

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ORCID

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce

Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : / /

Tezin Savunma Tarihi : / /

Tez Danışmanı :
ORCID : - - -

Trabzon

ÖNSÖZ

“Meteorolojik Faktörlerin Rüzgâr Enerji Santrallerine Etkisi” konulu bu tez çalışmasında, rüzgâr enerji santrallerinin performansını etkileyen meteorolojik faktörlerin kapsamlı bir biçimde incelenmesi amaçlanmıştır. Çalışma kapsamında elde edilen veriler, yürütülen literatür araştırmaları ve gerçekleştirilen analizler, rüzgâr enerjisi alanındaki bilimsel bilgi birikimine katkı sağlamayı hedeflemektedir.

Tezimin hazırlanması sürecinde öncelikle, değerli bilgi ve tecrübeleriyle her aşamada bana rehberlik eden danışmanım Doç. Dr. Zeynep HASIRCI TUĞCU’ya sabrı, desteği ve yol göstericiliği için sonsuz teşekkür ederim. Araştırma sürecinde motivasyonumu artıran, sabrı ve anlayışıyla her zaman yanımda olan eşim Murat ŞİMŞEK’e teşekkür ederim. Bu süreçte gösterdiği anlayış, bu tezin tamamlanmasında büyük rol oynamıştır. Ayrıca, verdikleri değerli veri desteği ve katkıları için Demirer Holding A.Ş. Ömer Ergin Bey’e, Elektrik/Elektronik Mühendisi Kadriye Şenay POSLU ÇILDAN’a, bu çalışmaya doğrudan veya dolaylı olarak katkı sağlayan tüm dostlarıma, meslektaşlarıma ve emeği geçen herkese teşekkür ederim.

Hatice ŞİMŞEK

Trabzon 2025

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Meteorolojik Faktörlerin Rüzgâr Enerji Santrallerine Etkisi” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Zeynep HASIRCI TUĞCU sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 12/09/2025

Hatice ŞİMŞEK

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	X
SEMBOLLER VE KISALTMALAR DİZİNİ	XI
1. GENEL BİLGİLER	1
1.1. Giriş	1
1.2. Çalışmanın Amacı ve Önemi	1
1.3. Literatür Araştırması.....	2
1.4. Dünyada ve Türkiye’de Rüzgâr Enerjisine Genel Bir Bakış	11
1.4.1. Dünyada Rüzgâr Enerjisi.....	12
1.4.2. Türkiye’de Rüzgâr Enerjisi	14
1.5. Rüzgâr Enerjisi ve Teknolojileri.....	16
1.5.1. Rüzgâr Enerjisinin Tanımı	16
1.5.2. Rüzgâr Enerjisinin Avantajları ve Dezavantajları	16
1.5.3. Rüzgâr Enerjisi Teknolojileri	17
1.5.4. Rüzgâr Türbinlerinin Çalışma Prensipleri	19
1.5.5. Rüzgâr Türbinlerinin Çalışmasını Etkileyen Faktörler	21
1.6. Rüzgâr Enerjisi Üretiminin Teorik Temelleri.....	22
1.6.1. Rüzgâr Hızı ve Güç İlişkisi	22
1.7. Rüzgâr Türbin Performansı ve Değerlendirme Kriterleri	23
1.7.1. Güç Katsayısı (C_p) ve Betz Limiti.....	23
1.7.2. Kapasite Faktörü (CF)	23
1.7.3. Güç Eğrisi ve Verimlilik Analizi.....	24
1.8. Meteorolojik Faktörlerin Enerji Üretimine Etkisi	25
1.8.1. Rüzgâr Hızı.....	26
1.8.2. Rüzgâr Yönü.....	26

1.8.3. Hava Sıcaklığı ve Hava Yoğunluğu	27
1.8.4. Nem ve Yağış	27
1.9. Makine Öğrenmesi Modelleri	27
1.9.1. Hafif Gradyan Artırmalı Makine (Light Gradient Boosting Machine – LightGBM)	28
1.9.2. Rastgele Orman (Random Forest - RF)	29
1.9.3. Geliştirilmiş Gradyan Artırma (Extreme Gradient Boosting - XGBoost).	30
1.9.4. K-En Yakın Komşu (K-Nearest Neighbors - KNN)	31
1.10. Performans Kriterleri	33
1.10.1. Ortalama Mutlak Hata (Mean Absolute Error– MAE)	34
1.10.2. Kök Ortalama Kare Hata (Root Mean Squared Error- RMSE).....	34
1.10.3. Determinasyon Katsayısı (R-Squared- R^2).....	35
2. YAPILAN ÇALIŞMALAR.....	36
2.1. Problemin Tanımı	36
2.2. Meteorolojik Veriler	36
2.2.1. Bahar Mevsimi (Nisan Ayı) Meteorolojik Verilerin Karşılaştırılması.....	37
2.2.2. Yaz Mevsimi (Ağustos Ayı) Meteorolojik Verilerin Karşılaştırılması.....	39
2.2.3. Kış Mevsimi (Aralık Ayı) Meteorolojik Verilerin Karşılaştırılması.....	41
2.3. Materyal ve Yöntem	44
2.4. Verilerin Düzenlenmesi	45
2.5. Korelasyon Analizi	46
3. BULGULAR VE TARTIŞMA.....	48
3.1. Hiperparametre Optimizasyonu Sonuçlarının Karşılaştırmalı Analizi (Optuna Tabanlı Bayesçi Yaklaşım)	48
3.2. Makine Öğrenmesi Algoritmalarının Performanslarının Değerlendirilmesi	50
3.2.1. RF Algoritması Enerji Üretim Tahmin Performansı	51
3.2.2. KNN Algoritması Enerji Üretim Tahmin Performansı	52
3.2.3. XGBoost Algoritması Enerji Üretim Tahmin Performansı.....	53
3.2.4. LightGBM Algoritması Enerji Üretim Tahmin Performansı	54
3.3. Performans Metrikleri.....	54
4. SONUÇLAR VE ÖNERİLER.....	56
5. KAYNAKLAR	59
ÖZGEÇMİŞ	

Yüksek Lisans Tezi

ÖZET

METEOROLOJİK FAKTÖRLERİN RÜZGÂR ENERJİ SANTRALLERİNE ETKİSİ

Hatice ŞİMŞEK

Karadeniz Teknik Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Zeynep HASIRCI TUĞCU

2025, 63 sayfa

Rüzgâr enerjisi, dünya genelinde giderek daha fazla önem kazanan yenilenebilir ve sürdürülebilir bir enerji kaynağıdır. Ancak, rüzgâr hızının değişkenliği rüzgâr enerjisi üretiminde belirsizlikler yaratmakta ve bu durum, şebeke entegrasyonu ile enerji planlaması açısından önemli sıkıntılara yol açmaktadır. Bu çalışmanın amacı, meteorolojik verileri kullanarak K-En Yakın Komşu (K-Nearest Neighbors - KNN), Geliştirilmiş Gradyan Artırma (Extreme Gradient Boosting - XGBoost), Rastgele Orman (Random Forest - RF) ve Hafif Gradyan Artırmalı Makine (Light Gradient Boosting Machine – LightGBM) algoritmalarının rüzgâr enerjisi üretimindeki tahmin performanslarını karşılaştırmalı olarak incelemektir. Çalışmada bir rüzgâr enerji santraline ait geçmişe yönelik üretim verileri kullanılmıştır. Tahmin modellerinde kullanılan giriş değişkenleri rüzgâr hızı, kanat açısı, sıcaklık, rotor hızı ve nacelle yönü; çıkış değişkeni ise rüzgâr enerjisi üretimidir. Her bir modelin tahmin performansını artırmak için hiperparametre optimizasyonu Bayesçi optimizasyon yöntemine dayanan Optuna kütüphanesi kullanılarak gerçekleştirilmiş ve bu aşamada 5 katlı çapraz doğrulama (K-Fold Cross Validation) tekniği uygulanmıştır. Modellerin tahmin doğrulukları; Kök Ortalama Kare Hata (Root Mean Square Error – RMSE), Ortalama Mutlak Hata (Mean Absolute Error - MAE) ve Belirleme Katsayısı (Coefficient of Determination - R^2) gibi istatistiksel performans ölçütleriyle değerlendirilmiştir.

Anahtar Kelimeler: Rüzgâr enerjisi, XGBoost, KNN, Random Forest, LightGBM, Bayesçi optimizasyonu, enerji tahmini

Master Thesis

SUMMARY

THE EFFECT OF METEOROLOGICAL FACTORS ON WIND POWER PLANTS

Hatice ŞİMŞEK

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Graduate Program
Supervisor: Assoc. Prof. Zeynep HASIRCI TUĞCU
2025, 63 Pages

Wind energy is a renewable and sustainable energy source which gains increasingly more importance around the world. However, the instability of wind speed creates uncertainties in wind energy production and this leads to significant problems in terms of grid integration and energy planning. The aim of this study is to comparatively examine the predictive performances of K-Nearest Neighbors (KNN), Extreme Gradient Boosting (XGBoost), Random Forest (RF) and Light Gradient Boosting Machine (LightGBM) algorithms in wind power generation using meteorological data. Historical generation data of a wind power plant were used in the study. The input variables used in the forecast models are wind speed, blade angle, temperature, rotor speed, and nacelle direction; The output variable is wind power generation. In order to increase the prediction performance of each model, hyperparameter optimization was performed using the Optuna library based on the Bayesian optimization method, and at this stage, the 5-fold cross validation technique was applied. Prediction accuracy of models was evaluated with statistical performance criteria such as Root Mean Square Error (RMSE), Mean Absolute Error (MAE) and Coefficient of Determination (R^2).

Keywords: Wind Energy, XGBoost, KNN, Random Forest, LightGBM, Bayesian Optimization, Energy Forecasting

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.	Dünya rüzgâr enerjisi kurulu gücü	13
Şekil 2.	Türkiye'nin yıllara göre rüzgâr enerjisi kurulu gücü	15
Şekil 3.	Yatay eksenli rüzgâr türbini	18
Şekil 4.	Dikey Eksenli Rüzgâr Türbini	19
Şekil 5.	Türbin yapısı.....	20
Şekil 6.	Türbin güç eğrisi.....	24
Şekil 7.	LightGBM algoritma yapısı.....	28
Şekil 8.	RF Algoritma Yapısı.....	30
Şekil 9.	XGBoost algoritma yapısı	31
Şekil 10.	KNN Algoritmasının temel işleyişi	33
Şekil 11.	Nisan ayı MGM-RES rüzgâr hızı grafiği	37
Şekil 12.	Nisan ayı MGM-RES sıcaklık grafiği	38
Şekil 13.	Ağustos ayı MGM-RES rüzgâr hızı grafiği.....	39
Şekil 14.	Ağustos ayı MGM-RES sıcaklık grafiği	40
Şekil 15.	Aralık ayı MGM-RES rüzgâr hızı grafiği.....	41
Şekil 16.	Aralık ayı MGM-RES sıcaklık grafiği	42
Şekil 17.	Örnek RES verileri	45
Şekil 18.	Korelasyon matrisi.....	47
Şekil 19.	RF Enerji üretim tahmini	51
Şekil 20.	KNN Enerji üretim tahmini	52
Şekil 21.	XGBoost Enerji üretim tahmini.....	53
Şekil 22.	LightGBM Enerji üretim tahmini	54

TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Literatür özet tablosu	10
Tablo 2. 2024 Yılı itibarıyla en yüksek rüzgâr enerjisi kapasitesine sahip ülkeler.....	12
Tablo 3. Türbin güç eğrisi tablosu	25
Tablo 4. MGM ve RES ölçüm verilerinin karşılaştırılması	43
Tablo 5. Modellerin hiperparametreleri ve optimizasyon aralıkları.....	49
Tablo 6. Makine öğrenmesi modellerinin performans karşılaştırması.....	55



SEMBOLLER VE KISALTMALAR DİZİNİ

C_p	: Güç Katsayısı
$d(x, y)$	: İki Nokta Arasındaki Öklidyen Mesafesi
n	: Veri Noktası Sayısı
P	: Rüzgârın Teorik Gücü (Power)
R^2	: Belirleme Katsayısı
V	: Rüzgâr Hızı
$\hat{y}$	: Tahmin Edilen Değer
$\bar{y}$	: Gerçek Değerlerin Ortalaması
π	: Pi Sayısı (3.14159...)
ρ (rho)	: Hava Yoğunluğu
A	: Rotor Süpürme Alanı
AC	: Alternatif Akım
ACO	: Karınca Kolonisi Optimizasyonu
ARIMA	: Otoregresif Bütünleşik Hareketli Ortalama
BAP	: Bilimsel Araştırma Projeleri
CF	: Kapasite Faktörü
CFD	: Hesaplmalı Akışkanlar Dinamiği
CNN	: Evrişimli Sinir Ağı
DBSCAN	: Yoğunluk Tabanlı Uzamsal Kümeleme
DC	: Doğru Akım
EMA	: Üssel Hareketli Ortalama
ETKB	: Enerji ve Tabii Kaynaklar Bakanlığı
EWT	: Ampirik Dalgacık Dönüşümü
FFANN	: İleri Beslemeli Yapay Sinir Ağı
FS	: Tahmin Becerisi
GA	: Genetik Algoritma
GBM	: Gradyan Artırmalı Makine
GRU	: Geçitli Tekrarlayan Birim
GW	: Gigawatt (1 GW = 1000 Megawatt)
GWEC	: Küresel Rüzgâr Enerjisi Konseyi (Global Wind Energy Council)

HAWT	: Yatay Eksenli Rüzgâr Türbini (Horizontal Axis Wind Turbine)
IEEMD	: Geliştirilmiş Topluluk Ampirik Mod Ayırıştırması
IRENA	: Uluslararası Yenilenebilir Enerji Ajansı (International Renewable Energy Agency)
JADE	: Uyarlanabilir Diferansiyel Evrim Algoritması
KNN	: K-En Yakın Komşu
LightGBM	: Hafif Gradyan Artırmalı Makine
LSTM	: Uzun Kısa Süreli Bellek
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hata
MATLAB	: Matematiksel Hesaplama Yazılımı
MGM	: Meteoroloji Genel Müdürlüğü
MW	: Megawatt (1 MW = 1000 kilowatt)
NMAE	: Normalleştirilmiş Ortalama Mutlak Hata
NWP	: Sayısal Hava Tahmini
PSO	: Parçacık Sürüsü Optimizasyonu
RES	: Rüzgâr Enerji Santrali
RF / RFR	: Rastgele Orman / Rastgele Orman Regresyonu
RMSE	: Kök Ortalama Kare Hatası
RNN	: Tekrarlayan Sinir Ağı
SVM	: Destek Vektör Makinesi
TFT	: Zamansal Füzyon Transformatörü
TLBO	: Öğretim-Öğrenme Tabanlı Optimizasyon
TÜREB	: Türkiye Rüzgâr Enerjisi Birliği
URL	: Web Kaynağı Adresi (Uniform Resource Locator)
UYBHM	: Ulusal Yenilenebilir Enerji Bilgi Haritası
VAWT	: Dikey Eksenli Rüzgâr Türbini (Vertical Axis Wind Turbine)
WE-Validate	: Rüzgâr Enerjisi Tahmin Doğrulama Platformu
WindPRO	: Rüzgâr Enerjisi Simülasyon Yazılımı
WindSim	: CFD Tabanlı Rüzgâr Enerjisi Yazılımı
WRF	: Hava Araştırma ve Tahmin Modeli
WT	: Dalgacık Dönüşümü

XGBoost : Aşırı Gradyan Artırma
YSA / ANN : Yapay Sinir Ağı



1. GENEL BİLGİLER

1.1. Giriş

Küresel ölçekte ekonomik büyüme, sanayileşme, nüfus artışı ve teknolojik ilerlemeler, enerji talebinin sürekli artmasına neden olmaktadır. Uzun yıllardır petrol, doğal gaz ve kömür gibi fosil yakıtlar bu talebi karşılayan temel enerji kaynakları arasında yer almaktadır. Ancak bu yakıtların sınırlı rezervlere sahip olması, ülkeler arasında eşit dağılmaması ve çevre üzerinde yarattıkları olumsuz etkiler, hem çevresel hem de ekonomik açıdan önemli sorunlara yol açmaktadır. Bu durum, enerji güvenliği ile sürdürülebilirliğini öncelikli gündem konularından biri hâline getirmiştir. İklim değişikliği, küresel ısınma ve hava kirliliği gibi çevresel sorunlar da fosil yakıtlara olan bağımlılığın azaltılması gerekliliğini açıkça ortaya koymaktadır. Bu çerçevede, alternatif ya da yenilenebilir enerji kaynakları; enerji arz güvenliğini güçlendirmek ve çevresel sürdürülebilirliği desteklemek açısından stratejik önem taşımaktadır. Karbon salımını azaltma potansiyelleri sayesinde iklim değişikliğinin olumsuz etkilerini sınırlandıran bu kaynaklar, tükenmez yapıları ile uzun vadeli enerji çözümleri sunmaktadır. Rüzgâr, güneş, biyokütle, jeotermal ve hidroelektrik gibi yenilenebilir kaynaklar, hem yerel hem de küresel ölçekte enerji arzına katkı sağlayarak ülkelerin enerji bağımsızlığını artırmaktadır.

1.2. Çalışmanın Amacı ve Önemi

Bu çalışmanın temel hedefi, rüzgâr enerji santrallerinde elektrik üretimini belirleyen meteorolojik değişkenlerin etkisini veri odaklı bir bakış açısıyla incelemek ve farklı makine öğrenmesi modelleri kullanarak üretim tahminlerinin doğruluğunu artırmaktır. Temiz ve yenilenebilir bir kaynak olan rüzgâr enerjisi, enerji arz güvenliği bakımından stratejik bir konumda yer almaktadır. Ancak rüzgâr hızındaki dalgalanmalar ve meteorolojik koşullardaki belirsizlikler, üretim planlamasında öngörü hatalarına sebep olabilmektedir.

Bu doğrultuda, geçmiş üretim verilerinden yararlanılarak rüzgâr hızı, kanat açısı, rotor hızı, sıcaklık ve nacelle yönü gibi parametrelerin üretim üzerindeki etkileri analiz edilmiş; KNN, XGBoost, RF ve LightGBM gibi yüksek performanslı makine öğrenmesi

algoritmaları ile rüzgâr enerjisi üretim tahminleri gerçekleştirilmiştir. Modellerin başarı düzeyleri RMSE, MAE ve R^2 gibi performans ölçütleri ile değerlendirilmiştir.

Araştırma kapsamında, meteorolojik faktörlerin üretim tahminlerine etkisinin daha net biçimde ortaya konması, rüzgâr santrallerinin verimliliğinin yükseltilmesi ve üretim planlarının daha güvenilir hâle getirilmesi amaçlanmaktadır. Elde edilen bulguların hem akademik literatüre hem de enerji sektöründeki uygulamalara katkı sağlaması öngörülmektedir.

