilir), W_1 gizli katmanın ağırlığı, b_1 gizli katmanın sapma değeri, W_2 çıkış katmanının ağırlığı, b_2 çıkış katmanının sapma değeri, Φ aktivasyon fonksiyonu ve O çıkış şeklindedir.

$$H = \Phi(x \cdot w_1 + b_1) \quad (3.24)$$

$$O = HW_2 + b_2 \quad (3.25)$$

MLP'de, giriş katmanı veri girişinin yapıldığı yerdir. Çıkış katmanının parametreleri ilgili problemin hedef değerlerine göre belirlenir. Şekil 3.4'te gösterildiği gibi katman

içerisindeki nöronların kendi aralarında herhangi bir bağlantıları bulunmamaktadır. Her bir katmanda bulunan veriler, bir önceki ve bir sonraki katmanlarda bulunan diğer nöronlarla birbirine bağlanan nöronlar aracılığı ile iletilmektedir. Bu bağlantılar sinaptik ağırlıklar ve hatalar ile ilişkili olup ve ağıdaki parametreler ağı hedefine göre sistemin eğitimi yoluyla ayarlanmaktadır. Gizli katmanda bulunacak nöron sayısı gerçekleştirilecek uygulamaya göre değişmekte olup yapılan denemeler ile tespit edilebilmektedir. Giriş ve çıkış nöronlarına ait değerler ayarlandıktan sonra, ağı her nöronuna ait aktivasyon fonksiyonuna uygun olarak gizli nöronlarla ilişkili parametreleri tahsis etmesi için ağı eğitilmektedir. Aktivasyon fonksiyonu doğrusal ve doğrusal olmayan fonksiyonlar şeklinde ikiye ayrılır. Doğrusal olmayan fonksiyonlarda genellikle sigmoid ve hiperbolik tanjant fonksiyonları kullanılmaktadır. MLP'nin aktivasyonuna ait yapı Şekil 3.5'te gösterilmektedir (Yüzgeç vd., 2022:3).



Şekil 3.5. MLP sıklıkla kullanılan bazı aktivasyon fonksiyonları a)Sigmoid, b)Hiperbolik-Tanjant, c) Doğrusal d)Adım aktivasyon fonksiyonları.


Kaynak: (Dokur, 2017)

MLP 'de, girdi değerlerine bağlı olarak istenilen çıktıyı üretebilme yolunun, ağı öğrenme yeteneğinden geçtiği açıktır. Öğrenme algoritmalarına göre, sinir ağları üç farklı türde sınıflandırılabilir. Danışmalı, danışmasız ve destekleyici öğrenme (Dokur, 2017: 23). Danışmalı öğrenme durumunda, eğitim sırasında hem girdiler hem de bu girdi değerleri için istenen çıktı değerleri sisteme sağlanır ve bu örneklerden genellemeler yaparak bir çözüm elde

edilir. Danışmasız öğrenmede ise sadece girdi değerleri verilir ve sistem, örneklerdeki parametreler arasındaki ilişkileri kendi kendine öğrenmesi beklenir. Destekleyici öğrenme ise sistemin, kendisine verilen girdilere karşılık gelen çıktıyı üretmesini bekler ve üretilen çıktı, olumlu veya olumsuz bir geribildirim sağlar. Bu bilgi, ağı eğitimi sürecini yönlendirmesine yardımcı olur. Literatürde en yaygın kullanılan yapay sinir ağı öğrenme algoritmaları geri yayılım ve Levenberg-Marquardt eğitim algoritmalarıdır. Bu çalışmada Levenberg-Marquardt eğitim algoritması kullanılmıştır.

3.6.2. Kernel Tabanlı Aşırı Öğrenme Makinesi (KELM)

Huang tarafından 2006 yılında önerilen aşırı öğrenme makinesi (ELM), geliştirilmiş tek gizli katmanlı ileri beslemeli ağlara dayanan hızlı bir makine öğrenme algoritmasıdır. ELM'nin diğer ünlü sinir ağı algoritmalarıyla karşılaştırıldığında temel avantajları, sinir modelindeki öğrenme parametrelerinin ayarlanması veya yinelemeli yöntem olmadan rastgele üretilmesidir. Çıkış ağırlıkları en küçük kareler (LS) yöntemiyle belirlenir. Günümüzde hem regresyon hem de sınıflandırma problemlerini içeren birçok gerçek uygulamada yaygın olarak kullanılmaktadır (Zhang vd., 2016:154). Şekil 3.6'da, ELM'nin temel iç ağ yapısını göstermektedir.



Şekil 3.6. ELM'nin Temel Yapısı

Kaynak:(Dokur, 2021)

N adet rastgele farklı örnekten oluşan bir eğitim seti verildiğinde $S = \{ (x_i, t_i) \mid x_i \in \mathbb{R}^n, t_i \in \mathbb{R}^m, i = 1, 2, \dots, N \}$, SLFNs'lerin $\bar{N}$ gizli düğümlü ağ fonksiyonu şu şekilde formüle edilebilir:

$$f_{\bar{N}} = \sum_{j=1}^{\bar{N}} \beta_j G(a_j, b_j, x_i) = t_i \quad i = 1, 2, \dots, N \quad (3.26)$$

Burada a_j ve b_j rastgele belirlenecek öğrenme parametreleridir. β_j , j 'nin gizli düğümünü ve çıktı düğümlerini birbirine bağlayan çıktı ağırlık matrisidir. x_i ve t_i sırasıyla i . gözlemin özelliği ve çıktısıdır. $G(a_j, b_j, x_i)$, ELM evrensel yaklaşım yeteneği teoremlerini karşılayan doğrusal olmayan parçalı sürekli bir fonksiyondur.

Yukarıdaki $\bar{N}$ denklemleri matris formunda şu şekilde yazılabilir.

$$H\beta = T$$

$$H = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_{\bar{N}}, b_{\bar{N}}, x_1) \\ \vdots & \ddots & \vdots \\ G(a_1, b_1, x_N) & \dots & G(a_{\bar{N}}, b_{\bar{N}}, x_N) \end{bmatrix}_{N \times \bar{N}} \quad (3.27)$$

Ayarlanabilir öğrenme parametreleri olmayan sabit doğrusal olmayan dönüşümden sonra, ELM ağının gizli katmanı, giriş alanını ELM özellik alanı adı verilen yeni bir doğrusal alana eşler. Tek çıkışlı düğüme sahip ELM modeli aşağıdaki optimizasyon problemi olarak formüle edilebilir.

$$J_{ELM} = \frac{1}{2} \|\beta\|^2 + C \frac{1}{2} \sum_{i=1}^N \|e_i\|^2 \quad (3.28)$$

$$h(x_i)\beta = t_i - e_i \quad (3.29)$$

Burada e_i , i 'inci gözlemin eğitim hatasını temsil eder. $h(x_i)$ çıktı gizli katman matrisinin i 'inci satırıdır. C , kullanıma özel bir parametredir ve eğitim hatası ile çıktı ağırlıklarının normu arasında bir denge sağlayabilir. KarushKuhnTucker (KKT) teorisine göre yukarıdaki ELM modeli aşağıdaki ikili optimizasyon probleminin çözümüne eşdeğerdir.

$$L_{ELM} = \frac{1}{2} \|\beta\|^2 + C \frac{1}{2} \sum_{i=1}^N \|e_i\|^2 - \sum_{i=1}^N \sum_{j=1}^m \tau_{ij} (h(x_i)\beta_j - t_{ij} + e_{ij}) \quad (3.30)$$

$$\bar{V}_{ELM} = \beta + CH^T(T - H\beta) = 0 \quad (3.30)$$

Eğitim gözlemlerinin sayısının gizli düğümlerin sayısından daha büyük olması durumunda bu, H 'nin tam sütun sıralamasında olduğu anlamına gelir. Daha sonra çıktı ağırlığı aşağıdaki gibi tahmin edilmelidir.

$$\hat{\beta} = (\frac{I_N}{C} + H^T H)^{-1} H^T T \quad (3.31)$$

Burada I_N , $\hat{N}$ boyutuna sahip bir birim matristir (bundan sonra benzer şekilde). Eğitim desenlerinin sayısı gizli düğümlerin sayısından küçük olduğunda, H'nin sütunları satırlardan daha fazla olur. Yani H tam satır rütbesine sahiptir ve HH^T tekil değildir. O zaman elimizde

$$\hat{\beta} = H^T (\frac{I_N}{C} + HH^T)^{-1} T \quad (3.32)$$

Özellikle, I_N / C veya I_N / C , ELM ile matris teorisi ve sırt regresyonu gibi diğer istatistiksel teoriler arasındaki bağlantıyı kuran düzenleme parametresi olarak adlandırılır.

