-

MARMARA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

GÜN ÖNCESİ ELEKTRİK PİYASASI İÇİN KISA DÖNEMLİ RÜZGAR GÜCÜ ÜRETİM TAHMİN YÖNTEMİ

EZGİ ARSLAN TUNCAR

DOKTORA TEZİ Elektrik Elektronik Mühendisliği Programı (Türkçe)

DANIŞMAN

Prof. Dr. Şafak SAĞLAM

EŞ-DANIŞMAN

Prof. Dr. Bülent ORAL

İSTANBUL, 2024

MARMARA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Marmara Üniversitesi Fen Bilimleri Enstitüsü Doktora Öğrencisi Ezgi ARSLAN TUNCAR'ın "Gün Öncesi Elektrik Piyasası İçin Kısa Dönemli Rüzgar Gücü Üretim Tahmin Yöntemi" başlıklı tez çalışması, ... 2024 tarihinde savunulmuş ve jüri üyeleri tarafından başarılı bulunmuştur.

Jüri Üyeleri

Prof.Dr. Şafak SAĞLAM (Danışman)

Marmara Üniversitesi ..... (İMZA).....

Doç.Dr. Adı SOYADI (Üye)

Marmara Üniversitesi ..... (İMZA).....

Dr. Öğr. Üyesi Adı SOYADI (Üye)

Marmara Üniversitesi ..... (İMZA).....

Doç.Dr. Adı SOYADI (Üye)

Marmara Üniversitesi ..... (İMZA).....

Dr. Öğr. Üyesi Adı SOYADI (Üye)

Marmara Üniversitesi ..... (İMZA).....

ONAY

Marmara Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ..... tarih ve ..... sayılı kararı ile Ezgi ARSLAN TUNCAR'ın Elektrik Elektronik Mühendisiliği (Türkçe) Programından Doktora derecesi alması onanmıştır.

Fen Bilimleri Enstitüsü Müdürü Prof. Dr. Adı SOYADI

TEŞEKKÜR

Bu tezin hazırlanmasında bana yol gösteren, bilgi ve deneyimlerini paylaşarak her aşamada destek olan danışmanlarım Prof. Dr. Şafak Sağlam ve Prof. Dr. Bülent Oral'a en derin teşekkürlerimi sunarım. Onların rehberliği ve sabrı, hayattaki önceliklere verdikleri değer bana örnek olmuştur ve bu çalışmayı başarıyla tamamlamamda büyük rol oynamıştır.

Ayrıca, bu uzun ve yorucu süreç boyunca yanımda olan, sevgi ve desteklerini hiç esirgemeyen sevgili aileme teşekkür ederim. Her şey onlarla güzel ve değerli. Geniş ailem Okumuş ailesine de yanımda oldukları için teşekkür ederim. Sevgili eşim Cüneyt'e, her şartta ve her yerde bana destek olduğu, hayatıma kattıkları ve hep yanımda olduğu için minnettarım.

Cumhuriyetimizin kurucusu Gazi Mustafa Kemal Atatürk'e ise, bir kadın olarak bu unvanı almamda ve bilime katkı sunmamda bana tanıdığı fırsatlar ve verdiği ilham için şükranlarımı sunarım.

İÇİNDEKİLER

TEŞEKKÜR ..... **i**
İÇİNDEKİLER ..... **ii**
ÖZET ..... **iv**
ABSTRACT ..... **v**
YENİLİK BEYANI ..... **vi**
SEMBOLLER ..... **vii**
KISALTMALAR ..... **viii**
ŞEKİL LİSTESİ ..... **xi**
TABLO LİSTESİ ..... **xii**
1. GİRİŞ **1**
1.1. Tezin Amacı 1
1.2. Çalışmanın Önemi 4
1.3. Kapsam 7
2. TEORİK BİLGİ VE LİTERATÜR TARAMASI **9**
2.1. Rüzgar Enerjisi ve Tahmin Yöntemlerine Genel Bakış 9
2.1.1. Rüzgar Enerjisi 9
2.1.2. Rüzgar enerjisinin avantaj ve dezavantajları 10
2.1.3. Türkiye ve dünyada rüzgar enerjisi potansiyeli 10
2.2. Rüzgar Enerjisi Tahmin Yöntemleri 16
2.2.1. Tahmin Yöntemlerinin Sınıflandırılması 18
2.3. Rüzgar Enerjisi Tahminindeki Zorluklar ve Avantajlar 35
2.4. Literatürdeki Boşluklar 36
2.5. Elektrik Piyasaları 37
3. MATERYAL VE YÖNTEM **40**
3.1. Araştırma Tasarımı 40
3.2. Çalışma Alanının Tanımı 42
3.3. Veri Toplama 46
3.3.1. Veri kaynakları 47
3.3.2. Veri tanımı 48
3.4. Veri Ön İşleme 49
3.4.1. Veri temizliği ve eksik değerlerin işlenmesi 49
3.4.2. Aykırı değer tespiti ve kaldırılması 50

3.4.3. Veri birleştirme ve ilişkilendirme 51
3.5. Model Geliştirme 51
3.5.1. Rastgele orman modeli 53
3.5.2. Destek vektör makinesi modeli 55
3.5.3. Hibrit model 57
3.6. Model Değerlendirme Metrikleri 59
4. BULGULAR VE TARTIŞMA 61
4.1. Rastgele Orman Modelinin Değerlendirilmesi 61
4.1.1. Model performansı 61
4.1.2. Tartışma 63
4.2. Destek Vektör Makinesi Modelinin Değerlendirilmesi 64
4.2.1. Model performansı 64
4.2.2. Tartışma 67
4.3. Hibrit Modelinin Değerlendirilmesi 68
4.3.1. Model performansı 68
4.3.2. Tartışma 68
4.5. Karşılaştırmalı Analiz 74
4.6. İçgörüler ve Etkiler 76
4.7. Model Geliştirme Sürecinde Karşılaşılan Zorluklar 76
4.8. Uygulama Perspektifleri ve Endüstriyel Uyumluluk 77
5. SONUÇLAR 81
KAYNAKÇA 86
ÖZGEÇMİŞ 95

ÖZET

GÜN ÖNCESİ ELEKTRİK PİYASASI İÇİN KISA DÖNEMLİ RÜZGAR GÜCÜ ÜRETİM TAHMİN YÖNTEMİ

Bu çalışmada, rüzgar enerjisinden elektrik üretim tahminlerinin doğruluğunu artırmak amacıyla hibrit bir makine öğrenimi modelinin geliştirilmesi ve değerlendirilmesi hedeflenmektedir. Çalışmada, mevcut yöntemler farklı parametreler ve özellik mühendislikleri ile kullanılarak yeni bir hibrit model oluşturulmaktadır. Bu hibrit yaklaşım, tahmin doğruluğunu artırmayı sağlamaktadır. Araştırma, rüzgar enerjisi üretim verilerinin toplanması ve analiz edilmesi ile kapsamlı veri setlerinin oluşturulması süreciyle başlamaktadır. Metodoloji bölümü veri toplama, ön işleme, model geliştirme ve model değerlendirme aşamalarından oluşmaktadır. İlk olarak rüzgar hızı, yönü, sıcaklık ve basınç gibi parametrelerden oluşan veri setleri toplanmaktadır. Ön işleme aşamasında, veriler temizlenerek modellemeye uygun hale getirilmektedir. Rastgele Orman (RF), Destek Vektör Makineleri (SVM) ve Yapay Sinir Ağları (ANN) kullanılarak bireysel modeller geliştirilmektedir. Bu modeller, hibrit bir modele entegre edilerek güçlü yönlerinden faydalanılmaktadır. Hibrit modelin performansı, Ortalama Mutlak Hata (MAE), Ortalama Karesel Hata (MSE) ve Belirleme Katsayısı (R^2) gibi istatistiksel ölçütlerle değerlendirilmektedir. Çalışma, mevcut yöntemlere yenilikçi bir katkı sunmakta ve hibrit modelin tahmin doğruluğunu artırma potansiyelini ortaya koymaktadır. Bu yeni yaklaşım, yenilenebilir enerji kaynaklarının yönetimi ve planlanmasında önemli bir potansiyel taşımaktadır.

ABSTRACT

SHORT-TERM WIND POWER GENERATION FORECASTING METHOD FOR DAY-AHEAD ELECTRICITY MARKET

This study aims to improve the accuracy of wind power generation forecasts through the development and evaluation of a hybrid machine learning model. The study develops a new hybrid model by using different parameters and feature engineering of existing methods. This hybrid approach is designed to enhance forecast accuracy. The research begins with the collection and analysis of wind energy production data to create comprehensive datasets. The methodology consists of four stages: data collection, preprocessing, model development, and model evaluation. Initially, datasets containing parameters such as wind speed, direction, temperature, and pressure are collected. In the preprocessing stage, the data are cleaned and prepared for modeling. Random Forest (RF), Support Vector Machines (SVM), and Artificial Neural Networks (ANN) are used to develop individual models. These models are then integrated into a hybrid model to leverage their strengths. The performance of the hybrid model is evaluated using statistical metrics such as Mean Absolute Error (MAE), Mean Squared Error (MSE), and the coefficient of determination (R^2). The study offers an innovative contribution to existing methods and demonstrates the potential of the hybrid model in improving forecast accuracy. This new approach holds significant potential for improving the management and planning of renewable energy resources.

YENİLİK BEYANI

GÜN ÖNCESİ ELEKTRİK PİYASASI İÇİN KISA DÖNEMLİ RÜZGAR GÜCÜ ÜRETİM TAHMİN YÖNTEMİ

Bu çalışmada, kısa dönemli rüzgar gücü tahmininde doğruluğu artırmak amacıyla literatürde mevcut makine öğrenmesi yöntemlerine dayalı yenilikçi bir yaklaşım sunulmaktadır. Temel yenilik, farklı makine öğrenmesi modellerini bir araya getirerek hibrit bir model geliştirilmesi ve bu sayede tahmin doğruluğunun artırılmasıdır. Rastgele Orman (RF) ve Destek Vektör Makineleri (SVM) kullanılarak elde edilen çıktılar, Yapay Sinir Ağı (ANN) modeli ile birleştirilerek daha sağlam ve esnek bir tahmin yöntemi oluşturulmuştur. Bu model, rüzgar enerjisinden elektrik üretimi için kısa dönemli tahminlerde kullanılmakta olup, bu zaman diliminde uygunluğu ve etkinliği kanıtlanmıştır.

Bu çalışma, meteorolojik tahmin verilerini kullanarak rüzgar gücü üretimini öngörmekte ve bu veriler üzerinden tahmin doğruluğunu artırmaktadır. Özellik mühendisliği ile elde edilen değişkenlerin modele entegrasyonu, tahmin başarımını yükseltmiş ve mevcut literatürdeki yöntemlerin ötesine geçilmiştir. Rüzgar enerjisi gibi değişken ve öngörülmesi zor yenilenebilir enerji kaynaklarının kısa vadeli tahminlerinde yüksek doğruluk, enerji arz ve talep dengesinin sağlanmasına, dolayısıyla piyasa istikrarına katkı sunmaktadır.

Ayrıca, bu çalışmada Python programlama dili kullanılarak çeşitli optimizasyonlar yapılmıştır. Python'un geniş makine öğrenmesi kütüphanelerine sahip olması, model geliştirme ve optimizasyon süreçlerini kolaylaştırmış ve yeni bir verimli hibrit modelin geliştirilmesine olanak tanımıştır. Bu avantajlar, modelin doğruluğunu artırmak için gereken parametre ayarlamalarının etkili bir şekilde yapılmasını sağlamış ve kısa dönemli tahminlerde yüksek performans elde edilmesini mümkün kılmıştır.

Sonuç olarak, bu tez, rüzgar gücü tahmininde kullanılan mevcut yöntemlerin performansını artırmak amacıyla yeni bir hibrit model geliştirmekte, kısa dönemli tahmin doğruluğunu optimize etmekte ve enerji piyasaları için güvenilir bir tahmin aracı sunarak, literatüre ve elektrik piyasasına önemli bir katkı sağlamaktadır.

SEMBOLLER

kW : Kilowatt

m : Metre

m/s : Hız

MW : Megawatt

MWh: Megawatt Saat

$\mathbf{R^2}$: Belirleme Katsayısı

TWh : Terawatt Saat

KISALTMALAR

AE Oto-Kodlayıcı (Auto-Encoder)

AI Yapay Zeka (Artificial Intelligence)

AMC Dikkate Dayalı Çok Bileşenli (Attention-Based Multi-Component)

ANFIS Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (Adaptive Network Based Fuzzy Inference System)

ANN Yapay Sinir Ağları (Artificial Neural Networks)

AR Otoregresif (Auto Regressive)

ARCH Otoregresif Koşullu Heteroskedastisite (Autoregressive Conditional Heteroscedasticity)

ARIMA Otoregresif Entegre Hareketli Ortalama (Auto-Regressive Integrated Moving Average)

ARMA Otoregresif Hareketli Ortalama (Auto-Regressive Moving Average)

BP Geri Yayılım (Back Propagation)

CEEMDAN Adaptif Gürültü ile Tam Topluluk Deneysel Mod Ayrıştırma (Complete Ensemble Empirical Mode Decomposition With Adaptive Noise)

CNN Evrişimli Sinir Ağı (Convolutional Neural Network)

ConvLSTM Evrişimli Uzun Kısa Süreli Bellek Ağı (Convolutional Long Short Memory Network)

DBN Derin İnanç Ağı (Deep Belief Network)

DL Derin Öğrenme (Deep Learning)

DWT Ayrık Dalga Dönüşümü (Discrete Wavelet Transform)

ELM Aşırı Öğrenme Makinesi (Extreme Learning Machine)

ENCSA Geliştirilmiş Karga Arama Algoritması (Enhanced Crow Search Algorithm)

EXMS Deneysel Adımlar (Experimental Steps)

FWNN Bulanık Dalgalet Sinir Ağı (Fuzzy Wavelet Neural Network)

GA Genetik Algoritma (Genetic Algorithm)

GMM Gauss Karışım Modeli (Gaussian Mixture Model)

GPR Gauss Süreci Regresyonu (Gaussian Process Regression)

GRU Kapılı Yinelemeli Birim (Gated Recurrent Unit)

HKLSSVM Hibrit-Çekirdek En Küçük Kareler Destek Vektör Makinesi (Hybrid-Kernel Least-Squares Support Vector Machine)

IOWA İndüklenmiş Sıralı Ağırlıklı Ortalama (Induced Ordered Weighted Average)

IVMD İyileştirilmiş Varyasyonel Mod Ayrıştırma (Improved Variational Mode Decomposition)

LSSVM En Küçük Kareler Destek Vektör Makinesi (Least Squares Support Vector Machine)

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

MA Hareketli Ortalama (Moving Average)

MAE Ortalama Mutlak Hata (Mean Absolute Error)

MAPE Ortalama Mutlak Yüzde Hatası (Mean Absolute Percentage Error)

MKRPINN Çok Çekirdekli Sırt Pseudo Ters Sinir Ağı (Multi Kernel Ridge Pseudo Inverse Neural Network)

MLP Çok Katmanlı Algılayıcı (Multi-Layer Perceptron)

MMMD Çok Ölçekli Matematiksel Morfolojik Ayrıştırma (Multiscale Mathematical Morphological Decomposition)

MSE Ortalama Kare Hata (Mean Square Error)

MWNN Morlet Dalgalet Sinir Ağı (Morlet Wavelet Neural Network)

NLP Doğal Dil İşleme (Natural Language Processing)

NN Sinir Ağı (Neural Network)

NSGA Hakim Olmayan Sıralama Genetik Algoritması (Non-Dominated Sorting Genetic Algorithm)

NWP Sayısal Hava Tahmini (Numerical Weather Prediction)

PCC Pearson Korelasyon Katsayısı (Pearson's Correlation Coefficient)

PSAF Parametrik Sinüs Aktivasyon Fonksiyonu (Parametric Sine Activation Function)

PSO Parçacık Sürü Optimizasyonu (Particle Swarm Optimization)

PSR Faz Uzayı Yeniden Yapılandırma (Phase Space Reconstruction)

RBF Radyal Taban Fonksiyonu (Radial Basis Function)

RF Rastgele Orman (Random Forest)

RMSE Kök Ortalama Kare Hata (Root Mean Square Error)

RNN Yinelemeli Sinir Ağı (Recurrent Neural Network)

RWT Tekrarlanan Dalgalet Dönüşümü (Repeated Wavelet Transform)

SARIMA Mevsimsel Otoregresif Entegre Hareketli Ortalama (Seasonal Autoregressive Integrated Moving Average)

SE Örnek Entropi (Sample Entropy)

SMLDAE Yığılmış Çok Seviyeli-Gürültü Azaltma Oto-Kodlayıcı (Stacked Multilevel-Denoising Autoencoder)

SOM Kendiliğinden Organize Harita (Self-Organizing Map)

SRNN Yığılmış Yinelemeli Sinir Ağı (Stacked Recurrent Neural Network)

SVM Destek Vektör Makinesi (Support Vector Machine)

SWD Sürü Ayrıştırma (Swarm Decomposition)

TOB Şeffaf Açık Kutu (Transparent Open Box)

TSA Zaman Serisi Analizi (Time Series Analysis)

VAPWCA Buharlaşma ve Yağışa Dayalı Su Döngüsü Algoritması (Vaporization And Precipitation Based Water Cycle Algorithm)

VAR Vektör Otoregresif (Vector Autoregressive)

VARTA Her Şeye Vektör-Otoregresif (Vector-Autoregressive-To-Anything)

VMD Varyasyonel Mod Ayrıştırma (Variational Mode Decomposition)

WDLSSVM Dalgalet Ayrıştırma En Küçük Kareler Destek Vektör Makinesi (Wavelet-Decomposition Least-Squares Support Vector Machine)

WPE Ağırlıklı Permütasyon Entropisi (Weighted Permutation Entropy)

WSCFS Rüzgar Hızı Kombine Tahmin Sistemi (Wind Speed Combined Forecasting System)

WT Dalgalet Dönüşümü (Wavelet Transform)

ŞEKİL LİSTESİ

Şekil 2.1: Türkiye 100m Yükseklikte Yıllık Ortalama Rüzgar Hızı Dağılımı. 15
Şekil 2.2: Rüzgar Enerjisi Tahmin Yöntemlerinin Süreç Çizelgesi 17
Şekil 2.3: Rüzgar Tahmini Yöntemlerinin Zaman Ölçeği Sınıflandırması 19
Şekil2.4: Tahmin Yöntemlerinin Sınıflandırılması 20
Şekil 2.5: Elektrik Piyasalarının Sınıflandırılması 38
Şekil 3.1: İş Akışı 41
Şekil 3.2: Nordex-N117 2,4 MW Türbin Genel Bakış Çizimi 44
Şekil 3.3: Sancak Enerji Yahyalı Rüzgar Enerji Santrali Konumu 47
Şekil 3.4: Veri Setinden Örnek Değerler 48
Şekil 3.5: Akış Diyagramının Metodolojisi 52
Şekil 3.6: Çalışmada kullanılan ANN Yapısı 58
Şekil 4.1: RF İçin MAE Değerleri 62
Şekil 4.2: RF İçin MSE Değerleri 62
Şekil 4.3: RF İçin R^2 Değerleri 63
Şekil 4.4: SVM İçin MAE Değerleri 65
Şekil 4.5: SVM İçin MSE Değerleri 66
Şekil 4.6: SVM İçin R^2 Değerleri 66
Şekil 4.7: ANN İçin MAE Değerleri 70
Şekil 4.8: ANN İçin MSE Değerleri 71
Şekil 4.9: ANN İçin R^2 Değerleri 71
Şekil 4.10: %40 Eğitim Verisi İçin R^2 Değerleri 72
Şekil 4.11: %60 eğitim verisi için R^2 değerleri 73
Şekil 4.12: GFS ve ECMWF verilerine göre enerji üretim tahminleri arasındaki farklar. 80

TABLO LİSTESİ

Tablo 2.1: Türkiye'de 2023 Yılında Aylara Göre Rüzgar Gücü Üretimi Ve Toplam Üretimdeki Payı.....13
Tablo 2.2: Türkiye'nin Yıllara Göre Rüzgar Enerjisi Kurulu Gücü.....14
Tablo 2.3: Rüzgar Enerjisi Kurulu Gücünün Bölgelere Göre Dağılımı.....16
Tablo 4.4: Modellerin Hata Metrik Değerleri.....74
Tablo 4.5: Kullanılan Tahmin Yöntemlerinin Özellikleri.....75
Tablo 4.6: GFS ve ECMWF Verilerine Göre Rüzgar Hızı ve Sıcaklık Değerleri.....79

1. GİRİŞ

1.1. Tezin Amacı

21. yüzyılın ikinci çeyreğine yaklaşırken, çevresel bilincin artması, küresel ısınma ve iklim değişikliği etkilerinin belirginleşmesi, artan enerji tüketimi ve teknolojik gelişmelerin ışığında, temiz ve yenilenebilir enerji kaynaklarının kullanımı giderek daha fazla önem kazanmaktadır. Küresel elektrik enerjisi talebi sürekli bir artış trendi göstermektedir ve bu büyüyen ihtiyacı karşılamak için sürdürülebilir ve çevre dostu bir alternatif olan rüzgar enerjisinden elektrik enerjisi üretimi, kritik bir öneme sahiptir. Rüzgar enerjisinden elde edilen elektrik enerjisinin şebekelere etkin şekilde entegre edilebilmesi, bu yöntemle yapılan elektriksel güç üretimi tahminlerinin doğruluğunu zorunlu kılmaktadır. Özellikle, gün öncesi elektrik piyasalarında güvenilir kısa dönemli rüzgar enerjisinden elektrik üretimi tahminleri, bu enerji kaynağının etkin entegrasyonu için temel bir faktör haline gelmektedir. Rüzgar enerjisinden elektrik üretiminin artmasıyla birlikte, bu değişken enerji kaynağının en verimli şekilde yönetilebilmesi için doğruluğu ve güvenilirliği yüksek tahminler zorunlu hale gelmiştir.

Bu doktora tezinin esas amacı, rüzgar enerjisinden elektrik üretimi tahminleriyle ilişkili güncel problemleri detaylı bir şekilde tanımlamak, bu problemlerin enerji sektöründeki etkilerini derinlemesine analiz etmek ve bilimsel ve pratik katkılar sunacak çözüm yolları geliştirmektir. Rüzgar enerjisinin verimli kullanımı, ekonomik ve çevresel sürdürülebilirliğin yanı sıra, küresel enerji arz güvenliği açısından da büyük önem taşımaktadır. Ancak, rüzgarın doğasında bulunan değişkenlik, bu yenilenebilir enerji kaynağından elektrik enerjisi üretimi tahminlerini karmaşık bir hale getirmektedir. Rüzgar hızındaki küçük bir değişiklik bile elektrik enerjisi üretimi değerlerinde önemli ölçüde sapmalara yol açabilmektedir ve bu durum enerji üreticileri ile tüketicileri için belirsizlikler yaratmakta, ekonomik etkilere yol açmakta ve enerji arz güvenliği riskleri oluşturmaktadır.

Bu tez, mevcut yöntemlerin ötesine geçerek, hibrit makine öğrenimi tekniklerini kullanarak bu belirsizlikleri minimize etmeyi ve tahmin doğruluğunu önemli ölçüde artırmayı amaçlamaktadır. Rastgele Orman (Random Forest - RF), Destek Vektör Makineleri (Support

Vector Machine - SVM) ve Yapay Sinir Ağları (Artificial Neural Networks - ANN) modellerinin entegre edildiği bu yenilikçi yaklaşım, rüzgar enerjisi tahminlerindeki zorlukların üstesinden gelmek için yeni bir çözüm sunmaktadır.

Elektrik piyasalarının işleyişi, enerji arzının güvenilir ve tahmin edilebilir olmasına bağlıdır ve bu durum piyasa istikrarı ile fiyat dalgalanmalarını doğrudan etkilemektedir. Rüzgar enerjisinden elektrik üretimi tahminlerindeki doğruluk, gün öncesi ve gerçek zamanlı elektrik piyasalarının verimli şekilde işlemesi için hayati bir öneme sahiptir. Gün öncesi piyasalarda, enerji üreticileri ve tüketicileri, ertesi gün için enerji alım-satımı yapmaktadır ve bu işlemler, rüzgar enerjisinden elektrik üretimi yapan tesislerin tahmin doğruluğuna büyük ölçüde bağlıdır. Rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğu, enerji fiyatlarının istikrarını doğrudan etkileyebilmekte ve piyasadaki dalgalanmaları azaltabilmektedir. Doğru tahminler, enerji üretimi ile tüketimi arasındaki dengenin korunmasına ve böylece şebekenin kararlılığına da katkıda bulunmaktadır.

Bu tez, rüzgar enerjisinden elektrik üretimi tahminlerinin rolünü ele almakta ve kısa dönemli rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğunu ve güvenilirliğini artırmayı hedefleyen yenilikçi stratejilerin geliştirilmesine odaklanmaktadır. Önerilen yöntem ile rüzgar enerjisinden elektrik üretimi tahminlerindeki doğruluğun iyileştirilmesinin, piyasa verimliliğine, şebeke yönetimine ve genel olarak enerji sektörüne etkisi değerlendirilmektedir. Bu çalışma, rüzgar enerjisinden elektrik üretimi tahmin süreçlerinde karşılaşılan zorlukları, veri kalitesinin etkisini, tahmin modelleme yöntemlerini ve çevresel değişikliklerin etkilerini detaylı bir şekilde incelemekte ve potansiyel iyileştirme yolları önermektedir.

Bu çalışma, özellikle gün öncesi elektrik piyasaları için kısa dönemli rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluk ve güvenilirliğini artırmaya yönelik stratejilere odaklanmaktadır. Yenilenebilir enerjiyi güç sistemlerine dahil etmek, tahmin edilemez doğaları nedeniyle özellikle şebeke işletme zorluklarını beraberinde getirmektedir[1], [2]. Yenilenebilir enerjinin değişken doğası ve iklim değişikliğinin etkileri, enerji sistemlerinin istikrarını riske atmaktadır. Bu durum, söz konusu riskleri azaltmak için yenilikçi çözümlerin

bulunmasını zorunlu kılmaktadır[3]. Bu çözümlerden biri, belirsizliği en aza indirmek için rüzgar enerjisi üretimi tahminlerinin hassasiyetini artırmaktır[4].

Mevcut literatür ve teknolojik ilerlemeler, bu alandaki gelişmeleri, makine öğrenimi ve yapay zeka gibi yeni metodolojilerin taşıdığı büyük potansiyeli gözler önüne sermektedir ancak literatürde önemli boşluklar bulunmaktadır. Bu çalışma, bu boşlukları doldurmayı hedeflemekte, rüzgar enerjisinden elektrik üretimi tahminlerini iyileştirmede hibrit makine öğrenimi modellerinin etkinliğini ve bu modellerin uygulanabilirliğini değerlendirmektedir. İleri tahmin modelleri, enerji üretiminin daha verimli planlanmasını ve optimizasyonunu, enerji kaynaklarının daha etkin kullanımını ve yenilenebilir enerjinin payının üretimde artırılmasını sağlama potansiyeline sahiptir. Bu kapsamda, rüzgar enerjisinden elektrik üretimi tahmin yöntemleri konusuna odaklanarak yenilenebilir enerji alanındaki literatüre önemli bir katkı sağlamayı hedeflemektedir.

Bu çalışma, rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğunu artırma çabalarında karşılaşılan zorluklara da detaylı bir inceleme sunmaktadır. Rüzgar enerjisinden elektrik üretiminin doğasından kaynaklanan belirsizlik, güvenilir üretim tahminlerinin elde edilmesini zorlaştıran bir etkendir. Bu belirsizlik, enerji şebekelerinde dengesizliklere yol açabilir ve enerji planlaması ile yönetim süreçlerinde verimsizliklere neden olabilmektedir. Mevcut geleneksel tahmin yöntemleri, özellikle kısa vadeli tahminlerde, bu belirsiz değişimi etkin bir şekilde modellemede genellikle yetersiz kalmaktadır. Bu tez, rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğunun iyileştirilmesinin gerekliliğini vurgulamakta ve ileri makine öğrenimi tekniklerinin söz konusu alanda uygulanabilirliğini ve potansiyelini derinlemesine araştırmayı amaçlamaktadır. İleri makine öğrenimi tekniklerinin kullanımı, enerji şebekelerinin kararlılığını artırmak ve yönetim süreçlerini iyileştirmek açısından büyük faydalar sağlamaktadır. Bu yaklaşım, rüzgar enerjisinden elektrik üretimi tahminleri alanında yeni bir dönemin başlangıcını işaret edebilir.

Bu çalışmanın esas gayesi, rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğunu ve güvenilirliğini artırmaya odaklanmaktır. Bu genel amaç doğrultusunda, çalışma aşağıdaki özel hedefleri barındırmaktadır:

1. Rüzgar enerjisinden elektrik üretimi tahminlerinde kullanılan mevcut yöntem ve teknolojilerin derinlemesine bir incelemesini yapmak ve bu sayede mevcut yaklaşımların güçlü ve zayıf yönlerini belirlemek.

2. Hibrit makine öğrenimi modellerinin, rüzgar enerjisinden elektrik üretimi tahmin yöntemlerinin performansı üzerindeki etkisini detaylı bir şekilde analiz etmek ve bu modellerin etkinliğini ve avantajlarını ortaya koymak.

3. Rüzgar enerjisinden elektrik üretimi tahmin yöntemlerinin doğruluğunu ve güvenilirliğini artıracak yeni yaklaşımlar ve teknikler geliştirmek ve bu sayede tahmin doğruluğunu iyileştirmek.

4. Geliştirilen modellerin ve tekniklerin uygulanabilirliğini ve etkinliğini değerlendirerek rüzgar enerjisinden elektrik üretimi tahmin süreçlerine fayda sağlamak ve bu yaklaşımların pratikteki değerini göstermek.

5. Gün öncesi elektrik piyasası için mevcut rüzgar enerjisinden elektrik üretimi tahmin modellerinin doğruluğunu ve sınırlılıklarını belirlemek, bu modellerin performansını değerlendirmek ve iyileştirme fırsatlarını belirlemek.

6. Hibrit makine öğrenimi modellerinin, gün öncesi piyasada kısa dönemli rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğunu ve güvenilirliğini artırmaya yönelik adımları tartışmak ve bu modellerin enerji piyasalarındaki uygulamalarını değerlendirmek.

Bu hedefler doğrultusunda, çalışma yenilenebilir enerji yönetimi ve şebeke planlamasında önemli iyileştirmeler sunmayı amaçlamaktadır.

1.2. Çalışmanın Önemi

Bu çalışma, rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğunu artırma amacı taşıyarak yenilenebilir enerji alanında önemli bir katkı sunmayı hedeflemektedir. Doğru tahminler, enerji üretimi ile tüketimi arasındaki dengesizlikleri en aza indirerek enerji verimliliğini artırmaktadır, enerji kaynaklarının daha etkin kullanılmasını sağlayarak hem ekonomik hem de çevresel faydalar sağlamaktadır. Ayrıca doğru tahminler sayesinde rüzgar enerjisinden elektrik enerjisinin elektrik şebekelerine entegrasyonu kolaylaşmakta, bu durum

enerji arz güvenliğini artırmakta ve fosil yakıtların kullanımını azaltmaktadır. Bu çalışma, gün öncesi elektrik piyasalarındaki fiyat dalgalanmalarını azaltmaya yardımcı olmak amacıyla daha güvenilir tahmin modellerinin geliştirilmesine katkı sağlayarak enerji üreticileri, tüketiciler ve politika yapıcılar için önemli faydalar sunmayı amaçlamaktadır. Güvenilir tahmin modelleri, enerji piyasalarının daha istikrarlı ve öngörülebilir olmasını sağlamaktadır ve bu da yatırımcıların ve tüketicilerin karar alma süreçlerini olumlu etkilemektedir. Enerji politikaları, daha güvenilir tahminler sayesinde daha sağlam temellere oturtulabilmekte ve yenilenebilir enerjiye geçiş süreci hızlanabilmektedir. Bu bağlamda, araştırmanın bulguları, rüzgar enerjisinden elektrik üretimi tahmin yöntemlerinde yenilikçi yaklaşımlar sunarak yenilenebilir enerji sektörünün sürdürülebilirliğine ve büyümesine katkıda bulunacaktır. Bu çalışma, mevcut tahmin modellerinin performansını değerlendirmekle kalmayıp, hibrit makine öğrenimi modellerinin bu alandaki potansiyelini de ortaya koyacaktır. Elde edilen sonuçlar, yenilenebilir enerji kaynaklarının daha etkin bir şekilde yönetilmesine ve enerji arz güvenliğinin artırılmasına yönelik önemli bilgiler sağlayacaktır.

Bu araştırma, enerji piyasaları ve politika yapım süreçlerine de önemli katkılarda bulunma potansiyeline sahiptir. Enerji piyasalarının daha öngörülebilir ve istikrarlı hale gelmesi, enerji üreticileri ve tüketiciler için ekonomik faydalar sağlamanın yanı sıra enerji arz güvenliğini de artırmaktadır. Doğru ve güvenilir tahmin modelleri, enerji fiyatlarındaki dalgalanmaları minimize etmekte ve piyasa katılımcılarının risklerini azaltmaktadır. Bu durum, yatırımcıların yenilenebilir enerji projelerine daha fazla güven duymasını sağlamakta ve sektördeki yatırımların artmasına yol açmaktadır. Rüzgar enerjisinden elektrik üretimi tahminlerindeki iyileşme, enerji piyasalarında fiyat istikrarını sağlamaya ve risk yönetimine katkı sağlamaya yardımcı olabilmektedir. Bu durumda hem enerji üreticileri hem de tüketiciler için ekonomik faydalar sağlanması beklenmektedir. Ayrıca politika yapımında daha yüksek doğrulukla yapılan enerji tahminleri, yenilenebilir enerji kaynaklarının payının artırılmasına ve şebeke entegrasyonunu destekleyen stratejilerin geliştirilmesine olanak sağlamaktadır. Doğru tahminler, enerji politikalarının daha gerçekçi ve uygulanabilir olmasını sağlamaktadır. Bu sayede enerji arz ve talep dengesinin daha etkin bir şekilde

yönetilmesi mümkün hale gelmektedir. Ayrıca enerji güvenliği politikalarının oluşturulmasında ve iklim değişikliği ile mücadelede kritik bir rol oynamaktadır. Bu, sürdürülebilir enerji sistemlerine geçişte önemli bir rol oynamakta ve politika yapıcıların karar alma süreçlerinde bilgiye dayalı, verimli stratejiler oluşturmasına imkan vermektedir. Bu bağlamda, çalışmanın bulguları, enerji sektöründe karşılaşılan mevcut zorlukların üstesinden gelmek ve yenilenebilir enerji kaynaklarının potansiyelinden tam olarak yararlanmak adına önemli bir adım teşkil edebilir.

Bu çalışma, aşağıdaki araştırma sorularını veya hipotezleri ele almayı amaçlamaktadır. Bu sorular ve hipotezler, rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğunu ve güvenilirliğini artırmaya yönelik stratejilerin geliştirilmesi sürecinde kilit rol oynamaktadır:

1. Mevcut rüzgar enerjisinden elektrik üretimi tahmin yöntemlerinin doğruluğu ve sınırlılıkları üzerinde hangi faktörler etkilidir?