1.3. Literatür Araştırması

Ekmekçi, İ. ve ark., 2011, enerji üretim amaçlı yapılan rüzgâr ölçümleri ve rüzgâr enerjisi potansiyelinin belirlenmesini incelemiştir. Çalışmada, Sakarya-Esentepe bölgesi için rüzgâr enerjisi potansiyel analizi yapılmıştır. Bu amaç ile Sakarya-Esentepe bölgesinde kurulan rüzgâr ölçüm istasyonundan 2007 yılı Ocak, Şubat, Mart, Nisan, Mayıs ve Haziran aylarına ait rüzgâr hızı ve rüzgâr yönü verileri kullanılarak, Sakarya-Esentepe bölgesinin Rüzgâr enerjisi potansiyelinin ön araştırılması yapılmıştır. Bölgenin rüzgâr enerjisi potansiyeli Weibull dağılımı kullanılarak istatistiksel olarak incelenmiştir. Bu amaçla sayısal çözümleme için, Matlab programı geliştirilmiştir. Ayrıca rüzgâr verilerinin analizinde WindPRO yazılımı kullanılmıştır.

Efe, B., 2012, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) Araştırma Projeleri çerçevesinde 110Y050 numaralı "Kısa Vadeli Rüzgâr Enerjisi Tahmin Sistemi" adlı projesi kapsamında, Manisa ilinin Soma ilçesinde karmaşık bir arazi yapısında bulunan Soma Rüzgâr Enerji Santrali'nde rüzgâr enerjisinin çeşitli kilometre çözünürlükte ve 0-72 saatlik tahminler ile değerlendirilmesi amacıyla fiziksel bir rüzgâr enerjisi tahmin sistemi geliştirilmesi hedeflenmiştir. Bu çalışma kapsamında, Soma Rüzgâr Enerji Santrali'ne en yakın konumda bulunan Manisa Meteoroloji İstasyonundan 1977-2006 yılları arasında ölçüm değerleri alınan 30 yıllık aylık ortalama sıcaklık, maksimum sıcaklık, minimum sıcaklık, ortalama bağıl nem, toplam yağış ve ortalama günlük rüzgâr değerleri incelenmiştir. Ayrıca, santral sahasında yer alan ölçüm direğinden elde edilen rüzgâr verileri de kullanılarak bölgenin rüzgâr karakteristikleri oluşturulmuştur. Yapılan simülasyon çalışmaları ile yerel gözlemler arasında karşılaştırmalar gerçekleştirilmiş, basit lineer regresyon yöntemi kullanılarak tahminler ile gözlemler arasında lineer bir ilişki kurulmuştur.

Kurulan bu ilişki sayesinde elde edilen tahmin değerlerinin ne ölçüde iyileştirildiği belirlenmiştir. Tez çalışmasında kullanılan SHT modelinin WRF çalışması ile mikro ölçek HID modellerinin çalışması için gerekli verilerin elde edilmesi amacıyla bilgisayar hesaplamaları yapılmış; bu hesaplamalar için proje kapsamında kurulan iş istasyonu ile İstanbul Teknik Üniversitesi (İTÜ) Ulusal Yüksek Başarımli Hesaplama Merkezi (UYBHM) sisteminden faydalanılmıştır. Ayrıca, İTÜ Bilimsel Araştırma Projeleri (BAP) kapsamında alınan 4 çekirdekli bir iş makinesi, çalışmadaki hesaplamaların bir kısmının gerçekleştirilmesine olanak tanımış ve modellerin çalıştırılması için gerekli donanım sağlanmıştır.

Şenol, Ü., 2017, Rüzgâr enerjisi üzerine bir inceleme yapılmış olan bu çalışmada rüzgâr enerjisi potansiyelinin tahmin edilmesinde yapay sinir ağlarından faydalanmıştır. Matlab (R2014A Sürümü) yazılımı ile uygulanan modelde rüzgâr hızı verileri test aşamasında kullanılırken, farklı tip rüzgâr türbinlerinin çıkış gücüne ait veriler eğitim aşamasında değerlendirilmiştir. Uygulama sonrasında yapılan regresyon analizleri, oluşturulan modelin tahminlerinin güvenilir ve tutarlı olduğunu göstermiştir. Tahmin sonuçları, seçilen bölgenin rüzgâr potansiyelinin oldukça yüksek olduğunu ve kaliteli türbinlerle yüksek kapasiteli enerji üretiminin mümkün olduğunu ortaya koymuştur. Ayrıca, enerji sektöründeki uygulayıcılar ve karar vericilerin, rüzgâr enerjisi ile ilgili çalışmalarında yapay sinir ağlarını alternatif bir yöntem olarak kolaylıkla kullanabilecekleri anlaşılmıştır.

Aktar, Ç., 2018, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından desteklenen 110Y050 numaralı “Kısa Vadeli Rüzgâr Enerjisi Tahmin Sistemi” konulu projeye yeni bir çalışma olarak, orta ölçek sayısal hava tahmin modeli WRF ile hesaplamalı akışkanlar dinamiği modelleri (CFD) olan Meteodyn ve WindSim kullanımıyla kısa vadeli rüzgâr enerjisi tahmini gerçekleştirmiştir. Çalışmada, Manisa ili Soma ilçesi sınırları içinde karmaşık arazi üzerinde kurulu bulunan Soma Rüzgâr Enerji Santrali (RES)’deki rüzgâr enerjisini, 1 km ve 3 km çözünürlükte ve 24 ile 48 saatler için tahmin eden bir sistem oluşturulması amaçlanmıştır.

Yakşı, B., 2018, Dünya ve Türkiye’nin enerji görünümünü incelemiş, rüzgâr enerjisi ve potansiyel analizi ile ilgili bilgiler vermiştir. Çalışmada, rüzgâr enerjisi temel enerji denklemleri, türbin rotor yarıçaplarının rüzgâr enerjisi üzerine etkileri, rüzgâr hızının rüzgâr enerjisi üzerine etkileri, yüksekliğe bağlı rüzgâr hız değişimleri gibi konular hakkında bilgiler verilmiştir. Çalışma kapsamında CFD tabanlı olan WindSim yazılımı yardımıyla

rüzgâr enerjisi potansiyel analizi yapılmıştır. Bursa ilinin kıyı şeridi olan Gemlik, Karacabey ve Mudanya ilçeleri için analizler yapılmış ve yıllık enerji üretim miktarları, ortalama rüzgâr hız haritaları, rüzgâr güç yoğunluğu haritaları, pürüzlülük haritaları oluşturulmuştur. Analizi yapılan ilçeler için Meteoroloji Genel Müdürlüğünden (MGM) saatlik rüzgâr hızı ve rüzgâr yönü bilgilerinin bulunduğu klimatoloji verileri alınmıştır. Alınan klimatoloji verileri ile WindSim programı kullanılarak analizler gerçekleştirilmiştir.

Oral, F. ve ark., 2019, Sakarya-Esentepe bölgesi için üç aylık rüzgâr verilerini kullanarak hem istatistiksel yöntem ile hem de WindPro programı ile rüzgâr enerjisi analizini yaparak ortalama rüzgâr hızı ve güç yoğunluğu değerlerini bulup sonuçları karşılaştırmışlardır. Çalışma iki aşamadan oluşmaktadır: Birinci aşamada, rüzgâr verilerinin istatistiksel analizi yapılmış, ortalama rüzgâr hızı ve güç yoğunluğu değerleri hem istatistiksel yöntem ile hem de WindPro programı yardımı ile analiz edilerek sonuçlar karşılaştırılmıştır. İkinci aşamada ise, seçilen bir rüzgâr türbini kullanılarak üretilebilecek enerji miktarının belirlenmesi amacı ile rüzgâr elektrik santral analizi yapılmıştır. Analiz sonuçlarının birbirine çok yakın olduğu görülmüştür. WindPro programı ile seçilen bölge için verilen bir rüzgâr türbini için enerji üretim miktarı ile kapasite faktörü yaklaşık olarak hesaplanmıştır.

Ma, Y. J. ve Zhai, M. Y., 2019, Dalgacık Dönüşümü (WT), Karınca Kolonisi Optimizasyon Algoritması (ACO) ve İleri Beslemeli Yapay Sinir Ağının (FFANN) hibridizasyonuna dayanan yeni bir çift aşamalı Entegre Makine Öğrenimi (ML) modeli, 24 saat önceden rüzgâr enerjisi üretim tahmini için geliştirmişlerdir. Geliştirilen model iki adımdan oluşmaktadır. İlk adımda, rüzgâr üretim sisteminin kurulum noktasındaki rüzgâr hızını tahmin etmek için çevresel faktörler (hava durumu değişkenleri) kullanılmıştır. İkinci adımda ise rüzgâr çiftliğinin gerçek üretimini çiftliğin bulunduğu yerdeki gerçek rüzgâr hızı gözlemine uyarlamıştır. İlk adımda tahmin edilen gelecekteki hız, daha sonra çiftliğin gelecekteki üretimini tahmin etmek için ikinci adıma verilmiştir. Geliştirilen yöntemin tahmin doğruluğu çeşitli kriterlere göre değerlendirilmiş ve diğer ML tabanlı modeller ve kalıcılık tabanlı referans modellerle karşılaştırılmıştır. Geliştirilen yöntemle elde edilen günlük Ortalama Mutlak Yüzde Hata (MAPE), Normalleştirilmiş Ortalama Mutlak Hata (NMAE) ve Tahmin Becerisi (FS) değerleri sırasıyla % 4,67, % 0,82 ve % 56,22'dir. Geliştirilen model, çeşitli performans kriterlerine göre değerlendirilen tüm modellerden daha iyi performans göstermiştir.

Wang, S. ve ark., 2021, Rüzgâr gücü tahmininin, enerji arzı ve talebini dengelemek için gerekli olan tüm enerji sisteminin belirsizliğini azalttığını belirterek, tahmin doğruluğunu artırmak için, veri temizleme ve özellik yeniden yapılandırmasına dayalı kısa vadeli bir rüzgâr gücü tahmin yöntemini önermişlerdir. Rüzgâr yönü, rüzgâr hızı ve rüzgâr gücünden oluşan çok sayıda tarihsel 15 veri analiz edilmiştir. Her örneğin yerel yoğunluğunu hesaplayarak aykırı değerler etkin bir şekilde tespit edilmiştir. Rüzgârın özellikleri, kısa vadede rüzgâr sürecinin değişimini yansıtan zaman serisi bilgileriyle birleştirilmiş küresel bir bilgi haritasına yeniden yapılandırılmıştır. Orijinal verilerin özellikleri büyük ölçüde zenginleştirilerek tahmin modeli için yüksek kaliteli bir eğitim seti sağlanmıştır. Kısa vadeli rüzgâr gücünü tahmin etmek için yeniden tasarlanmış bir Evrişimsel Sinir Ağı kullanılmış ve önerilen yöntemler, Çin'deki gerçek bir rüzgâr çiftliğinin veri kümesine dayalı olarak eğitilmiş ve test edilmiştir. Çok sayıda deneysel sonuç, önerilen yöntemlerin iyi performans gösterdiğini ve kısa vadeli rüzgâr enerjisi tahmininin doğruluğunu etkili bir şekilde geliştirdiğini göstermiştir.

Sæther, B., B., 2021, istatistik ve makine öğrenimi yöntemlerini kullanarak Kuzey Norveç'teki beş farklı rüzgâr çiftliği için gelecekteki rüzgâr enerjisini tahmin etmeyi amaçlamıştır. Çalışmada, ARIMAX süreci gibi geleneksel istatistiksel modellerden karmaşık makine öğrenimi modellerine kadar uzanan, rüzgâr enerjisinin kısa ile orta vadeli, çok adımlı tahmini için dört farklı tahmin modeli geliştirilmiştir. Ek olarak, modellerden ikisi hem yinelemeli hem de doğrudan çok adımlı tahmin tekniği kullanılarak uygulanmıştır. Her rüzgâr çiftliği için, modeller tüm bir yıl boyunca değerlendirilerek NWP modelinden değişkenler içeren çok değişkenli girdi verileri kullanılmıştır. Deneylerin sonuçları tüm konumlarda büyük ölçüde değişmiştir. Uygulanan modellerin kısa tahmin süresi için kalıcılık modeli tarafından geride bırakıldığı görülmüş ancak tahmin süresi arttığında, birkaç model kalıcılık modelinden daha düşük bir hata göstermiştir.

Emeksiz, C. ve Demir, İ., 2021, çalışmalarında rüzgâr hızını etkileyen birçok meteorolojik faktörün var olduğundan bahsederek, Tokat Gaziosmanpaşa Üniversitesi Mühendislik ve Mimarlık Fakültesi yerleşkesinde kurulan ölçüm istasyonundan ölçülen gerçek zamanlı rüzgâr hızı, nem, basınç ve sıcaklık verileri kullanılarak rüzgâr hızı tahminlemesini gerçekleştirmiştir. Çalışmada, özellikle meteorolojik veriler ile rüzgâr hızı arasında matematiksel bir bağlantı kurmak için Basit Lineer Regresyon, Çoklu Lineer Regresyon Ve Çoklu Nonlineer Regresyon yöntemleri kullanılmıştır. Çalışmanın sonucunda, rüzgâr hızının doğru ve güvenilir bir şekilde tahminlenmesinde çoklu nonlineer

regresyon yönteminin daha düşük hata oranında tahminleme yaptığı görülmüştür. Yıl bazlı yapılan analizler sonucunda ise en düşük hata $RMSE=0,062$ ile Sıcaklık-Nem grubunda, en yüksek hata ise $0,068$ ile Sıcaklık-Basınç grubunda görülmüştür.

Sarikaya, M., 2022, zaman serilerinin kendisinden gelen zamansal bilgilerin yanı sıra uzamsal bilgiyi derin öğrenme modellerine dâhil etmenin yollarını incelemiştir. Çok sahalı rüzgâr enerjisi tahmini amacıyla literatürden altı farklı derin öğrenme yöntemi; Çok Katmanlı Algılayıcılar, Tekrarlayan, Grafik ve Evrişimli Ağlar test edilmiştir. Her model, daha doğru uzun vadeli tahminler oluşturmak için sayısal hava durumu tahminleriyle beslenmiştir ve model parametreleri hiperparametre optimizasyonu ile belirlenmiştir. Son olarak, modeller bir yıllık süre boyunca Ağaç Tabanlı, Cezalı Regresyon ve Kalıcılık referans modelleriyle karşılaştırılmıştır. Çok sahalı yaklaşımı kullanmanın etkisini araştırmak için, tekrarlayan model hem her bir tesis için ayrı ayrı hem de tüm tesisler için aynı anda çok sahalı bir bağlamda eğitilmiştir. Çalışma bulgularına göre, tek santralli yinelenen model, çok sahalı yinelenen modelden daha iyi performans göstermiş, fakat evrişimli katmanları kullanan yöntemler tek santralli yinelenen model de dâhil olmak üzere tüm modellerden daha iyi performans göstermiştir.

Kiriş, Z., N. ve ark., 2022, çalışmalarında Dört Farklı Tekrarlayan Sinir Ağları (TSA) modelini rüzgâr enerjisi üretim tahminlemesi için kullanmıştır. Çalışmada, Türkiye'nin Yalova ilinde bulunan bir istasyondan elde edilen veriler kullanılarak kısa süreli rüzgâr hızı tahmini yapılmıştır. Analizde bir saat sonrasını tahmin ederek oluşacak ani arıza ve bakım planlamalarına müdahale edilmesi amaçlanmıştır. Öncelikle istasyondan alınan veriler incelenmiş, veri analizleri yapılmış, var olan verilerden yeni veriler üretilmiş ve veri setleri modeller için uygun hale getirilmiştir. Modellerden elde edilen performans sonuçları kabul edilebilir aralıkta olup TSA yöntemlerinin rüzgâr hızı tahmininde başarılı bir şekilde kullanılabileceğini ve geleneksel zaman serisi yöntemlerine göre daha iyi sonuçlar verdiği sonucuna varılmıştır.

Lee, J., C. ve ark., 2022, çalışmalarında rüzgâr enerjisi üretim tahmini yapmak için rüzgâr hızı, rüzgâr gücü vb. verilerinden oluşan veri setini ve Python programını kullanmışlardır. Yapılan çalışmada, topluluk araçlarının Zaman Serisi tahmininde etkili olduğu ancak genel olarak daha düşük bir performansa sahip olduğunu göstermiştir. Veri setini oluşturan veriler medyan mutlak hata ve değerlendirme puanı örneği olan Peirce başarı puanı ile analiz edilmiştir. Çok organizasyonlu topluluk ortalaması Zaman Serisi tahmininde yeterli başarıya sahip olduğu ve topluluk üyelerine kıyasla güç tahmininde daha düşük

performans gösterdiği bulunmuştur. Spektral analiz, topluluk ortalamasının birçok frekansta üyelerin çoğundan daha iyi performans gösterdiği ve tüm tahmin periyodu için düşük zaman serisi tahmin hataları ürettiği ileri sürülmüştür. Bu çalışmanın bir sonraki aşamasında, olasılık tahminlerini değerlendirmek ve sistematik bir prosedürle tahmin belirsizliğini ölçmek için WE-Validate'e yetenekler eklenmiş, rüzgâr tahmini iyileştirmek için WE-Validate'in topluluk katkısı değerlendirilmiştir.

Tubulekas, A., 2022, çalışmalarında kısa vadeli rüzgâr performansı tahminleri oluşturmak için çeşitli makine öğrenimi algoritmalarını kullanmıştır. Bu çalışmanın amacı, açık veri kümelerini kullanarak kısa vadeli rüzgâr enerjisi tahmini için farklı makine öğrenmesi algoritmalarının performansını araştırmaktır. Bu çalışma aynı zamanda hangi girdi özelliklerinin çıktı performansı üzerinde en büyük etkiye sahip olduğunu da araştırmıştır. İncelenen algoritmalar, Oto Regresyon, En Az Mutlak Büzülme Ve Seçim Operatörü (LASSO) yöntemiyle Doğrusal Regresyon (LR), Rastgele Orman Regresyonu ve Gradyan Artırmadır. Çalışmada, rüzgâr hızı, yönü ve günün saatinin en önemli girdi özellikleri olduğu, Gradyan Artırma modelinin incelenen algoritmalar arasında en iyi performansı gösterdiği sonucuna varılmıştır.

Yenilmez, D. ve Barut, Ö.N.E.R., 2023, yapay zekâ teknikleri ile kısa süreli rüzgâr enerji tahmini problemi çözümü için iki adet çalışma gerçekleştirmiştir. İlk çalışmada öncelikle temel makine öğrenmesi tekniklerini analiz ederek hangilerinin yüksek başarımla gösterdiği tespit edilmiştir. Daha sonra ortaya çıkan sonuçlara göre ikinci çalışmada YSA algoritması ile daha detaylı bir parametre araştırması ve sonuç kıyaslaması gerçekleştirilmiştir. Çalışmada, kısa süreli rüzgâr enerjisi ile elektrik üretimi tahmini için en bilinen ve en yaygın kullanılan makine öğrenimi algoritmaları olan Yapay Sinir Ağları, Basit Doğrusal Regresyon, Polinomal Regresyon, Destek Vektör Regresyon ve Rastgele Orman algoritmaları kullanılarak başarımları karşılaştırılmıştır. Ayrıca güncel ve gerçek enerji üretim değerlerinden oluşan bir veri seti üzerinde makine öğrenmesi teknikleri ile kısa süreli rüzgâr enerjisi tahmini gerçekleştirilmiştir. Deney sonuçları incelendiğinde Yapay Sinir Ağları modelinin lineer yapıda olmaması, eğitime kolayca adapte olabilme yeteneği, hataya karşı toleranslı olması gibi birçok avantaja sahip olması sayesinde bu problemin çözümü için en iyi performansı gösteren makine öğrenmesi algoritması olma başarısı göstermiştir. Rastgele Orman algoritması sahip olduğu yapı sayesinde güçlü hiperparametreler kullanarak tahmin problemlerinde yüksek performans gösterebilmesine karşın yapılan deney sonuçlarına göre Rastgele Orman algoritması, Yapay Sinir Ağları

modeline göre daha düşük performans göstermektedir. Ayrıca rüzgâr enerjisinin sahip olduğu kararsız yapısından dolayı Basit Doğrusal Regresyon, Polinomal Regresyon ve Destek Vektör Makinesi algoritmalarının başarısının diğer iki modele göre düşük kaldığı görülmektedir.