ELM algoritması evrensel yaklaşım yeteneğine sahiptir, bunun sonucunda ayırıcı hiperdüzlem ELM özellik uzayındaki orijinden geçebilir. ELM algoritması, SVM ve onun varyantlarından daha iyi performans gösterme eğilimindedir (Zhang vd., 2016:145).

$$y = h(x)\hat{y} = h(x)H^T (\frac{1}{\lambda} + HH^T)^{-1} T \quad (3.33)$$

Kernel-ELM Huang tarafından önerilmiştir. Bir çekirdek Kullanıcısı aşağıdaki durumlarda ELM matrisi oluşturulabilir. H özellik eşlemesinden habersizdir. Aşağıdakiler olabilir

Gizli katman özellik eşlemesi $h(x)$ 'in aşağıdakileri yapmasına gerek yoktur:

$$Y = h(x)H^T (\frac{1}{\lambda} + HH^T)^{-1} T = \begin{bmatrix} k(x, x_1) \\ k(x, x_2) \\ \vdots \\ k(x, x_n) \end{bmatrix}^{-T} (\frac{1}{\lambda} + HH^T)^{-1} T \quad (313)$$

4)

Kullanıcı, rolü üstlenen $k(u, v)$ çekirdeğini sağlar. $h(x)$ ve gizli düğümlerin sayısıdır. Ceza faktörü λ dır. ELM'nin rastgele haritalanmasının yerini kararlı bir çekirdek aldı. Çıkış ağırlığının stabilitesini artıran fonksiyon. Sonuç olarak, Kernel-ELM, ELM'den daha çok geliştirilebilir.

4. UYGULAMA

Bu tez çalışması kapsamında karşılaştırmalı olarak analiz edilen ve önerilen yenilikçi hibrit güneş tahmin modellerinin performansını değerlendirmek için Bilecik Şeyh Edebali Üniversitesi (BŞEÜ) yenilenebilir enerji laboratuvarından elde edilen veriler kullanılmıştır.

Bu kapsamda yapılan çalışmaların ilk aşamasında sistem altyapısının oluşturulması, verilerin elde edilmesi, ön işlenmesi ve zaman serisi olarak toplanması yer almaktadır. İkinci aşamada oluşturulan zaman serisi verileri ile geçmiş birkaç adıma dayalı farklı ayırıştırma metotları içeren hibrit çok katmanlı ağ modellerinin performansları incelenmiştir. Üçüncü ve son aşamada ise bu tez çalışması kapsamında önerilen CEEMDAN-Kernel-ELM hibrit modelinin performansı hem derin öğrenme metotları hemde geleneksel hibrit tahmin modelleri ile karşılaştırmalı olarak analiz edilmiştir. Tüm çalışmanın bulguları son adımda hata performans kriterleri ve Taylor diyagramı ile karşılaştırmalı olarak sunulmuştur.


4.1. Sistem Altyapısı ve Veri Seti Elde Edilmesi

BŞEÜ yenilenebilir enerji laboratuvarında (Şekil 4.1) her biri 190 W gücünde 63 adet polikristal güneş paneli bulunmasına karşın bu çalışmada her bir dizi de 9 panel olacak şekilde 4 dizi içeren toplam 36 adet panel devreye alınarak çalışma gerçekleştirilmiştir. Her bir panel 40° eğim açısına sahip olup 40.19°N , 29.96°E konumunda yer almaktadır. Paneller sırasıyla 36 V ve 5.28 A maksimum güç noktası gerilimi ve akımına sahip olup, 44.9 V açık devre gerilimi ve 5.65 A kısa devre akımına sahiptir.



Şekil 4.1. BŞEÜ Yenilenebilir Enerji Laboratuvarı

PV dizilerinin enerji kablolarının bağı olduğu pano Şekil 4.2’de verilmiştir. Her bir paralel dizi için 10A’lık bir sigorta kullanılmıştır. Pano içerisinde ek olarak acil stop butonları ve bir adet kontaktör bulunmaktadır.



Şekil 4.2. Enerji panosu

Şekil 4.2 ‘de önerilen sistem ile şebeke arasında bağlantı kuran pano gösterilmektedir. Burada kısaca üç fazlı şebekeye bağlantının yapıldığı pano yer almaktadır. İhtiyaca göre çift taraflı çalışmayı da desteklemektedir. Enerjinin çift yönlü akışını ölçmek için çift yönlü sayaç kullanılmıştır. Pano içerisinde iki adet 125A kesici, iki adet 40A kaçak akım rölesi, iki adet 32A üç fazlı sigorta tesis edilmiştir. Sayaç bağlantısı yapılmış olup ilgili dağıtım üzerinden şebekeye entegre edilmiştir. Şekil 4.3’te çift yönlü sayaç panosu görülmektedir.



Şekil 4.3. Çift yönlü sayaç panosu

Sistem elemanları içerisinde aynı zamanda Şekil 4.4'(a) da verilen, her biri 6F, 160V'luk 5 adet ultra-kapasitör modülü seri bağlanarak ultra-kapasitör grubu yer almaktadır. Ultra-kapasitör grubu DC-baraya bağlanarak oluşabilecek ani dalgalanmaları düzeltmek ve anlık yüksek güç akışı sağlamak amacı ile de kullanılabilir.

Şekil 4.4'(b) de verilen her biri 12V, 100Ah 2,23V hücre yüzer (floating) şarj geriliminde olan iç direnci $1.7m\Omega$ /hücre ye sahip 16 adet OPzS stasyonier bataryalar seri bağlanarak, toplam 192V gerilim seviyesinde enerji depolama batarya grubu elde edilmiştir. PV panellerin ürettiği gücün yetersiz kaldığı durumlarda gerekli enerjiyi sağlamak için batarya grubu devreye girecektir. Tez çalışmasında ki odak noktası veriye dayalı tahmin modeli içerdiğinden burada batarya yönetim sistemine ilişkin bir çalışmalar yapılabileceği öngörülmektedir. Şekil 4.4'te depolama birimleri görülmektedir.



Şekil 4.4. Depolama birimleri (a)Ultra Kapasitörler (b) Batarya Grubu.

Tez çalışması kapsamında mevcut güneş panellerinin şebekeye bağlantısı için Şekil 4.5’te gösterilen 4 MPPT kanallı Huawei Sun 2000- 20KTL marka ve modelinde %98.65 verimle çalışan 20kW’lık bir invertör montajı yapılmıştır. Invertör seçimi sırasında saf sinüs çıkışa sahip, DC baraya uygun girişe sahip olan, şebeke entegreli (50Hz frekans kilitlemeli), PV panel akım ve gerilimine uygun, MPPT özelliğine sahip Wi-fi Ethernet haberleşmesi olan ve harmonik değeri $THD < \%5$ olacak şekilde seçim yapılmıştır. Şekil 4.5’te üç fazlı invertör montaj görüntüsü, devre şeması ve verimlilik grafiği görülmektedir.




Şekil 4.5. Üç fazlı invertör montaj görüntüsü, devre şeması ve verimlilik grafiği

Montaj işlemleri öncesinde mevcut sistemde yer alan 63 panelin uzun süreli geçmiş kullanımı nedeniyle akım gerilim karakteristikleri Benning Solar ölçüm test cihazı ile 1000W/m² güneş ışıınım değerinde ölçümler alınmış ve sağlamlık kontrolleri yapılmıştır.


Veriler PV panel çıkışında bulunan 20kW kapasiteli invertörden internet tabanlı izlenerek gerçek zamanlı olarak toplanmıştır. Veriler 00:00 am - 23:55 pm arasında toplanmakta olup her gün için veri noktası mevcut olmasına karşın inverterin çıkışından elde edilen aktif güç değeri olduğu andaki değerler 5'er dakikalık olarak kaydedilmiştir. Kasım 2020'de kurulan sistem üzerinden alınan verilerde Ocak 2021 itibariyle kayıt işlemine başlanmış ve toplam 39.062 veri gerçek zamanlı olarak izlenmiş ve web tabanlı kaydedilmiştir. Şekil 4.6 ve 4.7'den görülebileceği üzere, kayıt ekranı üzerinden gerçek zamanlı izleme web tabanlı olarak yapılabilmektedir. Burada sistemin çevresel etkilerinin yanı sıra tüm sistem bileşenlerine ait değerler çevrimiçi olarak izlenebilmektedir. Elde edilen veriler Şekil 4.8'de

görülebileceği üzere aktif güç, gerilim akım, invertör ve ortam sıcaklığı gibi her faza ilişkin bilgiler sistemden csv formatında çekilebilmektedir.



Şekil 4.6. Devreye alınan uzaktan erişim izleme sistemi

Şekil 4.7 'deki üretilen toplam enerji miktarı ve çevreye katkısı gösterilmektedir.



Şekil 4.7. Arayüzdeki diğer sistem eleman bileşenlerinin değerleri


Sistemden elde edilen ön işlenmiş 5 dakikalık örnek verilere ilişkin toplam çıktı görüntüsü Şekil 4.8'de görülmektedir.

