

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

**HİBRİT DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK KISA DÖNEMLİ
RÜZGAR TAHMİNİ**

DOKTORA TEZİ

MEHMET BALCI

TEZ DANIŞMANI
PROF. DR. UĞUR YÜZGEÇ
İKİNCİ TEZ DANIŞMANI
DOÇ. DR. EMRAH DOKUR

BİLECİK, 2024
10590929

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

HİBRİT DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK KISA DÖNEMLİ
RÜZGAR TAHMİNİ

DOKTORA TEZİ

MEHMET BALCI

TEZ DANIŞMANI
PROF. DR. UĞUR YÜZGEÇ
İKİNCİ TEZ DANIŞMANI
DOÇ. DR. EMRAH DOKUR

BİLECİK, 2024
10590929

BEYAN

"Hibrit Derin Öğrenme Teknikleri Kullanılarak Kısa Dönemli Rüzgar Tahmini" 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	X
Destek alındı ise;			
Destekleyen kurum;			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TUBİTAK			
Diğer;...			
ETİK KURUL onayı var ise;			
ETİK KURUL karar tarih/sayı:		.../...	

Mehmet BALCI

.../.../2024

İmza

ÖN SÖZ

Bu tez çalışmamda bana yol gösteren, çalışmalarım sırasında takıldığım her noktada gece-gündüz demeden yardımcı olan, bana farklı bakış açıları kazandıran ve motivasyonumun artmasına sürekli katkıda bulunan tez danışmanlarım Prof. Dr. Uğur YÜZGEÇ'e ve Doç. Dr. Emrah DOKUR'a; çalışmalarına geliştirici eleştiri ve önerilerde bulunan tez izleme komitesi üyeleri Prof. Dr. Mehmet KURBAN'a ve Dr. Öğr. Üyesi Mustafa Alparslan ZEHİR'e sonsuz teşekkürlerimi sunarım. Tezimi bitirmem konusunda beni teşvik eden ve ellerinden geldiğince yardımcı olan Murat FİDAN'a, Hasan KILIÇ'a ve tüm mesai arkadaşlarıma teşekkür ediyorum.

Üzerimde bulunan haklarını asla ödeyemeceğim anneme ve babama; moralim ve motivasyonum düştüğünde sürekli yanımda bulunan ve desteğini hiçbir zaman esirgemeyen değerli eşim Meliha BALCI'ya tüm kalbimle teşekkür ederim.

Mehmet BALCI

2024

ÖZET

HİBRİT DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK KISA DÖNEMLİ RÜZGAR TAHMİNİ

Günümüzde artan enerji ihtiyacına paralel olarak çevresel etkiler de göz önüne alındığında yenilenebilir enerji kaynaklarının kullanımı önem kazanmaktadır. Yenilenebilir enerji alanındaki artan talep ve karbon nötrlüğüne ulaşma hedefi ile son yıllarda rüzgar enerji endüstrisinin hızlı bir büyüme yaşadığı görülmektedir. Özellikle büyük ölçekli açık deniz rüzgar enerjisinin elektrik şebekesine entegrasyonu, rüzgar hızının değişkenliği ve kesintililiği nedeniyle şebeke işle-timi ve dağıtımı için önemli zorluklar ortaya çıkmaktadır. Büyük ölçekli rüzgar enerji santral-lerini elektrik şebekelerine entegre etmek, şebeke güvenilirliğini ve verimliliği optimize etmek amacıyla bu alanda kısa dönemli tahminler oldukça büyük öneme sahiptir. Bu tez çalışması kapsamında karasal rüzgar hızı verisi ve açık deniz rüzgar gücü verileri kullanılarak kısa dö-nemli yenilikçi hibrit tahmin modelleri geliştirilmiştir. Bu kapsamda ayrıştırma metotlarının birincil ve ikincil kullanımının yanı sıra derin öğrenme tabanlı tahmin yaklaşımlarının perfor-mansları karşılaştırmalı olarak analiz edilmiştir. Tahmin modeli için geleneksel Çok Katmanlı Algılayıcı (Multilayer Perceptron, MLP) yanı sıra güncel Yankı Durum Ağı (Echo State Net-work, ESN), Uzun Kısa Süreli Bellek (Long Short Term Memory, LSTM) ve çift yönlü LSTM (BiLSTM) yaklaşımları kullanılmıştır. Birincil veya ikincil ayrıştırma içeren modellerde ise Ampirik Mod Ayrıştırması (Empirical Mode Decomposition, EMD), Topluluk Ampirik Mod Ayrıştırması (Ensemble Empirical Mode Decomposition, EEMD) ve Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayrıştırması (Complete Ensemble Empirical Mode Decompo-sition with Adaptive Noise, CEEMDAN), Sürü Ayrıştırması (Swarm Decomposition, SWD), Dalgacık Ayrıştırması (Wavelet Decomposition, WD) ve Varyasyonel Mod Ayrıştırması (Vari-ational Mode Decomposition, VMD) metotları karşılaştırmalı olarak incelenmiştir. Tüm analiz-ler üç farklı bölgeye ait açık deniz rüzgar gücü verileri ve bir karasal rüzgar hızı verisi kullanı-larak istatistiksel olarak karşılaştırmalı şekilde sunulmuştur. Hata performans kriterleri de dikkate alındığında tez çalışması kapsamında önerilen yenilikçi ikincil ayrıştırma tabanlı modellerin daha iyi sonuçlar verdiği gözlemlenmiştir.

Anahtar Kelimeler: Derin Öğrenme, Rüzgar Tahmini, Hibrit Derin Öğrenme, Ayrıştırma.

ABSTRACT

SHORT-TERM WIND FORECASTING USING HYBRID DEEP LEARNING TECHNIQUES

In parallel with the increasing energy demand, using renewable energy sources is becoming increasingly important when environmental impacts are considered. In light of the rising demand for renewable energy and the objective of attaining carbon neutrality, the wind energy sector has witnessed a period of accelerated expansion in recent times. The integration of large-scale offshore wind energy into the electricity grid presents a significant challenge to grid operation and distribution, due to the inherent variability and intermittency of wind speed. To integrate large-scale wind power plants into the electricity grid and to optimize grid reliability and efficiency, it is of great importance to have access to short-term forecasts. This thesis presents the development of innovative short-term hybrid forecasting models utilizing both onshore wind speed and offshore wind power data. In this context, the performance of primary and secondary use of decomposition methods, as well as deep learning-based forecasting approaches, is analyzed comparatively. In addition to the traditional Multilayer Perceptron (MLP), Echo State Network (ESN), Long Short-Term Memory (LSTM), and Bidirectional LSTM (BiLSTM) approaches are employed in the construction of the prediction model. The models under consideration are those employing either single or secondary decomposition. These include Empirical Mode Decomposition (EMD), Ensemble Empirical Mode Decomposition (EEMD), Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN), Swarm Decomposition (SWD), Wavelet Decomposition (WD) and Variational Mode Decomposition (VMD). All analyses are presented statistically in comparison with offshore wind power data and onshore wind speed data from three different regions. Concerning the error performance criteria, it is observed that the innovative secondary decomposition-based models proposed in this thesis yield superior results.

Keywords: Deep Learning, Wind Forecasting, Hybrid Deep Learning, Decomposition.

İÇİNDEKİLER

	Sayfa
ÖN SÖZ	i
ÖZET	ii
ABSTRACT	ii
TABLolar LİSTESİ	vi
ŞEKİLLER LİSTESİ	vii
KISALTMALAR VE SİMGELER LİSTESİ	ix
1. GİRİŞ	1
1.1. Literatür Taraması	3
1.2. Tez Çalışmasının Katkıları	12
2. Enerji Kavramı ve Enerji Kaynakları	14
2.1. Yenilenemeyen Enerji Kaynakları	15
2.1.1. Fosil Yakıtlar	15
2.1.2. Nükleer Enerji	16
2.2. Yenilenebilir Enerji Kaynakları	17
2.3. Rüzgar Enerjisi	20
3. KULLANILAN METOTLAR VE YÖNTEMLER	24
3.1. Kullanılan Öğrenme ve Tahmin Modelleri	24
3.1.1. Çok Katmanlı Algılayıcı	24
3.1.2. Uzun Kısa Süreli Bellek	26
3.1.3. Çift Yönlü Uzun Kısa Süreli Bellek	27
3.1.4. Yankı Durumu Ağları	28
3.2. Ayırıştırma Metotları	30

3.2.1. Ampirik Mod Ayrıştırması	30
3.2.2. Topluluk Ampirik Mod Ayrıştırması	31
3.2.3. Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayrıştırması	32
3.2.4. Varyasyonel Mod Ayrıştırması	33
3.2.5. Sürü Ayrıştırması	34
3.2.6. Dalgacık Ayrıştırması	35
3.3. Geliştirilen Hibrit Tahmin Modelleri	35
3.3.1. Birincil Ayrıştırma Tabanlı Hibrit Tahmin Modelleri	35
3.3.2. İkincil Ayrıştırma Tabanlı Hibrit Tahmin Modelleri	36
3.4. Kullanılan Veri Setleri	37
4. DENEYSEL ÇALIŞMALAR	39
4.1. Veri Normalizasyonu ve Kullanılan Metrikler	39
4.2. Birincil Ayrıştırma Tabanlı MLP Hibrit Modellerine Ait Çalışmalar	40
4.3. Birincil Ayrıştırma Tabanlı LSTM Hibrit Modellerine Ait Çalışmalar	49
4.4. Birincil Ayrıştırma Tabanlı EMD-ESN Hibrit Modeline Ait Çalışmalar	57
4.5. İkincil Ayrıştırma Tabanlı LSTM Hibrit Modellerine Ait Çalışmalar	60
4.6. İkincil Ayrıştırma Tabanlı BiLSTM Hibrit Modellerine Ait Çalışmalar	64
4.7. Genel Değerlendirme	68
5. SONUÇ	70
KAYNAKÇA	75

TABLÖLAR LİSTESİ

	Sayfa
Tablo 1.1. Literatürde birincil ayrıştırmanın kullanıldığı hibrit tahmin modelleri	10
Tablo 1.2. Literatürde ikincil ayrıştırmanın kullanıldığı hibrit tahmin modelleri	11
Tablo 4.1. Birincil ayrıştırma tabanlı MLP model sonuçları (BAL, Min-Max)	40
Tablo 4.2. Birincil ayrıştırma tabanlı MLP model başarımları (%) (BAL, Min-Max) . .	41
Tablo 4.3. Birincil ayrıştırma tabanlı MLP model sonuçları (BAL, Z-skör)	42
Tablo 4.4. Birincil ayrıştırma tabanlı MLP model başarımları (%) (BAL, Z-skör) . . .	42
Tablo 4.5. Birincil ayrıştırma tabanlı MLP model sonuçları (OFS, Min-Max)	44
Tablo 4.6. Birincil ayrıştırma tabanlı MLP model başarımları (%) (OFS, Min-Max) . .	44
Tablo 4.7. Birincil ayrıştırma tabanlı MLP model sonuçları (OFS, Z-skör)	47
Tablo 4.8. Birincil ayrıştırma tabanlı MLP model başarımları (%) (OFS, Z-skör)	47
Tablo 4.9. Birincil ayrıştırma tabanlı LSTM model sonuçları (ALL, Min-Max)	50
Tablo 4.10. Birincil ayrıştırma tabanlı LSTM model başarımları (%) (ALL, Min-Max) .	51
Tablo 4.11. Birincil ayrıştırma tabanlı LSTM model sonuçları (ALL, Z-skör)	54
Tablo 4.12. Birincil ayrıştırma tabanlı LSTM model başarımları (%) (ALL, Z-skör) . . .	54
Tablo 4.13. EMD-ESN model sonuçları (OFS, Min-Max)	57
Tablo 4.14. EMD-ESN model başarımları (%) (OFS, Min-Max)	58
Tablo 4.15. İkincil ayrıştırma tabanlı LSTM model sonuçları (ALL, Z-skör)	61
Tablo 4.16. İkincil ayrıştırma tabanlı LSTM model başarımları (%) (ALL, Z-skör) . . .	62
Tablo 4.17. İkincil ayrıştırma tabanlı BiLSTM model sonuçları (OFS, Z-skör)	65
Tablo 4.18. İkincil ayrıştırma tabanlı BiLSTM model başarımları (%) (OFS, Z-skör) . .	66
Tablo 4.19. Kullanılan dört veri seti için en başarılı modeller	69

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. Kara ve açık deniz rüzgar gücü kapasiteleri	2
Şekil 2.1. 2016-2028 yılları için yenilenebilir enerji kapasiteleri	17
Şekil 2.2. Türbin kanatları süpürme alanı.	21
Şekil 2.3. 1980-2030 yılları için kara ve açık deniz rüzgar türbini boyutları.	22
Şekil 2.4. Rotorlarına göre a) Yatay eksenli ve b) Dikey eksenli rüzgar türbini	22
Şekil 2.5. Yatay eksenli bir rüzgar türbinine ait genel yapı ve donanımlar.	23
Şekil 3.1. MLP modelinin genel yapısı	25
Şekil 3.2. LSTM'in genel mimarisi	26
Şekil 3.3. BiLSTM'in genel mimarisi	28
Şekil 3.4. ESN modelinin genel mimarisi	29
Şekil 3.5. Birincil ayrıştırma tabanlı hibrit modellerin blok diyagramı	36
Şekil 3.6. İkincil ayrıştırma tabanlı hibrit modellerin blok diyagramı	37
Şekil 3.7. Çalışmalarda kullanılan veri setlerinin coğrafi konumları	38
Şekil 4.1. Birincil ayrıştırma tabanlı MLP model sonuçları (BAL, Min-Max)	41
Şekil 4.2. Birincil ayrıştırma tabanlı MLP model sonuçları (BAL, Z-skor)	43
Şekil 4.3. Birincil ayrıştırma tabanlı MLP model sonuçları (WDS, Min-Max)	45
Şekil 4.4. Birincil ayrıştırma tabanlı MLP model sonuçları (BRW, Min-Max)	45
Şekil 4.5. Birincil ayrıştırma tabanlı MLP model sonuçları (HNP, Min-Max)	46
Şekil 4.6. Birincil ayrıştırma tabanlı MLP model sonuçları (WDS, Z-skor)	48
Şekil 4.7. Birincil ayrıştırma tabanlı MLP model sonuçları (BRW, Z-skor)	48
Şekil 4.8. Birincil ayrıştırma tabanlı MLP model sonuçları (HNP, Z-skor)	49
Şekil 4.9. Birincil ayrıştırma tabanlı LSTM model sonuçları (BAL, Min-Max)	51
Şekil 4.10. Birincil ayrıştırma tabanlı LSTM model sonuçları (WDS, Min-Max)	52

Şekil 4.11.	Birincil ayrıştırma tabanlı LSTM model sonuçları (BRW, Min-Max)	52
Şekil 4.12.	Birincil ayrıştırma tabanlı LSTM model sonuçları (HNP, Min-Max)	53
Şekil 4.13.	Birincil ayrıştırma tabanlı LSTM model sonuçları (BAL, Z-skor)	55
Şekil 4.14.	Birincil ayrıştırma tabanlı LSTM model sonuçları (WDS, Z-skor)	55
Şekil 4.15.	Birincil ayrıştırma tabanlı LSTM model sonuçları (BRW, Z-skor)	56
Şekil 4.16.	Birincil ayrıştırma tabanlı LSTM model sonuçları (HNP, Z-skor)	56
Şekil 4.17.	EMD-ESN model sonuçları (WDS, Min-Max)	59
Şekil 4.18.	EMD-ESN model sonuçları (BRW, Min-Max)	59
Şekil 4.19.	EMD-ESN model sonuçları (HNP, Min-Max)	60
Şekil 4.20.	İkincil ayrıştırma tabanlı LSTM model sonuçları (BAL, Z-skor)	63
Şekil 4.21.	İkincil ayrıştırma tabanlı LSTM model sonuçları (WDS, Z-skor)	63
Şekil 4.22.	İkincil ayrıştırma tabanlı LSTM model sonuçları (BRW, Z-skor)	64
Şekil 4.23.	İkincil ayrıştırma tabanlı LSTM model sonuçları (HNP, Z-skor)	64
Şekil 4.24.	İkincil ayrıştırma tabanlı BiLSTM model sonuçları (WDS, Z-skor)	67
Şekil 4.25.	İkincil ayrıştırma tabanlı BiLSTM model sonuçları (BRW, Z-skor)	67
Şekil 4.26.	İkincil ayrıştırma tabanlı BiLSTM model sonuçları (HNP, Z-skor)	68

KISALTMALAR VE SİMGELER LİSTESİ

ARIMA : Otoregresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average)

ASD : CEEMDAN-Entropi Tabanlı Spektral Kümeleme

Att-S2S : Dikkat Mekanizmasına Dayalı Diziden Diziye Yöntemi (Attention Mechanism-based Sequence to Sequence Method)

BaNN : Torbalama Sinir Ağı (Bagging Neural Network)

BiGRU : Çift Yönlü Kapılı Yinelemeli Birim (Bi-directional Gated Recurrent Unit)

BiLSTM : Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short Term Memory)

BiLSTM-A : Dikkat mekanizmasına dayalı BiLSTM (BiLSTM Based on Attention Mechanism)

BiTCN : Çift Yönlü Zamansal Evrişimli Ağ (Bidirectional Temporal Convolutional Network)

BO : Bayes Optimizasyonu (Bayesian Optimization)

Boruta-RF : Boruta - Rastgele Ormanı (Boruta - Random Forest)

BPNN : Geri Yayılımlı Sinir Ağı (Back-Propagation Neural Network)

CAPSNET : Kapsül Sinir Ağı (Capsule Neural Network)

CCF : Çapraz Korelasyon Fonksiyonu (Cross Correlation Function)

CCTransformer : Nedensel Evrişimli Dönüştürücü (Causal Convolutional Transformer)

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

ChB-SSO : Kaotik İkili Köpekbalığı Kokusu Optimizasyonu (Chaotic Binary Shark Smell Optimization)

CNN : Evrişimli Sinir Ağı (Convolutional Neural Network)

CoST : Mevsimsel Eğilim Gösterimlerinin Karşılaştırmalı Öğrenimi

CPSO : Kaotik Haritalamaya Dayalı Parçacık Sürüsü Optimizasyonu (Chaotic Mapping-based Particle Swarm Optimization)

CS : Guguk Kuşu Araması (Cuckoo Search)

CSA : Karga Arama Algoritması (Crow Search Algorithm)

CSO : Tavuk Sürüsü Optimizasyonu (Chicken Swarm Optimization)

D-ESN : Çift Katmanlı Aşamalı Eğitim ESN (Double-Layer Staged training ESN)

DAC : Veri Uyarlamalı Sansürleme (Data Adaptive Censoring)

DE : Diferansiyel Evrim (Differential Evolution)

DELM : Derin Aşırı Öğrenme Makinesi (Deep Extreme Learning Machine)

DGM : Ayırık Gri Model (Discrete Grey Model)

EEMD : Topluluk Ampirik Mod Ayırıştırması (Ensemble Empirical Mode decomposition)

EMD : Ampirik Mod Ayırıştırması (Empirical Mode Decomposition)

ENOA : Geliştirilmiş Aritmetik Optimizasyon Algoritması (Enhanced Arithmetic Optimization Algorithm)

ESMA : Geliştirilmiş Sümüklü Küf Algoritması (Enhanced Slime Mold Algorithm)

ESN : Yankı Durumu Ağları (Echo State Networks)

EWP : EEMD-Dalgacık Paket Dönüşümü

EWI : Ampirik Dalgacık Dönüşümü (Empirical Wavelet Transform)

FFT : Hızlı Fourier dönüşümü (Fast Fourier Transform)

FIG : Bulanık Bilgi Granülü (Fuzzy Information Granule)

FPA : Çiçek Tozlaşma Algoritması (Flower Pollination Algorithm)

FS : Özellik Seçimi (Feature Selection)

GA : Genetik Algoritma (Genetic Algorithm)

GP : Gauss Süreci (Gaussian Process)

GRU : Kapılı Yinelemeli Birim (Gated Recurrent Unit)

GWEC : Global Rüzgar Enerjisi Konseyi (Global Wind Energy Council)

GWO : Gri Kurt Optimizasyonu (Grey Wolf Optimization)

ICHOA : Geliştirilmiş Chimp Optimizasyon Algoritması (Improved Chimp Optimization Algorithm)

IDBO : Geliştirilmiş Gübre Böceği Optimizasyon Algoritması (Improved Dung Beetle Optimization Algorithm)

IEMD : Geliştirilmiş EMD

IMF : İçsel Mod Fonksiyonu (Intrinsic Mode Function)

IRENA : Uluslararası Yenilenebilir Enerji Ajansı (International Renewable Energy Agency)

IWOA : Geliştirilmiş Balina Optimizasyon Algoritması (Improved Whale Optimization Algorithm)

KPCA : Çekirdek Temel Bileşen Analizi (Kernel Principal Component Analysis)

LASSO : Mutlak Büzülme ve Seçim Operatörü (Least Absolute Shrinkage and Selection Operator)

LMS : En Küçük Kareler Ortalamasına (Least Mean Square)

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

MEMD : Çok Değişkenli EMD (Multivariate EMD)

MI : Karşılıklı Bilgi (Mutual Information)

MIC : Maksimum Bilgi Katsayısı (Maximal Information Coefficient)

MLP : Çok Katmanlı Algılayıcı (Multilayer Perceptron)

MOHHO : Çok Nesneli Harris Hawk Optimizasyonu (Multi Object Harris Hawk optimization)

MSSO : Çok Amaçlı Salp Sürüsü Optimizatörü (Multi-Objective Salp Swarm Optimizer)

MTL : Çok Görevli Öğrenme (Multi-Task Learning)

MTSO : Geliştirilmiş Ton Balığı Sürüsü Optimizasyonu (Modified Tuna Swarm Optimization)

PACF : Kısmi Oto-Korelasyon Fonksiyonu (Partial Auto-Correlation Function)

PCA : Temel Bileşen Analizi (Principal Component Analysis)

PCC : Pearson Korelasyon Katsayısı (Pearson Correlation Coefficient)

PSF : Desen Dizisi Tabanlı Tahmin (Sequence-based Forecasting)

PVMD : Parçacık Sürüsü Optimizasyonu-Varyasyonel Mod Ayırıştırma (Particle Swarm Optimization - Variational Mode Decomposition)

RELM : Düzenli Aşırı Öğrenme Makinesi (Regularised Extreme Learning Machine)

RF : Rastgele Orman (Random Forest)

RLMD : Sağlam Yerel Ortalama Ayırıştırma (Robust Local Mean Decomposition)

RNN : Tekrarlı Sinir Ağı (Recurrent Neural Network)

RReliefF : Regresyon İyileştirmesi (Regression ReliefF)

RTCN : Sağlam Zamansal Evrişimsel Ağ (Robust Temporal Convolutional Network)

SARIMA : Mevsimsel Oto-regresif Entegre Hareketli Ortalama (Seasonal Autoregressive Integrated Moving Average)

SE : Örnek Entropisi (Sample Entropy)

SSA : Tekil Spektrum Analizi (Singular Spectrum Analysis)

SVM : Destek Vektör Makinesi (Support Vector Machine)

SVMD : Ardışık Varyasyonel Mod Ayırıştırma, (Successive Variational Mode Decomposition)

SVR : Destek Vektör Makinesi Regresyonu (Support Vector Machine Regression)

SWD : Sürü Ayırıştırması (Swarm Decomposition)

TCN : Zamansal Evrişimsel Ağ (Temporal Convolutional Network)

TVFEMD : Zamanla Değişen Filtreleme Tabanlı Ampirik Mod Ayırıştırma, (Time Varying Filtering based Empirical Mode Decomposition)

VAR : Vektör Otoresif (Vector Autoregressive)

VMD : Varyasyonel Mod Ayırıştırma (Variational Mode Decomposition)

WD : Dalgacık Ayırıştırması (Wavelet Decomposition)


WOA : Balina Optimizasyon Algoritması (Whale Optimization Algorithm)

WPD : Dalgacık Paketi Ayırıştırma (Wavelet Packet Decomposition)

Xgboost : Aşırı Gradyan Güçlendirme (Extreme Gradient Boosting)

1. GİRİŞ

Sanayide yaşanan gelişmelerle beraber günlük yaşamımızı kolaylaştıran ürünlerin sayısı ve kullanım alanları her geçen gün artmaktadır. Bu ürünlerin çalışması için enerjiye ihtiyaç duyulmaktadır. Dolayısıyla artan cihazlara paralel olarak ihtiyaç duyulan enerji miktarı da artmaktadır. Günümüzde kullanılan enerjinin çoğunluğu halen yenilenemeyen veya iklim değişikliği üzerinde olumsuzluklara neden olan çevreye zararlı kaynaklardan elde edilmektedir. Enerji üretiminde devamlılık ve çevreye verilen zararlı etkileri azaltmak için alternatif enerji kaynaklarının popülerliği giderek artmaktadır. Bu kaynaklar arasında, yenilenebilir enerji kaynaklarından biri olan rüzgar enerjisi, elektrik üretiminde hızla yaygınlaşmaktadır (Shang vd., 2023; Tefera vd., 2023). Rüzgar enerjisi, küresel ölçekte enerji üretiminde karbon salınımını azaltmak için önde gelen başlıca bir yenilenebilir enerji kaynağı olup, dünya genelinde sıfır karbon hedeflerine ulaşmada önemli bir rol oynamaktadır (Dokur vd., 2022). Rüzgarın yaygın olarak kullanılması, emisyonların azaltılmasında ve daha sürdürülebilir bir enerji geleceğine geçişte önemli rol oynayacaktır. Global Rüzgar Enerjisi Konseyi (GWEC) 2023 raporuna göre küresel rüzgar enerjisi piyasası, 2022 yılındaki yeni kapasitesinde 77.6 GW denk gelen %9'luk gibi dikkate değer bir genişleme yaşayarak toplam kurulu gücünü 906 GW'a çıkarmıştır (S. Sun vd., 2023). Yapılan öngörülere göre, önümüzdeki beş yıl içinde yıllık yaklaşık 136 GW rüzgar enerjisi kapasitesi eklenmesi beklenmekte olup, bu da yıllık bileşik büyüme oranı olarak %15'e işaret etmektedir. Uluslararası Yenilenebilir Enerji Ajansı'nın (IRENA) 2024 yılına ait kara ve açık deniz rüzgar güçlerinin kapasitesi Şekil 1.1'de gösterilmiştir. Karada ve açık denizlerde kurulan rüzgar türbinleriyle bu oranlar daha da artırılabilir ve kapasitelerdeki verimli artışlar sayesinde karbon salınımı daha da azalacaktır (Yuzgec vd., 2024). Özellikle offshore türbinlerin rüzgardan elektrik üretim maliyetinin düzeltilmiş ortalamasını 2030 yılına kadar %55 gibi büyük oranda azaltması beklenmektedir. Avrupa Birliği (AB), dünya offshore rüzgar kapasitesinin büyük bir kısmını barındırmakta olup, 2030 yılına kadar offshore rüzgar enerjisi kapasitesini 60 GW'a çıkarmayı hedeflemiştir (Deveci vd., 2020).



Şekil 1.1. Kara ve açık deniz rüzgar gücü kapasiteleri

Kaynak: (IRENA, 2024)

Rüzgar enerjisi üretiminin etkin ve güvenilir bir şekilde yönetilmesinde; rüzgarın doğasında bulunan değişkenlik, kesiklik ve rastlantısallık gibi özellikler nedeniyle önemli bir zorluk yaşanmaktadır (X. Wang vd., 2023; Galphade vd., 2022). Rüzgarın güvenilir bir enerji kaynağı haline gelmesi için ileriye dönük olarak yüksek doğruluk oranlarıyla başarılı bir şekilde tahmin edilmesi gerekmektedir (X. Liu vd., 2023). Rüzgar gücü tahminlerinin doğruluğu, hem enerji üreticileri hem de şebeke operatörleri için kritik bir gereksinim olup hayati öneme sahiptir (Maradin, 2021; Bórawski vd., 2020). Yüksek doğruluk oranlarına sahip tahminler, enerji üretim planlamasında ani değişikliklerin önlenmesine yardımcı olmakta ve talep yönetimini optimize ederek şebekenin istikrarını sağlamaktadır. Ayrıca, bu tahminler sayesinde enerji arzı ve talep dengesizliğinin en aza indirilmesiyle birlikte şebeke operasyonlarında aşırı yüklenme veya enerji kaybı gibi olumsuz etkilerin önüne geçilmesi mümkündür. Tahminlerin doğruluğu, enerji üretiminin düşük olduğu dönemlerde planlı türbin bakımını daha verimli hale getirebilir ve bu sayede enerji kayıplarını en aza indirerek maliyetlerin düşmesine katkıda bulunabilir. Aynı zamanda, enerji üretimi için bildirilen kapasitenin karşılanmaması durumunda uygulanan ceza faktörünü azaltma noktasında da önemli bir rol oynar. Sürekli değişen rüzgar desenleri,

topografik etkiler ve çevresel faktörlerin karmaşık etkileşimi, bu tür dinamik koşullara uyum sağlayabilecek başarılı tahmin modellerini gerekli kılmaktadır. Rüzgar gücünün başarılı bir şekilde tahmin edilmesiyle, rüzgar enerjisinin şebekeye entegrasyonundaki sorunlar azalacak ve çevre dostu yenilenebilir bir enerjinin kullanımı artacaktır (Li vd., 2020). İlk rüzgar tahmin modelleri kara rüzgar tesisleri bağlamında geliştirilmiş ve uygulanmıştır (Archer vd., 2017). Ancak günümüzde açık deniz rüzgar türbinleri de her geçen gün artmaktadır. Bununla birlikte, geleneksel tahmin yöntemlerinin açık deniz ortamlarına uygulanabilirliği, çok sayıda faktör nedeniyle önemli iyileştirmeler gerektirmektedir. Özellikle, açık deniz rüzgarlarının hızı daha sürekli ve güçlü iken, daha az türbülans koşulları bulunmaktadır (Deveci vd., 2021; Lins vd., 2023). Bu yüzden büyük ölçekli açık deniz rüzgar enerjisinin güç sistemlerine başarılı bir şekilde entegrasyonunu kolaylaştırmak için, açık deniz rüzgar hızı karakteristikleri ve bunlarla ilişkili özellikleri işleyebilen modeller geliştirilmelidir.