Wu, B. ve ark., 2024, çalışmalarında rüzgâr hızının elektrik şebekesi operasyonlarının istikrarını sağlamada önemli bir rol oynadığını ancak, rüzgâr desenlerinin içsel yüksek oynaklığı ve durağan olmaması, doğru tahminler elde etmek için önemli zorluklar ortaya koyduğunu belirterek bu sorunu ele almak ve mevcut rüzgâr hızı tahmin modellerinin yorumlanabilirliğini artırmak için İki Aşamalı Ayırıştırma, Meteorolojik Veri Özellik Mühendisliği, İsteğe Bağlı Harici Arşiv (JADE) Algoritması ile Uyarlanabilir Diferansiyel Evrim ve Zamansal Füzyon Transformatörlerini (TFT) birleştiren yenilikçi bir kısa vadeli rüzgâr hızı tahmin modeli önermiştir. İlk olarak, rüzgâr hızı verileri, uyarlanabilir gürültü ile iyileştirilmiş tam topluluk ampirik mod ayırıştırması (IEEMD) kullanılarak ayırtırmaya tabi tutulmuş ve çoklu özmod fonksiyonları elde edilmiştir. Ek olarak, meteorolojik özellikler birleştirilmiş ve istatistiksel meteorolojik özelliklere dönüştürülerek girdi özelliklerinin etkinliği artırılmıştır. Daha sonra, TFT'nin hiperparametreleri güçlü JADE algoritması kullanılarak titizlikle optimize edilmiştir. Deneysel sonuçlar, IEEMD-EWT-JADE-TFT modelinin dikkate değer derecede yüksek tahmin doğruluğu elde ettiğini açıkça göstermiştir. Bu yorumlayıcı deneysel süreç ve sonuçları, güvenilir rüzgâr hızı tahmin süreçleri ve sonuçları arayan karar vericiler için yeni bir yol çizmiştir.

AlShafeey, M. ve Csaki, C., 2024, özellikle kısa ve uzun vadeli tahmin doğruluğuna yönelik kabiliyetine vurgu yaparak, rüzgâr enerjisi tahmini için dinamik bir hibrit modelin formülasyonunu ve geçerliliğini açıklamıştır. Model, geçmiş rüzgâr enerjisi üretiminden elde edilen zaman serisi verilerinin analizine dayanmaktadır ve Yapay Sinir Ağı (YSA), Destek Vektör Makinesi (SVM) ve K-En Yakın Komşu (K-NN) olmak üzere bir dizi makine öğrenimi algoritmasını kullanmaktadır. 2 MW gücünde, şebekeye bağlı bir rüzgâr türbininden toplanan ampirik veriler, modelin eğitim ve doğrulama aşamalarının temelini oluşturmuştur. Her bir bileşen algoritmasının performansını çeşitli ölçütler üzerinden incelemek amacıyla karşılaştırmalı bir değerlendirme metodolojisi tasarlanmıştır. Bu değerlendirme çerçevesi, daha sonra hibrit model içinde uygulanan dinamik anahtarlama mekanizması sayesinde hafifletilen bireysel algoritmalara özgü sınırlamaların belirlenmesini sağlamıştır. Söz konusu yenilikçi özellik, modelin geçmiş performans verilerine dayanarak en etkili tahmin tekniğini uyarlamalı olarak seçmesine imkân tanımaktadır. Çalışmanın

bulguları, yalnızca yenilenebilir enerji tahmini alanındaki mevcut bilgi birikimine katkı sunmakla kalmayıp, hibrit modelin farklı öngörücü analitik alanlarda da geniş bir uygulanabilirliğe sahip olduğunu ortaya koymaktadır.

Sulaiman, M. H. ve ark., 2024, çalışmalarında özellik seçimi için meta-sezgisel algoritmaların güçlü yönlerinden yararlanarak ve bunları Yapay Sinir Ağları (NN) ile entegre ederek rüzgâr enerjisi üretimi tahmin doğruluğunu artırmaya yönelik yenilikçi bir yaklaşım önermektedir. Özellikle, Genetik Algoritma (GA), Parçacık Sürüsü Optimizasyonu (PSO), Karınca Kolonisi Optimizasyonu (ACO), Öğretim–Öğrenme Tabanlı Optimizasyon (TLBO) ve Evrimsel Çiftleşme Algoritması (EMA) olmak üzere beş farklı algoritma, 18 özelliğe sahip kapsamlı bir veri setinden optimum özellik alt kümelerini belirlemek amacıyla NN modeli ile entegre edilmiştir. Sonuçlar, GA'nın en etkili özellikleri seçmede diğer algoritmalara kıyasla sürekli olarak daha iyi performans gösterdiğini ve rüzgâr gücü tahminlerinde daha yüksek hassasiyet sağladığını ortaya koymaktadır. Bu yenilikçi çerçeve, yenilenebilir enerji tahmini alanındaki bilgi birikimini ilerletmekte ve çeşitli uygulamalarda iyileştirilmiş tahminler için özellik kümelerini optimize etme konusunda değerli bilgiler sunmaktadır.

Ding, J., W. ve ark., 2024, çalışmalarında yeniden analiz ve yer istasyonu verilerini birleştiren ve tahmin doğruluğunu iyileştirmeyi amaçlayan yeni bir yaklaşım kullanarak rüzgâr gücü üretimini değerlendiren sağlam bir derin öğrenme modeli sunmuştur. Ham verilerdeki olası tutarsızlıkları gidermek için, Boxplot ve DBSCAN algoritması gibi ön işleme yöntemleri uygulanarak aykırı değer etkisi etkili bir şekilde azaltılmıştır. Bu çalışma, rüzgâr gücü tahmin yöntemlerini ilerletmekle beraber aynı zamanda tahmin modellemesinde çeşitli veri kaynaklarının entegrasyonu için yeni bir standart belirlemiştir. Bulgular, gelecekteki araştırmalar için değerli iç görüler sağlamaktadır ve potansiyel olarak bu yenilikçi metodolojileri küresel olarak sürdürülebilir enerji tahmininde daha geniş uygulamaları genişletmektedir.

Mahata, S. ve ark., 2024, çalışmalarında Hindistan'ın enerji sektöründeki hızlı dönüşüm sürecine, sağlam şebekelere ve dağıtık üretim birimlerine dikkat çekmişlerdir. Bu bağlamda, çalışma, makine öğrenimi teknikleri kullanılarak yüksek doğrulukta rüzgâr gücü tahminleri sağlayabilen bir sistem geliştirmeyi hedeflemektedir. Yapay Sinir Ağı (YSA), Tekrarlayan Sinir Ağı (RNN), Uzun Kısa Dönem Hafıza (LSTM), Geçitli Tekrarlayan Birim (GRU) ve Otoresif Bütünleşik Hareketli Ortalama (ARIMA) modellerinin karşılaştırmalı ve kapsamlı bir analizi gerçekleştirilmiştir. Deneyler ve modelleme, meteorolojik veriler ile

tarihsel elektrik üretim verileri dikkate alınarak yürütülmüştür. Bulgular, ARIMA'nın çok değişkenli analizde doğrusal olmayan veriler için diğer modellere kıyasla daha iyi performans gösterdiğini ve tahmin veri setinde MAPE skorunun 5,5'in altında olduğunu ortaya koymaktadır.

Bu çalışma kapsamında, rüzgâr enerjisi üretiminin tahminine yönelik yapılan bilimsel araştırmalar genel hatlarıyla değerlendirilmiştir. Literatürde, farklı makine öğrenmesi ve istatistiksel yöntemleri kullanan çok sayıda çalışma yer almaktadır. Tablo 1'de sunulan Literatür Özet Tablosu, seçilen akademik çalışmaları kullanılan yöntemler, veri kaynakları, model başarımları ve temel bulguları açısından karşılaştırmalı olarak özetlemektedir. Söz konusu tablo, rüzgâr enerjisi üretim tahminine yönelik literatürdeki eğilimlerin ve araştırma boşluklarının daha iyi anlaşılmasına katkı sağlamaktadır.

Tablo 1. Literatür özet tablosu

Yazar (Yıl)	Yöntem / Model	Uygulama Alanı / Veri	Öne Çıkan Bulgular / Katkılar
Ekmekçi vd. (2011)	WindPRO + Weibull + MATLAB	Sakarya – Esentepe	Üretim analizi ve uyumlu yazılım çıktısı.
Efe (2012)	WRF + Lineer Regresyon	Soma RES – 30 yıllık meteoroloji	Fiziksel modelleme ile tahminler geliştirildi.
Şenol (2017)	Yapay Sinir Ağı (ANN)	Rüzgâr türbini çıkış verileri	ANN tahminleri güvenilir bulundu.
Aktar (2018)	WRF + CFD (Metodyn, WindSim)	Soma RES	Kısa vadeli tahmin sistemi oluşturuldu.
Yakşı (2018)	CFD – WindSim	Bursa kıyı ilçeleri	Rüzgâr haritaları ve enerji analizleri üretildi.
Oral vd. (2019)	İstatistiksel + WindPRO	Sakarya – Esentepe	Türbin seçimi ile üretim potansiyeli hesaplandı.
Ma & Zhai (2019)	WT + ACO + FFANN	Çin – Çift aşamalı model	MAPE % 4,67 ile yüksek doğruluk elde edildi.
Wang vd. (2021)	CNN + Özellik Yeniden Yapılandırma	Çin – kısa vadeli tahmin	Tahmin doğruluğu artırıldı.

Tablo 1.'in devamı

Yazar (Yıl)	Yöntem / Model	Uygulama Alanı / Veri	Öne Çıkan Bulgular / Katkılar
Sæther (2021)	ARIMAX, ML	Norveç – 5 RES	Kısa vadede kalıcılık, uzun vadede ML üstün.
Emeksiz & Demir (2021)	Çoklu nonlinear regresyon	Tokat – Meteorolojik veriler	En düşük RMSE ile başarı sağlandı.
Sarıkaya (2022)	CNN, RNN, GNN	Çok sahalı veri	CNN modelleri en iyi sonucu verdi.
Kiriş vd. (2022)	TSA modelleri	Yalova – Rüzgâr hızı	TSA klasik yöntemlerden daha iyi.
Lee vd. (2022)	Ensemble Zaman Serisi	Python – Rüzgâr gücü	Topluluk modeli analiz edildi.
Tubulekas (2022)	GBT, LASSO, RF	Açık veri seti	GBT en iyi sonucu verdi.
Yenilmez & Barut (2023)	ANN, SVR, RF, LR	Gerçek üretim verisi	ANN en yüksek başarıyı sağladı.
Wu vd. (2024)	IEEMD + CNN (TFT)	Çin – kısa vadeli	Yüksek doğruluk ve yorumlanabilirlik sağlandı.
AlShafeey & Csaki (2024)	Hibrit (ANN, SVM, KNN)	2 MW Türbin verisi	Algoritmalar arası dinamik geçiş sağlandı.
Sulaiman vd. (2024)	GA, PSO, ACO + ANN	18 özellikli veri seti	GA ile yüksek doğruluklu özellik seçimi.
Ding vd. (2024)	IEEMD + DBSCAN + DL	Yerel + yeniden analiz	Aykırı temizleme sonrası yüksek doğruluk.
Mahata vd. (2024)	ANN, RNN, LSTM, GRU, ARIMA	Hindistan – Şebeke uyumu	ARIMA en düşük MAPE ile öne çıktı.

1.4. Dünyada ve Türkiye’de Rüzgâr Enerjisine Genel Bir Bakış

Küresel enerji ihtiyacının artması, fosil yakıtların çevresel etkileri ve iklim değişikliği gibi nedenlerle yenilenebilir enerji kaynaklarına olan ilgi her geçen gün artmaktadır. Bu bağlamda, sürdürülebilir, çevre dostu ve tükenmeyen bir enerji kaynağı olan rüzgâr enerjisi, dünya genelinde en hızlı büyüyen yenilenebilir enerji teknolojilerinden biri haline gelmiştir.

Gelişen teknolojiyle birlikte türbin verimliliğinin artması, maliyetlerin düşmesi ve devlet destekleri, rüzgâr enerjisi yatırımlarının yaygınlaşmasını sağlamıştır. Hem karasal (onshore) hem de deniz üstü (offshore) türbin kurulumlarıyla enerji üretiminin önemli bir parçası hâline gelen rüzgâr enerjisi, birçok ülkenin enerji politikalarında stratejik bir yer edinmektedir. Türkiye de sahip olduğu coğrafi avantajlar sayesinde bu alandaki potansiyelini değerlendirmeye başlamış ve son yıllarda önemli yatırımlar gerçekleştirmiştir. Bu bölümde, Dünya genelinde ve Türkiye özelinde rüzgâr enerjisinin mevcut durumu, gelişim süreci ve gelecek projeksiyonları ele alınacaktır.

1.4.1. Dünyada Rüzgâr Enerjisi

Rüzgâr enerjisi, küresel düzeyde sürdürülebilir kalkınma hedefleri açısından en önemli yenilenebilir enerji kaynaklarından biridir. 2024 yılı itibarıyla dünyada rüzgâr enerjisine dayalı toplam kurulu güç yaklaşık 1000 GW seviyesine ulaşmıştır. Bu kapasitenin yaklaşık % 90'ı kara rüzgâr santrallerinden, geri kalanı ise deniz üstü rüzgâr santrallerinden elde edilmektedir (IRENA, 2024). Küresel kapasitenin büyük bir kısmı Çin, ABD, Almanya, Hindistan ve İspanya gibi ülkelerde yoğunlaşmıştır.


Tablo 2. 2024 Yılı itibarıyla en yüksek rüzgâr enerjisi kapasitesine sahip ülkeler

Ülke	Kurulu Güç (GW)
Çin	440
ABD	150
Almanya	70
Hindistan	45
İspanya	30

Tablo 2’de dünyada rüzgâr enerjisi alanında önde gelen ülkelerin kurulu güçleri yer almaktadır (URL-6). Bu verilere göre, Çin Halk Cumhuriyeti büyük bir farkla lider konumunda olup 440 GW'lık kurulu güce sahiptir. Çin’in bu alandaki liderliği, özellikle son on yıl içerisinde uygulamaya koyduğu kapsamlı enerji politikaları, yerli üretimi destekleyen

sanayi teşvikleri ve altyapı yatırımları ile doğrudan ilişkilidir. Amerika Birleşik Devletleri (ABD), 150 GW ile ikinci sırada yer almakta olup, özellikle Orta batı ve kıyı bölgelerinde gerçekleştirilen büyük ölçekli kara tipi rüzgâr enerjisi projeleri sayesinde güçlü bir kapasiteye ulaşmıştır. Almanya, 70 GW kurulu gücü ile Avrupa kıtasında öne çıkan ülke konumundadır. Yenilenebilir enerji kaynaklarının teşviki ve Energiewende (enerji dönüşümü) politikası kapsamında yürütülen çalışmalar, Almanya'nın bu alandaki liderliğini sürdürmesini sağlamaktadır. Hindistan ve İspanya ise sırasıyla 45 GW ve 30 GW Kurulu güç kapasitesiyle sıralamada dördüncü ve beşinci sırada yer almaktadır. Bu ülkeler, uygun rüzgâr rejimlerine sahip bölgelerinde yoğunlaşan yatırımları sayesinde önemli ölçüde kapasite oluşturmuşlardır.

Söz konusu ülkelerin rüzgâr enerjisi alanında kaydettiği ilerleme, hem enerji arz güvenliğini artırmak hem de karbon salınımını azaltmak açısından kritik öneme sahiptir. Bu bağlamda, rüzgâr enerjisi yatırımlarının sadece çevresel değil aynı zamanda ekonomik ve stratejik faydalar sağladığı söylenebilir.



Şekil 1. Dünya rüzgâr enerjisi kurulu gücü (2010-2023) (IRENA, 2024)

Şekil 1’de verilen grafikteki verilere göre 2010 yılından 2024 yılına kadar dünyada rüzgâr enerjisine dayalı kurulu gücün istikrarlı ve güçlü bir şekilde arttığı görülmektedir. 2010 yılında yaklaşık 200 GW civarında olan küresel rüzgâr enerjisi kurulu gücü, 2020’ye gelindiğinde 700 GW seviyesini aşmış, 2024 yılında ise yaklaşık 1000 GW seviyesine ulaşmıştır. Bu büyümenin ardındaki temel faktörler şunlardır:

- Son 10 yılda Çin, rüzgâr enerjisi kapasitesini küresel toplamın yaklaşık %40'ına çıkaracak şekilde büyük ölçekli projeler hayata geçirmiştir.
- ABD, Almanya ve İspanya gibi ülkeler, karbon salınımını azaltmak ve enerji arz güvenliğini sağlamak amacıyla rüzgâr enerjisine yönelik teşvik mekanizmalarını geliştirmiştir.
- Türbin verimliliğinin artması, yatırım maliyetlerinin azalması ve deniz üstü türbin teknolojilerinin yaygınlaşması küresel kurulu gücün hızla artmasına katkı sağlamıştır (URL-6; IRENA, 2024).

Sonuç olarak grafik, rüzgâr enerjisinin artık ikincil bir kaynak değil küresel enerji arzında stratejik ve ana bir kaynak konumuna geldiğini göstermektedir. 2025 sonrası projeksiyonlarda da büyümenin devam edeceği öngörülmektedir.

1.4.2. Türkiye’de Rüzgâr Enerjisi

Türkiye, coğrafi konumu ve rüzgâr karakteristikleri bakımından Avrupa'nın önemli rüzgâr enerjisi potansiyeline sahip ülkelerinden biridir. Enerji ve Tabii Kaynaklar Bakanlığı (ETKB) tarafından hazırlanan Rüzgâr Enerjisi Potansiyel Atlası (REPA) verilerine göre karasal teknik potansiyel yaklaşık 57,8 GW, deniz üstü teknik potansiyel ise yaklaşık 20,8 GW olup toplam teknik potansiyel 78,6 GW'dir (Enerji ve Tabii Kaynaklar Bakanlığı [ETKB], 2024).


2024 yılı itibarıyla Türkiye'nin toplam rüzgâr enerjisi kurulu gücü yaklaşık 13,8 GW seviyesine ulaşmış ve bu kapasite ile Türkiye, Avrupa’da kurulu güç açısından altıncı sırada yer almıştır (URL-7, URL-9).

Türkiye’de bölgesel dağılıma bakıldığında rüzgâr santrallerinin büyük bölümü Ege ve Marmara bölgelerinde yoğunlaşmaktadır. Bölgesel dağılım açısından Marmara Bölgesi ilk sırada, Ege Bölgesi ise ikinci sırada yer almakta olup; İzmir, Balıkesir, Çanakkale, İstanbul ve Manisa illeri kurulu güç bakımından öne çıkmaktadır (URL-9).