Collection Time	Device SN	Inverter status	Phase A voltage (V)	Phase B voltage (V)	Phase C voltage (V)	Grid phase A current	Grid phase B current	Grid phase C current
18/04/2021 19:00:00	HV19A0045971	512	231.900	228.700	232.400	0.405	0.404	0.421
18/04/2021 19:05:00	HV19A0045971	2	231.100	229.200	233.800	0.000	0.000	0.000
18/04/2021 19:10:00	HV19A0045971	2	232.500	226.400	232.700	0.000	0.000	0.000
18/04/2021 19:15:00	HV19A0045971	2	230.000	227.400	232.700	0.000	0.000	0.000
18/04/2021 19:20:00	HV19A0045971	2	231.100	227.900	232.700	0.000	0.000	0.000
19/04/2021 06:35:00	HV19A0045971	0	233.000	229.000	233.100	0.000	0.000	0.000
19/04/2021 06:40:00	HV19A0045971	2	233.200	229.200	233.200	0.000	0.000	0.000
19/04/2021 06:45:00	HV19A0045971	2	233.300	229.100	233.600	0.000	0.000	0.000
19/04/2021 06:50:00	HV19A0045971	2	233.300	228.700	233.400	0.000	0.000	0.000
19/04/2021 06:55:00	HV19A0045971	2	232.200	229.200	233.700	0.000	0.000	0.000
19/04/2021 07:00:00	HV19A0045971	2	231.400	228.600	234.100	0.000	0.000	0.000
19/04/2021 07:05:00	HV19A0045971	2	232.600	228.700	233.100	0.000	0.000	0.000
19/04/2021 07:10:00	HV19A0045971	2	232.100	227.300	232.800	0.000	0.000	0.000
19/04/2021 07:15:00	HV19A0045971	512	232.800	228.300	233.400	0.413	0.409	0.440
19/04/2021 07:20:00	HV19A0045971	512	230.800	228.100	234.200	0.417	0.409	0.435
19/04/2021 07:25:00	HV19A0045971	2	231.700	228.100	233.200	0.000	0.000	0.000
19/04/2021 07:30:00	HV19A0045971	2	232.200	227.900	232.800	0.000	0.000	0.000
19/04/2021 07:35:00	HV19A0045971	2	231.300	227.500	231.600	0.000	0.000	0.000
19/04/2021 07:40:00	HV19A0045971	2	232.200	228.400	232.400	0.000	0.000	0.000
19/04/2021 07:45:00	HV19A0045971	512	231.100	228.000	233.300	0.466	0.463	0.486
19/04/2021 07:50:00	HV19A0045971	512	230.600	227.900	232.800	0.436	0.434	0.458
19/04/2021 07:55:00	HV19A0045971	512	232.000	226.200	231.800	0.417	0.407	0.443
19/04/2021 08:00:00	HV19A0045971	512	233.700	227.400	232.800	0.508	0.501	0.523
19/04/2021 08:05:00	HV19A0045971	512	232.900	228.100	232.600	0.512	0.500	0.541
19/04/2021 08:10:00	HV19A0045971	512	230.300	228.500	231.000	0.456	0.451	0.497

Şekil 4.8. Sistemden elde edilen ön işlemlenmiş 5 dakikalık örnek verilere ilişkin toplam çıktı görüntüsü

Şekil 4.9’da mevsimsel olarak alınan verilere ilişkin 5’er dakikalık zaman ufku için Ocak-Eylül 2021 tarihleri arasında tüm mevsim örneklerini içeren veriler gösterilmektedir. Burada sistem çıkışından alınan aktif güç değerleri kullanılmıştır. Tez çalışmasının hedefinde sistem algoritmasına ek yük getirebilecek sıcaklık, basınç, nem ve rüzgar gibi meteorolojik verilerin model girişinde kullanılması yerine geçmiş adımlı verilerle sistem modelin eğitilerek kısa dönemli tahminlerin yapılmasıdır. Bu kapsamda her bir mevsime ilişkin aylardan örnekler alınarak analizler gerçekleştirilmiştir. Verilerin çözünürlüğü 5 dakikalık zaman ufku ile sınırlıdır ki bu da bizlere çok kısa dönemli tahmin modellerinin geliştirilmesine olanak sağlamaktadır. Çözünürlüğün yüksek olması değişimler üzerinde ani dalgalanmaları barındırabilmesine karşın sistemi doğru çözümleme noktasında yetenek sağlamaktadır. Tüm veriler model girişinde eğitim ve test verileri olarak ayrıştırılmıştır. Sonrasında analiz edilecek olan model türüne göre ya ön işleme adımıyla alt bileşenlerine ayrılarak tahmin yaklaşımının girişine ya da doğrudan model girişine yerleştirilmiştir. Toplam veri 39.062 olup, bunun %70’i (27.343 veri) eğitim için, %30’u (11.719 veri) test amaçlı ayrılmıştır. Bu işlem, eğitim ve test setleri ile 50 kez tekrarlanmış olup tüm çalışmaların ortalama hata performans kriteri son olarak tahmin doğruluğu olarak alınmıştır. Çalışma kapsamında her bir mevsim örneğine ait birer aylık


veriler ayrı ayrı analiz edilerek karşılaştırmalı sonuçları sonraki bölümlerde ayrı ayrı sunulmuştur.



Şekil 4.9. Ocak-Eylül 2021 tarihleri arasında 5'er dakikalık zaman ufku için izlenen veri seti ve mevsimlere göre değişimleri.

Fotovoltaik güç tahmini çalışmalarında karşılaşılan önemli bir zorluk da eğitim veri setinin seçilmesi durumudur. Elektrik yükü tahmini gibi diğer tahmin çalışmalarında geçmiş yıllara dayalı olarak ağ eğitim veri seti oluşturmak genellikle kolayken, fotovoltaik güç tahmininde güneş ışınımının kesikli, kararsız ve değişken doğasından kaynaklanan birçok zorlukla karşılaşılır. Temel bir yöntem, sıcaklık, basınç ve nem gibi meteorolojik parametrelerle güneş ışınımını regresyon analizleri kullanarak tahmin etmektir. Ancak bu yöntem hassas, güvenilir ve sürekli bir yaklaşım sunamayabilir. Tez çalışması çerçevesinde ilk bölümlerde de belirtildiği gibi, fotovoltaik güç tahmininde giriş veri seti olarak geçmiş zaman aralıklarında bulunan güç çıkışları ile gelecekteki aktif güç verileri kullanılarak eğitim veri seti oluşturulur.

Bu eğitim veri seti, ağın giriş ve hedef verilerinden oluşmakta ve Şekil 4.10'da gösterildiği gibi kaydırmalı pencereleme tekniği ile modellenmektedir.



Şekil 4.10. Tez çalışmasında kullanılan kaydırmalı pencereleme tekniği.

Veriler ağ girişlerine verilmeden önce eşitlik 4.1'de gösterilen şekilde normalizasyonu yapılarak ölçeklendirilmiştir.

$$X_{norm} = [X_{gercek} - X_{min}] / [X_{maks} - X_{min}] \quad (4.1)$$

Burada giriş değerlerinin minimumu ve maksimum değerleri sırasıyla X_{min} ve X_{maks} ile gösterilirken, X_{gercek} orijinal veriyi nitelemektedir. Normalizasyon adımındaki amaç verileri belirli bir ölçek altında tutarak ağı eğitimi verimliliğini artırmaktır.


4.2. Mevsimsel Bazlı Veri Analizleri

4.2.1. MLP Tabanlı Tahmin Analizleri ve Sonuçları

Tez çalışmasının bu bölümünde farklı ayrıştırma metotlarına dayalı olarak yapılan MLP tabanlı analiz sonuçları paylaşılmaktadır. Bu bölümdeki çalışmaların amacı hem ayrıştırma metotlarının birbirlerine göre olan üstünlüklerini konvansiyonel bir tahmin modeli ile ortaya koyabilmek hemde her bir mevsimden seçilmiş olan aylardaki performanslarını karşılaştırabilmektedir. Kış mevsimi için Ocak, ilkbahar için Nisan, yaz için Temmuz ve sonbahar için Eylül ayı seçilerek bu aylar için PV panellerden alınan aktif güç verileri analiz edilmiştir. Tüm aylara ilişkin model sonuçları ayrı ayrı paylaşılmıştır. Burada kullanılan modellerde EMD, EEMD, CEEMDAN ve SWD yaklaşımlarının yanı sıra Liu ve arkadaşları (Liu vd., 2021:5), tarafından 2021 yılında önerilen EMD'nin geliştirilmiş versiyonu olan IEMD'nin de performansı incelenmiştir.


Uygulanan model ayrıştırma, tahmin ve birleştirme olarak üç ayrı aşamayı içermektedir. Orijinal veriler normalize edildikten sonra farklı ayrıştırma metotları ile sırasıyla alt bileşenlerine ilk aşamada ayrıştırılmıştır. Tahmin aşamasında ise farklı MLP modelleri her bir alt bileşen için ayrı ayrı oluşturularak tahmin çıkışı alınmıştır. Son aşama olan birleştirme fazında ise her bir alt bileşenden elde edilen ayrık tahmin sonuçları bu aşamada toplanarak nihai tahmin sonucu elde edilmiş olunur.