Literatürde hem açık deniz hem de kara rüzgar hızı ve gücünü tahmin etmek için birçok model geliştirilmiştir.

1.1. Literatür Taraması

Literatürde rüzgar hızını ve rüzgar gücünü tahmin için geliştirilen bazı modellerle ilgili bilgiler aşağıda verilmektedir.

Wang ve Wang; EEMD, Evrişimli Sinir Ağı (CNN) ve MLP ile özellik çıkarımına dayalı geliştirdikleri hibrit modelle kısa dönem rüzgar hızı tahmini yapmışlardır. Geliştirilen modelde; gürültüler EEMD ile temizlenmekte, CNN ile özellik çıkarımı yapılarak gereksiz bilgiler ortadan kaldırılmakta ve hazırlanan veri seti MLP'ye giriş olarak verilip tahminler yapılmaktadır. Bu sayede tahminlerdeki doğruluk artırılmaya çalışılmıştır (Wang ve Wang, 2021).

Samadianfard ve arkadaşları; MLP ve Balina Optimizasyon Algoritmasını (WOA) beraber kullanarak geliştirdikleri hibrit MLP-WOA modeliyle İran'ın kuzeyindeki bir bölge için rüzgar hızı tahminleri yapmışlardır. Geliştirilen modelde WOA optimizasyon algoritmasının MLP modelinin tahminlerdeki doğruluk oranına olumlu katkısı olduğu gözlemlenmiştir (Samadianfard vd., 2020).

Sarp ve arkadaşları; Veri Uyarlamalı Sansürleme (DAC) stratejisinden faydalanarak MLP, Tekrarlı Sinir Ağı (RNN) ve Destek Vektör Makinesi (SVM) tabanlı kısa vadeli rüzgar hızı tahmin modelleri önermişlerdir. Geliştirilen modellerde, DAC ile En Küçük Kareler Ortalamasına (LMS) dayalı DAC-LMS stratejisi kullanılmıştır. Bu yöntemle daha az bilgilendirici

özellikteki rüzgar hızı verileri sansürlendiği için MLP, RNN ve SVM modelleriyle yapılan eğitim sürecinin önemli ölçüde hızlandırıldığı ve testlerdeki tahminlerin başarısının arttığı ve verilerde oluşan değişikliğin ihmal edilebilecek düzeyde gerçekleştiği gözlemlenmiştir (Sarp vd., 2022).

Ahmadi ve Khashei, rüzgar tahminlerinde kullanılan hibrit rüzgar tahmin modellerini; veri ön işleme tabanlı yaklaşımlar, parametre optimizasyonu tabanlı yaklaşımlar, son işleme tabanlı yaklaşımlar ve bileşen kombinasyonu tabanlı yaklaşımlar olmak üzere dört ana kategoride incelenmişlerdir. Çalışmada bileşen kombinasyonlu modellerin en çeşitli ve kapsamlı yaklaşımlar olduğu ifade edilmiştir (Ahmadi ve Khashei, 2021).

Shu ve arkadaşları tarafından, Hızlı Fourier Dönüşümü (FFT) ile MLP-karıştırıcısı kullanılarak hibrit rüzgar tahmin modeli geliştirilmiştir. Çalışmada yüksek boyutlu özellikler ayrık- lanıp öğrenme işlemi için MLP karıştırıcısına dayalı derin öğrenme zaman serisi tahmini yapılmıştır. Ayrıca çalışmada yapılan tahminler için 4, 8, 12 ve 16 saat öncesine göre ayarlamalar yapılmış ve 4 saat öncesine gidilen tahminlerin en başarılı tahminler olduğu görülmüştür (Shu vd., 2022).

Memarzadeh ve Keynia; Karga Arama Algoritması (CSA), Dalgacık Dönüşümü (WT), entropi ve karşılıklı bilgi (MI) tabanlı özellik seçimi (FS) ile LSTM'nin beraber kullanıldığı bir hibrit model geliştirilerek kısa vadeli rüzgar hızı tahminleri yapmışlardır. Modelde; WT rüzgar hızındaki dalgalanmaları ortadan kaldırmak için, FS rüzgar hızı sinyalinin tahmini için aday girdilerini sıralamak ve gereksiz girdileri bilgi değerlerine göre ortadan kaldırmak için, CSA LSTM'nin yapısını ve giriş özelliklerinin sayısını optimize etmek için ve LSTM tahmin işlemi için kullanılmıştır. Modelde bu algoritma ve metotlar kullanılarak modelin tahminlerdeki doğruluğu ve hızı artırılmaya çalışılmıştır (Memarzadeh ve Keynia, 2020).

Shahid ve arkadaşları, kısa vadeli rüzgar gücü tahmini yapmak için Genetik Algoritma (GA) ile LSTM'yi beraber kullanarak GLSTM modelini geliştirmişlerdir. Modelde, LSTM'nin ardışık veriler, örneğin zaman serileri, üzerindeki özellikleri otomatik olarak öğrenme yeteneğinden faydalanılmıştır. GA ise LSTM'nin katmanlarında bulunan pencere boyutlarını ve nöron sayılarını iyileştirmek için kullanılmıştır. Bu sayede LSTM'nin tahminlerdeki doğruluk oranı kullanılan veri setleri için artırılmıştır (Shahid vd., 2021).

Geng ve arkadaşları, PCA-LSTM hibrit modeli için Temel Bileşen Analizi (PCA) ve LSTM'yi beraber kullanılmışlardır. Modelde, PCA metodu rüzgar hızını etkileyen meteorolojik

verilerin etkisi azaltmak için kullanılmıştır. Ayrıca modelin öğrenme oranını, gizli katman düğümlerinin sayısını ve LSTM ağıнын boyutunu verimli hale getirmek için farksal gelişim (DE) algoritması kullanılmıştır. Hazırlanan veriler LSTM modeli için girdi olarak kullanılıp tahminler yapılmıştır. Kullanılan algoritmalarla LSTM'nin rüzgar hızı tahminlerindeki doğruluk oranı yükseltilmeye çalışılmıştır (Geng vd., 2020).

Dolatabadi ve arkadaşları, Ayırık Dalgacık Paket Dönüşümü (DWPT) ve BiLSTM'yi entegre kullanarak geliştirdikleri hibrit modelle kısa vadeli rüzgar hızı tahminleri yapmışlardır. Çalışmada rüzgar hızındaki sinyallerin anlamlı bileşenlerini verimli bir şekilde çıkarabilmek ve diğer ayrıştırma tekniklerinin dezavantajlarını kaldırmak amacıyla DWP kullanılmıştır. Modelde; çift yönlü veri işleme, uzun vadeli bellek ve rüzgar hızı verilerinin derin zamansal özelliklerini yakalamadaki avantajları için BiLSTM'den yararlanılmıştır (Dolatabadi vd., 2020).

Jaseena ve Kovoov; Ampirik Dalgacık Dönüşümü (EWT) ve BiLSTM'den oluşan hibrit modelle rüzgar hızını tahmin etmek için çalışmalar yapmışlardır. Önerilen EWT-BiLSTM modelinde; EWT ile rüzgar verilerinin gürültüsünü azaltmak için veriler düşük ve yüksek frekanslı sinyallere ayrıştırılmıştır. Bu sayede BiLSTM'nin öğrenme ve tahminlerdeki doğruluk oranında iyileştirmeler elde edildiği tespit edilmiştir (K. U. Jaseena ve Kovoov, 2021).

Wang ve arkadaşları; EMD, PCA, Rastgele Orman (RF) ve LSTM'yi kullanarak hibrit EMD-PCA-RF-LSTM modelini geliştirmişlerdir. Modelde; veri setindeki çevresel faktörler En Az Mutlak Büzülme ve Seçim Operatörü (LASSO) algoritması ile filtrelenmiş, veri setinin durağan olmayan yapısı EMD ile genişletilmiş, analize büyük oranda etki edebilecek gürültüler PCA ile ortadan kaldırılmış, verilerin özelliklerinin önemi RF algoritması yardımıyla hesaplanarak daha fazla özellik çıkarılmış ve LSTM ile rüzgar gücü tahmini için çok değişkenli özellik serilerinin dinamik zaman modellemesi gerçekleştirilmiştir (D. Wang vd., 2022).

Zhang ve Wan; Çok Başlı Dikkat (MA), CNN, BiLSTM ve derin topluluk (deep ensemble) metotlarını beraber kullanarak geliştirdikleri hibrit modelle 24 saat sonraya yönelik rüzgar hızı tahminleri yapmışlardır. Geliştirilen modelde; ölçümlerin zamansal bilgilerinin yanında giriş değişkenlerinin mekansal korelasyonu da dikkate alınmış ve sayısal hava tahmini ile yerinde ölçümler birleştirilerek rüzgar hızındaki değişimlere uyum sağlama olanağı modele kazandırılmıştır (Zhang ve Wang, 2023).

D. Zhang ve arkadaşları, birçok algoritma ve yöntemi beraber kullanarak rüzgar gücünü tahmin etmek için hibrit bir model geliştirmişlerdir. Modelde; Pearson Korelasyon Katsayısı

(PCC) birincil meteorolojik deęiřkenlerini giriř serisi řeklinde ayarlamak, CEEMDAN rüzgar gücü serilerini yumuřatıp alt serilere ayırřtırmak ve EWT ise en yüksek karmařıklıęa sahip bileřenleri elde etmek için kullanılmıřtır. Çift Yönlü Zamansal Evriřimli Ağ (BiTCN) ile rüzgar hızı, rüzgar yönü ve rüzgar gücü serileriyle ilgili gizli bilgiler elde edilmektedir. Elde edilen bilgiler, dikkat mekanizmasıyla optimize edilmiř BiLSTM’de kullanılarak tahminler yapılmıřtır (D. Zhang vd., 2023).

Joseph ve arkadaşları; önceki rüzgar hızı gecikmesini belirlemek için Kısmi Otokorelasyon Fonksiyonu (PACF) ve dięer iklim deęiřkenlerinin gecikmelerini almak için Çapraz Korelasyon Fonksiyonu (CCF) kullanmıřlardır. Verilerdeki en iyi özellikleri bulmak için RReliefF (Regresyon İyileřtirmesi) ile eğitim verilerinden rastgele bazı örnekler seçilerek aynı sınıftaki en yakın komřularda arama yapılmaktadır. Boruta-RF kullanılarak bir özellik seçimi daha uygulanmakta ve BO (Bayes Optimizasyonu) ile BiLSTM parametreleri iyileřtirilerek tahminler yapılmaktadır (Joseph vd., 2023).

Liang ve arkadaşları, Kapsül Sinir Aęı (CAPSNET) ve Çok Amaçlı Harris řahin Optimizasyonu (MOHHO) ile BiLSTM’yi beraber kullanarak geliřtirdikleri CAPSNET-BiLSTM-MOHHO hibrit modeliyle rüzgar hızı tahmini yapmıřlardır. Modelde; CAPSNET aynı zaman noktasındaki birden fazla deęiřken arasındaki mekansal özelliklerin baęlantılarını çıkarmak, BiLSTM modelin eğitimi ile tahmin yapmak ve MOHHO ise elde edilen sonuçları aęırlıklandırmak için kullanılmıřtır. Ayrıca modelde, kendi kendine dikkat eden mekanizma ile BiLSTM’nin eğitim parametreleri en iyi hale getirilerek tahmin verimlilięi artırılmıřtır. Ayrıca BiLSTM’nin zamansal özellikleri ve geliřtirilen modelin sürekli deęerleri tahmin etmesini saęlamak amacıyla BiLSTM’ye regresyon katmanı kazandırılmıřtır (Liang vd., 2022).

Wei ve arkadaşları, kısa vadeli rüzgar gücünü tahmin etmek için Maksimum Bilgi Katsayısı (MIC), Çok Görevli Öğrenme (MTL) ve LSTM’yi beraber kullanarak çalışmalar yapmıřlardır. MIC yardımıyla rüzgar gücü ile rüzgar hızı arasındaki korelasyon ve rüzgar gücü ile rüzgar hızı arasındaki gecikmeli otokorelasyon analiz edilmiřtir. MTL, rüzgar gücü ile rüzgar hızı tahminleri için öğrenilen özellik temsilini paylaşmak için kullanılmıřtır. Bu sayede LSTM’nin parametreleri optimize edilip tahminlerdeki performans ve doęruluk artırılmaya çalışılmıřtır (Wei vd., 2023).

Y. Li ve arkadaşları, rüzgar hızını tahmin etmek için GA-VMD-IDBO-BiLSTM-A hibrit modeliyle çalışmalar yapmıřlardır. Modelde; GA, VMD, Geliřtirilmiř Gübre Böceęi Opti-

mizasyon Algoritması (IDBO) ve dikkat mekanizmasına dayalı BiLSTM-A entegre bir şekilde kullanılmıştır. Kullanılan modelin başarısının artırılması amacıyla; veri setindeki gürültüyü ortadan kaldırmak ve orijinal verinin niteliklerini çıkarmak için VMD, VMD'nin ayrıştırma verimliliğini artırmak amacıyla desen karıştırma ve eksik ayrıştırma sorununu çözerek optimize etmek için GA ve tahmin için kullanılan BiLSTM-A'daki parametrelerin seçimini iyileştirmek için ise IDBO algoritması kullanılmıştır (Y. Li vd., 2024).

Z. Liu ve arkadaşları, WD ile BiLSTM'yi beraber kullanarak kısa dönemli rüzgar gücü tahmini yapmışlardır. Modelde; WD, rüzgar gücü verilerinin değişkenliğini, doğrusal olmayan yapısını ve zamansal korelasyonunu detaylı bir biçimde işlemek için kullanılmıştır. Ayrıştırma sonucundaki veriler ileri-geri yönlü çalışma yapısından faydalanmak amacıyla BiLSTM'de giriş verisi olarak kullanılıp tahminler yapılmıştır (Z. Liu vd., 2021).

Phan ve Nguyen; GWO, CEEMDAN, CNN ve BiLSTM'yi entegre bir şekilde kullanarak geliştirdikleri hibrit modelle rüzgar hızı tahminleri yapmışlardır. Modelde; GWO ile parametrelerin optimizasyonu, CEEMDAN ile durağan olmayan rüzgar verilerinin etkili biçimde önceden işlenmesi, CNN ile verilerin özelliklerinin çıkarılması ve BiLSTM ile zamansal bağımlılıkların yakalanması sağlanmış olup modelin tahminlerdeki doğruluğu artırılmaya çalışılmıştır (Phan ve Nguyen, 2024).

Gao ve arkadaşları; VMD, SSA (Serçe Arama Algoritması) ve LSTM'yi beraber kullanarak geliştirdikleri SSA-VMD-LSTM hibrit modeliyle rüzgar gücü tahmini yapmışlardır. Modelde; girdi olarak kullanılan rüzgar gücü verilerinin işlenmesi ve ayrıştırılması için VMD kullanılmıştır. SSA ile VMD parametrelerinin elle ayarlanması yerine parametrelerin otomatik olarak ayarlanması sağlanmıştır. Bu sayede sinyallerin az veya aşırı bir şekilde ayrıştırılması engellenmeye çalışılmıştır. Hazırlanan veriler LSTM'de giriş verileri olarak kullanılarak modelin eğitim ve tahmin işlemleri gerçekleştirilmiştir. (X. Gao vd., 2023).

Hu ve Wang; VMD ve DE (Farksal Gelişim) ve ESN'nin beraber kullanılmasıyla geliştirilen hibrit VMD-DE-ESN modeliyle rüzgar hızı tahminleri yapmışlardır. Geliştirilen modelde; VMD ile veri seti ayrıştırılarak veri setindeki gürültü ortadan kaldırılmış ve orijinal serinin ana özellikleri çıkarılmıştır. DE ile ESN'nin üç önemli parametresi olan rezervuar ölçeği, bağlantı hızı ve spektral yarıçapı optimize edilmiştir. ESN, yeni bir RNN olup sahip olduğu yüksek evrensel optimumluk ve düşük hesaplama karmaşıklığı gibi avantajlar nedeniyle eğitim ve tahmin aşamalarında kullanılmıştır (Hu vd., 2021).

Bai ve arkadaşları, rüzgar hızını tahmin etmek için VMD-D-ESN hibrit modelini geliştirerek kullanmışlardır. Model; VMD, çift katmanlı aşamalı eğitim ESN (D-ESN) ve GA'nın beraber kullanılmasıyla geliştirilmiştir. VMD ile orijinal rüzgar hızı serisi alt dizilere ayrıştırılarak her bir dizinin karmaşıklığı ile durağanlığı azaltılmıştır. D-ESN, iki temel ESN'den oluşup rüzgar hızı eğitim setinin uzunluğunu otomatik olarak seçebilmekte, aşamalı olarak eğitim yapabilmektedir. Ayrıca D-ESN'de tahminlerdeki doğruluğu artırmak için eğitim seti seçimi ile hata işleme yeteneği geliştirilmiştir. D-ESN'nin hiperparametrelerini optimize etmek için GA kullanılarak çok katmanlı ESN parametrelerinin elle ayarlanmasından doğabilecek hatalar engellenmeye çalışılmıştır (Bai vd., 2021).

Huang ve arkadaşları, ESN ile beraber verileri modellemek için Gauss rastgele alanını kullanarak rüzgar hızını tahmin etmek için çalışmalar yapmışlardır. Çalışmada, tüm veriler Gauss rastgele alanıyla modellendikten sonra, bir dizi düğüm ele alınmakta ve bu düğümlerle tüm süreç temsil edilmektedir. Modelde uzay-zaman dinamikleri ESN ile modellenip rüzgar hızı için tahminler yapılmaktadır (Huang vd., 2022).

Tian ve arkadaşları, VMD, ESN ve Geliştirilmiş Balina Optimizasyon Algoritmasını (IWOA) beraber kullanarak rüzgar hızını tahmin etmek için çalışma yapmışlardır. Çalışmada, orijinal rüzgar hızı verisinin rastgeleliğini ve durağanlığını azaltıp asıl özelliklerine ait bilgiyi etkili bir şekilde temsil eden farklı frekanslara sahip bir dizi sabit bileşenlere ayrıştırmak için VMD kullanılmıştır. Doğrusal olmayan verileri öğrenme yeteneğinden faydalanmak için ESN seçilmiştir. ESN'de rezervuar parametrelerinin seçilme aşamasındaki problemi çözmek ve ESN'nin tahmin performansına ait rezervuar parametrelerini optimize için IWOA kullanılmıştır (Tian vd., 2021).

Ding ve arkadaşları, rüzgar hızını tahmin etmek için ikili dinamik özellikli ESN (SP-ESN), geliştirilmiş CEEMDAN (ICEEMDAN) ve Kaotik Çakal Optimizasyon Algoritmasını (CCOA) bir arada kullanmışlardır. SP-ESN'de rezervuarın derinliği, gecikme katsayısı, eğitim setinin uzunluğu otomatik bir şekilde ayarlanabilmekte ve gerçek dizinin özelliklerine göre hata düzeltilmesi yapılarak aşamalı bir şekilde model eğitilebilmektedir. CCOA ile ESN'nin hiperparametreleri ve eğitim setinin uzunluğu otomatik optimize edilip elle yapılacak optimizasyonların etkisi azaltılmıştır. ICEEMDAN ile veri setindeki dalgalanmaların etkisini azaltmak için ayrıştırma yapılmış ve ayrıştırma işleminde beyaz gürültü yerine özel bir gürültü kullanılmıştır (L. Ding vd., 2023).

Literatüre ve burada özetlenen çalışmalara bakıldığında rüzgarın yapısındaki düzensizlikten kaynaklanan yüksek frekansların tahminlere olan olumsuz etkilerini azaltmak amacıyla önerilen ve geliştirilen modellerde, bir veya birden fazla ayrıştırma metodunun kullanıldığı görülebilmektedir. Literatürde geliştirilen bir ayrıştırma algoritmasının kullanıldığı birincil ayrıştırma çalışmalardan bazıları Tablo 1.1’de ve ikincil ayrıştırma algoritmasının kullanıldığı çalışmalardan bazıları da Tablo 1.2’de özet olarak verilmektedir.



Tablo 1.1. Literatürde birincil ayrıştırmanın kullanıldığı hibrit tahmin modelleri

Referans	Metot	Veri Seti	Uygulama
(Li vd., 2022)	FPA-VMD-BiLSTM (Çiçek Tozlaşma Algoritması, VMD, BiLSTM)	Çin, Ningxia, Mahuangshan bölgesine ait 15 dakika periyotlu rüzgar gücü verisi	Kısa vadeli rüzgar gücü tahmini
(Abedinia vd., 2020)	IEMD (Geliştirilmiş EMD), K-ortalamalar kümelemesi, BaNN (Torbalama Sinir Ağı) ve ChB-SSO'dan (Kaotik İkili Köpekbalığı Kokusu Optimizasyonu) oluşan hibrit model	Üç farklı bölgeye ait rüzgar gücü verisi	Rüzgar gücü tahmini
(Jiang vd., 2021)	EMD-VAR (EMD, Vektör Otoregresif)	Çin, Shandong bölgesine ait 10 dakikalık periyotlarla kaydedilen rüzgar hızları	İleriye dönük 10 dakikalık rüzgar hızı tahmini
(N. Li vd., 2023)	EMD-CCTransformer (EMD, Nedensel Erişimli Dönüştürücü)	Kuzeybatı Çin'e ait 10 dakikalık aralıklarla kaydedilen rüzgar verisi	İleriye dönük 10 dakikalık rüzgar gücü tahmini
(Ran vd., 2023)	EMD-DGM (EMD, Ayrık Gri Model)	Çin'in ilkbahar döngüsel mevsimsel rüzgar enerjisi	İleriye dönük rüzgar enerjisi tahmini
(Yan vd., 2022)	SARIMA-EEMD-LSTM (Mevsimsel Otoregresif Entegre Hareketli Ortalama, EEMD, LSTM)	1 dakikalık aralıklarla kaydedilen rüzgar hızları	İleriye dönük 15, 30 ve 60 dakikalık rüzgar hızı tahmini
(C. Ding vd., 2022)	EEMD-LSTM-SVR (EEMD, LSTM, Destek Vektör Makinesi Regresyonu)	15 dakikalık aralıklarla kaydedilen rüzgar gücü verileri	İleriye dönük 1 saatlik rüzgar gücü tahmini
(K. Jaseena ve Koor, 2021)	EEMD-BiLSTM	Hindistan, Tamilnadu bölgesine ait 10 dakikalık periyotlu rüzgar hızları verisi	İleriye dönük rüzgar hızı tahmini
(Bokde vd., 2020)	EEMD-PSF-ARIMA (EEMD, Desen Dizisi Tabanlı Tahmin, Otoregresif Entegre Hareketli Ortalama)	Hindistan, Maharashtra bölgesine ait 1 saat aralıklı rüzgar gücü verisi	İleriye dönük 12 ve 24 saatlik rüzgar gücü tahmini
(An vd., 2022)	PVMD-ESMA-DELM (Parçacık Sürüş Optimizasyonu-Varyasyonel Mod Ayrıştırma, Geliştirilmiş Sümüklü Küf Algoritması, Derin Aşırı Öğrenme Makinesi)	Çin, İç Moğolistan bölgesine ait 15 dakikalık aralığa sahip rüzgar gücü verisi	İleriye yönelik ultra kısa vadeli (0-4 saat) rüzgar gücü tahmini
(Q. Li vd., 2024)	CEEMDAN-CNN-LSTM	Arktik bölgesine ait 3 saat periyotlu rüzgar hızı verisi	İleriye dönük 4 adımlı (12 saatlik) rüzgar hızı tahmini
(Cheng ve Wang, 2020)	EEMD-MSSO (EEMD, Çok Amaçlı Salp Sürüş Optimizatörü)	Çin, Penglai bölgesine ait 10 dakikalık aralıkla kaydedilen rüzgar hızı verisi	İleriye dönük 3 adımlı rüzgar hızı tahmini
(Suo vd., 2023)	TVFEMD-PACF-ICHOA-BiGRU (Zamanla Değişen Filtreleme Tabanlı Ampirik Mod Ayrıştırma, PACF, Geliştirilmiş Chimp Optimizasyon Algoritması, Çift Yönlü Kapalı Yinelemeli Birim)	Alaska, Kenai Yarımadası'na ait 10 dakika aralıklı rüzgar hızı verisi	İleriye dönük tek adımlı rüzgar hızı tahmini
(Tuerxun vd., 2022)	SVMD-MTSO-LSTM (Ardışık Varyasyonel Mod Ayrıştırma, Geliştirilmiş Ton Balığı Sürüş Optimizasyonu, LSTM)	China, Shaanxi bölgesine ait 1 dakikalık periyotlu rüzgar hızı verisi	İleriye dönük ultra kısa vadeli rüzgar hızı tahmini
(Parri vd., 2024)	VMD-CoST-SVR (VMD, Mevsimsel Eğilim Gösterimlerinin Karşılaştırmalı Öğrenimi, SVR)	ABD, Massachusetts, Leicester ve ABD, Oregon, Portland bölgelerine ait 5 dakika aralıklı rüzgar hızı verileri	İleriye yönelik 5, 10, 15 ve 30 dakikalık; 1 ve 2 saatlik rüzgar hızı tahminleri

Tablo 1.2. Literatürde ikincil ayrıştırmanın kullanıldığı hibrit tahmin modelleri

Referans	Metot	Veri Seti	Uygulama
(Emeksiz, 2022)	CEEMDAN-LMD-Hurst-BPNN (CEEMDAN, Yerel Ortalama Ayrıştırma, Hurst Analizi, Geri Yayılımlı Sinir Ağı)	Tokat iline ait 10 dakikalık periyotlarla kaydedilen rüzgar hızları	Rüzgar hızı tahmini
(Z. Sun vd., 2021)	WD-VMD-RF-Kmeans-LSTM-LSTM	Çin, Hebei bölgesine ait 10 dakikalık periyotlarla kaydedilen rüzgar gücü verileri	İleriye dönük 15 dakika, 30 dakika ve 1 saatlik rüzgar gücü tahmini
(Karijadi vd., 2023)	CEEMDAN-EWT-LSTM	Türkiye ve Fransa'daki iki farklı rüzgar çiftliğine ait 10 dakikalık periyotlu rüzgar gücü verileri	İleriye dönük 10 dakikalık rüzgar gücü tahmini
(W. Sun vd., 2021)	VMD-SGMD-DE-BPNN (VMD, Simplektik Geometri Modu Ayrıştırması, DE, BPNN)	Çin, Chengde bölgesine ait 20 dakika aralıklı rüzgar hızı verisi	İleriye yönelik 1-4 adımlı rüzgar hızı tahmini
(S. Zhang vd., 2021)	SSA-MEMD-ACNN-BiLSTM (Tekil Spektrum Analizi, Çok Değişkenli EMD, Dikkat Mekanizmalı CNN, BiLSTM)	ABD'deki, Kaliforniya - Sulama Yönetimi Bilgi Sistemi'ne ait 1 saat periyotlu rüzgar hızı verileri ve Teksas - Ulusal Rüzgar Enstitüsü'ne ait rüzgar hızı verileri	İleriye dönük 10 dakikalık ve 1 saatlik rüzgar hızı tahmini
(Ma vd., 2023)	WD-VMD-LSTM-TCN (WD, VMD, LSTM, Zamansal Evrişimsel Ağ)	Çin, Shandong bölgesine ait 15 dakika aralıklı rüzgar hızı verisi	İleriye yönelik 15 dakikalık rüzgar hızı tahmini
(Hou vd., 2024)	CEEMDAN-VMD-KPCA-ENAOA-BiLSTM-error (CEEMDAN, VMD, Çekirdek Temel Bileşen Analizi, Geliştirilmiş Aritmetik Optimizasyon Algoritması, BiLSTM, Hata Düzeltme)	Çin'in Kuzeybatısına ait 15 dakika periyotlu rüzgar gücü verileri	İleriye dönük 15 dakikalık rüzgar gücü tahmini
(Y. Zhang vd., 2022)	EWP-CS-RELM (EEMD-Dalgacık Paket Dönüşümü, Guguk Kuşu Arama, Düzenli Aşırı Öğrenme Makinesi)	Doğu Çin, Shandong bölgesine ait 15 dakikalık periyotlu rüzgar hızı verileri	İleriye dönük 15 dakikalık rüzgar hızı tahmini
(Xiang vd., 2020)	SD-BiGRU-CSO(FIG) (SSA-VMD, BiGRU, Tavuk Sürüsü Optimizasyonu (Bulanık Bilgi Granülü))	10 dakikalık periyotlu rüzgar hızı verileri	İleriye yönelik 1, 2 ve 3 adımlı rüzgar hızı tahmini
(G. Zhang vd., 2024)	ASD-RTCN (CEEMDAN-Entropi Tabanlı Spektral Kümeleme-VMD, Sağlam Zamansal Evrişimsel Ağ)	Çin'deki; Hebei'ye ait 5 dakika, İç Moğolistan'a ait 15 dakika, Shandong'a ait 30 dakika ve Xinjiang'e ait 60 dakika periyotlu rüzgar hızı verileri	İleriye yönelik 1, 2 ve 3 adımlı rüzgar hızı tahmini
(Sun ve Liu, 2024)	CPSO-VMD (Kaotik Haritalamaya Dayalı Parçacık Sürüsü Optimizasyonu-VMD), SE (Örnek Entropisi), ICEEMDAN, Att-S2S (Dikkat Mekanizmasına Dayalı Diziden Diziye Yöntemi)	ABD'deki, Kaliforniya Riverside ve Kaliforniya Merkez Sahil Vadilerine ait 1 saat periyotlu rüzgar hızı verileri	İleriye dönük 1 saatlik rüzgar hızı tahmini
(H. Wang vd., 2022)	CEEMDAN-RLMD-IWOA-LSTM (CEEMDAN, Sağlam Yerel Ortalama Ayrıştırma, IWOA, LSTM)	Kuzeybatı Çin, Gansu Eyaleti ve Kuzeydoğu Çin, Liaoning Eyaletine ait 5 dakikalık rüzgar hızı verileri	İleriye yönelik 5 dakikalık rüzgar hızı tahmini
(Sibtain vd., 2022)	VIL (VMD, ICEEMDAN, LSTM)	Pakistan, Sujawal bölgesine ait 10 dakikalık örnekleme aralıklı rüzgar hızı verileri	İleriye dönük 10 dakikalık rüzgar hızı tahmini
(J. Wang vd., 2023)	CEEMDAN, SSA, Xgboost (Aşırı Gradyan Güçlendirme) ve GP'den (Gauss Süreci) oluşan hibrit model	Çin'deki; Gansu - Dingxin, Yongchang, Jingtai ve Wushan bölgelerine ait rüzgar hızı verileri	İleriye yönelik rüzgar hızı tahmini
(C. Wang vd., 2021)	CEEMDAN, WPD (Dalgacık Paketi Ayrıştırma) ve GRU (Kapılı Yinelemeli Birim) modelinden oluşan hibrit model	Bir açık deniz rüzgar çiftliğine ait 10 dakika periyotlu rüzgar hızı verisi	İleriye dönük 10 dk, 30 dk, 1 saat ve 2 saatlik rüzgar hızı tahmini

1.2. Tez Çalışmasının Katkıları

Bu tez çalışmasında, literatürdeki rüzgar tahmin çalışmaları detaylı bir şekilde incelenmiş; geliştirilen modellerin performansını ölçmek için rüzgar hızı ve rüzgar gücü verilerinin beraber kullanılmadığı, normalizasyon yöntemlerinin etkisinin yeterince incelenmediği ve bu alanda kullanılmayan ayrıştırma işlemleri ile tahmin modelleri tespit edilmiştir. Böylece ileriye dönük bir saatlik rüzgar hızı ile rüzgar gücü tahmini için hibrit tahmin modelleri geliştirilerek literatüre çeşitli katkılar sunulmuştur. Bu katkılar özetle, dört farklı veri setinin kullanılması, birincil ve ikincil ayrıştırma işlemlerinin uygulanması, iki farklı normalizasyon yönteminin kullanılması ve dört derin öğrenme-yapay sinir ağı modelinin kullanılması şeklindedir. Yapılan bu katkılar aşağıda maddeler halinde listelenmiştir.