Bölgesel dağılım,

- Marmara Bölgesi : % 43,5
- Ege Bölgesi : % 29
- Diğer bölgeler (Akdeniz, Karadeniz ve diğer) : % 27,5

Ulusal Enerji Planı'na göre Türkiye, 2035 yılına kadar yenilenebilir enerji kapasitesini artırmayı hedeflemekte olup bu kapsamda kara yatırımlarına ek olarak deniz üstü projeleri de gündeme almaktadır (ETKB, 2022).



Şekil 2. Türkiye'nin yıllara göre rüzgâr enerjisi kurulu gücü (ETKB, 2024)

Şekil 2’de verile grafikte, Türkiye’nin rüzgâr enerjisi kurulu gücünde sürekli bir artış oluğu görülmektedir. 2010–2015 yılları arasında Türkiye’de rüzgâr enerjisi kapasitesi yaklaşık 1,33 GW’dan 4,72 GW’a yükselmiş olup, bu dönemde yıllık ortalama yaklaşık 0,68 GW’lık bir artış gözlemlenmiştir. 2015–2020 döneminde ise kapasite 4,72 GW’dan 9,31 GW’a çıkarak büyüme hızında belirgin bir artış kaydedilmiştir. 2020–2023 yılları arasında kapasite 12,34 GW seviyesine ulaşmış ve yalnızca üç yıl içinde yaklaşık 3 GW ek kapasite eklenmiştir. 2024 yılı itibarıyla ise Türkiye, 13,79 GW ile zirveye ulaşmıştır.

Bu eğilim, Türkiye’nin yenilenebilir enerji politikalarının, yatırım ortamının ve teknoloji gelişiminin rüzgâr enerjisinde güçlü bir ivme yarattığını gösteriyor. Özellikle 2020 sonrası artış, hem kara hem de planlanan deniz üstü projelerinin etkisinin hissedilmeye başladığını işaret ediyor.

1.5. Rüzgâr Enerjisi ve Teknolojileri

Enerji günümüzde sadece ekonomik kalkınmanın değil, aynı zamanda çevresel sürdürülebilirliğin de temel unsurlarından biri haline gelmiştir. Artan çevre bilinci ve iklim değişikliği ile mücadele hedefleri, fosil yakıtlara olan bağımlılığı azaltmak amacıyla alternatif arayışlara yönelmeyi teşvik etmektedir. Doğada kesintisiz olarak yenilenen kaynaklardan elde edilen enerji biçimleri yenilenebilir enerji kaynakları olarak adlandırılmakta olup güneş, rüzgâr, biyokütle, jeotermal enerji, hidroelektrik ve deniz dalgaları bu kaynaklar arasında yer almaktadır (Manwell ve ark. 2009, Hau, E. 2013).

Günümüzde yenilenebilir enerji teknolojileri; çevreye minimum zarar verme, sera gazı emisyonlarını azaltma ve enerji arz güvenliğini sağlama açısından kritik rol üstlenmektedir. Rüzgâr enerjisi ise bol kaynak potansiyeli, teknolojik gelişmeler ve düşük işletme maliyetleri sayesinde en hızlı büyüyen yenilenebilir enerji biçimlerinden biri olmuştur (URL-6).

Ayrıca, Sürdürülebilir enerji kullanımı ve ekolojik bozulmanın azaltılmasına ilişkin küresel bilinç arttıkça, yenilenebilir enerji dünya çapındaki ulusların enerji çerçevelerinde giderek önemli bir rol üstlenmiştir. Bol rezervleri, minimum harcamaları, ileri teknolojik gelişimi ve yenilenebilir enerji modelleri arasında minimum ekolojik ayak izi ile karakterize edilen rüzgâr enerjisi, son zamanlarda en hızlı genişleyen yeni yenilenebilir enerji kaynağı olarak ortaya çıkmıştır (URL-1).

1.5.1. Rüzgâr Enerjisinin Tanımı

Rüzgâr enerjisi, atmosferdeki sıcaklık ve basınç farklarından kaynaklanan hava hareketlerinin sahip olduğu kinetik enerjinin, uygun teknolojiler aracılığıyla önce mekanik ardından elektrik enerjisine dönüştürülmesidir. Güneşin yeryüzünü farklı oranlarda ısıtması sonucu ortaya çıkan bu enerji, doğrudan çevresel emisyon üretmeyen ve sürdürülebilirliği yüksek bir yenilenebilir enerji kaynağıdır (Ackermann & Söder, 2002).

1.5.2. Rüzgâr Enerjisinin Avantajları ve Dezavantajları

Rüzgâr enerjisi, sahip olduğu çevresel ve ekonomik yararları sayesinde yenilenebilir enerji kaynakları arasında önemli bir yere sahiptir. Öncelikle, rüzgâr türbinleri elektrik

üretimi esnasında doğrudan sera gazı emisyonu gerçekleştirmediği için çevre dostu bir enerji üretim yöntemi olarak değerlendirilmektedir. Ayrıca, rüzgâr atmosferde sürekli olarak meydana gelen doğal bir kaynak olduğundan, tükenme riski taşımamakta ve sürdürülebilir enerji arzı açısından güvenilir bir seçenek sunmaktadır. Bununla birlikte, rüzgâr santrallerinin başlangıç yatırım maliyetleri yüksek olsa da, kurulum sonrası işletme ve bakım masraflarının fosil yakıtlı santrallere göre oldukça düşük olması, uzun vadede ekonomik açıdan avantaj sağlamaktadır. Tüm bu yönleriyle rüzgâr enerjisi, hem çevresel hem de ekonomik sürdürülebilirlik hedefleriyle uyumlu bir enerji çözümüdür.


Rüzgâr enerjisi birçok açıdan avantajlı olsa da, bazı teknik ve çevresel olumsuz yönleri de mevcuttur. Öncelikle, rüzgâr hızı ve yönü zaman içinde değiştiğinden enerji üretiminde süreklilik sağlamak her zaman mümkün olmamaktadır. Bu durum, şebeke istikrarı açısından ek düzenleyici sistemlere (örneğin bataryalar, yedek üretim kaynakları) gereksinim duymaktadır. Ayrıca, rüzgâr türbinlerinin kurulumu için geniş alanlara ve uygun rüzgâr koşullarına sahip sahalara ihtiyaç duyulması, yer seçimini sınırlayıcı bir faktör hâline getirebilmektedir. Bunun yanında, türbinlerin oluşturduğu görsel kirlilik, çevresel etki değerlendirmeleri açısından zaman zaman toplumda olumsuz görüşlere sebep olmakta, kuş göç yolları üzerindeki projeler ise ekolojik dengenin bozulma riskini beraberinde getirebilmektedir (Chauhan, S. & Singh, R. 2014). Tüm bu hususlar, rüzgâr enerjisi yatırımlarında dikkatli planlama ve çevresel etki analizlerinin önemini ortaya koymaktadır.

1.5.3. Rüzgâr Enerjisi Teknolojileri

Rüzgâr enerjisi teknolojileri, rüzgârın kinetik enerjisini en verimli şekilde kullanılabilir elektrik enerjisine dönüştürmeye yönelik sistemlerden oluşmaktadır. Günümüzde en yaygın iki tür rüzgâr türbini mevcuttur: Yatay Eksenli Rüzgâr Türbinleri ve Dikey Eksenli Rüzgâr Türbinleri.

Yatay Eksenli Rüzgâr Türbinleri, özellikle büyük rüzgâr çiftliklerinde yüksek verimliliği ve güvenilirliği ile bilinen en yaygın türlerdir. Bununla birlikte, kentleşme arttıkça, Dikey Eksenli Rüzgâr Türbinleri kentsel ortamlardaki potansiyel avantajları nedeniyle dikkat çekmektedir (Chauhan, S. & Singh, R. 2014).

- Yatay Eksenli Rüzgâr Türbinleri




Şekil 3. Yatay eksenli rüzgâr türbini (Temiz, F., 2010)

Şekil 3'te yatay eksenli bir rüzgâr türbini şematik olarak gösterilmektedir. Bu türbin tipi, rüzgâr enerjisi santrallerinde en yaygın kullanılan türbin yapısını göstermektedir. Yatay eksenli türbinler, rotor milinin rüzgâr yönüne paralel yerleştirildiği sistemlerdir. Kanatlar rüzgârı önden alacak şekilde tasarlanır ve genellikle üç kanatlıdır. Bu türbinler, maksimum verim sağlamak amacıyla rüzgâr yönüne odaklanmak için yaw (yönlendirme) mekanizmasıyla donatılırlar. Yüksek verimlilikleri sayesinde büyük ölçekli rüzgâr çiftliklerinde yaygın olarak kullanılırlar (Hau, E., 2013).

Yatay eksenli rüzgâr türbinlerinin bir kısmı, rüzgârı ön tarafından alacak şekilde tasarlanır. Rüzgârı arkadan alan türbinlerin yaygın olarak bir kullanım yeri bulunmamaktadır. Rüzgârı önden alan türbinlerin avantajı, kule tarafından oluşturulan rüzgâr gölgelenmesinden etkilenmemeleridir. Ancak bu durumun dezavantajı, türbinin sürekli rüzgâr yönüne odaklanabilmesi için bir yönlendirme sisteminin tasarlanması zorunlu olmasıdır. Yatay eksenli rüzgâr türbinleri, rüzgâr enerjisinde çok önemli bir teknoloji olup büyük ölçekte elektrik üretimi sağlamaktadır.

- Dikey Eksenli Rüzgâr Türbinleri




Şekil 4. Dikey Eksenli Rüzgâr Türbini (URL-2)

Şekil 4’te şematik gösterimi verilen dikey eksenli rüzgâr türbinlerinde rotor mili yere dik konumlanır ve rüzgâr yönüne olan bağımlılık daha azdır. Türbinler bu özellikleri sayesinde şehir içinde veya dar alanlarda kurulumu uygundur. Yere yakın konumları nedeniyle düşük rüzgâr hızlarında çalışmalarında verim kaybı yaşanabilse de hem maliyetlerinin düşük olması hem de rüzgâr yönüne bağımlılıklarının az olması türbinleri şehir bölgelerinde kullanıma uygun kılmaktadır (Chauhan & Singh, 2014).

1.5.4. Rüzgâr Türbinlerinin Çalışma Prensibi

Rüzgâr türbinleri, aerodinamik prensipler sayesinde kanatlar üzerinde kaldırma (lift) ve sürüklenme (drag) kuvveti oluşturarak rotorun dönmesini sağlar. Elde edilen mekanik enerji, bir ana mil üzerinden dişli kutusuna (varsa) iletilir ve dönme hızı artırılarak jeneratöre aktarılır. Jeneratör bu enerjiyi elektrik enerjisine çevirir (Manwell ve ark. 2009).

Rüzgâr türbininin elektrik üretim sürecini gerçekleştiren temel bileşenleri Şekil 5’te şematik olarak gösterilmektedir.



Şekil 5. Türbin yapısı (Işık, M. C. ve ark. 2021)

Rüzgâr türbinlerinin çalışma prensibi, rüzgâr enerjisinin mekanik enerjiye ve ardından elektrik enerjisine dönüştürülmesi sürecini belirli adımlar dâhilinde gerçekleştirmektedir. Bu adımlar aşağıda sırasıyla verilmektedir:

Rotor, Kanatlar ve Göbek (Hub): Rotor, türbinin ön kısmında bulunan ve rüzgârla etkileşime giren en önemli parçadır. Kanatlar, rüzgârın kinetik enerjisini mekanik enerjiye çevirir. Genellikle aerodinamik verimliliği artırmak için 2 veya 3 kanatlı tasarımlar kullanılır. Kanatlara etki eden kaldırma ve sürüklenme kuvvetleri ile dönme hareketi sağlanır. Göbek, kanatlardan gelen dönme hareketini türbinin ana miline iletir. Kanatlar, göbek adı verilen merkez noktaya bağlıdır. Göbek, rüzgâr koşullarına bağlı olarak kanat açısını (pitch açısını) ayarlayan mekanizmalara da sahip olabilir.

Rüzgâr Akımının Rotor Kanatlarına Etkisi: Yeterli hızda esen rüzgâr, aerodinamik tasarıma sahip rotor kanatlarına çarparak kaldırma kuvveti oluşturur. Bu kuvvet, kanatların dönme hareketini başlatır.

Ana Mil ve Dişli Kutusu (Şanzıman - Gearbox): Rotorun dönme hareketini jeneratöre iletir. Büyük türbinlerde, jeneratörün yüksek hızlarda çalışmasını sağlamak için dişli kutusu

kullanılır. Doğrudan tahrikli sistemlerde (direct drive) dişli kutusu bulunmaz, rotor doğrudan jeneratöre bağlanır.

Rotorun Mil Üzerinden Dönme Hareketi Aktarması: Kanatların dönmesiyle oluşan mekanik dönme hareketi, düşük hız mili aracılığıyla dişli kutusuna iletilir. Dişli kutusu, rotor milinden gelen düşük hızdaki dönme hareketini, jeneratörün ihtiyaç duyduğu daha yüksek devir sayısına çıkararak iletir.

Jeneratör ve Yaw Mekanizması: Jeneratör, dönen mekanik enerjiyi elektrik enerjisine çevirmek için genellikle senkron veya asenkron jeneratörler kullanılır. Yaw mekanizması, rüzgâr yönüne göre türbinin dönmesini sağlar. Yatay eksenli rüzgâr türbinlerinde gereklidir.

Fren Sistemi, Kule ve Nacelle (Makine Bölmesi): Acil durumlarda veya aşırı rüzgâr hızlarında türbini durdurur. Elektriksel ve mekanik frenleme sistemleri bulunur. Kule, rotor ve diğer bileşenleri taşıyan yüksek yapıdır. Nacelle içinde jeneratör, dişli kutusu ve diğer sistemler bulunur.

Jeneratörde Elektrik Üretimi: Hızlandırılmış mekanik enerji, jeneratörde manyetik alan üzerinden elektrik enerjisine dönüştürülür. Alternatör ya da jeneratör burada ana dönüştürücü birimdir.

Kontrol Sistemi ve Dönüş Düzeni: Türbinin dönme yönü ve kanat açısı, maksimum verimlilik için kontrol sistemi tarafından sürekli olarak ayarlanır. Yaw motorları, türbin gövdesini rüzgâr yönüne çevirir.

Üretilen Elektriğin Düzenlenmesi ve Şebekeye Aktarılması: Jeneratörden elde edilen elektrik akımı, dönüştürücüler ve transformatör yardımıyla uygun gerilim ve frekansa getirilir ve iletim hattına aktarılır.

1.5.5. Rüzgâr Türbinlerinin Çalışmasını Etkileyen Faktörler

Rüzgâr türbinlerinin performansı, rüzgâr hızı, hava yoğunluğu, kanat uzunluğu, türbülans derecesi gibi parametrelerden etkilenmektedir. Özellikle rüzgâr hızının nominal değeri (~12–15 m/s) türbinin tam kapasitede çalışması için kritik öneme sahiptir. Yüksek seviyelerde hava yoğunluğu azaldığından güç üretimi de azalabilmektedir. Türbülans, kanatlar üzerinde düzensiz yük dağılımına neden olarak mekanik aşınmayı hızlandırabilir. Bu nedenle türbinlerin yerleşimi, bölgenin rüzgâr potansiyeli analiz edilerek planlanmalıdır (Hau, E., 2013).

1.6. Rüzgâr Enerjisi Üretiminin Teorik Temelleri

Rüzgâr enerjisi, atmosferdeki hava akımlarından elde edilen önemli bir yenilenebilir enerji kaynağıdır. Bu kaynağın elektrik üretimi için kullanılması, rüzgârın kinetik enerjisinin önce mekanik, sonra elektrik enerjisine dönüştürülmesi yoluyla gerçekleşir (Manwell ve ark., 2009). Rüzgâr türbinlerinin çalışma prensipleri, aerodinamik ilkeler, rüzgâr gücü formülleri, Betz limiti ve dönüşüm verimliliği gibi teorik temellere dayanır (Burton ve ark., 2011). Bu bölümde, rüzgâr enerjisinin fiziksel ve matematiksel esasları açıklanarak türbinlerin enerji üretim süreci detaylı olarak ele alınacaktır.

1.6.1. Rüzgâr Hızı ve Güç İlişkisi

Rüzgâr enerjisi üretiminde kullanılan temel fiziksel prensiplerden biri, rüzgârın kinetik enerjisinin bir kısmının mekanik enerjiye ve ardından elektrik enerjisine dönüştürülmesidir. Rüzgâr enerjisi üretimi, rüzgâr hızının doğrudan bir fonksiyonudur ve hızındaki küçük değişimler bile üretilen güç üzerinde önemli farklar yaratmaktadır. Rüzgârın taşıdığı kinetik enerji, türbin rotor alanından geçen hava kütlesinin hızına ve yoğunluğuna bağlıdır (Manwell ve ark., 2009, Burton ve ark., 2011). Bu enerji Denklem 1’de verilen formülle hesaplanır.

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

Denklem 1’de, P rüzgârın teorik gücünü (Watt), ρ havanın yoğunluğunu (kg/m^3), A türbin rotorunun süpürme alanını (m^2) ve V ise rüzgâr hızını (m/s) temsil etmektedir. Havanın yoğunluğu genellikle deniz seviyesinde ve 15°C sıcaklıkta yaklaşık 1.225 kg/m^3 olarak kabul edilmektedir (URL-8). Rotorun süpürme alanı, türbin kanatlarının dönerek taradığı dairesel alanı ifade etmekte ve $A = \pi \cdot r^2$ formülüyle hesaplanmaktadır. Rüzgâr hızı, rüzgâr gücü ile küçük hız değişimlerinde büyük farklar yaratacak şekilde V^3 ilişkisine sahiptir. Örneğin, rüzgâr hızı 2 katına çıktığında (örneğin 5 m/s ’den 10 m/s ’ye), güç 8 katına çıkar. Küçük hız değişimleri bile üretimde büyük farklar yaratabilir. Bu nedenle rüzgâr hızının doğru ölçülmesi ve türbinin kurulacağı yerin rüzgâr potansiyelinin iyi analiz edilmesi büyük önem taşımaktadır.

1.7. Rüzgâr Türbin Performansı ve Değerlendirme Kriterleri

Rüzgâr türbinlerinin performansını değerlendirmek için güç verimi, kapasite faktörü, aerodinamik verimlilik ve makine öğrenmesi temelli tahmin modelleri gibi çeşitli yöntemler kullanılmaktadır. Bu performans kriterleri, türbinlerin farklı rüzgâr hızlarında ne kadar verimli çalıştığını analiz etmeye yardımcı olmaktadır.

1.7.1. Güç Katsayısı (C_p) ve Betz Limiti

Bir rüzgâr türbini, rüzgârın kinetik enerjisinin yalnızca bir kısmını elektrik enerjisine dönüştürebilir. Türbinin enerji dönüşüm verimliliği Güç Katsayısı (C_p) ile ifade edilmektedir ve Denklem 2’de verilen formülle hesaplanmaktadır:

$$C_p = \frac{P_{türbin}}{P_{rüzgar}} \quad (2)$$

Denklemde, $P_{türbin}$ türbinin ürettiği gücü (Watt) ve $P_{rüzgar}$ rüzgârın taşıdığı toplam gücü (Watt) ifade etmektedir.

Betz Limiti, bir rüzgâr türbininin teorik olarak rüzgâr akışındaki enerjinin en fazla % 59.3’ünü elektriğe dönüştürebileceğini belirtmektedir (Betz, 1926, Manwell ve ark., 2009). Gerçek türbinlerde bu oran, aerodinamik ve mekanik kayıplar nedeniyle genelde %35–50 aralığında kalmaktadır.

