

T.C.
BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENME VE DERİN ÖĞRENME İLE
RÜZGÂR HIZININ
TAHMİNİ

Adem DEMİRTOP

Danışman: Prof. Dr. Emre ÇOMAK

BURDUR, 2024

ETİK KURALLARA UYGUNLUK BEYANI

Burdur Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin ilgili hükümleri uyarınca Yüksek Lisans Tezi olarak sunduğum “**Makine Öğrenme ve Derin Öğrenme ile Rüzgâr Hızının Tahmini**” başlıklı bu tezin;

- Kendi çalışmam olduğunu,
- Sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi,
- Bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi,
- Kullandığım verilerde değişiklik yapmadığımı,
- Tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını,
- Bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı,
- Bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı,

bildirir, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

26/06 /2024

Adem DEMİRTOP

ÖNSÖZ

Bu araştırma için beni yönlendiren, karşılaştığım zorlukları bilgi ve tecrübesi ile aşmamda yardımcı olan değerli Danışman Hocam **Prof. Dr. Emre ÇOMAK**'a teşekkürlerimi sunarım.

Yüksek Lisans eğitimimde değerli katkılarıyla ve sonrasında bilgi ve tecrübesi ile bana her zaman yardımcı olan değerli hocam **Prof. Dr. Ali Hakan IŞIK**'a teşekkürlerimi sunarım. Tez savunmasında bulunan ve tezin içerikleri ile ilgili değerli katkıları bulunan değerli hocalarım **Doç. Dr. Onur SEVLİ** ve **Dr. Öğr. Üyesi Gül Fatma TÜRKER**'e teşekkürlerimi sunarım. Tezi hazırlama, düzenleme, kontrol etme gibi yardımlarını esirgemeyen değerli hocam **Mustafa İNAN**'a teşekkürlerimi sunarım.

Eğitim hayatımın her aşamasında beni her anlamda destekleyen **annem, babam ve kardeşlerime** sonsuz sevgi ve saygılarımı sunarım.

Haziran, 2024

Adem DEMİRTOP

İÇİNDEKİLER

Sayfa

ÖNSÖZ	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iv
ÇİZELGELER DİZİNİ	vi
SİMGELER VE KISALTMALAR DİZİNİ.....	vii
ÖZET	ix
ABSTRACT.....	x
1. GİRİŞ	1
2. GENEL BİLGİLER	4
2.1. Yenilenebilir Enerjinin Makine Öğrenimi Tabanlı Tahmini.....	4
2.1.1. Denetimli Öğrenme.....	4
2.1.1.1. Karar Ağaçları	4
2.1.1.2. Destek Vektör Makineleri.....	5
2.1.1.3. Yapay Sinir Ağları.....	7
2.1.1.4. Lojistik Regresyon.....	9
2.1.2. Denetimsiz Öğrenme.....	9
2.1.2.1. Kümeleme.....	9
2.1.3. Yarı Denetimli Öğrenme.....	10
2.1.3.1. Çoklu Öğrenme.....	10
2.1.3.2. Yarı-Denetimli Öğrenme	12
2.1.4. Derin Öğrenme.....	13
2.1.4.1. Evrişimli Sinir Ağları	13
2.1.4.2. Tekrarlayan Sinir Ağları	14
2.2. Türkiye’deki Rüzgâr Enerjisi Potansiyeli	20
2.2.1. Türkiye’deki Genel Durum ve Bölgesel Analizler	22
2.2.2. Çanakkale İli ve Rüzgâr Enerjisi.....	29
2.2.3. Bozcaada, Ezine, Ayvacık ve Gökçeada’da Rüzgâr Enerjisi.....	30
2.2.4. Yıllık Ortalama Rüzgâr Hızı Dağılımı	31
2.3. Kaynak Özetleri.....	34
3. MATERYAL VE YÖNTEM	39
3.1. Veri Seti Tanımı	39
3.2. Python Programlama Dili	43
3.3. Modelin Tanımı	44
3.3.1. Uzun Kısa Süreli Bellek.....	45
3.3.2. Aşırı Gradyan Artırma	47
3.3.3. K-en Yakın Komşuluk	49
3.3.4. Karar Ağacı	51
3.3.5. Destek Vektör Regresyon	53
3.3.6. Geçitli Tekrarlayan Birim	54
3.3.7. Yapay Sinir Ağları	56
3.3.8. Evrişimli Sinir Ağları.....	58
3.4. Kullanılan Teknolojilere Göre Sistem Mimarileri	60
3.5. Performans Değerlendirmesi	64
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	66
4.1. Uzun Kısa Süreli Bellek Analizi	66
4.2. Aşırı Gradyan Artırma Analizi.....	68
4.3. K-en Yakın Komşuluk Analizi.....	70