1. Geliştirilen modellerin karadaki ve açık denizlerdeki rüzgar tahminlerinde göstereceği performansı analiz etmek amacıyla, bu çalışmada kullanılan modellerin tahmin süreçlerinde bir karasal rüzgar hızı verisi ve üç farklı açık deniz rüzgar güç verisi kullanılmıştır. Bu veriler, modellerin karadaki ve denizdeki rüzgarların karakteristiğini öğrenip yapılan tahminlerdeki başarısı hakkında fikir vermesi açısından önemlidir.

2. Rüzgarın stokastik ve öngörülemez doğası, doğru tahmin yapmayı zorlaştırır. Bu nedenle, modellerde kullanılan veriler önce ayrıştırılır. Bu süreçte rüzgar verileri bileşenlerine ayrılarak verilerdeki anomaliler tespit edilebilmekte ve verinin anlaşılma oranı artırılabilir. Böylece, tahminlerde olumsuz etki yaratan rüzgardaki ani değişimlerin etkisi azaltılarak modellerin başarı oranları ve performansları geliştirilmiştir.

3. Ayrıştırma işlemleri birincil ve ikincil ayrıştırma olmak üzere iki şekilde yapıldı. Birincil ayrıştırma işlemlerinde bir ayrıştırma algoritması kullanılırken ikincil ayrıştırma işlemlerinde iki ayrıştırma algoritması kullanılmıştır. İkincil ayrıştırma işleminde birincil ayrıştırma işlemi sonucunda elde edilen en yüksek frekanslı bileşen ikinci ayrıştırma algoritması ile tekrar ayrıştırılmaktadır. Bu sayede en yüksek frekanslı bileşenin tahminlerdeki olumsuz etkileri azaltılmaktadır.

4. Normalizasyon işleminin tahminlere olan etkisini incelemek için Min-Max ve Z-skor işlemleriyle veriler normalize edilip tahmin işlemleri yapılmıştır. Uygulanan normalizasyon işlemleriyle modellerin tahminlerdeki performansı yükseltilip verinin daha uygun bir şekilde işlenmesi sağlanmaktadır. Ayrıca uygulanan işlemlerle sayısal kararlılık artırılarak hesaplama hataları ve aşırı büyük veya küçük sayıların sebep olabileceği sorunlar önlenabilmektedir.

5. Derin öğrenme ve yapay sinir ağı olarak kullanılan MLP, LSTM, BiLSTM, ve ESN modellerinin verileri öğrenme ve tahmin etmedeki başarıları incelendi. Yapılan tahminlerle elde edilen sonuçlara dayanarak, bir veri setinde başarılı olan bir modelin diğer veri setlerinde de aynı başarıyı gösterip göstermediği analiz edilerek, tüm veri setlerinde tek bir modelin ne kadar etkili olacağı araştırıldı.

6. Birincil ayrıştırma ve ikincil ayrıştırma metotları kullanılarak geliştirilen hibrit tahmin modellerinin başarıları, hiçbir ayrıştırma yönteminin kullanılmadığı tekil tahmin modellerinin başarılarıyla kıyaslanmaktadır. Ayrıca birincil ve ikincil ayrıştırma işleminin kullanıldığı modellerle elde edilen sonuçlar da kıyaslanarak ikincil ayrıştırmanın tahminlerdeki başarıya olan etkisi de incelenmiştir. Yapılan kıyaslamalar sayesinde ikincil ayrıştırmanın etkisi ve hibrit modellerin tekil modellere göre gösterdiği başarılar incelenmektedir.

Bu tez çalışmasında kullanılan veri setleri ve geliştirilen modeller ile literatüre kazandırılan yenilikler aşağıda sunulmaktadır.

1. Balıkesir bölgesine ait rüzgar hızı verisi ile West of Duddon Sands, Barrow ve Horns Power bölgelerine ait rüzgar gücü verisi olmak üzere dört farklı veri seti beraber kullanılmıştır. Bu veri setleri ilk defa bu çalışma kapsamında geliştirilen modellerin performansını ölçmek amacıyla beraber kullanılmıştır.

2. İkincil ayrıştırma işlemi kapsamında, hem EMD ile VMD hem de EMD ile SWD teknikleri birlikte kullanılarak, hibrit rüzgar gücü ve rüzgar hızı tahmin modelleri geliştirilmiştir. Geliştirilen modeller ise EMD-VMD-LSTM, EMD-VMD-BiLSTM, EMD-SWD-LSTM ve EMD-SWD-BiLSTM şeklindedir.

3. EMD ve ESN yöntemlerinin entegre edildiği hibrit EMD-ESN modelinde West of Duddon Sands, Barrow ve Horns Power bölgelerinden elde edilen rüzgar gücü verileri kullanılarak rüzgar gücü tahminleri yapılmıştır.

4. Geliştirilen modellerde, veri setinin daha sağlıklı ve tutarlı sonuçlar verebilmesi için Min-Max ve Z-Skor normalizasyon teknikleri kullanılarak normalizasyon işlemi gerçekleştirilmiştir.

2. ENERJİ KAVRAMI VE ENERJİ KAYNAKLARI

Enerji kavramı sadece fizik biliminde değil, biyoloji, kimya, çevre bilimleri ve ekonomi gibi birçok alanda da önemli bir rol oynamaktadır. Örneğin biyolojide canlıların hayatta kalabilmesi ve işlevlerini yerine getirebilmesi için enerji gereklidir (El-Hafez vd., 2022). Bitkiler fotosentez işlemi sırasında güneş enerjisini kimyasal enerjiye dönüştürürken, bu kimyasal enerji insanlar ve hayvanlar tarafından besinler yoluyla alınarak metabolik süreçlerde kullanılır (Ahvenainen, 2017; Buan, 2018). Kimyada kimyasal reaksiyonlar ve bağ enerjileri, maddelerin enerji dönüşümleriyle doğrudan ilişkilidir; bu reaksiyonlar sırasında enerji açığa çıkabilir veya emilebilir. Çevre bilimlerinde enerji, doğal kaynakların yönetimi ve sürdürülebilirliği açısından önemli bir konudur (Olugbenga, 2009). Enerji; fosil yakıtların kullanımı, yenilenebilir enerji kaynaklarının geliştirilmesi ve enerji verimliliği, çevresel etkiler ve iklim değişikliği bağlamında büyük önem taşımaktadır (Abuzaid vd., 2022). Ekonomi alanında enerji, ekonomik faaliyetlerin ve endüstriyel süreçlerin temel bileşeni olarak kabul edilmektedir (Haldorai, 2022). Enerji maliyetleri, enerji arz ve talebi, enerji piyasaları ve politikaları ekonomik büyüme ve kalkınma üzerinde belirleyici etkilere sahiptir (Zwane vd., 2022).

Enerji kavramının bu kadar geniş ve çeşitli alanlarda uygulanabilmesi, doğrudan ya da dolaylı olarak her alanda bulunmasının bir sonucu olarak açıklanabilir. Modern yaşamın ayrılmaz bir parçası haline gelen kavramlar (Detken, 2023); teknolojideki ilerlemeler, enerji kaynaklarının keşfi ve kullanımı, enerji depolama ve enerji dağıtım teknolojilerindeki ilerlemeler olarak ifade edilebilir (Ikumapayi vd., 2023; Baudel, 2022). Enerji, günümüz dinamiklerini şekillendiren ve sürdürülebilir bir gelecek inşa etmek için sürekli üzerinde çalışılan bir alandır (Zsiborács vd., 2024; Salvarli ve Salvarli, 2020). Bu nedenle enerji konusunda akademik ve uygulamalı çalışmalar geleceğe yönelik enerji çözümlerinin ve politikalarının oluşturulması açısından hayati önem taşımaktadır.

Enerji kaynakları iki ana kategoriye ayrılabilir: yenilenemeyen ve yenilenebilir (Edenhofer vd., 2011). Yenilenemeyen enerji kaynakları, doğada sınırlı miktarda bulunan ve tükenildiğinde yenilenemeyen fosil yakıtlar ve nükleer enerji gibi kaynaklardan oluşmaktadır (Deshmukh vd., 2023). Bu kaynaklar, yüksek enerji yoğunlukları ve kolay erişilebilirlikleri nedeniyle yaygın olarak kullanılmaktadır ancak çevreye zararlı etkileri ve sürdürülemezliği gibi dezavantajları bulunmaktadır (Z. Wang vd., 2023; Valero vd., 2018). Yenilenebilir enerji kaynakları güneş, rüzgar, hidroelektrik, jeotermal ve biyokütle gibi sürekli yenilenen ve doğanın kendi dön-

güsünde tükenmeyen enerji kaynaklarıdır (Koohi-Fayegh ve Rosen, 2020; Arefin, 2020). Çevre dostu ve sürdürülebilir olmaları bu enerji kaynaklarını giderek daha popüler hale getirmektedir (Sani vd., 2019). Yenilenebilir enerji kullanımının artırılması, fosil yakıtların neden olduğu çevre sorunlarını azaltması ve enerji güvenliğini sağlaması açısından büyük önem taşımaktadır.

2.1. Yenilenemeyen Enerji Kaynakları

Yenilenemeyen (konvansiyonel) enerji kaynakları doğada sınırlı miktarda bulunan ve kullanıldığında tükenen, yani yenilenemeyen kaynaklardır (Castillo-Mussot vd., 2016). Ayrıca bu tür kaynakların kullanımının çevreye ve iklim değişikliği üzerinde olumsuz etkileri de bulunmaktadır (Ivanovski vd., 2021). Bu enerji kaynakları genellikle milyonlarca yıl süren doğal süreçler sonucunda ortaya çıkmakta ve yoğun insan kullanım faaliyetleri nedeniyle hızla tükenmektedir (Ertimi vd., 2021). Yenilenemeyen başlıca enerji kaynakları aşağıda verilmiştir.

2.1.1. Fosil Yakıtlar

Milyonlarca yıl süresince yer altında kalan organik maddelerin dönüşmesi ve çürümesiyle fosil yakıtlar oluşmaktadır (Schulthoff vd., 2022). Fosil yakıtlar; kömür, petrol ve doğal gaz olmak üzere aşağıdaki gibi üç ana başlık altında toplanabilir.

Kömür: Yer kabuğunun derinliklerinde, bataklıklarda biriken bitki ve ağaç materyallerinin yüksek basınç ve sıcaklık altında milyonlarca yıl boyunca dönüşmesiyle oluşmaktadır. Kömür; elektrik enerjisi üretiminde, demir cevherinden çelik elde edilmesinde, bazı endüstriyel alanlarda ve ısıtma amaçlı olarak kullanılmaktadır (Sobolev vd., 2023). Kömür kullanımı sonucunda karbondioksit (CO₂), kükürt dioksit (SO₂) ve nitrojen oksitler (NO_x) gibi zararlı gazların atmosfere salınması hava kirliliğine neden olmakta ve iklim değişikliği üzerinde olumsuz etkilere neden olmaktadır (Regufe vd., 2021). Ayrıca yer altından kömür çıkarmak amacıyla yapılan madencilik faaliyetleri de çevresel bozulmaya ve su kirliliğine neden olabilmektedir (Wibawa vd., 2020).

Petrol: Deniz, göl gibi büyük su kütlelerinde biriken plankton gibi organik maddelerin ve mikroskobik parçacıkların milyonlarca yıl boyunca yüksek basınç ve sıcaklık altında dönüşmesiyle ortaya çıkar. Petrolün ana bileşeni hidrokarbonlardır ve petrolün yapısında kükürt, nitrojen ve oksijen de bulunmaktadır (Alzahrani ve Rajendran, 2019). Günümüzde öncelikli olarak ulaşımda kullanılan benzin ve motorin de petrolden üretilmektedir. Bunun dışında petrol; elektrik üretiminde, ısıtmada, aydınlatmada kullanılmakta olup sanayide plastik, gübre, ilaç ve bazı kimyasal ürünlerin üretiminde temel hammaddedir (Nolan, 2019). Petrolün tüm bu fay-

dalarının yanı sıra çeşitli zararları da bulunmaktadır. Petrol çıkarılıp kullanılırken toprağın ve suyun kirlenmesine neden olur, bu da çevre kirliliğine neden olur (Sun ve Li, 2020). Ayrıca petrol ve türevlerinin yanması sonucu atmosfere salınan sera gazları, günümüzde büyük sorun haline gelen küresel ısınma ve iklim değişikliği gibi durumlara olumsuz etki yapmaktadır.


Doğal gaz: Doğal gaz, karada ve denizlerin tabanlarında biriken organik maddelerin yüksek basınç ve sıcaklık altında milyonlarca yıllık bir süreç içerisinde oluşan metan ağırlıklı bir enerji kaynağıdır. Doğal gazın ana bileşeni metan olmasına rağmen yapısında etan, propan, bütan ve diğer hidrokarbonlarla beraber az miktarda karbondioksit, nitrojen, hidrojen sülfür ve helyum da bulunabilmektedir (Drake vd., 2019). Doğal gaz; elektrik üretiminde, ısıtmada, ulaşımda ve petrokimya endüstrisinde hammadde olarak kullanılmaktadır (Zelenika vd., 2021). Doğal gaz, kömür ve petrol gibi diğer fosil yakıtlarla karşılaştırıldığında daha temiz bir yanma sürecine sahiptir ve yanma sonucu karbondioksit ve kükürt dioksit gibi zararlı maddelerin salınımı daha azdır (Khade vd., 2023). Bu nedenle yenilenebilir enerji kaynaklarına geçişte petrol ve kömür yerine alternatif enerji kaynağı olarak değerlendirilmektedir (Rao vd., 2018). Ancak güçlü bir sera gazı olan metan, doğal gazın ana bileşeni olduğundan metan sızıntıları yaşanması durumunda ciddi bir çevre sorunu yaşanabilir (Carlucci, 2019).

2.1.2. Nükleer Enerji

Nükleer enerji, uranyum ve plütonyum gibi radyoaktif elementlerin atom çekirdeklerinin parçalanması veya birleşmesi sonucu ortaya çıkan bir enerjidir (Putri vd., 2022). Günümüzde elektrik enerjisinin üretiminde ağırlıklı olarak çekirdeklerin parçalanması yöntemi kullanılmaktadır (Guarierio vd., 2022). Nükleer santrallerde gerçekleştirilen bu işlemle büyük miktarda enerji açığa çıkarılmaktadır. Bu sayede kesintisiz ve sürekli enerji üretimi sağlanabilmektedir. Nükleer enerji, düşük karbon emisyonuna sahip olduğu için yenilenebilir enerji kaynaklarıyla birlikte iklim değişikliğiyle mücadelede önemli bir rol üstlenebilir (Yu, 2021). Ancak enerji üretimi sırasında ortaya çıkan radyoaktif atıklar binlerce yıl boyunca tehlikeli olabilmektedir ve çevre ile insan sağlığı için tehdit oluşturabildiğinden bunların güvenli bir şekilde depolanması ve yönetilmesi çok büyük önem teşkil etmektedir (Wisnubroto vd., 2021). Ayrıca nükleer santrallerde meydana gelebilecek kazalar insan ve çevre sağlığı üzerinde yıllarca devam edecek olan çok ciddi sorunlar oluşturacaktır (IAEA, 2001).

2.2. Yenilenebilir Enerji Kaynakları

Yenilenebilir enerji, doğal kaynaklardan elde edilen ve devamlı bir şekilde yenilenebilen enerji çeşitleri şeklinde ifade edilebilir. Yenilenebilir enerji, geleneksel fosil yakıtlara alternatif olarak sunulan sürdürülebilir ve çevre dostu çözümdür (Sirmaçek vd., 2023). Bu çözüm, son yıllarda giderek artan küresel ısınma ve iklim değişikliğiyle mücadelede önemli rol oynamaktadır (Verma, 2021). Yenilenebilir enerji kaynaklarının mevcut durumda toplam dünya enerji talebinin %15 ila %20'sini karşıladığı tahmin edilmektedir ve biyokütlenin geleneksel kullanımları da hesaba katılacak olunursa, yenilenebilir enerji kaynaklarının küresel enerji talebinin yaklaşık %18'ini karşılayacağı düşünülmektedir (Painuly, 2001; Ellabban vd., 2014). Şekil 2.1'de 2016 ila 2028 yılları için yenilenebilir enerji kaynaklarının kapasiteleri verilmektedir. Yenilenebilir enerji kaynaklarının potansiyelinin oldukça fazla olduğu ve teorikte dünyanın enerji talebini karşılayabileceği öngörülmektedir (Sharma vd., 2020). Yenilenebilir enerji türleri; güneş enerjisi, hidroelektrik enerji, biyokütle enerjisi, jeotermal enerji ve rüzgar enerjisi şeklinde sınıflandırılabilir.



Şekil 2.1. 2016-2028 yılları için yenilenebilir enerji kapasiteleri

Kaynak: (IEA, 2023)

Güneş enerjisi: Güneş ışığından elde edilen yenilenebilir ve çevre dostu bir enerji kaynağıdır. Fotovoltaik paneller ve piller ile yoğunlaştırılmış güneş enerjisi teknolojilerinin kullanılmasıyla elektrik ve ısı üretiminde yaygın bir enerjidir (Maharana vd., 2021). Güneş panellerinin; binaların dış cephelerine, çatıların üstüne ve geniş arazilere kurulmasıyla oluşturulan sistemlerden enerji sağlanır. Güneş var oldukça güneş enerjisinin de var olması, düşük işletme maliyetleri, enerji bağımsızlığı ve çevre dostu olması ise güneş enerjisinin başlıca avantajları

arasındadır (Imasiku, 2021). Ülkemizde de son yıllarda güneş enerjisinden elektrik üretmek için büyük yatırımlar yapılmaktadır. İlk kurulum maliyetlerinin yüksekliği ve hava koşullarına bağlı olarak enerji üretiminin değişmesi ise güneş enerjisinin dezavantajları olarak sayılabilir (Devabhaktuni vd., 2013).

Hidroelektrik enerji: Suyun kinetik ve potansiyel enerjisinin elektrik enerjisine dönüştürülmesiyle üretilen çevre dostu ve yenilenebilir bir enerji kaynağıdır. Barajlar ve nehir tipi santraller aracılığıyla suyun yüksek basınçla türbinleri döndürmesiyle elektrik üretilmektedir (Gyamfi vd., 2018). Bu santrallerle enerji arzı; düşük işletme maliyetleri, yüksek verimlilik oranları ve uzun ömürlü gibi özellikler sayesinde sağlanmaktadır (Lou vd., 2023). Bu avantajların yanında barajların ekosistemler üzerindeki olumsuz etkileri, balıkların göç yollarını engellemesi ve suyun kalitesini olumsuz etkilemesi gibi dezavantajları da bulunabilmektedir (Ali vd., 2020). Ayrıca, barajların inşaatları yüksek maliyetler gerektirmekte ve bazen yerel toplulukların yer değiştirmesine sebep olabilmektedir (Akhmetshin ve Kovalenko, 2019). Teknolojide yaşanan gelişmeler ve yapılacak çevresel düzenlemelerle hidroelektrik santrallerin verimliliği ve sürdürülebilirliği daha da artırılabilir. Elektrik üretimi için her zaman büyük barajlar gerekmemekte; küçük ölçekli hidroelektrik projeleri ve pompalı depolama sistemleriyle de üretim yapılarak enerji güvenliğine önemli katkılar sağlanmaktadır (Navia ve Amaya, 2023).

Biyokütle enerjisi: Enerji üretmek amacıyla organik maddelerden elde edilen yenilenebilir bir enerji çeşididir. Ağaç atıkları, tarımsal atıklar, hayvansal atıklar ve biyokütle enerjisi elde etmek için özel olarak yetiştirilen bitkiler bu enerji için kaynak olarak kullanılmaktadır (Carraro vd., 2020). Kaynaklar; yakma, piroliz, gazlaştırma, fermentasyon ve anaerobik sindirim gibi farklı yöntemler yardımıyla enerjiye dönüştürülmektedir (Rathore vd., 2022). Biyokütle enerjisinin en dikkat çekici özellikleri, yenilenebilir ve karbon nötr olmasıdır. Çünkü bitkilerin büyümek için ihtiyaç duyarak atmosferden aldığı karbon, enerji üretilirken atmosfere geri salınmaktadır (Uddin vd., 2018). Ayrıca, enerji üretiminde kullanılan tarımsal, hayvansal ve endüstriyel atıkların azaltılması, atık yönetiminde iyileştirmelere yol açmakta ve yerel kaynakların kullanılması sayesinde enerji güvenliğini artırmaktadır (Vyas vd., 2022). Tüm bu olumlu yönlerinin yanında, genelde biyokütle enerjisinin verimliliği diğer enerji kaynaklarına göre daha düşük ve enerji bitkilerinin yetişmesi için geniş tarım arazileri gerekmesi bu enerjinin dezavantajları olarak söylenebilir (Woolf vd., 2016).

Jeotermal enerji: Yer kabuğunun derinliklerindeki sıcak su ve buharının yüzeye çıkarılmasıyla kullanılan Dünya'nın iç yapısındaki ısısından elde edilen bir yenilenebilir enerji türüdür. Jeotermal enerji, genellikle volkanik bölgeler, sıcak su kaynakları ve jeotermal kaynakların olduğu yerlerde yaygın olarak bulunmaktadır (Alfaro vd., 2021). Bu enerji, buhar santralleri aracılığıyla elektrik üretiminde ve binalarda ısıtma amaçlı olarak kullanılmaktadır. Jeotermal enerji; sürdürülebilir, karbon salınımının düşük olması ve hava koşullarından bağımsız olarak sürekli enerji üretimi sağlaması nedeniyle tercih edilmektedir (Takács, 2017). Jeotermal enerji kaynaklarının dezavantajları; coğrafi olarak sınırlı olup sadece belirli bölgelerde bulunması ve ilk kurulumda yüksek sondaj ve altyapı maliyetleri gerektirmesi olarak söylenebilir (Islam vd., 2022). Yanlış yönetildiğinde yeraltı sularının kirlenmesine ve yüzeyde deformasyona neden olması gibi çevresel riskler de taşıyabilmektedir (Dhar vd., 2020). Ancak, teknolojiden faydalanarak ve doğru stratejilerle yönetildiğinde, jeotermal enerjinin fosil yakıtlara olan bağımlılığı azaltarak çevre dostu ve sürdürülebilir bir alternatif enerji kaynağı sunacağı öngörülmektedir (Ismail, 2011).

Rüzgar enerjisi: Atmosferdeki hava hareketlerinden elde edilen yenilenebilir ve sürdürülebilir bir enerji türüdür. Rüzgar türbinleri sayesinde rüzgarın kinetik enerjisi mekanik enerjiye, ardından elektrik enerjisine dönüştürülmektedir. Rüzgar enerjisi, karasal ve açık denizlerde deniz üstü türbinler olmak üzere iki ana kategoride incelenmektedir (Peçanha vd., 2020). Ayrıca düşük karbon salınımı ve düşük işletme maliyetleri ile öne çıkan rüzgar enerjisi, yerel enerji kaynaklarının kullanımını sağlayarak enerji güvenliğini artırır ve bölgesel kalkınmalara katkı sağlar (Olabi vd., 2021). Bununla birlikte, rüzgarın sürekliliği ve şiddetine bağlı olarak enerji üretiminde dalgalanmalar yaşanabilmektedir, kurulan türbinlerin geniş alanlar kaplaması ve manzara üzerinde olumsuz etkileri olabilmektedir (Singh, 2023). Rüzgar türbinlerinin ilk kurulum maliyetleri yüksek olabilir; ancak teknolojideki ilerlemeler sayesinde maliyetler düşmüş ve bu da rüzgar enerjisini fosil yakıtlara kıyasla daha cazip bir alternatif enerji kaynağı haline getirmiştir (Du, 2019). Rüzgar enerjisinin temiz ve çevre dostu bir enerji kaynağı olarak gelecekte enerji üretiminde önemli bir rol oynamaya devam edeceği düşünülmektedir (Stadtman vd., 2023). Bu tez çalışmasının konusu rüzgar tahmini olduğu için sonraki bölümde rüzgar ile ilgili detaylı bilgilere yer verilecektir.

2.3. Rüzgar Enerjisi

Rüzgar enerjisi; karasal ve açık deniz rüzgar enerjisi olarak ikiye ayrılabilir. Karasal rüzgar enerjisi, karada kurulan rüzgar türbinleri yardımıyla elde edilen enerjidir. Türbinler, hesaplamalar ve ölçümler yapılarak en uygun yerlere konumlandırılır. Bu tür türbinlerin çeşitli dezavantları bulunmaktadır. Bunlar; geniş alanlar kaplayarak manzara üzerinde olumsuz etkilere sebep olması, türbinlerin çalışması sırasında çıkan gürültü, kuşlar üzerindeki olumsuzluklar ve ilk kurulum maliyetinin yüksekliği şeklindedir (Q. Gao vd., 2022). Ancak ilk kurulumdan sonra maliyetlerin düşmesi ve yenilenebilir olması en büyük avantajdır (Seetharaman vd., 2019). Türkiye ve dünyanın birçok bölgesinde rüzgar enerjisi elde etmek için genelde bu enerji türü kullanılmaktadır (Çelikdemir ve Özdemir, 2023).

Açık deniz rüzgar enerjisi; açık denizlerde kurulan rüzgar türbinlerinden elde edilen enerjidir. Açık deniz rüzgar türbinleri, çoğunlukla kıyıdan belli bir mesafedeki uzaklıkta ve suyun içinde kurulurlar. Bu sayede kıyıdan uzaktaki denizlerde bulunan ve karadakilere göre daha güçlü-sürekli olan rüzgar akımlarından faydalanılır (Kořakowski ve Rutkowski, 2022). Açık deniz türbinleri; karasal alanlara ihtiyaç duymadığı için arazi kullanımları üzerinde olumsuz etkileri daha azdır, karada görsel ve gürültü kirliliğine de sebep olmazlar (Xu ve Si, 2018). Bu sistemlerin dezavantajları; türbinler denizde kurulduğu için ilk kurulum ile bakım maliyetleri yüksektir, denizdeki zorlu koşullar bakım-onarımı karmaşık hale getirebilir ve türbinler kurulurken dikkatli olunmaması durumunda deniz ekosistemleri üzerinde olumsuz etkiler yaratabilir (Degraer vd., 2020). Açık deniz rüzgar enerjisi, özellikle Avrupa kıtasında büyük bir gelişim göstermektedir. Baltık Denizi, Kuzey Denizi ve Atlantik Okyanusu'nda büyük rüzgar çiftlikleri bulunmaktadır (Musial vd., 2019).

Yukarıda da açıklandığı gibi hem kara hem de açık deniz rüzgar enerjilerinden faydalanmak için kurulan sistemlerin avantaj ve devantajları bulunduğu görülmektedir. Ancak uzun vadede iklim değişikliği, sera gazları ve sürdürülebilirlik gibi faydaları düşünülecek olursa bu enerjilerin kullanımının dünyadaki insan ve diğer canlı yaşamı için büyük yararlar sağlayacağı düşünülmektedir (Gandoman vd., 2020).