1.7.2. Kapasite Faktörü (CF)


Rüzgâr türbinlerinin performansını değerlendirmek amacıyla, genellikle belirli bir zaman dilimi içinde üretilen gerçek enerji ile teorik maksimum enerji karşılaştırılır. Bir türbinin belirli bir dönem içinde fiilen ürettiği enerji miktarının, teoride tam kapasitede çalışması halinde üreteceği enerjiye oranı kapasite faktörü (CF) olarak tanımlanmaktadır (Burton ve ark., 2011). Kara rüzgâr santralleri için bu değer genelde % 25–40, açık deniz santralleri için ise % 40–60 aralığındadır (Sathyajith, 2006).

$$CF = \frac{E_{gerçek}}{E_{maksimum}} \times 100 \quad (3)$$

Denklem 3'te, $E_{gerçek}$ türbinin belirli bir süre boyunca gerçek işletme koşullarında ürettiği enerji miktarını ifade etmekte ve kilowatt-saat (kWh) cinsinden ölçülmektedir. $E_{maksimum}$ ise türbinin aynı süre zarfında hiçbir duraksama olmaksızın ve sürekli olarak tam kapasitede (nominal güçte) çalışması durumunda üretebileceği teorik maksimum enerji miktarını temsil etmektedir.

1.7.3. Güç Eğrisi ve Verimlilik Analizi

Türbin performansı, rüzgâr hızına bağlı olarak üretilen güç eğrisi ile analiz edilmektedir. Gerçek güç eğrisi, üreticinin belirttiği teorik eğriyle karşılaştırılarak türbinin verimli çalışıp çalışmadığı anlaşılabilmektedir. Veri seti alınan rüzgâr enerji santralinde kullanılan türbin modeli Enercon E-48 Güç eğrisi (Power Curve) Şekil 6'da verilmektedir.



Şekil 6. Türbin güç eğrisi (URL-3)

Şekil 6'da verilen grafiğe göre türbine ait güç eğrisi tablosu Tablo 3'te verilmektedir.

Tablo 3. Türbin güç eğrisi tablosu

Rüzgâr Hızı (m/s)	Üretilen Güç (kW)	Verimlilik (CP)(%)
0-2.5	0	0
4	50	6.25
6	280	35
8	600	75
10	780	97.5
11-13	800 (Nominal)	100
14+	800	100
25+	0 (Hız kesme)	0

Tablo 3'te verilen verilere göre, rüzgâr türbininin performansının doğrudan rüzgâr hızına bağlı olduğu görülmektedir. 0–2,5 m/s aralığında türbin çalışmıyorken, 4 m/s'de yaklaşık 50 kW güç ve % 6,25 verimlilik elde edilmektedir. Rüzgâr hızı arttıkça güç üretimi de artmakta ve 6 m/s'de 280 kW (% 35), 8 m/s'de 600 kW (% 75), 10 m/s'de ise 780 kW (% 97,5) seviyelerine ulaşmaktadır. 11–13 m/s aralığında türbin nominal kapasitesi olan 800 kW'a ulaşmakta ve verimlilik % 100 kabul edilmektedir. 14 m/s ve üzerindeki hızlarda bu seviye korunurken, 25 m/s'yi aşan rüzgârlarda türbin güvenlik nedeniyle devre dışı kalmaktadır. Bu veriler, türbinin optimum verimle 11–13 m/s aralığında çalıştığını göstermektedir.

1.8. Meteorolojik Faktörlerin Enerji Üretimine Etkisi

Yenilenebilir enerji kaynakları, artan enerji ihtiyacı ve çevresel sürdürülebilirlik hedefleri doğrultusunda giderek daha fazla önem kazanmaktadır. Bu bağlamda rüzgâr enerjisi, temiz ve sınırsız bir enerji kaynağı olması nedeniyle dikkat çeken yenilenebilir enerji türlerinden biridir. Ancak rüzgâr türbinlerinden elde edilen enerji üretimi, doğrudan meteorolojik koşullara bağlıdır.

Rüzgâr hızı, rüzgâr yönü, nem, basınç ve hava sıcaklığı gibi atmosferik değişkenler rüzgâr enerjisi üretimini etkileyen en önemli faktörlerdendir. Bu faktörlerin değişkenliği, rüzgâr enerji santrallerinin üretim kapasitesinde öngörülemeyen dalgalanmalara yol

açabilmektedir. Bu nedenle, meteorolojik faktörler rüzgâr enerji sistemlerinin performansı, verimliliği ve işlevselliği üzerinde kritik bir rol oynamaktadır.

1.8.1. Rüzgâr Hızı

Rüzgâr hızı, rüzgârın en önemli özelliklerinden biridir ve atmosferdeki hava kütlelerinin hareket hızını ifade etmektedir. Genellikle m/s (metre/saniye) veya km/s (kilometre/saat) cinsinden ölçülmektedir.

Rüzgâr hızı değişkenliği, rüzgâr türbinlerinin üretebildiği elektrik miktarını doğrudan etkileyen en kritik meteorolojik faktörlerden biridir. Rüzgâr hızındaki dalgalanmalar, türbinlerin hem verimliliği hem de operasyonel güvenilirliği üzerinde belirleyici rol oynamaktadır. Bu nedenle, rüzgâr hızının zamansal değişimlerinin doğru şekilde analiz edilmesi ve bu değişkenliğin hem türbin tasarımında hem de enerji üretim modellerinde dikkate alınması büyük önem taşımaktadır. Rüzgâr hızı arttıkça üretilen enerji de artmakta, ancak çok yüksek hızlarda türbinler güvenlik nedeniyle otomatik olarak devre dışı kalabilmektedir. Ayrıca rüzgâr hızının günlük, periyodik ve mevsimsel değişkenliği, açık ve kapalı yük koşullarında türbinin akım ve voltaj çıkışlarını doğrudan etkilemekte ve genel enerji üretimi üzerinde önemli dalgalanmalara yol açmaktadır (Muhammad ve ark., 2014). Bundan dolayı, rüzgâr hızı değişkenliği hem üretim süreçlerinin optimizasyonu hem de enerji tahmin modellerinin doğruluğu açısından dikkatle değerlendirilmelidir.

1.8.2. Rüzgâr Yönü

Rüzgâr yönü, rüzgâr enerjisi üretimini doğrudan etkileyen önemli meteorolojik faktörlerden biridir. Bir rüzgâr türbininin maksimum verimle çalışabilmesi için, gelen rüzgârın belirli bir yönden ve uygun açıda türbine çarpması gerekmektedir.

Rüzgâr türbinleri, genellikle rüzgâr yönüne göre yerleştirilir. Bir bölgedeki uzun dönemli rüzgâr verileri analiz edilerek türbinlerin en yüksek verimi sağlayacak şekilde konumlandırılması sağlanmaktadır. Ancak rüzgâr yönü değişken bir parametre olduğundan, türbinlerin verimli çalışması için Yaw kontrol sistemi gibi mekanizmalarla rüzgârın yönüne göre sürekli olarak ayarlanması gereklidir. Bununla birlikte eğer rüzgâr, türbinlerin çalışması

için uygun olmayan bir yönden eserse veya çok sık yön değiştirirse, üretim verimi önemli ölçüde azalabilmektedir.

Sonuç olarak, rüzgâr yönü değişimleri enerji üretimini doğrudan etkileyerek santral verimliliğini belirleyen önemli faktörlerden biri haline gelmektedir. Doğru tahmin ve optimizasyon yöntemleriyle bu etkinin minimize edilmesi mümkündür.

1.8.3. Hava Sıcaklığı ve Hava Yoğunluğu

Hava sıcaklığı rüzgâr modellerini ve atmosferik sirkülasyonu etkileyerek rüzgâr enerjisi üretimini etkileyen meteorolojik bir faktördür. Kara ve deniz arasındaki veya farklı atmosferik katmanlar arasındaki sıcaklık farklılıkları hava yoğunluğu, rüzgâr hızı ve türbin bileşenlerinin performansı üzerinde etkili olabilmektedir.

Hava yoğunluğu, sıcaklığa bağlı olarak değişmektedir. Sıcaklık arttıkça hava yoğunluğu azalır, bu da türbinlerin üretebileceği enerji miktarını düşürebilir. Soğuk havalarda hava yoğunluğu daha yüksek olduğundan, aynı rüzgâr hızında daha fazla enerji üretilebilir.

1.8.4. Nem ve Yağış

Rüzgâr enerjisi üretimi yalnızca rüzgâr hızı ve yönüyle değil aynı zamanda atmosferdeki nem ve yağış gibi diğer meteorolojik faktörlerle de doğrudan veya dolaylı olarak etkilenmektedir.

Nem, hava yoğunluğunu ve rüzgâr türbini performansını etkileyerek rüzgâr enerjisi üretimini etkileyen meteorolojik bir faktördür. Yüksek nem hava yoğunluğunu azaltarak rüzgâr türbin verimliliğinin azalmasına neden olurken, düşük nem hava yoğunluğunu artırarak verimliliği artırabilir.


1.9. Makine Öğrenmesi Modelleri

Makine öğrenmesi, bilgisayarların verilerden öğrenerek tahmin yapmasını sağlayan yöntemler bütünüdür ve rüzgâr enerjisi üretimi gibi çok sayıda değişkene bağlı sistemlerde doğruluk oranını artırmada etkili bir araç olarak kullanılmaktadır (Qureshi ve ark., 2020).

Günümüzde enerji, sağlık, finans gibi birçok alanda yaygın olarak kullanılan bu yöntemler, karmaşık verilerle çalışmada önemli avantajlar sunmaktadır. Bu çalışmada, rüzgâr enerjisi üretimini tahmin etmek için farklı makine öğrenmesi yöntemleri kullanılmış ve bu modellerin performansları karşılaştırılmıştır. Aşağıda kullanılan algoritmalar detaylı şekilde açıklanmıştır.

1.9.1. Hafif Gradyan Artırmalı Makine (Light Gradient Boosting Machine – LightGBM)

LightGBM, Microsoft tarafından geliştirilen karar ağaçları temelli bir gradyan artırma algoritmasıdır. Büyük boyutlu veri kümeleri üzerinde yüksek hız ve doğruluk sağlaması amacıyla tasarlanmıştır. Klasik gradyan artırma yöntemlerinden ayrılan en önemli yönü, yaprak odaklı (leaf-wise) bir büyüme stratejisi benimsemesidir. Bu strateji, her iterasyonda hatası en yüksek olan yaprak düğümünü bölerek tahmin performansını artırmaktadır (URL-5).



Şekil 7. LightGBM algoritma yapısı (URL-5)


Pek çok gradyan artırmalı modelde ağaçlar seviyelere (level-wise) göre genişletilirken, Şekil 7’de görüldüğü üzere LightGBM en yüksek bilgi kazancına sahip düğümü seçerek derinlemesine dallanma gerçekleştirir. Bu sayede daha hızlı öğrenme sağlanır ve genel hata azalır (Ke ve ark., 2017). Ayrıca LightGBM, özellik bölme sürecini doğrudan ham veride değil, histogram temelli ayrıklaştırma yöntemiyle yürütür. Sürekli değişkenler belirli aralıklara bölünerek histogramlar oluşturulur ve karar ağaçları da bu histogramlardan faydalanarak inşa edilir. Bu yöntem, bellek tüketimini düşürürken modelin işlem hızını da artırır.

Bunun yanında LightGBM, kategorik deęişkenleri otomatik olarak tanıyıp işleyebilme yeteneęi sayesinde pek çok sektörde yaygın olarak kullanılmaktadır. Enerji üretimi tahmini gibi zaman serisi tabanlı uygulamalarda, doęru özellik mühendislięiyle birleřtirildięinde yüksek başarı elde etmek mümkündür. Ancak, model performansı hiperparametre ayarlarına duyarlıdır ve bu nedenle uygun optimizasyon süreçleriyle desteklenmelidir (Ke ve ark., 2017).

1.9.2. Rastgele Orman (Random Forest - RF)

RF, 2001 yılında Leo Breiman tarafından geliştirilmiř, karar ağaęlarından oluřan bir topluluk (ensemble) öğrenme yöntemidir (Breiman, L., 2001). Sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan algoritmanın temel mantıęı, birden fazla bağımsız karar ağaęının bir araya gelerek genel bir karar mekanizması oluřturmasıdır. Sınıflandırmada çoęunluk oyu, regresyonda ise ortalama deęer hesaplanarak son tahmin elde edilir. Bu yaklařım, tek bir karar ağaęına kıyasla daha yüksek doęruluk ve daha güçlü genelleme yeteneęi saęlar.

řekil 8’de gösterilen RF algoritma yapısında, eğitim veri kümesinden rastgele ve tekrarlı örnekler alınarak her bir karar ağaęı farklı alt veri kümeleri üzerinde bağımsız řekilde eğitilir. Her bir karar ağaęı, kendisine verilen alt veri kümesine göre bağımsız olarak öğrenme sürecini tamamlar ve kendi tahminini üretir (Result 1, Result 2, Result 3). Ardından, bu bağımsız ağaęların çıktıları birleřtirilir. Eęer problem sınıflandırma ise, her ağaęın oylaması alınarak çoęunluk oylaması (Majority Voting) yöntemi uygulanır ve en çok seęilen sınıf nihai sonuç olur. Eęer problem regresyon ise, tüm ağaęların tahminleri toplanarak ortalama alma (averaging) yöntemi ile final sonuç elde edilir.



Şekil 8. RF Algoritma Yapısı (URL-4)

Bu yapı sayesinde tek bir karar ağacının sınırlılıkları ve hata payı azaltılmakta, modelin genelleme yeteneği artmakta ve aşırı uyum (overfitting) riski önemli ölçüde düşmektedir (Breiman, 2001).


Rüzgâr enerjisi gibi çok değişkenli sistemlerde, rüzgâr hızı, sıcaklık, nem ve basınç gibi değişkenlerin bir arada modellenmesi için uygundur.

1.9.3. Geliştirilmiş Gradyan Artırma (Extreme Gradient Boosting - XGBoost)

XGBoost, Tianqi Chen ve Carlos Guestrin tarafından 2016 yılında tanıtılan gradyan artırma mantığıyla çalışan güçlü bir makine öğrenmesi algoritmasıdır (Chen & Guestrin, 2016). Temel olarak, zayıf karar ağaçları ardışık şekilde eğitilerek bir önceki tahmin hataları düzeltilir. XGBoost'un klasik gradyan artırmalı modellere göre farkı, hesaplama verimliliğini artıran ve aşırı öğrenmeyi önlemeye yardımcı olan düzenleme tekniklerini içermesidir.

Ayrıca, paralel hesaplama yeteneği ve gelişmiş optimizasyon seçenekleri sayesinde büyük veri setlerinde yüksek performans sunar. Hiperparametre ayarlarının esnekliği, çapraz doğrulama desteği ve kullanıcı dostu ara yüzü, XGBoost'un popülerliğini artıran faktörlerdendir. Finans, sağlık, enerji ve rekabetçi veri bilimi yarışmalarında yaygın olarak

tercih edilen algoritma, enerji üretimi tahmini gibi regresyon problemlerinde de etkili sonuçlar üretir.



Şekil 9. XGBoost algoritma yapısı (Chen & Guestrin, 2016)

Şekil 9’da XGBoost algoritma yapısı gösterilmektedir. Algoritmada, ilk karar ağacı (Decision Tree 1) eğitim verileri üzerinde oluşturulur ve bu ağacın tahmin hataları hesaplanarak ikinci karar ağacına (Decision Tree 2) aktarılır. İkinci ağaç, bir önceki ağacın yapamadığı doğru tahminleri iyileştirmeyi amaçlar. Bu süreç, belirlenen ağaç sayısı kadar devam eder. Her yeni ağaç, bir önceki tahminin hatalarını minimize etmeye çalışarak modelin genel performansını artırır. Son aşamada tüm ağaçlardan elde edilen sonuçlar ağırlıklı olarak birleştirilir ve nihai tahmin (prediction) değeri elde edilir.

1.9.4. K-En Yakın Komşu (K-Nearest Neighbors - KNN)

KNN algoritması, Cover ve Hart tarafından 1967 yılında geliştirilmiş basit ve sezgisel bir öğrenme yöntemidir (Cover & Hart, 1967). Eğitim süreci gerektirmeyen bu algoritma, sınıflandırma ve regresyon problemlerinde temel karşılaştırma modellerinden biri olarak yaygın biçimde kullanılır.

KNN algoritmasının temel prensibi, yeni bir verinin tahminini en yakın K komşunun bilgilerine dayandırmaktır. Bu algoritma, yeni bir verinin tahminini yapmak için en yakın komşuların ortalamasını alır ve verilerin etiketlerini veya değerlerini, yakınındaki K komşularına dayalı olarak tahmin eder. Her bir veri noktası, özelliklerinin oluşturduğu bir

vektör olarak temsil edilir ve diğer veri noktalarıyla arasındaki mesafeler hesaplanır. Bu mesafe hesaplamasında genellikle Öklidyen mesafesi tercih edilir. İki veri noktası arasındaki mesafe Denklem 4'te gösterildiği şekilde hesaplanır:

$$d(x,y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4)$$

Denklemde $d(x,y)$ iki nokta arasındaki mesafeyi, x ve y iki veri noktasını, n özelliklerin sayısını ve x_i ve y_i x ve y noktalarının i .inci özelliğini göstermektedir. Elde edilen mesafelere göre en küçük mesafeye sahip K adet veri noktası seçilir. KNN algoritması, bu komşuların etiketlerini kullanarak tahmin yapar.

Sınıflandırma problemlerinde, en yakın komşuların etiketleri arasından çoğunlukla görülen sınıf seçilir (Denklem 5).


$$\hat{y} = mode(y_1, y_2, \dots, y_K) \quad (5)$$

Regresyon problemlerinde ise, bu komşuların etiket değerlerinin ortalaması alınarak tahmin yapılır (Denklem 6).

$$\hat{y} = \frac{1}{K} \sum_{i=1}^K y_i \quad (6)$$

Denklem 5 ve Denklem 6'da, $\hat{y}$ tahmin edilen değeri, $y_1, y_2, \dots, y_K$ K komşusunun etiket değerlerini ve mode çoğunluk kararını belirleyen fonksiyonu göstermektedir.

KNN algoritmasının temel işleyişi Şekil 10'da gösterilmektedir.



Şekil 10. KNN Algoritmasının temel işleyişi (Cover & Hart, 1967)

Algoritmadaki en kritik parametre K değeridir. Küçük bir K değeri modelin aşırı öğrenmesine, çok büyük bir K değeri ise genelleme gücünün azalmasına neden olabilir. Bu nedenle uygun K değeri, doğrulama yöntemleriyle dikkatle seçilmelidir.

Rüzgâr enerjisi üretimi gibi zaman serisi temelli regresyon problemlerinde KNN, özellikle kısa vadeli benzerlikleri yakalamada başarılı bir referans modeli olarak değerlendirilebilir.

1.10. Performans Kriterleri

Rüzgâr enerjisi üretimi gibi zaman serisi temelli regresyon problemlerinde model başarısı, çeşitli hata metrikleriyle değerlendirilmektedir (Hyndman & Athanasopoulos, 2018).