İlk aşama olan ayrıştırma adımı, Şekil 4.11'de de gösterildiği gibi Ocak ayı için orijinal sinyal alt bileşenleri olan öz kip fonksiyonlarına (IMF) ayrıştırılmıştır. Burada yüksek frekanslı bileşen IMF₁ ile gösterilirken düşük frekanslı bileşen IMF₈ ile ifade edilir ve R_n ise artık sinyali göstermektedir. Ayrıştırma sonuçları, her sinyalin farklı özelliklere sahip olduğunu ve bu da seriye gömülü farklı doğal salınım modlarına işaret ettiğini göstermektedir.



Şekil 4.11. Ocak ayı için EMD tabanlı ayrıştırma sonuçları

EMD'nin mod karıştırma problemini ortadan kaldırmak için Gauss beyaz gürültüsünün istatistiksel özelliklerinden yararlanan EEMD'de karşılaştırma yapmak için bu çalışmada kullanılmıştır. EEMD kullanılarak ayrıştırılan ham verilerin IMF'leri Şekil 4.12'de gösterilen Nisan ayına ait 12 ayrı IMF bileşeni ve bir artık sinyal bileşeni de dahil olmak üzere sunulmuştur. CEEMDAN algoritması ise EEMD'ye dayalı sonlu uyarlamalı beyaz gürültü ekler ve beyaz gürültü ekledikten sonra EEMD'nin eksiklik ve yeniden yapılandırma hatası sorunlarının üstesinden gelir. Şekil 4.13'te ise CEEMDAN kullanılarak ayrıştırılmış Temmuz ayına ait alt bileşen serisi gösterilmektedir. IEMD için ise benzer alt bileşen yapıları gözlemlenmesi sebebiyle ayrı olarak aylık bazda sunulmamıştır.




Şekil 4.12. Nisan ayı için EEMD tabanlı ayrıştırma sonuçları




Şekil 4.13. Temmuz ayı için CEEMDAN tabanlı ayrıştırma sonuçları

Sürü ayrıştırması (SWD) adı verilen, durağan olmayan sinyallerin analizine yönelik akıllı bir yaklaşım, EMD tabanlı modellerle karşılaştırma amacıyla ilk kez güneş verilerine bu tez çalışması kapsamında uygulanmıştır. 2020 yılında SWD güneş enerjisi tahmini için (Dokur, 2020:4) kullanılmış olsa da bu yaklaşımın diğer ayrıştırma modellerine olan üstünlüğünden ziyade hibrit kullanımın önemine dikkat çekilmiştir. Bu amaçla Apostolidis ve Hadjileontiadis'in biyomedikal sinyaller için önerdiği SWD, bu çalışmada karşılaştırma amacıyla kullanılmıştır. Şekil 4.14'te SWD algoritması ile ayrıştırılan Eylül ayı verileri sunulmaktadır. Genellikle bu tür ayrıştırmalarda en yüksek frekans bileşeninin tahmin doğruluğu diğer alt bileşenlerin tahmin doğruluğundan daha düşük gözlemlenebilmektedir.




Şekil 4.14. Eylül ayı için SWD tabanlı ayrıştırma

Ayrıştırma adımından sonra elde edilen tüm alt bileşenler için ayrı MLP modelleri oluşturulmuştur. Burada kayan pencere tekniği kullanılarak MLP girişine iki adım öncesinden ve bir adım sonrasında verinin mevcut değeri tahmin edilmiştir. Hibrit modellerin Ocak ve Temmuz ayına ait karşılaştırmalı test sonuçları sırasıyla Şekil 4.15 ve 4.16'da sunulmaktadır.



Şekil 4.15. Ocak ayı zaman serisine ilişkin karşılaştırmalı tahmin sonuçları



Şekil 4.16. Temmuz ayı zaman serisine ilişkin karşılaştırmalı tahmin sonuçları

Modellerinin performans karşılaştırmalarının sadece zaman serisi üzerindeki grafiklerden ele almak aşım noktalarındaki değişimleri ve bunlara olan göstermek için avantaj sağlasada genel olarak model performansının uyumluluğunu gösterme adına tek başına şüphesiz ki yeterli değildir. Bu sebeple literatürde de sık kullanılan hata performans metrikleri bu tez çalışması kapsamında da model performanslarının karşılaştırılması adına ele alınmıştır. Tüm modellerin performansları, test veri setinde tahmin edilen değerin hedef değerden sapması dikkate alınarak değerlendirilmiştir. Bu amaçla bu çalışmada modellerin performansını doğrulamak amacıyla RMSE, MSE ve MAE metrikleri kullanılmıştır. Bu metriklerle ilişkin eşitlikler denklem (4.2), denklem (4.3) ve denklem (4.4)'te gösterilmiştir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \tilde{y}_i)^2}{N}} \quad (4.2)$$

$$MSE = \frac{\sum_{i=1}^N (y_i - \tilde{y}_i)^2}{N} \quad (4.3)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \tilde{y}_i| \quad (4.4)$$

Burada y_i ve $\tilde{y}_i$ sırasıyla gerçek ve tahmin değerlerini göstermektedir. N ise performans karşılaştırması için kullanılan toplam veri sayısını göstermektedir. MAE, tahmin sonuçlarının ortalama mutlak tahmin hatası konusunda yorumlama yapmamızı sağlarken, RMSE/MAE kullanmanın fiziksel temeli ise tüm test seti için güneş enerjisi tahmininin genel hatasını ifade etmektedir.

Ocak ayına ilişkin hata performans metrikleri kullanılarak yapılan model karşılaştırma sonuçları Tablo 4’de sunulmuştur. Tablo 4.1’de Ocak ayı hata performans metriği sonuçları incelendiğinde EMD-MLP hibrit yaklaşımına ait RMSE, MSE ve MAE hata performans metrikleri sırasıyla 0,3792, 0,1438 ve 0,2252 olarak bulunmuş ve model performansının diğer modellere göre daha iyi olduğu sonucuna ulaşılmıştır. EEMD-MLP ve CEEMDAN-MLP yaklaşımları, EMD-MLP hibrit yaklaşımına göre rekabetçi bir sonuç göstermektedir. Ancak model performans başarımı en düşük olan tekil MLP mimarisinde ise sırasıyla RMSE, MSE ve MAE metriklerine 0,5933, 0,352 ve 0,3224 değeriyle ulaşılmıştır. IEMD tabanlı hibrit model performansı da tekil modellerle benzer şekilde düşük olarak bulunmuştur. Veri niteliğine göre model performanslarının değişkenlik göstereceği açık olmasına karşın Ocak ayı özelinde özellikle EEMD ve CEEMDAN yaklaşımlarının kullanılmasında beyaz gürültü ekleme adımının avantaj sağlamadığı görülmektedir.

Tablo 4.1. Ocak Ayı Tüm Hibrit Modellerin Karşılaştırmalı Hata Performans Metrikleri Sonuçları

		RMSE	MSE	MAE
OCAK	MLP	0.5933	0.3520	0.3224
	EMD-MLP	0.3792	0.1438	0.2252
	EEMD-MLP	0.4106	0.1686	0.2324
	CEEMDAN-MLP	0.4454	0.1989	0.1955
	SWD-MLP	0.4489	0.2015	0.2977
	IEMD-MLP	0.5143	0.2645	0.2866

Tablo 4.2’de sunulan Nisan ayı sonuçlarında ise CEEMDAN-MLP hibrit yaklaşımının RMSE, MSE ve MAE hata performansı metriklerine sırasıyla 0,1415, 0,0200 ve 0,0647 olarak bulunmuş ve performansının diğer modellere göre daha iyi olduğu sonucuna varılmıştır. EMD-MLP ve EEMD-MLP yaklaşımları, CEEMDAN-MLP’ den sonra diğer düşük hata metriklerine sahip metotlar olarak görülmektedir. En düşük model doğruluğuna sahip sonuçlar sırasıyla 1,7036, 2,9021 ve 1,0653 RMSE, MSE ve MAE değerleri ile IEMD-MLP yaklaşımı olduğu gözlemlenmiştir. MLP tekil modelinde diğer hibrit modellere göre başarımının düşük olduğu gözlemlenmiştir. Nisan ayı için sonuç olarak diğer modellere göre çok daha düşük hata performans metriğine sahip CEEMDAN-MLP yaklaşımı en uygun sonucu verdiği görülmektedir.