Rüzgar enerjisi güç yoğunluğu, rüzgardan elde edilecek güç ve yapılacak yatırımlar için oldukça önemlidir. Bir bölgeye rüzgar türbinleri kurulmadan önce yaklaşık bir yıl boyunca rüzgar ölçümleri yapılmaktadır (Ataseven ve Ataseven, 2009). Yıllık ortalama güç yoğunluğu $\bar{P}_i$, yıllık ortalama hava yoğunluğu ρ_i , ortalamanın alındığı süre içerisindeki toplam gözlem sayısı


n ve gözlem yapıldığındaki rüzgar hızı V_i olmak üzere rüzgar enerjisi güç yoğunluğu aşağıdaki denklemle hesaplanır (Akınsal, 2009).

$$\bar{P}_i = \frac{1}{2n} \sum_{i=1}^n \rho_i V_i^3 \quad (2.1)$$

Rüzgar enerjisinden elde edilecek güç, yapılacak yatırımlar ve elde edilecek ekonomik kazanımlar için oldukça önemlidir. Rüzgar enerjisinden elde edilecek güç aşağıda verilen denklemler yardımıyla ile hesaplanabilir. Denklemlerde P elde edilecek güç, C_p güç katsayısı, ρ havanın yoğunluğu, A rüzgar türbin kanatlarının süpürdüğü alanı, r rotor yarıçapı ve V rüzgar hızı olarak ifade edilmektedir. Şekil 2.2’de rüzgar türbini kanatları ve süpürme alanı gösterilmiştir.

$$A = \pi r^2 \quad (2.2)$$

$$P = \frac{1}{2} C_p \rho A V^3 \quad (2.3)$$




Şekil 2.2. Türbin kanatları süpürme alanı

Yukarıdaki eşitliklerde görülebileceği üzere rüzgardan elde edilecek gücü artırmanın bir yolu da daha büyük rotor yarıçapına sahip türbinler kullanmaktır. Şekil 2.3’te gösterildiği gibi 1980 ila 2030 yılları arası için rüzgar türbin boyutları verilmektedir. Şekilde 2030 yılı için verilen boyut tahmin edilen boyuttur.


Rüzgar türbinleri, kullanılan rotorun çeşidine göre yatay ve dikey eksenli olmak üzere iki kategoriye ayrılabilir. Bu türbin türleri Şekil 2.4’te verilmiştir. Yatay eksenli rüzgar tür-

binlerinin en büyük avantajı, sağladığı yüksek verimlilik ve enerji üretim kapasitesidir. Ayrıca türbinlerin aerodinamik tasarımı, büyük ölçekli kullanım olanağı ve yüksek rüzgar hızlarında verimli çalışmasına da imkan tanımaktadır. Dikey eksenlilerde ise generatör ve dişli kutusu gibi aktarma organlarının yerde konumlandırılması bu tipteki türbinlerin en iyi avantajı olarak görülmektedir. Bu türdeki türbinlerin kullanımı yatay eksenlilere göre oldukça düşüktür.



Şekil 2.3. 1980-2030 yılları için kara ve açık deniz rüzgar türbini boyutları


Kaynak: (GWEC, 2024)



Şekil 2.4. Rotorlarına göre a) Yatay eksenli ve b) Dikey eksenli rüzgar türbini

Kaynak: (Dursun, 2020)

Rüzgar enerjisini kullanmak için rüzgar türbinlerinde birçok donanım ve parça bulunmaktadır. Bu bileşenlerin türbinlerde bulunduğu konumlar ve isimleri Şekil 2.5'te sunulan türbin üzerinde gösterilmektedir. Türbinlerden enerji elde etmek için bu bileşenlerin bakımlarının ve kontrollerinin düzenli periyotlarla yapılması gerekmektedir.



Şekil 2.5. Yatay eksenli bir rüzgar türbinine ait genel yapı ve donanımlar

Kaynak: (Akdoğan, 2011)

3. KULLANILAN METOTLAR VE YÖNTEMLER


Bu bölümde tez çalışmasında kullanılan metotlar ve ayrıştırma yöntemleri açıklanmaktadır. Ayrıca çalışmaların tasarımı ve yürütülme sürecinde kullanılan yöntemlerin seçimi ve uygulanmasıyla ilgili açıklamalar da bulunmaktadır. Tezin temel metotları, araştırmanın amaçları doğrultusunda belirlenmiş olup bu doğrultuda veri toplama ve hibrit modeller geliştirilmiştir.

3.1. Kullanılan Öğrenme ve Tahmin Modelleri

Bu bölümde, çalışmada kullanılan metotlar olan MLP, LSTM, BiLSTM ve ESN modelleri hakkında detaylı bilgiler verilmektedir. Bu modeller, genellikle zaman serilerinin analizinde derin öğrenme alanında yaygın olarak kullanılan temel tekniklerdir. MLP, bir geleneksel yapay sinir ağı yapısı olup, gizli katmanları sayesinde karmaşık ilişkileri modelleyebilmektedir. LSTM, zaman serileri gibi zaman bağımlı verilerde uzun vadeli bağımlılıkları koruyabilen özel bir yinelemeli sinir ağı türüdür. BiLSTM ise, LSTM'nin geliştirilmiş bir versiyonu olup, girdi verilerini hem ileri hem de geri yönlü işleyerek veriler arasında daha kapsamlı ilişki kurulmasında yardımcı olur. ESN modeli geri beslemeli yapay sinir ağlarının bir türü olup, rastgele oluşturulmuş ve sabitlenen bir iç durumu kullanarak zaman serisi verilerinin öğrenilmesini ve tahmin edilmesini sağlar. Bu bölümde, her bir modelin çalışma prensipleri detaylı bir şekilde ele alınacaktır.

3.1.1. Çok Katmanlı Algılayıcı

Esnek ve başarılı makine öğrenme yöntemleri yapay sinir ağları (YSA) insan beyninin çalışmasından esinlenerek geliştirilmiştir. YSA, klasik yöntemlerle çözülmesi zor olan problemlerde etkin bir alternatif oluşturmaktadır. MLP, basit bir yapıya sahip sık kullanılan ve geleneksel ileri beslemeli YSA'lar arasında oldukça popülerdir (Gorgel ve Kavlak, 2020). Tek katmanlı algılayıcılarla doğrusal olaylar tahmin edilebilirken, MLP ile doğrusal olmayan olayların tahmini de yapılabilmektedir (Konakoglu, 2020). MLP, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı olmak üzere birkaç katmandan meydana gelmektedir. Bu katmanlar Şekil 3.1'de gösterilmiştir.



Şekil 3.1. MLP modelinin genel yapısı

Kaynak: (Balcı vd., 2022)

MLP'nin matematiksel denklemleri aşağıda gösterilmiştir. Denklemlerde; X giriş, H gizli katmanın çıkışı (gizli katman değişkeni olarak da ifade edilir), $W1$ gizli katmanın ağırlığı, $b1$ gizli katman için eşik değeri, $W2$ çıkış katmanının ağırlığı, $b2$ çıkış katmanının eşik değeri, ϕ aktivasyon fonksiyonu ve O çıkış şeklindedir.

$$H = \phi(X.W1 + b1) \quad (3.1)$$


$$O = H.W2 + b2 \quad (3.2)$$

MLP'de, giriş katmanı veri girişinin yapıldığı yerdir. Çıkış katmanının parametreleri ilgili problemin hedef değerlerine göre belirlenir. Şekil 3.1'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 ağdaki parametreler ağın 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, ağın her nöronuna ait aktivasyon fonksiyonuna uygun olarak gizli nöronlarla ilişkili parametreleri tahsis etmesi için ağ eğitilmektedir. Aktivasyon fonksiyonu doğrusal ve doğrusal olmayan fonksiyonlar şeklinde ikiye ayrılır. Doğrusal olmayan fonksiyonlarda genellikle sigmoid ve hiperbolik tanjant fonksiyonları kullanılmaktadır. Bu çalışmada, aktivasyon fonksiyonu olarak logsig (Log-sigmoid) fonksiyonu kullanılmıştır.

3.1.2. Uzun Kısa Süreli Bellek

LSTM, belirli bir zaman aralığında değerleri hatırlama yeteneğine sahip bir tür tekrarlayan sinir ağıdır (RNN). LSTM'lerde, öğrenilen bilgiler saklanır ve zaman içinde bu değerler korunur. Ayrıca LSTM'de nöronlar arasında ileriye doğru bağlantılara izin verilir. LSTM, olaylar arasında belirsiz aralıklar ve sürelerin bulunduğu durumlarda zaman serilerini sınıflandırmak, işlemek ve tahmin etmek için oldukça uygun bir modeldir. LSTM ağları, LSTM üniteleri ve tekrar eden bileşenlerden oluşur. Bu tekrar eden bileşenler, ağın uzun veya kısa süreli bilgileri hatırlamasını sağlar. Böylece saklanan bilgiler, yinelemeli olarak değişmeden kalır ve ağ zaman içinde geri yayılım algoritmasıyla eğitilir. LSTM'nin genel yapısı Şekil 3.2'de gösterilmektedir.

LSTM, ardışık verilerde uzun vadeli bağımlılıkları koruyabilen bir RNN türüdür. Özellikle, geleneksel RNN'lerde yaygın olan kaybolan gradyan sorununu önlemek için tasarlanmıştır, bu sorun uzun vadeli bağımlılıkları öğrenmeyi zorlaştırır. LSTM'ler, bilgiyi işleyip ileten bir dizi hücreden oluşur ve her hücre; giriş, unutma ve çıkış kapıları adı verilen üç tür kapıyı içerir. Bu kapılar, LSTM'in önceki zaman adımlarından bilgiyi seçip saklamasına veya reddetmesine izin verir, bu durum LSTM'in uzun vadeli bağımlılıkları öğrenmesine ve sürdürmesine olanak tanır (Hochreiter ve Schmidhuber, Kasım 1997).



Şekil 3.2. LSTM'in genel mimarisi

Kaynak: (Balci vd., 2023)

LSTM'in işlem adımları aşağıda gösterildiği gibi sıralanabilir.

1. x_t ve b_{t-1} değerleri hesaplanır ve atılacak (sonraki aşamaya aktarılmayacak) değerler f_t sigmoid fonksiyonu ile tespit edilir.

$$f_t = \sigma(w_f.[h_{t-1}, x_t] + b_f) \quad (3.3)$$

2. Sigmoid katman tarafından saklanacak veriye karar verilir ve $\tilde{C}_t$ 'ye değer veren yeni aday $x(t)$, h_{t-1} ve $\tanh(\cdot)$ ile hesaplanır.

$$i_t = \sigma(w_i.[h_{t-1}, x_t] + b_i) \quad (3.4)$$

$$\tilde{C}_t = \tanh(w_c.[h_{t-1}, x_t] + b_c) \quad (3.5)$$

3. Yeni C_t , $\tilde{C}_t$ ile i_t ile çarpılması ve f_t ile C_t çarpımının toplamından elde edilir.

$$C_t = f_t.C_{t-1} + i_t.\tilde{C}_t \quad (3.6)$$


4. Sigmoid katmanı çıkış bilgisi için karar verir.

$$s_t = \sigma(w_o.[h_{t-1}, x_t] + b_o) \quad (3.7)$$

$$h_t = s_t.\tanh(C_t) \quad (3.8)$$

3.1.3. Çift Yönlü Uzun Kısa Süreli Bellek

BiLSTM, LSTM'in geliştirilmiş bir versiyonu olup iki bağımsız yapay sinir ağından meydana gelmektedir. Bu yapıda ağlar, hem ileriye hem de geriye doğru bilgiye sahiptir. Girdiler, geçmişten geleceğe ve gelecekte geçmiş olmak üzere iki farklı yönde işlenir. BiLSTM'yi tek yönlü çalışan LSTM'den ayıran özellik, geleceğe yönelik bilginin de korunması ve bu bilginin iki gizli katmanla birleştirilmesidir. Bu sayede, herhangi bir zaman diliminde hem geçmiş hem de geleceğe ait bilgiler saklanabilir. BiLSTM'in genel çalışmasına ait diyagram Şekil 3.3'te verilmiştir.



Şekil 3.3. BiLSTM'in genel mimarisi


3.1.4. Yankı Durumu Ağları

ESN; yetenekli, uyarlanabilir, girdi katmanı, gizli katman ve çıktı katmanından oluşan bir RNN mimarisidir. ESN, seyrek ve rastgele tekrarlayan bağlantılara sahip çok sayıda rastgele oluşturulmuş nörondan oluşan ve eğitilebilir bir doğrusal katmandan oluşmaktadır (Zheng vd., 2020). Model, karmaşık zamansal verileri işleme kapasitesine sahip olup ESN'lerle, özellikle doğrusal olmayan zaman serilerinin tahmini, örüntü tanıma ve sinyal işleme gibi çalışmalar yapılabilir. Sağladığı etkinlik ve basitlik sayesinde, özellikle zaman serisi tahminlerinde dikkate değer bir ilgi görmektedir (J. Liu vd., 2020).

ESN'nin merkezinde, birbirine bağlı düğümlerden oluşan dinamik bir rezervuar bulunur. Bu aktivasyonlar, girdi verilerindeki zamansal bağımlılıkları ve karmaşık desenleri topluca yakalar. ESN'leri geleneksel RNN'lerden ayıran şey, bu düğümlerin sabit, rastgele bağlantılı olmasıdır; bu bağlantılara 'rezervuar' denir ve tekrarlayan ağların eğitim zorluklarını basitleştirerek eğitimin çok hızlı şekilde yapılmasını sağlar (Jaeger, 2001). Rezervuar, geleneksel sinir ağının gizli katmanına benzetilebilir (Hu vd., 2021). ESN'ler, sadeleştirilmiş mimarileri, kolay eğitim süreçleri ve geniş bir uygulama yelpazesinde gösterdikleri olağanüstü performans ile tanınırlar.

ESN modelinin temel mimarisi Şekil 3.4'te gösterilmiş olup modelin üç ana katmanı; bir girdi katmanı, dinamik bir rezervuar ve bir çıktı katmanı şeklindedir. Girdi katmanının rolü, ağın aktivasyonunu uyaran girdi sinyallerini almaktır. Dinamik rezervuar, seyrek bağlantılı birçok nöron içerir ve ESN'de gizli katmanın yerini alarak bilgiyi verimli bir şekilde işler. Son olarak, çıktı katmanı ağın çıktı sinyalini üretir. Şekil 3.4'teki ESN mimari yapısına bakıldığında, giriş katmanının H giriş birimlerine sahip olduğu, rezervuarın N rezervuar nö-

ronu içerdği ve çıktı katmanının L nöronundan oluştuğu kabul edilmektedir. Şekilde $u(k) = [u_1(k), u_2(k), \dots, u_H(k)]^T$ giriş vektörünü, $x(k) = [x_1(k), x_2(k), \dots, x_N(k)]^T$ dinamik rezervuarın durum vektörünü ve $y(k) = [y_1(k), y_2(k), \dots, y_L(k)]^T$ çıkış vektörünü temsil etmektedir. Dahili rezervuar birimleri arasındaki ağırlık matrisi W ile ifade edilir. Giriş katmanı ile rezervuar nöronları arasındaki bağlantı ise giriş ağırlığı matrisi (W_{giris}) ile gösterilmiştir.



Şekil 3.4. ESN modelinin genel mimarisi

Çıkış ağırlığı matrisi W_{cikis} ve çıktı katmanını rezervuar nöronlara bağlayan geri besleme ağırlık ilişkileri ise W_{geri} ile ifade edilmektedir. ESN rezervuarlarının ve çıktıların durumuna ilişkin güncelleme aşağıdaki denklemlerle ifade edilebilir:

$$x(k+1) = f(W_{giris}u(k+1) + W_x(k) + W_{geri}y(k)) \quad (3.9)$$

$$y(k+1) = g(W_{cikis}x(k+1)) \quad (3.10)$$

Yukarıdaki denklemlerde rezervuardaki nöronların aktivasyon fonksiyonları f ve çıkış katmanındaki nöronların aktivasyon fonksiyonları g ile belirtilmiştir. Eğitim süreci boyunca, giriş ağırlık matrisi W_{giris} , iç ağırlık matrisi W ve geri besleme ağırlık matrisi W_{geri} başlangıçta belirlenen değerlerini koruyarak sabit kalır, sadece çıkış ağırlık matrisi W_{cikis} eğitim veri seti rehberliğinde basit doğrusal regresyon ile uyarlanır. Bu yaklaşım, özellikle rezervuarın iç dinamiklerini temsil eden ağırlık matrislerinin orijinal rastgele başlatılmasını koruyarak ve bunları eğitim sırasında sabit tutarak öğrenme sürecini kolaylaştırır. Bu nedenle, bir ESN modellemenin ana odağı çıkış ağırlık matrisinin hesaplanmasıyla ilgilidir. Doğrusal regresyon algoritması

W_{cikis} 'i elde etmek için yaygın olarak kullanılır.

$$W_{cikis} = R^{-1}Y \quad (3.11)$$

Yukarıdaki eşitlikte R rezervuar durum vektörünü temsil ederken Y beklenen çıkış vektörünü belirtmektedir.

3.2. Ayırıştırma Metotları

Bu bölümde çalışmadaki hibrit modellerde kullanılan ayırıştırma algoritmaları hakkında bilgiler verilecektir. Ayırıştırma algoritmaları, rüzgarın yapısı dolayısıyla meydana gelen ani dalgalanmaların neden olduğu hata oranlarını azaltmak için kullanılmaktadır.

3.2.1. Ampirik Mod Ayırıştırması

EMD, sinyalleri zaman-frekans uzayında analiz etmek amacıyla kullanılan bir ayırıştırma yöntemidir. EMD ile sinyaller, zaman ölçeğinde darbeli bir frekans spektrumuna sahip ve sinyalin yapısını yansıtan bileşenler olan içsel mod fonksiyonlarına (Intrinsic Mode Functions, IMF) ayrıştırılır. Her IMF, sinyalin özgün bir bileşeni olup IMF'lerle sinyalin zaman-frekans özellikleri tespit edilebilir. Ayrıca IMF'ler, sinyalin belirli bir frekans aralığına ve zaman çerçevesine uygun şekilde uyum sağlayarak sinyalin yerel özelliklerinin ve yapılarının ayırt edilmesini sağlar. EMD adımları $x(t)$ bir sinyal olmak üzere aşağıda gösterilen adımlardan meydana gelmektedir (Wang, 2021).

1. Zaman serilerinin yerel maksimum ve yerel minimumları belirlenir. Yerel minimumun eğri interpolasyonu kullanılarak alt zarf sınırı ($l(t)$) ve yerel maksimumun eğri interpolasyonu kullanılarak üst zarf sınırı ($u(t)$) belirlenir.

2. Sinyalin ortalama bileşenini tespit için etmek kullanılan ortalama bileşen $m(t)$, üst ve alt zarflar kullanılarak hesaplanır.

$$m(t) = \frac{u(t) + l(t)}{2} \quad (3.12)$$

3. Orijinal sinyalden ortalama bileşen çıkarılır.

$$h(t) = x(t) - m(t) \quad (3.13)$$

4. $h(t)$ IMF ilkelerini karşılıyorsa, $h(t)$ yeni IMF $c(t)$ olarak kabul edilir ve artık sinyal $r(t)$ hesaplanır. Eğer IMF ilkeleri karşılanmıyorsa $h(t)$ ile $x(t)$ yer değiştirilir ve 1'den 4'e kadar adımlar tekrarlanır.

$$r(t) = x(t) - h(t) \quad (3.14)$$

5. $r(t)$ yeni $x(t)$ olarak ayarlanır ve tüm IMF'ler hesaplanana kadar ilk dört adım tekrarlanır.

Yukarıdaki adımlar boyunca IMF'ler edilir ve orijinal sinyal $x(t)$ aşağıdaki denklemle ifade edilmektedir. Denklemden n IMF sayısını, $c_i(t)$ IMF'yi ve $r_n(t)$ son kalıntıdır ve orijinal sinyalin eğilimi ifade etmektedir.

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (3.15)$$

3.2.2. Topluluk Ampirik Mod Ayrıştırması

EEMD, EMD'nin sinyallerin zaman-frekans özelliklerini ayırırken yaşanan zorlukları çözmek amacıyla geliştirilmiştir. EEMD'de, gerçekleştirilen çoklu EMD işlemlerinin toplu sonuçları kullanılarak belirli bir sinyal, zaman-frekans özelliklerine ayrıştırılmaktadır. Yani EEMD, EMD'nin geliştirilmiş bir versiyonudur. Dolayısıyla EMD'nin özelliklerine ve yeteneklerine sahip bir yöntemdir. EEMD'nin temel adımları aşağıdaki gibi özetlenmiştir (Gaci, 2016).

1. Orijinal sinyal $x(t)$ olmak üzere, $x(t)$ 'ye gürültü eklenir.

$$Y_n(t) = x(t) + u(t) \quad n = 1, 2, \dots, N \quad (3.16)$$

2. Yeni $Y_n(t)$ sinyali, EMD kullanılarak IMF'lerine ayrıştırılır. IMF'lerin toplam sayısı $M - 1$, $IMF_m^{(n)}$ m. IMF ve $r_M^{(n)}$ n. denemede bulunan kalıntı olmak üzere Y aşağıdaki gibi elde edilir.

$$Y_n(t) = \sum_{m=1}^{M-1} IMF_m^{(n)}(t) + r_M^{(n)}(t) \quad (3.17)$$

3. İlk iki adım sırasıyla N defa yinelenir. N. denemenin sonunda ortalama IMF ($\overline{IMF}_m$) elde edilir.

$$\overline{IMF}_m(t) = \frac{1}{N} \sum_{n=1}^N IMF_m^{(n)}(t) \quad (3.18)$$

4. Elde edilen IMF'ler birleştirilir. Bu sayede orijinal sinyali temsil eden yeni sinyal edilir.

3.2.3. Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayırıştırması

CEEMDAN, EEMD'nin bir versiyonu olup zaman serilerini analiz etmek için kullanılan bir yöntemdir. CEEMDAN'da EEMD'den farklı olarak adaptif gürültü ekleme yapılır. Böylece sinyaldeki varyasyonlar vurgulanabilir ve gürültüler bastırılabilir. CEEMDAN'ın işlem adımları aşağıdaki gibi özetlenebilir (J. Zhang vd., 2018).

1. Giriş sinyali $x(t)$, eklenen gürültü $v^i(t)$ ve genlik ε_0 olacak şekilde gürültü eklenmiş sinyalin denklemi aşağıda gösterilmektedir.

$$x^i(t) = x(t) + \varepsilon_0 v^i(t) \quad (3.19)$$

2. Birinci IMF ($\overline{IMF}_1(t)$), $x^i(t)$ 'nin EMD ile ayrıştırılması ile elde edilir.

$$\overline{IMF}_1(t) = \frac{1}{I} \sum_{i=1}^I IMF_1^i(t) \quad (3.20)$$

3. İlk artık $r(t)$ hesaplanması aşağıdaki denklemle yapılmaktadır.

$$r_1(t) = x(t) - \overline{IMF}_1(t) \quad (3.21)$$

4. Birinci IMF oluşturulana kadar $r_1(t) + \varepsilon_1 E_1(v^i(t))$ ayırtırmaya devam edilir. E_k k. IMF olmak üzere ikinci IMF aşağıdaki eşitlikle bulunur.

$$\overline{IMF}_2(t) = \frac{1}{I} \sum_{i=1}^I E_1((r_1(t) + \varepsilon_1 E_1(v^i(t))) \quad (3.22)$$

5. k. artık r değerini hesaplamak için $k = 2, \dots, N$ olacak şekilde 3. adım tekrarlanır ve $(k + 1)$. IMF aşağıdaki denklemle bulunur.

$$r_k(t) = r_{k-1}(t) - \overline{IMF}_k(t) \quad (3.23)$$

$$\overline{IMF}_{k+1}(t) = \frac{1}{I} \sum_{i=1}^I E_1(r_k(t) + \varepsilon_k E_k(v^i(t))) \quad (3.24)$$

6. Monoton (artmayan veya azalmayan) artık değer elde edilene kadar 4. adım yinelenir. $x(t)$ sonuç sinyali aşağıdaki denklemle hesaplanır.

$$x(t) = \sum_{k=1}^K \overline{IMF}_k(t) + R(t) \quad (3.25)$$

3.2.4. Varyasyonel Mod Ayırıştırması

VMD, bir sinyali zaman ve frekans özelliklerine sahip ayırt edici salınımlı bileşenlere ayırıştırmak için kullanılan bir sinyal işleme tekniğidir. VMD, geleneksel EMD yönteminin bir genişlemesi olup, bir sinyalin yerel maksimum ve minimumlarına dayanmaktadır. VMD, sinyali IMF'lerin bir toplamına ayırır; bu fonksiyonlar, belirgin frekans ve zaman özelliklerine sahip olan salınımlı bileşenlerdir (Ahmadi vd., 2023).

VMD ile bir sinyal bant sınırlı modlara ayrılmaktadır. Her mod, sınırlı frekans aralığında merkezlenir ve az spektral örtüşme gösterir. Ayırıştırma, modal fonksiyonu ve merkez frekansını güncelleyerek belirli bir bant genişliğine sahip birkaç mod elde etmek için iteratif olarak gerçekleştirilir (Şenkal ve Emeksiz, 2023).

VMD'nin EMD'ye göre başlıca avantajı, EMD kullanılarak ayırıştırılması zor olabilen durağan ve doğrusal olmayan sinyalleri işleyebilmesidir. VMD ile ayrıca, üretilen IMF'lerin sayısının kontrol edilme imkanı bulunmaktadır. Bu sayede hesaplama karmaşıklığı azaltılır ve sinyalin belirli frekans bileşenlerine odaklanmak için olanak sağlanır (Rehman ve Aftab, 2019).

VMD'de amaç, bir sinyali belirli özellikleri karşılayan salınım fonksiyonları olarak tanımlanan IMF'ler toplamına ayırıştırmaktır. Bir $x(t)$ sinyali I sayısı kadar kipten oluşmakta olup aşağıdaki eşitliklerle ifade edilir (Soğanlı ve Arıkan, 2017).

$$x(t) = \sum_{i=1}^I u_i(t) \quad (3.26)$$

Problemin maliyet fonksiyonu aşağıdaki eşitlik ile gösterilmekte olup, w_i ve u_i için yön çarpanları metodu ile problem çözülmektedir.

$$\begin{aligned} \arg \min_{\{u_i\}, \{w_i\}, \{\lambda\}} \alpha \sum_{i=1}^I \left\| \partial_i \left[\left(\sigma(t) + \frac{j}{\pi t} \right) \cdot u_i(t) \right] e^{-jw_i t} \right\|_2^2 + \left\| x(t) - \sum u_i(t) \right\|_2^2 \\ + \left\langle \lambda, x(t) - \sum u_i(t) \right\rangle \end{aligned} \quad (3.27)$$

3.2.5. Sürü Ayrıştırması

SWD, sabit olmayan sinyalleri analiz etmek için geliştirilen bir metottur. Bu yöntem temel olarak sürü filtrelemeden (SWF, Swarm Filtering) oluşmaktadır (Schwartz vd., 2021). Metotta av sürüsünün avlama yaklaşımı bulunmaktadır. Sürünün başarılı bir av için sürüş ve uyum olmak üzere iki etkileşim gücü bulunmaktadır. Sürüş gücü, $F_{dr}(n, i)$ ile ifade edilmek üzere aşağıdaki eşitlikle bulunmaktadır.

$$F_{dr}(n, i) = P_{av}(n) - P_i(n - 1) \quad (3.28)$$

Yukarıdaki eşitlikte; i ve n üye sayısı ve adım sayısıdır. Avın konum bilgisi ise P_{av} ile ifade edilmektedir. Sürünün tüm üyeleri için uyarılmış bağlılık kuvveti $F_{uyum}(n, i)$ ile gösterilmek üzere aşağıdaki denklemle kuvvet hesaplanmaktadır.

$$F_{uyum,i}^n = \frac{1}{M-1} \cdot \sum_{j=1, j \neq i}^M f(P_i[n-1] - P_j(n-1)) \quad (3.29)$$

$$f(d) = -sgn(d) \cdot \ln\left(\frac{|d|}{d_{cr}}\right) \quad (3.30)$$

Yukarıdaki eşitliklerde işaret ve logaritmik fonksiyon $sgn(...)$ ve $\ln(...)$ şeklinde gösterilmektedir. Üyeler arasındaki mesafe ve kritik mesafe d ve d_c ile gösterilmektedir. M , sürü sayısını temsil etmek üzere, sürünün avını takip edebilmesi için her adımda konum ve hız bilgisi aşağıdaki gibi güncellenir.

$$V_i[n] = V_i[n-1] + \delta \cdot (F_{Dr,i}^n + F_{Uyum,i}^n) \quad (3.31)$$

$$P_i[n] = P_i[n-1] + \delta \cdot (V_i[n]) \quad (3.32)$$

Eşitliklerde gösterilen δ sürünün esnekliğini kontrol etmek için kullanılan parametredir. β sürünün üyelerini etkileyen ölçek parametresi olmak üzere, SWF'nin çıktısı (y) aşağıdaki eşitlikle hesaplanmaktadır.

$$y[n] = \beta \cdot \sum_{i=1}^M P_i[n] \quad (3.33)$$

3.2.6. Dalgacık Ayırıştırması

WD ile bir sinyalin özellikleri hem zaman hem de frekans olarak yerleştirilir. WD, belirli bir sinyalin farklı frekans bileşenlerinin zaman yerleştirilmesine imkan veren doğrusal bir dönüşümdür. Ortaya çıkan dönüşümün hem frekans hem de zaman çözünürlüğü sabitlenmektedir. WD’de zaman içindeki sonlu bir süreye sahip olan dalgacıkların analiz fonksiyonlarıyla, zaman genişlikleri frekanslarına ayarlanarak, yüksek frekanslı dalgacıklar çok dar ve düşük frekanslı dalgacıklar daha geniş olacaktır. Böylece orijinal frekans üzerine bindirilmiş yerleştirilmiş yüksek frekanslı bileşenleri içeren geçici durumlar analiz edilebilmektedir.

WD ile bir zaman alanı sinyali farklı frekans gruplarına ayrıştırılabilmektedir. WD’de, sabit sayıda periyoda karşılık gelen pencere uzunluğu gibi belirli bir matematiksel özelliği belirten çeşitli işlevler kullanılmaktadır. WD durumunda sağlanması gereken temel şart; temel fonksiyonların, ortalaması sıfır olan Hilbert uzayının sınırları içinde bulunmasıdır.

3.3. Geliştirilen Hibrit Tahmin Modelleri


Bu tez çalışmasında kullanılan hibrit tahmin modelleri; ayrıştırma algoritmalarının MLP, LSTM, BiLSTM ve ESN ile beraber entegre bir şekilde kullanılmasıyla geliştirildi. Böylece ayrıştırma algoritmaları sayesinde rüzgar hızında yaşanan ani değişimlerin etkisi azaltılıp tahminlerdeki doğruluk artırılmaya çalışıldı.