2. Hibrit makine öğrenimi modelleri, rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğunu ve güvenilirliğini nasıl artırabilir?

3. RF, SVM, ANN gibi farklı makine öğrenimi tekniklerinin rüzgar enerjisinden elektrik üretimi tahmin performansı üzerindeki etkileri nelerdir?

4. Geliştirilen hibrit model, rüzgar enerjisinden elektrik üretimi tahminlerinde geleneksel modellere kıyasla anlamlı bir iyileşme mi göstermektedir?

5. Rüzgar enerjisinden elektrik üretimi tahminlerinde kullanılan veri setlerinin kalitesi, tahminlerin doğruluğunu nasıl etkilemektedir?

Bu sorular, tezin temelini oluşturmaktadır ve araştırmanın yönünü belirlemektedir. Araştırma, bu soruların cevaplarını arayarak rüzgar enerjisinden elektrik üretimi tahminlerindeki mevcut zorlukları aşmayı ve yenilenebilir enerji alanına önemli katkılar sunmayı amaçlamaktadır.

1.3. Kapsam

Bu çalışma, Türkiye'nin Kayseri ilindeki Sancak Enerji Yahyalı Rüzgar Enerji Santrali verileri kullanılarak gerçekleştirilmektedir. Araştırmanın kapsamı, gün öncesi elektrik piyasası için kısa dönemli rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğunu ve güvenilirliğini artırmaya yönelik stratejilerin geliştirilmesi ve değerlendirilmesine odaklanmaktadır. Bu stratejilerin geliştirilmesi sürecinde kullanılan veri setleri, rüzgar enerjisi santralinden elde edilen gerçek zamanlı verilerden oluşmaktadır. Ayrıca bu verilerin analizinde kullanılan makine öğrenimi modelleri ve bu modellerin belirli koşullar ve parametreler altındaki performansları detaylı bir şekilde incelenecektir. Çalışmanın bu özel odak noktası, kullanılan veri setlerinin kalitesi, veri toplama sürecinde karşılaşılan zorluklar ve veri setlerinin analizinde kullanılan makine öğrenimi modellerinin belirli koşullar karşısında gösterdiği performans duyarlılığı gibi sınırlamaları kapsamaktadır. Özellikle veri setlerinin kalitesi, tahmin modellerinin doğruluğunu doğrudan etkileyen en kritik faktörlerden biridir. Veri setlerindeki eksiklikler veya hatalar tahmin sonuçlarını olumsuz etkileyebilir. Bu nedenle veri kalitesinin iyileştirilmesi ve veri temizleme süreçlerinin optimize edilmesi de bu çalışmanın önemli bir parçasını oluşturmaktadır.

Enerji üreticileri, tüketiciler ve politika yapıcılar için kritik öneme sahip olan günlük enerji piyasası işlemlerinde karar verme süreçlerini iyileştiren doğru ve güvenilir tahmin modellerinin geliştirilmesine büyük bir ihtiyaç bulunmaktadır. Bu çalışmanın bir diğer önemli amacı, enerji üreticileri ve politika yapıcılar için geliştirilecek tahmin modellerinin, enerji piyasalarındaki fiyat dalgalanmalarını minimize etmesi ve piyasa istikrarının sağlanmasıdır. Ayrıca bu modellerin, enerji tüketicilerinin elektrik maliyetlerini azaltarak ekonomik fayda sağlaması hedeflenmektedir. Gün öncesi piyasalar için tahminlerin iyileştirilmesi, enerji üretimi ve tüketimi arasındaki potansiyel dengesizliklerin azaltılmasını, enerji kaynaklarının daha verimli kullanılmasını ve yenilenebilir enerji kaynaklarının elektrik şebekelerine entegrasyonunun kolaylaştırılmasını amaçlamaktadır. Bu süreçte, rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğunun artırılması şebeke operatörlerinin enerji arz ve talep dengesini daha etkin bir şekilde yönetmesine olanak tanıyacaktır. Ayrıca doğru tahminler sayesinde yenilenebilir enerji kaynaklarının şebekeye entegrasyonu

sırasında yaşanabilecek teknik ve operasyonel zorluklar minimize edilecektir. Bu bağlamda, çalışmanın bulguları, rüzgar enerjisinden elektrik üretimi tahminlerinde yenilikçi yaklaşımların benimsenmesini teşvik ederek, gün öncesi elektrik piyasasının daha verimli ve etkili bir şekilde işlemesine katkıda bulunmayı hedeflemektedir.

Bu tez, rüzgar enerjisinden elektrik üretimi tahminlerinin doğruluğunu ve güvenilirliğini artırmaya yönelik kapsamlı bir çalışmayı sunmaktadır. Araştırma, giriş bölümünde belirlenen araştırma soruları ve hedefleri çerçevesinde ilerlemektedir. Giriş bölümünde çalışmanın arka planı, problemin ifadesi, amaçları, önemi, kapsamı ve kısıtlılıklar açıklanmıştır. Literatür taraması kapsamında, rüzgar enerjisinden elektrik üretimi tahminlerinde kullanılan mevcut yöntemler, karşılaşılan zorluklar ve bu alandaki teknolojik gelişmeler detaylı bir şekilde incelenmiş, literatürdeki boşluklar ve bu boşlukların araştırmaya katkıları vurgulanmıştır. Materyal ve yöntem bölümünde, çalışmanın dayandığı teorik ve pratik yaklaşımlar açıklanmış; kullanılan veri setlerinin kalitesi, veri toplama ve analiz süreçleri ile makine öğrenimi modellerinin teorik temelleri ve uygulanış biçimleri detaylandırılmıştır. Araştırma sorularına yönelik yöntemlerin seçimi ve bu yöntemlerin çalışma kapsamındaki katkıları ele alınmıştır. Bulgular ve tartışma bölümünde, modelleme sonuçları ve bu sonuçların enerji sektörü açısından teorik ve pratik katkıları değerlendirilmiş; RF, SVM ve hibrit modellerle yapılan tahminlerin doğruluğu ve güvenilirliği, literatürdeki yöntemlerle karşılaştırmalı olarak ele alınmıştır. Ayrıca model performans metrikleri ve enerji piyasalarına yönelik uygulama perspektifleri tartışılmıştır. Sonuçların uygulanabilirliği ve endüstriyel perspektifler bölümünde, çalışmanın enerji piyasalarındaki mevcut sorunlara getirdiği çözümler ile bu çözümlerin endüstrideki potansiyel etkileri değerlendirilmiş ve rüzgar enerjisinin tahmin edilmesi ile elektrik piyasalarına entegrasyonunda elde edilen bulguların sektör paydaşları için nasıl bir yol haritası oluşturabileceği açıklanmıştır. Son olarak, sonuçlar bölümünde çalışmanın genel bulguları özetlenmiş, tezin sınırlılıkları tartışılmış ve gelecekte yapılabilecek araştırmalara yönelik öneriler sunulmuştur.

2. TEORİK BİLGİ VE LİTERATÜR TARAMASI

2.1. Rüzgar Enerjisi ve Tahmin Yöntemlerine Genel Bakış

2.1.1. Rüzgar Enerjisi

Rüzgar enerjisi, enerji üretiminde sürdürülebilirlik ve yenilenebilir enerjinin simgelerinden biri haline gelmiştir. Doğal süreçlerle yenilenen ve tükenme riski olmayan bir enerji kaynağı olarak hem çevresel hem de ekonomik açıdan önemli avantajlar sunmaktadır. Güneş Sistemi'ndeki en büyük enerji kaynaklarından biri olan Güneş'ten gelen ısının, Dünya'nın atmosferindeki hava kütlelerinin farklı sıcaklık ve basınçlarda hareket etmesine sebep olmasıyla rüzgar oluşumu gerçekleşmektedir. Sürekli hareket eden bu hava kütleleri, kinetik enerji taşımakta ve bu kinetik enerji rüzgar türbinleri aracılığıyla elektrik enerjisine dönüştürülmektedir. Rüzgar enerjisi kullanımı, çeşitli avantajları nedeniyle her geçen gün artmaktadır. Bu avantajlar arasında yakıt maliyetinin olmaması, işletme giderlerinin düşük olması, çevre dostu bir enerji kaynağı olması ve karbon ayak izinin azaltılmasına katkı sağlaması yer almaktadır. Ayrıca rüzgar enerjisi yerel ekonomilere katkı sağlamakta, istihdam yaratmakta ve enerji güvenliğini artırmaktadır. Yenilenebilir ve temiz bir enerji kaynağı olarak, fosil yakıt bağımlılığını azaltmakta ve küresel iklim değişikliği ile mücadelede önemli bir rol oynamaktadır.

Rüzgar türbinleri, genellikle yüksek verimlilikle çalışacak şekilde tasarlanmaktadır. Türbinlerin enerji üretimi, rüzgar hızı ile doğrudan ilişkilidir. Ancak rüzgarın değişken doğası, enerji üretimini tahmin etmeyi ve şebekeye uyumlu bir şekilde entegre etmeyi zorlaştırmaktadır. Rüzgar enerjisinden elektrik üretimindeki bu dalgalanmalar, enerji şebekesinin dengesini korumak ve enerji talebi ile arzını dengelemek için gelişmiş yönetim sistemleri ve depolama çözümleri gerektirmektedir.

Rüzgar enerjisi teknolojilerindeki yenilikler sayesinde türbinler daha yüksek verimli, daha uzun ömürlü ve daha az bakım gerektirecek şekilde geliştirilmektedir. Türbin tasarımlarındaki yenilikler daha geniş alanları kapsayan kanatları, daha dayanıklı malzemeleri ve yüksek enerji üretme yeteneklerini içermektedir. Gelişen rüzgar haritalama

teknikleri sayesinde ise rüzgar türbinlerinin yerleştirileceği uygun konumlar daha doğru bir şekilde tespit edilmekte ve böylece enerji üretimi maksimize edilmektedir.

2.1.2. Rüzgar enerjisinin avantaj ve dezavantajları

Yenilenebilir enerji kaynaklarının kullanımının birçok avantajı bulunmaktadır. Çevrenin korunması, sera gazı emisyonlarının önemli ölçüde azalması, fosil yakıt tüketiminin düşürülmesi, enerji ithalatına olan bağımlılığın azaltılması, inovasyonun ve ekonomik gelişmenin teşvik edilmesi, istihdamın artırılması, kırsal kalkınmanın desteklenmesi ve enerji erişiminin genişletilmesi bu avantajlar arasında yer almaktadır. Bu avantajlar yenilenebilir enerji kaynaklarının çevre dostu olduğunu ve sürdürülebilir kalkınma hedeflerine ulaşmak için kritik bir role sahip olduğunu göstermektedir[5].

Öte yandan yenilenebilir enerji kaynaklarının kullanımıyla ilgili bazı zorluklar ve dezavantajlar da mevcuttur. Bunlar arasında en belirgin olanları bu enerji kaynaklarının hava koşullarına bağlılığı, süreklilik ve tahmin edilebilirliğin düşüklüğü, elektrik üretiminde düşük kapasite, enerji verimliliğinin az olması, düşük kapasite kullanımı ve nispeten yüksek elektrik üretim maliyetleridir. Yenilenebilir enerji kaynaklarının doğası gereği coğrafi konum ve hava koşullarına olan bağlılıkları, elektrik üretimindeki dalgalanmaları artırmakta ve elektrik sisteminin dengesini etkileyebilmektedir. Ayrıca yenilenebilir enerji tesislerinin kurulumu için gerekli olan yüksek başlangıç maliyetleri, özellikle gelişmekte olan ekonomiler için önemli bir engel teşkil etmektedir[5].

Bu bağlamda, yenilenebilir enerji kaynaklarının avantajları çevresel sürdürülebilirlik ve uzun vadeli ekonomik faydalar sunarken, dezavantajları ve zorlukları teknolojik yenilikler ve maliyet etkin çözümler aracılığıyla ele alınabilmekte ve en aza indirilebilmektedir. Bu yaklaşım, yenilenebilir enerjinin potansiyelini en üst düzeye çıkarırken karşılaşılan zorlukları da hafifletmeye yardımcı olmaktadır.

2.1.3. Türkiye ve dünyada rüzgar enerjisi potansiyeli

Türkiye enerji sektöründe yaşanan son gelişmeler ve gelecek beklentileri, yenilenebilir enerji kaynaklarının kullanımının önemini göstermektedir. 2023 yılında Türkiye'nin elektrik

enerjisi tüketimi bir önceki yıla göre %0,2 oranında azalarak 330,3 TWh olarak gerçekleşmiş, elektrik üretimi ise %0,6 azalarak 326,3 TWh olmuştur. Bu veriler, enerji tüketiminde ve üretiminde yaşanan küçük değişikliklerin, enerji kaynaklarının daha verimli ve sürdürülebilir şekilde kullanılması gerekliliğini vurgulamaktadır[6].

2023 yılında ülkemizin elektrik üretimindeki kaynak dağılımı incelendiğinde, %36,3'lük bir payla kömürün hala önemli bir yer tuttuğu, %21,4 ile doğal gazın, %19,6 ile hidrolik enerjinin ve önemli bir yükseliş gösteren %10,4 ile rüzgar enerjisinin takip ettiği görülmektedir. Rüzgar enerjisi, ülkenin enerji üretiminde her geçen gün daha fazla yer kaplamakta ve Türkiye'nin yenilenebilir enerji kaynaklarından elektrik üretimindeki çeşitliliğini ve kapasitesini artırmaktadır[6].

2024 yılı ocak ayı sonu itibarıyla Türkiye'nin kurulu gücü 107.271 MW'a ulaşmıştır. Kurulu gücün kaynaklara göre dağılımında, hidrolik enerji %29,8 ile en büyük paya sahipken, doğal gaz %23,7 ve kömür %20,3 ile önemli kaynaklar arasında yer almaktadır. Rüzgar enerjisinden elektrik enerjisi üretimi, %11,1 ile dikkat çekici bir artış göstererek Türkiye'nin enerji üretimindeki çeşitliliğinin ve yenilenebilir enerjiye verilen önemin bir göstergesi haline gelmiştir. Güneş enerjisinin de %11,0 ile rüzgar enerjisinden elektrik enerjisi üretimine yakın bir paya sahip olması ülkenin yenilenebilir enerji kaynaklarını çeşitlendirdiğini ve bu alanda önemli adımlar attığını göstermektedir[6].

Elektrik enerjisi üretim santrali sayısı 2024 yılı ocak ayı sonu itibarıyla 15.959'a ulaşırken rüzgar enerjisi santrallerinin sayısının 365 adet olduğu görülmektedir. Bu santraller, Türkiye'nin rüzgar enerjisinden elde ettiği elektriği artırmada kritik bir role sahiptir. Güneş enerjisi santrallerinin sayısının 13.872 ile oldukça yüksek olması da yenilenebilir enerjinin ülke genelinde yaygınlaştığının bir işaretidir[6].

Türkiye Ulusal Enerji Planı'na göre, elektrik tüketiminin 2025 yılında 380,2 TWh, 2030 yılında 455,3 TWh, 2035 yılında ise 510,5 TWh seviyesine ulaşması beklenmektedir. Bu artan enerji talebini karşılamak için, rüzgar enerjisinden elektrik enerjisi üretimi gibi yenilenebilir enerji kaynaklarının kullanımının artırılması, çevresel sürdürülebilirlik ve enerji güvenliği açısından büyük öneme sahiptir. Türkiye'nin rüzgar enerjisinden elektrik enerjisi

üretimi kapasitesinin genişletilmesi, gelecekteki enerji ihtiyaçlarının karşılanması açısından kritik bir öneme sahip olacaktır. Bu kapasite artışı, enerji güvenliği, sürdürülebilir kalkınma ve karbon ayak izinin azaltılması açısından önemli katkılar sağlayacaktır. Rüzgar enerjisinin bu denli ön plana çıkarılması, Türkiye'nin yenilenebilir enerjiye verdiği önemi ve bu alandaki potansiyelini göstermektedir. Bu durum, ülkenin enerji üretimini çeşitlendirme, karbon ayak izini azaltma ve enerji üretiminde öz kaynaklarının kullanımına yönelik attığı adımların bir örneği olarak değerlendirilebilir[6].

Tüm bu bilgiler doğrultusunda Türkiye'nin rüzgar enerjisinden elektrik enerjisi üretimi kapasitesindeki artış ve bu enerji kaynağının elektrik üretimindeki payının artması, sürdürülebilir enerji hedeflerine ulaşma konusundaki kararlılığını göstermektedir. Rüzgar enerjisinden elektrik enerjisi üretimi, enerji üretimindeki çeşitliliği artırma ve yenilenebilir enerji kaynaklarından maksimum fayda sağlama konusunda önemli bir rol oynayacaktır. Bu bağlamda Türkiye'nin rüzgar enerjisinden elektrik enerjisi üretimi alanında kaydettiği ilerleme, gelecekteki enerji stratejileri için sağlam bir temel oluşturmaktadır[6].

2023 yılında Türkiye'nin rüzgar enerjisinden elektrik enerjisi üretimi aylık ve yıllık bazda ele alındığında toplam elektrik tüketiminde belirgin bir rol oynamıştır. Ocak ayından aralık ayına kadar detaylı olarak incelendiğinde, rüzgar enerjisinden elektrik enerjisi üretiminin en yüksek paya ulaştığı aylar kasım (%13), şubat ve eylül (%12) olarak kaydedilmiştir. Yılın genelinde rüzgar enerjisinden elektrik enerjisi üretiminin ortalama payı %11 civarında seyretmiştir ve bu durum rüzgar enerjisinden elektrik enerjisi üretiminin Türkiye'nin enerji portföyündeki giderek artan önemini vurgulamaktadır. Tablo 2.1'de yer alan bu veriler, ülkemizdeki yenilenebilir enerji stratejilerinin ve rüzgar enerjisi yatırımlarının etkisini yansıtmakta, Türkiye'nin enerji çeşitliliği ve sürdürülebilirliği yönünde attığı adımları göstermektedir[6].

Türkiye'nin rüzgar enerjisi kapasitesi, 2003 yılında 18,9 MW iken, yıllar içinde istikrarlı bir şekilde büyüme göstererek 2022 yılında 11.396,2 MW'lık bir kurulu güce ulaşmıştır. 20 yıllık bu gelişim verileri Tablo 2.2'de gösterilmektedir[6]. Bu süre içinde rüzgar enerjisinin Türkiye'nin toplam kurulu gücündeki payı %0,05 gibi düşük bir orandan %10,97 gibi dikkate değer bir orana çıktığı görülmektedir. Türkiye'nin toplam kurulu gücü ise 2003 yılında

35.587,0 MW iken 2022 yılı itibarıyla 103.809,3MW'a ulaşarak neredeyse üç katına çıkmıştır. Rüzgar enerjisinin kurulu gücündeki bu artış, Türkiye'nin yenilenebilir enerjiye olan bağlılığının ve bu sektörde gerçekleştirdiği yatırımların açık bir göstergesidir. Rüzgar enerjisinin ülkenin enerji portföyündeki artan önemi, sürdürülebilir enerji hedeflerine ulaşmada ve enerji üretiminde çeşitliliği artırmada merkezi bir role sahip olmaya devam edecektir.

Tablo 2.1: Türkiye'de 2023 Yılında Aylara Göre Rüzgar Gücü Üretimi Ve Toplam Üretimdeki Payı[6]

2023 AYLAR	RÜZGAR (MWh)	TÜRKİYE TOPLAM ÜRETİM (MWh)	TÜRKİYE TOPLAM TÜKETİM (MWh)	ÜRETİMDE RÜZGARIN PAYI %
Ocak	2.684.742	26.805.329	27.468.350	10
Şubat	2.873.810	24.141.059	24.488.064	12
Mart	3.030.929	25.980.035	26.375.848	12
Nisan	2.393.388	24.077.459	24.279.908	10
Mayıs	2.342.940	25.709.563	25.954.174	9
Haziran	2.263.835	24.943.271	25.126.476	9
Temmuz	3.072.654	31.509.686	31.783.099	10
Ağustos	3.186.622	33.300.850	33.657.604	10
Eylül	3.354.966	28.199.693	28.519.882	12
Ekim	2.287.512	25.141.982	25.263.898	9
Kasım	3.329.225	25.097.283	25.460.522	13
Aralık	3.062.535	27.233.222	28.307.235	11
TOPLAM (MWh)	33.883.158	322.139.431	326.685.060	11

Tablo 2.2: Türkiye'nin Yıllara Göre Rüzgar Enerjisi Kurulu Gücü[6]

YILLAR	RÜZGAR (MW)	TÜRKİYE TOPLAM KURULU GÜCÜ (MW)	RÜZGARIN PAYI %
2003	18,9	35.587,0	0,053109281
2004	18,9	36.824,0	0,051325223
2005	20,1	38.843,5	0,051746109
2006	59,0	40.564,8	0,145323039
2007	147,5	40.835,7	0,361203555
2008	363,7	41.817,2	0,869737811
2009	791,6	44.761,2	1,768495930
2010	1.320,2	49.524,1	2,665772826
2011	1.728,7	52.911,1	3,267178343
2012	2.260,6	57.059,4	3,961836262
2013	2.759,7	64.007,5	4,311525993
2014	3.629,7	69.519,8	5,221102477
2015	4.503,2	73.146,7	6,156395299
2016	5.751,3	78.497,4	7,326739484
2017	6.516,2	85.200,0	7,648100939
2018	7.005,4	88.550,8	7,911149306
2019	7.591,2	91.267,0	8,317525837
2020	8.832,4	95.890,6	9,210907842
2021	10.607,0	99.819,6	10,626143040
2022	11.396,2	103.809,3	10,977984150

Türkiye'nin rüzgar enerjisi potansiyeli ülkenin çeşitli bölgelerinde farklılık gösteren rüzgar hızlarıyla doğrudan ilişkilidir. Şekil 2.1'de görüldüğü üzere, yıllık ortalama rüzgar hızı dağılımı, Türkiye'nin geniş bir coğrafyasında rüzgar enerjisi kullanımının verimliliğini ortaya koymaktadır[7]. 100 metre yükseklikte yapılan ölçümlere göre, özellikle kıyı bölgelerde ve bazı iç kesimlerde rüzgar hızlarının 7,5 m/s'yi aştığı yerler olduğu görülmektedir. Bu durum rüzgar türbinleri için uygun ve ekonomik açıdan verimli koşullar oluşturmaktadır. Kırmızı ve turuncu tonlarıyla belirtilen bu alanlar rüzgar enerjisi

yatırımlarının odaklanması gereken potansiyel konumları göstermektedir. Türkiye'nin rüzgar haritasındaki bu dağılım, rüzgar enerjisi üretiminde öncelikli bölgelerin belirlenmesinde ve mevcut rüzgar parklarının optimize edilmesinde kritik öneme sahiptir.

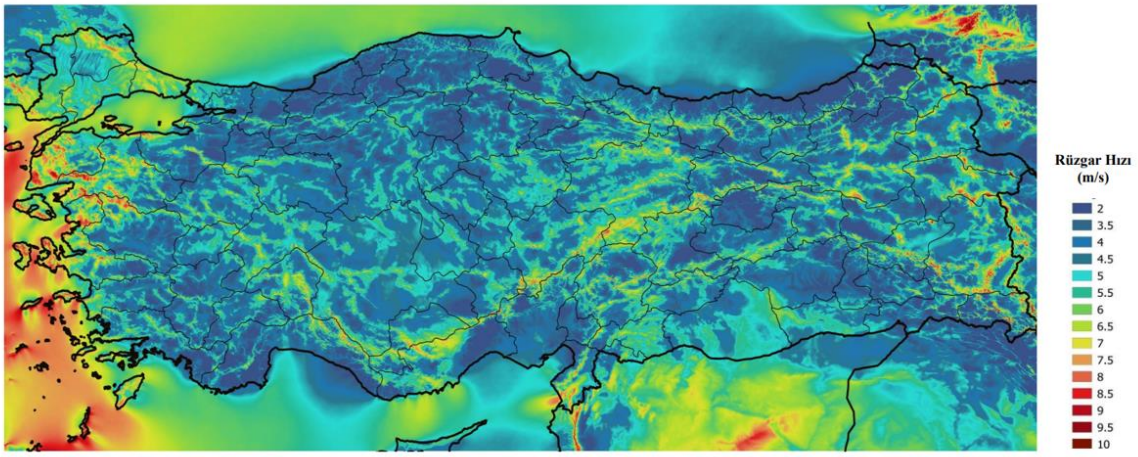

Şekil 2.1: Türkiye 100m Yükseklikte Yıllık Ortalama Rüzgar Hızı Dağılımı[7].

Rüzgar enerjisinden elektrik enerjisi üretimi, yenilenebilir enerji üretim kaynakları içinde hızla büyüyen bir paya sahiptir. Uluslararası Yenilenebilir Enerji Ajansı'nın (IRENA) verilerine göre, rüzgar enerjisinden elektrik enerjisi üretim kapasitesi son on yılda önemli ölçüde artmıştır. Bu artış, teknolojik ilerlemeler, maliyetlerin düşmesi ve hükümet politikalarının yanı sıra, daha geniş bir kabul görmesiyle desteklenmektedir. Küresel rüzgar enerjisinden elektrik enerjisi üretimi kullanımı genişlemekte olup, 2013 ile 2022 yılları arasında farklı bölgelerde kurulu rüzgar enerjisinden elektrik enerjisi üretimi kapasitesindeki büyümeyi gösteren Tablo 2.3'te belirtilmiştir. 2022 yılı itibarıyla, Asya kurulu kapasite ile önde gelirken, Kuzey Amerika son on yılda yaklaşık on üç kat büyüme ile en önemli artışı göstermiştir. Küresel toplam kurulu rüzgar enerjisinden elektrik enerjisi üretim kapasitesi de geçtiğimiz on yılda üç katına çıkarak 898.856 MW'a ulaşmıştır[8].

Tablo 2.3: Rüzgar Enerjisi Kurulu Gücünün Bölgelere Göre Dağılımı[8]

BÖLGELER	2013 (MW)	2016 (MW)	2019 (MW)	2022 (MW)
Dünya	300.052	467.013	622.78	898.856
Afrika	1.742	3.831	5.529	7.687
Asya	99.542	184.143	257.669	425.485
Amerika & Karib	754	1.481	1.949	2.101
Avrasya	2.775	5.801	7.783	13.712
Avrupa	118.17	155.727	196.11	240.285
Orta Doğu	122	423	775	1.053
Kuzey Amerika	70.122	97.526	123.597	163.47
Okyanusya	3.895	5.066	8.625	11.522
Güney Amerika	2.93	13.013	20.742	33.541

2.2. Rüzgar Enerjisi Tahmin Yöntemleri

Rüzgar enerjisinden elektrik enerjisi üretimi tahmin yöntemleri, tahmin edilen zaman aralığı, tahmin model yapısı, tahmin edilen fiziksel değerler ve kullanılan girdi-çıktı verileri gibi çeşitli kriterlere göre sınıflandırılmaktadır[4], [9]. Literatürde en yaygın kullanılan yaklaşım tahmin yöntemlerini zaman aralığına göre kategorize etmektir. Bu kategoriler, ultra kısa vadeli, kısa vadeli, orta vadeli ve uzun vadeli tahminleri içermektedir[10], [11]. Bu çalışmada, özellikle 4 ile 72 saat arasındaki zaman dilimi için yapılan kısa vadeli tahminlere özel bir vurgu yapılmaktadır[10]. Kısa vadeli tahminler, gün öncesi elektrik piyasasında arz ve talebi dengelemek için kritik öneme sahiptir. Bu nedenle, hedef değişkeni yüksek doğrulukla tahmin etme yeteneği, güç şebekesi içindeki zamanında ve güvenilir operasyonlar için oldukça büyük önem taşımaktadır.

Akademik literatürde kısa vadeli tahminlerin ilk kavramsallaştırmaları 1970'lerde ortaya çıkmış ancak bu alanda önemli bir ilerleme 1980 yılında Notis ve meslektaşları tarafından yapılan çalışma ile gerçekleşmiştir. 1980'ler boyunca çeşitli çalışmalarda istatistiksel zaman

serisi analizi yöntemlerini kullanılsa da sayısal hava tahmini yöntemi 1990'lı yıllarda öne çıkmaya başlamıştır. 2000'li yılların başında, tahminde makine öğrenimi ve sinir ağlarının kullanımı ön plana çıkmıştır[12]. 2000'lerin ilk on yılında, otoregresif tahmin yöntemleri geliştirilmiş ve çalışmaların odak noktası bu yöntemlere kaymıştır. Takip eden on yılda, literatürde ARIMA, ARMA, VDM, ELM, SVM ve ANN gibi çeşitli diğer yöntemler incelenmiştir[13]. Şekil 2.2'de gösterildiği gibi Rüzgar Enerjisi Tahmin Yöntemlerinin Süreç Çizelgesi rüzgar enerjisi tahmininin tarihçesini gösterir.



Şekil 2.2: Rüzgar Enerjisi Tahmin Yöntemlerinin Süreç Çizelgesi

Birçok model ayrıntılı bir şekilde incelenmiş ve hibrit yaklaşımlar kullanılmış, her yöntemin avantajları ve dezavantajları değerlendirilmiştir. Bu çalışma, mevcut literatürün teknolojik ilerlemelerle bir sentezini sunarak ve yöntemlerin güçlü ve zayıf yönlerini değerlendirerek araştırmacılara literatürde yaygın olarak kullanılan yöntemler hakkında kapsamlı bir

inceleme sağlamayı amaçlamaktadır. Bu sayede şebeke sistem operatörleri, elektrik tüccarları ve rüzgar enerjisinden elektrik enerjisi üretimi yapan çiftlik operatörleri dahil olmak üzere tüm paydaşlara, etkili enerji depolama yönetimi ve mikro şebeke programlaması konusunda bilinçli kararlar almaları için gereken bilgiyle donatmayı hedeflemektedir. Rüzgar enerjisinden elektrik enerjisi üretimi sırasında rüzgar hızlarının rastlantısal ve aralıklı doğasının ortaya koyduğu zorluklara rağmen doğru ve güvenilir tahminler, şebeke entegrasyonuyla ilişkili riskleri azaltabilmekte ve iletim ile dağıtım ağı tüm seviyelerinde etkili enerji ticaretini kolaylaştırabilmektedir.

Rüzgar enerjisinden elektrik enerjisi üretimi, küresel enerji sisteminde yenilenebilir ve temiz bir kaynak olarak önemli bir rol oynamaktadır. İklim değişikliği ile mücadelede ve sürdürülebilir kalkınma hedeflerine ulaşmada kritik bir öneme sahiptir. Fosil yakıtların yol açtığı karbon emisyonlarını azaltmada ve enerji güvenliğini artırmada etkili bir çözüm olarak öne çıkmaktadır. Rüzgar enerjisinden elektrik enerjisi üretiminin entegrasyonu, enerji üretimi ve tüketimi arasındaki dengenin korunmasını, enerji piyasalarında fiyat istikrarının sağlanmasını ve yenilenebilir enerjinin genişletilmesine yönelik politika ve stratejilerin geliştirilmesini gerektirmektedir. Tahmin yöntemlerinin sürekli iyileştirilmesi, rüzgar enerjisinden elektrik enerjisi üretiminden elde edilen faydaların maksimize edilmesi ve sürdürülebilir bir enerji geleceğine ulaşılmasında hayati bir öneme sahiptir.

2.2.1. Tahmin Yöntemlerinin Sınıflandırılması

Rüzgar enerjisinden elektrik enerjisi üretim tahmin tekniklerinin zamana göre sınıflandırılması literatürde birçok şekilde ele alınmış olsa da, genellikle dört bölümde incelenmesi doğru olacaktır. Bunlar: Ultra kısa vadeli tahmin, kısa vadeli tahmin, orta vadeli tahmin ve uzun vadeli tahmin yöntemleridir. Ultra kısa vadeli tahminler dakikalarla ifade edilirken kısa vadeli tahminler saatlerle, orta vadeli tahminler günlerle ve uzun vadeli tahminler haftalar, aylar ve hatta yıllarla ifade edilmektedir. Şekil 2.3'te, yaygın kullanılan rüzgar enerjisinden elektrik enerjisi üretimi tahmin yöntemlerinin zaman sınıflandırması gösterilmekte ve kullanım alanlarına örnekler verilmektedir[14].



Şekil 2.3: Rüzgar Tahmini Yöntemlerinin Zaman Ölçeği Sınıflandırması

Tahmin yöntemleri iki ana kategoriye ayrılmaktadır. Bunlar fiziksel ve istatistiksel yöntemlerdir[15], [16]. Ancak bu yöntemler tek başlarına kullanıldığında tahmin doğrulukları düşük olmaktadır. Tahminlerin doğruluğunu artırmak için, fiziksel ve istatistiksel yöntemlerin kombinasyonuyla hibrit yöntemler geliştirilmiştir. Literatürdeki çalışmalar incelendiğinde hibrit yöntemlerin bireysel yöntemlere kıyasla daha yüksek doğruluk eğiliminde olduğu gözlemlenmektedir. Bu nedenle, fiziksel, istatistiksel ve hibrit modelleri içerecek şekilde tahmin yöntemlerini değerlendirmek ve sınıflandırmak önemlidir[17], [18]. Şekil 2.4, literatürde yaygın kullanılan tahmin yöntemlerinin yaklaşımlarına dayalı sınıflandırmasını göstermektedir.