Tablo 4.2. Nisan Ayı Tüm Hibrit Modellerin Karşılaştırmalı Hata Performans Metrikleri Sonuçları

		RMSE	MSE	MAE
NİSAN	MLP	0.3486	0.1215	0.2154
	EMD-MLP	0.2651	0.0703	0.1319
	EEMD-MLP	0.3132	0.0981	0.2441
	CEEMDAN-MLP	0.1415	0.0200	0.0647
	SWD-MLP	0.3283	0.1078	0.2054
	IEMD-MLP	1.7036	2.9021	1.0653

Temmuz ayına ilişkin hata performans metriklerine ait karşılaştırmalı model sonuçları Tablo 4.3’te sunulmaktadır. Tablodan da görülebileceği gibi yine CEEMDAN-MLP hibrit modelinin sonuçları 0.3458, 0.1196, ve 0.1405 RMSE, MSE ve MAE değerleri ile en yüksek model başarımına ve en düşük hata performans metriğine sahip olduğu gözlemlenmiştir. Sırasıyla EMD ve EEMD tabanlı oluşturulan modeller yine diğer düşük hata performans metriklerine sahiptir. Temmuz ayı verilerinden de görülebileceği gibi hibrit modellerin tekil MLP modelinden çok daha iyi sonuç verdiği sonucuna ulaşılabilir. IEMD ve SWD ayrıştırma

adımlarına dayalı modellerin EMD tabanlı modellere göre daha düşük performansa sahip olduğu bu ay için gözlemlenmiştir.

Tablo 4.3. Temmuz Ayı Tüm Hibrit Modellerin Karşılaştırmalı Hata Performans Metrikleri Sonuçları

		RMSE	MSE	MAE
TEMMUZ	MLP	0.5875	0.3452	0.3046
	EMD-MLP	0.3638	0.1324	0.1894
	EEMD-MLP	0.4416	0.1950	0.3088
	CEEMDAN-MLP	0.3458	0.1196	0.1405
	SWD-MLP	0.4635	0.2148	0.2204
	IEMD-MLP	0.4867	0.2369	0.2472


Tüm karşılaştırmalı modeller için Tablo 4.4'te Eylül ayına ilişkin hata performans metriği sonuçlarına bakıldığında yine CEEMDAN-MLP hibrit yaklaşımının sırasıyla RMSE, MSE ve MAE hata performans metriklerinin 0.4619, 0.2134 ve 0.2258 bulunarak model başarımının diğer modellere göre daha iyi olduğu sonucuna ulaşılmıştır. SWD-MLP ve EEMD-MLP yaklaşımları CEEMDAN-MLP hibrit yaklaşımına rekabetçi bir sonuç gösterse de özellikle IEMD ayrıştırma tekniğinde ayrıştırmış sinyaller için oluşturulan tahmin sonuçlarının toplamının negatif değerli bulunması hata performans metriğini artırdığı gözlemlenmiştir. Bu da IEMD yaklaşımının en düşük hata performans değerine sahip olmasına neden olmuştur. Eylül ayı için sonuç olarak CEEMDAN-MLP hibrit yaklaşımı daha iyi sonuç verirken IEMD-MLP en düşük hata performansı göstermektedir.

Tablo 4.4. Eylül Ayı Tüm Hibrit Modellerin Karşılaştırmalı Hata Performans Metrikleri Sonuçları

		RMSE	MSE	MAE
EYLÜL	MLP	0.6737	0.4539	0.3462
	EMD-MLP	1.2688	1.6098	0.4835
	EEMD-MLP	0.4674	0.2184	0.3181
	CEEMDAN-MLP	0.4619	0.2134	0.2258
	SWD-MLP	0.5318	0.2828	0.2681
	IEMD-MLP	2.2749	5.1751	0.8344

Hata performansını daha detaylı incelemek için ve ayrıştırma metodlarının birbirine olan üstünlüklerini ayrıntılı bir şekilde ortaya koyabilmek için bu tez çalışmasında Taylor diagramı da kullanılarak istatistiksel bir karşılaştırma da yapılmıştır. Modellere ilişkin standart sapma, kök ortalama kare sapma (RMSD) ve korelasyon katsayısı arasındaki ilişkiyi tanımlamak için

bu tez çalışmasında, Şekil 4.17'de sunulan Taylor diyagramını sunulmuştur. Şekil 4.17'deki sonuçlara göre, korelasyon katsayısı değeri 1'e ne kadar yakınsa, gerçek veriler ile tahmin edilen veriler arasındaki ilişki o kadar doğrusal olur. Ancak grafikteki standart sapma ve RMSD değerleri ne kadar düşük olursa modelin performansı da o kadar yüksek olur. Buna göre Şekil 4.17'ye göre kırmızı toplamı temsil edilen CEEMDAN-MLP modeli en iyi tahmin sonucunu sunmaktadır.




Şekil 4.17. Temmuz ayı zaman serisine ilişkin karşılaştırmalı tahmin sonuçları

Tüm istatistiksel sonuçlar incelendiğinde CEEMDAN tabanlı hibrit modelin genel performans kapasitesi aylık bazda en iyi sonuçları verdiği gözlemlenmiştir. CEEMDAN yaklaşımının hibrit modelde güneş enerjisi tahmini için daha iyi bir veri modelleme aracı olarak kabul edilebileceğinin açık bir göstergesidir. Bu çalışmada SWD tabanlı modelinin üstünlüğü beklense de genel olarak EMD tabanlı modellerde daha yüksek doğruluk oranlarına ulaşılmıştır. Bu bize ayrıştırılan her sinyal için en uygun modelin seçilemediği durumunu göstermektedir. Aynı değerlerden karşılaştırma yapılmasının uygun olacağı düşünülerek MLP mimarileri aynı olarak ele alınmıştır. Bu bölümde yapılan analizlerde aynı tahmin mimarisinde farklı ayrıştırma metotlarının performansı incelenerek CEEMDAN ayrıştırma metodunun üstünlüğü

ortaya koyulmuştur. Tezin bir sonraki aşamasında ise en iyi model sonucuna ulaşılan CEEMDAN tabanlı ayrıştırma modelinin seçilerek daha yenilikçi ve hızlı bir yaklaşımın güncel ve geleneksel modellere göre performansları karşılaştırmalı olarak sunulacaktır.

4.2.2. Kernel ELM tabanlı Hibrit Tahmin Model Sonuçları ve Analizleri

Tez çalışmasının bir önceki bölümünde ayrıştırma metotlarının geleneksel tahmin modeli ile hibrit yapısının karşılaştırılması yapılarak elde edilen sonuçlara göre en iyi model sonucu verdiği bulunan CEEMDAN yaklaşımının bu bölümde yenilikçi bir modelle hibrit yapısının model önerimi sunulmuştur. Bu kapsamda literatürde hızlı bir yaklaşım olan ELM tabanlı oluşturulan tahmin modeli bu tez çalışmasında referans olarak alınmıştır. Buna ek olarak Kernel fonksiyonları ile parametre optimizasyonu sayesinde model performans artırımı da yapılmıştır. Sonuç olarak tez çalışmasının bu bölümünde CEEMDAN-Kernel-ELM hibrit modeli önerilmiş bu modelin hem tekil hem hibrit hemde güncel derin öğrenme modelleriyle karşılaştırması sunularak model performansı detaylı olarak incelenmiştir. Analizde, sunulan her mevsime ait örnek veri setleri ile yine ilgili ayların orijinal zaman serisi kullanılmıştır. Modellerin farklı özelliklerdeki performansını göstermek amacıyla sonuçlar her sezonun birer aylık dönemleri için yine gerçekleştirilmiştir. Bu kapsamda önerilen CEEMDAN-Kernel-ELM yaklaşımının akış şeması Şekil 4.18'de sunulmaktadır.



Şekil 4.18. Önerilen modelin akış şeması.


Önerilen hibrit yöntem ayrıştırma, tahmin ve birleştirme olmak üzere üç farklı modül üzerinden yine uygulanmıştır. Ayrıştırma sayesinde normalize edilen orijinal güneş enerjisi

verileri bu adımda farklı ayrıştırma yöntemleriyle alt bileşenlerine ayrılmıştır. Tahmin aşamasında ayrıştırılan her sinyal için ayrı Kernel-ELM modelleri oluşturularak tahmin uygulanmıştır. Burada elde edilen tüm sonuçlar son adımda toplanarak hibrit modelin çıktısı elde edilmiştir. CEEMDAN yaklaşımı ile ayrıştırılan sinyallere ilişkin örnek alt bileşenler bir önceki bölümde detayları ile sunulmuştu. Burada özellikle en yüksek frekanslı bileşenin ilk alt bileşen olduğu ve en önemli tahmin zorluğunun bu öz kip fonksiyonunda gözlemlendiği söylenebilir. Burada seriye gömülü çeşitli doğal salınım modlarındaki benzersiz niteliklerin ayrı ayrı tahmin edilmesi genel modelin doğruluğunda avantaj sağlamaktadır.