3.3.1. Birincil Ayrıştırma Tabanlı Hibrit Tahmin Modelleri

Birincil ayrıştırma tabanlı hibrit tahmin modelleri, bir ayrıştırma algoritmasıyla birlikte MLP, LSTM, BiLSTM, ve ESN modellerinin beraber kullanılmasıyla geliştirilmiştir. Bu modellerde, normalize edilmiş veriler bir ayrıştırma algoritmasıyla IMF’lere ayrıştırılıp kullanılmaktadır. Yapılan çalışmalarda kullanılan ayrıştırma algoritmasına ve veri setine göre elde edilen IMF sayıları değişebilmektedir. Elde edilen IMF’ler modellerin giriş verisi olarak kullanılmaktadır. Ayrıştırma işlemi sayesinde rüzgarın yapısından kaynaklanan ve tahminlerdeki doğruluk oranının düşmesine sebep olan anlık değişimlerin etkisi azaltılabilmektedir. Geliştirilen modellerin çalışması Şekil 3.5’te gösterilmiş olup aşağıdaki adımlarla özetlenebilir.

1. Kullanılacak veriler ayrıştırılarak IMF’ler elde edilir.
2. Ayrıştırılan veriler normalize edilir.
3. Normalize edilmiş IMF’ler eğitim ve test aşamalarında kullanılır.
4. Elde edilen sonuçlar denormalize edilir.

5. Denormalize edilmiş IMF'ler toplanarak tahmin sonuçları edilir. Bu sonuçlarla metrik değerler ve grafikler oluşturulur.




Şekil 3.5. Birincil ayrıştırma tabanlı hibrit modellerin blok diyagramı

3.3.2. İkincil Ayrıştırma Tabanlı Hibrit Tahmin Modelleri

İkincil ayrıştırma işleminin uygulandığı hibrit modellerde birden fazla ayrıştırma algoritması kullanılmaktadır. Bu modellerde veriler önce birinci ayrıştırma algoritmasıyla IMF'lerine ayrıştırılır. Elde edilen IMF'lerden en yüksek frekansa sahip olan birinci IMF farklı bir ayrıştırma algoritması ile tekrar ayrıştırılır. İkinci ayrıştırma ve birinci ayrıştırmadan elde edilen IMF'ler normalize edilip modellerde giriş verisi olarak kullanılmaktadır. Daha sonra her IMF için tahminler yapılmaktadır. İkinci ayrıştırma işlemi, tahminlerde hata oranının artmasına neden olan birinci IMF'deki yüksek frekansların etkisini azaltmak için kullanılmaktadır. Modellerin çalışması Şekil 3.6'da gösterilmiş olup aşağıdaki adımlarla özetlenebilmektedir.

1. Birincil ayrıştırma işlemiyle verilere ait IMF'ler elde edilir.
2. En yüksek frekanslı birinci IMF farklı bir ayrıştırma algoritması ile tekrar ayrıştırılır.
3. Birinci ve ikinci ayrıştırma ile elde edilen tüm IMF bileşenleri normalize edilir.
4. Normalize veriler eğitim ve test aşamalarında kullanılır.

5. Eğitim ve test aşamalarının sonuçları denormalize edilir.
6. Denormalize IMF'lerden oluşan sonuçlar, eğitim ve test aşamaları için ayrı ayrı toplanarak metrik değerler ve grafikler oluşturulur.




Şekil 3.6. İkincil ayrıştırma tabanlı hibrit modellerin blok diyagramı

3.4. Kullanılan Veri Setleri

Çalışmada kullanılan modellerin performansını değerlendirmek için üç farklı bölgedeki açık deniz (offshore) rüzgar çiftliğine ait gerçek rüzgar gücü verileri ve Balıkesir iline ait kara-sal (onshore) rüzgar hızı verisi kullanılmıştır. Veri setlerinin ait olduğu coğrafi konumları Şekil 3.7’de gösterilmiştir. Barrow rüzgar çiftliğinin güç kapasitesi 90 MW olup kule yüksekliği 75 metredir ve Barrow rüzgar çiftliği 30 adet Vestas V90-3000 türbininden oluşmaktadır. West of Duddon Sands’in güç kapasitesi 388.8 MW olup kule yüksekliği 80 metredir ve bu rüzgar çiftliği 108 Siemens SWT-3.6-120 türbininden meydana gelmektedir. Horns Power rüzgar çiftliğinin kurulu gücü ise 160 MW, kule yüksekliği 70 metre ve rüzgar çiftliğinde 49 adet Vestas V80-2000 türbini bulunmaktadır. Bu veri setleri 2019-2020 yıllarında bir saatlik periyotlarla kaydedilmiş bir yıllık veriler olup 8760 güç verisi içermektedir. Balıkesir iline ait veriler ise dokuz ay boyunca 10 dakikalık periyotlarla kaydedilmiş verilerden oluşmaktadır. Veriler 1 saatlik veriye dönüştürülüp işlemlerde kullanılmaktadır. Kullanılan veri setlerine ait standart sapma-

lar; Barrow için 28.1497, West of Duddon Sands için 72.0836, Horns Power için 51.1955 ve Balıkesir için 3.6532 şeklindedir. Deneysel çalışmalarda veri setleri bazı kısaltmalar ile ifade edilerek gösterilmiştir. West of Duddon Sands veri seti için WDS, Barrow veri seti için BRW, Horns Power veri seti için HNP ve Balıkesir veri seti için BAL kısaltmaları kullanılmıştır.



Şekil 3.7. Çalışmalarda kullanılan veri setlerinin coğrafi konumları

4. DENEYSEL ÇALIŞMALAR

Bu bölümde tez çalışması kapsamında geliştirilen modellerle yapılan çalışmaların sonuçları ve modellerin başarımını değerlendirmek için kullanılan metrikler ile ilgili bilgilendirmeler yapılmaktadır.

4.1. Veri Normalizasyonu ve Kullanılan Metrikler

Çalışmada kullanılan metrikler MSE, RMSE, MAE ve R^2 olup aşağıda matematiksel ifadeleri verilmiştir. Eşitliklerde; e_j hatayı ve n veri boyutunu göstermektedir.

$$MSE = \frac{1}{n} \sum_{j=1}^n e_j^2 \quad (4.1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n e_j^2} \quad (4.2)$$

$$MAE = \frac{1}{n} \sum_{j=1}^n |e_j| \quad (4.3)$$

Regresyon analizi (R^2) hesaplamasında; sayının değeri X , tahmin değeri X_i , değerlerin ortalaması $\bar{X}$, hataların kareler toplamı S_{Err} , değerlerin ortalamaya uzaklığının kareler toplamı S_{Top} olmak üzere R^2 'yi hesaplamak için aşağıdaki eşitlikler kullanılmaktadır.

$$S_{Err} = \sum (X - X_i)^2 \quad (4.4)$$

$$S_{Top} = \sum (X - \bar{X})^2 \quad (4.5)$$

$$R^2 = 1 - \frac{S_{Err}}{S_{Top}} \quad (4.6)$$

Tahmin modellerinde kullanılacak veriler, normalize edilerek modellerin eğitim ve test aşamalarında kullanılmıştır. Normalize işlemi önemli bir veri ön işleme adımı olup bu işlemle veri özelliklerinin ölçekleri uygun bir şekilde ayarlanabilmektedir. Böylece modellerin eğitimi daha istikrarlı şekilde olmakta, normalize verilerle algoritmalar daha hızlı çalışmakta ve daha iyi genellemeler yapılabilmektedir. Ayrıca normalize veriler sayesinde modellerin eğitiminde uç değerlerin olumsuz etkileri azaltılıp modellerin performansı artırılabilir. Bu tez çalış-

ması kapsamında Min-Max ve Z-skör Normalizasyonu olmak üzere iki normalizasyon işlemi kullanılmıştır. İki modele ait matematiksel ifadeler aşağıda verilmiş olup eşitliklerde; Min-Max normalizasyonla elde edilen veri X_N , Z-skör ile elde edilen veri X_Z , orijinal veri X_{orj} , veri setinin ortalaması μ ve veri setinin standart sapması σ ile ifade edilmiştir.

$$X_N = \frac{X_{orj} - \min(X_{orj})}{\max(X_{orj}) - \min(X_{orj})} \quad (4.7)$$

$$X_Z = \frac{X_{orj} - \mu}{\sigma} \quad (4.8)$$

4.2. Birincil Ayırıştırma Tabanlı MLP Hibrit Modellerine Ait Çalışmalar

Geliştirilen hibrit modellerde MLP ile beraber kullanılan ayırıştırma metotları; EMD, EEMD ve CEEMDAN olup, geliştirilen modeller; EMD-MLP, EEMD-MLP ve CEEMDAN-MLP şeklinde adlandırılmıştır. Bu modellerin başarılarını analiz etmek için Balıkesir veri seti önce ayırıştırılmış ve iki farklı normalizasyon işlemi (Min-Max ve Z-skör) uygulanmıştır. Daha sonra normalize veriler modeller için giriş verisi olarak kullanılmıştır. Model eğitimi için veri setinin %70'i, geri kalanı ise test aşaması için ayrılmıştır. Modellerin başarımını ölçmek için yapılan çalışmalarda her model için metrik değerler elde edilmiştir. Ayrıca ayırıştırma işleminin tahminlerde doğruluğu artırma başarısını inceleyebilmek için ayırıştırma işleminin kullanılmadığı tekil MLP modeliyle de tahminler yapılmıştır. İlk olarak Balıkesir veri seti için, Min-Max normalizasyonu kullanılarak önerilen üç birincil ayırıştırılmalı MLP modeli ile tekil MLP modeline ait metrik sonuçları Tablo 4.1'de verilmiştir.

Tablo 4.1. Birincil ayırıştırma tabanlı MLP model sonuçları (BAL, Min-Max)


Modeller	Eğitim Aşaması				Test Aşaması			
	MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
MLP	2.3746	1.541	1.1217	0.80568	2.3599	1.5362	1.1069	0.85202
EMD-MLP	0.55543	0.74527	0.53582	0.95455	0.64039	0.80024	0.60179	0.95984
EEMD-MLP	0.66265	0.81403	0.58832	0.94627	1.7925	1.3388	1.031	0.88857
CEEMDAN-MLP	0.71911	0.848	0.61841	0.94115	1.6064	1.2675	0.98254	0.89926

Tablo 4.1'deki değerler incelendiğinde en başarılı modelin eğitim aşamasında MSE 0.55543, RMSE 0.74527, MAE 0.53582 ve R^2 0.95455; test aşamasında ise MSE 0.64039,

RMSE 0.80024, MAE 0.60179 ve R^2 0.95984 değerleriyle EMD ayrıştırma metodunun kullanıldığı EMD-MLP modelinin olduğu gözlemlenmiştir. Hibrit modellerin tekil MLP modeline göre elde ettiği başarımlar oranları yüzdesel olarak Tablo 4.2’de verilmiştir. Tablodaki sonuçlar bize kullanılan hibrit modellerin daha başarılı olduğunu ve en başarısız modelin ise tekil MLP modeli olduğunu açıkça göstermektedir. Kullanılan dört modelin Balıkesir veri setinin test aşaması için elde edilen tahmin sonuçlarına ait grafikleri Şekil 4.1’de gösterilmiştir. Grafikler incelendiğinde, hedef eğriye en yakın tahminin EMD-MLP modeli tarafından yapıldığı görülmektedir.

Tablo 4.2. Birincil ayrıştırma tabanlı MLP model başarımları (%) (BAL, Min-Max)

Modeller	Eğitim Aşaması				Test Aşaması			
	MSE	RMSE	MAE	R^2	MSE	RMSE	MAE	R^2
EMD-MLP	76.6095	51.6372	52.2314	18.4776	72.8637	47.9078	45.6328	12.6546
EEMD-MLP	72.0942	47.1752	47.5510	17.4499	24.0434	12.8499	6.8570	4.2898
CEEMDAN-MLP	69.7166	44.9708	44.8685	16.8144	31.9293	17.4912	11.2350	5.5445



Şekil 4.1. Birincil ayrıştırma tabanlı MLP model sonuçları (BAL, Min-Max)

Yapılan çalışmalarda, verilerin normalize edilme yöntemlerinin modellerin başarısına etkisini gözlemlemek amacıyla, MLP modelleriyle yapılan işlemler Z-skor normalizasyon yöntemi ile tekrarlanmıştır. Eğitim ve test aşaması için veri seti %70 ve %30 olarak yine ayrılmıştır. Z-skor ile normalize edilen verilerin kullanıldığı MLP modellerine ait metrik sonuçlar Tablo

4.3'te verilmektedir. Tablo 4.1'deki Min-Max normalizasyonu kullanılarak elde edilen sonuçlar ile kıyaslama yapıldığında Z-skor normalizasyon işleminin kullanıldığı modellerin az da olsa daha başarılı olduğu tespit edilmiştir. Z-skor normalizasyonu kullanılarak geliştirilen hibrit modellerin MLP'ye göre elde ettiği başarımlar oranları Tablo 4.4'te listelenmiştir. Tablodaki başarımlar oranları analiz edildiğinde kullanılan tüm hibrit modellerin Min-Max normalizasyonunda olduğu gibi tekil MLP modelinden daha başarılı olduğu gözlemlenmiştir.


Tablo 4.3. Birincil ayrıştırma tabanlı MLP model sonuçları (BAL, Z-skor)

Modeller	Eğitim Aşaması				Test Aşaması			
	MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
MLP	2.3331	1.5274	1.1077	0.80908	2.3698	1.5394	1.0913	0.8514
EMD-MLP	0.53936	0.73441	0.52433	0.95962	0.57143	0.75593	0.55567	0.95683
EEMD-MLP	0.60579	0.77832	0.56202	0.95525	0.63262	0.79537	0.5754	0.95274
CEEMDAN-MLP	0.62117	0.78814	0.57948	0.95787	0.79915	0.89395	0.6224	0.93358

Tablo 4.4. Birincil ayrıştırma tabanlı MLP model başarımları (%) (BAL, Z-skor)

Modeller	Eğitim Aşaması				Test Aşaması			
	MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
EMD-MLP	76.8823	51.9176	52.6650	18.6063	75.8870	50.8945	49.0818	12.3831
EEMD-MLP	74.0350	49.0428	49.2624	18.0662	73.3049	48.3325	47.2739	11.9027
CEEMDAN-MLP	73.3758	48.3999	47.6862	18.3900	66.2777	41.9287	42.9671	9.6523

Önerilen üç hibrit model ile tekil MLP modelinin Z-skor normalizasyonu kullanılarak yapılan normalize test verileri için elde edilen tahmin sonuçları Şekil 4.2'de gösterilmiştir. Grafikteki siyah renkle işaretlenen hedef eğriye en yakın eğrinin EMD-MLP eğrisi olduğu görülmektedir.



Şekil 4.2. Birincil ayrıştırma tabanlı MLP model sonuçları (BAL, Z-skor)

Geliştirilen modellerin farklı veri setleri için performanslarını analiz etmek için üç farklı açık deniz rüzgar çifliği olan West of Duddon Sands, Barrow ve Horns Power bölgelerine ait gerçek rüzgar gücü verileri kullanılmıştır. Veri setlerinin %70'lik kısmı eğitim için geri kalanı ise test için ayrılmıştır. Min-Max normalizasyonu ile ön işleme tabi tutulan veri setleri için önerilen birincil ayrıştırma metotlarına dayanan hibrit MLP modellerinin sonuçları Tablo 4.5'te gösterilmiş olup, ayrıştırma metotlarına dayanan modellerin daha başarılı olduğu açıktır.

Kullanılan veri setinin değişkenliğine göre en başarılı model de değişkenlik göstermektedir. West of Duddon Sands verisi için eğitim aşamasında en başarılı model EMD-MLP, test aşamasında CEEMDAN-MLP; Barrow verisi için eğitim ve test aşamasında genel olarak (test aşamasında MAE hariç) EMD-MLP en başarılı model olmuştur. Horns Power veri seti için ise CEEMDAN-MLP, eğitim aşamasında MSE, RMSE ve eğitim ile test aşamasının MAE değerlerine göre başarılı iken; EEMD-MLP, her iki aşamanın R^2 değerleri ile test aşamasının MSE ve RMSE değerlerine göre en başarılı model olmuştur.

Tablo 4.5'de kullanılan hibrit modellerin tekil MLP modeline göre başarı oranları Tablo 4.6'da özetlenmektedir. Veriler incelendiğinde Horns Power verisi için EMD-MLP modelinin test aşamasındaki MSE, RMSE ve R^2 değerleri hariç hibrit modellerin MLP'ye başarı oranlarının yükseldiği gözlemlenmektedir. Bunun nedeni Horns Power veri setinde enerji üretiminin bulunmadığı uzun süreli sıfır değerlerinin bulunmasıdır.

Tablo 4.5. Birincil ayrıştırma tabanlı MLP model sonuçları (OFS, Min-Max)

Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
WDS	MLP	349.2	18.687	11.717	0.93433	340.05	18.44	11.458	0.92474
	EMD-MLP	76.81	8.7641	5.8983	0.98555	118.4	10.881	7.8754	0.9738
	EEMD-MLP	96.469	9.8219	6.9552	0.98208	147.26	12.135	9.3881	0.96783
	CEEMDAN-MLP	92.932	9.6401	6.5122	0.98252	114.64	10.707	7.0288	0.97463
BRW	MLP	74.106	8.6085	5.6794	0.91309	66.384	8.1476	5.2229	0.89705
	EMD-MLP	15.097	3.8855	2.6715	0.98229	19.764	4.4457	3.35	0.96935
	EEMD-MLP	20.076	4.4806	3.195	0.9766	20.228	4.4975	3.3236	0.96886
	CEEMDAN-MLP	18.429	4.2929	2.9322	0.97839	19.815	4.4514	2.9383	0.96927
HNP	MLP	396	19.9	12.81	0.84808	546.26	23.372	14.214	0.79219
	EMD-MLP	104.88	10.241	6.715	0.95976	664.86	25.785	13.869	0.74707
	EEMD-MLP	105.11	10.252	6.91	0.96006	147.11	12.129	8.5404	0.94463
	CEEMDAN-MLP	104.34	10.215	6.6862	0.95997	162.05	12.73	8.0978	0.93835

(Offshore: OFS, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)


Tablo 4.6. Birincil ayrıştırma tabanlı MLP model başarımları (%) (OFS, Min-Max)

Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
WDS	EMD-MLP	78.0040	53.1006	49.6603	5.4820	65.1816	40.9924	31.2672	5.3053
	EEMD-MLP	72.3743	47.4399	40.6401	5.1106	56.6946	34.1920	18.0651	4.6597
	CEEMDAN-MLP	73.3872	48.4128	44.4209	5.1577	66.2873	41.9360	38.6560	5.3950
BRW	EMD-MLP	79.6278	54.8644	52.9616	7.5787	70.2278	45.4355	35.8594	8.0598
	EEMD-MLP	72.9091	47.9514	43.7441	6.9555	69.5288	44.7997	36.3649	8.0051
	CEEMDAN-MLP	75.1316	50.1318	48.3713	7.1515	70.1509	45.3655	43.7420	8.0508
HNP	EMD-MLP	73.5152	48.5377	47.5800	13.1686	-21.7113	-10.3243	2.4272	-5.6956
	EEMD-MLP	73.4571	48.4824	46.0578	13.2039	73.0696	48.1046	39.9156	19.2429
	CEEMDAN-MLP	73.6515	48.6683	47.8048	13.1933	70.3346	45.5331	43.0294	18.4501


(Offshore: OFS, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)

Açık deniz veri setleri için birincil ayrıştırmaya dayanan MLP tabanlı modellerin test sonuçları sırasıyla sunulmuş olup, ilk olarak West of Duddons sonuçları Şekil 4.3’de gösterilmiştir. Grafik incelendiğinde, siyah hedef eğrisinin, CEEMDAN-MLP modeline ait eğri (yeşil) tarafından diğer modellere göre daha başarılı bir şekilde takip edildiği görülmektedir. Birincil

ayırıştırma metotlarına dayanan hibrit MLP modellerinin Barrow veri seti için test sonuçlarına ait grafikler Şekil 4.4’de gösterilmiştir.




Şekil 4.3. Birincil ayrıştırma tabanlı MLP model sonuçları (WDS, Min-Max)



Şekil 4.4. Birincil ayrıştırma tabanlı MLP model sonuçları (BRW, Min-Max)

Eğriler yorumlandığında, EMD-MLP ve CEEMDAN-MLP modellerinin hedef eğrisine yakın başarı sergilediği, ancak EMD-MLP’nin daha başarılı olduğu tespit edilmiştir. Horns Power veri seti için tekil MLP modeli ile önerilen hibrit modellerin test aşamasına ait tahmin

sonuçları Şekil 4.5'te sunulmuştur. Grafikler incelendiğinde en başarılı modelin CEEMDAN-MLP modeline ait eğri olduğu gözlemlenmiştir.



Şekil 4.5. Birincil ayrıştırma tabanlı MLP model sonuçları (HNP, Min-Max)

West of Duddon Sands, Barrow ve Horns Power veri setleri MLP modellerinde kullanılırken normalizasyon işleminin, yapılan tahminlerdeki başarıya etkisini tespit etmek için burada da Z-skor normalizasyon işlemi yapılmıştır. Elde edilen sonuçlar Tablo 4.7'de gösterilmiş olup verileri normalize ederken Z-skor işleminin kullanıldığı modellerle genelde daha başarılı sonuçlar elde edildiği gözlemlenmiştir. Veri setlerine göre başarılı modeller ise West of Duddon Sands ve Barrow için EMD-MLP başarılı olurken Horns Power için ise genelde (MAE değerleri hariç) EEMD-MLP en başarılı model olmuştur.

Açık deniz veri setlerinin, birincil ayrıştırma tabanlı MLP hibrit modellerde Z-skor normalizasyon kullanılmasıyla elde edilen performans sonuçlarının tekil MLP'ye göre elde ettiği başarımlar oranları Tablo 4.8'de gösterilmektedir. Tablodaki yüzdelik oranlara bakıldığında hibrit modellerin tekil MLP modelinden daha başarılı olduğu görülmektedir.

Üç farklı açık deniz veri seti için birincil ayrıştırma işlemli MLP hibrit modellerinde Z-skor normalizasyonu kullanılarak yapılan normalize test verileri üzerindeki rüzgar gücü tahmin sonuçlarına ait grafikler sırasıyla sunulmaktadır. Şekil 4.6'da West of Duddon Sands veri setine ait tahmin sonuçları gösterilmektedir. Benzer şekilde, Şekil 4.7'de Barrow veri setine ait grafikler yer almakta olup, Şekil 4.8'de ise Horns Power veri seti için tahmin sonuçları verilmiştir.

Tablo 4.7. Birincil ayrıştırma tabanlı MLP model sonuçları (OFS, Z-skor)


Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
WDS	MLP	346.84	18.624	11.658	0.93477	337.63	18.375	11.466	0.92528
	EMD-MLP	81.762	9.0422	6.0488	0.98446	85.906	9.2685	6.1474	0.98458
	EEMD-MLP	103.83	10.19	7.458	0.9805	162.98	12.766	9.2751	0.97537
	CEEMDAN-MLP	94.955	9.7445	6.3489	0.9815	113.92	10.673	6.8776	0.97994
BRW	MLP	73.906	8.5969	5.7087	0.91332	65.784	8.1108	5.272	0.89798
	EMD-MLP	13.911	3.7297	2.5841	0.98383	15.587	3.948	2.7622	0.97795
	EEMD-MLP	18.809	4.337	3.0899	0.9787	20.102	4.4835	3.2106	0.97212
	CEEMDAN-MLP	19.307	4.394	2.9525	0.97597	22.597	4.7537	3.1666	0.97137
HNP	MLP	399.81	19.995	12.791	0.84662	528.5	22.989	13.96	0.79895
	EMD-MLP	233.45	15.279	10.004	0.92575	211.42	14.54	9.2178	0.90772
	EEMD-MLP	115.62	10.753	7.2881	0.95698	127.6	11.296	7.6047	0.95035
	CEEMDAN-MLP	127.56	11.294	7.2324	0.95214	131.43	11.464	7.4758	0.94835

(Offshore: OFS, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)


Tablo 4.8. Birincil ayrıştırma tabanlı MLP model başarımları (%) (OFS, Z-skor)

Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
WDS	EMD-MLP	76.4266	51.4487	48.1146	5.3157	74.5562	49.5592	46.3858	6.4089
	EEMD-MLP	70.0640	45.2857	36.0268	4.8921	51.7282	30.5252	19.1078	5.4135
	CEEMDAN-MLP	72.6228	47.6777	45.5404	4.9991	66.2589	41.9156	40.0174	5.9074
BRW	EMD-MLP	81.1774	56.6158	54.7340	7.7202	76.3058	51.3242	47.6062	8.9055
	EEMD-MLP	74.5501	49.5516	45.8738	7.1585	69.4424	44.7219	39.1009	8.2563
	CEEMDAN-MLP	73.8763	48.8886	48.2807	6.8596	65.6497	41.3905	39.9355	8.1728
HNP	EMD-MLP	41.6098	23.5859	21.7888	9.3466	59.9962	36.7524	33.9699	13.6141
	EEMD-MLP	71.0813	46.2216	43.0217	13.0354	75.8562	50.8635	45.5251	18.9499
	CEEMDAN-MLP	68.0948	43.5159	43.4571	12.4637	75.1315	50.1327	46.4484	18.6995


(Offshore: OFS, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)



Şekil 4.6. Birincil ayrıştırma tabanlı MLP model sonuçları (WDS, Z-skor)



Şekil 4.7. Birincil ayrıştırma tabanlı MLP model sonuçları (BRW, Z-skor)



Şekil 4.8. Birincil ayrıştırma tabanlı MLP model sonuçları (HNP, Z-skor)

4.3. Birincil Ayrıştırma Tabanlı LSTM Hibrit Modellerine Ait Çalışmalar

LSTM derin öğrenme tekniğiyle birlikte EMD, EEMD ve CEEMDAN gibi veri ayrıştırma yöntemlerinin bir araya getirilmesiyle oluşturulan hibrit modellerde; Balıkesir, West of Duddon Sands, Barrow ve Horns Power gibi farklı kaynaklardan elde edilen veri setleri giriş verisi olarak kullanılarak ileriye dönük rüzgar tahminleri yapılmıştır. Bu sayede, LSTM'nin geliştirilen modellerle yapılan tahminlerdeki başarıya etkisi belirlenmeye çalışılmıştır. Bu çalışmalarda kullanılan LSTM kodları Matlab'da bulunan araçlardaki hazır kod olmayıp ayrıca geliştirilen bir LSTM kodudur. Elde edilen sonuçlara ait metrikler değerler Tablo 4.9'da sunulmuştur. Tablodaki değerler incelenecek olunursa; Balıkesir verisi için EMD-LSTM ve West of Duddon Sands için eğitim aşamasındaki MAE hariç CEEMDAN-LSTM modelleri en başarılı model olmuştur. Barrow verisi için modellerin başarılı olduğu metrik değerler değişkenlik göstermiş olup eğitim aşamasındaki tüm metrikler için EMD-LSTM, test aşamasındaki tüm metrikler için ise CEEMDAN-LSTM en başarılı model olmuştur. Horns Power veri seti için ise eğitim ve test aşamasındaki tüm metriklere göre en başarılı modelin EEMD-LSTM modeli olduğu gözlemlenmiştir.

Tablo 4.9. Birincil ayrıştırma tabanlı LSTM model sonuçları (ALL, Min-Max)

Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
BAL	LSTM	2.4185	1.5552	1.1254	0.80209	2.3205	1.5233	1.0808	0.85449
	EMD-LSTM	0.76661	0.87556	0.63983	0.93726	0.8279	0.90989	0.6477	0.94808
	EEMD-LSTM	1.1007	1.0491	0.76388	0.91117	1.135	1.0653	0.79289	0.92947
	CEEMDAN-LSTM	0.86787	0.9316	0.67593	0.92897	0.98981	0.99489	0.70986	0.93793
WDS	LSTM	351.6	18.751	11.865	0.93387	336.71	18.35	11.438	0.92548
	EMD-LSTM	129.06	11.36	7.8553	0.97573	125.47	11.201	7.8225	0.97223
	EEMD-LSTM	146.21	12.092	8.9008	0.9728	162.05	12.73	9.078	0.96446
	CEEMDAN-LSTM	122.33	11.06	7.9246	0.97699	120.09	10.959	7.4121	0.97342
BRW	LSTM	73.703	8.5851	5.6184	0.91357	65.43	8.0889	5.2144	0.89853
	EMD-LSTM	23.412	4.8386	3.4151	0.97255	23.883	4.887	3.3576	0.96296
	EEMD-LSTM	28.346	5.3241	3.8542	0.96706	25.532	5.0529	3.6275	0.96101
	CEEMDAN-LSTM	26.016	5.1005	3.5196	0.96949	23.663	4.8645	3.2598	0.9633
HNP	LSTM	403.91	20.097	12.597	0.84507	540.21	23.242	13.559	0.79449
	EMD-LSTM	162.65	12.753	8.6267	0.93761	731.02	27.037	14.585	0.7219
	EEMD-LSTM	138.56	11.771	8.0622	0.94738	186.42	13.654	9.3737	0.93028
	CEEMDAN-LSTM	153.64	12.395	8.7112	0.94107	200.16	14.148	9.9364	0.92386

(Offshore & Onshore: ALL, Balıkesir: BAL, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)


Dört veri setinin LSTM tabanlı hibrit modellerde kullanılmasıyla elde edilen performans sonuçlarının, tekil LSTM modeline göre gösterdiği başarı oranları yüzdelik olarak Tablo 4.10'da sunulmaktadır. Tablodaki oranlar incelendiğinde Horns Power veri setinin kullanıldığı EMD-LSTM modelinin test aşamasındaki değerler için LSTM'ye göre başarımının düşük olduğu görülmektedir. Diğer tüm durumlarda hibrit modellerin başarı oranlarında artış olduğu gözlemlenmiştir.