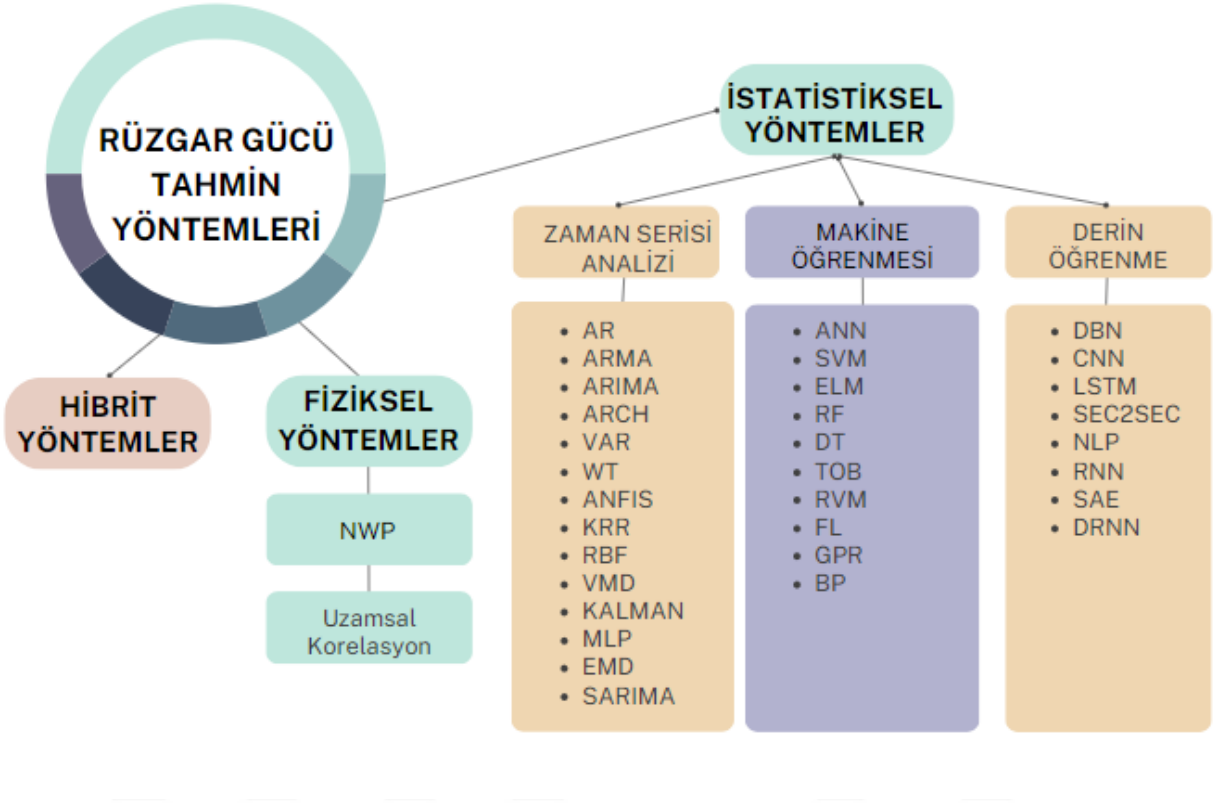

Şekil2.4: Tahmin Yöntemlerinin Sınıflandırılması

2.2.1.1 Fiziksel tahmin yöntemleri

Fiziksel tahmin modelleri arasında, Sayısal Hava Tahmini (Numerical Weather Prediction-NWP) yöntemi en yaygın kullanılan yaklaşım olarak öne çıkmaktadır. NWP'de, rüzgar yönü, rüzgar hızı, barometrik basınç ve nem gibi gerçek zamanlı atmosferik veriler kullanılarak rüzgar enerjisinden elektrik enerjisi üretimi tahminleri yapılmaktadır. NWP, özellikle uzun vadeli rüzgar enerjisinden elektrik enerjisi üretimi tahminleri için doğru sonuçlar üretmede son derece etkili olmuştur ve büyük ölçekli rüzgar enerjisi tesislerinin yönetiminde geniş çapta kullanılmaktadır. Bu yöntemin hassasiyeti, özellikle rüzgar enerjisinden elektrik enerjisi üretimi tahmin bağlamında temel bir rol oynadığı için hayati önem taşımaktadır[9]. NWP yöntemin literatür çalışmalarının temel taşı olduğunu belirtmek gerekmektedir. Ancak bu yöntemin önemli bir dezavantajı, yüksek hesaplama süresi nedeniyle ilişkili hata

oranlarına yol açmasıdır[19]. Rüzgar tahminindeki bir diğer fiziksel yaklaşım, farklı konumlardaki rüzgar hızları arasındaki mekansal korelasyonları kullanan mekansal korelasyon yöntemidir[20]. Bu yaklaşımda, tahmin edilen noktalardan ve yakın bölgelerden rüzgar hızı zaman serileri kullanılmakta ve farklı alanlardaki rüzgar hızlarının mekansal ilişkisi dikkate alınarak rüzgar hızı tahmin edilmektedir[21], [22].

Rüzgar enerjisi üretiminin rüzgar hızı, yönü ve şiddeti gibi meteorolojik verilere bağlı olduğu göz önüne alındığında, geleceğe yönelik tahminler yapmak için belirli verilerin kullanılması zorunlu hale gelmektedir. Bu meteorolojik veriler aslında NWP olarak bilinen bir tahmin metodolojisinden türetilmektedir. NWP'nin rüzgar tahminlerinin ilk aşamalarında temel bir yapı taşı olarak hizmet ettiği söylemek doğru olacaktır[23].

2.2.1.2 İstatistiksel Tahmin Yöntemleri

İstatistiksel tahmin yöntemleri zaman serisi analizi, makine öğrenimi ve derin öğrenme olmak üzere üç ana kategoriye ayrılmaktadır. Bu yöntemler, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde yüksek boyutlu ve doğrusal olmayan verileri işleme kapasiteleri nedeniyle yaygın olarak kullanılmaktadır. Zaman serisi analizi, geçmiş veri trendlerini analiz ederek gelecekteki değerleri tahmin etme yeteneği sunarken; makine öğrenimi, veri setlerindeki karmaşık ilişkileri modelleyebilme avantajı sağlamaktadır. Derin öğrenme yöntemleri ise, özellikle çok katmanlı yapay sinir ağları aracılığıyla, tahmin performansını daha da iyileştirebilmektedir. Bu yöntemlerin her biri, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerindeki doğruluğu artırmaya yönelik önemli potansiyele sahiptir.

- ✓ **Zaman serisi analizi**

Rüzgar enerjisi üretiminin tahmin edilmesinde zaman serisi analizi araçlarının kullanımı, kısa vadeli güç tahminlerine önemli katkılar sunmaktadır. Otoregresif (Autoregressive-AR) model, önceki değişkenleri mevcut değişkenlerle birleştirirken, Hareketli Ortalama (Moving Average-MA) modeli geçmiş hataları dikkate almaktadır. Bu iki yaklaşımı birleştiren ARMA modeli, kapsamlı bir analiz yöntemi sunmaktadır. Otoregresif Entegre Kaydırma Ortalamaları (Auto-Regressive İntegrated Moving Average-ARIMA) modelleri ise, zaman

serisinin orijinal değerlerini değiştirerek daha detaylı tahminler yapılmasını sağlamaktadır[24], [25].

1976 yılında Jenkins ve Box tarafından tanıtılan otoregresif zaman serisi analizi, bu alandaki çalışmaların temel taşını oluşturmaktadır[26].

ARMA modelleri, rüzgar gücü ve hızındaki dalgalanmaları tahmin etmek için kullanılır ve yüksek doğruluğa sahiptir. Ancak büyük veri kümelerinde, veri dalgalanmaları nedeniyle tahmin yaklaşımlarının güvenilirliği azalır, bu da bir sorun oluşturmaktadır[27], [28]. Korprasertsak tarafından yapılan bir çalışmada, ANN, GP ve ARMA gibi farklı tahmin modellerinin performansı karşılaştırılmıştır. Araştırmacılar, ANN modelinin tahmin yeteneği açısından iyi performans gösterdiğini kanıtlamışlardır. Ayrıca, hesaplama gereksinimlerine rağmen diğer modellere göre daha çok yönlü olduğu da gösterilmiştir[29].

ARIMA modelleri, istatistiksel analiz yöntemine dayanarak rüzgar enerjisi üretimini tahmin etmek için kullanılmaktadır. Tahminler, önceki zaman serisi değerlerini kullanarak yapılmaktadır[21], [30].

Zhang ve meslektaşları tarafından gerçekleştirilen bir çalışmada, Ayrık Dalga Dönüşümü (DWT), Mevsimsel Otoregresif Entegre Kaydırma Ortalamaları (SARIMA) ve Derin Öğrenme tekniklerinin birleştirildiği yeni bir hibrit model önerilmektedir. Bu model, yapılan testlerde yüksek performans sergileyerek, zaman serisi analizinin karmaşık modelleri kullanılarak rüzgar gücünü tahmin etmedeki üstünlüğünü ortaya koymaktadır. Araştırma ekibi, modelin doğruluğunu İskoçya'da bulunan bir rüzgar türbini üzerinde gerçekleştirdikleri rüzgar gücü tahmini ile test etmektedir[31].

Aasim ve meslektaşları tarafından gerçekleştirilen çalışmada, ARIMA ve Dalgacık Dönüşümü (WT) modelleri kullanılarak rüzgar hızlarını tahmin etme sürecinde farklı zaman serilerinden kaynaklanan hatalar analiz edilmiştir. Yinelemeli Dalga Dönüşümü (RWT) yaklaşımını kullanarak geliştirilen yeni model, rüzgar hızlarını tahmin etme konusunda yüksek doğruluk sağlamaktadır. RWT-ARIMA modeli, çeşitli zaman dilimlerinde diğer zaman serisi modelleriyle karşılaştırılarak test edilmiştir ve rüzgar hızlarını tahmin etme konusunda diğer modellere kıyasla daha üstün olduğu ortaya konulmuştur[32].

Liu ve meslektaşlarının gerçekleştirdiği çalışmada, İskoçya'daki rüzgar hızlarını tahmin etmek amacıyla bir SARIMA modeli sunulmaktadır. Bu model, derin öğrenme tekniklerine dayanan Uzun Kısa Süreli Bellek (LSTM) ve Kapalı Yinelemeli Birim (GRU) algoritmalarıyla karşılaştırılmıştır. SARIMA modelinin test sonuçları, gelecekteki zaman serisi veri gecikmelerini ve açık deniz rüzgar hızlarını doğru bir şekilde tahmin edebilme kapasitesini göstermektedir[33].

Otoregresif Koşullu Değişen Varyans (ARCH) modelleri, zaman serisi verilerindeki rastgele dalgalanmaları modellemekte ve belirli dönemlerdeki değişiklikleri dikkate almaktadır[34], [35]. Serinin koşullu varyansı önceki değerlere bağlı olarak değişmekte ve bu değişen varyans işlevi uzun vadeli otokorelasyon sergileyebilmektedir[36].

Peng ve meslektaşlarının çalışmasında, rüzgar hızı serileri dalgalet analizi kullanılarak yaklaşık ve detaylı serilere ayrılmıştır. Her bileşen için ARIMA modeli uygulanmış ve seri üzerindeki değişen varyansın etkisi ile bir ARIMA-ARCH modeli oluşturulmuştur. Bu yöntemle, rüzgar hızı değerleri tahmini, yaklaşık ve detaylı değerlerin toplamıyla hesaplanarak rüzgar hızı tahmininde iyileştirilmiş doğruluk elde edilmiştir[36].

Vektör Otoregresif (VAR) modelleri, iki veya daha fazla zaman serisi arasındaki lineer ilişkileri modelleyerek tek değişkenli otoregresif modelleri genişletmektedir[37], [38]. Bu modeller, rüzgar hızı tahmini, elektrik fiyatı tahmini ve yük tahmini gibi çeşitli enerji sistemleri işlemlerinde geniş bir uygulama alanı bulmaktadır. VAR modelleri, enerji sistemlerinin karmaşıklığını ve çoklu değişkenler arasındaki dinamik etkileşimleri etkili bir şekilde ele alabilme yeteneği ile ön plana çıkmaktadır[39].

Koivisto ve meslektaşları tarafından önerilen Vektörel Otoregresif-çok çeşitli bağımlı değişkenler (VARTA) süreci, çoklu konumlardaki rüzgar hızlarını modellemek üzere zamansal çapraz korelasyonu içermektedir. Bu yaklaşım, çeşitli konumlardaki yüksek veya düşük rüzgar hızlarının eş zamanlı veya ardışık olasılıklarını değerlendirmekte ve zamansal ile mekansal bağımlılıkları göz önünde bulundurmaktadır. Modelin performansı, Finlandiya'da 21 konumda yapılan ölçümlerle test edilmiş olup yüksek rüzgar enerjisi kapasitesine sahip sistemler için önemli içgörüler sağlamaktadır[40].

Kalman filtresi, istatistiksel gürültü ve hata kullanarak değişkenleri tahmin etmek için ikinci dereceden lineer bir tahmin yöntemidir ve olasılık dağılımı analizi temelinde veri eğilimlerini temsil etmektedir[41]. En küçük kareler yöntemine verimli bir hesaplama çözümü sunmaktadır, gözlem değişikliklerine kolayca uyum sağlamakta, minimal arka plan bilgisi gerektirmekte ve düşük hesaplama maliyetleri sergilemektedir[42], [43].

Kalman tarafından 1960 yılında tanıtılan Kalman filtresi, hesaplama alanındaki gelişmeler nedeniyle rüzgar enerjisinde birçok uygulama bulmuştur ve bir sürecin durumunu tahmin etmek için kullanılabilmektedir. Ayrıca geçmişi, mevcut durumu ve geleceği tahmin etmek gibi çeşitli diğer işlevleri de yerine getirebilmektedir[44].

Cassola ve meslektaşları, rüzgar hızı ve rüzgar gücü tahmini için optimal yapılandırmayı belirlemek amacıyla Kalman filtresini kullanmışlardır. Bu yöntem, İtalya'da bir NWP modelinden ve iki anemometrik istasyondan alınan 2 yıllık rüzgar hızı veri seti retrospektif olarak değerlendirilmiş ve doğrudan rüzgar hızı model çıktısına kıyasla, özellikle kısa vadeli tahminler için bu metodun önemli ölçüde iyileştirildiği sonucuna varılmıştır[45].

- ✓ **Makine öğrenimi**

Makine Öğrenimi (Machine Learning-ML), bilgisayarların veya diğer cihazların verilerden öğrenme yeteneği kazanmasını amaçlayan bilgisayar bilimlerinin bir dalıdır. ML, verilerden bilgi çıkarma ve veri tabanlı tahminler yapma yöntemleri ve algoritmaları sağlamaktadır. Makine öğrenimi algoritmaları, veri kümesi davranışını tanımlamak, beklenen çıktıya göre model giriş özelliklerini belirlemek ve geçmiş kayıtlara dayanarak çıktı özelliklerini tahmin etmek için geniş çapta kullanılmaktadır. Kısa vadeli rüzgar enerjisi tahmininde, ML yöntemleri genellikle sayısal hava tahminleri yerine zaman serisi verilerini kullanmaktadır ve tahmin modelini eğitmek için kullanılan veri setine eğitim veri seti denir ve bu set geçmiş ölçümlere dayanmaktadır[43], [46].

ANN, insan beyninden esinlenerek oluşturulan hesaplama modelleridir. Bu ağlar, giriş, çıkış ve gizli katmanlardan oluşur, veri işlemesi ise gizli katmanda gerçekleşmektedir. Yaygın olarak kullanılan YSN türleri, çok katmanlı algılayıcılar (MLP'ler) ve radyal taban fonksiyon (RBF) ağlarıdır[47], [48], [49]. ANN'ler, karmaşık doğrusal olmayan ilişkileri modelleme,

yeni verilere uyum sağlama, çoklu girişleri paralel olarak işleme ve hasar görmüş bileşenlerle bile işlevselliği sürdürme gibi avantajlar sağlamaktadır. Ancak yorumlanabilirlik eksikliği nedeniyle sıklıkla "kara kutu" modelleri olarak görülmektedir. Ayrıca aşırı uyumluluğa yatkındırlar, bu da düzenleme tekniklerinin kullanımını gerektirmektedir. Özellikle büyük veri kümeleri için hesaplama karmaşıklığı gerektirmektedirler ve etkili öğrenme için büyük miktarda etiketli eğitim verisi talep etmektedirler bu da veri kalitesi ve miktarına duyarlılıklarını artırmaktadır[50].

Mabel ve meslektaşları, 3 yıllık bir dönem boyunca yedi rüzgar çiftliğinden alan verisi toplamış ve bu verileri analiz ederek rüzgar çiftliklerinden elektrik üretimini tahmin etmektedir. Önerilen model, ANN metodolojisi kullanılarak geliştirilmiştir. Model, giriş olarak rüzgar hızı, nispi nem ve enerji çıkış değişkenlerini dikkate almaktadır. Modelleme MATLAB programı kullanılarak gerçekleştirilmiştir. Modelin doğruluğu, gerçek değerlerle karşılaştırılarak değerlendirilmiş ve yüksek doğruluk sağladığı bulunmuştur[51].

Ansari ve meslektaşları, farklı özelliklere sahip üç farklı türde rüzgar türbini için güç üretimini tahmin etmek amacıyla rüzgar verilerini MATLAB kullanarak analiz etmektedirler. Tahminler gerçek verilerle karşılaştırılmakta ve %80'in üzerinde bir doğruluk elde edilmektedir[52].

Nair ve meslektaşları, Hindistan'daki üç farklı bölgede ANN, ARIMA ve bu ikisinin birleşiminden oluşan hibrit bir yöntemi kullanmıştır. Önerilen model için giriş verileri, 3 yıl boyunca 1 saatlik aralıklarla rüzgar hızını içermektedir. Modelin doğruluğunu değerlendirmek için Ortalama Mutlak Yüzde Hata (MAPE), Ortalama Kare Hatası (MSE) ve Ortalama Mutlak Hata (MAE) gibi sayısal hata değerlendirme yöntemleri kullanılmıştır. Sonuçlar, hibrit modelin hata oranının ANN ve ARIMA modellerinden ayrı olarak daha küçük olduğunu göstermektedir[53].

Sahay ve meslektaşları, kısa vadeli rüzgar hızını tahmin etmek için çeşitli ANN algoritmalarını MATLAB kullanarak değerlendirmiştir. Tahmin için kullanılan veriler, saatlik tarihçe verileri ile rüzgar yönü ve rüzgar hızını içermektedir. Benzetim sonuçları, küçük bir hata ile doğru rüzgar hızı tahminlerinin yapılabileceğini göstermektedir[54].

Bulanık mantık, karmaşık sistemleri modellemek için kullanılan bir yöntemdir, özellikle eksik bilgi ve belirsizlik içeren sorunları çözmek için idealdir[55].

Sideratos ve ekibi, yapay zeka tekniklerini kullanarak rüzgar enerjisini tahmin etmek için istatistiksel bir yöntem geliştirmiştir. Bu yöntemi geliştirdikleri çalışmada, geçmiş verileri ve rüzgarın yönü ve hızını kullanarak tahminler yapılmaktadır. Bu yaklaşımın dikkate değer bir özelliği, meteorolojik tahminlerin kalitesini tahmin etme yeteneğidir. Araştırmacılar, geliştirdikleri yöntemle rüzgar enerjisi seviyelerini 48 saat öncesinden tahmin etmektedir ve bu sayede rüzgar enerjisi için faydalı tahminler sağlamaktadır[56].

Kariniotakis ve ekibi, bir rüzgar çiftliğinin gücünü tahmin etmek için bulanık mantık ve yinelenebilir yüksek boyutlu sinir ağları kullanarak modeller geliştirmektedir. Bu modeller, çeşitli rüzgar enerjisi zaman serileri üzerinde test edilmiş olup ve geleneksel modellere göre daha iyi performans sergilemektedir[53].

SVM algoritması, ilk kez 1995 yılında Vapnik ve Cortes tarafından önerilmektedir. İstatistiksel öğrenme ve yapısal risk minimizasyon teorisine dayalı olarak geliştirilen bu makine öğrenme yöntemi, genellikle bir tahmin yöntemi olarak kullanmaktadır. SVM'nin amacı, giriş alanlarını doğrusal olmayan bir eşlemleme aracılığıyla yüksek boyutlu alanlara dönüştürmektir[57], [58], [59]. SVM yöntemi, aşırı uyum sorununu ve yerel minimumları aşabilme yeteneği nedeniyle sinir ağlarına göre daha etkili bir alternatiftir[60].

SVM modelleri, rüzgar ve güneş enerjisi tahminlerinde yaygın olarak kullanılmaktadır. Son derece hassas olup karmaşık ilişkileri işleyebilmektir. Ancak SVM modelleri, yorumlanabilirlik ve hiperparametre seçimi konusundaki sınırlamaları nedeniyle bazı dezavantajlara sahiptir, veri içindeki zaman bağımlılıklarını yakalamakta zorlanabilmektedir[55].

SVM yöntemi, kendine özgü özellikleriyle bilinir ve şu şekilde özetlenebilir:

I. Yüksek doğruluk ve sağlamlık gösterir,

II. Karmaşık doğrusal olmayan karar sınırlarını etkin bir şekilde modelleyebilir,

III. Aşırı uyumu birçok alternatif modele göre daha başarılı bir şekilde önler,

IV. Eğittiği modelin kısa ve öz bir temsilini sunar,

V. Desen tanıma, regresyon ve sınıflandırma gibi uygulamalarda esneklik sunar[61].

Min Ding ve meslektaşları, rüzgar enerjisini etkileyen çeşitli faktörleri dikkate alan bir zaman serisi yöntemi olan hibrit çekirdek en küçük kareler destek vektör makinesi (HKLSSVM) kullanarak bir model önermiştir. Araştırmacılar, önerilen çerçeveyi dalgalet ve deneysel mod dekompozisyon modelleri ile karşılaştırmıştır. Yapılan karşılaştırmalar sonucunda, önerilen modelin diğer modellere göre daha iyi performans sergilediği belirlenmiştir[62].

Ling Li ve meslektaşları, SVM ve geliştirilmiş yarasa algoritmasını birleştiren bir hibrit model önermiştir. Yapılan çalışmada, önerilen modelin geriye yayılım sinir ağı ve Gauss süreç regresyonu gibi diğer modellere göre üstün tahmin performansı sergilediği gösterilmektedir[63].

Ji ve meslektaşları, rüzgar enerjisinin tahmininde kaotik analiz temelli bir yaklaşım kullanmaktadır. Bu, bir zaman serisi analizi ve bir faz uzayı yeniden yapılandırma prosedürünü içermektedir. Araştırmacılar öncelikle verilerdeki kaos seviyesini belirlemek için Lyapunov üssünü hesaplamaktadır. Ardından, farklı çok boyutlu regresyon modelleri kullanılarak yakındaki rüzgar çiftliklerinden toplanan zaman serisi verileri analiz edilmektedir. Önerilen çerçeve, kararlılık ve doğruluk açısından klasik LSSVM modelinden daha iyi performans göstermektedir[64].

RF, birden fazla zayıf karar ağacını oylama veya ortalamayla birleştirerek nihai sonuca ulaşan esnek bir makine öğrenme algoritmasıdır, bu da sonucu daha sağlam hale getirmektedir. RF, bir algoritma olan torbalama yöntemini kullanarak birçok karar ağacını birleştirmektedir[65].

RF algoritmasının özünde, verinin hiyerarşik yapısından önceden tanımlanmış özellikleri kullanarak öğrenen Karar Ağaçları (Decision Trees-DT) bulunmaktadır. DT'ler, girdi uzaylarını segmente etme konusunda etkilidir, bu da her alt kümedeki doğrusal modellerin veriyi daha etkili bir şekilde yorumlamasını sağlamaktadır. Standart Yapay Sinir Ağlarının aksine, DT'ler daha küçük veri setleriyle çalışırken bir avantaj sunan daha az eğitim verisine

bağımlıdır. Bir DT'deki her girdi örneği benzersiz bir yol izler, ancak bu basitlik genellikle manuel özellik mühendisliği gerektirmektedir[66].

Sun ve meslektaşları, rüzgar enerjisi değişkenliğini daha iyi yakalayabilen ve tahmin istikrarını sağlayabilen ikincil dekompozisyon, ön-tahmin ve hata analizi gibi unsurlardan oluşan bir hibrit model önermektedir. RF algoritması, rüzgar gücünün düzenli eğilimini belirlemek için kullanılmakta olup K-ortalama ve LSTM'nin birleşimi ise düzensiz bileşenlerin analizinde kapsamlı bir yetenek sağlamaktadır[67].

- ✓ **Derin öğrenme**

Derin öğrenme tabanlı modeller, makine öğrenme yöntemlerinin genişletilmiş bir formu olup birkaç gizli katmana sahip olan yapıları içermektedir. Literatürde yaygın olarak kullanılan üç ana derin öğrenme türü: İstiflenmiş otokodlayıcılar (SAE), derin inanç ağları (DBN) ve derin tekrarlayan sinir ağları (RNN) olarak bilinmektedir[68].

Derin öğrenme, özellikle SAE, derin Boltzmann makineleri (DBM) ve Evrişimli Sinir Ağları (CNN) gibi temel teknikleri kapsamaktadır. İstiflenmiş otokodlayıcılar, otokodlayıcıları temel yapı taşları olarak kullanmakta ve veri uyumu için bir lojistik regresyon katmanı ile birleştirilmiş denetimsiz bir öğrenme bileşenini içermektedir[69]. SAE'nin temel amacı, giriş verilerinin boyutunu indirgeyerek temsili bir elde etmektir.

Zhang ve arkadaşları çoklu rüzgar türbinleri için rüzgar vektörünü (rüzgar hızı ve yönü) ileriye dönük tahmin etmek amacıyla yeni bir derin öğrenme modeli geliştirilmiştir. Model, Konvolüsyonel Minimum Geçit Belleği Sinir Ağı ve Grafik Konvolüsyonel Sinir Ağı kombinasyonuyla, türbinler arasındaki mekansal ilişkiyi dikkate alarak tahmin yapmaktadır. Tibet'ten alınan iki veri setiyle yapılan testler sonucunda, modelinin mevcut yöntemlere göre %90 daha yüksek tahmin doğruluğu sağladığı görülmüştür[70].

Araştırmacılar, modelleri olarak DBM ve SAE modellerini kullanmaktadır. Başlangıçta, giriş birimlerini çıktılara uygun bir dağılım bulmayı amaçlayan üretken bir model olan DBM, çok sayıda gizli Boole birimine sahiptir. Diğer sinir ağlarına kıyasla, hem DBM hem de SAE, yerel minimum sorununu ele almak için eğitim süreçlerini kullanmaktadır[71].

DBM ve SAE'nin eğitim süreci, iki aşamada gerçekleşmektedir. İlk aşama, olumlu başlangıç değerlerinin belirlenmesine odaklanırken, sonraki aşama ağın performansının ayarlanmasını içermektedir[72].

2.2.1.3 Hibrit yöntemler

Hibrit yöntemler, model performansını artırma amacıyla fiziksel ve istatistiksel yöntemleri bir araya getiren teknikler olarak tanımlanmaktadır. Bu teknikler, her bir bireysel modelin güçlü yönlerini kullanarak, mevcut yaklaşımlara kıyasla daha yüksek doğrulukta sonuçlar elde etmeyi hedeflemektedir. Literatür taraması, önerilen yöntemlerin önemli bir bölümünün hibrit yöntemler olduğunu göstermektedir.

Lean Yu ve arkadaşları, karmaşık özelliklere odaklanan bozulma-yeniden yapılandırma-ensemble yaklaşımını kullanarak, kısa vadeli rüzgar enerjisi tahminlerinde doğruluğu artıran yenilikçi bir model geliştirmişlerdir. Bu model, Yapay Zeka (AI), Aşırı Öğrenme Makineleri (ELM), Destek Vektör Regresyonu (SVR) ve ANN gibi referans modelleri geride bırakarak etkinliğini kanıtlamaktadır[73].

Gaiping Sun ve arkadaşları ise, kümeleme ve dalgacık tabanlı sinir ağlarını birleştiren bir hibrit model geliştirerek, benzer rüzgar hızı desenlerini tanımlamak için Öklid Mesafesi ve Kosinüs Açısı ölçümlerini kullanmaktadır. Bu yaklaşım, diğer modellere kıyasla tahmin doğruluğunda önemli iyileştirmeler sağlamaktadır[74].

Bo Gu ve ekibi, zaman serisi tahmininde etkili olan tekrarlayan sinir ağı LSTM'i kullanarak, 4 saatlik, 24 saatlik ve 72 saatlik tahminler için üstün doğrulukta sonuçlar elde eden bir model önermişlerdir. Bu sonuçlar, BP sinir ağı, Parçacık Sürü Optimizasyonu (PSO) ve hibrit PSO-BP modeline kıyasla daha iyidir[75].

Peng Lu ve meslektaşları, tarihsel rüzgar enerjisi ve temel meteorolojik verileri kullanarak CNN ve LSTM'nin birleşimine dayanan bir tahmin modeli geliştirmektedir. Anahtar meteorolojik faktörlerin seçimi, veri ayrıştırma, bütünleşik model yapısı oluşturma ve iyileştirme stratejisi içeren entegre bir tahmin çerçevesi sunmaktadır. CNN-LSTM modeli,

gün öncesinden rüzgar gücünü etkili bir şekilde tahmin ederken tahmin doğruluğunu ve güvenilirliğini artırmaktadır[76].

Jinhua Zhang ve meslektaşları, BP, Dalgacık ve İlgili Vektör Makinesi (RVM) kullanarak birleştirilmiş bir tahmin modeli önermektedir. Bu hibrit yaklaşım, her yöntemden elde edilen bireysel sonuçların doğruluğunu artırmayı amaçlamaktadır. Çalışma sonuçları bu birleşik sistemin her yöntemin ayrı sonuçlarını geride bıraktığını göstermektedir[77].

David A. Wood, Çoklu Giriş Değişkenleri arasındaki belirgin ilişkileri tüm veri setinde tanımlama yeteneğini vurgulamaktadır. Bu özellik, ilişkileri dikkate alan veri setindeki çoğu makine öğrenme algoritmasını ayırmakta ve bu giriş değişkeni ilişkilerini kullanarak tahmin yöntemlerini geliştirmektedir[78].

Pei Du ve meslektaşları, tahmin doğruluğunu artırmak için tasarlanmış bir hibrit model tanıtmaktadır. Yaklaşımları, gürültüyü kaldırmak ve birincil veri özelliklerini çıkarmak için tam bir ensemble empirik mod ayrıştırma ile başlamaktadır. Ardından, optimize edilerek geliştirilmiş dalgacık sinir ağı son derece doğru ve stabil tahminler üretmek için kullanılmaktadır. Dört vaka çalışması ve 18 karşılaştırma modeli ile yapılan karşılaştırmalı değerlendirmeler, hibrit modelin daha düşük ortalama mutlak yüzde hatasına yol açtığını göstermektedir[79].

Zhang ve arkadaşları, üç rüzgar çiftliğindeki güç üretimini tahmin etmek ve karşılaştırmak için SVM, Dalgacık ve RBF'yi kullanmaktadır. Simülasyon sonuçları, SVM yönteminin daha yüksek doğruluk ve verimlilik gösterdiğini ortaya koymaktadır[80].

AlShafeey ve Csaki rüzgar enerjisinin kısa ve uzun vadeli tahminleri için dinamik bir hibrit model geliştirilmesini ele almaktadır. Model, ANN, SVM ve K-En Yakın Komşu algoritmalarını birleştirerek, gerçek zamanlı veriler doğrultusunda en uygun tahmin yöntemini seçmek üzere tasarlanmıştır. 2 MW'lık bir rüzgar türbininden elde edilen veri seti, kısa vadeli (15 dakikalık aralıklarla) ve uzun vadeli tahminlerde modelin doğruluğunu kanıtlamıştır. Bu hibrit model, hem operasyonel hem de stratejik planlama süreçlerinde rüzgar enerjisi tahminlerinin doğruluğunu artırarak şebeke operatörleri ve rüzgar santrali yönetimi için değerli bir araç sunmaktadır[81].

Naik ve meslektaşları, Evaporasyon ve Yağış Tabanlı Su Döngüsü Optimizasyon Algoritması (VAPWCA) kullanarak optimize edilen Çoklu Çekirdekli Regularize Psödo-Ters Sinir Ağı (MKRPINN) tabanlı yeni bir hibrit teknik önermektedir. Çeşitli modellerle yapılan karşılaştırmalı değerlendirmeler, bu modelin RMSE, MAPE, MAE ve CC2 gibi performans ölçütleri temelinde üstünlüğünü göstermektedir[82].

Kai Qu ve ekibi, doğal dil işleme alanında yaygın olarak kullanılan Transformer modelini rüzgar enerjisi tahminine uygulamaktadır. Bu yeni yaklaşım, birden fazla rüzgar çiftliği arasındaki korelasyon düzeylerini doğru bir şekilde çıkararak, kesin rüzgar enerjisi tahminleri sağlamakta ve vaka çalışmalarında diğer yöntemleri geride bırakmaktadır[83].

Xin Liu ve arkadaşları, uyarlanabilir rüzgar enerjisi tahminleri için bir parametrik sinüs aktivasyon fonksiyonu (PSAF) algoritması ile bir SRNN sunmaktadır. Model, NERL rüzgar verilerine uygulandığında SVR, ANN, RNN, LSTM ve GRU ile karşılaştırıldığında üstün performans sergilemektedir[84].

Ahmed ve arkadaşları rüzgar enerjisinden saatlik elektrik üretimi tahmini için yeni bir entegre yaklaşım sunmaktadır. Model, ilk seviyede XgBoost, CatBoost ve Rastgele Orman algoritmalarını kullanarak ara tahminler oluşturur. Ardından, bu ara tahminler doğrusal regresyon ile ikinci seviyede işlenerek nihai üretim tahmini yapılır. Geliştirilen model, XgBoost, CatBoost, RF, LSTM ve GRU gibi mevcut yöntemlerle karşılaştırılmış ve her iki veri seti üzerinde de daha yüksek doğruluk göstermiştir. Özellikle, modelin Türkiye türbini veri setinde MAE değerinde %1.9 ve %26.65 oranında iyileşme sağladığı belirtilmiştir. Bu sonuçlar, önerilen entegre modelin rüzgar enerjisi tahmininde mevcut yöntemlere kıyasla üstün bir performans sergilediğini ortaya koymaktadır[85].

Xiong ve ekibi, gerçek rüzgar türbini verilerini kullanarak kısa vadeli rüzgar tahmini için CNN ve LSTM'yi birleştiren AMC-LSTM adında bir hibrit model önermektedir. Bu model, çok ölçekli özellikleri etkili bir şekilde entegre ederek tahmin performansını artırmaktadır[86].

Toubeau ve ekibi, karmaşık zamansal rüzgar enerjisi dinamiklerini yakalamak için LSTM kullanmaktadır ve bir Belçika vaka çalışmasında optimal yeniden kalibrasyonun tahmin güvenilirliğini artırdığını göstermektedir[87].

Zhang ve arkadaşları, rüzgar türbini güç tahmini için LSTM'ye dayalı derin öğrenme ağı kullanmaktadır ve hata dağılımlarını analiz etmek için bir Gauss karışım modeli (GMM) kullanmaktadır. LSTM, doğruluk ve yakınsama hızı açısından diğer yöntemleri geride bırakmaktadır[88].

Duan ve arkadaşları, LSTM temelli güçlü bir hibrit rüzgar enerjisi tahmin modeli önermekte ve bu model Correntropy-enhanced Variational Mode Decomposition (IVMD) ile Sample Entropy (SE) yöntemlerini içermektedir. İki Çin rüzgar çiftliğinden alınan gerçek verilerle yapılan deneyler, yöntemin geleneksel yaklaşımlara kıyasla etkinliğini göstermektedir[89].

Çevik ve meslektaşları, ANFIS, ANN ve SVR kullanarak üç aşamalı bir rüzgar enerjisi tahmin yöntemi tanıtmaktadır. EMD ve Stationary Wavelet Decomposition (SWD) ön işleme yöntemleri kullanılarak elde edilen çok aşamalı model, etkili bir rüzgar enerjisi tahmini sağlamaktadır[90].

Ling-Ling Li ve meslektaşları, Geliştirilmiş Yumurta Arama Algoritması Optimizasyonu ve Extreme Learning Machine (ENCSA-ELM) modeli ile son derece doğru kısa vadeli rüzgar gücü tahmini sağlamaktadır. Model, geleneksel yöntemlere ve diğer ELM-optimizasyon algoritmalarına göre üstün performans göstermektedir[91].

Ahmad ve arkadaşları, güneş ve rüzgar enerjisi tahminleri için Gauss GPR çerçevesini kullanmaktadır. İki zaman çözünürlüğünde iyi performans gösteren model, veri içindeki gücü tahmin etmek için etkili bir yöntem sunmaktadır[92].

Liu ve arkadaşları, ANFIS, BPNN, RBFNN ve LSSVM'i içeren yeni bir hibrit metodoloji sunmaktadır. Pearson korelasyon katsayısına dayalı bir veri ön işleme yöntemi kullanan bu metodolojinin bireysel modellere kıyasla tahmin kesinliğini iyileştirdiği gösterilmektedir[93].