CEEMDAN-Kernel-ELM'nin performansını karşılaştırmak için analizde LSTM ve tekil Kernel-ELM modelleri de kullanılmıştır. Önerilen modeli LSTM ile karşılaştırmanın amacı, iyi bilinen derin öğrenme yaklaşımının üstünlüğünü göstermektir. LSTM son yıllarda özellikle zaman serisi analizinde kullanılmaya başlanması önerilen modeli karşılaştırma adına yönlendirmiştir. Bu çalışmada LSTM modelindeki gizli katman sayısı güneş verileri için 4 adet uygulanmıştır. Dört katman için gereken LSTM ünitesi sayısı 100, 100, 75, 75 olarak hesaplanmıştır. Küme büyüklüğü (batch size) 16 ve maksimum eğitim iterasyonu (epoch) sayısı 100 olarak seçilmiştir. Uygulanan LSTM modelinde Adam optimizasyonu kullanılmıştır (Huang vd.,2014:5). Öğrenme oranı 0,005 olarak seçilmiştir. Model parametrelerinin ilk seçim kriterleri rastgelliği göz önüne alındığında, hataları azaltmak için tüm LSTM modelleri 1000 kez test edilmiştir. Ayrıca hibrit modellerin üstünlüğünü göstermek amacıyla analize tekil bir Kernel-ELM modeli de eklenmiştir. Buna ek olarak bir önceki bölümde ele alınan iki ayrı hibrit modelde çalışmada karşılaştırma amaçlı olarak eklenmiştir.

Örnek bir aya (Temmuz) ilişkin test sonuçlarının karşılaştırmalı tahmin değişimi Şekil 4.19'da paylaşılmaktadır. Buna göre mor rengi ile gösterilen önerilen model olan CEEMDAN-Kernel-ELM yaklaşımının açık mavi ile gösterilen gerçek değerlere olan uyumu görülmektedir. Şekilden de görülebileceği gibi EMD tabanlı hibrit modelin özellikle sıfıra yakınsama gösteren minimum noktalarında model başarımı düşüktür. Bu da ayrıştırma esnasında alt bileşenlerden bazılarının negatif değere gitmesi sebebiyle gözlemlendiği sonucuna ulaşılabilir. Buna ek olarak tekil model olan Kernel-ELM modelinde ise bulutsuzluk olan periyotlarda gözlemlenen kesiksiz dönemlerde minimum değerlerdeki trendi takip etmesine karşın maksimum değerlerdeki değişimlerde model performansı önerilen modele göre düşüklüğü kolaylıkla gözlemlenebilmektedir. Yine SWD tabanlı modelin kesikli dönemlerdeki başarımı yüksek olmasına karşın ekstra salınım bileşenlerinin eklenmesi doğru değişimleri tahmin etmede

zorluğa sebep olmaktadır. LSTM modelinde ise maksimum değerlerdeki değişimde oldukça fazla bir hata payı gözlemlenmiştir.



Şekil 4.19. Temmuz zaman serisi için test sonuçlarının tahmin edilmesi

Test sonuçlarının şekil üzerinden genel başarımlar değerlendirilmesi yapılabilmeye karşın nihai en iyi modelin bir önceki bölümde de ele alındığı şekilde hata performans metrikleri ile verilmesi ve yorumlanması model performanslarının açıklanabilmesi adına daha anlamlı sonuçlar gösterecektir. Bu sebeple bir önceki bölümde de ele alınan hata performans metrikleri ile model performansları karşılaştırılmıştır. Aynı zamanda diğer aylara ilişkin tahmin sonuçları benzer performans göstermesi ve detaylı yorumlamaya imkan tanıyamaması nedeniyle tekrar paylaşılmamış olup bunun yerine karşılaştırmalı hata performans metrikleri ile tüm aylara ilişkin sonuçlar paylaşılmıştır. Buna göre Tablo 4.5'te tüm aylara ilişkin hata performans kriterlerinin karşılaştırmalı sonuçlarını göstermektedir.

Tablo 4.5. Güneş Enerjisi Veri Setleri İçin Önerilen Modelin Tahmin Sonuçlarının Karşılaştırmalı Analizi

Aylar	Metotlar	RMSE	MSE	MAE
Ocak	EMD-MLP	0.3792	0.1438	0.2252
	SWD-MLP	0.4489	0.2015	0.2977
	Kernel-ELM	0.5902	0.3484	0.3741
	LSTM	0.6102	0.3723	0.3301
	Önerilen Model	0.2546	0.1245	0.1870
Nisan	EMD-MLP	0.2651	0.0703	0.1319
	SWD-MLP	0.3283	0.1078	0.2054
	Kernel-ELM	0.3317	0.1100	0.1777
	LSTM	0.3409	0.1162	0.2024
	Önerilen Model	0.1820	0.0331	0.1226
Temmuz	EMD-MLP	0.3638	0.1324	0.1894
	SWD-MLP	0.4635	0.2148	0.2204
	Kernel-ELM	0.6372	0.4060	0.3974
	LSTM	0.5832	0.3401	0.2983
	Önerilen Model	0.3460	0.1197	0.1396
Eylül	EMD-MLP	1.2688	1.6098	0.4835
	SWD-MLP	0.5318	0.2828	0.2681
	Kernel-ELM	0.7096	0.5035	0.4551
	LSTM	0.6707	0.4499	0.3443
	Önerilen Model	0.4111	0.1690	0.2217

Tablodan da görülebileceği gibi önerilen hibrit modelin (CEEMDAN-Kernel-ELM) Ocak ayına ait RMSE, MSE ve MAE hata performansı metrikleri sırasıyla 0,2546, 0,1245 ve 0,1870 olarak bulunmuş ve model performansının diğer modellere göre çok daha iyi olduğu düşük performans metrikleri ile birlikte görülmektedir. Yine aynı ay için EMD-MLP yaklaşımı CEEMDAN-Kernel-ELM hibrit modeline göre rekabetçi sonuçlar gösterse de önerilen model tüm aylara göre daha iyi doğruluğa sahiptir. LSTM modelinin sonucu yine bu ay için 0,6102, 0,3723 ve 0,3301 sırasıyla RMSE, MSE ve MAE değerleri ile oldukça düşük bir performans göstermektedir. Tekil modellerin hibrit modellere olan üstünlükleri açıkça görülsede Kernel-ELM tabanlı modelin LSTM'e göre daha iyi sonuç verdiği gözlemlenmektedir.


İlkbahar dönemi için yine önerilen modelin diğer modellere göre RMSE, MSE ve MAE hata performans metrikleri sırasıyla 0.1820, 0.0331 ve 0.1226 bulunmuş olup yine diğer modellere göre çok daha iyi sonuç verdiği görülmektedir. EMD tabanlı hibrit model performansı bu yaklaşıma en yakın performans değerini göstersedeyse SWD tabanlı hibrit model

sonuçları neredeyse tekil modellerle aynı rekabetçi sonuçlara ulaşmıştır. LSTM yine Nisan ayı içinde benzer şekilde en düşük performansı göstermektedir.

Temmuz ayı için elde edilen hata performans değerleri dikkate alındığında Kernel-ELM tekil modelinin en düşük performansı gösterdiği gözlemlense de önerilen CEEMDAN-Kernel-ELM hibrit modeli en yüksek doğruluğa 0.3460, 0.1197 ve 0.1396 değerleri ile sırasıyla RMSE, MSE ve MAE hata performans metrikleri ile ulaştığı gözlemlenmiştir. Yine EMD tabanlı hibrit modelin SWD tabanlı ayrıştırma içeren modele göre daha iyi sonuç verdiği gözlemlenmektedir.

Eylül ayı dikkate alındığında önerilen modelin hata değerinin çok daha düşük olduğu görülmektedir. Önerilen yöntem, Eylül ayındaki EMD-MLP modeline kıyasla RMSE performans hatası ölçüsünü %67,59 oranında azalttığı görülmektedir. SWD-MLP hibrit bir model olsa da bağımsız Kernel-ELM, Nisan gibi bazı aylar için benzer performans ölçümleri gösterir. Ocak, Nisan ve Temmuz ayları dikkate alındığında en düşük model performansına LSTM'nin sahip olduğu görülmektedir. Burada hiperparametreler tüm LSTM modelleri için aynı şekilde seçilmiştir. Şüphesiz ki LSTM'nin model performansını artırmak için bazı farklı parametrelerle eğitilebilir. Ancak bu tez çalışması LSTM modelini geliştirmek yerine daha hızlı bir model olan hibrit Kernel-ELM yöntemine odaklanmıştır. Tablo 8'de gösterilen verilere göre CEEMDANKernel-ELM; EMD-MLP, SWD-MLP, tekil Kernel-ELM ve LSTM gibi tahmin modelleriyle karşılaştırıldığında en düşük RMSE, MSE ve MAE metrikleriyle diğer tüm tahmin modellerinden daha iyi performans göstermektedir.

Yine tez çalışmasının bu bölümünde standart sapma, RMSD ve korelasyon katsayısı arasındaki ilişkiyi açıklamak için, Şekil 4.20'de sunulan Taylor diyagramını kullanılmıştır. Gerçek veri ile tahmin edilen veri arasındaki ilişkiyi ortaya koyabilmek için yine korelasyon katsayısı değeri 1'e yakınsamasıyla incelenmiştir. Bununla birlikte grafikteki standart sapma ve RMSD değerleri ne kadar düşük olursa modelin performansı da o kadar yüksek olacağı açıktır. Şekil 4.20'ye göre siyah üçgenle temsil edilen CEEMDAN-Kernel-ELM modeli en iyi tahmin sonucunu sunmaktadır.