Kullanılan dört veri seti Min-Max normalizasyonu ile normalize edilerek LSTM tabanlı modellerde kullanılmasıyla, test aşamasında elden edilen tahmin sonuçlarına ait grafikler aşağıda gösterilmektedir. Şekil 4.9'da Balıkesir verisine ait sonuç grafikleri, Şekil 4.10'da West of Duddon Sands verisine ait sonuç grafikleri, Şekil 4.11'de Barrow verisine ait sonuç grafikleri ve Şekil 4.12'de Horns Power verisine ait sonuç grafikleri verilmektedir.

Tablo 4.10. Birincil ayrıştırma tabanlı LSTM model başarımları (%) (ALL, Min-Max)


Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
BAL	EMD-LSTM	68.3023	43.7011	43.1464	16.8522	64.3223	40.2685	40.0722	10.9527
	EEMD-LSTM	54.4883	32.5424	32.1237	13.5995	51.0881	30.0663	26.6386	8.7748
	CEEMDAN-LSTM	64.1154	40.0977	39.9387	15.8187	57.3450	34.6885	34.3209	9.7649
WDS	EMD-LSTM	63.2935	39.4166	33.7944	4.4824	62.7365	38.9591	31.6095	5.0514
	EEMD-LSTM	58.4158	35.5128	24.9827	4.1687	51.8725	30.6267	20.6330	4.2119
	CEEMDAN-LSTM	65.2076	41.0165	33.2103	4.6173	64.3343	40.2779	35.1976	5.1800
BRW	EMD-LSTM	68.2347	43.6396	39.2158	6.4560	63.4984	39.5839	35.6091	7.1706
	EEMD-LSTM	61.5402	37.9844	31.4004	5.8551	60.9781	37.5329	30.4330	6.9536
	CEEMDAN-LSTM	64.7016	40.5889	37.3558	6.1210	63.8346	39.8620	37.4847	7.2084
HNP	EMD-LSTM	59.7311	36.5428	31.5178	10.9506	-35.3214	-16.3282	-7.5669	-9.1367
	EEMD-LSTM	65.6953	41.4291	35.9990	12.1067	65.4912	41.2529	30.8673	17.0915
	CEEMDAN-LSTM	61.9618	38.3241	30.8470	11.3600	62.9477	39.1274	26.7173	16.2834

(Offshore & Onshore: ALL, Balıkesir: BAL, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)


**Şekil 4.9.** Birincil ayrıştırma tabanlı LSTM model sonuçları (BAL, Min-Max)



Şekil 4.10. Birincil ayrıştırma tabanlı LSTM model sonuçları (WDS, Min-Max)



Şekil 4.11. Birincil ayrıştırma tabanlı LSTM model sonuçları (BRW, Min-Max)



Şekil 4.12. Birincil ayrıştırma tabanlı LSTM model sonuçları (HNP, Min-Max)

Geliştirilen LSTM tabanlı birincil ayrıştırmanın kullanıldığı hibrit modellerde Z-skor işlemiyle veriler normalize edildiğinde modellerin başarımının nasıl değişeceği tespit edilmeye çalışılmıştır. Bu amaçla yukarıdaki veri setleri ve modellerle yapılan tahminlerde sadece normalizasyon yöntemi Z-skor ile değiştirilerek tahminler tekrar yapılmış ve elde edilen metrik değerler Tablo 4.11’de listelenmiştir. Balıkesir ve Barrow verileriyle yapılan çalışmalarda hem eğitim hem de test aşamalarındaki tüm metrik değerler için en başarılı model EMD-LSTM modeli olmuştur. West of Duddon Sands verisi için test aşamasındaki R^2 değeri hariç eğitim ve test aşamalarına ait diğer değerlere göre CEEMDAN-LSTM modeline ait sonuçların daha iyi olduğu gözlemlenmiştir. Test aşamasındaki R^2 0.96631 değeriyle EMD-LSTM en iyi sonuca sahipken CEEMDAN-LSTM modeliyle R^2 0.96456 değeri elde edilmiştir. Horns Power veri setiyle yapılan tahminlere ait metrik değerler incelendiğinde test aşamasındaki MAE değeri hariç diğer tüm değerlere göre en başarılı modelin EEMD-LSTM modeli olduğu tespit edilmiştir. Tablo 4.9 ve Tablo 4.11’deki sonuçlar incelenip Min-Max normalizasyonu yöntemi ve Z-skor yönteminin kullanıldığı çalışmalara ait sonuçlar incelendiğinde sonuçların birbirine yakın olduğu görülebilmektedir. Bazı veri setlerinde Min-Max’ın kullanıldığı modeller daha iyi sonuçlara sahip iken bazı veri setleri için ise Z-skor yönteminin kullanıldığı modele ait sonuçların az da olsa daha iyi olduğu gözlenmiştir. Kullanılan veri setlerinin Z-skorla normalize edildikten sonra hibrit LSTM modellerinde kullanılmasıyla yapılan çalışmalardan elde edilen performans sonuçlarının, tekil LSTM modeline kıyasla başarımların değişimi yüzdesel Tablo 4.12’de sunulmaktadır.

Tablo 4.11. Birincil ayrıştırma tabanlı LSTM model sonuçları (ALL, Z-skor)

Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
BAL	LSTM	2.5519	1.5975	1.1773	0.79114	3.2544	1.804	1.263	0.79592
	EMD-LSTM	0.71554	0.8459	0.60737	0.94645	0.71543	0.84583	0.61893	0.94596
	EEMD-LSTM	0.81438	0.90243	0.6508	0.92033	0.87801	0.93702	0.68702	0.88612
	CEEMDAN-LSTM	0.78719	0.88724	0.64698	0.94045	0.81363	0.90201	0.66063	0.9399
WDS	LSTM	375.21	19.37	13.976	0.92943	366.7	19.149	13.18	0.91884
	EMD-LSTM	193.29	13.903	10.075	0.96326	187.63	13.698	10.245	0.96631
	EEMD-LSTM	190.43	13.8	10.156	0.96312	326.08	18.058	12.23	0.94779
	CEEMDAN-LSTM	158.64	12.595	8.9713	0.97032	184.16	13.571	9.5587	0.96456
BRW	LSTM	79.085	8.8929	6.4932	0.90726	68.945	8.3033	5.8621	0.89308
	EMD-LSTM	22.832	4.7783	3.4786	0.97346	25.095	5.0094	3.5896	0.9645
	EEMD-LSTM	44.92	6.7022	4.6568	0.94692	43.983	6.632	4.6394	0.93587
	CEEMDAN-LSTM	161.88	12.723	9.4105	0.8131	150.21	12.256	9.283	0.78296
HNP	LSTM	416.86	20.417	14.263	0.8401	578.32	24.048	16.118	0.77999
	EMD-LSTM	386.26	19.654	13.524	0.87716	336.95	18.356	11.918	0.85292
	EEMD-LSTM	185.95	13.636	9.5958	0.93019	192.1	13.86	9.7789	0.92801
	CEEMDAN-LSTM	209.09	14.46	9.7301	0.9235	198.24	14.08	9.5399	0.91902


(Offshore & Onshore: ALL, Balıkesir: BAL, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)

Tablo 4.12. Birincil ayrıştırma tabanlı LSTM model başarımları (%) (ALL, Z-skor)


Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
BAL	EMD-LSTM	71.9605	47.0485	48.4099	19.6312	78.0165	53.1136	50.9952	18.8511
	EEMD-LSTM	68.0873	43.5099	44.7210	16.3296	73.0208	48.0588	45.6041	11.3328
	CEEMDAN-LSTM	69.1528	44.4607	45.0454	18.8728	74.9991	49.9994	47.6936	18.0898
WDS	EMD-LSTM	48.4848	28.2241	27.9121	3.6399	48.8328	28.4662	22.2686	5.1663
	EEMD-LSTM	49.2471	28.7558	27.3326	3.6248	11.0772	5.6974	7.2079	3.1507
	CEEMDAN-LSTM	57.7197	34.9768	35.8092	4.3995	49.7791	29.1295	27.4757	4.9758
BRW	EMD-LSTM	71.1298	46.2684	46.4270	7.2967	63.6014	39.6698	38.7660	7.9970
	EEMD-LSTM	43.2004	24.6343	28.2819	4.3714	36.2057	20.1281	20.8577	4.7913
	CEEMDAN-LSTM	-104.6912	-43.0692	-44.9285	-10.3785	-117.8693	-47.6040	-58.3562	-12.3304
HNP	EMD-LSTM	7.3406	3.7371	5.1812	4.4114	41.7364	23.6693	26.0578	9.3501
	EEMD-LSTM	55.3927	33.2125	32.7224	10.7237	66.7831	42.3653	39.3293	18.9772
	CEEMDAN-LSTM	49.8417	29.1767	31.7808	9.9274	65.7214	41.4504	40.8121	17.8246

(Offshore & Onshore: ALL, Balıkesir: BAL, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)

Oransal verilere bakıldığında sadece CEEMDAN-LSTM modelinde Barrow verisi kullanılarak elde edilen başarı oranlarının, tekil LSTM'ye göre azaldığı görülmektedir. Dört veri setinin Z-skorla ile normalize edilip LSTM tabanlı modellerde kullanılmasıyla, modellerin test aşamasında yapılan tahminlere ait sonuç grafikleri aşağıda verilmiştir. Şekil 4.13'te Balıkesir verisi için sonuçlar, Şekil 4.14'te West of Duddon Sands verisi için sonuçlar verilmiştir.




Şekil 4.13. Birincil ayrıştırma tabanlı LSTM model sonuçları (BAL, Z-skor)




Şekil 4.14. Birincil ayrıştırma tabanlı LSTM model sonuçları (WDS, Z-skor)

Şekil 4.15'te Barrow verisinin sonuç grafikleri ve Şekil 4.16'da Horns Power verisinin sonuç grafikleri gösterilmektedir.



Şekil 4.15. Birincil ayrıştırma tabanlı LSTM model sonuçları (BRW, Z-skor)



Şekil 4.16. Birincil ayrıştırma tabanlı LSTM model sonuçları (HNP, Z-skor)

4.4. Birincil Ayrıştırma Tabanlı EMD-ESN Hibrit Modeline Ait Çalışmalar

Geliştirilen EMD-ESN modelinin başarımını ölçmek için West of Duddon Sands, Barrow ve Horns Power veri setleri kullanılarak tahminler yapılmıştır. Karşılaştırma için kullanılan diğer modeller ve tüm modellere ait tahmin sonuçları Tablo 4.13'te gösterilmektedir.

Tablo 4.13. EMD-ESN model sonuçları (OFS, Min-Max)

Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
WDS	LSTM	384.23	19.602	13.951	0.9277	381.38	19.529	14.207	0.9156
	BiLSTM	362.21	19.032	11.962	0.9319	349.84	18.704	11.145	0.9226
	MLP	361.25	19.007	12.360	0.9321	345.47	18.587	11.540	0.9235
	ANFIS	426.13	20.643	13.301	0.9199	413.55	20.336	12.464	0.9085
	ESN	340.30	18.447	11.513	0.9360	333.57	18.264	11.259	0.9272
	EMD-LSTM	162.85	12.761	9.5021	0.9694	169.59	13.023	9.9876	0.9625
	EMD-BiLSTM	144.97	12.040	9.1340	0.9727	136.22	11.671	8.8001	0.9699
	EMD-ESN	101.40	10.070	7.0519	0.9809	99.584	9.9792	7.0126	0.9783
BRW	LSTM	85.584	9.2512	5.8682	0.8996	77.555	8.8065	5.6011	0.8797
	BiLSTM	79.715	8.9284	6.3167	0.9065	69.033	8.3086	5.8006	0.8929
	MLP	75.323	8.6789	5.8548	0.9117	66.689	8.1663	5.2974	0.8966
	ANFIS	83.991	9.1647	6.3036	0.9015	76.158	8.7269	5.8011	0.8819
	ESN	72.693	8.5260	5.5998	0.9149	64.177	8.0111	5.1728	0.8995
	EMD-LSTM	25.422	5.0420	3.7225	0.9702	22.108	4.7019	3.3991	0.9657
	EMD-BiLSTM	17.634	4.1993	3.0517	0.9793	15.658	3.9571	2.9132	0.9757
	EMD-ESN	18.633	4.3165	3.0380	0.9782	15.458	3.9316	2.8334	0.9758
HNP	LSTM	416.42	20.406	14.221	0.8403	541.45	23.269	15.497	0.7940
	BiLSTM	430.73	20.754	12.405	0.8348	568.02	23.833	13.472	0.7839
	MLP	423.16	20.571	13.979	0.8377	553.63	23.529	15.356	0.7894
	ANFIS	435.64	20.872	14.067	0.8329	550.86	23.470	15.007	0.7904
	ESN	384.95	19.620	12.483	0.8514	577.70	24.035	15.032	0.7759
	EMD-LSTM	168.76	12.991	9.0148	0.9353	785.19	28.021	15.910	0.7013
	EMD-BiLSTM	125.86	11.219	7.9517	0.9517	770.13	27.751	15.016	0.7070
	EMD-ESN	124.73	11.168	7.5774	0.9519	239.80	15.486	10.614	0.9070

(Offshore: OFS, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)

Tablodaki sonuç değerleri incelendiğinde; Barrow veri setinin eğitim aşamasında EMD-BiLSTM modeli başarılı iken, Barrow verisinin test aşaması ve diğer veri setlerinin hem eği-


tim hem de test aşamalarında elde edilen metrik değerlere göre en başarılı modelin geliştirilen EMD-ESN hibrit modeli olduğu açıkça görülebilmektedir. Tablo 4.13'te kullanılan hibrit modellerin, tekil modellerine göre gösterdiği başarıların oransal değişimleri Tablo 4.14'te verilmektedir ve tablodaki yüzdesel sonuçlar incelendiğinde yalnızca Horns Power verisi için EMD-LSTM ve EMD-BiLSTM modellerinin, tekil LSTM ve BiLSTM modellerine göre başarısız olduğu görülmektedir. Bu durum Horns Power veri setinde bulunan aralıklı duruş sayısının çok fazla olmasından kaynaklanmaktadır. Ancak EMD-ESN modelinin, Barrow verisinin test aşaması hariç diğer tüm durumlar için en iyi başarı oranını yakaladığı görülmektedir.

Tablo 4.14. EMD-ESN model başarımları (%) (OFS, Min-Max)


Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
WDS	EMD-LSTM	57.6165	34.8995	31.8895	4.4905	55.5325	33.3146	29.6994	5.1235
	EMD-BiLSTM	59.9763	36.7381	23.6415	4.3804	61.0622	37.6016	21.0399	5.1302
	EMD-ESN	70.2028	45.4112	38.7484	4.8002	70.1460	45.3614	37.7156	5.5103
BRW	EMD-LSTM	70.2958	45.4990	36.5649	7.8443	71.4938	46.6088	39.3137	9.7736
	EMD-BiLSTM	77.8787	52.9669	51.6884	8.0297	77.3181	52.3734	49.7776	9.2683
	EMD-ESN	74.3675	49.3725	45.7481	6.9189	75.9135	50.9231	45.2250	8.4838
HNP	EMD-LSTM	59.4736	36.3374	36.6092	11.3121	-45.0162	-20.4220	-2.6650	-11.6773
	EMD-BiLSTM	70.7798	45.9430	35.8992	14.0088	-35.5815	-16.4394	-11.4608	-9.8111
	EMD-ESN	67.5984	43.0785	39.2982	11.7995	58.4906	35.5690	29.3906	16.8941

(Offshore: OFS, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)


ESN ve EMD-ESN modellerinin performansını analiz etmek için kullanılan tüm veri setlerinin test aşamalarına ait sonuç grafikleri aşağıda gösterilmiştir. West of Duddon Sands verisine ait grafik Şekil 4.17'de, Barrow verisinin grafiği Şekil 4.18'de ve Horns Power verisinin sonuç grafiği de Şekil 4.19'da gösterilmiştir. Grafiklerde EMD ile ayrıştırmanın ESN'nin başarısına etkisini açıkça görülebilmektedir. Üç şekilde de EMD'nin kullanıldığı EMD-ESN hibrit modeline ait eğrinin hedef eğriye daha çok benzediği, dolayısıyla EMD-ESN'nin tekil ESN modelinden daha başarılı olduğu açıkça tespit edilmektedir.



Şekil 4.17. EMD-ESN model sonuçları (WDS, Min-Max)



Şekil 4.18. EMD-ESN model sonuçları (BRW, Min-Max)



Şekil 4.19. EMD-ESN model sonuçları (HNP, Min-Max)

4.5. İkincil Ayırıştırma Tabanlı LSTM Hibrit Modellerine Ait Çalışmalar

Veri setlerinin ayrıştırılmasından elde edilen IMF'lerden birincisi en yüksek frekansa sahip olanıdır ve modellerle yapılan tahminlere etkisi oldukça fazladır. Bu etkiyi azaltıp modellerin başarımını artırmak için birinci IMF'nin farklı bir ayrıştırma yoluyla tekrar ayrıştırıldığı ikincil ayrıştırma modelleri geliştirilmiştir. LSTM ile beraber WD, SWD ve VMD ikincil ayrıştırma yöntemi olarak ve birincil ayrıştırma yöntemi olarak ise EMD kullanılmıştır. Daha önceki çalışmalarda Z-skor yönteminin kullanıldığı modellere ait sonuçların az da olsa daha iyi olması ve literatüre yeni çalışmalar kazandırmak amacıyla bundan sonraki çalışmalarda veriler normalize edilirken sadece Z-skor kullanılacaktır. Modellerin başarılarını değerlendirmek için Balıkesir, West of Duddon Sands, Barrow ve Horns Power veri setleri kullanılıp elde edilen başarı değerleri Tablo 4.15'de gösterilmiştir. Tablodaki sonuçlar incelendiğinde Barrow verisinin test aşamasındaki MAE değeri hariç genel olarak ikincil ayrıştırmanın kullanıldığı modellerle yapılan tahminlerin en başarılı model olduğu gözlemlenmiştir. İkincil ayrıştırmalarda da VMD'nin kullanıldığı modellerin genel olarak daha başarılı olduğu tespit edilmiştir.

Tablo 4.15. İkincil ayrıştırma tabanlı LSTM model sonuçları (ALL, Z-skor)

Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması				Süre (Sn)
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²	
BAL	LSTM	2.4014	1.5496	1.1227	0.80349	2.3638	1.5375	1.0928	0.85177	113.1959
	EMD-LSTM	0.59938	0.77419	0.56274	0.95095	0.63894	0.79934	0.59993	0.95993	407.7759
	EMD-WD-LSTM	0.51583	0.71821	0.51612	0.95754	0.58223	0.76304	0.58309	0.96338	432.6597
	EMD-SWD-LSTM	0.55351	0.74399	0.55031	0.95471	0.54441	0.73784	0.55225	0.96586	467.1414
	EMD-VMD-LSTM	0.17432	0.41751	0.30879	0.98565	0.20958	0.4578	0.35763	0.98677	448.3545
WDS	LSTM	384.23	19.602	13.951	0.92774	381.38	19.529	14.207	0.91559	148.5253
	EMD-LSTM	118.57	10.889	7.938	0.9777	189.56	13.768	10.872	0.95805	775.3806
	EMD-WD-LSTM	313.33	17.701	10.814	0.95126	342.16	18.498	11.565	0.9388	596.4127
	EMD-SWD-LSTM	95.874	9.7915	7.3311	0.98197	113.95	10.675	8.384	0.97478	1069.756
	EMD-VMD-LSTM	53.66	7.3253	5.5504	0.98993	55.35	7.4397	5.8589	0.98774	1019.496
BRW	LSTM	85.584	9.2512	5.8682	0.89963	77.555	8.8065	5.6011	0.87972	154.2016
	EMD-LSTM	19.553	4.4219	3.2652	0.97707	19.988	4.4708	3.3104	0.969	671.7028
	EMD-WD-LSTM	11.686	3.4185	2.5464	0.98606	18.836	4.34	3.5442	0.9707	862.4153
	EMD-SWD-LSTM	17.53	4.1868	3.1402	0.97944	19.245	4.3869	3.3108	0.97015	1059.051
	EMD-VMD-LSTM	13.619	3.6905	2.7679	0.98409	19.053	4.365	3.4472	0.97048	1675.394
HNP	LSTM	416.42	20.406	14.221	0.84025	541.45	23.269	15.497	0.79402	140.7827
	EMD-LSTM	115.94	10.767	7.5895	0.95552	654.87	25.59	14.346	0.75087	645.7035
	EMD-WD-LSTM	528.41	22.987	14.031	0.88104	25609	160.03	50.659	0.48722	600.8379
	EMD-SWD-LSTM	98.163	9.9077	6.8884	0.96234	558.56	23.634	13.083	0.78751	826.3923
	EMD-VMD-LSTM	68.058	8.2497	5.9371	0.97402	311.24	17.642	9.6467	0.88263	694.5717

(Offshore & Onshore: ALL, Balıkesir: BAL, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)

LSTM tabanlı ikincil ayrıştırma metotlarının kullanıldığı modellerin çalışma sürelerinin, kullanılan ayrıştırma yöntemlerinin sayısına ve algoritmasına bağlı olarak değişkenlik gösterdiği belirlenmiştir. Yapılan çalışmalarda, iki farklı bilgisayar konfigürasyonu kullanıldığı için verilen bazı sürelerde bir tutarsızlık görülebilir. Ancak modellerin çalışma süreleri genel olarak incelenecek olunursa yapılan analizlerde, kullanılan ayrıştırma yöntemlerinin sayısının artmasıyla birlikte modelin çalışma süresinin de arttığı gözlemlenmiştir. Bu durum, daha karmaşık ve detaylı ayrıştırma işlemlerinin, modelin çalışma sürecinin uzamasına neden olduğu şeklinde ifade edilebilir.

Tablo 4.15’de elde edilen sonuçlara göre EMD’nin kullanıldığı LSTM tabanlı birincil ve ikincil ayrıştırmalı hibrit modellerin tekil LSTM’ye göre elde ettikleri başarı oranları Tablo 4.16’da yüzdesel olarak gösterilmektedir. Oranlar incelendiğinde; Barrow verisi için genelde EMD-WD-LSTM modeli ve diğer veri setleri için ise EMD-VMD-LSTM modelinin en iyi başarı oranını elde ettiği gözlemlenmektedir. Horns Power verisi için EMD-VMD-LSTM modeli


hariç diğer modellerin tekil LSTM'ye göre başarısız olduğu metrik değerlerin bulunduğu tespit edilmiştir.

Tablo 4.16. İkincil ayrıştırma tabanlı LSTM model başarımları (%) (ALL, Z-skor)


Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
BAL	EMD-LSTM	75.0404	50.0394	49.8762	18.3524	72.9698	48.0104	45.1016	12.6983
	EMD-WD-LSTM	78.5196	53.6519	54.0287	19.1726	75.3689	50.3714	46.6426	13.1033
	EMD-SWD-LSTM	76.9505	51.9883	50.9833	18.8204	76.9689	52.0104	49.4647	13.3945
	EMD-VMD-LSTM	92.7409	73.0569	72.4958	22.6711	91.1338	70.2244	67.2740	15.8493
WDS	EMD-LSTM	69.1409	44.4495	43.1009	5.3851	50.2963	29.4997	23.4743	4.6374
	EMD-WD-LSTM	18.4525	9.6980	22.4858	2.5352	10.2837	5.2793	18.5965	2.5350
	EMD-SWD-LSTM	75.0478	50.0485	47.4511	5.8454	70.1217	45.3377	40.9868	6.4647
	EMD-VMD-LSTM	86.0344	62.6298	60.2150	6.7034	85.4869	61.9043	58.7605	7.8802
BRW	EMD-LSTM	77.1534	52.2019	44.3577	8.6080	74.2273	49.2330	40.8973	10.1487
	EMD-WD-LSTM	86.3456	63.0480	56.6068	9.6073	75.7127	50.7182	36.7231	10.3419
	EMD-SWD-LSTM	79.5172	54.7432	46.4878	8.8714	75.1854	50.1857	40.8902	10.2794
	EMD-VMD-LSTM	84.0870	60.1079	52.8322	9.3883	75.4329	50.4343	38.4549	10.3169
HNP	EMD-LSTM	72.1579	47.2361	46.6317	13.7185	-20.9475	-9.9746	7.4272	-5.4344
	EMD-WD-LSTM	-26.8935	-12.6482	1.3361	4.8545	-4629.7	-587.7	-226.90	-38.639
	EMD-SWD-LSTM	76.4269	51.4471	51.5618	14.5302	-3.1600	-1.5686	15.5772	-0.8199
	EMD-VMD-LSTM	83.6564	59.5721	58.2514	15.9206	42.5177	24.1827	37.7513	11.1597

(Offshore & Onshore: ALL, Balıkesir: BAL, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)


İkincil ayrıştırma metotlarının kullanıldığı LSTM tabanlı modelleri, EMD-LSTM ve LSTM modelleriyle yapılan tahminlerin, test aşamasına ait sonuçların grafikleri aşağıda verilmiştir. Bu grafiklerden Şekil 4.20'de Balıkesir verisine, Şekil 4.21'de West of Duddon Sands verisine, Şekil 4.22'de Barrow verisine ve Şekil 4.23'te Horns Power verisine ait tahmin sonuçları gösterilmektedir.




Şekil 4.20. İkincil ayrıştırma tabanlı LSTM model sonuçları (BAL, Z-skor)



Şekil 4.21. İkincil ayrıştırma tabanlı LSTM model sonuçları (WDS, Z-skor)



Şekil 4.22. İkincil ayrıştırma tabanlı LSTM model sonuçları (BRW, Z-skor)



Şekil 4.23. İkincil ayrıştırma tabanlı LSTM model sonuçları (HNP, Z-skor)

4.6. İkincil Ayrıştırma Tabanlı BiLSTM Hibrit Modellerine Ait Çalışmalar

LSTM'nin geliştirilmiş bir versiyonu olan BiLSTM'nin ve ikincil ayrıştırma işleminin birlikte kullanılmasıyla geliştirilen hibrit modellerde, BiLSTM'in yapılan tahminlerin doğruluk oranına katkısı incelenmiştir. BiLSTM'nin LSTM'den temel farkı, ileri ve geri yönlü öğrenme yeteneğinin bulunmasıdır. Bu sayede zaman serisi verilerinde daha detaylı örüntü tespitleri ve

daha hassas tahminler yapılabilir. Geliştirilen modellerde EMD birincil ayrıştırma için kullanılırken; WD, SWD ve VMD ikincil ayrıştırma işlemi için kullanılmıştır. Veri setleri olarak ise West of Duddon Sands, Barrow ve Horns Power kullanılmıştır. BiLSTM’li modellerde Balıkesir veri seti kullanılmamasının nedeni; veri setinin standart sapmasının diğer veri setlerine göre çok düşük olması ve Balıkesir verileri hız verilerinden oluşurken diğer veri setlerinin güç verileri olması şeklindedir. Çalışmalar sonucunda modellerin başarımını gösteren metrik değerler Tablo 4.17’de verilmiştir. Tablodaki sonuçlar yorumlanacak olursa tüm veri setlerinde ve tüm metrik değerler için en başarılı modelin EMD-VMD-BiLSTM modeli olduğu gözlemlenmiştir.

Tablo 4.17. İkincil ayrıştırma tabanlı BiLSTM model sonuçları (OFS, Z-skor)

Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması				Süre (Sn)
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²	
WDS	BiLSTM	362.21	19.032	11.962	0.93188	349.84	18.704	11.145	0.92257	232.1497
	EMD-BiLSTM	144.97	12.04	9.134	0.97274	136.22	11.671	8.8001	0.96985	1403.827
	EMD-WD-BiLSTM	327.79	18.105	11.657	0.94901	342.58	18.509	11.503	0.93873	1345.757
	EMD-SWD-BiLSTM	101.71	10.085	7.4792	0.98087	99.336	9.9668	7.6334	0.97801	1499.723
	EMD-VMD-BiLSTM	59.542	7.7164	5.7386	0.98883	63.854	7.9909	6.3459	0.98586	1373.887
BRW	BiLSTM	79.715	8.9284	6.3167	0.90651	69.033	8.3086	5.8006	0.89294	242.2429
	EMD-BiLSTM	17.634	4.1993	3.0517	0.97932	15.658	3.9571	2.9132	0.97572	1193.31
	EMD-WD-BiLSTM	19.86	4.4565	3.5261	0.97631	21.79	4.6679	3.4785	0.96611	1278.926
	EMD-SWD-BiLSTM	18.111	4.2557	3.156	0.97876	14.05	3.7484	2.7601	0.97821	1392.249
	EMD-VMD-BiLSTM	10.43	3.2296	2.4436	0.98782	12.078	3.4753	2.5902	0.98129	1430.672
HNP	BiLSTM	430.73	20.754	12.405	0.83476	568.02	23.833	13.472	0.78391	235.6978
	EMD-BiLSTM	125.86	11.219	7.9517	0.95172	770.13	27.751	15	0.70702	1138.922
	EMD-WD-BiLSTM	494.26	22.232	13.24	0.88872	22200	149	47.182	0.55549	1283.308
	EMD-SWD-BiLSTM	98.504	9.9249	6.913	0.96221	568.96	23.853	13.089	0.78355	1301.916
	EMD-VMD-BiLSTM	58.954	7.6782	5.4133	0.9775	321.39	17.927	10.003	0.8788	1329.383

(Offshore: OFS, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)

Yukarıdaki tabloda bulunan BiLSTM modellerine ait değerlerle Tablo 4.15’te verilen LSTM modellerinin metrik değerleri kıyaslanacak olursa şu şekilde yorum yapılabilir. West of Duddon Sands veri seti için EMD-VMD-LSTM modeli ve Barrow veri seti için EMD-VMD-BiLSTM modelleri en başarılı modeller olmuştur. Horns Power veri seti için ise eğitim aşamasında EMD-VMD-BiLSTM modeli ve test aşamasında da EMD-VMD-LSTM modeli en iyi metriklerle sahip modeller olmuştur. Hem LSTM hem de BiLSTM modellerinin en başarılı modellerine ait değerler incelenecek olursa elde edilen sonuçların benzerlik gösterdiği görü-

lebilmektedir. Bu durumda yapılan çalışmalar için LSTM ve BiLSTM'in benzer performans sergilediği şeklinde ifade edilebilir. Aynı şekilde BiLSTM'li modellerde de modellerin karmaşıklığı artıkça çalışma sürelerinin de arttığı gözlemlenmiştir.