Qin ve arkadaşları, veri karakteristiklerini öğrenmek için dört DNN modeli geliştirilen iki aşamalı bir tahmin yöntemi önermekte ve farklı yöntemlerle model ekstrapolasyonunu araştırmaktadır. Bu model, mevcut modellere göre daha iyi performans göstermektedir[94].

Dadkhah ve meslektaşları, rüzgar hızı, rüzgar yönü ve ek iklim faktörlerini içeren bir veri seti kullanarak doğru güç çıkışı tahmini için bir yaklaşım önermektedir. Bu faktörler, tahmin yönteminde önemli bir rol oynamaktadır[95].

Ding ve arkadaşları, kısa vadeli rüzgar enerjisi tahminleri için NWP rüzgar hızı hatalarını düzelten bir model sunmaktadır. Bu model, hataları çift yönlü tekrarlayan birim sinir ağları kullanarak düzeltmekte ve NWP rüzgar hızı serilerini yeniden düzenlemektedir. Önerilen model, diğer yöntemlere kıyasla kısa, orta ve uzun vadeli tahminlerde üstünlük sağlamaktadır[96].

Jiandong ve arkadaşları, doğruluk ve kararlılığı artırmak amacıyla ayrıştırma, doğrusal olmayan ağırlıklı kombinasyon ve iki derin öğrenme modelini birleştiren bir model geliştirmektedir. Bu yöntem, mevcut yaklaşımlara kıyasla üstün performans sergilemektedir[97].

Ghoushchi ve ekibi, bir rüzgar çiftliğinde güç çıkışını tahmin etmek için genişletilmiş bir bulanık dalgalet sinir ağı kullanmaktadır. Bu yaklaşım, kısa vadeli tahminlerde geleneksel yöntemlere üstünlük sağlamaktadır[60].

Xing ve ekibi, rüzgar hızı tahminleri için yeni bir metodoloji sunmaktadır. Bu metodoloji, deneysel sonuçlara göre test edilen modellere kıyasla nokta ve aralık tahminlerinde üstün doğruluk sağlamaktadır[98].

Viet ve arkadaşları, planlanmış rüzgar enerjisi geliştirme politikalarını dikkate alan bir tahmin yöntemi önermekte ve bu yöntem belirli bir rüzgar çiftliğinde etkinliğini kanıtlamaktadır[99].

Sun ve arkadaşları, VMD ve LSTM tekniklerini birleştiren yeni bir rüzgar enerjisi tahmin modeli sunmaktadır. Bu model tahmin doğruluğunu önemli ölçüde artırmaktadır[100].

Kumar ve meslektaşları, dört makine öğrenimi algoritmasının güçlü yanlarını kullanan bir model ansamblisi kullanarak tahmin doğruluğunu artırmayı savunmaktadır. Önerilen model çeşitli aylar için, Hindistan'daki gerçek rüzgar çiftliği verileriyle yapılan değerlendirmede bireysel modellere üstünlük göstermektedir[101].

Maurya ve Goswami, rüzgar gücü tahmininde Çok Değişkenli Zaman Serisi Tahmini'nin (MTFS) önemini vurgulamaktadır. Kompleks Empirik Mod Ayrıştırma (CEEMDAN), Uyarlanabilir Gürültü Teknikleri ve Dikkat tabanlı bir yaklaşım kullanarak gürültüyü azaltmak ve etkili özellikler seçmektedir. Genetik Algoritma ile hiperparametre optimizasyonu yapılmakta ve yaklaşımları, RMSE ve MAE puanları açısından dikkat tabanlı olmayan modellere üstünlük sağlamaktadır[102].

Zheng ve arkadaşları, deniz üstü rüzgar enerjisi tahmini için bir Derin Sinir Ağı (DNN) yöntemi geliştirmekte ve girdi verilerinin belirsizliğini ele almak için kümeleme analizini kullanmaktadır. Önerilen yöntem, BPNN ve WNN yöntemlerine kıyasla %40 daha yüksek tahmin doğruluğu sağlamaktadır[103].

Singh ve arkadaşları, Hindistan'daki rüzgar hızı ve gücünü tahmin etmek için Yapay Sinir Ağı tabanlı yaklaşımlar sunmakta ve birden çok kaynaktan gelen verileri kullanmaktadır. Rüzgar gücü tahmini, rüzgar hızı tahminine göre daha düşük hata oranına sahip olmaktadır[104].

Weidong ve arkadaşları, rüzgar hızı ve güç üretimi tahmini için üç genetik sinir ağı (NN) tekniğini karşılaştırmakta ve Genetik Algoritma BP'nin Standart BP ve Momentum BP'ye göre daha etkili ve doğru olduğunu bulmaktadır[105].

Sun ve Zhao, aralık tahminlerinde yüksek performans sergileyen Değişken Mod Ayrıştırma (VMD), ConvLSTM ve hata analizini içeren kısa vadeli rüzgar enerjisi tahmini için birleşik bir model önermektedir[106].

Jeyakumar ve arkadaşları, kısa vadeli rüzgar enerjisi tahmini için Markov zinciri tabanlı modeller önermekte ve bu modeller mevsimsel değişkenliklerle birinci ve ikinci dereceden modelleri içermektedir. İkinci derece modeller, özellikle yüksek ve düşük rüzgar rejimlerinde yüksek doğruluk sergilemektedir[107].

2.3. Rüzgar Enerjisi Tahminindeki Zorluklar ve Avantajlar

Rüzgar enerjisinden elektrik enerjisi üretimi tahmin edilmesi, enerji sistemlerinin etkin yönetimi ve karar verme süreçlerinin optimizasyonu açısından hayati bir öneme sahiptir. Bu tahminler, üretim ile tüketim arasında bir denge kurarak enerji piyasalarının istikrarlı ve verimli bir şekilde işlemesini sağlamakta ve böylece rüzgar enerjisinden elektrik enerjisi üretiminin tüm potansiyelinden yararlanılmasını mümkün kılmaktadır. Ancak rüzgar enerjisinden elektrik enerjisi üretimi tahmin süreçleri, rüzgar hızındaki doğal değişkenlikten kaynaklanan önemli zorluklarla karşı karşıya kalmaktadır. Ayrıca öngörülebilirliği artırma çabası, nitelikli ve kapsamlı veri setlerine olan ihtiyacı artırmakta ve tahmin modellerinin doğruluğu üzerinde etkili olmaktadır. Buna karşın yapay zeka ve makine öğrenimi teknolojilerindeki ilerlemeler, tahminlerin hassasiyet ve güvenilirliğini iyileştirme potansiyeli taşımaktadır.

Hibrit modelleme teknikleri, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu artırmada kritik bir avantaj sunmaktadır. Bu teknikler, farklı tahmin modellerinin güçlü yönlerini birleştirerek daha kapsamlı ve doğru tahminler üretmektedir. Global ölçekteki meteorolojik veriler ve yerel hava durumu örüntülerinin detaylı analizi, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde mevcut yöntemlerin sınırlılıklarını aşmak ve enerji sistemlerinin genel performansını iyileştirmek için kullanılabilmektedir.

Bu bağlamda, tahmin süreçlerinin ve kullanılan modellerin sürekli gözden geçirilmesi ve iyileştirilmesi, rüzgar enerjisinden elektrik enerjisi üretiminin daha etkili bir şekilde yönetilmesini ve enerji sistemlerine entegrasyonunu sağlamak açısından gereklidir. İleriye yönelik araştırmalar, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu ve güvenilirliğini artırmanın yanı sıra, enerji piyasalarının ve politika yapım süreçlerinin daha da geliştirilmesine katkıda bulunabilecektir. Bu kapsamda, modelleme tekniklerindeki ilerlemeler, enerji sistemlerinin geleceği açısından stratejik bir öneme sahiptir ve bu alandaki disiplinler arası çalışmaların teşvik edilmesi önem taşımaktadır.

2.4. Literatürdeki Boşluklar

Mevcut literatürde rüzgar enerjisinden elektrik enerjisi üretimi tahmin modelleri üzerine yapılan çalışmalar, makine öğrenimi ve hibrit modelleme tekniklerinin kullanımındaki gelişmeleri detaylıca belgelemektedir. Bu teknolojiler, tahmin doğruluğunu iyileştirme ve rüzgar enerjisinin değişken doğasıyla başa çıkma konusunda önemli adımlar atmıştır. Ancak bu alanda, özellikle yüksek kaliteli veri setlerine erişim ve çeşitli modellerin entegrasyonu gibi alanlarda belirgin eksiklikler tespit edilmiştir. Bu çalışma, enerji sektörünün karşı karşıya kaldığı bu temel zorluklara odaklanmakta ve rüzgar enerjisinden elektrik enerjisi üretimi tahmin süreçlerinin optimizasyonunu hedeflemektedir.

Veri toplama ve işleme metodolojilerinin geliştirilmesi, veri kalitesinin artırılması ve daha geniş veri erişilebilirliğinin sağlanması, öngörü süreçlerinin temelini oluşturmaktadır. Karmaşık arazi şartlarının ve atmosferik koşulların modellemesinin iyileştirilmesi ile geniş kapsamlı rüzgar enerjisinden elektrik enerjisi üretimi tahminleri için geliştirilen modeller, gerçek dünya verilerine daha iyi uyum sağlamakta ve rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin genel doğruluğunu artırmaktadır. Hibrit modellerin gelişimi, çeşitli tahmin metodolojilerinin güçlü yönlerini bir araya getirerek daha tutarlı ve kapsamlı tahminlerin oluşturulmasını sağlamaktadır. Bu, rüzgar enerjisinden elektrik enerjisi üretimi kaynaklarının entegre edilmesi ve enerji sistemlerinin genel verimliliğinin artırılması yönünde kritik bir adım teşkil etmektedir.

Bu bağlamda, rüzgar enerjisinden elektrik enerjisi üretimi tahmin modellerinin sürekli iyileştirilmesi, yenilenebilir enerji kaynaklarının yönetimini ve enerji sistemlerinin sürdürülebilirliğini destekleyici stratejik öneme sahiptir. İleri teknolojik altyapılar ve interdisipliner araştırmalar, bu süreçlerin daha da gelişmesini sağlayacak ve rüzgar enerjisinden elektrik enerjisi üretiminin potansiyelinden tam anlamıyla yararlanılmasına olanak tanıyacaktır. Sonuç olarak, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerindeki doğruluğun ve güvenilirliğin artırılması, enerji piyasalarının istikrarını sağlamakta ve sürdürülebilir enerji sistemlerine geçişte temel bir rol oynamakta, yenilenebilir enerjinin etkin kullanımı için sağlam bir zemin oluşturmaktadır.

2.5. Elektrik Piyasaları

Elektrik piyasası, elektrik enerjisinin üretimi, dağıtımı ve ticaretinin yapıldığı, düzenlenmiş veya serbest piyasa koşullarında faaliyet gösteren bir pazar yeridir. Bu piyasa, elektrik üreticileri, tüketicileri, dağıtım şirketleri ve aracıları bir araya getirerek, elektrik enerjisinin alıcılar ve satıcılar arasında etkin bir şekilde dolaşımını sağlamaktadır. Şekil 2.5'te Türkiye'deki elektrik piyasaları sınıflandırılmıştır[108].

Elektrik piyasa fiyatları, bir dizi faktörün karmaşık etkileşimleri sonucunda şekillenmektedir. Bu faktörler arasında yeni kapasite yatırımları, enerji politikaları ve piyasa yapısı, piyasa oyuncularının fiyat stratejileri ve manipülasyonları, yenilenebilir enerji kaynaklarının hacmi ve üretim değişkenlikleri, yakıt ve kaynak fiyatlarıyla işletme maliyetleri, arz-talep dengesi, ekonomi, nüfus ve sanayileşme trendleri, sistemdeki planlı veya plansız bakım ve onarımlar, hava şartları, sezonsallık ve tatil dönemleri gibi zaman faktörleri ile geçmiş elektrik fiyat arşivleri yer almaktadır. Bu çok boyutlu etmenler, elektrik piyasası fiyatlarının belirlenmesi ve değişkenliğinin anlaşılmasında merkezi bir rol oynamaktadır. Örneğin, hava şartlarının iyileşmesi yenilenebilir enerji kaynaklarının daha fazla kullanımını teşvik edebilmekte, bu da arzın artmasına ve potansiyel olarak fiyatların düşmesine yol açabilmektedir. Benzer şekilde, yakıt fiyatlarındaki artışlar maliyetlerin yükselmesine ve dolayısıyla elektrik piyasa fiyatlarının yükselmesine sebep olabilmektedir. Piyasa oyuncularının stratejileri ve eylemleri de fiyatlar üzerinde manipülatif etkilere sahip olabilirken ekonomik ve demografik trendler uzun vadeli arz ve talep beklentilerini şekillendirmektedir[108].

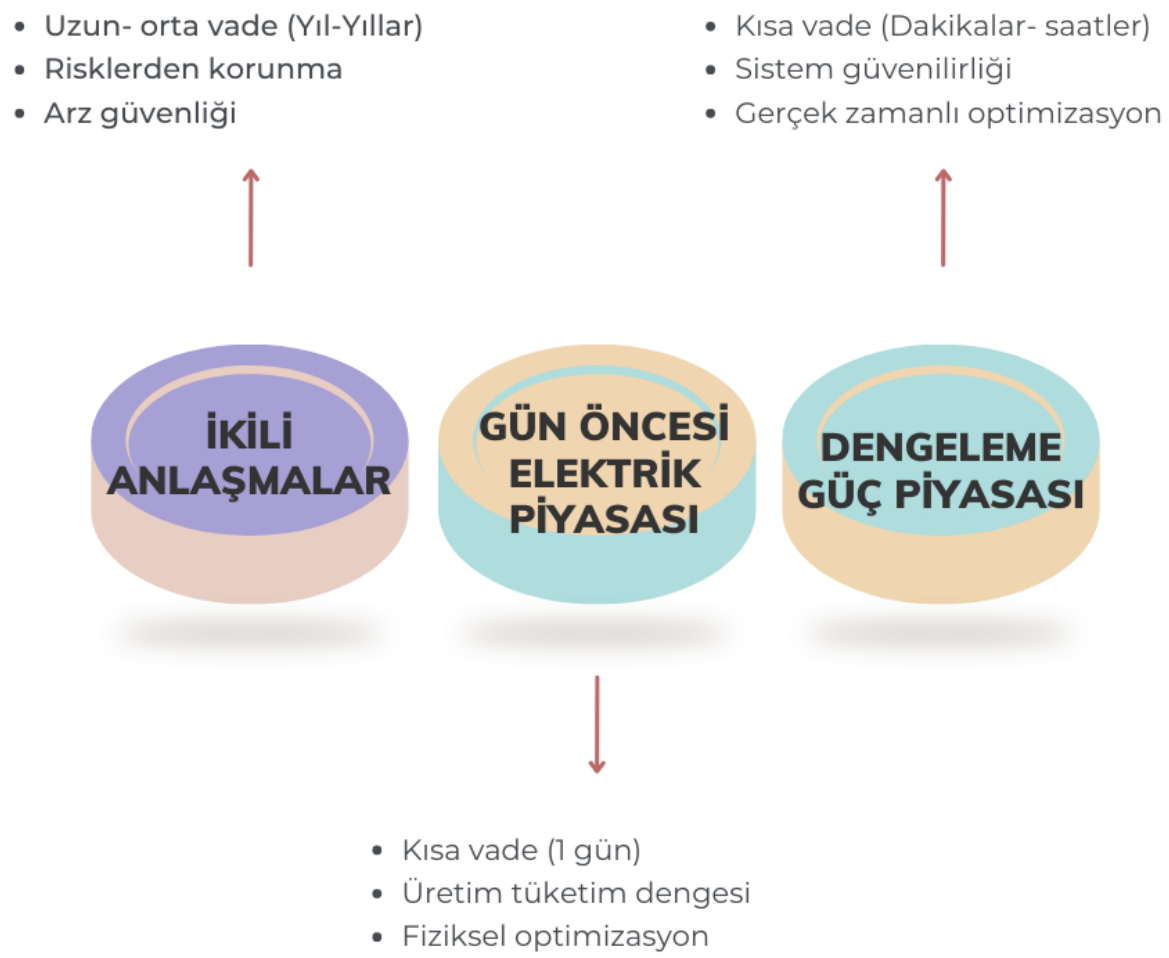

Şekil 2.5: Elektrik Piyasalarının Sınıflandırılması

Türkiye'de elektrik piyasasının serbestleştirilmesine yönelik olarak, gün öncesi piyasası ve dengeleme güç piyasası 1 Aralık 2011 tarihinde hayata geçirilmiştir. Gün öncesi piyasada, şebeke katılımcıları piyasa fiyatlarını temel alarak elektrik arz ve taleplerini düzenleyebilmektedir. Bu piyasada, fiyat teklif eğrilerinin kesişme noktası piyasa fiyatını ve miktarını belirlerken dengeleme piyasası üretim planlarındaki sapmaları düzeltmekte ve enerji talebinin artışı, fiyatları yükseltmektedir. Rüzgar enerjisinden elektrik enerjisi üretimi yapan santraller de bu piyasada aktif rol oynamakta ancak rüzgara bağımlı oldukları için üretimlerini zaman kaydıramamaktadır[109].

Gün öncesi piyasası, elektrik enerjisinin bir gün öncesinde planlandığı ve ticaretinin yapıldığı bir piyasadır. Enerji Piyasaları İşletme A.Ş. tarafından yürütülen bu piyasa, üretici ve tedarikçi tarafların arz ve talep tahminlerine dayalı olarak fiyatın oluştuğu bir mekanizmadır. Bu piyasa, elektrik üreticilerinin ve tüketicilerinin elektrik enerjisini önceden satın alarak arz ve talep dengesi oluşturmalarını sağlar[110].

Wang ve arkadaşları, rüzgar enerjisi üretim tahminlerinin elektrik piyasası üzerindeki etkilerini değerlendirmiştir. Araştırmalarında, gün öncesi tahminler ile 4 saat öncesi tahminlerinin şebeke operasyonları açısından önemini vurgulamışlardır. Gün öncesi tahminler, rüzgar enerjisinin arzını planlama ve birim taahhütlerinin düzenlenmesi için kritik rol oynamaktadır. 4 saat öncesi tahminleri ise gerçek zamanlı talep ve arz dengesinin sağlanmasında önemli bir yere sahiptir. Çalışmada, gün öncesi tahminlerin doğruluğunun artırılmasının piyasa maliyetlerinde %4,47'ye kadar tasarruf sağlayabileceği ve arz-talep dengesizliğini minimize ederek enerji sistemlerinin verimliliğini artırabileceği belirtilmektedir[111].

Exizidis ve arkadaşlarının çalışmasında belirtildiği gibi, elektrik piyasasında rüzgar enerjisinin entegrasyonu, hem kısa vadeli piyasa kararlarını hem de operasyonel planlamayı önemli ölçüde etkilemektedir. Gün öncesi piyasa kararları genellikle rüzgar enerjisi tahminlerine dayanarak alınmaktadır ve bu tahminlerin doğruluğu, gerçek zamanlı dengesizlikleri azaltmada kritik bir rol oynamaktadır. Tahminlerdeki belirsizlikler, piyasa maliyetlerini artırabilir ve dengesizliklerin giderilmesi için ek esnek kaynakların devreye sokulmasını gerektirebilir. Bununla birlikte, rüzgar enerjisi tahminlerinin paylaşıldığı durumlarda, daha doğru piyasa tahminleri yapılmakta ve bu da sistem maliyetlerini azaltarak piyasaların daha verimli işlemesini sağlamaktadır[112].

3. MATERYAL VE YÖNTEM

3.1. Araştırma Tasarımı

Bu çalışma, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu ve güvenilirliğini artırmaya yönelik yenilikçi bir hibrit makine öğrenimi modelinin geliştirilmesi ve kapsamlı bir şekilde değerlendirilmesine odaklanmaktadır. Şekil 3.1'de tez çalışmasının iş akışı görülmektedir. Araştırmanın temeli, geniş bir veri seti üzerinden gerçekleştirilen derinlemesine analizler ve gelişmiş modelleme tekniklerinin uygulanmasına dayanmaktadır. Araştırmanın ilk aşaması, rüzgar enerjisinden elektrik enerjisi üretimi ile ilgili mevcut verilerin toplanması ve bu veriler üzerinden detaylı bir analiz yapılmasıdır. Bu süreç, tahmin modelinin geliştirilmesi için gerekli olan yüksek kaliteli ve kapsamlı veri setlerinin oluşturulmasını içermekte olup araştırmanın başarısında kritik bir öneme sahiptir.

Araştırma tasarımı, üç temel aşamadan oluşmaktadır: Detaylı veri toplama ve veri ön işleme, yenilikçi modelleme tekniklerinin geliştirilmesi ve elde edilen modelin kapsamlı bir şekilde değerlendirilmesi. Veri toplama sürecinde, rüzgar hızı, rüzgar yönü, sıcaklık, basınç ve diğer ilgili çevresel parametrelerden oluşan zengin veri setleri titizlikle toplanmaktadır. Bu süreçte, veri kalitesini maksimize etmek amacıyla çeşitli kaynaklardan yararlanılmakta ve veri toplama yöntemlerinin doğruluğu sürekli olarak gözden geçirilmektedir.

Veri ön işleme aşamasında, eksik veri düzeltme, gürültü azaltma, veri normalizasyonu ve diğer önemli veri temizleme işlemleri gerçekleştirilmektedir. Bu aşama, modelin eğitimi ve test edilmesi süreçlerinde kullanılacak olan veri setlerinin güvenilirliğini ve tutarlılığını sağlamak açısından hayati öneme sahiptir. Ayrıca bu aşamada yapılan analizler, model geliştirme sürecinde karşılaşılabilecek potansiyel sorunların önceden tespit edilmesine ve giderilmesine olanak tanımaktadır.

Model geliştirme aşamasında, RF, SVM ve ANN gibi çeşitli ileri düzey makine öğrenimi teknikleri uygulanmaktadır. Her bir teknik, belirli avantajları ve özellikleri nedeniyle seçilmiş olup bu tekniklerin güçlü yönleri daha sonra geliştirilecek olan hibrit modelin temelini oluşturmaktadır. Hibrit modelin geliştirilmesi süreci, bu farklı modellerin tahmin

kabiliyetlerini birleştirerek rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde daha yüksek bir doğruluk seviyesine ulaşmayı amaçlamaktadır.

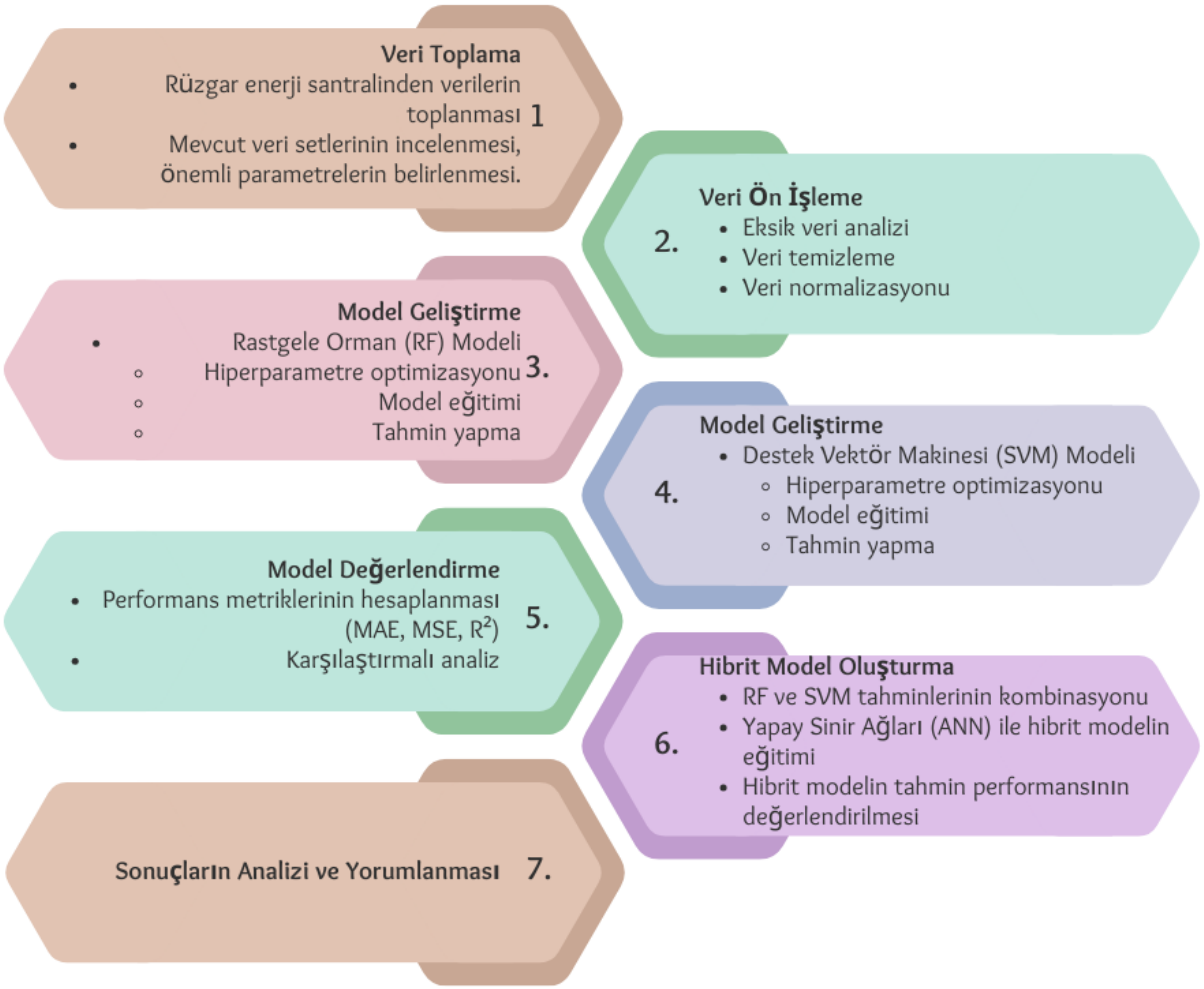

Şekil 3.1: İş Akışı

Model değerlendirme aşamasında, geliştirilen hibrit modelin performansı, geniş bir yelpazede istatistiksel ölçütler kullanılarak detaylı bir şekilde analiz edilmektedir. Bu ölçütler, modelin tahmin doğruluğunu, güvenilirliğini ve uygulanabilirliğini değerlendirmek için kritik öneme sahiptir. Performans metrikleri arasında MAE, MSE ve R^2 gibi ölçütler dikkatlice incelenmektedir. Ayrıca, modelin dayanıklılığını ve çeşitli koşullara adaptasyon

yeteneğini test etmek amacıyla, farklı zaman aralıklarını kapsayan çeşitli eğitim ve test veri setleri kullanılmaktadır. Bu kapsamlı değerlendirme, modelin gerçek dünya koşullarında nasıl performans göstereceğine dair önemli içgörüler sağlamaktadır.

Bu araştırma, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu ve güvenilirliğini artırmada makine öğrenimi tekniklerinin nasıl etkin bir şekilde kullanılabileceğine dair değerli bilgiler sunmaktadır. Hibrit modelin geliştirilmesi, enerji sektöründeki karar vericilere ve mühendislere, rüzgar enerjisinden elektrik enerjisi üretimi kaynaklarının planlanması ve yönetilmesi konusunda güçlü bir araç sunmaktadır. Ayrıca bu çalışma, rüzgar enerjisinden elektrik enerjisi üretimi tahmin modellerinin gelecekteki gelişimine yönelik bir yol haritası sağlayarak yenilenebilir enerji alanında sürekli iyileştirme ve inovasyonun önemini vurgulamaktadır.

Rüzgar enerjisinden elektrik enerjisi üretimi tahmin modellerinin geliştirilmesi ve değerlendirilmesi sürecinde elde edilen bulgular, enerji sistemlerinin daha verimli ve sürdürülebilir bir şekilde yönetilmesine önemli katkılar sağlamaktadır. Özellikle yenilenebilir enerji kaynaklarının giderek daha fazla kullanıldığı günümüzde, bu bulgular, enerji üretimi ve tüketimi arasındaki dengenin korunmasında kritik bir rol oynamaktadır. Bu nedenle, bu çalışma rüzgar enerjisinden elektrik enerjisi üretimi tahminlerindeki doğruluğu artırma çabalarına önemli bir katkı sunmakta ve gelecekte yapılacak araştırmalara ilham vermektedir.

3.2. Çalışma Alanının Tanımı

Bu araştırma, Türkiye'deki Sancak Enerji Yahyalı Rüzgar Enerjisi Santrali verileri ile gerçekleştirilmiştir. Çalışma alanı, yüksek rüzgar enerjisi potansiyeline sahip ve mevcut rüzgar türbinleri ile enerji üretimi yapılan bir bölgedir. Tesiste, Nordex N117 model 22 adet rüzgar türbini bulunmaktadır. Türbinler 1500 ile 1750 metre arasında değişen yüksekliklerde yer almaktadır.

Yahyalı rüzgar santralinde 91 metre göbek yüksekliği, 117 metre rotor çapı ve 2400 kW anma gücüne sahip 22 adet Nordex-N117 2,4 MW rüzgar türbini bulunmaktadır. Şekil 3.2’de

kullanılan türbinin genel bakış çizimi bulunmaktadır[113]. Bu rüzgar türbinlerinin devreye girme rüzgar hızı 3 m/s, devreden çıkan rüzgar hızı ise 20 m/s'dir.

Bu çalışma alanı tanımı, araştırmanın uygulanabilirliğinin ve elde edilen sonuçların anlaşılmasını kolaylaştırmaktadır. Ayrıca rüzgar enerjisi tahmin modellerinin geliştirilmesi ve değerlendirilmesi sürecinde kullanılan veri setlerinin kapsamı ve niteliği hakkında önemli bilgiler sağlamaktadır. Tesisteki rüzgar türbinlerinden toplanan veriler, rüzgar enerjisi üretim tahminlerini iyileştirmeye yönelik makine öğrenimi modellerinin geliştirilmesi için temel oluşturmaktadır.

Bu çalışmada Python programlama dili kullanılmıştır. Python, son derece okunabilir ve yazımı kolay bir programlama dili olup özellikle veri bilimi, makine öğrenimi ve yapay zeka alanlarında veri işleme, istatistiksel analiz ve algoritmik problem çözme gibi görevler için sıklıkla tercih edilmektedir. Python, zengin kütüphaneleri ve esnek yapısıyla bilim ve mühendislik alanlarında da geniş bir kullanım alanına sahiptir.

Python kütüphanelerinden Pandas, veri analizi için güçlü ve hızlı araçlar sunmaktadır. İndekslenmiş tablolar, zaman serileri ve diğer veri yapıları ile çalışmayı mümkün kılan DataFrame'lerle işlemleri kolaylaştırmaktadır. Bir diğer önemli kütüphane olan NumPy ise, büyük çok boyutlu diziler ve matematiksel işlemlerle çalışmayı basitleştirmektedir. Pandas ve NumPy'nin birlikte kullanılması, veri ön işleme, temizleme ve analitik işlemlerin verimli bir şekilde yapılmasına olanak tanımaktadır.

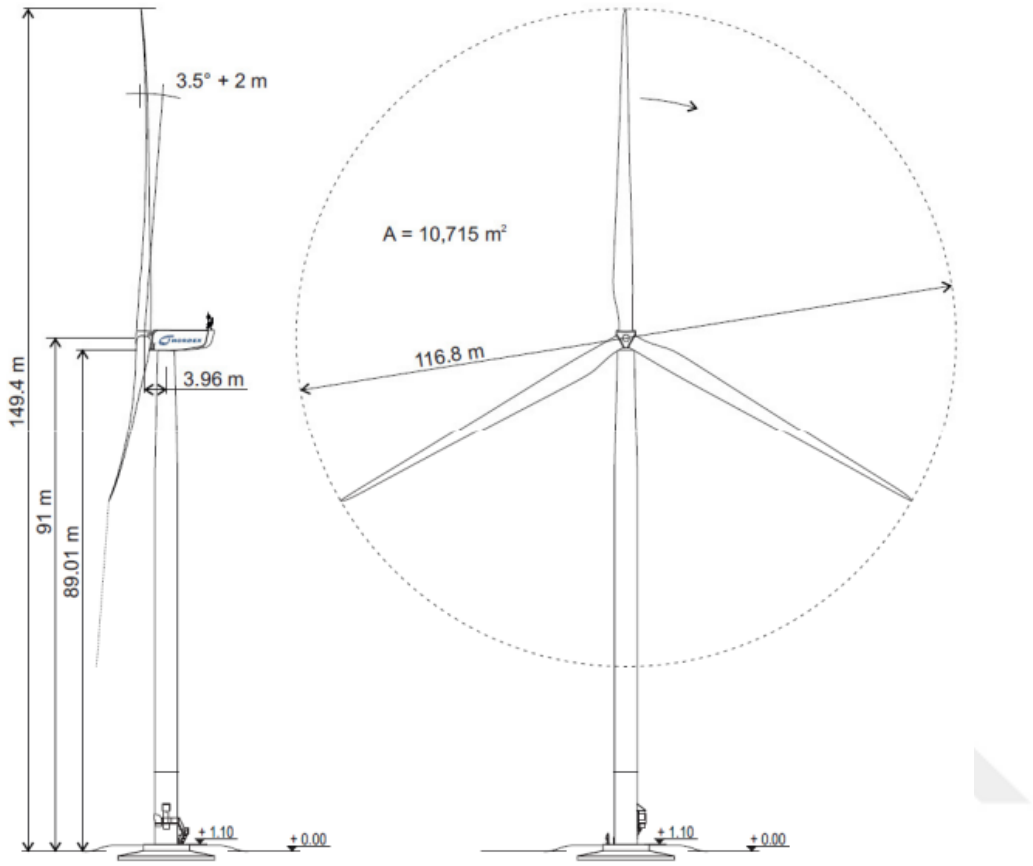

Şekil 3.2: Nordex-N117 2,4 MW Türbin Genel Bakış Çizimi[113]

Modelleme sürecinde, RF ve SVM gibi algoritmalar, karmaşık veri kümelerinden öğrenme ve tahmin yapma kabiliyetleriyle öne çıkar. RF, karar ağaçlarından oluşan bir topluluk yöntemi kullanarak birden fazla karar ağacının tahminlerini birleştirerek daha stabil ve güvenilir tahminler sağlar. SVM ise özellikle sınıflandırma ve regresyon problemlerinde etkili olan, veriyi yüksek boyutlu bir uzaya dönüştürerek optimal karar sınırlarını belirleyen bir yöntemdir.

Python'da model seçimi ve hiperparametre optimizasyonu için kullanılan GridSearchCV ve RandomizedSearchCV gibi araçlar, farklı parametre kombinasyonlarını deneyerek en iyi model performansını bulmayı kolaylaştırmaktadır. ANN, karmaşık ve doğrusal olmayan

ilişkileri modelleyebilen ve veri setindeki karmaşık yapıları öğrenebilen yapay zeka modelleridir. Python'un TensorFlow ve Keras gibi kütüphaneleri, ANN modellerinin tasarımını ve eğitimini basitleştirerek araştırmacılar ve mühendislerin bu güçlü modelleri karmaşık veri kümeleri üzerinde etkili bir şekilde kullanmalarını sağlamaktadır.