Bu metrikler, modelin gerçek değerleri ne kadar isabetli tahmin edebildiğini göstermektedir. Aşağıda yaygın kullanılan temel performans metrikleri açıklanmıştır:

1.10.1. Ortalama Mutlak Hata (Mean Absolute Error– MAE)

MAE, tahmin edilen değer ile gerçek değer arasındaki farkın mutlak değerlerinin ortalamasıdır (Hyndman & Koehler, 2006). Bu metrik, modelin tahminlerinin gerçek değerlere ortalama ne kadar yakın olduğunu göstermekte ve hata büyüklüğünü doğrudan ifade ettiği için yorumlanması oldukça kolaydır. Ayrıca, her bir tahminin ortalama hata miktarını ortaya koymaktadır. Formülü, Denklem 7’de gösterilmektedir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

Denklemde, n toplam veri noktası sayısını, y_i gerçek (gözlenen) değeri, $\hat{y}_i$ model tarafından tahmin edilen değeri ve $|y_i - \hat{y}_i|$ her bir veri noktası için tahmin hatasının mutlak değerini göstermektedir.

MAE, büyük hataları diğerlerine göre daha az vurguladığından, uç değerlerin çok baskın olmadığı veri setlerinde tercih edilir. Rüzgâr hızı veya üretim tahmini gibi uygulamalarda sıkça kullanılır.

1.10.2. Kök Ortalama Kare Hata (Root Mean Squared Error- RMSE)

RMSE, hata karelerinin ortalamasının karekökü alınarak hesaplanan ve büyük hatalara daha duyarlı bir ölçüttür ve daha büyük hatalara daha duyarlıdır. Bu yönüyle tahminlerdeki istikrarsızlıkları daha net ortaya çıkarmaktadır. Formülü Denklem 8’de gösterilmektedir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

Denklemde, n toplam veri noktası sayısını, y_i gerçek (gözlenen) değeri, $\hat{y}_i$ model tarafından tahmin edilen değeri ve $(y_i - \hat{y}_i)^2$ her bir veri noktası için hatanın karesini göstermektedir.

RMSE'nin birimi, tahmin edilen değişkenle aynıdır. Bu özellik, yorumlanmasını kolaylaştırır. Özellikle enerji tahminlerinde büyük sapmaları göz önüne almak için kullanılır.

1.10.3. Determinasyon Katsayısı (R-Squared- R^2)

R^2 , modelin bağımlı değişkeni ne ölçüde açıkladığını gösteren bir uygunluk katsayısıdır ve modelin açıklayıcılık gücünü yansıtarak, bağımlı değişkendeki varyansın ne kadarının bağımsız değişkenlerle açıklandığını ifade etmektedir. Metrik, 0 ile 1 arasında değer almakta ve 1'e yaklaştıkça modelin veriyle uyum seviyesi artmaktadır. Formülü Denklem 9'da verilmiştir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (9)$$

Denklemde, y_i gerçek (gözlenen) değeri, $\hat{y}_i$ modelin tahmin ettiği değerleri, $\bar{y}$ gerçek değerlerin ortalamasını, $\sum (y_i - \hat{y}_i)^2$ modelin tahmin hatalarının toplamını, $\sum (y_i - \bar{y})^2$ gerçek değerlerin ortalamadan sapmalarının toplamını göstermektedir.

- $R^2 = 1$: Mükemmel uyum, tüm değişkenliği açıklar.
- $R^2 = 0$: Hiçbir açıklama yapamaz, rastgele tahmin gibidir.
- $R^2 < 0$: Ortalama değerden bile kötü tahmin yapar.

R^2 değeri 0 ile 1 arasında olup, 1'e ne kadar yakınsa model o kadar başarılı kabul edilir. Ancak yüksek R^2 her zaman pratikte iyi tahmin anlamına gelmeyebilir. Özellikle rüzgâr hızı veya enerji üretimi gibi verilerde, modelin pratik doğruluğunu değerlendirmek için RMSE ve MAE gibi ek metriklerle birlikte kullanılması önerilir.

2. YAPILAN ÇALIŞMALAR

2.1. Problemin Tanımı


Rüzgâr enerjisi, sürdürülebilir ve yenilenebilir bir enerji kaynağı olmasına rağmen, üretim miktarı doğrudan meteorolojik faktörlere bağlı olarak değişkenlik göstermektedir. Bu durum, enerji üretiminin doğru tahmin edilmesini zorlaştırmakta ve şebeke dengesi, maliyet optimizasyonu ve enerji arz güvenliği açısından önemli bir sorun teşkil etmektedir. Geleneksel tahmin yöntemlerinin yetersiz kaldığı durumlarda makine öğrenme ve derin öğrenme tabanlı modellerin kullanımı giderek artmaktadır. Çalışmada, farklı makine öğrenme algoritmalarının rüzgâr enerjisi üretimi tahminindeki performansları karşılaştırılarak, en uygun modelin belirlenmesi hedeflenmiştir.

2.2. Meteorolojik Veriler

Çalışmada, rüzgâr enerjisi üretimi tahminlerinde daha doğru sonuçlar elde edebilmek için İzmir'in Çeşme ilçesinde bulunan Meteoroloji Genel Müdürlüğünden alınan istasyon verileri yerine Rüzgâr Enerji Santrali sahasında yapılan yerinde ölçümler tercih edilmiştir. Rüzgâr enerji santralinden veri temin edilmesinin başlıca nedeni; bölgedeki arazinin yapısının, ölçüm yapılan yüksekliklerin farklı olması ve yerel rüzgâr hareketlerinin MGM verilerinde tam karşılık bulamamasıdır. Ayrıca, MGM istasyon verilerinde veri eksikliği, düzensizlikler gibi sınırlılıklar da analizlerin doğruluğunu olumsuz etkilemektedir. Makine öğrenme tabanlı tahmin modellerinin güvenilir şekilde eğitilebilmesi için yüksek zaman çözünürlüğüne sahip, eksiksiz ve tutarlı veri setlerine ihtiyaç duyulmaktadır. Bu doğrultuda, analizlerin güvenilirliğini artırmak ve model performansını optimize edebilmek amacıyla doğrudan rüzgâr enerji santralinden temin edilen veriler kullanılmıştır.


Çalışmada, MGM istasyonundan 10 metre yükseklikten elde edilen veriler ile santrale ait yaklaşık 60–65 metre yükseklikteki ölçüm verileri karşılaştırılarak sonuçlar değerlendirilmiştir. Karşılaştırılan ölçüm verileri bahar, yaz ve kış mevsimlerini temsil edecek şekilde Nisan, Ağustos ve Aralık aylarından seçilmiştir.

2.2.1. Bahar Mevsimi (Nisan Ayı) Meteorolojik Verilerin Karşılaştırılması



Şekil 11. Nisan ayı MGM-RES rüzgâr hızı grafiği

Şekil 11’de verilen grafikte Nisan ayına ait RES sahasında yapılan yerinde ölçümler ile MGM ölçüm verilerinin karşılaştırılması gösterilmektedir. RES’e ait rüzgâr hızı verilerinin MGM’ye ait rüzgâr hızı verilerinden belirgin bir şekilde daha yüksek değerler olduğu görülmektedir. Bu farklılık santral sahasındaki yerel topoğrafik ve meteorolojik koşulların, bölgesel ölçüm istasyonlarından farklılık göstermesinden kaynaklanmaktadır. Yerinde ölçülen rüzgâr hızları, türbin yüksekliği, yerel hava akımları ve engelleyici unsurlar gibi etkenlerden etkilenmekte ve bu da daha doğru üretim tahminlerine imkân tanımaktadır.




Şekil 12. Nisan ayı MGM-RES sıcaklık grafiği

Şekil 12’de verilen sıcaklık grafiğinde ise MGM ve RES’ten alınan ölçüm verileri arasında ciddi bir farklılık gözlemlenmemektedir. Her iki veri seti de benzer eğilimler göstermekte olup sıcaklık değerleri paralel bir şekilde değişmektedir. Bu durum, sıcaklık değişimlerinin yerel ölçekte rüzgâr hızına göre daha az değişken olduğunu göstermektedir.


Sonuç olarak, Nisan ayı için yapılan karşılaştırmalarda, enerji üretimi tahminlerinde özellikle rüzgâr hızı parametresinde yerel ölçümlerin kullanılmasının önemini bir kez daha ortaya koymaktadır. Sıcaklık verilerinde ise MGM ölçümleri destekleyici ve doğrulayıcı bir kaynak olarak kullanılabilir.

2.2.2. Yaz Mevsimi (Ağustos Ayı) Meteorolojik Verilerin Karşılaştırılması



Şekil 13. Ağustos ayı MGM-RES rüzgâr hızı grafiği

Şekil 13'te verile grafikte, Ağustos ayında RES'ten alınan rüzgâr hızı verilerinin MGM verilerine kıyasla belirgin şekilde daha yüksek olduğu görülmektedir. Bu fark, özellikle yaz aylarında yerel rüzgâr akımlarının, arazi üzerindeki yerel iklimsel etkilerin ve yükseklik farklarının daha etkili olduğunu göstermektedir. RES verileri, türbin sahasında yapılan yerinde ölçümler olduğu için rüzgâr santralinin gerçek performansını yansıtmada daha güvenilir olduğunu göstermektedir.




Şekil 14. Ağustos ayı MGM-RES sıcaklık grafiği

Şekil 14’te verilen grafikte ise MGM ve RES sıcaklık değerlerinin birbirine daha yakın olduğu gözlemlenmektedir. Ağustos ayında sıcaklıklar genel olarak yüksek seyretmekte ve MGM verileriyle RES verileri paralel bir değişim göstermektedir. Ancak yerel ölçümler, özellikle maksimum sıcaklık değerlerinde MGM’den biraz daha yüksek değerler sunmuştur. Bu durum, santral sahasındaki açık alan etkisi ve yerel ısı birikimi gibi faktörlerle açıklanabilir.


Sonuç olarak, Ağustos ayına ait grafiklerde özellikle yaz dönemlerinde rüzgâr hızındaki yerel farklılıkların enerji üretim tahminlerinde ne kadar kritik olduğunu bir kez daha ortaya koymaktadır. Yerinde ölçümlerle desteklenen RES verileri, rüzgâr türbinlerinin potansiyel üretim kapasitesini daha doğru şekilde yansıtırken; sıcaklık verilerinde MGM verileri destekleyici ve referans niteliğinde kullanılabilir.

2.2.3. Kış Mevsimi (Aralık Ayı) Meteorolojik Verilerin Karşılaştırılması



Şekil 15. Aralık ayı MGM-RES rüzgâr hızı grafiği

Şekil 15’te verilen grafikte, Aralık ayında RES sahasında ölçülen rüzgâr hızlarının MGM verilerine göre belirgin şekilde daha yüksek olduğu görülmektedir. Bu durum, kış aylarında yerel rüzgâr akımlarının santral sahasında daha güçlü ve değişken olabildiğini göstermektedir. Özellikle Aralık ayında RES verilerinde yer yer ani yükselişler gözlenirken, MGM verileri daha düşük ve daha yatay bir seyir izlemektedir. Bu fark, türbin sahasında yapılan yerinde ölçümlerin enerji üretim tahminlerinde ne kadar kritik olduğunu bir kez daha ortaya koymaktadır.



Şekil 16. Aralık ayı MGM-RES sıcaklık grafiği

Şekil 16’da verilen sıcaklık grafiğinde ise Aralık ayında sıcaklık değerlerinin genel eğilimi açısından MGM ve RES verilerinin birbirine yakın olduğu görülmektedir. Ancak belirli günlerde RES sahasında yapılan ölçümlerde sıcaklık değerlerinin MGM verilerine kıyasla daha yüksek çıktığı dikkat çekmektedir. Bu farklılık, santral sahasındaki yerel iklimsel etkenler, yerel ısı adası etkisi veya ölçüm noktalarının konum farklarından kaynaklanabilir.

Sonuç olarak, Aralık ayında rüzgâr hızı değişkenliği yerel ölçümlerde daha yüksek gözlemlenirken, sıcaklık değerlerinde MGM ve RES verileri arasında büyük sapmalar olmadığı görülmektedir. Bu durum, rüzgâr hızının yerel etkilerden sıcaklığa kıyasla daha fazla etkilendiğini ve dolayısıyla yerinde ölçüm yapılmasının gerekliliğini desteklemektedir.

Tablo 4. MGM ve RES ölçüm verilerinin karşılaştırılması

Kriter	MGM Ölçüm Verileri	RES Ölçüm Verileri
Ölçüm Yeri	Bölgesel ölçüm istasyonları (genel iklim verisi)	Santral sahasında direk ölçüm (yerel veri)
Rüzgâr Hızı	Düşük hassasiyet, genelleştirilmiş	Yüksek hassasiyet, türbin noktasına özgü
Sıcaklık Verisi	Genelde güvenilir ve istikrarlı	Saha bazlı küçük farklılıklar gösterebilir
Topoğrafik Etki	Topoğrafya ve yerel iklimsel özellikler tam yansımaz	Arazi şekli, yükseklik, engeller doğrudan etkili
Enerji Üretim Tahmini Etkisi	Daha belirsiz tahminler	Daha doğru, gerçeğe yakın tahminler
Elde Edilebilirlik	Ücretsiz, geniş kapsama alanı	Ek donanım ve bakım gerektirir
Kullanım Amacı	Destekleyici ve karşılaştırma	Ana veri kaynağı

Tablo 4, MGM'nin bölgesel veri setleri ile RES sahasında yapılan yerinde ölçümlerin temel farklarını özetlemektedir. Tablodan da görüldüğü üzere, rüzgâr hızı RES sahasında yerinde ölçüldüğünde topoğrafik ve yerel iklimsel etkiler doğrudan dikkate alındığından, bölgesel verilere kıyasla daha yüksek doğruluk sunmaktadır. Bu durum, rüzgâr enerji üretim tahmin modellerinin performansını artırmak ve tahmin belirsizliğini azaltmak açısından kritik bir avantaj sağlamaktadır (Burton ve ark., 2011).

Sonuç olarak, Nisan, Ağustos ve Aralık aylarına ait MGM-RES verilerinin karşılaştırılmasından görüldüğü üzere, rüzgâr hızı değerleri yerinde ölçümlerde genelde MGM değerlerinden daha yüksektir. Bu fark, yerel arazi şekilleri, engeller, yükseklik ve yerel iklimsel unsurlar gibi etkenlerden kaynaklanmaktadır. Özellikle rüzgâr hızındaki küçük farklar bile üretilecek enerji miktarını doğrudan etkilediğinden, yerinde ölçüm verileri çok daha güvenilir ve gerçeğe yakındır. Sıcaklık değerlerinde MGM ve RES verileri arasında genelde daha az fark oluşmaktadır. Ancak rüzgâr enerjisi üretiminde sıcaklık değişkeninin etkisi, rüzgâr hızına kıyasla daha sınırlı olduğu için kritik değişken rüzgâr hızıdır. Bu nedenle

özellikle rüzgâr hızında yerel ölçümler, tahminlerin doğruluğunu büyük oranda artırmaktadır.

2.3. Materyal ve Yöntem

Verilerin toplanması, bu çalışmanın temel aşamalarından biri olup doğru ve güvenilir sonuçlar elde edilebilmesi açısından büyük önem taşımaktadır. Çalışmada rüzgâr enerji üretimi tahmini amacıyla kullanılan veri seti, Türkiye’de faaliyette olan ve İzmir’in Çeşme ilçesinde kurulu bulunan bir RES’e ait olup, toplamda 49 türbinden oluşan santralin 1, 9, 19, 39 ve 49 numaralı türbinlerinden elde edilen ve meteorolojik faktörleri de içeren yaklaşık 330.000 adet ölçümden oluşmaktadır. Veriler, 01 Ocak 2023 ile 30 Haziran 2024 tarihleri arasında, 10 dakikalık zaman aralıklarıyla kaydedilmiş rüzgâr hızı, rotor hızı, kanat açısı, sıcaklık, nacelle yönü ve enerji üretimi değişkenlerini kapsamaktadır.

Santralin toplam kurulu gücü 56,20 MWe olup, kullanılan türbinlerin modeli Enercon E-48 ve her birinin kurulu gücü 800 kW’tır. Veri setinde giriş değişkenleri olarak rüzgâr hızı, kanat açısı, sıcaklık, rotor hızı ve nacelle yönü; çıkış değişkeni olarak ise rüzgâr enerjisi üretimi seçilmiştir.

Bu yüksek çözünürlüklü veri seti, rüzgâr enerjisi üretimi tahmininde kullanılacak olan makine öğrenme modellerinin eğitilmesi ve test edilmesi için uygun bir temel oluşturmuştur.

Veri seti; veri işleme aşamasında eksik gözlemler ve aykırı değerler analiz edilerek temizlenmiş, eğitim ve test verisi olmak üzere iki alt kümeye ayrılmıştır. Tahmin modelleri olarak KNN, XGBoost, RF ve LightGBM algoritmaları kullanılmıştır. Modellerin hiperparametreleri Optuna Kütüphanesi kullanılarak optimize edilmiştir.

Her bir modelin başarımı, MAE, RMSE ve R^2 gibi performans metrikleri ile değerlendirilmiştir. Sonuçlar grafiksel olarak görselleştirilmiş ve modellerin tahmin gücü karşılaştırmalı olarak analiz edilmiştir. Bu yöntemsel yaklaşım sayesinde, farklı algoritmaların rüzgâr enerjisi üretimi üzerindeki tahmin performansları detaylı bir şekilde karşılaştırılmış ve en uygun modelin belirlenmesi hedeflenmiştir.

	A	B	C	D	E	F	G	H	I
1	Türbin No	Tarih/Saat	Nacelle Yönü	Sıcaklık	Rüzgar Hızı	Rotor Hızı	Kanat Açısı	Üretim	
2	1	5/1/2023 12:10 AM	6	15	4	12,43	1,5	3	
3	1	5/1/2023 12:20 AM	4	15	3,8	12,38	1,5	3	
4	1	5/1/2023 12:30 AM	6	15	3,5	12,11	1,5	2	
5	1	5/1/2023 1:30 AM	10	14	3,3	12,08	1,5	1	
6	1	5/1/2023 1:40 AM	16	14	3,4	12,15	1,5	2	
7	1	5/1/2023 1:50 AM	19	14	3,6	12,21	1,5	2	
8	1	5/1/2023 2:10 AM	13	15	3,5	12,22	1,5	2	
9	1	5/1/2023 3:00 AM	28	14	2,6	3,52	44,9	1	
10	1	5/1/2023 3:10 AM	23	14	4,1	13,03	1,5	4	
11	1	5/1/2023 3:20 AM	25	15	4,2	13,52	1,5	5	
12	1	5/1/2023 3:30 AM	30	15	3,3	12,03	1,5	1	
13	1	5/1/2023 3:40 AM	20	15	3,3	11,96	1,5	1	
14	1	5/1/2023 3:50 AM	25	15	3,3	12,01	1,5	2	
15	1	5/1/2023 4:00 AM	29	15	4,6	14,43	1,5	7	

Şekil 17. Örnek RES verileri

Şekil 17’de veri setinin örnek bir formatı gösterilmektedir. Veri seti, tablo formatında düzenlenmiş olup her bir satır bir gözlem noktasını ve her bir sütun, rüzgâr hızı, sıcaklık ve kanat açısı gibi özellikleri temsil etmektedir.