BiLSTM tabanlı ikincil ayrıştırma işlemi kullanılarak geliştirilen hibrit modeller ile EMD-BiLSTM modelinin, BiLSTM modeliyle elde edilen performans değerlerine başarı oranları yüzde olarak Tablo 4.18'de verilmiştir. Değerlere bakıldığında EMD-VMD-BiLSTM tüm veri setleri için en yüksek başarı oranına sahip model olmuştur. Horns Power verisinin sonuçlarında EMD-VMD-LSTM hariç diğer modellerinin bazı sonuç değerlerinin BiLSTM'ye başarı oranının düştüğü görülmektedir.

Tablo 4.18. İkincil ayrıştırma tabanlı BiLSTM model başarımları (%) (OFS, Z-skor)


Veri Setleri	Modeller	Eğitim Aşaması				Test Aşaması			
		MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
WDS	EMD-BiLSTM	59.9763	36.7381	23.6415	4.3847	61.0622	37.6016	21.0399	5.1248
	EMD-WD-BiLSTM	9.5028	4.8707	2.5497	1.8382	2.0752	1.0426	-3.2122	1.7516
	EMD-SWD-BiLSTM	71.9196	47.0103	37.4753	5.2571	71.6053	46.7130	31.5083	6.0093
	EMD-VMD-BiLSTM	83.5615	59.4557	52.0264	6.1113	81.7477	57.2771	43.0606	6.8602
BRW	EMD-BiLSTM	77.8787	52.9669	51.6884	8.0319	77.3181	52.3734	49.7776	9.2705
	EMD-WD-BiLSTM	75.0862	50.0862	44.1781	7.6999	68.4354	43.8185	40.0321	8.1943
	EMD-SWD-BiLSTM	77.2803	52.3352	50.0372	7.9701	79.6474	54.8853	52.4170	9.5494
	EMD-VMD-BiLSTM	86.9159	63.8278	61.3152	8.9696	82.5040	58.1723	55.3460	9.8943
HNP	EMD-BiLSTM	70.7798	45.9430	35.8992	14.0112	-35.5815	-16.4394	-11.3420	-9.8085
	EMD-WD-BiLSTM	-14.7494	-7.1215	-6.7312	6.4641	-3808.3131	-525.1836	-250.2227	-29.1385
	EMD-SWD-BiLSTM	77.1309	52.1784	44.2725	15.2679	-0.1655	-0.0839	2.8429	-0.0459
	EMD-VMD-BiLSTM	86.3130	63.0038	56.3620	17.0995	43.4192	24.7808	25.7497	12.1047

(Offshore: OFS, West of Duddon Sands: WDS, Barrow: BRW, Horns Power: HNP)


BiLSTM tabanlı ikincil ayrıştırmanın kullanıldığı hibrit modellerle elde edilen tahminlerin test aşamasına ait sonuç grafikleri aşağıda gösterilmektedir. Şekil 4.24'te West of Duddon Sands verisinin sonuç grafikleri, Şekil 4.25'te Barrow veri setinin sonuç grafikleri ve Şekil 4.26'da Horns Power verisinin sonuç grafikleri verilmiştir.



Şekil 4.24. İkincil ayrıştırma tabanlı BiLSTM model sonuçları (WDS, Z-skor)



Şekil 4.25. İkincil ayrıştırma tabanlı BiLSTM model sonuçları (BRW, Z-skor)



Şekil 4.26. İkincil ayrıştırma tabanlı BiLSTM model sonuçları (HNP, Z-skor)

4.7. Genel Değerlendirme

Çalışmalarda geliştirilen modellerin tahminlerdeki performanslarını ölçmek için Balıkesir, West of Duddon Sands, Barrow ve Horns Power veri setleri kullanılarak yapılan tahmin sonuçları değerlendirildiğinde en başarılı olan modeller Tablo 4.19’da gösterilmektedir. Tablodaki tüm modellerde normalizasyon işlemi için Z-Skor kullanılmıştır. Kıyaslama işlemi için eğitim ve test aşamalarındaki MSE ile R^2 metrik değerleri referans alınmıştır. Değerler incelendiğinde Balıkesir veri seti için eğitim aşamasındaki MSE 0.17432 ve R^2 0.98565; test aşamasındaki MSE 0.20958 ve R^2 0.98677 sonuçlarıyla EMD-VMD-LSTM modeli en başarılı model olmuştur. West of Duddon Sands veri seti için eğitim ve test aşamasında en başarılı model EMD-VMD-LSTM olup eğitim aşamasında MSE 53.66 ve R^2 0.98993; test aşamasında MSE 55.35 ve R^2 0.98774 değerleri elde edilmiştir. Barrow veri seti için eğitim aşamasındaki MSE 10.43 ve R^2 0.98782; test aşamasındaki MSE 12.078 ve R^2 0.98129 sonuçlarıyla EMD-VMD-BiLSTM modeli en iyi performansı göstermiştir. Horns Power veri seti için eğitim aşamasındaki MSE 58.954 ve R^2 0.9775 değerleriyle EMD-VMD-BiLSTM; test aşamasındaki MSE 127.6 ve R^2 0.95035 değerleriyle EEMD-MLP modeli en başarılı model olmuştur.

Tablo 4.19. Kullanılan dört veri seti için en başarılı modeller

Veri Setleri	Eğitim Aşaması			Test Aşaması		
	Model	MSE	R2	Model	MSE	R2
Balıkesir	EMD-VMD-LSTM	0.17432	0.98565	EMD-VMD-LSTM	0.20958	0.98677
West of Duddon Sands	EMD-VMD-LSTM	53.66	0.98993	EMD-VMD-LSTM	55.35	0.98774
Barrow	EMD-VMD-BiLSTM	10.43	0.98782	EMD-VMD-BiLSTM	12.078	0.98129
Horns Power	EMD-VMD-BiLSTM	58.954	0.9775	EEMD-MLP	127.6	0.95035

5. SONUÇ

Bu tez çalışması, rüzgar enerjisinin elektrik şebekelerine entegrasyonu sırasında ortaya çıkan zorlukları ele almaktadır. Rüzgar enerjisinin doğası gereği değişkenlik ve belirsizlik göstermesi, enerji üretiminde öngörülemeyen dalgalanmalara yol açarak şebeke güvenilirliği ve verimliliğini olumsuz etkileyebilmektedir. Çalışmanın ana problemi, kısa dönemli rüzgar hızlarının ve güç üretiminin yüksek doğrulukla tahmin edilerek şebeke entegrasyonunu optimize etmek ve böylece enerji arz güvenliğini artırmaktır. Özellikle, karasal ve açık deniz rüzgar santrallerinden elde edilen verilerin kullanılmasıyla geliştirilen hibrit derin öğrenme modelleri, rüzgar enerjisinin öngörülemez doğasından kaynaklanan bu sorunları çözmek üzere tasarlanmıştır.

Bu tez çalışması, kısa dönemli rüzgar tahmininde yenilikçi hibrit derin öğrenme modellerinin geliştirilmesini hedeflemektedir. Çalışmada kullanılan temel yöntemler arasında Çok Katmanlı Algılayıcı (MLP), Yankı Durumu Ağı (ESN), Uzun Kısa Süreli Bellek (LSTM) ve çift yönlü LSTM (BiLSTM) gibi derin öğrenme teknikleri bulunmaktadır. Bu modellerin performansını optimize etmek için çeşitli ayrıştırma teknikleri uygulanmıştır. Birincil ayrıştırma yöntemlerinin yanı sıra, ikincil ayrıştırma yöntemleri de kullanılarak Ampirik Mod Ayrıştırması (EMD), Topluluk Ampirik Mod Ayrıştırması (EEMD), Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayrıştırması (CEEMDAN), Sürü Ayrıştırması (SWD), Dalgacık Ayrıştırması (WD) ve Varyasyonel Mod Ayrıştırma (VMD) gibi gelişmiş teknikler değerlendirilmiştir. Bu kapsamda, hem karasal hem de açık deniz rüzgar verileri (Balıkesir, West of Duddon Sands, Barrow ve Horns Power bölgelerine ait gerçek rüzgar hızı ve rüzgar gücü verileri) kullanılarak, hibrit modellerin etkinliği ve tahmin doğruluğu detaylı bir şekilde incelenmiştir. Birincil ayrıştırma işlemleri kullanılarak geliştirilen modeller; EMD-MLP, EEMD-MLP, CEEMDAN-MLP, EMD-LSTM, EEMD-LSTM, CEEMDAN-LSTM ve EMD-ESN modelleridir. İkincil ayrıştırma işlemlerinin uygulandığı LSTM ve BiLSTM tabanlı hibrit modeller ise; EMD-WD-LSTM, EMD-SWD-LSTM, EMD-VMD-LSTM, EMD-WD-BiLSTM, EMD-SWD-BiLSTM ve EMD-VMD-BiLSTM şeklindedir. Ayrıştırma teknikleri, rüzgar verilerinin özelliklerinin daha iyi yakalanmasını sağlayarak, modellerin tahmin performansını artırmakta önemli rol oynamıştır. Özellikle, ikincil ayrıştırma tabanlı modellerin, öngörülerde daha yüksek doğruluk oranları sağladığı ve bu doğruluğun enerji şebekelerinin güvenilirliği ile verimliliğini artırmada kritik bir faktör olduğu gözlemlenmiştir. Çalışmada ayrıca, farklı normalizasyon tekniklerinin (Min-Max ve Z-skor) modellerin performansına olan etkisi incelenmiş ve çeşitli ayrıştırma yöntemlerinin kombinasyonu ile optimal model yapılandırmaları belirlenmiştir. Bu

sayede, enerji sektöründe daha sürdürülebilir ve güvenilir bir yenilenebilir enerji entegrasyonu için stratejik katkılar sağlanmıştır.

Modellerin tahminlerinde normalizasyon işleminin etkisini ölçmek amacıyla birincil ayrıştırma işleminin kullanıldığı; EMD-MLP, EEMD-MLP, CEEMDAN-MLP, EMD-LSTM, EEMD-LSTM, CEEMDAN-LSTM modellerinde hem Min-Max hem de Z-skor normalizasyon teknikleri uygulanmıştır. İkincil ayrıştırma işleminin kullanıldığı; EMD-WD-LSTM, EMD-SWD-LSTM, EMD-VMD-LSTM, EMD-WD-BiLSTM, EMD-SWD-BiLSTM ve EMD-VMD-BiLSTM modellerinde ise sadece Z-skor ile normalizasyon işlemleri gerçekleştirilmiştir.

Çalışmada kullanılan tüm modellerin için tahmin sonuçları veri setlerine göre gruplandırılıp oransal kıyaslamalar ve değerlendirilmeler yapılmıştır. Oransal kıyaslamalar için eğitim ve test aşamalarındaki MSE ve R^2 değerleri referans alınmıştır. Aşağıda bu değerler, veri setlerine göre tek tek ele alınıp çalışmadaki sonuçlar hakkında genel bir değerlendirme yapılmıştır.

1. Balıkesir veri setiyle yapılan çalışmalar sonucunda, en yüksek performansı gösteren modeller; Min-Max normalizasyonu ve Z-skor işlemlerinin uygulandığı, birincil ayrıştırma sürecinden geçirilen EMD-MLP ve EMD-LSTM modelleri ile ikincil ayrıştırma sürecinin kullanıldığı EMD-VMD-LSTM modeli olmuştur. Bu modeller arasında da EMD-VMD-LSTM modelinin en iyi sonuçlara sahip olduğu görülmüştür. EMD-VMD-LSTM modelinin diğer başarılı modellere göre elde ettiği başarı oranları; Min-Max normalizasyonlu EMD-MLP’de eğitim ve test aşamasındaki MSE ile R^2 için sırasıyla MSE %68.615, R^2 %3.258, MSE %67.273 ve R^2 %2.805 şeklinde olmuştur. Z-skorun uygulandığı EMD-MLP’ye göre ise başarı oranları, eğitim ve test aşamaları için sırasıyla; MSE %67.680, R^2 %2.712, MSE %63.323 ve R^2 %3.129 olarak artmıştır. Min-Max normalizasyonlu EMD-LSTM’ye oranla gösterilen başarı oranları, eğitim ve test aşamalarına göre sırasıyla; MSE %77.260, R^2 %5.162, MSE %74.685 ve R^2 %4.080 olmuştur. Z-skorlu EMD-LSTM’ye göre ise EMD-VMD-LSTM’in eğitim ve test aşamaları için ise sırasıyla; MSE %75.637, R^2 %4.141, MSE %70.705 ve R^2 %4.314 değerleriyle başarı oranının arttığı tespit edilmiştir.

2. West of Duddon Sands veri seti kullanılarak yapılan tahminlerde MLP, LSTM, ESN ve BiLSTM tabanlı modellerden en başarılı olanlar arasında yapılan kıyaslamalara göre en iyi sonuçları EMD-VMD-LSTM modeli elde etmiştir. EMD-VMD-LSTM’nin diğer başarılı modellere göre sahip olduğu başarı oranları; Min-Max normalizasyonunun kullanıldığı EMD-MLP göre eğitim aşamasında MSE %30.139 ve R^2 %0.444, test aşamasında CEEMDAN-MLP

göre MSE %51.718 ve R^2 %1.345 başarımlar elde edilmiştir. Z-skor'un kullanıldığı EMD-MLP'ye göre eğitim ve test aşamaları için MSE %34.370, R^2 %0.555, MSE %35.569 ve R^2 %0.320 oranlarıyla başarımlar elde edilmiştir. Min-Max normalizasyonunun kullanıldığı hibrit CEEMDAN-LSTM'ye göre eğitim ve test aşamalarında elde edilen başarımlar MSE %56.135, R^2 %1.324, MSE %53.909 ve R^2 %1.471 şeklinde gerçekleşmiştir. Z-skorun kullanıldığı CEEMDAN-LSTM'ye göre gösterilen başarımlar eğitim ile test aşamalarındaki MSE için %66.175, R^2 için %2.020 ve MSE için %69.944; EMD-LSTM'nin test aşamasındaki R^2 değeri için %2.217 şeklinde olmuştur. EMD-ESN'ye göre eğitim ve test aşamalarındaki MSE %47.080, R^2 %0.917, MSE %44.418 ve R^2 %0.969 başarımlarlarıyla EMD-VMD-LSTM daha başarılı olmuştur. EMD-VMD-LSTM modelinin, ikincil ayrıştırmanın kullanıldığı diğer model olan EMD-VMD-BiLSTM modeline göre ise gerçekleşen başarımlar oranları sırasıyla eğitim ile test aşamaları için MSE %9.878, R^2 %0.111, MSE %13.317 ve R^2 %0.190 şeklinde meydana gelmiştir.

3. Barrow veri setinin kullanıldığı MLP, LSTM, ESN ve BiLSTM tabanlı modellerle yapılan tahminlerden elde edilen performans değerlerine göre en iyi model EMD-VMD-BiLSTM modeli olmuştur. Her çalışmada başarılı olan modelin, EMD-VMD-BiLSTM modeli ile oransal olarak kıyaslanmasıyla tespit edilen yüzdesel sonuçlar şu şekildedir. EMD-VMD-BiLSTM modelinin, Min-Max normalizasyonunun kullanıldığı EMD-MLP modeline göre eğitim ve test aşamalarına ait MSE %30.913, R^2 %0.562, MSE %38.888 ve R^2 %1.231 şeklinde gerçekleşen başarımlar gözlemlenmiştir. Z-skor'un kullanıldığı EMD-MLP modeline göre eğitim ile test aşamalarına ait kıyaslamalar sonucunda gerçekleşen başarımlar; MSE için %25.023, R^2 için %0.405, MSE için %22.512 ve R^2 için %0.341 olarak gerçekleşmiştir. Min-Max normalizasyonunun kullanıldığı EMD-LSTM modeline göre elde edilen başarımlar; eğitim aşamasında MSE için %55.450 ve R^2 için %1.570, CEEMDAN-LSTM'ye göre oluşan başarımlar test aşamasında MSE için %48.958 ve R^2 için %1.867 şeklinde hesaplanmıştır. Z-skor işleminin kullanıldığı EMD-LSTM modeline kıyasla hesaplanan başarımlar; eğitim aşamasında MSE değerine göre %54.318 ve R^2 değerine göre %1.475, test aşamasında MSE değeri için %51.870 ve R^2 değeri için %1.740 şeklinde tespit edilmiştir. ESN modeli için yapılan çalışmalara göre gerçekleşen başarımlar şu şekilde olmuştur; EMD-BiLSTM modelinin eğitim aşamasına ait metriklere göre MSE için %40.852 ve R^2 için %0.870, EMD-ESN'nin test aşamasındaki MSE değerine göre %21.865 ve R^2 değerine göre %0.563 olarak gerçekleşmiştir. İkincil ayrıştırmanın kullanıldığı EMD-WD-LSTM modeline göre ise eğitim aşamasında MSE

için %10.747 ve R^2 için %0.178, test aşamasında da MSE için %35.878 ve R^2 için %1.090 olarak elde edilen başarımlarıyla EMD-VMD-BiLSTM modeli daha başarılı tahmin sonuçları elde etmiştir.

4. Horns Power veri setiyle yapılan tüm tahmin çalışmaları analiz edildiğinde eğitim aşamasındaki sonuçlara göre EMD-VMD-BiLSTM modeli ve test aşamasındaki tahmin sonuçlarına göre ise Z-skorlu EMD-MLP modeli en başarılı sonuçlara sahip modeller olmuştur. EMD-VMD-BiLSTM'in eğitim aşamasındaki başarı değerlerinin diğer modellerin eğitim aşamasındaki değerlerine göre gerçekleşen başarımları; Min-Max normalizasyonunun kullanıldığı CEEMDAN-MLP modelinin MSE değerine göre %43.498, EEMD-MLP modelinin R^2 değeri için %1.81, EEMD-LSTM'nin MSE değerine göre %57.452 ve R^2 için %3.179, EMD-ESN modelinin MSE değerine göre %52.734 ve R^2 için %2.694 şeklinde hesaplanmıştır. Z-skor'un kullanıldığı modeller için eğitim aşamasında gerçekleşen başarımları; EEMD-MLP'nin MSE değerine göre %49.010 ve R^2 için %2.144, EEMD-LSTM'nin MSE değerine göre %68.295 ve R^2 için %5.086, EMD-VMD-LSTM'nin MSE değeri için %13.376 ve R^2 için %0.357 olarak gerçekleşmiştir. Test aşamasında ise Z-skor'un kullanıldığı EEMD-MLP modelinin diğer başarılı modellerin test aşamasındaki değerlerine göre elde ettiği başarımları; Min-Max normalizasyonunun kullanıldığı EEMD-MLP'nin MSE değeri için %13.262 ve R^2 için %0.605, EEMD-LSTM'nin MSE değeri için %31.552 ve R^2 için %2.157, EMD-ESN'nin MSE değeri için %46.788 ve R^2 için %4.78 şeklinde olmuştur. Z-skor'un kullanıldığı modellere göre ise gerçekleşen başarımları; EEMD-LSTM'nin MSE değeri için %33.576 ve R^2 için %2.407, EMD-VMD-LSTM'nin MSE değeri için %59.002 ve R^2 için %7.672, EMD-VMD-BiLSTM'nin MSE değeri için %60.297 ve R^2 için %8.141 şeklinde meydana gelmiştir.

Yukarıdaki değerlendirmeler sonucunda elde edilen bilgilerle kullanılan modellerle ilgili şöyle bir özetleme yapılabilir. Ayırıştırma işleminin kullanıldığı hibrit modellerin tekil modellere göre daha başarılı tahminler yaptığı görülmüştür. Hibrit modellerde de ikincil ayırıştırmanın kullanıldığı modellerin, birincil ayırıştırmanın kullanıldığı modellere göre daha genelde başarılı sonuçlar elde ettiği tespit edilmiştir. Bu çalışmada ayırıştırma işlemleri için EMD ve VMD algoritmalarının beraber kullanıldığı ikincil ayırıştırma hibrit modeller, genelde en başarılı modeller olmuşlardır. İkincil ayırıştırma işlemi sayesinde, birincil ayırıştırma işlemi sonucunda oluşturulan bileşenlerin en yüksek frekanslı bileşeni olan birinci IMF tekrar ayırıştırılarak kullanılmaktadır. Bu sayede rüzgar tahminlerinde doğru tahminlerde negatif etki yaratan stokastik yapısının etkisi azaltılabilmektedir. Normalizasyon işlemlerinin, modellerin tahminlerine olan etkisinin incele-

mek üzere yapılan çalışmalarda da Z-skor'un uygulandığı modellerin az farkla da olsa genelde daha iyi değerlere sahip olduğu tespit edilmiştir.

Yapılan tahmin çalışmalarında modellerin karadaki ve denizdeki rüzgarları tahmin etmedeki başarıları da kıyaslandı. Yapılan tahminler sonucunda elde edilen değerler analiz edildiğinde, denizlerdeki rüzgarların tahminlerindeki başarı oranının karadaki rüzgarların tahminindeki başarı oranına göre daha düşük çıktığı görülmüştür. Bu durumun denizlerdeki rüzgarların karakteristiğinin, karadaki rüzgarlara göre daha değişken bir yapıda olmasından kaynaklandığı sonucuna varılabilir.

Bu tez çalışması kapsamında rüzgar hızı ve gücü tahmini için geliştirilen hibrit modellerle tahminler yapıp elde edilen sonuçlar karşılaştırılmıştır. Kıyaslamalarda; hibrit modellerin tahminlerdeki başarısının tekil modellere göre daha yüksek olduğu, ancak modellerin çalışma süresinin tekil modellere göre fazla olduğu gözlemlenmiştir. Ayrıca bir veri seti için başarılı tahmin sonuçlarına sahip olan bir modelin, farklı bir veri seti için aynı oranda başarılı olamayabileceği de tespit edilmiştir. Bu durum her bölgedeki rüzgarın karakteristiğinin farklı olmasından kaynaklanmaktadır. Bu nedenle farklı karakteristiğe sahip bölgelerde başarı oranı yüksek rüzgar tahminleri yapmak için seçilecek model de farklı olabilmektedir.

Gelecekteki araştırmalar, bu tez çalışmasında elde edilen bulguları geliştirmek için birkaç umut verici yolu ele alabilir. İlk olarak, uydu görüntüleri ve gerçek zamanlı hava durumu güncellemeleri gibi ek meteorolojik veri kaynaklarının çalışmaya dahil edilmesi, tahmin modellerini daha da iyileştirebilir. İkinci olarak, Çekişmeli Üretici Ağlar (Generative Adversarial Networks: GANs) veya Transformer tabanlı modeller gibi gelişmiş makine öğrenimi modellerinin entegrasyonu, tahmin doğruluğunda yeni bakış açıları ve iyileştirmeler sunabilir. Ayrıca, iklim değişikliğinin rüzgar modelleri üzerindeki etkilerinin incelenmesi ve bu değişikliklerin tahmin modellerine dahil edilmesi, daha sağlam ve uyarlanabilir tahminler sağlayabilir. Araştırmacılar ayrıca, bir bölgede eğitilen modellerin minimum yeniden eğitimle başka bir bölgeye uyarlandığı ve böylece tahmin modellerinin ölçeklenebilirliğini artıran transfer öğrenme potansiyelini de göz önünde bulundurmalıdır. Genel olarak, bu gelecekteki araştırma yönleri, rüzgar enerjisi tahmini alanında önemli ilerlemeler vaat etmekte ve daha verimli, güvenilir yenilenebilir enerji sistemlerine katkıda bulunma potansiyeli taşımaktadır.

KAYNAKÇA

- Abedinia, O., Lotfi, M., Bagheri, M., Sobhani, B., Shafie-Khah, M., & Catalão, J. P.** (2020). “Improved EMD-based complex prediction model for wind power forecasting”. *IEEE Transactions on Sustainable Energy* 11 (4).
- Abuzaid, H., Almashhour, R., Mohammed, A., & Beheiry, S.** (2022). “Assessment of the Perception of Sustainability for Occupants of Residential Buildings: A Case Study in the UAE”. *Buildings* 12 (7).
- Ahmadi, F., Tohidi, M., & Sadrianzade, M.** (2023). “Streamflow prediction using a hybrid methodology based on variational mode decomposition (VMD) and machine learning approaches”. *Applied Water Science* 13 (6).
- Ahmadi, M., & Khashei, M.** (2021). “Current status of hybrid structures in wind forecasting”. *Engineering applications of artificial intelligence* 99.
- Ahvenainen, S.** (2017). “Use of recycled nutrients in biological wastewater treatment”. *Lappeenranta University of Technology*.
- Akdoğan, Ş.** (2011). “Değişken hızlı değişken kanat açılı bir rüzgar türbininin modellenmesi, simülasyonu ve kontrolü”. *Gebze Yüksek Teknoloji Enstitüsü Mühendisliği Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi*, numara s 93.
- Akhmetshin, E., & Kovalenko, K.** (2019). “Construction of large dams: problems and development trends”. *MATEC Web of Conferences*, cilt 265. EDP Sciences.
- Akinsal, A.** (2009). “Rüzgar enerjisi ve Türkiye rüzgar potansiyeli, rüzgar enerjisinde değişken ve sabit fiyat tarifeleri ve enerji depolama teknikleri”. Yüksek lisans tezi, Fen Bilimleri Enstitüsü.
- Alfaro, C., Rueda-Gutiérrez, J., Casallas, Y., Rodríguez, G., & Malo, J.** (2021). “Approach to the geothermal potential of Colombia”. *Geothermics* 96.
- Ali, M., Liu, L., Geng, Y., & Khokhar, S.** (2020). “Emergy based sustainability evaluation of a hydroelectric dam proposal in South Asia”. *Journal of Cleaner Production* 264.
- Alzahrani, A. M., & Rajendran, P.** (2019). “Petroleum hydrocarbon and living organisms”. *Hydrocarbon pollution and its effect on the environment*.

An, G., Chen, L., Tan, J., Jiang, Z., Li, Z., & Sun, H. (2022). “Ultra-short-term wind power prediction based on PVMD-ESMA-DELM”. *Energy Reports* 8.

Archer, C., Simão, H., Kempton, W., Powell, W. B., & Dvorak, M. (2017). “The challenge of integrating offshore wind power in the US electric grid. Part I: Wind forecast error”. *Renewable energy* 103.

Arefin, S. S. (2020). “Optimization techniques of islanded hybrid microgrid system”. *Renewable Energy-Resources, Challenges and Applications*. IntechOpen.

Ataseven, M. S., & Ataseven, S. (2009). “Rüzgar Ölçüm Sistemleri”. *Web Sayfası: <http://www.emo.org.tr>*, (Erişim Tarihi: Temmuz 2011).

Bai, Y., Liu, M.-D., Ding, L., & Ma, Y.-J. (2021). “Double-layer staged training echo-state networks for wind speed prediction using variational mode decomposition”. *Applied Energy* 301.

Balci, M., Yüzgeç, U., & Dokur, E. (2022). “Rüzgâr Hızı Tahmini İçin Ayrıştırmaya Dayalı Hibrit Yöntemlerin Karşılaştırmalı Bir Çalışması”. *International Conference On Emerging Sources In Science May*.

Balci, M., Dokur, E., Yuzgec, U., & Erdogan, N. (2023). “Multiple decomposition-aided long short-term memory network for enhanced short-term wind power forecasting”. *IET Renewable Power Generation*.

Baudel, T. (2022). “Co-constructing Shared Values and Ethical Practice for the Next Generation: Lessons Learned from a Curriculum on Information Ethics”. *Platforms and Artificial Intelligence: The Next Generation of Competences*. Springer.

Bokde, N., Feijóo, A., Al-Ansari, N., Tao, S., & Yaseen, Z. M. (2020). “The hybridization of ensemble empirical mode decomposition with forecasting models: Application of short-term wind speed and power modeling”. *Energies* 13 (7).

Bórawski, P., Beldycka-Bórawska, A., Jankowski, K. J., Dubis, B., & Dunn, J. W. (2020). “Development of wind energy market in the European Union”. *Renewable Energy* 161.

Buan, N. (2018). *Methanogens: pushing the boundaries of biology*. *Emerg Top Life Sci* 2: 629–646.

- Carlucci, A. P.** (2019). “Introductory chapter: The challenges of future internal combustion engines”. *The Future of Internal Combustion Engines*. IntechOpen.
- Carraro, C. d. F. F., Martins, A. C., Silva Faria, A. C. da, & Loures, C. C. A.** (2020). “Agroenergy from Residual Biomass: Energy Perspective”. *Biotechnological Applications of Biomass*.
- Castillo-Mussot, M. del, Ugalde-Véle, P., Montemayor-Aldrete, J. A., Lama-García, A. de la, & Cruz, F.** (2016). “Impact of global energy resources based on energy return on their investment (EROI) parameters”. *Perspectives on global development and technology* 15 (1-2).
- Cheng, Z., & Wang, J.** (2020). “A new combined model based on multi-objective salp swarm optimization for wind speed forecasting”. *Applied Soft Computing* 92.
- Çelikdemir, S., & Özdemir, M. T.** (2023). “Türkiye’s Offshore Hybrid Energy Potential and Cost Estimation in the Eastern Mediterranean”. *Türk Doğa ve Fen Dergisi* 12 (1).
- Degraer, S., Carey, D. A., Coolen, J. W., Hutchison, Z. L., Kerckhof, F., Rumes, B., & Vanaverbeke, J.** (2020). “Offshore wind farm artificial reefs affect ecosystem structure and functioning”. *Oceanography* 33 (4).
- Deshmukh, M. K. G., Sameeroddin, M., Abdul, D., & Sattar, M. A.** (2023). “Renewable energy in the 21st century: A review”. *Materials Today: Proceedings* 80.
- Detken, F.** (2023). “Young children’s ideas of energy compared with the scientific energy concept: Results of a video study with interviews about children’s own drawings”. *Frontiers in Education*, cilt 8. Frontiers Media SA.
- Devabhaktuni, V., Alam, M., Depuru, S. S. S. R., Green II, R. C., Nims, D., & Near, C.** (2013). “Solar energy: Trends and enabling technologies”. *Renewable and Sustainable Energy Reviews* 19.
- Deveci, M., Cali, U., Kucuksari, S., & Erdogan, N.** (2020). “Interval type-2 fuzzy sets based multi-criteria decision-making model for offshore wind farm development in Ireland”. *Energy* 198.
- Deveci, M., Özcan, E., John, R., Pamucar, D., & Karaman, H.** (2021). “Offshore wind farm site selection using interval rough numbers based Best-Worst Method and MARCOS”. *Applied Soft Computing* 109.