Bu kütüphanelerin birleşimi, Python'u veri odaklı araştırma ve geliştirme süreçlerinde vazgeçilmez kılmakta ve rüzgar enerjisinden elektrik enerjisi üretimi tahminleri gibi zorlu görevlerde yüksek performanslı çözümler sunmaktadır. Veri toplama süreci, 2017'den 2022'ye kadar olan dönemi kapsamaktadır ve her 10 dakikada bir rüzgar hızı, rüzgar yönü, sıcaklık ve basınç gibi parametreler kaydedilmiştir. Araştırmada, eksik verilerin en az olduğu dördüncü türbin başlangıçta referans türbin olarak seçilmiş, ancak beklenenden daha düşük tahmin doğruluğu nedeniyle yakındaki üçüncü ve beşinci türbinlerin verileri de analize dahil edilmiştir.

Süreç, Python'un Pandas ve NumPy kütüphaneleri kullanılarak veri analizi, temizleme ve hazırlık işlemlerini kapsamaktadır. Bu adımlar arasında belirli koşullar altında güç üretim değerlerinin "NaN" ile değiştirilmesi, türbinler arasındaki korelasyon analizlerinin yapılması ve eksik veriler için doğrusal interpolasyonun uygulanması bulunmaktadır. Bu ön işleme adımları, hem eğitim verilerine hem de 2022 ve 2023 yıllarına ait 13 aylık test verilerine uygulanmıştır.

Modelleme aşamasında, RF ve SVM modelleri eğitilmiş ve hiperparametre ayarlamaları sırasıyla GridSearchCV ve RandomizedSearchCV kullanılarak yapılmıştır. En iyi performansı sergileyen modeller, MAE, MSE ve R^2 gibi hata ölçütlerine dayanarak seçilmiştir. Son aşamada, RF ve SVM tahminleri, rüzgar hızlarının karesinin hesaplanmasıyla daha da geliştirilmiş bir ANN modeli kullanılarak birleştirilmiştir.

RF ve SVM, sırasıyla %60 ve %40 oranlarında girdi olarak kullanılmıştır. Rüzgar hızı, rüzgar yönü, sıcaklık ve rüzgar hızlarının karesi gibi özellikler üzerinde eğitilen ANN modeli, tahmin doğruluğunu önemli ölçüde artırmıştır. Başlangıçtaki metodolojik yaklaşımın yanı sıra modelin sağlamlığı ve adaptasyon kabiliyeti eğitim ve test veri setlerinin oranları değiştirilerek daha detaylı bir şekilde doğrulanmıştır. Bu süreçte, model altı yıllık veri seti

üzerinden değerlendirilmiştir. İlk olarak veri setinin %40'ı eğitim amacıyla, %60'ı test süreci için ayrılmıştır. Daha sonra bu oranlar tersine çevrilmiş ve veri setinin %60'ı eğitim, %40'ı ise test için kullanılmıştır. Bu ek doğrulama adımı, modelin farklı veri dağılımlarına ne kadar esnek ve uyumlu olduğunu test etmek için yapılmıştır. Sonuç olarak, modelin çeşitli senaryolarda gösterdiği güvenilirlik ve performans güçlendirilmiştir.

3.3. Veri Toplama

Bu çalışmada veri toplama süreci, Sancak Enerji Yahyalı Rüzgar Enerji Santrali'nden elde edilen gerçek zamanlı üretim verileri üzerinden gerçekleştirilmiştir. Şekil 3.3'te santralin konumu Kayseri rüzgar haritası üzerinde gösterilmiştir.

Haritada, Kayseri'nin rüzgar hızı dağılımını temsil eden bir rüzgar haritası yer almaktadır. Bu tür haritalar genellikle rüzgar türbinleri için potansiyel lokasyonları belirlemek ve mevcut tesislerin performansını değerlendirmek amacıyla kullanılmaktadır. Renk gradyanı, mavi tonlarının en düşük rüzgar hızlarını (2 m/s) ve kırmızı tonlarının en yüksek rüzgar hızlarını (10 m/s) temsil ettiği şekilde tasarlanmıştır.

Haritaya göre Kayseri il genelinde rüzgar hızları değişiklik göstermektedir. Merkezi bölgelerde ve dağlık alanlarda rüzgar hızları nispeten daha yüksekken bazı vadilerde ve alçak bölgelerde rüzgar hızlarının düşük olduğu görülmektedir. Yüksek rüzgar hızlarına sahip alanlar, rüzgar türbinleri için potansiyel olarak daha uygun lokasyonlar olarak değerlendirilebilmektedir.

X ile işaretlenmiş konum, kullanılan verilerin toplandığı santralin yerini göstermektedir. Bu konum, haritadaki renk gradyanına göre orta ile yüksek rüzgar hızları arasında bir yerde bulunmaktadır.

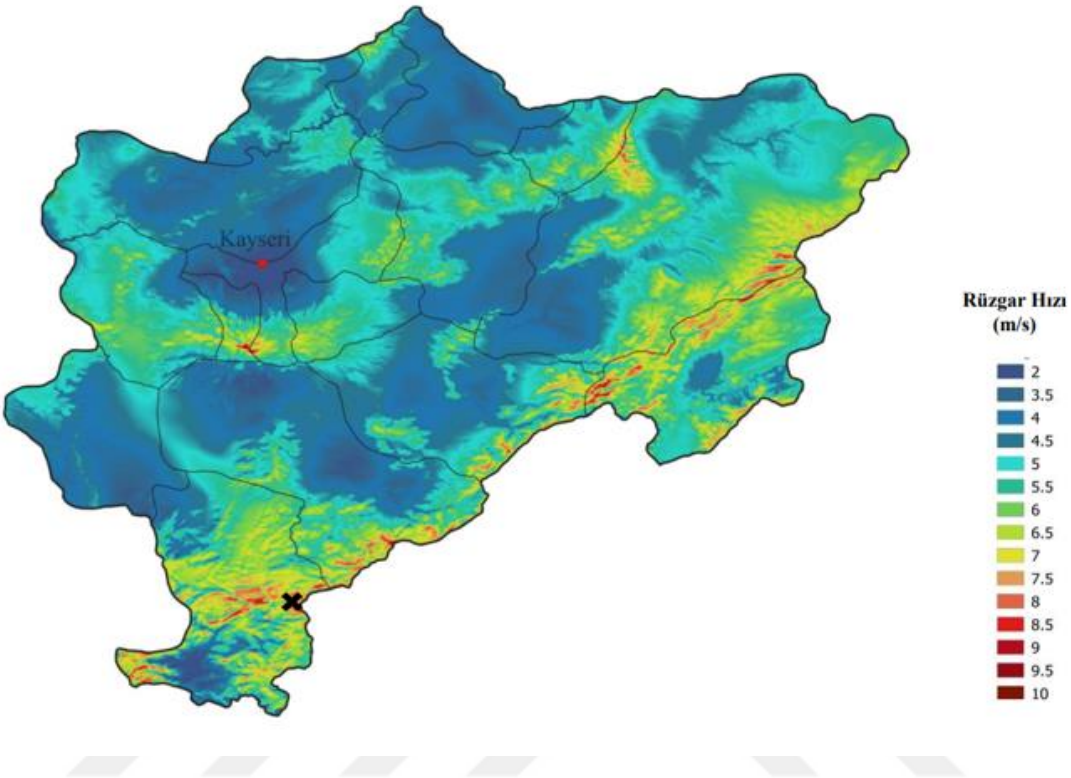

Şekil 3.3: Sancak Enerji Yahyalı Rüzgar Enerji Santrali Konumu[114]

3.3.1. Veri kaynakları

Veri toplama ve analizi, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu artırmak için atılan ilk ve en önemli adımdır. Bu araştırmada kullanılan veri seti, türbinlerin rüzgar hızı, rüzgar yönü, sıcaklık ve basınç gibi değişkenlerini içermekte olup, 2017 ile 2023 yılları arasında her on dakikada bir sistemli olarak kaydedilmiştir. Şekil 3.4'te veri setinden örnek 10 satır verilmektedir. Veri toplama işlemi, enerji santralinin geniş sensör ağından yararlanılarak gerçekleştirilmiştir. Bu da modelin enerji üretim tahminlerinin doğruluğunu iyileştirme potansiyelini artırmaktadır.

Tarih ve Saat	Rüzgar Hızı (m/s)	Rüzgar Yönü	Sıcaklık (°C)
2017-01-01 00:00:00	5.47896	190.375	-3.07611
2017-01-01 00:10:00	4.63255	190.203	-3.08988
2017-01-01 00:20:00	4.76338	190.648	-3.14266
2017-01-01 00:30:00	4.6735	192.19	-3.18238
2017-01-01 00:40:00	5.34411	190.405	-3.25108
2017-01-01 00:50:00	5.73031	189.679	-3.28939
2017-01-01 01:00:00	4.7701	182.657	-3.2893
2017-01-01 01:10:00	4.33641	181.538	-3.31721
2017-01-01 01:20:00	4.1241	178.844	-3.40017
2017-01-01 01:30:00	5.06997	179.402	-3.46456

Şekil 3.4: Veri Setinden Örnek Değerler

Zaman serisi verileri, rüzgar enerjisinden elektrik enerjisi üretimi tahmin modellerinin geliştirilmesinde kullanılmak üzere detaylı bir şekilde analiz edilmiş ve özenle işlenmiştir. Veri setinin kapsamlılığı, rüzgar enerjisinden elektrik enerjisi üretiminin dinamiklerini ve karmaşıklığını anlamada ayrıca tahmin modellerinin doğruluğunu artırmada kritik bir rol oynamaktadır. Veri toplama ve işleme süreçleri, araştırmanın metodolojik sağlamlığını desteklemekte ve güvenilir sonuçlar elde edilmesine olanak tanımaktadır.

3.3.2. Veri tanımı

Toplanan veriler, rüzgar enerjisinden elektrik enerjisi üretimi tahmin modelinin geliştirilmesi ve test edilmesi için kullanılan temel bileşenleri oluşturmaktadır. Veri setinde yer alan rüzgar hızı ve rüzgar yönü gibi parametreler, rüzgar enerjisinden elektrik enerjisi üretiminin tahmin edilmesinde kritik öneme sahiptir. Ayrıca sıcaklık ve basınç gibi atmosferik koşulların da rüzgar enerjisinden elektrik enerjisi üretimi üzerinde önemli bir etkisi bulunmaktadır. Veri seti, bu parametrelerin zaman içindeki değişimlerini yansıtan kapsamlı ve detaylı bir zaman serisi veri tabanını içermektedir.

Veri toplama sürecinde, veri kalitesini ve analiz için gereken tutarlılığı sağlamak amacıyla, veri ön işleme ve temizleme adımları da dikkate alınmıştır. Bu süreç, eksik verilerin

doldurulması, aykırı değerlerin düzeltilmesi ve veri setinin modelleme için uygun hale getirilmesini içermektedir. Bu aşamada kullanılan yöntemler, veri setinin analize hazır hale getirilmesinde ve sonraki modelleme aşamalarında elde edilecek sonuçların güvenilirliğini artırmada önemli bir rol oynamaktadır.

3.4. Veri Ön İşleme

Veri ön işleme sürecinde, enerji üretiminde temel bir faktör olan rüzgar hızı, metrik olarak veri setinden çıkarılmış ve temizlenmiştir. Bu süreçte, Pandas kütüphanesinin sunduğu işlevler kullanılarak hatalı veri türleri düzeltilmiş ve eksik veri noktaları doldurulmuştur. Örneğin, belirli rüzgar hızı eşiklerinin altında güç üretimi yapılmadığında veya belirli sıcaklık koşullarında donma riski bulunduğunda veriler filtrelenmiştir. Ayrıca benzer rüzgar hızı ve rüzgar yönü koşulları altında enerji üretimi olmadığı durumlar için özel koşullar belirlenmiştir. Veri setindeki tutarlılığı sağlamak amacıyla eksik veri noktaları linear interpolasyon yöntemiyle veri setine uygun bir şekilde tamamlanmıştır. Bu titiz veri temizliği ve ön işleme yaklaşımı, sonraki analitik adımların doğruluğunu ve güvenilirliğini artırmada kritik bir öneme sahiptir. Aynı zamanda Python programlama dili ile uygulanan ileri düzey veri analizi pratiklerinin bir örneğini sunmaktadır.

Veri setinin modelleme süreçlerine hazırlanmasında kullanılan bu kodlar, metodolojik bir çerçeve sağlayarak araştırmanın bütünlüğünü desteklemektedir. Veri ön işleme, rüzgar enerjisinden elektrik enerjisi üretimi tahminleri gibi karmaşık analizlerde verilerin analize uygun hale getirilmesi için kritik bir süreçtir. Bu aşama, veri setindeki eksikliklerin, tutarsızlıkların ve potansiyel hataların düzeltilmesini içermektedir. Aşağıda, Python kodu temelinde detaylandırılmış veri ön işleme adımlarını bulanmaktadır.

3.4.1. Veri temizliği ve eksik değerlerin işlenmesi

Eksik değerler, veri setindeki bilgi eksikliğinden kaynaklanmakta olup analiz sonuçlarını önemli ölçüde etkilemektedir. Veri toplama ve işleme metodolojilerinin geliştirilmesi, veri kalitesinin artırılması ve daha geniş veri erişimine olanak sağlanması, öngörü süreçlerinin temelini oluşturmaktadır. Bu çalışmada kullanılan veri setleri, rüzgar hızı, sıcaklık ve atmosferik basınç gibi kritik parametreleri içermekte ve türbinlerin performansını ve rüzgar

enerjisinden elektrik enerjisi üretimi kapasitesini doğru bir şekilde analiz etmek için kullanılmaktadır. Veri ön işleme kodunda, belirli koşullar altında güç çıktısı değerlerinin 'NaN' olarak işaretlenmesiyle eksik değerler tespit edilmektedir. Örneğin, rüzgar hızı türbinin çalışma eşiğinin altında olduğu halde güç çıktısının sıfır olmadığı ya da rüzgar hızı yeterli olmasına rağmen sıcaklığın donma noktasının altında olduğu ve güç çıktısının yine sıfır olduğu durumlar belirlenmektedir. Bu yöntem, türbinin beklenen performansını yansıtmayan anomali verilerin düzeltilmesine yardımcı olmaktadır.

Eksik verilerin kaldırılması ve interpolasyon yöntemiyle doldurulması, analiz için gereksiz veya düzeltilmesi mümkün olmayan eksik verilerin dropna fonksiyonu ile veri setinden çıkarılmasını içermektedir. Ardından, interpolate fonksiyonu ile kalan eksik veriler, çevreleyen değerlere dayalı olarak doldurulmaktadır. Bu doğrusal interpolasyon yöntemi, veri setindeki boşlukların mantıklı bir şekilde doldurulmasını sağlayarak analizin tutarlılığını artırmaktadır.

3.4.2. Aykırı değer tespiti ve kaldırılması

Aykırı değerler, genellikle ölçüm hataları, kayıt hataları veya olağan dışı olaylar nedeniyle veri setinde beklenmeyen büyük sapmalar olarak ortaya çıkmaktadır. Bu çalışmada, aykırı değerler belirli istatistiksel eşik değerlerinin üzerindeki veya altındaki değerlerin incelenmesiyle tespit edilmiştir. Örneğin, rüzgar hızı aniden çok yüksek değerlere ulaştığında veya güç üretiminde beklenmeyen dalgalanmalar olduğunda bu durumlar aykırı değer olarak işaretlenmiş ve düzeltilmiştir. Bu kodda, aykırı değer tespiti için bir yöntem önerilmekte ancak somut bir uygulama sunulmamaktadır. Aykırı değerlerin belirlenmesi, genellikle veri setinin istatistiksel analizi veya belirli bir eşik değerin üzerindeki ya da altındaki değerlerin incelenmesiyle gerçekleştirilmektedir.

Tespit edilen aykırı değerler, analizin doğruluğunu artırmak amacıyla ya veri setinden çıkarılmakta ya da daha mantıklı değerlerle değiştirilerek düzeltilmektedir. Bu süreç, analizin güvenilirliğini önemli ölçüde artırmaktadır. Ön işleme adımlarından geçirilen veriler, analiz ve raporlama için Excel dosyaları olarak kaydedilmektedir. Bu, veri setinin daha sonraki analizlerde kolaylıkla kullanılabilmesini sağlamaktadır.

3.4.3. Veri birleştirme ve ilişkilendirme

Farklı türbinlerden gelen veriler, tek bir veri seti halinde birleştirilerek analiz edilecek verilere kapsamlı bir bakış açısı kazandırmaktadır. Bu çalışmada, pd.concat fonksiyonu kullanılarak farklı türbinlere ait veriler birleştirilmiştir. Ayrıca korelasyon analizi yapılarak farklı türbinlerdeki güç ve rüzgar hızı arasındaki ilişki incelenmiş ve bu ilişkilerin gücü ve yönü belirlenmiştir.

3.5. Model Geliştirme

Bu çalışma, Türkiye'deki bir Rüzgar Enerjisi Tesisi için kısa vadeli rüzgar enerjisinden elektrik enerjisi üretimi tahminlerine odaklanmaktadır. Araştırma, tesis için veri analizi ve tahmin yöntemi geliştirilmesini kapsamaktadır. Çalışmada izlenen metodolojiyi ve sıralı adımları görsel olarak temsil etmek amacıyla, genel süreci açıklayan bir akış diyagramı Şekil 3.4 olarak dahil edilmiştir.

Bu çalışma, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu artırmak amacıyla çeşitli makine öğrenimi modelleri ve bu modellerin birleşiminden oluşan bir hibrit modeli kullanmaktadır. Model geliştirme süreci ise Şekil 3.4'deki adımları içermektedir.

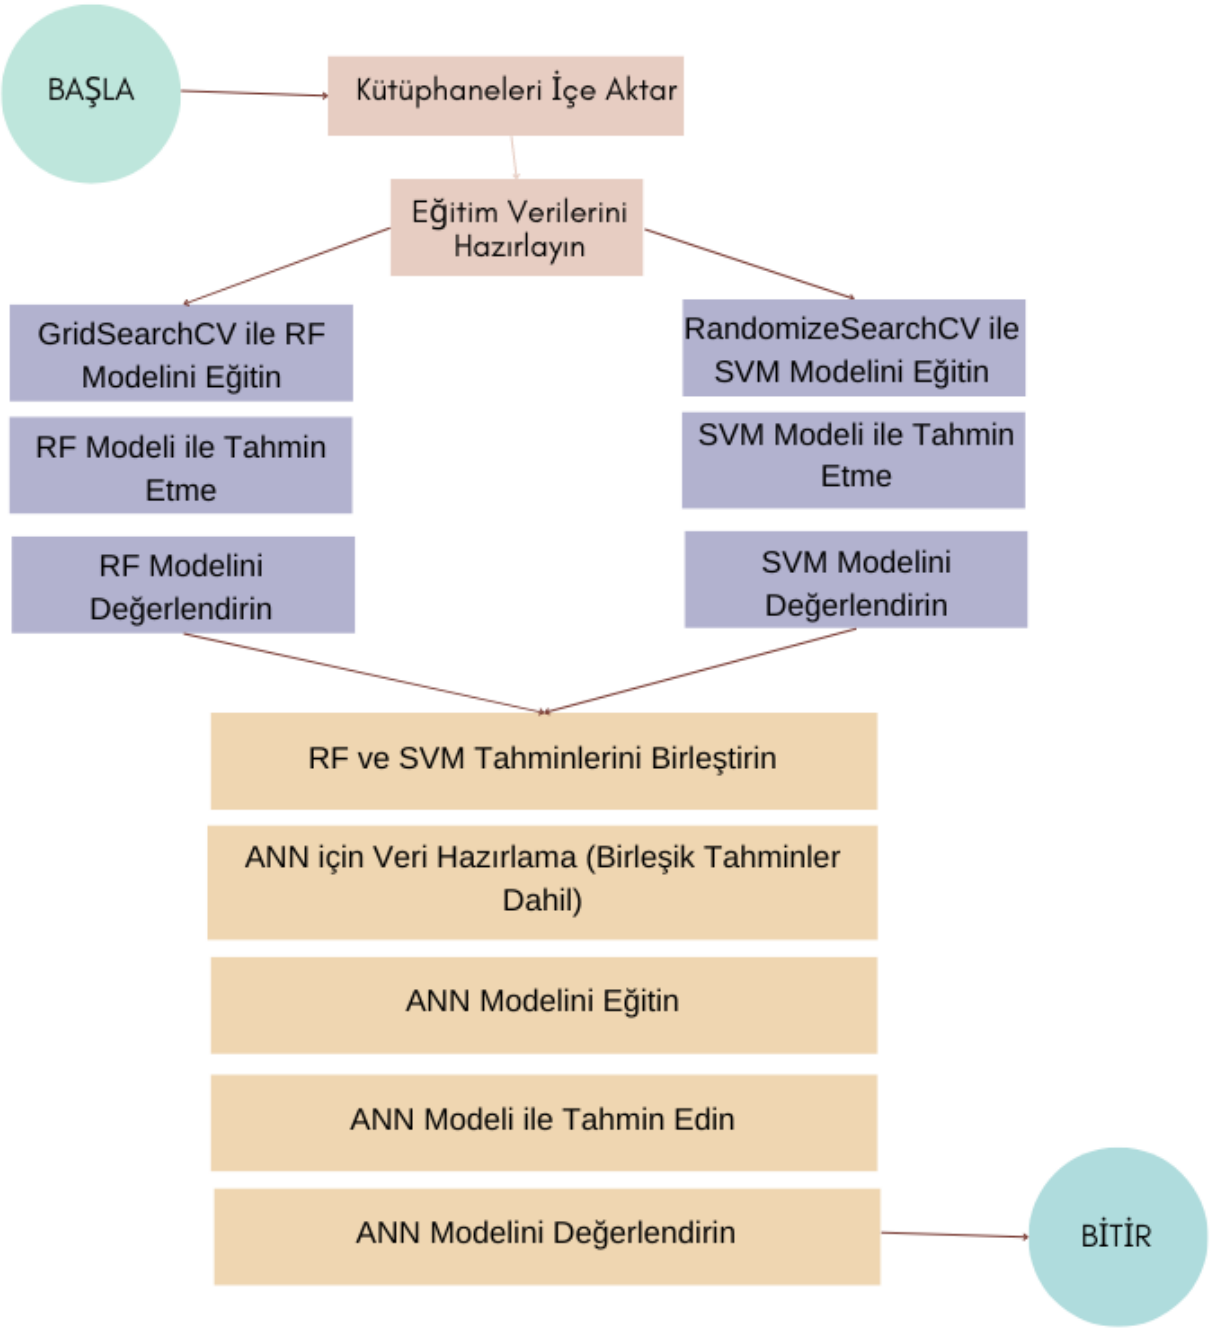

Şekil 3.5: Akış Diyagramının Metodolojisi

3.5.1. Rastgele orman modeli

Rastgele Orman modeli, çok sayıda karar ağacının toplu karar verme mekanizmasını kullanmaktadır. Her bir ağaç, rüzgar enerjisinden elektrik enerjisi üretimi tahmininde kullanılan özelliklerin rastgele alt kümeleri üzerinde eğitilmekte ve bu çeşitlilik, modelin veri setinin çeşitli yönlerini öğrenmesini sağlamaktadır. Öğrenme sürecinde, her ağacın kararları dikkate alınarak çoğunluk oylaması ya da ortalama alma yöntemi ile tahmin yapılmaktadır. Bu yöntem, aşırı uyuma (overfitting) karşı dayanıklı olup modelin genellemesini güçlendirmektedir.

Karar ağaçları, sınıflandırma ve regresyon gibi makine öğrenmesi görevlerinde yaygın olarak kullanılan popüler bir yöntemdir. Bu yöntem, veri setini temsil eden bir dizi karar kuralından oluşur ve bu kurallar ağaç yapısı şeklinde düzenlenir. Her bir karar düğümü, veri setini belirli bir özelliğe göre ikiye ayırmakta ve bu sayede veriler daha homojen alt gruplara bölünmektedir. Karar ağacının en üstündeki kök düğüm, tüm veri setini temsil ederken, ağacın dalları karar düğümleri olarak işlev görmekte ve her bir yaprak düğüm, bir çıktı sınıfı veya değeri ile ilişkilendirilmektedir[115].

Karar ağacını oluşturma süreci, veri setini en iyi şekilde ayıran özelliği belirlemekle başlar. Bu seçim, genellikle Gini saflığı, entropi ve bilgi kazancı gibi ölçütler kullanılarak yapılır. Bir özellik seçildikten sonra, veri seti bu özelliğe göre ikiye ayrılır ve süreç her bir alt küme için tekrarlanır. Bu bölme işlemi, tüm veriler yeterince homojen gruplara ayrılana kadar veya belirlenen bir maksimum derinliğe ulaşana kadar devam eder. Ancak karar ağaçlarının da aşırı uyum gibi sorunları vardır. Aşırı uydurma, modelin eğitim verilerine çok iyi uyum sağlaması ancak yeni verilere karşı genelleme yapamaması durumudur. Bu sorunu azaltmak için budama teknikleri kullanılır. Budama, ağacın belli bir derinlikte kesilmesi veya en az bilgi kazancına sahip dalların çıkarılması yoluyla ağacın karmaşıklığını azaltır[115].

Karar ağaçlarının en büyük avantajlarından biri, oluşturulan modelin anlaşılmasının ve yorumlanmasının kolay olmasıdır. Hem sayısal hem de kategorik verilerle çalışabilirler ve veri ölçeklendirmesi gerektirmezler. Ancak küçük veri değişikliklerine karşı hassas olabilirler ve dengesiz veri setlerinde yanıltıcı sonuçlar verebilirler. Bu yüzden, karar

ağaçlarını dikkatli bir şekilde eğitmek ve onları gerçek dünya problemlerine uygulamadan önce doğru şekilde ayarlamak önemlidir.

Bu çalışmada, RF modeli rüzgar hızı, yönü, sıcaklık ve basınç gibi önemli parametreleri kapsayan geniş bir veri seti üzerinde eğitilmiştir. Modelin eğitimi sırasında, GridSearchCV kullanılarak en uygun hiperparametrelerin belirlenmesi için kapsamlı bir arama yapılmıştır. Bu süreç, modelin tahmin performansını maksimize eder ve rüzgar enerjisi üretimi tahminlerinin doğruluğunu artırmayı hedefler.

RF modeli için GridSearchCV aracılığıyla kapsamlı bir parametre arama alanı tanımlanmıştır: 'n_estimators' (ağaç sayısı), 'max_depth' (ağaçların maksimum derinliği), 'min_samples_split' (bir düğümü bölmek için gereken minimum örnek sayısı) ve 'min_samples_leaf' (bir yaprak düğümünde olması gereken minimum örnek sayısı) parametreleri üzerinde durulmuştur. Her bir parametre için belirlenen aralıklar, modelin farklı yönlerden incelenmesini ve en iyi performansı sunacak yapılandırmanın seçilmesini sağlamıştır.

RF modelinin gücü, GridSearchCV kullanılarak yapılan hiperparametre optimizasyonundan kaynaklanır. Bu süreç, n_estimators (ağaç sayısı), max_depth (maksimum derinlik), min_samples_split (bir düğümü bölmek için gerekli minimum örnek sayısı), ve min_samples_leaf (bir yaprak düğümünde bulunması gereken minimum örnek sayısı) gibi kritik parametreler için en uygun değerlerin seçilmesini içerir.

Örneğin, GridSearchCV ile RF modeli için yapılan hiperparametre ayarlamasında, n_estimators için [50, 100, 150], max_depth için [None, 10, 20, 30], min_samples_split için [2, 5, 10], ve min_samples_leaf için [1, 2, 4] değerleri denenmiştir. Bu yöntem, modelin performansını maksimize eden en iyi parametre kombinasyonunu belirlemek için bu parametrelerin tüm kombinasyonlarını dener.

Model, tahmin gücünü artırmak için kullanılan özellik mühendisliği teknikleri ile desteklenmiştir. Örneğin, rüzgar hızının karesi gibi türetilmiş özellikler, enerji üretim potansiyelinin daha doğru bir göstergesi olarak modelin girdi veri setine eklenmiştir. Eğitim

veri seti, santralden alınan gerçek zamanlı verilere dayanmaktadır, bu da modelin gerçek dünya koşullarına uygunluğunu artırır.

RF, özelliklerin tahminlerdeki önemini belirleme yeteneğine sahiptir. Rüzgar hızı, rüzgar yönü ve hava sıcaklığı gibi özelliklerin her birinin önemi, modelin tahminlerini iyileştirmede önemli rol oynar. Türetilmiş özellikler, örneğin rüzgar hızının karesi, modelin tahmin gücünü artırmak için kullanılır.

Bu çalışmada, RF modeli, rüzgar hızı, yönü, sıcaklık ve basınç gibi parametreleri içeren geniş bir veri seti üzerinde eğitilmiştir. Modelin eğitimi sırasında, GridSearchCV ile en uygun hiperparametreler belirlenmiş ve modelin tahmin performansını artıracak şekilde yapılandırılmıştır.

Test aşamasında, modelin çeşitli istatistiksel ölçütlerle değerlendirilmesi, hem doğruluğun hem de modelin pratik uygulanabilirliğinin anlaşılmasını sağlar. MAE, MSE ve R^2 gibi metrikler, modelin tahmin başarısını ve şebeke enerji yönetimi için uygulanabilirliğini ölçmede kullanılmıştır.

RF modeli, bu tez çalışmasında rüzgar enerjisi tahminlerinin doğruluğunu ve güvenilirliğini artırmak için kritik bir bileşen olarak belirlenmiştir. Model, rüzgar enerjisi üretimini etkileyen dinamiklerin karmaşık doğasını başarıyla modelleyebilmekte ve enerji piyasasında karar verme süreçlerini destekleyecek güvenilir tahminler sunmaktadır.

3.5.2. Destek vektör makinesi modeli

SVM, rüzgar enerjisinden elektrik enerjisi üretimi tahmininde kullanılan etkili bir model olarak öne çıkmaktadır. SVM, yüksek boyutlu uzaylarda veri noktalarını sınıflandırma veya regresyon analizinde yüksek performans sergilemektedir[116], [117]. Bu model, rüzgar hızı, rüzgar yönü ve sıcaklık gibi temel parametreler üzerinden rüzgar enerjisinden elektrik enerjisi üretimi değerlerini tahmin etmek üzere eğitilmiş ve modelin doğruluğunu artırmak için hiper düzlemi en iyi şekilde tanımlayacak parametreler özenle seçilmiştir.

SVM modelinin optimizasyonu, RandomizedSearchCV kullanılarak gerçekleştirilmiştir. Bu yöntem, 'C' (düzenleme parametresi), 'kernel' (çekirdek türü), 'degree' (polinomial çekirdeğin

derecesi) ve 'gamma' (çekirdek katsayısı) gibi parametreler için geniş bir aralık sunmakta ve modelin genelleştirme yeteneğini artırmaktadır. RandomizedSearchCV, veri setinin karmaşıklığını ve yapısal özelliklerini en iyi şekilde yakalayacak parametre kombinasyonunu bulmak amacıyla rastgele örnekleme yöntemiyle bir dizi deneme yapmaktadır. Bu yaklaşım, modelin rüzgar enerjisinden elektrik enerjisi üretimi verileri arasındaki karmaşık ilişkileri daha iyi anlamasını ve doğruluğunu artırmasını sağlamaktadır.

Modelin eğitim süreci, özellik ölçeklendirme işlemi ile desteklenmiştir. StandardScaler kullanılarak eğitim ve test veri setlerindeki özellikler ölçeklendirilmiş, bu da modelin daha stabil ve hızlı öğrenmesini sağlamıştır. Özellikle SVM'nin çekirdek yöntemlerini kullanırken özellikler arasındaki mesafeler modelin performansını doğrudan etkilemektedir.

Eğitilen model, test veri seti üzerinde değerlendirilmiştir. Modelin tahmin performansı, MAE, MSE ve R^2 skoru gibi metriklerle ölçülmüştür. Bu metrikler, modelin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde ne kadar doğru ve güvenilir olduğunu belirlemek için kullanılmıştır. Test sonuçları, SVM modelinin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde yüksek doğruluk sağladığını ve enerji sektöründe karar destek sistemleri geliştirilmesi için değerli bir araç olabileceğini göstermektedir.

SVM modeli, bu çalışmada rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde kullanılan hibrit modelleme yaklaşımının önemli bir parçası olarak öne çıkmaktadır. Modelin geliştirilmesi ve test edilmesi süreci, rüzgar enerjisinden elektrik enerjisi arzının saatlik değişimlerine uyum sağlayacak şekilde optimize edilmiş olup bu durum modelin şebeke işletmecilerine güçlü bir referans sağladığını göstermektedir.

Bu detaylı analiz ve optimizasyon süreci, SVM modelinin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde nasıl etkili bir şekilde kullanılabileceğini ortaya koymaktadır. Modelin başarısı, karmaşık veri setlerindeki ilişkileri anlama ve doğru tahminlerde bulunma yeteneğine dayanmaktadır. Bu yaklaşım, enerji sektöründe karar verme süreçlerini desteklemek ve rüzgar enerjisinden elektrik enerjisi üretimi kaynaklarının etkin yönetilmesine katkı sağlamak için önemli bir adımdır.

3.5.3. Hibrit model

Bu araştırmada, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu artırmak amacıyla, RF, SVM ve ANN teknolojilerinin güçlü yönlerini birleştiren ileri düzey bir hibrit model geliştirilmiştir. Bu entegre yaklaşım, her bir modelin tek başına sunduğundan daha kapsamlı ve doğru tahminler üretme potansiyeline sahiptir.

Hibrit modelin temeli, özellikle rüzgar hızı, rüzgar yönü, sıcaklık ve basınç gibi çeşitli meteorolojik parametreler dikkate alınarak eğitilen RF ve SVM modellerinden elde edilen tahminler üzerine kurulmuştur. RF ve SVM, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin temelini oluştururken ANN modeli bu tahminleri daha da geliştirmek amacıyla kullanılmaktadır.

Modelin eğitimi sürecinde, SVM ve RF modelleri önce standartlaştırılmış bir eğitim seti üzerinde eğitilmiş ardından bu modellerden elde edilen tahminler hibrit modelin daha kapsamlı eğitim seti olarak kullanılmıştır. Bu aşamada, RandomizedSearchCV aracılığıyla gerçekleştirilen hiperparametre optimizasyonu, modelin performansını en üst düzeye çıkarmak için kritik öneme sahiptir. 'C', 'kernel', 'degree' ve 'gamma' gibi parametreler üzerinde yapılan bu optimizasyon, modelin rüzgar enerjisinden elektrik enerjisi üretimi verileri arasındaki karmaşık ilişkileri daha etkin bir şekilde anlamasını sağlamıştır.

ANN modeli, türetilmiş özellikler de dahil olmak üzere genişletilmiş bir özellik seti kullanılarak eğitilmiştir. Bu model, rüzgar hızı, rüzgar yönü, sıcaklık ve rüzgar hızının karesi gibi özelliklerle giriş katmanı olarak kurulmuş, iki gizli katman ve bir çıktı katmanı ile yapılandırılmıştır. Modelin eğitimi sırasında öğrenme oranı, epoch sayısı ve batch boyutu gibi kritik hiperparametreler özenle ayarlanmıştır. Şekil 3.5'te kullanılan ANN yapısının detayları gösterilmektedir.