Şekil 4.20. Güneş verileri tahmin modellerinin Taylor diyagramı.

Sonuç olarak, önerilen hibrit modelin genel performans kapasitesi aylık bazlı mevsimsel analizler için en iyi sonuçları vermiştir. Tüm bu sonuçlar incelendiğinde önerilen CEEMDAN- Kernel-ELM hibrit modelinin kısa dönemli güneş enerjisi tahmini için daha iyi bir veri modelleme aracı olarak kabul edilebileceği sonucuna ulaşılabilir. Bununla birlikte literatürde farklı veri setleri için üstün başarımlar gösteren SWD tabanlı ayrıştırma mevsimsel bazlı aylık güneş enerjisi verileri için önerilen modele ve EMD tabanlı hibrit modele göre daha düşük performans göstermiştir. Bunun ayrıştırılan her sinyal için en uygun modelin seçilemediği durumundan kaynaklandığı sonucuna ulaşılabilir. Buna ek olarak her veri setinin kendi öznelitelerine göre alt bileşenleri oluşturma da başarımının veri setine bağlı olduğu açıktır.

5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, güneş enerjisi tahmini için CEEMDAN ve Kernel-ELM modeline dayalı geliştirilmiş bir metodoloji sunulmaktadır. Hibrit model, ön işleme adımında CEEMDAN ve tahmin modelinde ise Kernel-ELM işleviyle birleştirir. CEEMDAN ayrıştırma modelinin seçiminde bu çalışmada geleneksel bir tahmin modelindeki başarımı dikkate alınarak yapılmıştır. Bu kapsamda tezin ilk aşamasında güncel ve farklı ayrıştırma tekniklerinin başarımı incelenerek diğer ayrıştırma modellerine göre en iyi sonucu veren CEEMDAN ayrıştırma algoritması seçilmiştir. Ayrıştırma adımı, daha doğrusal ve kararlı verilerin elde edilmesi nedeniyle modelin performansını artırdığı gözlemlenmiştir.

Tez çalışmasının ikinci aşamasında ortaya konulan yenilikçi tahmin modelinde Kernel fonksiyonu işlevi sürecinde, ELM'nin gizli katmanındaki rastgele ağırlıklarının ve değişkenlerinin ayarlanması sağlanmıştır. RMSE, MSE ve MAE gibi performans ölçümleri kullanılarak çeşitli tahmin modellerinin tahmin doğruluğu incelenmiş olup önerilen modelin üstün performansı ortaya koyulmuştur. BŞEÜ Yenilenebilir Enerji Laboratuvarı'ndan toplanan verilerin simülasyon sonuçları sayesinde CEEMDAN-Kernel-ELM modeli, diğer dört yöntemle (EMD-MLP, SWD-MLP, Kernel-ELM ve LSTM) karşılaştırıldığında güneş enerjisi tahmin doğruluğunu önemli ölçüde artırdığı sonucuna ulaşılmıştır. Önerilen hibrit modelin tahmin sonuçlarının, tekil modelin sonuçlarından daha iyi olduğu da doğrulanmıştır. Önerilen yöntem, Ocak ayı referans alındığında Kernel-ELM modeline kıyasla MAE performans hatası metriği dikkate alındığında %50 oranında azalttığı sonucuna ulaşılmaktadır. Sonuç olarak tüm aylar dikkate alındığında karşılaştırma sonuçları, önerilen CEEMDAN-Kernel-ELM'nin en düşük hata metrik değerlerine sahip tüm durumlarda diğer modellerden daha iyi performans gösterdiği sonucunu ortaya çıkarmıştır.

Sıcaklık, rüzgar hızı, nem gibi ilgili özelliklerin girdi özelliklerine dahil edilmesiyle gelecekte çok değişkenli modellerin geliştirilmesi de mümkündür. Ayrıca tahmin modelinin parametrelerinin belirlenmesinde meta-sezgisel yaklaşımların kullanılabileceği öngörülmektedir. Burada özellikle hibrit modelin performans süresi dikkate alınarak modele meta-sezgisel bir algoritmanın eklenmesi adımı gerçekleştirilmemiştir.

KAYNAKÇA

- Akhavein, M., & Firuzabad F.** (2011). A heuristic-based approach for reliability importance assessment of energy producers. *A.Energy Policy* 39(3), 1562-1568 Elsevier.
- Akil, M., Dokur E., & Bayındır R.** (2022). Smart coordination of predictive load balancing for residential electric vehicles based on EMD-Bayesian optimised LSTM. *IET Renewable Power Generation* 16(15) 3216-3232, Doi.org/10.1049/rpg2.12572
- Al-Dahidi, S., Ayadi, O., Adeeb, J., Alrbai, M., & Qawasmeh, B. R.** (2018). Extreme learning machines for solar photovoltaic power predictions, *Energies*, 11(10). 2725, DOI: 10.3390/en11102725.
- Alternatif Energy Tutorials.** (2023) <https://www.alternative-energy-tutorials.com/solar-power/solar-irradiance.html>.
- Apostolidis, G.K., & Hadjileontiadis, L. J.** (2017). Swarm decomposition: A novel signal analysis using swarm intelligence. *Elsevier*, 132(40-50). DOI: 10.1016/j.sigpro.2016.09.004
- Behera, M. K., Majumder, I., & Nayak, N.** (2018). Solar photovoltaic power forecasting using optimized modified extreme learning machine technique. *Engineering Science and Technology, an International Journal*, 21(3) 428–438, DOI: 10.1016/j.jestch.2018.04.013.
- BlagaAndreea, R., Nicoleta, S., Ciprian S., Marius D., & Viorel Badescu, P.** (2019). A current perspective on the accuracy of incoming solar energy forecasting. *Elsevier*, . 70(119-144) DOI: 10.1016/j.pecs.2018.10.003
- Bölat, V.** (2015). Güneş Enerjisinden Elektrik Üretiminin Önemi. (60026)
- Çağlar, A. E.** (2020). The importance of renewable energy consumption and FDI inflows in reducing environmental degradation: Bootstrap ARDL bound test in selected 9 countries. *Elsevier* , 264(10)- 121663, Doi.10.1016/j.jclepro.2020.121663
- Das, S.** (2020). Short term forecasting of solar radiation and power output of 89.6 kwp solar PV power plant., *Materials Today. Proceedings*, 39(5), 1959-1969, DOI: 10.1016/j.matpr.2020.08.449.
- Demirtaş, M., Akkoyunlu, N., Akkoyun, & E., Çetinbaş, İ.** (2020). Akıllı Şebekelerde Güneş Enerjisi Üretiminin Zamana Bağlı Olasılıksal Tahmini. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: 549704*

Denton, J.W. (1995). How good are neural networks for causal forecasting? *J. Bus. Forecasting* 14(17–20)

Dokur, E. (2017). Enerji Sistemlerinde Rüzgar Hızı Modellemesi İçin Geliştirilen Finsler Geometrisi Tabanlı Yeni Bir Yaklaşım Analizi Ve Uygulaması. (Yayınlanmış Doktora Tezi) *Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Bilecik*

Dokur, E. (2020). Swarm decomposition technique based hybrid model for very short-term solar PV power generation forecast. *Elektronika ir Elektrotechnika*, 26(3),79–83, DOI:10.5755/j01.eie.26.3.25898.

Dokur, E., Erdogan, N., Salari, M. E., Karakuzu, C., & Murphy, J. (2022). Offshore wind speed short-term forecasting based on a hybrid method: Swarm decomposition and meta-extreme learning machine, *Energy*, 248(123595), DOI: 10.1016/j.energy.2022.123595.

EİE.(2022). T.C.Enerji İşleri Genel Müdürlüğü Enerji Raporları. <https://enerji.gov.tr/eigm>

Ekolojist. (2023). Yenilenebilir Enerji İklim Değişikliği. <https://www.ekolojist.com>

Eseye, A.T., Zhang,J., & Zheng,D. (2018). Short-term photovoltaic solar power forecasting using a hybrid Wavelet-PSO-SVM model based on SCADA and Meteorological information. *Renewable Energy*, 118(357–367), DOI: 10.1016/j.renene.2017.11.011.

GEPA. (2022). Güneş Enerjisi Potansiyel Atlası. T.C.Enerji ve Tabii Kaynaklar Bakanlığı. <https://www.enerji.gov.tr>

Gernaat, D. E. H. J., de Boer, H. S., Daioglou, V., Yalew, S. G., Müller, C., & van Vuuren D. P. (2021). Climate change impacts on renewable energy supply. *Nature Climate Change*, 11 (119–125), DOI: 10.1038/s41558-020-00949-9.