- Dhar, A., Naeth, M. A., Jennings, P. D., & Gamal El-Din, M.** (2020). “Geothermal energy resources: potential environmental impact and land reclamation”. *Environmental Reviews* 28 (4).
- Ding, C., Zhou, Y., Ding, Q., & Li, K.** (2022). “Integrated carbon-capture-based low-carbon economic dispatch of power systems based on EEMD-LSTM-SVR wind power forecasting”. *Energies* 15 (5).
- Ding, L., Bai, Y.-L., Fan, M.-H., Yu, Q.-H., Zhu, Y.-J., & Chen, X.-Y.** (2023). “Serial-parallel dynamic echo state network: A hybrid dynamic model based on a chaotic coyote optimization algorithm for wind speed prediction”. *Expert Systems with Applications* 212.
- Dukur, 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.
- Dolatabadi, A., Abdeltawab, H., & Mohamed, Y. A.-R. I.** (2020). “Hybrid deep learning-based model for wind speed forecasting based on DWPT and bidirectional LSTM network”. *IEEE Access* 8.
- Drake, H., Roberts, N. M., Heim, C., Whitehouse, M. J., Siljeström, S., Kooijman, E., Broman, C., Ivarsson, M., & Åström, M. E.** (2019). “Timing and origin of natural gas accumulation in the Siljan impact structure, Sweden”. *Nature communications* 10 (1).
- Du, M.** (2019). “Improving lstm neural networks for better short-term wind power predictions”. *2019 IEEE 2nd International Conference on Renewable Energy and Power Engineering (REPE)*. IEEE.
- Dursun, E. H.** (2020). “Rüzgar enerjisi dönüşüm sistemlerinin MPPT kontrolü ile enerji verimliliğinin iyileştirilmesi”. *T.C. Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü*.
- Edenhofer, O., Pichs-Madruga, R., Sokona, Y., Seyboth, K., Kadner, S., Zwickel, T., Eickemeier, P., Hansen, G., Schlömer, S., & Stechow, C. von.** (2011). *Renewable energy sources and climate change mitigation: Special report of the intergovernmental panel on climate change*. Cambridge University Press.

- Ellabban, O., Abu-Rub, H., & Blaabjerg, F.** (2014). "Renewable energy resources: Current status, future prospects and their enabling technology". *Renewable and sustainable energy reviews* 39.
- Emeksiz, M., Cem & Tan.** (2022). "Multi-step wind speed forecasting and Hurst analysis using novel hybrid secondary decomposition approach". *Energy* 238.
- Ertimi, B., Sarmidi, T., Khalid, N., & Helmi Ali, M.** (2021). "The policy framework of natural resource management in oil-dependence countries". *Economies* 9 (1).
- Gaci, S.** (2016). "A new ensemble empirical mode decomposition (EEMD) denoising method for seismic signals". *Energy Procedia* 97.
- Galphade, M., Nikam, V., Banerjee, B., & Kiwelekar, A. W.** (2022). "Comparative Analysis of Wind Power Forecasting Using LSTM, BiLSTM, and GRU". *International Conference on Frontiers of Intelligent Computing: Theory and Applications*. Springer.
- Gandoman, F. H., Ahmadi, A., Aleem, S. H. A., Ardeshiri, M., Nezhad, A. E., Van Mierlo, J., & Berecibar, M.** (2020). "Ocean wind energy technologies in modern electric networks: opportunity and challenges". *Advances in Modelling and Control of Wind and Hydrogenerators*. IntechOpen.
- Gao, Q., Lian, S., & Yan, H.** (2022). "Aerodynamic performance analysis of adaptive drag-lift hybrid type vertical Axis wind turbine". *Energies* 15 (15).
- Gao, X., Guo, W., Mei, C., Sha, J., Guo, Y., & Sun, H.** (2023). "Short-term wind power forecasting based on SSA-VMD-LSTM". *Energy Reports* 9.
- Geng, D., Zhang, H., & Wu, H.** (2020). "Short-term wind speed prediction based on principal component analysis and LSTM". *Applied sciences* 10 (13).
- Gorgel, P., & Kavlak, E.** (2020). "Uzun kısa süreli hafıza ve evrimsel sinir ağları ile rüzgar enerjisi üretim tahmini". *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi* 11 (1).
- Guarrieiro, L. L., Anjos, J. P. d., Silva, L. A. d., Santos, A. Á., Calixto, E. E., Pessoa, F. L., Almeida, J. L. d., Andrade Filho, M., Marinho, F. S., & Rocha, G. O. d.** (2022). "Technological perspectives and economic aspects of green hydrogen in the energetic transition: challenges for chemistry". *Journal of the Brazilian Chemical Society* 33 (8).
- GWEC.** (2024). *Global Wind Report 2024*. GWEC: Brussels, Belgium.

- Gyamfi, S., Derkyi, N. S., & Asuamah, E. Y.** (2018). “The potential and the economics of hydropower investment in West Africa”. *Sustainable Hydropower in West Africa*. Elsevier.
- El-Hafez, O. J., ElMekkawy, T. Y., Kharbeche, M. B. M., & Massoud, A. M.** (2022). “Economic Energy Allocation of Conventional and Large-Scale PV Power Plants”. *Applied Sciences* 12 (3).
- Haldorai, A.** (2022). “A Survey of Renewable Energy Sources and their Contribution to Sustainable Development”. *J. Enterp. Bus. Intell* 2.
- Hochreiter, S., & Schmidhuber, J.** (Kasım 1997). “Long Short-Term Memory”. *Neural Computation* 9 (8). eprint: <https://direct.mit.edu/neco/article-pdf/9/8/1735/813796/neco.1997.9.8.1735.pdf>.
- Hou, G., Wang, J., & Fan, Y.** (2024). “Multistep short-term wind power forecasting model based on secondary decomposition, the kernel principal component analysis, an enhanced arithmetic optimization algorithm, and error correction”. *Energy* 286.
- Hu, H., Wang, L., & Tao, R.** (2021). “Wind speed forecasting based on variational mode decomposition and improved echo state network”. *Renewable Energy* 164.
- Huang, H., Castruccio, S., & Genton, M. G.** (2022). “Forecasting high-frequency spatio-temporal wind power with dimensionally reduced echo state networks”. *Journal of the Royal Statistical Society Series C: Applied Statistics* 71 (2).
- IAEA, H.** (2001). *Processing of Radioactive Waste from Nuclear Applications*. Vienna.
- IEA.** (2023). *Renewables 2023*. IEA: International Energy Agency.
- Ikumapayi, O. M., Ogedengbe, T. S., Laseinde, O. T., Kazeem, R. A., Afolalu, S. A., Akinlabi, S. A., & Akinlabi, E. T.** (2023). “A brief study into renewable energy technologies”. *E3S Web of Conferences*, cilt 391. EDP Sciences.
- Imasiku, K.** (2021). “A Solar Photovoltaic Performance and Financial Modeling Solution for Grid-Connected Homes in Zambia”. *International Journal of Photoenergy* 2021 (1).
- IRENA, I. R. E. A.** (2024). *Electricity Capacity Trends*. <https://www.irena.org/Energy-Transition/Technology/Wind-energy> [Accessed: (07/14/2024)].

- Islam, M. T., Nabi, M., Arefin, M., Mostakim, K., Rashid, F., Hassan, N., Rahman, S., McIntosh, S., Mullins, B., & Mueen, S.** (2022). "Trends and prospects of geothermal energy as an alternative source of power: A comprehensive review". *Heliyon* 8 (12).
- Ismail, B. I.** (2011). "Power Generation Using Nonconventional Renewable Geothermal & Alternative Clean Energy Technologies". *Planet Earth 2011-Global Warming Challenges and Opportunities for Policy and Practice*. IntechOpen.
- Ivanovski, K., Hailemariam, A., & Smyth, R.** (2021). "The effect of renewable and non-renewable energy consumption on economic growth: Non-parametric evidence". *Journal of Cleaner Production* 286.
- Jaeger, H.** (2001). "The "echo state" approach to analysing and training recurrent neural networks with an erratum note". *Bonn, Germany: German National Research Center for Information Technology GMD Technical Report* 148 (34).
- Jaseena, K. U., & Kovoov, B. C.** (2021). "Decomposition-based hybrid wind speed forecasting model using deep bidirectional LSTM networks". *Energy Conversion and Management* 234.
- Jaseena, K., & Kovoov, B. C.** (2021). "EEMD-based Wind Speed Forecasting system using Bidirectional LSTM networks". *2021 International Conference on Computer Communication and Informatics (ICCCI)*. IEEE.
- Jiang, Z., Che, J., & Wang, L.** (2021). "Ultra-short-term wind speed forecasting based on EMD-VAR model and spatial correlation". *Energy Conversion and Management* 250.
- Joseph, L. P., Deo, R. C., Prasad, R., Salcedo-Sanz, S., Raj, N., & Soar, J.** (2023). "Near real-time wind speed forecast model with bidirectional LSTM networks". *Renewable Energy* 204.
- Karijadi, I., Chou, S.-Y., & Dewabharata, A.** (2023). "Wind power forecasting based on hybrid CEEMDAN-EWT deep learning method". *Renewable Energy* 218.
- Khade, A. R., Damodara, V. D., & Chen, D. H.** (2023). "Reduced Mechanism for Combustion of Ammonia and Natural Gas Mixtures". *Clean Technologies* 5 (2).
- Kořakowski, P., & Rutkowski, G.** (2022). "The analysis of offshore industry transition acceleration from oil & gas to wind". *TransNav, International Journal on Marine Navigation and Safety of Sea Transportation* 16 (2).

- Konakoglu, B.** (2020). “Çok Katmanlı Algılayıcı Yapay Sinir Ağı ile Jeodezik Elipsoidal Koordinatların (φ , λ , h) 3 Boyutlu Global Kartezyen Koordinatlara (X , Y , Z) Dönüşümü”. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi* 10 (3).
- Koohi-Fayegh, S., & Rosen, M. A.** (2020). “A review of renewable energy options, applications, facilitating technologies and recent developments”. *European Journal of Sustainable Development Research* 4 (4).
- Li, J., Wang, G., Li, Z., Yang, S., Chong, W. T., & Xiang, X.** (2020). “A review on development of offshore wind energy conversion system”. *International Journal of Energy Research* 44 (12).
- Li, J., Zhang, S., & Yang, Z.** (2022). “A wind power forecasting method based on optimized decomposition prediction and error correction”. *Electric Power Systems Research* 208.
- Li, N., Dong, J., Liu, L., Li, H., & Yan, J.** (2023). “A novel EMD and causal convolutional network integrated with Transformer for ultra short-term wind power forecasting”. *International Journal of Electrical Power & Energy Systems* 154.
- Li, Q., Wang, G., Wu, X., Gao, Z., & Dan, B.** (2024). “Arctic short-term wind speed forecasting based on CNN-LSTM model with CEEMDAN”. *Energy* 299.
- Li, Y., Sun, K., Yao, Q., & Wang, L.** (2024). “A dual-optimization wind speed forecasting model based on deep learning and improved dung beetle optimization algorithm”. *Energy* 286.
- Liang, T., Chai, C., Sun, H., & Tan, J.** (2022). “Wind speed prediction based on multi-variable Capsnet-BILSTM-MOHHO for WPCCC”. *Energy* 250.
- Lins, D. R., Guedes, K. S., Pitombeira-Neto, A. R., Rocha, P. A. C., & Andrade, C. F. de.** (2023). “Comparison of the performance of different wind speed distribution models applied to onshore and offshore wind speed data in the Northeast Brazil”. *Energy* 278.
- Liu, J., Sun, T., Luo, Y., Yang, S., Cao, Y., & Zhai, J.** (2020). “Echo state network optimization using binary grey wolf algorithm”. *Neurocomputing* 385.
- Liu, X., Zhang, L., Wang, J., Zhou, Y., & Gan, W.** (2023). “A unified multi-step wind speed forecasting framework based on numerical weather prediction grids and wind farm monitoring data”. *Renewable Energy* 211.

- Liu, Z., Li, Y., Yao, J., Cai, Z., Han, G., & Xie, X.** (2021). “Ultra-short-term forecasting method of wind power based on W-BiLSTM”. *2021 IEEE 4th International Electrical and Energy Conference (CIEEC)*. IEEE.
- Lou, E., Song, Y., Geng, Z., & Zhao, Y.** (2023). “Pumped Storage Hydropower: Technological Implementation, Environmental Consideration, and Potential Growth”. *E3S Web of Conferences*, cilt 385. EDP Sciences.
- Ma, K., Zhang, W., Guo, Z., Zhao, J., & Qiu, W.** (2023). “A hybrid forecasting model for very short-term wind speed prediction based on secondary decomposition and deep learning algorithms”. *Earth Science Informatics* 16 (3).
- Maharana, S. M., Mohapatra, A., Saiprakash, C., & Kundu, A.** (2021). “Comparative analysis of different PV array configurations under partial shading conditions”. *2020 3rd International Conference on Energy, Power and Environment: Towards Clean Energy Technologies*. IEEE.
- Maradin, D.** (2021). “Advantages and disadvantages of renewable energy sources utilization”. *International Journal of Energy Economics and Policy* 11 (3).
- Memarzadeh, G., & Keynia, F.** (2020). “A new short-term wind speed forecasting method based on fine-tuned LSTM neural network and optimal input sets”. *Energy Conversion and Management* 213.
- Musial, W. D., Beiter, P. C., Spitsen, P., Nunemaker, J., & Gevorgian, V.** (2019). *2018 offshore wind technologies market report*. Teknik rapor. National Renewable Energy Lab.(NREL), Golden, CO (United States).
- Navia, J. M. A., & Amaya, A. O.** (2023). “Summary of environmental impacts associated with hydroelectric plants in Colombia.” *Revista de Investigación Agraria y Ambiental (RIAA)* 14 (2).
- Nolan, D.** (2019). “Overview of oil, gas, and petrochemical facilities”. *Handbook of Fire and Explosion Protection Engineering Principles for Oil, Gas, Chemical, and Related Facilities*.
- Olabi, A., Wilberforce, T., Elsaid, K., Salameh, T., Sayed, E. T., Husain, K. S., & Abdelkareem, M. A.** (2021). “Selection guidelines for wind energy technologies”. *Energies* 14 (11).
- Olugbenga, F. P.** (2009). “Energy exploitation, utilization, and its environmental effects—the choice to make and the decision to take”. *Toxicological & Environmental Chemistry* 91 (5).

- Painuly, J. P.** (2001). "Barriers to renewable energy penetration; a framework for analysis". *Renewable energy* 24 (1).
- Parri, S., Teeparthi, K., & Kosana, V.** (2024). "A hybrid methodology using VMD and disentangled features for wind speed forecasting". *Energy* 288.
- Peçanha, L. B. C., Oliveira, N. d. S. B., & Bretas, W. V.** (2020). "Generation of Wind Energy with Kites: A Review of the Airborne Wind Energy Technology". *2020 IEEE PES Transmission & Distribution Conference and Exhibition-Latin America (T&D LA)*. IEEE.
- Phan, Q. B., & Nguyen, T. T.** (2024). "Enhancing wind speed forecasting accuracy using a GWO-nested CEEMDAN-CNN-BiLSTM model". *ICT Express* 10 (3).
- Putri, N. K., Bambang, J., & Aritonang, S.** (2022). "Uranium and Thorium potential for Indonesia's Future Energy Security". *International Journal of Education and Social Science Research* 5 (1).
- Ran, M., Huang, J., Qian, W., Zou, T., & Ji, C.** (2023). "EMD-based gray combined forecasting model-Application to long-term forecasting of wind power generation". *Heliyon* 9 (7).
- Rao, K. V. S., Kurbet, S., & Kuppast, V. V.** (2018). "A review on performance of the IC engine using alternative fuels". *Materials Today: Proceedings* 5 (1).
- Rathore, N., Paul, A. S., & Panwar, N.** (2022). "Experimental investigation on the production of bio-oil from maize straw at a pilot scale". *Environmental Engineering Research* 27 (1).
- Regufe, M. J., Pereira, A., Ferreira, A. F., Ribeiro, A. M., & Rodrigues, A. E.** (2021). "Current developments of carbon capture storage and/or utilization-looking for net-zero emissions defined in the Paris agreement". *Energies* 14 (9).
- Rehman, N. u., & Aftab, H.** (2019). "Multivariate Variational Mode Decomposition". *IEEE Transactions on Signal Processing* 67 (23).
- Salvarli, M. S., & Salvarli, H.** (2020). "For sustainable development: Future trends in renewable energy and enabling technologies". *Renewable energy-resources, challenges and applications*. IntechOpen.
- Samadianfard, S., Hashemi, S., Kargar, K., Izadyar, M., Mostafaeipour, A., Mosavi, A., Nabipour, N., & Shamshirband, S.** (2020). "Wind speed prediction using a hybrid model of the multi-layer perceptron and whale optimization algorithm". *Energy Reports* 6.

- Sani, G. D., Ibrahim, A., Sahabi, S., & Lailaba, B. B.** (2019). "Renewable energy: Environmental impacts and economic benefits for sustainable development". *International Journal of Engineering Research* 8 (08).
- Sarp, A. O., Mengüç, E. C., Peker, M., & Güvenç, B. Ç.** (2022). "Data-adaptive censoring for short-term wind speed predictors based on MLP, RNN, and SVM". *IEEE Systems Journal* 16 (3).
- Schulthoff, M., Kaltschmitt, M., Balzer, C., Wilbrand, K., & Pomrehn, M.** (2022). "European road transport policy assessment: a case study for Germany". *Environmental Sciences Europe* 34 (1).
- Schwartz, I. B., Edwards, V., & Hindes, J.** (2021). "Interacting Swarm Sensing and Stabilization". *arXiv preprint arXiv:2106.01824*.
- Seetharaman, K. M., Patwa, N., & Saravanan, Y. G.** (2019). "Breaking barriers in deployment of renewable energy". *Heliyon* 5 (1).
- Shahid, F., Zameer, A., & Muneeb, M.** (2021). "A novel genetic LSTM model for wind power forecast". *Energy* 223.
- Shang, Z., Chen, Y., Chen, Y., Guo, Z., & Yang, Y.** (2023). "Decomposition-based wind speed forecasting model using causal convolutional network and attention mechanism". *Expert Systems with Applications* 223.
- Sharma, H. B., Sarmah, A. K., & Dubey, B.** (2020). "Hydrothermal carbonization of renewable waste biomass for solid biofuel production: A discussion on process mechanism, the influence of process parameters, environmental performance and fuel properties of hydrochar". *Renewable and sustainable energy reviews* 123.
- Shu, H., Song, W., Zhang, J., Song, Z., Xiao, K., & Li, C.** (2022). "A study of MLP-mixer with FFT for short term wind speed forecasting". *5th International Conference on Computer Information Science and Application Technology (CISAT 2022)*, cilt 12451. SPIE.
- Sibtain, M., Bashir, H., Nawaz, M., Hameed, S., Azam, M. I., Li, X., Abbas, T., & Saleem, S.** (2022). "A multivariate ultra-short-term wind speed forecasting model by employing multistage signal decomposition approaches and a deep learning network". *Energy Conversion and Management* 263.

Singh, U. (2023). “The role of hosting capacity study in power system advancements: a review”. *arXiv preprint arXiv:2301.04765*.

Sirmacek, B., Gupta, S., Mallor, F., Azizpour, H., Ban, Y., Eivazi, H., Fang, H., Golzar, F., Leite, I., Melsión, G. I. vd. (2023). “The potential of artificial intelligence for achieving healthy and sustainable societies”. *The ethics of artificial intelligence for the sustainable development goals*. Springer.

Sobolev, V., Holub, N., & Tereshkova, O. (2023). “MAGNETIC STIMULATION OF CHEMICAL REACTIONS IN COAL”. *Natsional'nyi Hirnychyi Universytet. Naukovyi Visnyk*, numara 4.

Soğanlı, A., & Arıkan, O. (2017). “Joint multi-emitter signal separation and angle of arrival estimation via variational mode decomposition”. *2017 25th Signal Processing and Communications Applications Conference (SIU)*. IEEE.

Stadtman, F., Rasheed, A., Kvamsdal, T., Johannessen, K. A., San, O., Kölle, K., Tande, J. O., Barstad, I., Benhamou, A., & Brathaug, T. (2023). “Digital twins in wind energy: Emerging technologies and industry-informed future directions”. *IEEE Access*.

Sun, P., & Li, J. (2020). “Analysis on the restriction of oil use to environmental protection”. *IOP Conference Series: Earth and Environmental Science*, cilt 558. 2. IOP Publishing.

Sun, S., Du, Z., Jin, K., Li, H., & Wang, S. (2023). “Spatiotemporal wind power forecasting approach based on multi-factor extraction method and an indirect strategy”. *Applied Energy* 350.

Sun, W., Tan, B., & Wang, Q. (2021). “Multi-step wind speed forecasting based on secondary decomposition algorithm and optimized back propagation neural network”. *Applied Soft Computing* 113.

Sun, X., & Liu, H. (2024). “Multivariate short-term wind speed prediction based on PSO-VMD-SE-ICEEMDAN two-stage decomposition and Att-S2S”. *Energy*.

Sun, Z., Zhao, M., Dong, Y., Cao, X., & Sun, H. (2021). “Hybrid model with secondary decomposition, randomforest algorithm, clustering analysis and long short memory network principal computing for short-term wind power forecasting on multiple scales”. *Energy* 221.

- Suo, L., Peng, T., Song, S., Zhang, C., Wang, Y., Fu, Y., & Nazir, M. S.** (2023). “Wind speed prediction by a swarm intelligence based deep learning model via signal decomposition and parameter optimization using improved chimp optimization algorithm”. *Energy* 276.
- Şenkal, S., & Emeksiz, C.** (2023). “The Effect of Data Decomposition on Prediction Performance in Wind Speed Prediction with Artificial Neural Network”. *International Scientific and Vocational Studies Journal* 7 (2).
- Takács, J.** (2017). “Possibility of Geothermal Water’s Using in Geothermal Energy Systems”. *Periodica Polytechnica Mechanical Engineering* 61 (4).
- Tefera, E., Martínez-Ballesteros, M., Troncoso, A., & Martínez-Álvarez, F.** (2023). “A New Hybrid CNN-LSTM for Wind Power Forecasting in Ethiopia”. *International Conference on Hybrid Artificial Intelligence Systems*. Springer.
- Tian, Z., Li, H., & Li, F.** (2021). “A combination forecasting model of wind speed based on decomposition”. *Energy Reports* 7.
- Tuerxun, W., Xu, C., Guo, H., Guo, L., Zeng, N., & Cheng, Z.** (2022). “An ultra-short-term wind speed prediction model using LSTM based on modified tuna swarm optimization and successive variational mode decomposition”. *Energy Science & Engineering* 10 (8).
- Uddin, M., Techato, K., Taweekun, J., Rahman, M. M., Rasul, M., Mahlia, T., & Ashrafur, S.** (2018). “An overview of recent developments in biomass pyrolysis technologies”. *Energies* 11 (11).
- Valero, A., Valero, A., Calvo, G., Ortego, A., Ascaso, S., & Palacios, J.-L.** (2018). “Global material requirements for the energy transition. An exergy flow analysis of decarbonisation pathways”. *Energy* 159.
- Verma, S.** (2021). “Analysis of Indian traditional buildings using passive cooling through natural ventilation techniques”. *Int J Res Appl Sci Eng Tech (IJRASET)[online]* 9 (2321-9653).
- Vyas, P., Sharma, S., & Gupta, J.** (2022). “Vermicomposting with microbial amendment: implications for bioremediation of industrial and agricultural waste”. *BioTechnologia* 103 (2).
- Wang, C., Liu, Z., Wei, H., Chen, L., & Zhang, H.** (2021). “Hybrid deep learning model for short-term wind speed forecasting based on time series decomposition and gated recurrent unit”. *Complex System Modeling and Simulation* 1 (4).

Wang, D., Cui, X., & Niu, D. (2022). “Wind power forecasting based on LSTM improved by EMD-PCA-RF”. *Sustainability* 14 (12).

Wang, H., Xiong, M., Chen, H., & Liu, S. (2022). “Multi-step ahead wind speed prediction based on a two-step decomposition technique and prediction model parameter optimization”. *Energy Reports* 8.

Wang, H., & Wang, J. (2021). “Short term wind speed forecasting based on feature extraction by cnn and mlp”. *2021 2nd International Symposium on Computer Engineering and Intelligent Communications (ISCEIC)*. IEEE.

Wang, J., He, M., & Qiu, S. (2023). “Two-stage decomposition multi-scale nonlinear ensemble model with error-correction-coupled Gaussian process for wind speed forecast”. *Atmosphere* 14 (2).

Wang, T. (2021). “A combined model for short-term wind speed forecasting based on empirical mode decomposition, feature selection, support vector regression and cross-validated lasso”. *PeerJ Computer Science* 7.

Wang, X., Li, X., & Su, J. (2023). “Distribution drift-adaptive short-term wind speed forecasting”. *Energy* 273.

Wang, Z., Liu, S., Yang, Z., & Dong, S. (2023). “Perspective on Development of Piezoelectric Micro-Power Generators”. *Nanoenergy Advances* 3 (2).

Wei, J., Wu, X., Yang, T., & Jiao, R. (2023). “Ultra-short-term forecasting of wind power based on multi-task learning and LSTM”. *International Journal of Electrical Power & Energy Systems* 149.

Wibawa, B., Iswara, A., & Boedisantoso, R. (2020). “Impact assessment of coal power plant using life cycle assessment (LCA)”. *IOP Conference Series: Earth and Environmental Science*, cilt 506. 1. IOP Publishing.

Wisnubroto, D., Zamroni, H., Sumarbagiono, R., & Nurliati, G. (2021). “Challenges of implementing the policy and strategy for management of radioactive waste and nuclear spent fuel in Indonesia”. *Nuclear Engineering and Technology* 53 (2).

Woolf, D., Lehmann, J., & Lee, D. R. (2016). “Optimal bioenergy power generation for climate change mitigation with or without carbon sequestration”. *Nature Communications* 7 (1).

- Xiang, L., Li, J., Hu, A., & Zhang, Y.** (2020). “Deterministic and probabilistic multi-step forecasting for short-term wind speed based on secondary decomposition and a deep learning method”. *Energy Conversion and Management* 220.
- Xu, B., & Si, W.** (2018). “Discussion of Several Key Technologies about Offshore Wind Power”. *IOP Conference Series: Earth and Environmental Science*, cilt 153. 2. IOP Publishing.
- Yan, Y., Wang, X., Ren, F., Shao, Z., & Tian, C.** (2022). “Wind speed prediction using a hybrid model of EEMD and LSTM considering seasonal features”. *Energy Reports* 8.
- Yu, M.** (2021). “Assessment on the environmental impact of conventional energy forms”. *IOP Conference Series: Earth and Environmental Science*, cilt 680. 1. IOP Publishing.
- Yuzgec, U., Dokur, E., & Balci, M.** (2024). “A novel hybrid model based on Empirical Mode Decomposition and Echo State Network for wind power forecasting”. *Energy* 300.
- Zelenika, I., Rajič, P., Kovačić, T., & Srpak, M.** (2021). “Hydrogen underground storage as a critical factor in the energy transition period”. *Tehnički vjesnik* 28 (5).
- Zhang, D., Chen, B., Zhu, H., Goh, H. H., Dong, Y., & Wu, T.** (2023). “Short-term wind power prediction based on two-layer decomposition and BiTCN-BiLSTM-attention model”. *Energy* 285.
- Zhang, G., Zhang, Y., Wang, H., Liu, D., Cheng, R., & Yang, D.** (2024). “Short-term wind speed forecasting based on adaptive secondary decomposition and robust temporal convolutional network”. *Energy* 288.
- Zhang, J., Hou, G., Ma, B., & Hua, W.** (2018). “Operating characteristic information extraction of flood discharge structure based on complete ensemble empirical mode decomposition with adaptive noise and permutation entropy”. *Journal of Vibration and Control* 24 (22).
- Zhang, Y.-M., & Wang, H.** (2023). “Multi-head attention-based probabilistic CNN-BiLSTM for day-ahead wind speed forecasting”. *Energy* 278.
- Zhang, S., Chen, Y., Xiao, J., Zhang, W., & Feng, R.** (2021). “Hybrid wind speed forecasting model based on multivariate data secondary decomposition approach and deep learning algorithm with attention mechanism”. *Renewable Energy* 174.

Zhang, Y., Zhang, W., Guo, Z., & Zhang, S. (2022). “An effective wind speed prediction model combining secondary decomposition and regularised extreme learning machine optimised by cuckoo search algorithm”. *Wind Energy* 25 (8).

Zheng, K., Qian, B., Li, S., Xiao, Y., Zhuang, W., & Ma, Q. (2020). “Long-short term echo state network for time series prediction”. *IEEE Access* 8.

Zsiborács, H., Vincze, A., Pintér, G., & Baranyai, N. H. (2024). “The potentials of thermal energy storage using domestic electric water heater technology with PV systems in the EU countries”. *MRS Energy & Sustainability* 11 (1).

Zwane, N., Tazvinga, H., Botai, C., Murambadoro, M., Botai, J., De Wit, J., Mabasa, B., Daniel, S., & Mabhaudhi, T. (2022). “A bibliometric analysis of solar energy forecasting studies in Africa”. *Energies* 15 (15).