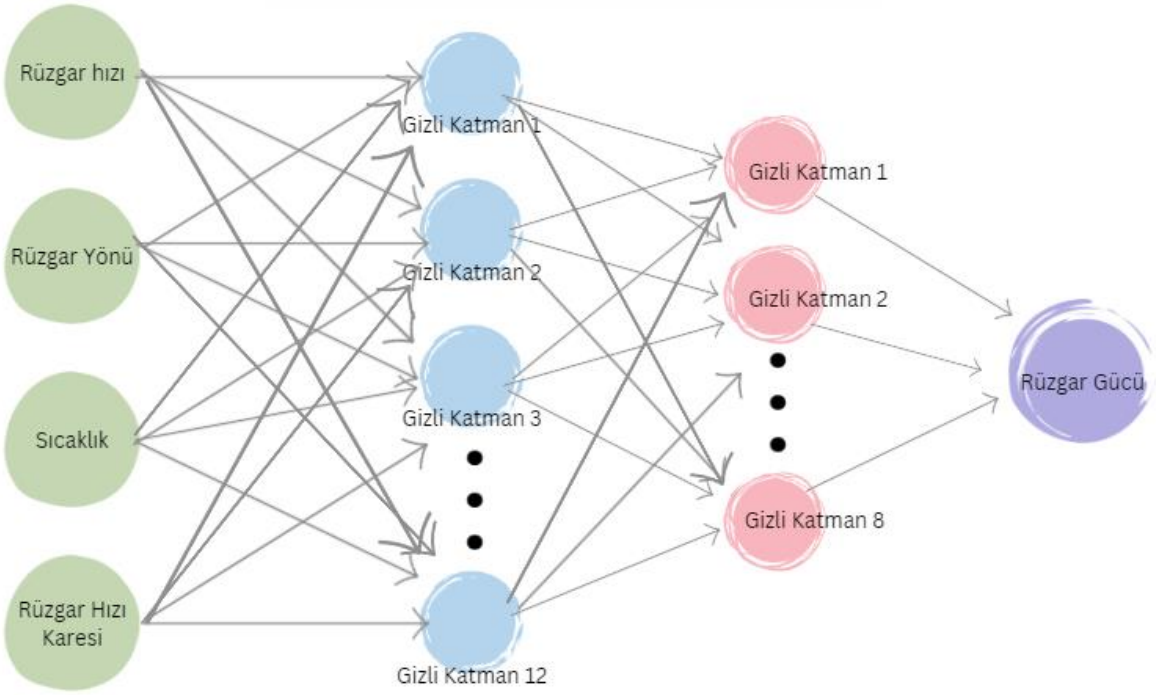

Şekil 3.6: Çalışmada kullanılan ANN Yapısı

Hibrit modelin eğitimi, RF ve SVM modellerinden elde edilen tahminlerin birleştirilmesi ve bu kombinasyonun ANN modeli tarafından daha ileri analizler için kullanılmasıyla gerçekleştirilmiştir. Bu strateji, ANN'in mevcut tahminleri daha da geliştirebilecek yeni desenleri ve ilişkileri öğrenmesini sağlamaktadır. Model, geniş bir veri seti üzerinde eğitilmiş olup, performansı ortalama mutlak hata, ortalama kare hata ve R^2 gibi çeşitli istatistiksel metrikler kullanılarak değerlendirilmiştir.

Test edilen hibrit model, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde yüksek düzeyde doğruluk ve güvenilirlik sunmaktadır. Modelin eğitim ve test süreçleri, özellikle rüzgar enerjisinden elektrik enerjisi üretiminin zamana bağlı değişkenliğini tahmin etme kabiliyetini önemli ölçüde geliştirmiştir. Bu geliştirilmiş hibrit model, enerji üretimi planlaması ve şebeke yönetimi gibi kritik karar verme süreçlerinde kullanılabilecek güçlü bir araç olarak öne çıkmaktadır.

Geliştirilen bu hibrit model, rüzgar enerjisinden elektrik enerjisi üretimi tahminleri konusunda mevcut yöntemlerin ötesine geçerek, enerji piyasalarında ve şebeke işletmeciliğinde karar verme süreçlerini desteklemek için kapsamlı ve doğru bilgiler sunma potansiyeline sahiptir. Bu modelin uygulanması, rüzgar enerjisi kaynaklarının daha etkin bir şekilde yönetilmesine ve enerji sistemlerinin sürdürülebilirliğinin artırılmasına katkıda bulunabilir.

3.6. Model Değerlendirme Metrikleri

Model değerlendirme, geliştirilen tahmin modellerinin performansını ölçmek ve karşılaştırmak için kritik bir süreçtir. Bu çalışmada model performansını değerlendirmek amacıyla kullanılan ana metrikler şu şekildedir:

1. Ortalama Mutlak Hata: MAE, tahmin edilen değerler ile gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasını göstermektedir. MAE, modelin tahminlerinin doğruluğunu ortaya koymakta olup daha düşük değerler daha iyi bir performansı işaret etmektedir.

2. Ortalama Kare Hata: MSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasını göstermektedir. MSE, büyük hataları daha fazla cezalandırmakta ve model performansının genel bir ölçüsünü sağlamaktadır.

3. Belirleme Katsayısı: R^2, modelin veri setindeki varyansın ne kadarını açıkladığını göstermektedir. Değerin 1'e ne kadar yakın olduğu, modelin o kadar iyi performans sergilediğini ifade etmektedir. R^2, modelin genel uyumunu ve tahmin gücünü değerlendiren önemli bir metriktir.

Bu üç metrik, modelin performansını çeşitli açılardan değerlendirerek modelin ne kadar etkili olduğunu ve tahminlerin ne kadar güvenilir olduğunu belirlememize olanak tanımaktadır. Ayrıca bu metrikler, farklı modellerin performanslarını karşılaştırmak ve en uygun modeli seçmek için kritik öneme sahiptir. Eğitim ve test veri setleri üzerinde gerçekleştirilen çeşitli senaryo analizleri, modelin robustluğunu ve farklı koşullar altındaki adaptasyon yeteneğini de test etmemize imkân sağlamaktadır.

Bu değerlendirme süreci, modelin güçlü ve zayıf yönlerini anlamak, potansiyel iyileştirme alanlarını belirlemek ve gelecekteki araştırma yönlerini şekillendirmek için önemli bir temel oluşturmaktadır. Dolayısıyla bu metrikler model geliştirme ve seçim süreçlerinde kritik bir rol oynamakta ve gelecekteki model iyileştirmeleri için değerli içgörüler sunmaktadır.

4. BULGULAR VE TARTIŞMA

4.1. Rastgele Orman Modelinin Değerlendirilmesi

4.1.1. Model performansı

RF modeli, rüzgar enerjisi tahmininde kullanılan güçlü bir makine öğrenimi yöntemidir. RF modeli, karar ağaçlarının birleştirilmesiyle oluşturulan bir topluluk öğrenme modelidir ve hem sınıflandırma hem de regresyon problemlerinde etkilidir. Bu çalışmada, RF modelinin performansı aşağıdaki hata metrikleri kullanılarak değerlendirilmiştir

- MAE: 88.759

- MSE: 34173.246

- R^2: 0.9318

Şekil 4.1, RF modeli için elde edilen MAE değerlerini, Şekil 4.2, MSE değerlerini ve Şekil 4.3, R^2 değerlerini göstermektedir. MAE, tahmin edilen ve gerçek değerler arasındaki farkların ortalamasını ifade eder; bu nedenle, modelin genel tahmin hatasını değerlendirmek için önemli bir metrik olarak kullanılmıştır. Şekilden, RF modelinin MAE değerinin belirli bir sınırın altında kaldığı ve kabul edilebilir hata seviyelerine sahip olduğu görülmektedir. MSE, tahmin edilen ve gerçek değerler arasındaki farkların karelerinin ortalamasını ifade eder. Karelerin alınması, büyük hataların daha fazla önemsenmesine olanak tanır. Şekildeki düşük MSE değeri, modelin büyük sapmalar yapmadan tahmin ürettiğini göstermektedir. R^2, modelin bağımlı değişkendeki varyansın ne kadarını açıklayabildiğini ifade eder. Şekilden, RF modelinin R^2 değerinin oldukça yüksek olduğu ve bu da modelin tahminlerinde güçlü bir doğruluk sağladığını göstermektedir. R^2 değerinin 0.93 olması, modelin toplam veri varyansının %93'ünü başarıyla açıkladığını ifade etmektedir.Bu metrikler, RF modelinin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde oldukça yüksek bir doğruluk seviyesine ulaştığını göstermektedir. R^2 değeri, modelin veri setindeki varyansın %93.18'ini açıklayabildiğini belirtmekte olup bu da modelin tahmin yeteneğinin oldukça yüksek olduğunu göstermektedir.

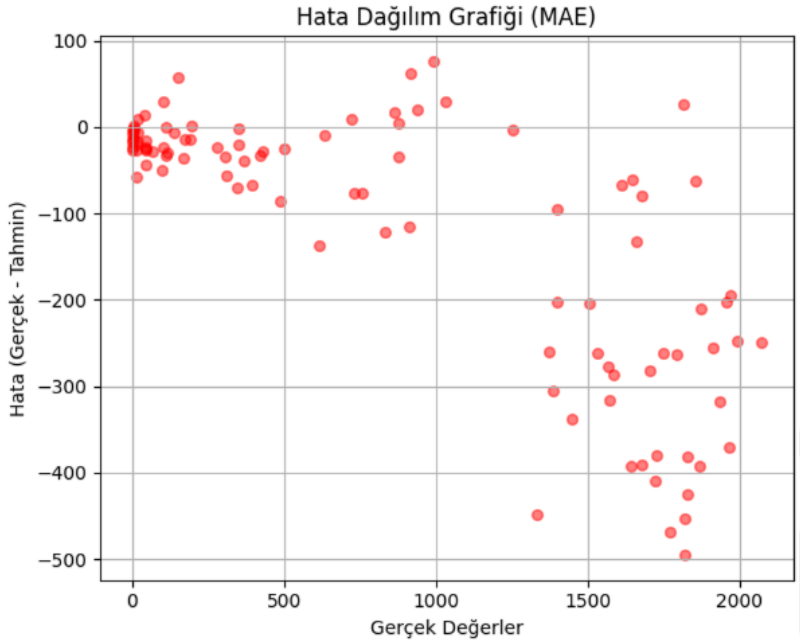

Şekil 4.1: RF İçin MAE Değerleri

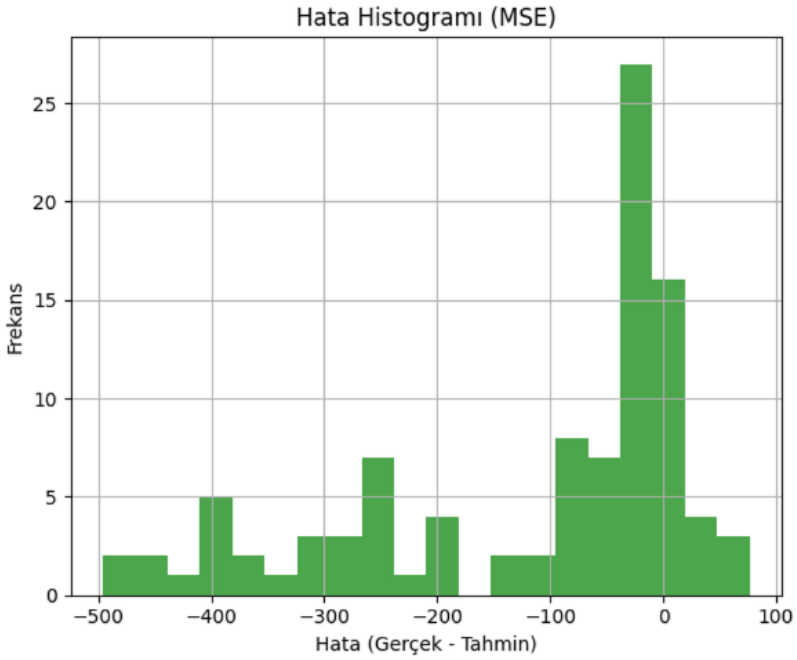

Şekil 4.2: RF İçin MSE Değerleri

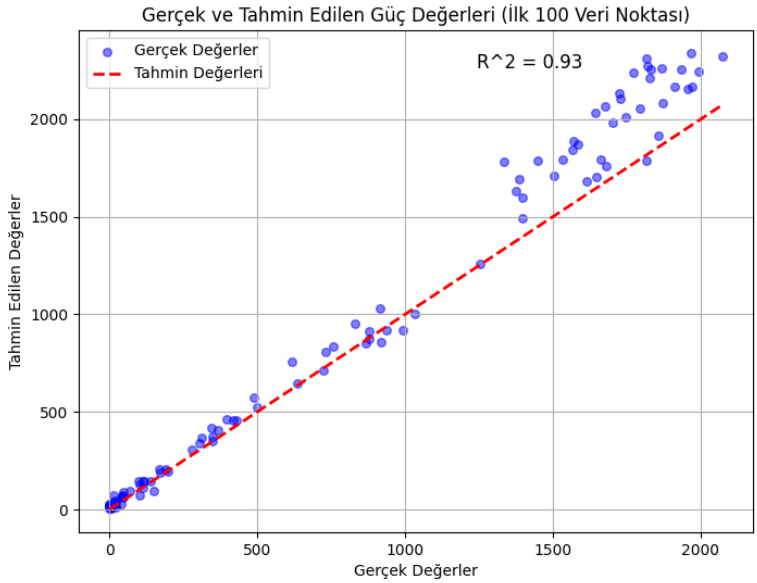

Şekil 4.3: RF İçin R^2 Değerleri

Bu metrikler, RF modelinin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde oldukça yüksek bir doğruluk seviyesine ulaştığını göstermektedir. R^2 değeri, modelin veri setindeki varyansın %93.18'ini açıklayabildiğini belirtmekte olup bu da modelin tahmin yeteneğinin oldukça yüksek olduğunu göstermektedir.

4.1.2. Tartışma

RF modeli, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde yüksek doğruluk sağlamasının yanı sıra, model karmaşıklığı ve yorumlanabilirliği açısından dengeli bir yaklaşım sunmaktadır. Modelin başarısı, karar ağaçlarının topluluk öğrenme yoluyla birleştirilmesinin tekil karar ağacı modellerine kıyasla daha güvenilir ve kararlı tahminler sağladığını göstermektedir. Ayrıca RF modeli, veri üzerindeki gürültünün ve aykırı değerlerin etkisini azaltmada etkili olduğunu kanıtlamıştır.

Bu çalışmada uygulanan RF modeli, kısa dönemli rüzgar gücü tahminlerinde sağladığı yüksek doğruluk ile öne çıkmaktadır. Model, tahmin performansını değerlendiren çeşitli hata metrikleri açısından analiz edilmektedir ve elde edilen MAE: 88,76, MSE: 34.173,25 ve R^2: 0,9318 değerleri, literatürde yer alan benzer çalışmalarla karşılaştırıldığında başarılı bir

sonuç sağlamaktadır. Sidi Daoud ve Adama II rüzgar çiftlikleri üzerinde gerçekleştirilen çalışmalarda RF modellerinin hata oranlarının sırasıyla RMSE: 88,19 ve MAE: 68,40 olduğu rapor edilmiştir[65], [118]. Bu sonuçlar, çalışmada kullanılan RF modelinin diğer modellere göre daha düşük hata oranları ve daha yüksek bir R^2 değeri sunduğunu göstermektedir. Özellikle, yerel rüzgar hızı ve yönü gibi temel parametrelerle sağlanan bu uyum, modelin tahminlerde istikrarlı bir doğruluk elde etmesini sağlamaktadır. Böylece, çalışmada kullanılan RF modeli, diğer yöntemlerle kıyaslandığında kısa dönemli tahminlerde güvenilir ve etkili bir çözüm sunmaktadır.

Bu modelin rüzgar enerjisinden elektrik enerjisi üretimi tahmininde kullanılması, özellikle rüzgar hızı ve rüzgar yönü gibi önemli özelliklerin karmaşıklığını ve zaman içindeki değişkenliğini modelleyebilme yeteneğinden kaynaklanmaktadır. Ancak modelin daha da iyileştirilmesi için farklı parametre ayarlarının ve özellik mühendisliği tekniklerinin detaylı bir şekilde incelenmesi gerekmektedir. Bu incelemeler, RF modelinin performansını daha da artırarak rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu ve güvenilirliğini artırmaktadır.

4.2. Destek Vektör Makinesi Modelinin Değerlendirilmesi

4.2.1. Model performansı

SVM modeli, rüzgar enerjisi tahminleri için kullanılan başka bir güçlü makine öğrenimi yöntemidir. SVM, özellikle yüksek boyutlu veri setlerinde karmaşık desenleri ve ilişkileri modellemede etkilidir. Bu çalışmada, SVM modelinin performansı aşağıdaki hata metrikleri kullanılarak değerlendirilmiştir:

- MAE: 87.897

- MSE: 36528.460

- R^2: 0.9247

Şekil 4.4, SVM modelinin tahminlerinde kullanılan MAE değerlerini göstermektedir. MAE, tahmin edilen ve gerçek değerler arasındaki farkların mutlak ortalamasını ifade eder ve düşük bir MAE, modelin genel tahmin doğruluğunu gösterir.

Şekil 4.5, modelin tahminlerindeki MSE değerlerini sunmaktadır. MSE, tahmin edilen ve gerçek değerler arasındaki farkların karelerinin ortalamasını ifade eder ve büyük sapmaların modele etkisini değerlendirmek için önemlidir. Şekilden, modelin tahmin hatalarının kabul edilebilir bir seviyede olduğu görülmektedir.

Şekil 4.6, R^2 değerlerini göstermektedir. R^2, modelin veri setindeki varyansın ne kadarını açıklayabildiğini ölçer ve yüksek bir R^2 değeri, modelin tahmin doğruluğunun oldukça yüksek olduğunu göstermektedir. Bu çalışmada, SVM modeli veri setindeki varyansın %92.47'sini açıklayarak güçlü bir performans sergilemektedir.

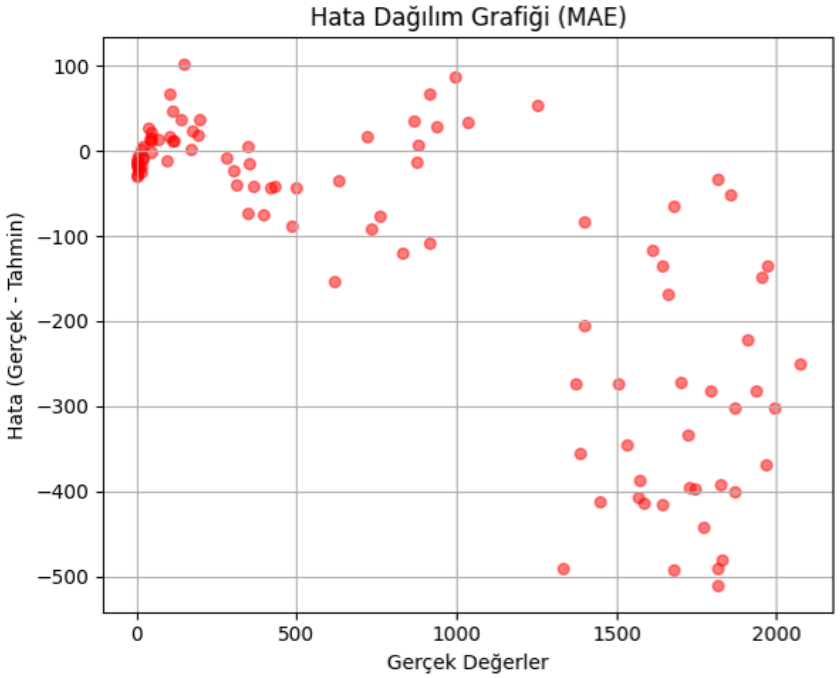

Şekil 4.4: SVM İçin MAE Değerleri

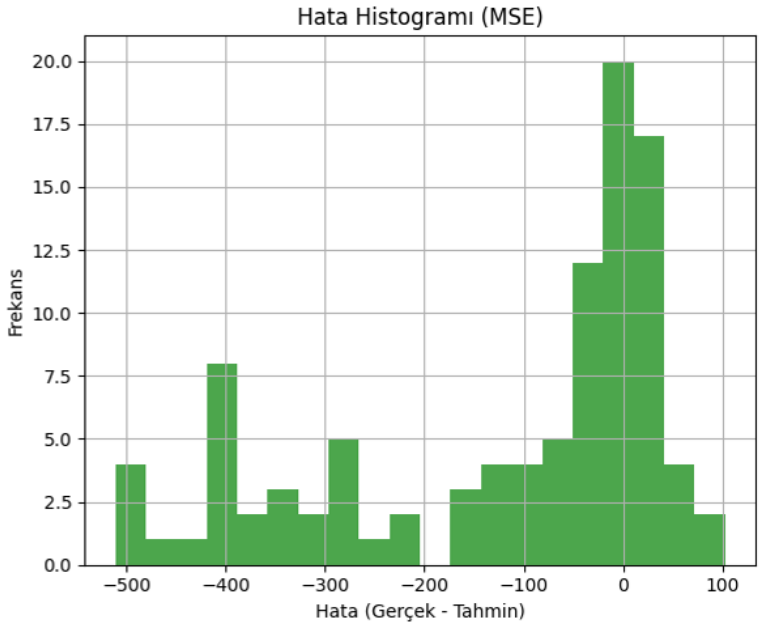

Şekil 4.5: SVM İçin MSE Değerleri

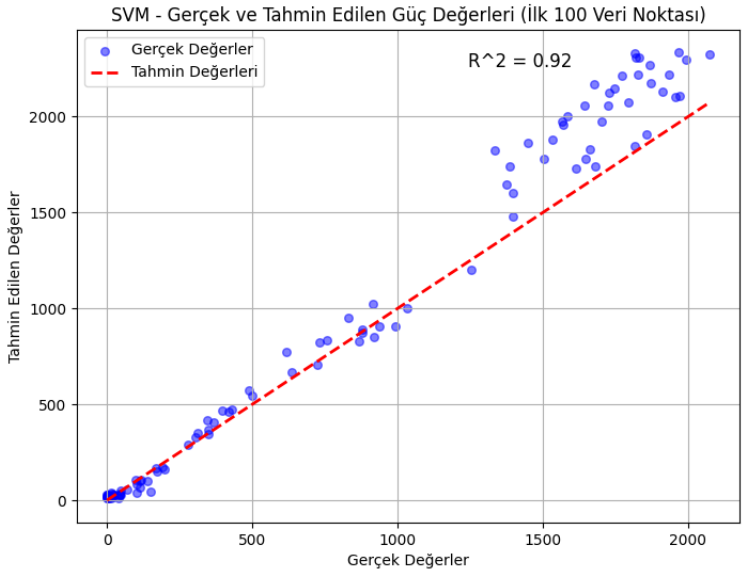

Şekil 4.6: SVM İçin R^2 Değerleri

Bu metrikler, SVM modelinin rüzgar enerjisi üretim tahminlerinde yüksek bir doğruluk seviyesine ulaştığını göstermektedir. R^2 değeri, modelin veri setindeki varyansın %92.47'sini açıklayabildiğini belirtir bu da modelin tahmin yeteneğinin yüksek olduğunu göstermektedir.

4.2.2. Tartışma

SVM modeli, veri setlerindeki karmaşık ilişkileri modelleme yeteneği nedeniyle rüzgar enerjisinden elektrik enerjisi üretimi tahmininde etkili bir araçtır. Modelin yüksek R^2 değeri, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerindeki başarısını göstermektedir. Ancak SVM modelinin performansını daha da iyileştirmek için hiperparametre ayarlarının ve çekirdek fonksiyon seçiminin optimize edilmesi gerekmektedir. Ayrıca modelin zamanla ilişkili desenleri yakalama kabiliyetini artırmak için zaman serisi verileriyle daha fazla çalışma yapılması önem arz etmektedir.

Bu çalışmada kullanılan SVM modelinin kısa dönemli rüzgar gücü tahminindeki başarımı, literatürdeki diğer SVM modelleri ile sayısal olarak karşılaştırılmaktadır. Modelin elde ettiği MAE: 87.897, MSE: 36.528 ve R^2: 0.9247 değerleri, literatürdeki benzer çalışmalara kıyasla dikkat çekici bir doğruluğa ulaşmaktadır. Zeng ve Qiao'nun önerdiği SVM modeli, kısa dönemli tahminlerde MAE: 65.3 ve MSE: 28.9 değerlerine ulaşarak yüksek doğruluk sergilemektedir; ancak bu doğruluk seviyesi için modelin hiperparametrelerinin detaylı bir optimizasyon sürecinden geçmesi gerekmektedir[119]. Ding ve arkadaşlarının hibrit kernel tabanlı SVM modelinde ise MAE: 72.45 ve MSE: 31.502 değerleri kaydedilmekte olup, modelin karmaşıklığı ve çoklu kernel yapısı, işlem maliyetini artıran unsurlar olarak öne çıkmaktadır[62].

Bu bağlamda, çalışmada kullanılan SVM modelinin diğer modellere kıyasla daha az işlem gücü gerektirmesi, önemli bir avantaj sunmaktadır. Diğer çalışmaların daha düşük hata oranlarına sahip olmasının başlıca nedenleri, kullanılan veri setlerinin çeşitliliği ve karmaşık optimizasyon süreçlerinin uygulanmış olmasıdır. Bu faktörler dikkate alındığında, bu çalışmadaki SVM modeli, doğruluğunu optimize etme sürecini sadeleştirerek veri uyumunu sağlamakta ve işlem maliyeti açısından daha verimli bir yapı sunmaktadır.

SVM modelinin kullanımı, özellikle rüzgar hızı ve rüzgar yönü gibi önemli özellikleri içeren karmaşık veri setlerinde yüksek doğrulukta tahminler üretebilir. Ancak modelin karmaşıklığı ve yorumlanabilirliğin sınırlı olması gibi zorluklar da bulunmaktadır. Bu zorlukların üstesinden gelmek için, modelin daha anlaşılır hale getirilmesine yardımcı olacak tekniklerin geliştirilmesi önem taşımaktadır.

4.3. Hibrit Modelinin Değerlendirilmesi

4.3.1. Model performansı

ANN modeli, rüzgar enerjisi üretim tahminlerinde kullanılan gelişmiş bir makine öğrenimi tekniğidir. ANN modeli, çok katmanlı algılayıcılar (MLPs) gibi karmaşık, doğrusal olmayan ilişkileri modelleme yeteneği ile bilinmektedir. Bu çalışmada, ANN modelinin performansı aşağıdaki metrikler kullanılarak değerlendirilmiştir:

- MAE: 4.953

- MSE: 52.170

- R^2: 0.9995

Bu metrikler, ANN modelinin rüzgar enerjisi üretim tahminlerinde olağanüstü bir doğruluk seviyesine ulaştığını göstermektedir. R^2 değeri, modelin veri setindeki varyansın %99.95'ini açıklayabildiğini gösterir bu da modelin tahmin yeteneğinin son derece yüksek olduğunu kanıtlamaktadır.

4.3.2. Tartışma

ANN modeli, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde yüksek performans göstermesiyle dikkat çekmektedir. Bu yüksek doğruluk, ANN'nin karmaşık ve zamanla değişen ilişkileri öğrenme ve modelleme yeteneğinden kaynaklanmaktadır. Ayrıca ANN modeli, büyük veri setleriyle çalışırken bile yüksek bir öğrenme kapasitesi ve adaptasyon yeteneği sunmaktadır.

Bu modelin başarısı, rüzgar enerjisinden elektrik enerjisi üretimi tahmininde ANN kullanımının potansiyelini vurgulamakta ve özellikle yüksek doğruluk gerektiren

uygulamalar için güçlü bir araç sunmaktadır. Ancak ANN modellerinin "kara kutu" doğası, model kararlarının yorumlanabilmesi konusunda zorluklar yaratabilmektedir. Bu sorunu ele almak için modelin karar yapısını daha şeffaf hale getirecek tekniklerin geliştirilmesi önem taşımaktadır.

Ayrıca, modelin eğitimi sırasında karşılaşılan zorluklar ve modelin genelleştirme yeteneği, gelecekteki araştırmalar için önemli düşünce alanları sunmaktadır. ANN modellerinin daha da geliştirilmesi rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu ve güvenilirliğini artırmada önemli bir rol oynayabilir.

Simülasyonlara dayanarak bireysel modellerin (RF ve SVM) performansı ile RF, SVM ve ANN içeren hibrit yaklaşımın performansı derinlemesine analiz edilmiştir. Şekil 4.7, hibrit modelin eğitim seti üzerinde elde ettiği MAE değerlerini göstermektedir. Şekil 4.8, hibrit modelin MSE değerlerini sunmaktadır. Şekil 4.9, hibrit modelin R^2 değerlerini göstermektedir. R^2, modelin veri setindeki varyansın ne kadarını açıklayabildiğini ifade eder. Şekilde görüldüğü üzere, hibrit model R^2 değeri açısından oldukça yüksek bir performans sergileyerek, tahmin edilen değerlerin gerçek verilerle büyük ölçüde örtüştüğünü göstermektedir. Bireysel modeller ve hibrit model için hata ölçümleri sunulmuş ve incelenmiştir.

RF modeli için hesaplanan hata ölçümleri şunlardır:

- MAE: 88.75900637097202

- MSE: 34173.24577660178

- R^2: 0.9318450263229781

SVM modelinin hata ölçümleri biraz farklıydı:

- MAE: 87.8972929881658

- MSE: 36528.4601911497

- R^2: 0.9247668876222306

Ancak, SVM, RF ve ANN modellerinden gelen tahminlerin birleştirildiği hibrit metodoloji, tahmin doğruluğunda önemli bir artış göstermiştir. Hibrit yaklaşımın ANN bileşeni aşağıdaki metrikleri göstermiştir:

- MAE: 4.953822250316712

- MSE: 52.1700614682648

- R^2: 0.9994940440855387

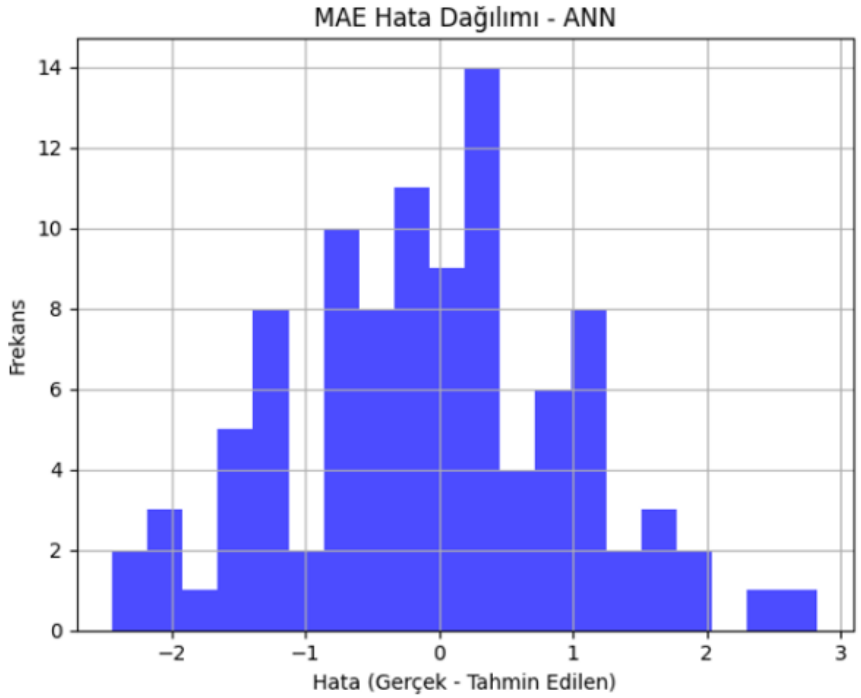

Şekil 4.7: ANN İçin MAE Değerleri

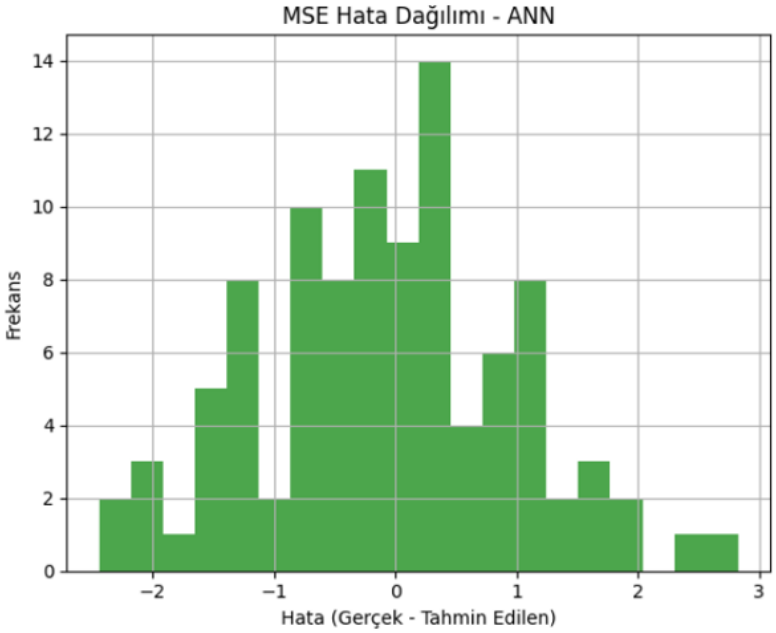

Şekil 4.8: ANN İçin MSE Değerleri

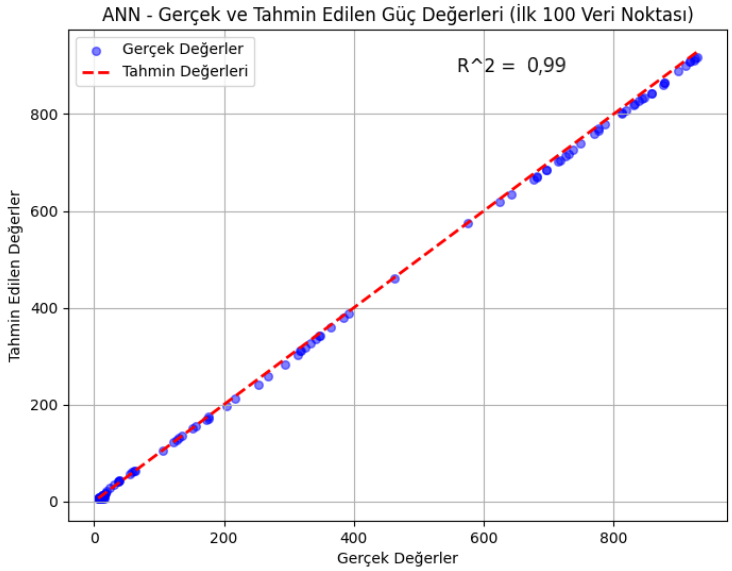

Şekil 4.9: ANN İçin R^2 Değerleri

Modelin başarısının daha fazla doğrulanması için eğitim ve test verilerinin oranları değiştirilerek daha fazla doğrulama yapılmıştır. Verilerin %40'ı eğitim için ayrıldığında ANN modeli metrikleri aşağıdaki gibidir:

- MAE: 82.16667423425238

- MSE: 32281.939591245162

- R^2: 0.9515782233351634

Şekil 4.10 %40 eğitim verisi için R^2 değerlerini göstermektedir.