2.4. Verilerin Düzenlenmesi

Santrale ait 01.01.2023–30.06.2024 tarihleri arasındaki yaklaşık 1,5 yıllık veriler incelendiğinde aykırı ve eksik verilerin bulunduğu tespit edilmiştir. Genellikle bakım ve arıza süreçlerinden kaynaklanan bu tür veriler, tahmin performansını olumsuz yönde etkilemektedir. Bu nedenle ilk aşamada eksik veriler veri setinden çıkarılmış, aykırı veriler ise temizlenerek analiz dışı bırakılmıştır. Eksik verilerin analiz edilmesinde, eksik veri oranı ve veri setinin yapısı göz önünde bulundurularak silme, ortalama veya medyan değeriyle tamamlama gibi yöntemlerden yararlanılmıştır. Veri setinin büyük olması nedeniyle, modelin daha verimli çalışmasını sağlamak ve tahmin performansını artırmak amacıyla karar destek noktaları oluşturulmuş ve ön işleme sürecinde belirli koşullara odaklanılmıştır.

Karar destek noktaları belirlenirken, veri setinde bulunan rüzgâr hızı, sıcaklık, kanat açısı ve üretim seviyeleri gibi değişkenlere göre eşik değerler belirlenmiştir. Bu eşik değerler, çalışma dinamikleri ve enerji üretim kapasitesi göz önünde bulundurularak seçilmiştir. Bunun için de santralde kullanılan türbin modelinin güç eğrisi üzerindeki değerler temel alınmış ve değişkenler belirli aralıklarda kategorize edilmiştir.

Veri setinde aykırı değerler temizlenirken;


- Belirli eşik değerlerinin altında kalan üretim seviyeleri silinmiştir.
- Üretimin fiziksel olarak mümkün olmayan değerlerde olduğu durumlar silinmiştir.
- Belirli rüzgâr hızlarında aniden sıfır üretim kaydedilen veriler silinmiştir.

Veri önışlem süreci, makine öğrenme modellerinin doğruluğunu artırmak, hatalı ve aykırı verilerin modelin tahmin performansını düşürmesini önlemek ve rüzgâr hızına karşılık gelen üretim seviyelerini daha doğru bir şekilde modelleyebilmesi adına anlamlı verileri kullanmak için yapılmıştır.

2.5. Korelasyon Analizi

Makine öğrenmesi modellerinin başarısında doğru değişkenlerin seçimi kritik bir rol oynamaktadır. Özellik seçimi, hem modelin tahmin doğruluğunu artırmak hem de model karmaşıklığını ve hesaplama süresini azaltmak amacıyla gerçekleştirilmektedir (Guyon & Elisseeff, 2003). Bu süreçte, öncelikle veri setindeki bağımsız değişkenlerin hedef değişkenle olan ilişkileri incelenmiş, ardından modellerde kullanılacak en anlamlı ve etkili değişkenler belirlenmiştir.

Değişkenler arasındaki doğrusal ilişkileri ölçmek için korelasyon matrisi oluşturulmuştur. Korelasyon katsayısı, -1 ile +1 arasında değer alır ve +1 güçlü pozitif ilişkiyi, -1 ise güçlü negatif ilişkiyi temsil etmektedir. Değerlerin 0'a yakın olması ise değişkenler arasında anlamlı bir ilişki olmadığını göstermektedir (Hair ve ark., 2010).



Şekil 18. Korelasyon matrisi

Şekil 18’de görüldüğü üzere çalışmada rüzgâr hızı, rotor hızı, kanat açısı, sıcaklık ve nacelle yönü gibi meteorolojik ve operasyonel değişkenlerin enerji üretimi ile olan korelasyonları incelenmiştir. Elde edilen sonuçlar, enerji üretimini en çok etkileyen değişkenlerin rüzgâr hızı ve rotor hızı olduğunu göstermiştir. Bazı değişkenler arasında yüksek korelasyon gözlemlendiğinde, çoklu doğrusal bağlantı sorununu önlemek amacıyla ilgili değişkenlerin yeniden değerlendirilmesi veya uygun dönüşümlerle işlenmesi gerektirebilmektedir (James ve ark., 2013).

3. BULGULAR VE TARTIŞMA

Bu bölümde, rüzgâr enerjisi üretiminin tahminine yönelik geliştirilen makine öğrenmesi modellerinden elde edilen sonuçlar sunulmaktadır. Çalışma kapsamında kullanılan KNN, XGBoost, RF ve LightGBM algoritmalarının performansları, seçilen değerlendirme metrikleri MAE, RMSE ve R^2 üzerinden analiz edilmiştir. Modellerin tahmin doğruluğu hem sayısal sonuçlar hem de grafiksel görselleştirmelerle karşılaştırılmış, hangi modelin enerji üretimi tahmini açısından daha başarılı olduğu ortaya konmuştur.

3.1. Hiperparametre Optimizasyonu Sonuçlarının Karşılaştırmalı Analizi (Optuna Tabanlı Bayesçi Yaklaşım)

Çalışmada uygulanan hiperparametre optimizasyon süreci, modellerin tahmin performanslarını artırmak amacıyla geniş bir parametre aralığında gerçekleştirilmiştir. Her makine öğrenme algoritması için hiperparametrelerin en uygun kombinasyonlarını belirlemek amacıyla Bayesçi optimizasyon yöntemi olan Optuna kütüphanesi kullanılmıştır. Bayesçi optimizasyon, önceki denemelerden elde edilen başarı skorlarını temel alarak, bir sonraki hiperparametre kombinasyonlarını olasılıksal modeller aracılığıyla seçen bir arama yöntemidir. Bu özellik, klasik GridSearch veya RandomSearch gibi yöntemlere göre daha az iterasyonla daha başarılı sonuçlar elde edilmesini sağlamaktadır (Snoek ve ark., 2012, Akiba ve ark., 2019). Çalışmada, K-Fold = 5 değeri seçilerek her model için 5 katlı çapraz doğrulama uygulanmış ve eğitim verilerinde ortalama hata metriklerine göre optimize edilen hiperparametre değerleri elde edilmiştir. Optimizasyon sonucunda elde edilen en iyi hiperparametreler, modellerin öğrenme stratejileri ve veriyle etkileşim biçimleri hakkında önemli bilgiler sunmuştur.

Tablo 5'te dört farklı makine öğrenme modeli için elde edilen ortalama en iyi hiperparametre değerleri ve bu değerlerin arandığı optimizasyon aralıkları gösterilmektedir.

Tablo 5. Modellerin hiperparametreleri ve optimizasyon aralıkları

Model	Hiperparametre	Optimum Ortalama Değer	Optimizasyon Aralığı
RF	n_estimators	198	[50, 400]
	max_depth	20	[5, 30] (log)
	min_samples_split	15	[2, 20]
	min_samples_leaf	6	[1, 10]
KNN	n_neighbors	12	[1, 30]
	weights	distance	['uniform', 'distance']
	p	1	[1, 2]
XGBoost	n_estimators	295	[50, 500]
	learning_rate	0.0224	[0.005, 0.2] (log)
	max_depth	10	[3, 15]
	subsample	0.851	[0.6, 1.0]
	colsample_bytree	0.918	[0.6, 1.0]
	gamma	0.200	[0.0, 0.5]
LightGBM	n_estimators	409	[50, 500]
	learning_rate	0.028	[0.005, 0.2] (log)
	num_leaves	174	[20, 256]
	max_depth	11	[-1, 20]
	min_child_samples	54	[20, 100]
	reg_alpha	0.274	[0.0, 1.0]
	reg_lambda	0.550	[0.0, 1.0]

Tablo 5 incelendiğinde Optuna kütüphanesi kullanılarak yapılan optimizasyon sonucunda $n_estimators = 198$, $max_depth = 20$, $min_samples_split = 15$ ve $min_samples_leaf = 6$ değerleri ile RF modeli hem aşırı öğrenmeden kaçınmış hem de karmaşık veri yapısını başarılı şekilde modelleyebilmiştir. Ağaç derinliğinin log aralıkta optimize edilmesi, daha geniş ancak dengeli yapılar oluşturulmasına katkı sağlamıştır.

KNN modeli için en uygun $n_neighbors = 12$, $p = 1$ ve $weights = distance$ değerleri elde edilmiştir. Bu yapı, özellikle yakın komşulara ağırlık verilerek daha isabetli tahminler üretmeyi hedeflemiştir. Ancak KNN algoritmasının, zaman serisi benzeri karmaşık ve dinamik veri yapılarında sınırlı başarımı, optimizasyon sonucuna rağmen belirgin kalmıştır.

XGBoost modelinde $learning_rate = 0.0224$, $n_estimators = 295$, $max_depth = 10$, $subsample = 0.851$, $colsample_bytree = 0.918$ ve $gamma = 0.200$ gibi parametreler, Bayesçi optimizasyonu ile belirlenmiştir. Özellikle düşük öğrenme oranı ile birlikte yüksek ağaç sayısı, modelin kademeli ve güvenilir öğrenmesini sağlamış; örnekleme oranları ile aşırı öğrenme riski sınırlandırılmıştır. Bu yapı, yüksek doğruluk ve güçlü genelleme yeteneği sunmuştur.


LightGBM modeli için $learning_rate = 0.028$, $n_estimators = 409$, $num_leaves = 174$, $max_depth = 11$, $min_child_samples = 54$, $reg_alpha = 0.274$ ve $reg_lambda = 0.550$ gibi değerler elde edilmiştir. Bu parametre ayarları, modelin hem esnek hem de düzenli öğrenmesini sağlamış ve eğitim-tahmin süresini optimize etmiştir. Özellikle $L1$ (reg_alpha) ve $L2$ (reg_lambda) düzenleme terimlerinin doğru ayarlanması, LightGBM'in aşırı öğrenmeye karşı dayanıklı hale gelmesine katkı sağlamıştır.

Sonuç olarak, Bayesçi optimizasyonu hiperparametrelerin olasılıksal arama mantığıyla etkin biçimde taranmasını sağlayarak her model için en uygun kombinasyonlara daha kısa sürede ulaşılmasına olanak tanımıştır. Bu durum, özellikle büyük veri setleriyle yapılan enerji tahminlerinde, hesaplama yükünü azaltırken model performansını artırma açısından büyük avantaj sağlamaktadır (Bergstra & Bengio, 2011, Akiba ve ark., 2019). XGBoost ve LightGBM gibi gradyan artırmalı algoritmalar ile RF algoritması, bu süreç sonunda en düşük hata oranlarına ve en yüksek R^2 skorlarına ulaşmıştır. KNN ise hiperparametre optimizasyonuna rağmen sınırlı bir başarı göstermiştir.

3.2. Makine Öğrenmesi Algoritmalarının Performanslarının Değerlendirilmesi

Bu bölümde, rüzgâr enerjisi üretiminin makine öğrenmesi yöntemleriyle tahmin edilmesine yönelik gerçekleştirilen çalışma sonuçları paylaşılmıştır.

3.2.1. RF Algoritması Enerji Üretim Tahmin Performansı




Şekil 19. RF Enerji üretim tahmini

Şekil 19’da verilen grafikte RF algoritması ile tahmin edilen enerji üretimi değerleri ile gerçek enerji üretimi değerleri karşılaştırmalı olarak gösterilmektedir. Yatay ekseninde gerçek enerji üretimi (kWh), dikey ekseninde ise model tarafından tahmin edilen enerji üretimi (kWh) yer almaktadır. Kırmızı kesikli çizgi, ideal tahmin durumunu (yani tahmin edilen değerlerin birebir gerçek değere eşit olduğu durumu) temsil etmektedir.

Grafikteki dağılım incelendiğinde, tahmin edilen değerlerin büyük çoğunluğunun ideal çizgiye oldukça yakın olduğu görülmektedir. Bu durum, RF modelinin genel olarak yüksek bir doğrulukla tahmin gerçekleştirdiğini göstermektedir. Bununla birlikte, özellikle yüksek üretim değerlerinde tahminlerin zaman zaman gerçek değerlerin altında ya da üstünde kaldığı gözlenmektedir. Bu sapmalar modelin bazı uç değerleri yakalamakta zorlandığını ya da aşırı öğrenme yerine daha temkinli bir tahmin stratejisi izlediğini göstermektedir. Genel olarak, RF modelinin doğrusal ilişkiyi başarılı bir şekilde öğrenebildiği, farklı üretim seviyelerinde istikrarlı tahminler sunduğu ve enerji üretimi tahmininde güvenilir bir yöntem olabileceği söylenebilmektedir.


3.2.2. KNN Algoritması Enerji Üretim Tahmin Performansı



Şekil 20. KNN Enerji üretim tahmini

Şekil 20’de yer alan KNN modeline ait grafik incelendiğinde, tahmin edilen enerji üretimi değerlerinin referans çizgisi (gerçek = tahmin doğrusu) etrafında belirgin bir dağınıklık sergilediğini göstermektedir. Modelin bazı üretim aralıklarında gerçek enerji üretimi değerlerine yakın tahminler yaptığı ancak, genel olarak tahmin performansında belirgin sapmaların bulunduğunu ve veri noktalarının referans çizgisinden uzaklaşması, modelin tahmin hatalarının yüksek olduğunu ve tutarlı sonuçlar üretemediğini göstermektedir. Özellikle yüksek üretim seviyelerinde, tahminlerin gerçek değerlerden saptığı ve yayılımının arttığı gözlenmektedir. Bu durumun, KNN algoritmasının karmaşık ve doğrusal olmayan ilişkileri yeterince iyi modelleyememesinden kaynaklandığı şeklinde açıklanabilmektedir. Komşuluk temelli çalışan bu algoritma, sadece yakın veri noktalarına dayalı tahminlerde bulunduğu için, veri setinin dağılımına ve yoğunluğuna karşı oldukça hassastır. Her ne kadar R^2 değeri modelin genel açıklayıcılığının kabul edilebilir düzeyde olduğunu gösterse de, tahmin doğruluğunun düşük olması, uygulama açısından önemli bir dezavantaj oluşturmaktadır. Bu kapsamda grafik, KNN algoritmasının enerji üretimi tahmininde daha sınırlı ve değişken bir performans sergilediğini açıkça ortaya koymaktadır.


3.2.3. XGBoost Algoritması Enerji Üretim Tahmin Performansı



Şekil 21. XGBoost Enerji üretim tahmini

Şekil 21’de verilen XGBoost modeline ait gerçek ve tahmin edilen enerji üretimi değerlerinin karşılaştırıldığı grafik incelendiğinde, veri noktalarının büyük çoğunluğunun referans çizgisine oldukça yakın bir şekilde konumlandığı gözlenmektedir. Tahmin edilen değerler, özellikle orta ve yüksek üretim seviyelerinde gerçek değerlerle büyük ölçüde örtüşmekte; bu durum modelin hem doğruluk hem de kararlılık açısından güçlü bir performans sergilediğini göstermektedir. Modelin tahmin eğrisi ile gerçek değer eğrisi arasında görülen yüksek paralellik, XGBoost’un öğrenme sürecinde veri setindeki örüntüleri başarıyla yakaladığını ortaya koymaktadır. XGBoost’un yüksek performansı, algoritmanın ağaç tabanlı yapısı sayesinde doğrusal olmayan ilişkileri modelleyebilme yeteneğinden ve hiperparametre optimizasyonu sonucunda elde edilen ideal parametre ayarlarından kaynaklanmaktadır. Grafik üzerinde birkaç noktada küçük sapmalar olsa da bu sapmaların düzenli olmadığı görülmektedir. Bu da modelin aşırı öğrenmeye düşmeden dengeli bir öğrenme gerçekleştirdiğini göstermektedir. XGBoost modeli, gerek hata değerleri gerekse yüksek R^2 skoru ile rüzgâr enerjisi tahmininde üstün performans sergilemiştir.

3.2.4. LightGBM Algoritması Enerji Üretim Tahmin Performansı



Şekil 22. LightGBM Enerji üretim tahmini

Şekil 22’de LightGBM algoritması ile tahmin edilen enerji üretim değerleri ile gerçek enerji üretim değerlerinin karşılaştırması verilmektedir. Grafikteki dağılım, LightGBM modelinin genel olarak doğru tahminlerde bulunduğunu göstermektedir. Verilerin büyük çoğunluğu ideal çizginin çevresinde yoğunlaşmış olup, modelin düşük ve orta üretim değerlerini oldukça başarılı bir şekilde tahmin ettiği görülmektedir. Özellikle 0-120 kWh aralığında tahmin başarımı yüksektir. Ancak, yüksek üretim seviyelerine çıkıldıkça bazı tahminlerde sapmalar gözlemlenmektedir. Bu sapmaların az sayıda olması, modelin genel olarak yüksek üretim değerlerini de başarılı bir şekilde yansıttığını göstermektedir. Sonuç olarak, LightGBM algoritması enerji üretimi tahmininde hem doğruluk hem de genellenebilirlik açısından etkili bir yöntem olarak değerlendirilebilmektedir.

3.3. Performans Metrikleri

Model sonuçlarının daha net anlaşılabilmesi için, bu bölümde performans metrikleri üzerinden karşılaştırmalar yapılmıştır. Daha önce ayrıntılı olarak açıklanan MAE, Kök RMSE ve R^2 metrikleri kullanılarak her bir modelin tahmin başarımı değerlendirilmiştir. Bu

metrikler, modellerin hata paylarını ve açıklayıcılık düzeylerini ortaya koyarak hangi algoritmanın daha güçlü bir performans sergilediğini belirlemeye imkân tanımaktadır.

Tablo 6. Makine öğrenmesi modellerinin performans karşılaştırması

Model	RMSE (kW)	MAE (kW)	R ²
RF	1,825	0,899	0,9987
LightGBM	1,850	0,960	0,9986
XGBoost	1,854	0,965	0,9986
KNN	6,917	3,866	0,9763

Tablo 6'ya bakıldığında uygulanan algoritma sonuçlarına göre, RF algoritması en düşük RMSE (1,825) ve MAE (0,899) değerlerine ulaşarak en başarılı model olarak öne çıkmıştır. Bu modeli sırasıyla LightGBM (RMSE: 1,850, MAE: 0,960) ve XGBoost (RMSE: 1,854, MAE: 0,965) algoritmaları takip etmiştir. Her üç model de oldukça yüksek R² değerleri (0,998) ile güçlü tahmin performansı sergilemiştir. Diğer taraftan, KNN algoritması diğer modellere kıyasla daha yüksek hata oranlarına sahip olup (RMSE: 6,917, MAE: 3,866) ve daha düşük bir R² değeri (0,9763) ile nispeten daha zayıf bir tahmin performansı göstermiştir.

Ayrıca, bu sonuçlar ağaç tabanlı algoritmaların (RF, XGBoost, LightGBM) rüzgâr enerjisi üretimi tahmininde daha isabetli ve güvenilir sonuçlar verdiğini ortaya koymaktadır.

Enerji üretimi tahmininde kullanılan modellerin doğruluğunu ve güvenilirliğini değerlendirmek için uygun performans metriklerinin seçimi kritik öneme sahiptir.

Çalışmada kullanılan MAE, RMSE ve R² gibi istatistiksel ölçütler, makine öğrenmesi modellerinin gerçek veriye ne kadar yakın tahminler yaptığını nesnel biçimde ortaya koymaktadır.

Bu metrikler, özellikle yenilenebilir enerji kaynaklarının değişkenliğe ve dış koşullara bağlı yapısı nedeniyle tahmin modelinin güvenilirliğini test etmekte yaygın olarak tercih edilmektedir (Hyndman & Koehler, 2006; Zhang ve ark., 2019). Dolayısıyla, bu metriklerin birlikte kullanımı modellerin hem doğruluğunu hem de genellenebilirliğini ortaya koymak açısından önemlidir.