Gun, A. R., Dokur, E., Yuzgec, U., & Kurban, M. (2023). Short-Term Solar Power Forecasting Based on CEEMDAN and Kernel Extreme Learning Machine. *Elektronika ir Elektrotechnika*, 29(2), 28, DOI :10.5755/j02.eie.33856

Han, Y. Wang, N. Ma, M.;Zhou, H. Dai, & S. Zhu, H. A. (2019). PV power interval forecasting based on seasonal model and nonparametric estimation algorithm. *Sol. Energy* , 184(515–526).

Huang, C.M.,Chen, S.J.,Yang, S.P., & Kuo, C.J. (2015). One-day-ahead hourly forecasting for photovoltaic power generation using an intelligent method with weather-based forecasting models. *IET Generation, Transmission & Distribution*, 9(14), 1874–1882, DOI: 10.1049/iet-gtd.2015.0175

Huang, G.-B. (2014). An insight into extreme learning machines: Random neurons, random features and kernels. *Cognitive Computation*, 6(376–390), DOI: 0.1007/s12559-014-9255-2.

IEA,(2022). Uluslararası Enerji Ajansı <https://www.iea.org/data-and-statistics/charts/global-energy-tained-co2-emissions-by-scenario-1990-2050>,

Kaaya, I., & Ascencio-Vásquez J. (2021). Solar Radiation - Measurements, Modeling and Forecasting for Photovoltaic Solar Energy Applications. *Engineering* DOI:10.5772/INTECHOPEN.97049

Kaya, D., Dokur, E., & Kurban, M. (2019). Güneş Işınım Şiddetinin Tahmininde Dalgacık Ayırıştırma Yönteminin Kullanılmasının Analizi ve Uygulaması. 3. *Uluslararası GAP Matematik Mühendislik, Fen ve Sağlık Bilimleri Kongresi, 29 Kasım-1 Aralık, Şanlıurfa*, s. (760-763)

Kushwaha, V. N., & Pindoriya, M. (2019). A SARIMA-RVFL hybrid model assisted by wavelet decomposition for very short-term solar PV power generation forecast. *Renewable Energy*, 140(124–139), .DOI: 10.1016/j.renene.2019.03.020.

Lei, Y., Lin J., He Z. & Zuo MJ. (2013). Dönen makinelerin arıza teşhisinde ampirik mod ayrışması üzerine bir inceleme. *Mechanical Systems and Signal Processing* , 35(1-2), 108–126.

Leva, S., Dolara, A., Grimaccia, F., Mussetta, M., & Ogliari, E. (2017). Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power. *Elsevier*, 131(88–100), DOI: 10.1016/j.matcom.2015.05.010.

Lichtenegger, G., Rentizelas, A. A., Trivyza, N., & Siegl, S. (2020). Offshore and onshore wind turbine blade waste material forecast at a regional level in Europe until 2050. *Waste management*, 106(120-131). Doi: 10.1016/j.wasman.2020.03.018.

Lin, H., Sun, Q., & Chen, S.Q. (2020). Reducing exchange rate risks in international trade: A hybrid forecasting approach of CEEMDAN and multilayer LSTM. *MDPI Sustainability*, 12(6), 2451, DOI:10.3390/su12062451.

Lin, Y., Yan, Y., Xu ,J., Liao, & Y., Ma, F. (2021). Forecasting stock index price using the CEEMDAN-LSTM model. *The North American Journal of Economics and Finance*, 57(101421), DOI: 10.1016/j.najef.2021.101421.

Liu, Z., Peng,D.,Zuo,M.J., Xia, J., & Qin, Y. (2022). Improved Hilbert–Huang transform with soft sifting stopping criterion and its application to fault diagnosis of wheelset bearings. *Elsevier* 125(426-444). DOI: 10.1016/j.isatra.2021.07.011.

- Melikoglu, M.** (2023). The role of renewables and nuclear energy in Turkey's Vision 2023 energy targets: Economic and technical scrutiny. *Elsevier* 62(1-12). DOI: 10.1016/j.rser.2016.04.029.
- Monjoly, S., André, M., Calif, R., & Soubdhan, T.** (2016). Hourly forecasting of global solar radiation based on multiscale decomposition methods: A hybrid approach. *Elsevier*, 119(288–298). DOI: 10.1016/j.energy.2016.11.061.
- Osman, M. K., M., Mashor, Y., & Jaafar, H.** (2012). Detection of tuberculosis bacilli in tissue slide images using HMLP network trained by extreme learning machine. *Elektronika ir Elektrotechnika*, 120(4), 69–74, DOI: 10.5755/j01.eee.120.4.1456.
- Paterova, T., & Prauzek, M.** (2021). Estimating harvestable solar energy from atmospheric pressure using deep learning. *Elektronika ir Elektrotechnika*, 27(5), 8–25, DOI:10.5755/j02.eie.28874.
- Pérez-Enciso, & M., Zingaretti L.M.** (2019). A Guide for Using Deep Learning for Complex Trait Genomic Prediction. *National Library of Medicine* 10(7). DOI: 10.3390/genes10070553
- Pierro, M.** (2017). Data-driven upscaling methods for regional photovoltaic power estimation and forecast using satellite and numerical weather prediction data. *Solar Energy*, 158(1026–1038), DOI: 10.1016/j.solener.2017.09.068.
- Qiana, Z., PeicY., Zareipourd H., & Chene N.** (2019). A review and discussion of decomposition-based hybrid models for wind energy forecasting applications. *Applied energy* 235(939-953)
- Ram, M., Aghahosseini , A., & Breyer, C.** (2020). Job creation during the global energy transition towards 100% renewable power system by 2050. *Elsevier*, 151(119682) DOI:10.1016/j.techfore.2019.06.008
- Sahu, R. K., Shaw, B., & Nayak, J. R.** (2021). Short/medium term solar power forecasting of Chhattisgarh state of India using modified TLBO optimized ELM. *Engineering Science and Technology, an International Journal*, 24(5) 1180–1200, DOI: 10.1016/j.jestch.2021.02.016.
- Shi, J., Lee, W.-J., Liu, Y., Yang, Y., & Wang, P.** (2012). Forecasting power output of photovoltaic systems based on weather classification and support vector machines. *IEEE Transactions on Industry Applications*, 48(3) 1064–1069, DOI: 10.1109/TIA.2012.2190816.

- Thangave, A., & Govindaraj, V.** (2022). Forecasting energy demand using conditional random field and convolution neural network. *Elektronika ir Elektrotechnika*, 28(5), 12–22, DOI:10.5755/j02.eie.30740.
- Türkyılmaz, T.** (2020). Geliştirilen Yeni Bir Yazılım ile Rüzgar ve Güneş Enerji Sistemlerinin Analizi ve Uygulaması.(Yayınlanmış Doktora Tezi) *Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Bilecik*
- VanDeventer, W. Jamei, E. Thirunavukkarasu, G.S. Seyedmahmoudian, M. Soon, T. Horan, & B. Stojcevski.** (2019). A. Short-term PV power forecasting using hybrid GASVM technique. *Elsevier*, 140(367–379)
- VanDeventer, W.** (2019). Short-term PV power forecasting using hybrid GASVM technique. *Elsevier*, 140(367– 379), DOI: 10.1016/j.renene.2019.02.087.
- Yang, Z., Mourshed, M., Liu, K., Xu, X., & Feng, S.** (2020). A novel competitive swarm optimized RBF neural network model for shortterm solar power generation forecasting. *Elsevier* , 397(415–421), DOI: 10.1016/j.neucom.2019.09.110.
- Yolcan, O.O.** (2023) World energy outlook and state of renewable energy: 10-Year evaluation. *Elsevier* 2(4),DOI:10.1016/j.igd.2023.100070
- Yüzgeç, U., Dokur E., & Balcı M.** (2022). Rüzgar Hızı Tahmini İçin Ayrıştırılmaya Dayalı Hibrit Yöntemlerin Karşılaştırmalı Bir Çalışması. *International Conference On Emerging Sources In Science At: İstanbul, Türkiye* (124-126).
- Zeng, J., & Qiao, W.** (2012). Short-term solar power prediction using a support vector machine. *Elsevier*, 52(118–127), DOI: 10.1016/j.renene.2012.10.009.
- Zhang, G.P.** (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Elsevier*, 50(159-175), DOI/10.1016/S0925-2312(01)00702-0
- Zhang, H., Z.S., & Yin Y.** (2016). Online sequential ELM algorithm with forgetting factor for real applications. *Elsevier*, 261(144-152261) DOI:10.1016/j.neucom.2016.09.121
- Zhou, C., Yin, K., Cao, Y., Intrieri, E., Ahmed, B., & Catani, F.** (2018). Displacement prediction of step-like landslide by applying a novel kernel extreme learning machine method. *Springer-Verlag GmbH Germany part of Springer Nature Landslides*, 15(2211–2225), DOI: 10.1007/s10346-018-1022-0.