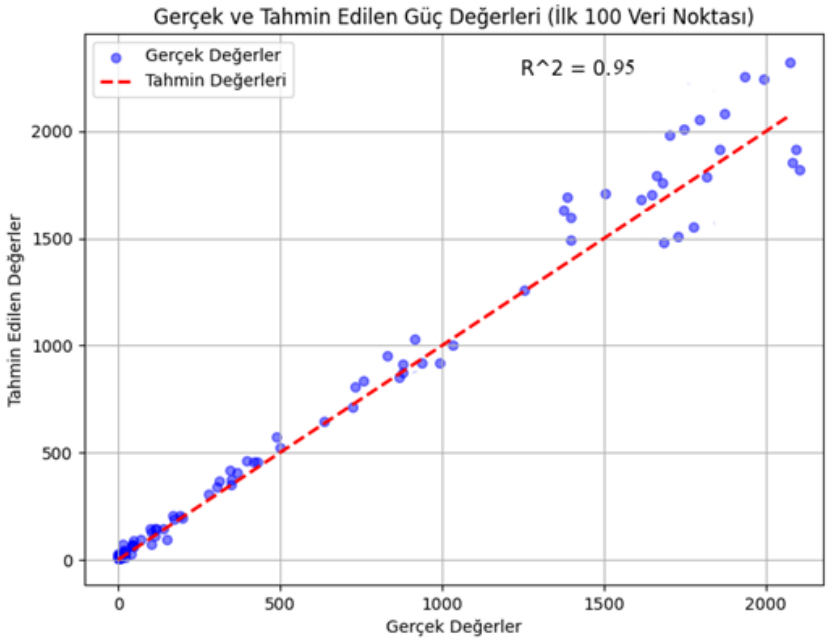

Şekil 4.10: %40 Eğitim Verisi İçin R^2 Değerleri

Eğitim verisinin %60'ına çıkarılmasıyla elde edilen sonuçlar ise şunlardır:

- MAE: 78.40750671861854

- MSE: 31889.523355440266

- R^2: 0.962320471292967

Şekil 4.11 ise eğitim verisinin %60 olduğu durum için R^2 değerlerinin grafiğini göstermektedir.

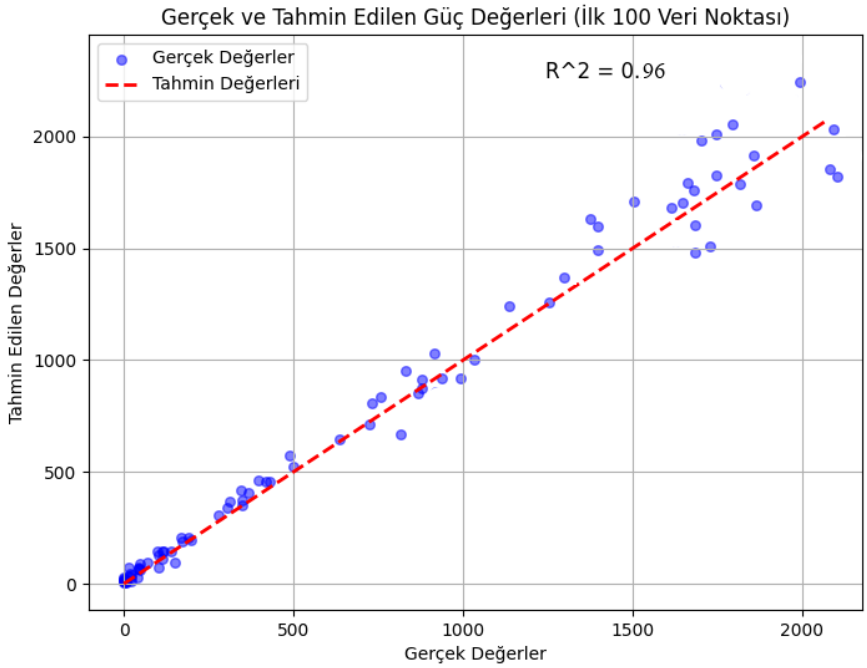

Şekil 4.11: %60 eğitim verisi için R^2 değerleri

Eğitim ve test verilerine yönelik ayarlanan veri bölümleri, R^2 puanlarında önemli iyileştirmeler ortaya koymuştur bu da modelin etkileyici tahmin doğruluğunu vurgulamıştır. Bireysel ve hibrit modellerin performans analizi, hibrit yaklaşımın rüzgar enerjisi üretimi tahmininin hassasiyetini önemli ölçüde artırdığını ortaya koymaktadır. RF modeli için R^2 değeri 0.93, SVM modeli için 0.92 olarak kaydedilmişken hibrit model bireysel modelleri önemli ölçüde geride bırakarak 0.99 R^2 değerine ulaşmıştır. Bu, hibrit modelin rüzgar enerjisi tahmini konusundaki başarısını vurgulamaktadır. Farklı eğitim ve test oranları, hibrit yaklaşımın sağlamlığını ve uyum sağlayabilmesini doğrulamış, modelin farklı veri kümelerindeki performansıyla ilgili kapsamlı bir bakış sunmuştur. Her modelin ilk 100 veri noktası için R^2 grafikleri sağlanmıştır bu da modellerin tahmin doğruluğunun detaylı bir görsel temsilini sunmaktadır.

Bu çalışmada, RF, SVM ve ANN'i birleştiren hibrit model, 0.99 R^2 ile önemli bir ilerleme kaydetmişken bireysel RF ve SVM modelleri sırasıyla 0.93 ve 0.92 R^2 değerlerine ulaşmıştır.

Bu, Alkabbani ve meslektaşlarının araştırmasıyla karşılaştırıldığında, hibrit yaklaşımın 0.95 R^2 değerine ulaşması dikkate değerdir. Bu, önerilen hibrit modelin birden fazla makine öğrenimi tekniğini entegre etme faydalarını daha etkili bir şekilde kullandığını göstermektedir[120]. Bouabdallaoui ve ekibinin çalışması, SVM modelinin 0.95 R^2 ile yüksek bir performans sergilediğinde, önerilen hibrit model bu kıyaslama değerinin üstesinden gelmiştir[121]. Chaudhary ve arkadaşları, RF (1.8999) ve Karar Ağacı (1.2169) için SVM'nin (20.8346) altında daha düşük MAPE değerleri bulmuş, bu da RF modelinin güçlü performansını pekiştirmiştir[122]. Ancak önerilen hibrit modelin 4.953 MAE ve 52.170 MSE değerleri, tahmin doğruluğunda daha da büyük bir iyileşme olduğunu göstermektedir. Bu sayısal karşılaştırmalar, önerilen hibrit yaklaşımın üstünlüğünü doğrulamanın yanı sıra rüzgar enerjisi tahmininde daha yüksek hassasiyet elde etmek için çeşitli makine öğrenimi tekniklerini birleştirme potansiyelini vurgulamaktadır.

4.5. Karşılaştırmalı Analiz

Bu bölümde, RF, SVM, ANN ve bu tekniklerin birleşiminden oluşan hibrit modelin performansları karşılaştırmalı olarak analiz edilmiştir. Her bir modelin performansı, MAE, MSE ve R^2 gibi hata metrikleri kullanılarak değerlendirilmiştir.

Tablo 4.4: Modellerin Hata Metrik Değerleri

MODEL	MAE	MSE	R2
RF	88,75900637	34.173,24578	0,931845026
SVM	87,89729299	36.528,46019	0,924766888
HİBRİT (ANN)	4,95382225	52,17006147	0,999494044
HİBRİT (ANN) (%40 EĞİTİM)	82,16667423	32.281,93959	0,951578223
HİBRİT (ANN) (%60 EĞİTİM)	78,40750672	31.889,52336	0,962320471

RF ve SVM modelleri, rüzgar enerjisi üretim tahminlerinde yüksek doğruluk seviyelerine ulaşmış olmalarına rağmen ANN ve özellikle hibrit model bu modelleri önemli ölçüde

aşmıştır. Hibrit model, ANN'in güçlü yönlerini RF ve SVM modelleri ile birleştirerek R^2 değerinde %99.95 gibi olağanüstü bir başarıya ulaşmıştır. Bu, hibrit modelin veri setindeki varyansın neredeyse tamamını açıklayabildiğini ve son derece yüksek bir tahmin doğruluğuna sahip olduğunu göstermektedir.

Karşılaştırmalı analiz, hibrit modelin, rüzgar enerjisi üretim tahminlerinde bireysel makine öğrenimi modellerine göre önemli bir iyileşme sağladığını ortaya koymuştur. Hibrit modelin başarısı, farklı makine öğrenimi tekniklerinin entegrasyonunun tahmin doğruluğunu nasıl artırabileceğinin güçlü bir kanıtıdır.

Bu analiz, rüzgar enerjisi tahminlerinde kullanılan farklı modellerin güçlü ve zayıf yönlerini ortaya koymakla kalmamış aynı zamanda hibrit modelleme yaklaşımının potansiyel avantajlarını da vurgulamıştır. Hibrit modelin yüksek performansı, rüzgar enerjisi tahminlerinde makine öğrenimi tekniklerinin gelecekteki uygulamaları için umut verici bir yol gösterici olabilir. Bu yaklaşım, daha doğru ve güvenilir rüzgar enerjisi tahminleri elde etmek için farklı modellerin ve tekniklerin nasıl etkili bir şekilde birleştirilebileceğine dair değerli içgörüler sunmaktadır.

Tablo 4.5: Kullanılan Tahmin Yöntemlerinin Özellikleri

Tahmin Yöntemi	Avantajları	Dezavantajları	Uygulama Bulguları
Rastgele Orman (RF)	Aşırı uyuma karşı robust, değişken önemini belirleme kabiliyeti	Karar yapısı karmaşık olabilir, yorumlanabilirliği sınırlı	İyi genelleme yapabilme ve yüksek varyanslı verilerde stabil performans gösterme
Destek Vektör Makineleri (SVM)	Yüksek boyutlu uzaylarda etkili, marjinal ayrımı iyi yapar	Parametre seçiminde hassas, ölçeklendirmesi zor	Lineer olmayan ilişkileri iyi modelleme, ancak büyük veri setlerinde yavaş çalışma
Yapay Sinir Ağları (ANN)	Güçlü öğrenme kapasitesi, karmaşık ilişkileri öğrenebilme	"Kara kutu" modeli, veriye duyarlılık	Çok çeşitli durumları modelleyebilme, fakat model optimizasyonu için uzmanlık gereksinimi
Hibrit Modeller	Farklı tahmin modellerinin güçlü yönlerini bütünleştirme, esnek yapılar	Kurulum ve yorumlama karmaşık olabilir	Yüksek tahmin doğruluğu, fakat uygun hiperparametre seçimi ve model validasyonu zorlayıcı olabilir

4.6. İçgörüler ve Etkiler

Bu çalışmanın sonuçları, rüzgar enerjisi üretim tahminlerinde makine öğrenimi ve hibrit modelleme tekniklerinin etkin kullanımının önemini ortaya koymaktadır. Karşılaştırmalı analiz, hibrit modelin bireysel RF, SVM ve ANN modellerine kıyasla önemli bir doğruluk artışı sağladığını göstermiştir. Hibrit modelin R^2 değerinin %99.95'e ulaşması, modelin veri setindeki varyansın neredeyse tamamını açıklayabildiğini ve bu tekniklerin rüzgar enerjisi tahminlerinde son derece etkili olduğunu kanıtlamaktadır.

Bu bulgular, enerji yönetimi ve planlaması alanında önemli etkilere sahiptir. Hibrit modelin yüksek doğruluk seviyesi, enerji üreticilerine ve şebeke operatörlerine daha güvenilir tahminler sunarak rüzgar enerjisinin etkin bir şekilde entegrasyonunu ve yönetimini sağlar. Bu, enerji piyasalarının daha etkili işlemesine, enerji depolama ve talep yanıtı stratejilerinin optimizasyonuna ve nihayetinde yenilenebilir enerji kaynaklarının daha geniş kabulüne katkıda bulunmaktadır.

Ayrıca bu çalışma, rüzgar enerjisi tahminlerini iyileştirmek için farklı makine öğrenimi modellerinin ve tekniklerinin nasıl birleştirilebileceğine dair değerli içgörüler sunmaktadır. Hibrit modelleme yaklaşımı, gelecekteki araştırmalarda keşfedilmek üzere yeni yollar açmakta ve makine öğrenimi modellerinin performansını artırmak için çeşitli tekniklerin entegrasyonunun potansiyelini vurgulamaktadır.

Son olarak, bu çalışmanın sonuçları, rüzgar enerjisi üretim tahminlerindeki doğruluğu artırma çabalarının sürdürülebilir ve yenilenebilir enerji sistemlerine geçişte kritik bir rol oynadığını göstermektedir. Hibrit modelleme tekniklerinin başarılı uygulanması, enerji sistemlerinin güvenilirliğini ve verimliliğini artırarak yenilenebilir enerjinin genel kabulünü ve kullanımını teşvik etmektedir. Bu çalışma, rüzgar enerjisi tahmin alanında ilerlemeye yönelik sağlam bir temel sağlar ve makine öğrenimi ve hibrit modelleme tekniklerinin gelecekteki uygulamaları için yol göstericidir.

4.7. Model Geliştirme Sürecinde Karşılaşılan Zorluklar

Model geliştirme sürecinde, altı yıllık, on dakika aralıklarla toplanan kapsamlı veri setlerinin analizi ve yönetimi önemli zorluklar oluşturmaktadır. İlk etapta, 22 türbin arasından en

anlamlı veriye sahip türbinin seçilmesi, veri ön işleme, eksik veya hatalı verilerin düzeltilmesi gibi süreçler zaman ve emek yoğun çalışmalar gerektirmektedir. Modelin karmaşıklığı ise, farklı modelleri deneme ve parametre ayarlamaları yapma, özellik mühendisliği teknikleri uygulayarak veri setinin doğruluğunu ve model performansını artırma çalışmalarını kapsamaktadır. Bu süreçler, yüksek işlem gücü gerektiren ve uzun süreler alan işlemler olup veri bilimcilerinin sabır ve titizliğini test etmektedir. Bu zorluklar, özellikle büyük ölçekli veri setleriyle çalışırken model geliştirmenin zorunlu parçaları olarak ortaya çıkmaktadır.

4.8. Uygulama Perspektifleri ve Endüstriyel Uyumluluk

Uygulamaya geçirildiğinde bu tür bir model, rüzgar enerjisi tahminlerinin doğruluğunu artırarak enerji piyasalarında ve şebeke işletmecilerinde önemli iyileştirmeler sağlayabilir. Endüstriyel ölçekte uygulanan model, enerji üretim planlamasını iyileştirebilir ve yenilenebilir enerji kaynaklarının entegrasyonunu hızlandırabilir. Modelin etkinliği, farklı enerji tahmin projelerindeki başarı öyküleri ve araştırma bulgularının enerji politikaları yapımında nasıl değerli bir kaynak olabileceğiyle desteklenebilir. Enerji sektöründe karşılaşılan mevcut zorlukların üstesinden gelmede ve yenilenebilir enerji kaynaklarının potansiyelinden tam olarak yararlanmada önemli bir adım olabilir.

Bunun yanı sıra, enerji piyasalarının etkin işleyişini sağlamak ve piyasadaki katılımcıların adil bir şekilde tekliflerini sunmalarını sağlamak için belirli süreçler uygulanmaktadır. Bu süreçlerin doğru ve şeffaf bir şekilde yönetilmesi, enerji piyasasının sağlıklı işleyişine katkı sağlamaktadır.

Gün Öncesi Piyasası sürecinde şu adımlar izlenir:

- Teklif Bildirimi (12:30'a kadar): Piyasa katılımcıları, bir sonraki güne ait tekliflerini Piyasa İşletmecisine iletir.
- Teminat Kontrolü (12:30-13:00): Piyasa açılışı öncesinde teminat kontrolleri yapılır.
- Teklif Doğrulama (12:30-13:00): Bildirilen teklifler Piyasa İşletmecisi tarafından doğrulanır.

- Optimizasyon ve Fiyat Belirleme (13:00-13:30): Teyit edilen teklifler değerlendirilir ve piyasa takas fiyatları ve miktarları belirlenir.
- Ticari İşlem Onayları ve İtiraz (13:30-14:00): Onaylanan işlem miktarları piyasa katılımcılarına bildirilir. İtirazlar 13:30-13:50 arasında alınır ve 13:50-14:00 arasında değerlendirilir. Saat 14:00'da nihai fiyatlar ve eşleşmeler duyurulur.
- İkili Anlaşma Bildirimi (00:00-17:00): Piyasa katılımcıları, ikili anlaşmalarını Yeni Gün Öncesi Piyasası sistemine bildirir.
- İkili Anlaşmaların Kontrolü (17:00-17:05): İkili anlaşmalar Kontrol Prosedürüne İlişkin yöntemi ile kontrol edilir.
- İtiraz Süreci (17:05-17:15): Kontrol Prosedürüne İlişkin yöntemi uyarınca iptal edilen ikili anlaşmalar için itiraz süreci gerçekleştirilir.

Bu süreç, piyasa işleyişinin düzenli ve şeffaf şekilde yönetilmesini sağlar[110].

Enerji Piyasaları İşletme A.Ş.'nin belirlemiş olduğu kurallar doğrultusunda, gün öncesi piyasasında yer alan katılımcıların teklifleri, belirli süreçler dahilinde şeffaf bir şekilde değerlendirilir. Bu süreçler arasında tekliflerin sunulması, fiyatın belirlenmesi ve sonuçların açıklanması gibi aşamalar bulunmaktadır. Katılımcıların piyasaya sundukları teklifler, üretim ve tüketim dengelemelerini sağlamak amacıyla dikkatle analiz edilir.

Gün öncesi piyasası, elektrik enerjisinin verimli ve öngörülebilir bir şekilde tedarik edilmesi açısından kritik bir rol oynar. Bu piyasa sayesinde arz-talep dengesi sağlanırken, elektrik fiyatlarının stabil kalması da mümkün olmaktadır. Bu durum, tüm piyasa katılımcıları için öngörülebilirlik ve istikrar sağlar. Elektrik enerjisi üreten rüzgar santrallerinde bu süreçte üretim tahmini gerçekleştirmek, bir sonraki gün için teklif vermek açısından önemlidir. Bu kapsamda rüzgar hızı ve yönü gibi temel meteorolojik verilerin doğru tahmin üretilmesinde kritik rol üstlenirler. Şekil 4.12'de görüldüğü üzere GFS ve ECMWF gibi iki farklı meteorolojik veri kaynağı kullanılarak rüzgar enerjisi üretim tahminleri analiz edilmiştir[123]. Tablo 4.6'da, her iki veri kaynağından alınan rüzgar hızı ve sıcaklık bilgileri yer almaktadır. Analiz sonucunda her iki veri seti arasındaki belirgin farklılıkların enerji üretim tahminlerinde farklı sonuçlar doğurduğu gözlemlenmiştir. Bölüm 3.2'de belirtildiği üzere türbinlerin çalışmaya başlaması için en az 3m/s'lik rüzgar hızı gerekmektedir.

Özellikle, ECMWF verilerinde rüzgar hızının düşük olması durumunda üretim tahminlerinin de sıfır veya çok düşük değerlere düştüğü görülmektedir.

Tablo 4.6: GFS ve ECMWF Verilerine Göre Rüzgar Hızı ve Sıcaklık Değerleri

Tarih ve Saat	Rüzgar Hızı (m/s)		Sıcaklık (°C)	
	GFS	ECMWF	GFS	ECMWF
22/11/2024 20:00	4.3	1.4	6.2	9.3
23/11/2024 02:00	3.9	1.2	6.5	7.4
23/11/2024 08:00	4.4	1.2	7	9.3
23/11/2024 14:00	5.7	1.9	11	8.9
23/11/2024 20:00	6.2	2.2	7.4	9.1

Bu bulgu, endüstriyel uygulamalarda meteorolojik veri kaynaklarının dikkatli bir şekilde seçilmesi gerektiğine işaret etmektedir. Farklı meteorolojik veri setlerinin enerji üretim tahminleri üzerindeki etkisi, uygun veri kaynağının seçilmesinin büyük önem taşıdığını göstermektedir. Rüzgar enerjisi santrallerinin doğru planlanması ve üretim tahminlerinin sağlıklı yapılması için:

- Kullanılacak meteorolojik veri setlerinin güvenilirliğinin ve doğruluğunun artırılması,
- Çeşitli veri kaynaklarının sonuçlar üzerindeki etkisinin kapsamlı analizlerle değerlendirilmesi,
- Endüstriyel süreçlerde kullanılan modellerin, bu veri kaynakları arasındaki uyumluluğu göz önünde bulundurularak optimize edilmesi gerektiği vurgulanmaktadır.

Bu perspektif doğrultusunda, rüzgar enerjisi üretim tahminlerinin endüstriyel uygulamalar için daha verimli ve güvenilir hale getirilmesi sağlanabilir. GFS ve ECMWF gibi veri kaynaklarının karşılaştırılması ve elde edilen bulgular, endüstriyel uygulamalara uyumlu enerji tahmin modellerinin geliştirilmesi açısından önemli bir içgörü sunmaktadır.

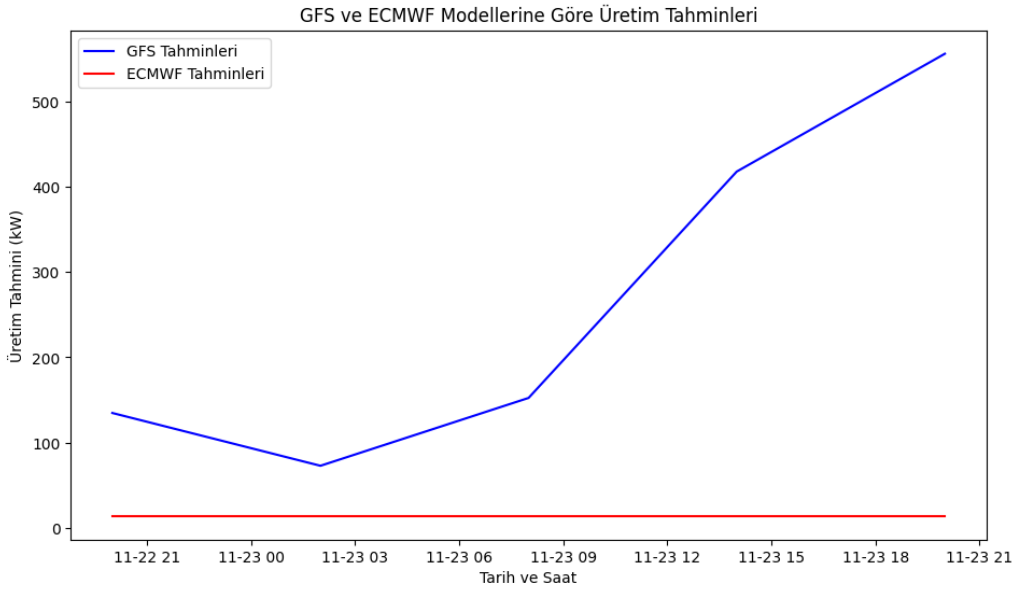

Şekil 4. 12: GFS ve ECMWF verilerine göre enerji üretim tahminleri arasındaki farklar.

5. SONUÇLAR

Bu çalışma, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu artırma amacıyla çeşitli makine öğrenimi modellerinin ve bir hibrit modelin uygulanabilirliğini detaylı bir şekilde incelemektedir. Araştırma sonuçları, RF, SVM, ANN ve bu tekniklerin entegre edildiği bir hibrit modelin performanslarını karşılaştırmaktadır. Sonuçlar, hibrit modelin bireysel modellere göre rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde önemli ölçüde daha yüksek bir doğruluk seviyesine ulaştığını göstermektedir. R^2 değeri %99.95 olarak belirlenen hibrit model, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde olağanüstü bir başarı sergilemekte ve veri setindeki varyansın neredeyse tamamını açıklamaktadır.

Bu sonuçlar, makine öğrenimi ve hibrit modelleme tekniklerinin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerindeki potansiyelini vurgulamaktadır. Hibrit modelin yüksek performansı, enerji üretimi ve yönetiminde karar verme süreçlerini desteklemekte ve rüzgar enerjisinin elektrik sistemlerine etkin entegrasyonunu ve yönetimini sağlamaktadır. Bu çalışma, hibrit makine öğrenimi modellerinin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde kullanılabilirliğini ve etkinliğini ortaya koymaktadır. Bu bulgular, literatürdeki boşlukları doldurmakta ve ileri araştırmalar için yeni bir temel oluşturmaktadır. Bu model, enerji piyasalarının daha etkili işlemesine ve enerji depolama ve talep yanıtı stratejilerinin optimizasyonuna katkı sağlamaktadır. Geliştirilen model, enerji üreticileri ve şebeke operatörleri için daha güvenilir ve doğru tahminler sunarak enerji arz-talep dengesinin daha etkin yönetilmesine katkıda bulunmaktadır.

Bu çalışmada benimsenen kapsamlı yaklaşım, çeşitli makine öğrenimi tekniklerini ve özellik mühendisliğini karmaşık bir şekilde birleştirerek rüzgar enerjisinden elektrik enerjisi üretimi tahmin doğruluğunu önemli ölçüde artırmaktadır. Veri toplama sürecinde eksik ve hatalı veriler önemli bir zorluk teşkil etmektedir. Bu durum, modelin performansını etkileyebilecek potansiyel bir sınırlılık olarak değerlendirilmektedir.

Sonuç olarak, araştırma rüzgar enerjisinden elektrik enerjisi üretimi tahmini için hibrit makine öğrenimi modellerine dayanmaktadır. RF ve SVM modellerinin sinerjik

entegrasyonu, güçlü bir hibrit sistem oluşturarak tahmin doğruluğunda önemli iyileştirmeler sağlamaktadır ve bu durum elde edilen yüksek R^2 skorlarıyla kanıtlanmaktadır. Yöntemin adaptasyon kabiliyeti ve sağlamlığı, çeşitli eğitim ve test verisi bölünmeleri üzerindeki tutarlı ve güvenilir performansıyla daha da desteklenmektedir. Bu çalışma, yalnızca Yahyalı Rüzgar Enerjisi Santrali verilerini kullanmaktadır. Farklı coğrafi bölgelerdeki rüzgar enerjisinden elektrik enerjisi üretimi santrallerinden elde edilen verilerle yapılacak çalışmalar, bulguların genelleştirilebilirliğini artırabilecektir.

Bu çalışma, hibrit modellerin tahmin doğruluğunu artırmada etkinliğini doğrulamanın yanı sıra yenilenebilir enerji araştırmalarını ilerletmede titiz veri analizi ve model değerlendirmesinin önemli rolünü vurgulamaktadır. Ayrıca bu modellerin başarılı bir şekilde uygulanması ve doğrulanması rüzgar enerjisinden elektrik enerjisi üretimi tahmin alanında öngörü analizi için değerli bilgiler ve güvenilir bir çerçeve sunarak gelecekteki çalışmalara referans noktası sağlamaktadır. Bu çalışmanın bulguları, daha optimize edilmiş ve verimli enerji yönetimi için yol açarak rüzgar enerjisinden elektrik enerjisi üretimi piyasalarına güvenilir bir şekilde katkı sağlayacak daha geniş sürdürülebilirlik ve yenilenebilir enerji kullanımı hedeflerine önemli ölçüde katkıda bulunmaktadır.

Bu tez, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu artırma amacıyla makine öğrenimi ve hibrit modelleme tekniklerinin uygulanabilirliğini detaylı bir şekilde incelemektedir. Çalışmanın katkıları şu ana başlıklar altında özetlenmektedir:

Yenilikçi Hibrit Model Yaklaşımı: Çalışma, RF, SVM ve ANN gibi farklı makine öğrenimi tekniklerinin bir araya getirilerek oluşturulan bir hibrit modelin geliştirilmesine odaklanmaktadır. Bu hibrit model, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde yüksek doğruluk seviyesi elde etmekte ve modelin veri setindeki varyansın neredeyse tamamını açıklayabildiği gösterilmektedir.

Makine Öğrenimi Tekniklerinin Karşılaştırmalı Analizi: Çalışma, farklı makine öğrenimi modellerinin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerindeki performanslarını karşılaştırmalı olarak analiz etmekte ve hibrit modelin bireysel modellere göre önemli bir doğruluk artışı sağladığını ortaya koymaktadır.

Enerji Yönetimi ve Planlaması Üzerine Etkiler: Hibrit modelin yüksek performansı, rüzgar enerjisinden elektrik enerjisi üretimi ve yönetiminde karar verme süreçlerini destekleyerek rüzgar enerjisinin etkin bir şekilde entegrasyonunu ve yönetimini sağlama potansiyeline sahiptir. Bu, enerji piyasalarının daha etkili işlemesine ve enerji depolama stratejilerinin optimizasyonuna katkıda bulunabilmektedir.

Gelecekteki Araştırmalara Yol Gösterici Olması: Bu çalışma, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerini iyileştirmek için farklı makine öğrenimi tekniklerinin nasıl birleştirilebileceğine dair değerli içgörüler sunmakta ve bu alanda daha ileri araştırmalar için sağlam bir temel oluşturmaktadır. Gelecek çalışmalarda, farklı coğrafi bölgelerden elde edilen veriler kullanılarak hibrit modelin genelleştirilebilirliği ve performansı değerlendirilebilir. Derin öğrenme tekniklerinin hibrit modellere entegrasyonu, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu daha da artırabilmektedir.

Çalışmanın bu katkıları, makine öğrenmesi ve hibrit modelleme tekniklerinin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerindeki potansiyelini vurgulamakta ve enerji sektöründe yenilikçi çözümler geliştirilmesine yönelik ilham kaynağı oluşturmaktadır. Bu çalışma, hibrit makine öğrenimi modellerinin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerindeki doğruluğunu artırarak, enerji piyasalarının daha istikrarlı ve öngörülebilir hale gelmesine katkıda bulunmaktadır. Doğru ve güvenilir rüzgar enerjisinden elektrik enerjisi üretimi tahmin modelleri, enerji politikalarının daha sağlam temellere oturtulmasına ve yenilenebilir enerji kaynaklarının daha etkin kullanılmasına olanak tanımaktadır.

Bu çalışmanın bulguları, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin doğruluğunu artırma çabalarında makine öğrenimi ve hibrit modelleme tekniklerinin önemli rol oynadığını göstermektedir. Gelecek araştırmalar için aşağıdaki öneriler sunulmaktadır:

1. Model Çeşitlemesi ve İyileştirme: Mevcut çalışmada kullanılan RF, SVM, ANN ve hibrit model dışında başka makine öğrenimi ve derin öğrenme modellerinin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerindeki potansiyeli araştırılmalıdır. Ayrıca model hiperparametrelerinin daha detaylı ayarlanması ve özellik mühendisliği tekniklerinin geliştirilmesiyle mevcut modellerin performansı iyileştirilebilmektedir.

2. Veri Setinin Genişletilmesi: Farklı coğrafi bölgelerden ve farklı türbin tiplerinden toplanan veri setlerinin kullanılması, modellerin genelleştirme yeteneğini ve uygulanabilirliğini test etmek için önemlidir. Ayrıca uzun dönemli veri setleri kullanarak modellerin zaman içindeki performans değişikliklerini incelemek de faydalı olacaktır.

3. Karmaşık Arazi Koşulları ve Deniz Üstü Rüzgar Çiftlikleri: Rüzgar enerjisinden elektrik enerjisi üretimi tahmin modellerinin karmaşık arazi koşullarında ve deniz üstü rüzgar çiftliklerinde nasıl performans gösterdiğini araştırmak, modelin uygulanabilirliğini geniş bir yelpazede test etmek için önemlidir.

4. Gerçek Zamanlı Tahminler: Rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinin gerçek zamanlı olarak nasıl optimize edilebileceğini ve tahminlerin enerji yönetimi sistemlerine nasıl entegre edilebileceğini araştırmak, bu alanda önemli bir araştırma konusudur.

5. Yenilenebilir Enerji Kaynaklarının Entegrasyonu: Rüzgar enerjisinden elektrik enerjisi üretimi tahminlerini, güneş enerjisi ve hidroelektrik gibi diğer yenilenebilir enerji kaynaklarıyla entegre eden kapsamlı bir enerji yönetimi modelinin geliştirilmesi, enerji sistemlerinin sürdürülebilirliğini artırabilmektedir.

Bu öneriler, rüzgar enerjisinden elektrik enerjisi üretimi tahminleri ve genel olarak yenilenebilir enerji yönetimi alanında ilerlemeyi teşvik ederek enerji sistemlerinin verimliliğini ve güvenilirliğini artıracak potansiyele sahiptir. Bu çalışma, hibrit makine öğrenimi modellerinin rüzgar enerjisinden elektrik enerjisi üretimi tahminlerindeki doğruluğunu artırarak enerji piyasalarının daha istikrarlı ve öngörülebilir hale gelmesine katkıda bulunmaktadır. Doğru ve güvenilir rüzgar enerjisinden elektrik enerjisi üretimi tahmin modelleri, enerji politikalarının daha sağlam temellere oturtulmasına ve yenilenebilir enerji kaynaklarının daha etkin kullanılmasına olanak tanımaktadır.

Bu tez, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde makine öğrenimi ve hibrit modelleme tekniklerinin potansiyelini detaylı bir şekilde incelemektedir. Yapılan çalışma, RF, SVM ve ANN gibi tekniklerin entegre edildiği hibrit modelin, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde yüksek doğruluk seviyelerine ulaşabileceğini

göstermektedir. Hibrit modelin bireysel makine öğrenimi modellerine göre önemli bir doğruluk artışı sağladığı ve modelin veri setindeki varyansın neredeyse tamamını açıklayabildiği belirlenmiştir.

Bu bulgular, rüzgar enerjisinden elektrik enerjisi üretimi tahminlerini iyileştirmek için makine öğrenimi ve hibrit modelleme tekniklerinin etkili bir şekilde nasıl kullanılabileceğine dair değerli içgörüler sunmaktadır. Ayrıca enerji üretimi ve yönetiminde karar verme süreçlerini destekleyerek rüzgar enerjisinden elektrik enerjisi üretiminin etkin bir şekilde entegrasyonunu ve yönetimini sağlama potansiyeline sahiptir.

Sonuç olarak, bu çalışma rüzgar enerjisinden elektrik enerjisi üretimi tahmin alanında ilerlemeye yönelik sağlam bir temel sunmakta ve makine öğrenimi ile hibrit modelleme tekniklerinin gelecekteki uygulamaları için yol gösterici olmaktadır. Rüzgar enerjisinden elektrik enerjisi üretimi tahminlerinde doğruluğu artırma çabaları, sürdürülebilir ve yenilenebilir enerji sistemlerine geçişte kritik bir rol oynamaktadır. Bu tez, bu alandaki bilgi birikimini zenginleştirmekte ve yenilikçi çözümler geliştirilmesine yönelik ilham kaynağı oluşturmaktadır.

KAYNAKÇA

[1] L. C. Cradden, G. P. Harrison, and J. P. Chick, “Will climate change impact on wind power development in the UK?,” *Climatic Change*, vol. 115, pp. 837–852, 2012.

[2] D. Hdidouan and I. Staffell, “The impact of climate change on the levelised cost of wind energy,” *Renewable Energy*, vol. 101, pp. 575–592, 2017.

[3] S. Niu, Z. Zhang, X. Ke, G. Zhang, C. Huo, and B. Qin, “Impact of renewable energy penetration rate on power system transient voltage stability,” *Energy Reports*, vol. 8, no. Supplement 1, pp. 487–492, 2022.