4. SONUÇLAR VE ÖNERİLER

Rüzgâr enerjisi, fosil yakıt tüketiminin çevresel etkilerini azaltmak ve enerji arzını sürdürülebilir şekilde çeşitlendirmek açısından önemli bir yenilenebilir kaynak olarak değerlendirilmektedir (Hyndman & Athanasopoulos, 2018). Bu enerji türünün üretim kapasitesi doğrudan atmosferik koşullara bağlı olduğundan, meteorolojik değişkenlerin doğru şekilde modellenmesi ve öngörülmesi, enerji yönetimi açısından kritik bir öneme sahiptir.

Bu kapsamda gerçekleştirilen bu çalışmada, Türkiye'nin İzmir ili Çeşme ilçesinde faaliyette bulunan bir rüzgâr enerji santraline (RES) ait veriler kullanılmıştır. Toplam 49 türbinden seçilen 1, 9, 19, 39 ve 49 numaralı türbinlere ilişkin yaklaşık 330.000 satırlık yüksek çözünürlüklü ölçüm verisi analiz edilmiştir. Söz konusu veriler; 1 Ocak 2023 – 30 Haziran 2024 tarihleri arasında, her 10 dakikada bir kaydedilen rüzgâr hızı, rotor hızı, kanat açısı, sıcaklık, nacelle yönü ve enerji üretim miktarı değişkenlerini kapsamaktadır.

Çalışmanın başlangıcında, veri bütünlüğünü sağlamak amacıyla eksik ve uç değerler belirlenerek temizlenmiş; ardından, veri seti eğitim ve test alt kümelerine ayrılarak dört farklı makine öğrenmesi algoritması (LightGBM, RF, XGBoost, KNN) ile üretim tahminleri yapılmıştır. Çalışmanın temel amacı, bu algoritmaların performanslarını kıyaslayarak en yüksek doğruluğa sahip modelin tespit edilmesidir.

Çalışmada, LightGBM'in yaprak bazlı büyüme stratejisi ve histogram tabanlı ayırıklaştırma özelliği sayesinde, büyük veri setlerinde hızlı ve doğruluk seviyesi yüksek tahminler üretebildiği ortaya konmuştur. RF, topluluk öğrenmesi ve bagging yöntemine dayanan yapısıyla güçlü bir genelleme yeteneğine sahip olup aşırı öğrenmeye karşı dayanıklı bir yöntem olarak değerlendirilmiştir. XGBoost, geliştirilmiş düzenleme teknikleri ve esnek hiperparametre optimizasyonu sayesinde hesaplama verimliliği yüksek, güçlü bir tahmin modeli sunmuştur. KNN ise basit ve sezgisel yapısına rağmen, veri setinin boyutu ve değişkenler arasındaki karmaşık ilişkiler nedeniyle çalışmada beklenen başarıyı gösterememiş ve bu bağlamda daha çok temel bir karşılaştırma modeli olarak kullanılmıştır.

Tüm modeller, MAE, RMSE ve R^2 performans metrikleri üzerinden değerlendirilmiş; Bayeşçi optimizasyon yöntemine dayanan Optuna kütüphanesi kullanılarak hiperparametre ayarları iyileştirilmiştir. Bulgular, her bir algoritmanın veri özelliklerine bağlı olarak farklı avantajlar sunduğunu göstermektedir.

Çalışmada elde edilen tahmin performansları, literatürdeki benzer araştırmalarla karşılaştırıldığında uygulanan modellerin güvenilirliğini ve doğruluğunu ortaya koymaktadır. Örnek olarak;

Rajaperumal ve ark. (2025) tarafından yapılan çalışmada, 3,25 kW kapasiteli bir rüzgâr türbinine ait veriler kullanılarak makine öğrenmesi yöntemleriyle (Yapay Sinir Ağları, Regresyon Tabanlı Yöntemler) enerji üretimi tahmini yapılmıştır. Çalışmada elde edilen sonuçlara göre, RMSE = 3,25 kW, MAE = 2,45 kW ve $R^2 = 0,91$ olarak rapor edilmiştir. Bu değerler, küçük ölçekli türbinlerde tahmin performansının sınırlı kaldığını ve hata değerlerinin yüksek olduğunu göstermektedir. Bu tez kapsamında kullanılan modeller ise çok daha düşük hata değerleri ve yüksek R^2 sonuçları üretmiştir. Örneğin, RF modeli için RMSE = 1,825 kW, MAE = 0,899 kW ve $R^2 = 0,9987$ elde edilmiştir. Benzer şekilde, LightGBM (RMSE = 1,850 kW, MAE = 0,960 kW, $R^2 = 0,9986$) ve XGBoost (RMSE = 1,854 kW, MAE = 0,965 kW, $R^2 = 0,9986$) algoritmaları da daha yüksek doğruluk sağlamıştır.

Emeksiz ve Demir (2021) çalışmalarında, Tokat Gaziosmanpaşa Üniversitesi ölçüm istasyonundan elde edilen meteorolojik verileri kullanarak rüzgâr hızı tahmini gerçekleştirilmiş ve Basit Lineer, Çoklu Lineer ve Çoklu Non-lineer Regresyon tekniklerinin performanslarını karşılaştırmıştır. Çalışmada en düşük RMSE değeri 0,062–0,068 aralığında gözlenmiş ve Çoklu Non-lineer Regresyonun diğer yöntemlere kıyasla daha başarılı olduğu belirtilmiştir. Buna karşın bu çalışmada ise RF, LightGBM ve XGBoost modelleri için elde edilen R^2 değerleri 0,9986–0,9987 aralığında bulunmuş, KNN modeli ise yaklaşık 0,9763 seviyesinde kalmış, RMSE ve MAE değerleri de düşük seviyelerde gerçekleşmiştir. Karşılaştırıldığında, bu tez çalışmasında kullanılan büyük ve çok değişkenli veri seti ile ensemble tabanlı modellerin yüksek performansı, Emeksiz ve Demir'in tek istasyonlu ve sınırlı değişkenli veri setinde uygulanan regresyon modellerinin performansından daha iyi çıkmıştır. Dolayısıyla, veri hacmi ve model karmaşıklığı arttıkça tahmin doğruluğunun anlamlı şekilde yükseldiği görülmektedir.

Zhang, J., ve ark. (2019) tarafından yapılan çalışmada, olasılıklı rüzgâr gücü tahminine yönelik literatürde yer alan farklı yöntemlerin performansları değerlendirilmiş ve elde edilen R^2 değerlerinin genellikle 0,85–0,95 aralığında olduğu belirtilmiştir. Bu sonuçlar, kullanılan veri setlerinin çeşitliliği, farklı coğrafi koşullar ve olasılıklı tahmin yöntemlerinin doğasından kaynaklanan belirsizliklerle ilişkilidir. Bu çalışmada ise RF, LightGBM ve XGBoost modelleri için elde edilen R^2 değerleri 0,9986–0,9987 aralığında bulunmuş, KNN

modeli ise yaklaşık 0,9763 seviyesinde kalmıştır. Dolayısıyla bu çalışmada ulaşılan sonuçlar, Zhang ve arkadaşlarının çalışmasında raporlanan değerlerden daha yüksek olup, bu durumun veri setinin kapsamı, yüksek çözünürlüklü yapısı ve hiperparametre optimizasyonu ile ilişkilendirilmektedir.

Veri kalitesi açısından değerlendirme yapıldığında, yerinde ölçüm verileri MGM istasyon verilerine kıyasla özellikle rüzgâr hızı değişkeninde daha güvenilir olduğu görülmüştür. Nisan, Ağustos ve Aralık aylarına ait karşılaştırmalar; topoğrafya, yerel iklimsel özellikler ve türbin yükseklik farklılıklarının yerinde ölçümün önemini ortaya koyduğunu göstermektedir. Sıcaklık değişkeninde ise MGM ile RES verileri arasındaki fark sınırlı kalmış; bu parametre tamamlayıcı bir girdi olarak değerlendirilmiştir.

Bu çalışma bulgularına dayanarak, rüzgâr enerjisi üretim tahminlerinin geliştirilmesi için bazı öneriler sunulabilir. Daha uzun dönemli ve farklı lokasyonlardan elde edilecek veriler, modelin genellenebilirliğini artırabilir. Ek meteorolojik değişkenlerin dâhil edilmesi ve zaman serisi ya da derin öğrenme tabanlı hibrit yaklaşımların kullanılması, tahmin doğruluğunu yükseltebilir. Ayrıca, gerçek zamanlı veri akışıyla kısa vadeli uyarı sistemleri geliştirilebilir ve modellerin karar süreçleri yorumlanabilirlik teknikleriyle daha şeffaf hale getirilebilir. Elde edilen modeller, yeni santral planlamalarında referans oluşturabileceği gibi, uzun vadeli enerji politikalarına da katkı sağlayabilir.

5. KAYNAKLAR

- Ackermann, T., & Söder, L. (2002). An overview of wind energy status 2002. *Renewable and Sustainable Energy Reviews*, 6(1–2), 67–127.
- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A Next-generation Hyperparameter Optimization Framework. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2623–2631. Anchorage, Alaska, ABD.
- Aktar, Ç. (2018). *Manisa Soma Bölgesi İçin Meso Ölçek Sayısal Hava Tahmin Modeli (Wrf) Sonuçları İle Hesaplamalı Akışkanlar Dinamiği Modelleri (Meteodyn ve WindSim) Kullanılarak Kısa Vadeli Rüzgâr Enerjisi Tahmini*. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- AlShafeey, M., & Csaki, C. (2024). Adaptive machine learning for forecasting in wind energy: A dynamic, multi-algorithmic approach for short and long-term predictions. *Heliyon*, 10(15):34807.
- Betz, A. (1926). *Wind-Energy and its Extraction by Windmills*. Göttingen, Almanya.
- Bergstra, J., & Bengio, Y. (2011). Random search for hyper-parameter optimization. In *Advances in Neural Information Processing Systems*, 24, 281–289.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32.
- Burton, T., Jenkins, N., Sharpe, D., & Bossanyi, E. (2011). *Wind Energy Handbook* (2nd ed.). Wiley.
- Chauhan, S., & Singh, R. (2014). A review on integrated renewable energy system based power generation for stand-alone applications: Configurations, storage options, sizing methodologies and control. *Renewable and Sustainable Energy Reviews*, 38, 99–120.
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794.
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27.
- Ding, J. W., Chuang, M. J., Tseng, J. S., & Hsieh, I. Y. L. (2024). Reanalysis and ground station data: Advanced data preprocessing in deep learning for wind power prediction. *Applied Energy*, 375, 124129.
- Efe, B. (2012). *Manisa Soma Bölgesi İçin Meso Ölçek Sayısal Hava Tahmin Modeli (Wrf) ve Hesaplamalı Akışkanlar Dinamiği Modeli (WindSim) Kullanılarak Kısa Vadeli*

Rüzgâr Enerjisi Tahmini. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul

Ekmekçi, İ., Şen, Y., Onat, A., & Ulaş, M. (2011). Enerji Üretim Amaçlı Rüzgâr Ölçümü ve Analizi. *Rüzgâr Enerjisi ve Rüzgâr Türbinleri Yerel Sempozyumu*. Balıkesir.

Emeksiz, C., & Demir, İ. (2021). Farklı Regresyon Teknikleri Kullanarak Rüzgâr Hızına Etkiyen Meteorolojik Parametrelerin İncelenmesi. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 100–110.

ETKB (2022). *World Bank, 2024*. Ankara: Enerji ve Tabii Kaynaklar Bakanlığı.

ETKB (2024). *Rüzgâr enerjisi potansiyeli*. Ankara: Enerji ve Tabii Kaynaklar Bakanlığı.

ETKB (2025). *Türkiye Ulusal Enerji Planı (2023–2035)*. Ankara: Enerji ve Tabii Kaynaklar Bakanlığı.

Guyon, I., & Elisseeff, A. (2003). An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research*, 3, 1157–1182.

Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Multivariate Data Analysis* (7th ed.). Pearson Prentice Hall.

Hau, E. (2013). *Wind Turbines: Fundamentals, Technologies, Application, Economics* (3rd ed.). Springer.

Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688.

Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2nd ed.). OTexts.

IRENA (2025) International Renewable Energy Agency 2024, *Renewable Capacity Statistics*.

Işık, C. M., Kaya, O., Türk, V., & Aydemir, F. (2021). Model Rüzgâr Türbini Projesi. Bitirme Tezi, Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Trabzon.

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning: with Applications in R*. Springer.

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). *LightGBM: A highly efficient gradient boosting decision tree*. In Proceedings of the 31st International Conference on Neural Information Processing Systems (3149–3157). Long Beach, CA, ABD.

Kiriş, Z. N., Beyca, Ö. F., & Kosanoğlu, F. (2022). Tekrarlayan Sinir Ağları Temelli Rüzgâr Hızı Tahmin Modelleri: Yalova Bölgesinde Bir Uygulama. *International Journal of Energy Applications and Technologies*, 178–188.

- Lee, J. C., Draxl, C., & Berg, L. K. (2022). Evaluating Wind Speed and Power Forecasts for Wind Energy Applications Using an Open-Source and Systematic Validation Framework. *Renewable Energy*, 457–475.
- Ma, Y. J., & Zhai, M. Y. (2019). A Dual-Step Integrated Machine Learning Model For 24h-Ahead Wind Energy Generation Prediction Based On Actual Measurement Data And Environmental Factors. *Applied Sciences*, 21–25.
- Mahata, S., Harsh, P., & Shekher, V. (2024). Comparative study of time-series forecasting models for wind power generation in Gujarat, India. *e-Prime-Advances in Electrical Engineering, Electronics and Energy*, 8, 100511.
- Manwell, J. F., McGowan, J. G., & Rogers, A. L. (2009). *Wind Energy Explained: Theory, Design and Application* (2nd ed.). John Wiley & Sons.
- Muhammad, U. K., Umar, S., Musa, M., & Garba, M. M. (2014). Effect of Wind Speed Variation on Wind Turbine Performance. *International Journal of Engineering Research and Applications*, 4(1), 11–15.
- Oral, F., Behçet, R., & Gönel, E. (2019). Sakarya-Esentepe Bölgesi İçin Rüzgâr Enerjisi Potansiyel Analizi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 362–371.
- Qureshi, R., Arif, S. M., & Mehreen, A. (2020). Wind energy forecasting using machine learning: State-of-the-art, challenges and solutions. *Energies*, 13(11), 2923.
- Rajaperumal, A., Chinnappan, S., & Kumar, P. (2025). Probabilistic forecasting of wind power generation: A review. *Journal of Renewable Energy Studies*, 18(5), 1125–1140.
- Sarıkaya, M. (2022). *Deep learning approaches for multi-site wind power forecasting in the West Aegean region of Turkey*. Boğaziçi University, Institute for Graduate Studies in Science and Engineering, M.S. Thesis, İstanbul.
- Sathyajith, M. (2006). *Wind Energy: Fundamentals, Resource Analysis and Economics*. Springer.
- Sæther, B. B. (2021). *Wind Power Prediction With Machine Learning Methods In Complex Terrain Areas*. UiT The Arctic University of Norway, Master's Thesis, Tromsø, Norveç.
- Şenol, Ü. (2017). *Yapay Sinir Ağları İle Rüzgâr Enerjisi Potansiyelinin Tahmini*. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical Bayesian Optimization of Machine Learning Algorithms. *Advances in Neural Information Processing Systems (NeurIPS)*, 25.

- Sulaiman, M. H., Mustaffa, Z., Saari, M. M., & Abas, M. F. (2024). Wind Power Forecasting with Metaheuristic-Based Feature Selection and Neural Networks. *Cleaner Energy Systems*, 9(12), 100149.
- Temiz, F. (2010). *Rüzgâr Enerji Sistemlerinde Optimizasyon*. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Tubulekas, A. (2022). *Exploring Machine Learning Techniques for Short-Term Wind Power Forecasting of Multiple Wind Parks*, Institutionen for informationsteknologi, Uppsala Universitet, Master's Thesis, Uppsala, İsveç.
- URL-1. (2024, Temmuz 16). https://fbe.bingol.edu.tr/programlar_/yenilenebilir-enerji-sistemleri adresinden alınmıştır.
- URL-2. (2024, Aralık 21). https://www.megep.meb.gov.tr/mte_program_modul-moduller_pdf adresinden alınmıştır.
- URL-3. (2025, Ocak 4). <https://en.wind-turbine-models.com/turbines/529-enercon-e-48> adresinden alınmıştır.
- URL-4. (2025, Mart 16). <https://interactivechaos.com/en/wiki/random-forest> adresinden alınmıştır.
- URL-5. (2025, Nisan 16). LightGBM Documentation Features. <https://lightgbm.readthedocs.io/en/latest/Features.html> adresinden alınmıştır.
- URL-6. (2025, Haziran 5). GWEC- Global Wind Report 2024. <https://gwec.net/global-wind-report-2024/> adresinden alınmıştır.
- URL-7. (2025, Haziran 5). <https://www.iklimhaber.org/turkiyede-2024te-uretilen-elektrigin-34u-ruzgar-enerjisinden-saglandi> adresinden alınmıştır.
- URL-8. (2025, Temmuz 5). Density of air: https://en.wikipedia.org/wiki/Density_of_air adresinden alınmıştır.
- URL-9. (2025, Temmuz 10). Türkiye Rüzgâr Enerjisi 2024 Raporu: <https://www.yesilhaber.com/turkiye-ruzgar-raporu-2024> adresinden alınmıştır.
- Wang, J., Wang, Y., Li, X., & Zhang, H. (2020). Machine learning-based wind power forecasting: A review. *Energy*, 208, 118118. <https://doi.org/10.1016/j.energy.2020.118118>
- Wang, S., Li, B., Li, G., & Wu, J. (2021). Short-term wind power prediction based on multidimensional data cleaning and feature reconfiguration. *Applied Energy*, 292.
- Wu, B., Yu, S., Peng, L., & Wang, L. (2024). Interpretable wind speed forecasting with meteorological feature exploring and two-stage decomposition. *Energy*, 130782, 294.

- Yakşı, B. (2018). *Türkiye ve Dünya’da Rüzgâr Enerjisi Potansiyel Analizi*. Bursa Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Bursa.
- Yenilmez, D., & Barut, Ö. N. E. R. (2023). Short-Term Wind Energy Forecasting with Machine Learning Techniques. *9th International Congress on Engineering and Technology Management*, İstanbul.
- Zhang, J., Wang, J., & Wang, X. (2019). Review on probabilistic forecasting of wind power generation. *Renewable and Sustainable Energy Reviews*, 32, 255–270.



ÖZGEÇMİŞ

İlkokul ve ortaokul öğreniminden sonra lise öğrenimini Affan Kitapçıoğlu Lisesinde 1995 yılında tamamladı. 1995-1996 Eğitim-Öğretim yılında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde lisans eğitime başladı. 1999 yılında Elektronik Mühendisliği bölümünden mezun oldu. 2022 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim dalında tezli yüksek lisans programına başladı. 2025 yılı Eylül ayında “Meteorolojik Faktörlerin Rüzgâr Enerji Santrallerine Etkisi” başlıklı yüksek lisans tez savunmasını yaptı. İyi derecede İngilizce bilmektedir.

Şimşek, H., & Hasırcı Tuğcu, Z. (2025, June 24–26). The Performance Analysis of KNN and XGboost Models in Wind Energy Forecasting: A Bayesian Optimization Based Approach. In *Proceedings of the 7th International Black Sea Modern Scientific Research Congress* (pp. 584–593). Artvin, Turkey.