[4] R. Tawn and J. Browell, “A review of very short-term wind and solar power forecasting,” *Renewable and Sustainable Energy Reviews*, vol. 153, p. 111758, 2022.

[5] D. Maradin, “Advantages and disadvantages of renewable energy sources utilization,” *International Journal of Energy Economics and Policy*, 2021.

[6] “T.C. Enerji ve Tabii Kaynaklar Bakanlığı Bilgi Merkezi.” [Online]. Available: https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik 12/05/2023

[7] “Türkiye REPA.” [Online]. Available: https://repa.enerji.gov.tr/REPA/

[8] IRENA, “Renewable Energy Statistics 2023,” 2023.

[9] R. Meka, A. Alaeddini, and K. Bhaganagar, “A robust deep learning framework for short-term wind power forecast of a full-scale wind farm using atmospheric variables,” *Energy*, vol. 221, p. 119759, 2021, doi: https://doi.org/10.1016/j.energy.2021.119759.

[10] C. Monteiro *et al.*, “Wind power forecasting : state-of-the-art 2009.,” Nov. 2009, doi: 10.2172/968212.

[11] J. Zhang, M. Cui, B.-M. Hodge, A. Florita, and J. Freedman, “Ramp forecasting performance from improved short-term wind power forecasting over multiple spatial and temporal scales,” *Energy*, vol. 122, pp. 528–541, 2017, doi: https://doi.org/10.1016/j.energy.2017.01.104.

[12] A. Costa, A. Crespo, J. Navarro, G. Lizcano, H. Madsen, and E. Feitosa, “A review on the young history of the wind power short-term prediction,” *Renewable and Sustainable Energy Reviews*, vol. 12, no. 6, pp. 1725–1744, 2008, doi: https://doi.org/10.1016/j.rser.2007.01.015.

[13] Y. Chen, X. Hu, and L. Zhang, “A review of ultra-short-term forecasting of wind power based on data decomposition-forecasting technology combination model,” *Energy Reports*, vol. 8, pp. 14200–14219, 2022, doi: https://doi.org/10.1016/j.egyr.2022.10.342.

[14] Q. Chen and K. A. Folly, “Wind Power Forecasting,” *IFAC-PapersOnLine*, vol. 51, pp. 414–419, 2018.

[15] L. Landberg, “Short-term prediction of the power production from wind farms,” *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 80, no. 1, pp. 207–220, 1999, doi: https://doi.org/10.1016/S0167-6105(98)00192-5.

[16] A. Tascikaraoglu and M. Uzunoglu, “A review of combined approaches for prediction of short-term wind speed and power,” *Renewable and Sustainable Energy Reviews*, vol. 34, pp. 243–254, 2014, doi: https://doi.org/10.1016/j.rser.2014.03.033.

[17] S. Hanifi, X. Liu, Z. Lin, and S. Lotfian, “A Critical Review of Wind Power Forecasting Methods—Past, Present and Future,” *Energies*, vol. 13, no. 15, 2020, doi: 10.3390/en13153764.

[18] B. Yang *et al.*, “State-of-the-art one-stop handbook on wind forecasting technologies: An overview of classifications, methodologies, and analysis,” *Journal of Cleaner Production*, vol. 283, p. 124628, 2021, doi: https://doi.org/10.1016/j.jclepro.2020.124628.

[19] M. Li, M. Yang, Y. Yu, P. Li, Z. Si, and J. Yang, “Wind Power Probabilistic Forecasting Based on Wind Correction Using Weather Research and Forecasting Model,” in *2020 IEEE 3rd Student Conference on Electrical Machines and Systems (SCEMS)*, 2020, pp. 619–624. doi: 10.1109/SCEMS48876.2020.9352362.

[20] Y. Zhang, Y. Li, and G. Zhang, “Short-term wind power forecasting approach based on Seq2Seq model using NWP data,” *Energy*, vol. 213, p. 118371, 2020, doi: https://doi.org/10.1016/j.energy.2020.118371.

[21] M. Lei, L. Shiyan, J. Chuanwen, L. Hongling, and Z. Yan, “A review on the forecasting of wind speed and generated power,” *Renewable and Sustainable Energy Reviews*, vol. 13, no. 4, pp. 915–920, 2009, doi: https://doi.org/10.1016/j.rser.2008.02.002.

[22] X. Yang, Y. Xiao, and S. Chen, “Wind speed and generated power forecasting in wind farm,” *Proceedings-Chinese Society of Electrical Engineering*, vol. 25, no. 11, p. 1, 2005.

[23] D. Yang and J. Kleissl, “Summarizing ensemble NWP forecasts for grid operators: Consistency, elicitability, and economic value,” *International Journal of Forecasting*, vol. 39, no. 4, pp. 1640–1654, 2023, doi: https://doi.org/10.1016/j.ijforecast.2022.08.002.

[24] J. M. González-Sopeña, V. Pakrashi, and B. Ghosh, “An overview of performance evaluation metrics for short-term statistical wind power forecasting,” *Renewable and Sustainable Energy Reviews*, vol. 138, p. 110515, 2021, doi: https://doi.org/10.1016/j.rser.2020.110515.

[25] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, “Statistical and Machine Learning forecasting methods: Concerns and ways forward,” *PloS one*, vol. 13, no. 3, p. e0194889, 2018.

[26] M. J. Duran, D. Cros, and J. Riquelme, “Short-term wind power forecast based on ARX models,” *Journal of Energy Engineering*, vol. 133, no. 3, pp. 172–180, 2007.

[27] Y. Cao, Y. Liu, D. Zhang, W. Wang, and Z. Chen, “Wind power ultra-short-term forecasting method combined with pattern-matching and ARMA-model,” in *2013 IEEE Grenoble Conference*, 2013, pp. 1–4. doi: 10.1109/PTC.2013.6652257.

[28] M. Milligan, M. Schwartz, and Y. Wan, “Statistical Wind Power Forecasting Models: Results for U.S. Wind Farms; Preprint,” May 2003, [Online]. Available: https://www.osti.gov/biblio/15003903

[29] N. Korprasertsak and T. Leephakpreeda, “Robust short-term prediction of wind power generation under uncertainty via statistical interpretation of multiple forecasting models,” *Energy*, vol. 180, pp. 387–397, 2019, doi: https://doi.org/10.1016/j.energy.2019.05.101.

[30] B.-M. Hodge, A. Zeiler, D. Brooks, G. Blau, J. Pekny, and G. Reklatis, “Improved Wind Power Forecasting with ARIMA Models,” in *21st European Symposium on Computer Aided Process Engineering*, vol. 29, E. N. Pistikopoulos, M. C. Georgiadis, and A. C. Kokossis, Eds., in Computer Aided Chemical Engineering, vol. 29. , Elsevier, 2011, pp. 1789–1793. doi: https://doi.org/10.1016/B978-0-444-54298-4.50136-7.

[31] W. Zhang, Z. Lin, and X. Liu, “Short-term offshore wind power forecasting - A hybrid model based on Discrete Wavelet Transform (DWT), Seasonal Autoregressive Integrated Moving Average (SARIMA), and deep-learning-based Long Short-Term Memory (LSTM),” *Renewable Energy*, vol. 185, pp. 611–628, 2022, doi: https://doi.org/10.1016/j.renene.2021.12.100.

[32] Aasim, S. N. Singh, and A. Mohapatra, “Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting,” *Renewable Energy*, vol. 136, pp. 758–768, 2019, doi: https://doi.org/10.1016/j.renene.2019.01.031.
[33] X. Liu, Z. Lin, and Z. Feng, “Short-term offshore wind speed forecast by seasonal ARIMA - A comparison against GRU and LSTM,” *Energy*, vol. 227, p. 120492, 2021, doi: https://doi.org/10.1016/j.energy.2021.120492.
[34] S. Gao, Y. He, and H. Chen, “Wind speed forecast for wind farms based on ARMA-ARCH model,” in *2009 International Conference on Sustainable Power Generation and Supply*, 2009, pp. 1–4. doi: 10.1109/SUPERGEN.2009.5348142.
[35] M.-D. Wang, Q.-R. Qiu, and B.-W. Cui, “Short-term wind speed forecasting combined time series method and arch model,” in *2012 International Conference on Machine Learning and Cybernetics*, 2012, pp. 924–927. doi: 10.1109/ICMLC.2012.6359477.
[36] P. Lv and L. Yue, “Short-term wind speed forecasting based on non-stationary time series analysis and ARCH model,” in *2011 International Conference on Multimedia Technology*, 2011, pp. 2549–2553. doi: 10.1109/ICMT.2011.6002447.
[37] M. Ghofrani and M. Alolayan, *Time series and renewable energy forecasting*, vol. 10. IntechOpen, 2018.
[38] Z. Jiang, J. Che, and L. Wang, “Ultra-short-term wind speed forecasting based on EMD-VAR model and spatial correlation,” *Energy Conversion and Management*, vol. 250, p. 114919, 2021.
[39] M. He, V. Vittal, and J. Zhang, “A sparsified vector autoregressive model for short-term wind farm power forecasting,” in *2015 IEEE Power & Energy Society General Meeting*, IEEE, 2015, pp. 1–5.
[40] M. Koivisto *et al.*, “Wind speed modeling using a vector autoregressive process with a time-dependent intercept term,” *International Journal of Electrical Power & Energy Systems*, vol. 77, pp. 91–99, 2016, doi: https://doi.org/10.1016/j.ijepes.2015.11.027.
[41] H. H. H. Aly, “A Hybrid Optimized Model of Adaptive Neuro-Fuzzy Inference System, Recurrent Kalman Filter and Neuro-Wavelet for Wind Power Forecasting Driven by DFIG,” *Energy*, vol. 239, p. 122367, 2022, doi: https://doi.org/10.1016/j.energy.2021.122367.
[42] J. Heinermann and O. Kramer, “Machine learning ensembles for wind power prediction,” *Renewable Energy*, vol. 89, pp. 671–679, 2016, doi: https://doi.org/10.1016/j.renene.2015.11.073.
[43] P. Louka *et al.*, “Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering,” *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 96, no. 12, pp. 2348–2362, 2008, doi: https://doi.org/10.1016/j.jweia.2008.03.013.
[44] R. E. Kalman, “A new approach to linear filtering and prediction problems,” 1960.
[45] F. Cassola and M. Burlando, “Wind speed and wind energy forecast through Kalman filtering of Numerical Weather Prediction model output,” *Applied Energy*, vol. 99, pp. 154–166, 2012, doi: https://doi.org/10.1016/j.apenergy.2012.03.054.
[46] H. Demolli, A. S. Dokuz, A. Ecemis, and M. Gokcek, “Wind power forecasting based on daily wind speed data using machine learning algorithms,” *Energy Conversion and Management*, vol. 198, p. 111823, 2019, doi: https://doi.org/10.1016/j.enconman.2019.111823.
[47] T. M. Alabi *et al.*, “A review on the integrated optimization techniques and machine learning approaches for modeling, prediction, and decision making on integrated energy systems,” *Renewable Energy*, vol. 194, pp. 822–849, 2022, doi: https://doi.org/10.1016/j.renene.2022.05.123.

[48] J. Ferrero Bermejo, J. F. Gómez Fernández, F. Olivencia Polo, and A. Crespo Márquez, “A review of the use of artificial neural network models for energy and reliability prediction. A study of the solar PV, hydraulic and wind energy sources,” *Applied Sciences*, vol. 9, no. 9, p. 1844, 2019.

[49] Y. Sewsynker-Sukai, F. Faloye, and E. B. G. Kana, “Artificial neural networks: an efficient tool for modelling and optimization of biofuel production (a mini review),” *Biotechnology & Biotechnological Equipment*, vol. 31, no. 2, pp. 221–235, 2017.

[50] S. V. Medina and U. P. Ajenjo, “Performance Improvement of Artificial Neural Network Model in Short-term Forecasting of Wind Farm Power Output,” *Journal of Modern Power Systems and Clean Energy*, vol. 8, no. 3, pp. 484–490, 2020, doi: 10.35833/MPCE.2018.000792.

[51] M. C. Mabel and E. Fernandez, “Analysis of wind power generation and prediction using ANN: A case study,” *Renewable Energy*, vol. 33, no. 5, pp. 986–992, 2008, doi: https://doi.org/10.1016/j.renene.2007.06.013.

[52] S. Ansari, T. G. Sampath Vinayak Kumar, and J. Dhillon, “Wind Power Forecasting using Artificial Neural Network,” in *2021 4th International Conference on Recent Developments in Control, Automation & Power Engineering (RDCAPE)*, 2021, pp. 35–37. doi: 10.1109/RDCAPE52977.2021.9633643.

[53] G. Kariniotakis, E. Nogaret, and G. Stavrakakis, “A fuzzy logic and a neural network based wind power forecasting model,” in *1996 European Union Wind Energy Conference, EUWEC’96*, 1996, pp. 596–599.

[54] K. B. Sahay and K. Singh, “Short-Term Price Forecasting by Using ANN Algorithms,” in *2018 International Electrical Engineering Congress (iEECON)*, 2018, pp. 1–4. doi: 10.1109/IEECON.2018.8712254.

[55] A. Zendehboudi, M. A. Baseer, and R. Saidur, “Application of support vector machine models for forecasting solar and wind energy resources: A review,” *Journal of Cleaner Production*, vol. 199, pp. 272–285, 2018, doi: https://doi.org/10.1016/j.jclepro.2018.07.164.

[56] N. Vinay, A. S. Bale, S. Tiwari, and C. R. Baby, “Artificial intelligence as a tool for conservation and efficient utilization of renewable resource,” *Artificial intelligence for renewable energy systems*, pp. 37–77, 2022.

[57] O. Chapelle, V. Vapnik, O. Bousquet, and S. Mukherjee, “Choosing multiple parameters for support vector machines,” *Machine learning*, vol. 46, pp. 131–159, 2002.

[58] C. Cortes and V. Vapnik, “Support vector machine,” *Machine learning*, vol. 20, no. 3, pp. 273–297, 1995.

[59] J. Tinoco, A. G. Correia, and P. Cortez, “Support vector machines applied to uniaxial compressive strength prediction of jet grouting columns,” *Computers and Geotechnics*, vol. 55, pp. 132–140, 2014, doi: https://doi.org/10.1016/j.compgeo.2013.08.010.

[60] S. J. Ghoushchi, S. Manjili, A. Mardani, and M. K. Saraji, “An extended new approach for forecasting short-term wind power using modified fuzzy wavelet neural network: A case study in wind power plant,” *Energy*, vol. 223, p. 120052, 2021, doi: https://doi.org/10.1016/j.energy.2021.120052.

[61] Najeebullah, A. Zameer, A. Khan, and S. G. Javed, “Machine Learning based short term wind power prediction using a hybrid learning model,” *Computers & Electrical Engineering*, vol. 45, pp. 122–133, 2015, doi: https://doi.org/10.1016/j.compeleceng.2014.07.009.

[62] M. Ding *et al.*, “A time series model based on hybrid-kernel least-squares support vector machine for short-term wind power forecasting,” *ISA Transactions*, vol. 108, pp. 58–68, 2021, doi: https://doi.org/10.1016/j.isatra.2020.09.002.
[63] L.-L. Li, X. Zhao, M.-L. Tseng, and R. R. Tan, “Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm,” *Journal of Cleaner Production*, vol. 242, p. 118447, 2020, doi: https://doi.org/10.1016/j.jclepro.2019.118447.
[64] T. Ji, J. Wang, M. Li, and Q. Wu, “Short-term wind power forecast based on chaotic analysis and multivariate phase space reconstruction,” *Energy Conversion and Management*, vol. 254, p. 115196, 2022, doi: https://doi.org/10.1016/j.enconman.2021.115196.
[65] A. Lahouar and J. B. H. Slama, “Hour-ahead wind power forecast based on random forests,” *Renewable Energy*, vol. 109, pp. 529–541, 2017, doi: https://doi.org/10.1016/j.renene.2017.03.064.
[66] A. Wang *et al.*, “Random-forest based adjusting method for wind forecast of WRF model,” *Computers & Geosciences*, vol. 155, p. 104842, 2021, doi: https://doi.org/10.1016/j.cageo.2021.104842.
[67] zexian Sun, mingyu Zhao, yan Dong, xin Cao, and H. Sun, “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*, vol. 221, p. 119848, 2021, doi: https://doi.org/10.1016/j.energy.2021.119848.
[68] H. Wang, Z. Lei, X. Zhang, B. Zhou, and J. Peng, “A review of deep learning for renewable energy forecasting,” *Energy Conversion and Management*, vol. 198, p. 111799, 2019, doi: https://doi.org/10.1016/j.enconman.2019.111799.
[69] Q. Hu, R. Zhang, and Y. Zhou, “Transfer learning for short-term wind speed prediction with deep neural networks,” *Renewable Energy*, vol. 85, pp. 83–95, 2016, doi: https://doi.org/10.1016/j.renene.2015.06.034.
[70] Z. Zhang, H. Dai, D. Jiang, Y. Yu, and R. Tian, “Multi-step ahead forecasting of wind vector for multiple wind turbines based on new deep learning model,” *Energy*, p. 131964, 2024.
[71] G. E. Hinton, “Deep belief networks,” *Scholarpedia*, vol. 4, no. 5, p. 5947, 2009.
[72] H. Z. Wang, G. B. Wang, G. Q. Li, J. C. Peng, and Y. T. Liu, “Deep belief network based deterministic and probabilistic wind speed forecasting approach,” *Applied Energy*, vol. 182, pp. 80–93, 2016, doi: https://doi.org/10.1016/j.apenergy.2016.08.108.
[73] L. Yu, Y. Ma, Y. Ma, and G. Zhang, “A complexity-trait-driven rolling decomposition-reconstruction-ensemble model for short-term wind power forecasting,” *Sustainable Energy Technologies and Assessments*, vol. 49, p. 101794, 2022, doi: https://doi.org/10.1016/j.seta.2021.101794.
[74] G. Sun *et al.*, “Short-term wind power forecasts by a synthetical similar time series data mining method,” *Renewable Energy*, vol. 115, pp. 575–584, 2018, doi: https://doi.org/10.1016/j.renene.2017.08.071.
[75] B. Gu, T. Zhang, H. Meng, and J. Zhang, “Short-term forecasting and uncertainty analysis of wind power based on long short-term memory, cloud model and non-parametric kernel density estimation,” *Renewable Energy*, vol. 164, pp. 687–708, 2021, doi: https://doi.org/10.1016/j.renene.2020.09.087.
[76] P. Lu, L. Ye, M. Pei, Y. Zhao, B. Dai, and Z. Li, “Short-term wind power forecasting based on meteorological feature extraction and optimization strategy,” *Renewable Energy*, vol. 184, pp. 642–661, 2022, doi: https://doi.org/10.1016/j.renene.2021.11.072.

[77] J. Zhang, H. Meng, B. Gu, and P. Li, “Research on short-term wind power combined forecasting and its Gaussian cloud uncertainty to support the integration of renewables and EVs,” *Renewable Energy*, vol. 153, pp. 884–899, Jun. 2020, doi: 10.1016/j.renene.2020.01.062.

[78] D. A. Wood, “Hourly-averaged solar plus wind power generation for Germany 2016: Long-term prediction, short-term forecasting, data mining and outlier analysis,” *Sustainable Cities and Society*, vol. 60, p. 102227, 2020, doi: https://doi.org/10.1016/j.scs.2020.102227.

[79] P. Du, J. Wang, W. Yang, and T. Niu, “A novel hybrid model for short-term wind power forecasting,” *Applied Soft Computing*, vol. 80, pp. 93–106, 2019, doi: https://doi.org/10.1016/j.asoc.2019.03.035.

[80] Z. Jinhua, Y. Jie, W. U. Wenjing, and L. I. U. Yongqian, “Research on Short-term Forecasting and Uncertainty of Wind Turbine Power Based on Relevance Vector Machine,” *Energy Procedia*, vol. 158, pp. 229–236, 2019, doi: https://doi.org/10.1016/j.egypro.2019.01.081.

[81] M. AlShafeey and C. Csaki, “Adaptive machine learning for forecasting in wind energy: A dynamic, multi-algorithmic approach for short and long-term predictions,” *Heliyon*, vol. 10, no. 15, 2024.

[82] J. Naik, S. Dash, P. K. Dash, and R. Bisoi, “Short term wind power forecasting using hybrid variational mode decomposition and multi-kernel regularized pseudo inverse neural network,” *Renewable Energy*, vol. 118, pp. 180–212, 2018, doi: https://doi.org/10.1016/j.renene.2017.10.111.

[83] K. Qu, G. Si, Z. Shan, X. Kong, and X. Yang, “Short-term forecasting for multiple wind farms based on transformer model,” *Energy Reports*, vol. 8, pp. 483–490, 2022, doi: https://doi.org/10.1016/j.egyr.2022.02.184.

[84] X. Liu, J. Zhou, and H. Qian, “Short-term wind power forecasting by stacked recurrent neural networks with parametric sine activation function,” *Electric Power Systems Research*, vol. 192, p. 107011, 2021, doi: https://doi.org/10.1016/j.epsr.2020.107011.

[85] U. Ahmed, S. S. Abbas, S. Razzaq, and A. Mahmood, “A novel integrated approach for short-term wind power forecasting,” in *2024 7th International Conference on Energy Conservation and Efficiency (ICECE)*, IEEE, 2024, pp. 1–6.

[86] B. Xiong, L. Lou, X. Meng, X. Wang, H. Ma, and Z. Wang, “Short-term wind power forecasting based on Attention Mechanism and Deep Learning,” *Electric Power Systems Research*, vol. 206, p. 107776, 2022, doi: https://doi.org/10.1016/j.epsr.2022.107776.

[87] J.-F. Toubeau, P.-D. Dapoz, J. Bottieau, A. Wautier, Z. D. Grève, and F. Vallée, “Recalibration of recurrent neural networks for short-term wind power forecasting,” *Electric Power Systems Research*, vol. 190, p. 106639, 2021, doi: https://doi.org/10.1016/j.epsr.2020.106639.

[88] J. Zhang, J. Yan, D. Infield, Y. Liu, and F. Lien, “Short-term forecasting and uncertainty analysis of wind turbine power based on long short-term memory network and Gaussian mixture model,” *Applied Energy*, vol. 241, pp. 229–244, 2019, doi: https://doi.org/10.1016/j.apenergy.2019.03.044.

[89] J. Duan *et al.*, “Short-term wind power forecasting using the hybrid model of improved variational mode decomposition and Correntropy Long Short -term memory neural network,” *Energy*, vol. 214, p. 118980, 2021, doi: https://doi.org/10.1016/j.energy.2020.118980.

[90] H. H. Çevik, M. Çunkaş, and K. Polat, “A new multistage short-term wind power forecast model using decomposition and artificial intelligence methods,” *Physica A: Statistical*

Mechanics and its Applications, vol. 534, p. 122177, 2019, doi: https://doi.org/10.1016/j.physa.2019.122177.

[91] L.-L. Li, Z.-F. Liu, M.-L. Tseng, K. Jantarakolica, and M. K. Lim, "Using enhanced crow search algorithm optimization-extreme learning machine model to forecast short-term wind power," *Expert Systems with Applications*, vol. 184, p. 115579, 2021, doi: https://doi.org/10.1016/j.eswa.2021.115579.

[92] T. Ahmad, D. Zhang, and C. Huang, "Methodological framework for short-and medium-term energy, solar and wind power forecasting with stochastic-based machine learning approach to monetary and energy policy applications," *Energy*, vol. 231, p. 120911, 2021, doi: https://doi.org/10.1016/j.energy.2021.120911.

[93] J. Liu, X. Wang, and Y. Lu, "A novel hybrid methodology for short-term wind power forecasting based on adaptive neuro-fuzzy inference system," *Renewable Energy*, vol. 103, pp. 620–629, 2017, doi: https://doi.org/10.1016/j.renene.2016.10.074.

[94] J. Qin, J. Yang, Y. Chen, Q. Ye, and H. Li, "Two-stage short-term wind power forecasting algorithm using different feature-learning models," *Fundamental Research*, vol. 1, no. 4, pp. 472–481, 2021, doi: https://doi.org/10.1016/j.fmre.2021.06.010.

[95] M. Dadkhah, M. J. Rezaee, and A. Z. Chavoshi, "Short-term power output forecasting of hourly operation in power plant based on climate factors and effects of wind direction and wind speed," *Energy*, vol. 148, pp. 775–788, 2018, doi: https://doi.org/10.1016/j.energy.2018.01.163.

[96] M. Ding, H. Zhou, H. Xie, M. Wu, Y. Nakanishi, and R. Yokoyama, "A gated recurrent unit neural networks based wind speed error correction model for short-term wind power forecasting," *Neurocomputing*, vol. 365, pp. 54–61, 2019, doi: https://doi.org/10.1016/j.neucom.2019.07.058.

[97] J. Duan, P. Wang, W. Ma, S. Fang, and Z. Hou, "A novel hybrid model based on nonlinear weighted combination for short-term wind power forecasting," *International Journal of Electrical Power & Energy Systems*, vol. 134, p. 107452, 2022, doi: https://doi.org/10.1016/j.ijepes.2021.107452.

[98] Q. Xing, J. Wang, H. Lu, and S. Wang, "Research of a novel short-term wind forecasting system based on multi-objective Aquila optimizer for point and interval forecast," *Energy Conversion and Management*, vol. 263, p. 115583, 2022, doi: https://doi.org/10.1016/j.enconman.2022.115583.

[99] D. T. Viet, V. V. Phuong, M. Q. Duong, A. Kies, B. U. Schyska, and Y. K. Wu, "A Short-Term Wind Power Forecasting Tool for Vietnamese Wind Farms and Electricity Market," in *2018 4th International Conference on Green Technology and Sustainable Development (GTSD)*, 2018, pp. 130–135. doi: 10.1109/GTSD.2018.8595557.

[100] S. Sun, W. Zheng, and J. Zhang, "A Short-Term Wind Power Prediction Forecasting using Variational Modes Decomposition Based on Long-Short Term Memory," in *2021 International Conference on Information Technology and Biomedical Engineering (ICITBE)*, 2021, pp. 25–29. doi: 10.1109/ICITBE54178.2021.00015.

[101] D. Kumar, R. Abhinav, and N. Pindoriya, "An Ensemble Model for Short-Term Wind Power Forecasting using Deep Learning and Gradient Boosting Algorithms," in *2020 21st National Power Systems Conference (NPSC)*, 2020, pp. 1–6. doi: 10.1109/NPSC49263.2020.9331902.

[102] M. Maurya and A. K. Goswami, "Attention Based Short Term Wind Power Forecasting Using Sample Entropy And Correlation Analysis for Noise filtration," in *2022 IEEE International*

Conference on Power Electronics, Smart Grid, and Renewable Energy (PESGRE), 2022, pp. 1–7. doi: 10.1109/PESGRE52268.2022.9715886.
[103] X. Zheng, X. Qi, H. Liu, X. Liu, and Y. Li, "Deep Neural Network for Short-Term Offshore Wind Power Forecasting," in *2018 OCEANS - MTS/IEEE Kobe Techno-Oceans (OTO)*, 2018, pp. 1–5. doi: 10.1109/OCEANSKOBE.2018.8559431.
[104] A. Singh, K. Gurtej, G. Jain, F. Nayyar, and M. M. Tripathi, "Short term wind speed and power forecasting in Indian and UK wind power farms," in *2016 IEEE 7th Power India International Conference (PIICON)*, 2016, pp. 1–5. doi: 10.1109/POWERI.2016.8077339.
[105] X. Weidong, L. Yibing, and L. Xingpei, "Short-term forecasting of wind turbine power generation based on Genetic Neural Network," in *2010 8th World Congress on Intelligent Control and Automation*, 2010, pp. 5943–5946. doi: 10.1109/WCICA.2010.5554476.
[106] Z. Sun and M. Zhao, "Short-Term Wind Power Forecasting Based on VMD Decomposition, ConvLSTM Networks and Error Analysis," *IEEE Access*, vol. 8, pp. 134422–134434, 2020, doi: 10.1109/ACCESS.2020.3011060.
[107] P. Jeyakumar, N. Kolambage, N. Geeganage, G. Amarasinghe, and S. K. Abeygunawardane, "Short-term Wind Power Forecasting Using a Markov Model," in *2021 3rd International Conference on Electrical Engineering (EECon)*, 2021, pp. 19–24. doi: 10.1109/EECon52960.2021.9580963.
[108] Y. Biçen, "Türkiye elektrik enerjisi piyasası gelişim süreci: Gün öncesi ve dengeleme güç piyasası özellikleri," *Karaelmas Fen ve Mühendislik Dergisi*, vol. 6, no. 2, pp. 432–438, 2016.
[109] C. Yıldız and M. Şekkeli, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 22, no. 5, pp. 361–366, Oct. 2016, [Online]. Available: https://dergipark.org.tr/en/pub/pajes/issue/24961/263446
[110] "EPİAŞ Gün Öncesi Piyasası Süreçleri." [Online]. Available: https://www.epias.com.tr/gun-oncesi-piyasasi/surecler/ 22/11/2024
[111] Q. Wang, H. Wu, A. R. Florita, C. B. Martinez-Anido, and B.-M. Hodge, "The value of improved wind power forecasting: Grid flexibility quantification, ramp capability analysis, and impacts of electricity market operation timescales," *Applied Energy*, vol. 184, pp. 696–713, 2016, doi: https://doi.org/10.1016/j.apenergy.2016.11.016.
[112] L. Exizidis, S. J. Kazempour, P. Pinson, Z. de Greve, and F. Vallée, "Sharing wind power forecasts in electricity markets: A numerical analysis," *Applied Energy*, vol. 176, pp. 65–73, 2016, doi: https://doi.org/10.1016/j.apenergy.2016.05.052.
[113] "Nordex N117 2,4MW Datasheet."
[114] "Kayseri REPA." [Online]. Available: https://repa.enerji.gov.tr/REPA/iller/KAYSERI-REPA.pdf10/06/2023
[115] W. Shen, N. Jiang, and N. Li, "An EMD-RF Based Short-term Wind Power Forecasting Method," in *2018 IEEE 7th Data Driven Control and Learning Systems Conference (DDCLS)*, 2018, pp. 283–288. doi: 10.1109/DDCLS.2018.8515901.
[116] Y. Wang, Y. Fan, P. Bhatt, and C. Davatzikos, "High-dimensional pattern regression using machine learning: From medical images to continuous clinical variables," *NeuroImage*, vol. 50, no. 4, pp. 1519–1535, 2010, doi: https://doi.org/10.1016/j.neuroimage.2009.12.092.
[117] H. Geng, F. Song, J. Shen, and J. Li, "A classification and regression assisted optimization algorithm for high-dimensional expensive many-objective problems," *Neurocomputing*, vol. 586, p. 127629, 2024, doi: https://doi.org/10.1016/j.neucom.2024.127629.

[118] S. T. Ayele, M. B. Ageze, M. A. Zeleke, and T. A. Miliket, “Adama II wind farm long-term power generation forecasting based on machine learning models,” *Scientific African*, vol. 21, p. e01831, 2023, doi: https://doi.org/10.1016/j.sciaf.2023.e01831.

[119] J. Zeng and W. Qiao, “Support vector machine-based short-term wind power forecasting,” in *2011 IEEE/PES Power Systems Conference and Exposition*, 2011, pp. 1–8. doi: 10.1109/PSCE.2011.5772573.

[120] H. Alkabbani, F. Hourfar, A. Ahmadian, Q. Zhu, A. Almansoori, and A. Elkamel, “Machine Learning-based Time Series Modelling for Large-Scale Regional Wind Power Forecasting: a Case Study in Ontario, Canada,” *Cleaner Energy Systems*, vol. 5, p. 100068, 2023, doi: https://doi.org/10.1016/j.cles.2023.100068.

[121] D. Bouabdallaoui, T. Haidi, F. Elmariami, M. Derri, and E. M. Mellouli, “Application of four machine-learning methods to predict short-horizon wind energy,” *Global Energy Interconnection*, vol. 6, no. 6, pp. 726–737, 2023, doi: https://doi.org/10.1016/j.gloei.2023.11.006.

[122] A. Chaudhary, A. Sharma, A. Kumar, K. Dikshit, and N. Kumar, “Short term wind power forecasting using machine learning techniques,” *Journal of Statistics and Management Systems*, vol. 23, no. 1, pp. 145–156, 2020.

[123] “Meteorolojik Veri,” Nov. 22, 2024. [Online]. Available: https://www.wetterzentrale.de/en/show_diagrams.php?geoid=117068&model=gfs&var=2&run=12&lid=ENS&bw=1

ÖZGEÇMİŞ

EZGİ ARSLAN TUNCAR

Elektrik ve Elektronik Mühendisi

Sydney, NSW

Eğitim

Elektrik ve Elektronik Mühendisliği Doktora Programı, Marmara Üniversitesi, İstanbul, Türkiye
(Şubat 2020 – Aralık 2024)
Tez Konusu: Gün Öncesi Elektrik Piyasası İçin Kısa Dönemli Rüzgar Gücü Üretim Tahmin Yöntemi

Elektrik ve Elektronik Mühendisliği Yüksek Lisans, Marmara Üniversitesi, İstanbul, Türkiye
(Şubat 2015 – Haziran 2019)
Tez Konusu: Fotovoltaik güç sistemlerinin stadyumlara entegre edilmesi

Elektrik ve Elektronik Mühendisliği, Sakarya Üniversitesi, Sakarya, Türkiye
(Eylül 2011 – Haziran 2013)

İş Deneyimi

Elektrik Mühendisi, Güneş Enerjisi Uzmanı, Solaviva, Sydney, NSW
(Haziran 2023 – Günümüz)

Öğretim Görevlisi, Ataşehir Adıgüzel Meslek Yüksekokulu, İstanbul, Türkiye
(Ocak 2020 – Şubat 2023)

Elektrik ve Elektronik Mühendisi, Proje Mühendisi, UDG, Bakü, Azerbaycan
(Nisan 2017 – Eylül 2019)

Elektrik ve Elektronik Mühendisi, Güneş Enerjisi Uzmanı, EFTCG, İstanbul, Türkiye
(Kasım 2016 – Ocak 2017)

Elektrik ve Elektronik Mühendisi, Güneş Enerjisi Uzmanı, Özyer Group, Muğla, Türkiye
(Aralık 2015 – Şubat 2016)

Elektrik ve Elektronik Mühendisi, Aktif Elektrik, İstanbul, Türkiye
(Ağustos 2014 – Aralık 2015)

Yayınlar

- Oral, B., Arslan Tuncar, E., "Integration of Photovoltaic Power Systems onto Stadium Roofs: Sustainability and Energy Economics", 8. International Advanced Technologies Symposium, Elazığ, 2017
- Oral, B., Arslan Tuncar, E., "Evaluation Of Stadiums In Urban Areas For Photovoltaic Potential: A Case Study", Academic Journal Of Science, ISSN: 2165-6282, 08(01):89–100 (2018)
- E. Arslan Tuncar ve İ. Kıyak, "Economic Analysis of Maglev Train Technology: A Case Study for Ankara-Sivas Line", Kırklareli University Journal of Engineering and Science, vol. 7, no. 2, pp. 205-220, Dec. 2021
- Arslan Tuncar, E., Sağlam, Ş., & Oral, B. "A Review of Short-Term Wind Power Generation Forecasting Methods in Recent Technological Trends", Energy Reports, 12, 197-209. (2024)