4.4.	Karar Ağacı Analizi.....	72
4.5.	Destek Vektör Regresyon Analizi.....	74
4.6.	Geçitli Tekrarlayan Birim Analizi.....	76
4.7.	Yapay Sinir Ağları Analizi.....	78
4.8.	Evrişimli Sinir Ağları Analizi	80
5.	SONUÇ VE ÖNERİLER.....	83
	KAYNAKLAR	88



ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. Karar Ağacı.....	5
Şekil 2.2. Destek Vektör Makineleri.....	7
Şekil 2.3. Yapay Sinir Ağları.....	8
Şekil 2.4. Çoklu Öğrenme.....	11
Şekil 2.5. Evrişimli Sinir Ağları	14
Şekil 2.6. Tekrarlayan Sinir Ağları	15
Şekil 2.7. Makine Öğrenme Türleri	17
Şekil 2.8. Küresel enerji sisteminde dönüşümler (IEA, 2024)	21
Şekil 2.9. Türkiye’deki rüzgâr enerjisinin yıllara göre toplam kurulu güç içerisindeki oran (ETKB, 2024).....	23
Şekil 2.10. Türkiye’deki rüzgâr enerjisine dayalı yıllara göre kurulu güç (ETKB, 2024)	24
Şekil 2.11. Türkiye’de 2000’den itibaren yenilenebilir elektrik üretiminin kaynağa göre gelişimi (IEA, 2024).....	25
Şekil 2.12. Türkiye’de 2000’den itibaren toplam nihai tüketimin gelişimi (IEA, 2024)	25
Şekil 2.13. Türkiye toplam elektrik tüketim dağılımı (IEA, 2024)	26
Şekil 2.14. Türkiye’deki toplam enerji arzının gelişimi (IEA, 2024).....	27
Şekil 2.15. Türkiye’de 2000’den bu yana toplam enerji arzının değişimi (IEA, 2024)	27
Şekil 2.16. Türkiye’de yurtiçi enerji üretiminin gelişimi (IEA, 2024)	28
Şekil 2.17. Türkiye’deki yurtiçi enerji üretimi 2022 yılı (IEA, 2024).....	29
Şekil 2.18. Çanakkale yıllık ortalama rüzgâr hız dağılımı (ETKB, 2024)	30
Şekil 2.19. Türkiye yıllık ortalama rüzgâr hız dağılımı (ETKB, 2024).....	32
Şekil 2.20. Marmara bölgesine ait yıllık ortalama rüzgâr hız dağılımı (ETKB, 2024)	33
Şekil 2.21. Çanakkale iline ait yıllık ortalama rüzgâr hız dağılımı (ETKB, 2024)	34
Şekil 3.1. Ayvacık ilçesine ait normalize edilmiş meteorolojik verilerin zamana göre değişim grafiği	41
Şekil 3.2. Bozcaada ilçesine ait normalize edilmiş meteorolojik verilerin zamana göre değişim	41
Şekil 3.3. Ezine ilçesine ait normalize edilmiş meteorolojik verilerin zamana göre değişim	42

Şekil 3.4. Gökçeada ilçesine ait normalize edilmiş meteorolojik verilerin zamana göre değişim	42
Şekil 3.5. LSTM, XGBoost, KNN, Decision Tree, SVR, GRU, YSA ve CNN ait iş akış şeması.....	45
Şekil 4.1. LSTM modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri	67
Şekil 4.2. XGBoost modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri	69
Şekil 4.3. KNN modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri	71
Şekil 4.4. Karar Ağacı modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri.....	73
Şekil 4.5. SVR modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri	75
Şekil 4.6. GRU modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri	77
Şekil 4.7. YSA modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikler	79
Şekil 4.8. CNN modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri	81

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1. Makine öğrenme türlerinin avantajları ve dezavantajları	18
Çizelge 3.1. Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerine ait günlük ortalama değerler.....	40
Çizelge 3.2. LSTM modeline ait algoritma adımları	46
Çizelge 3.3. XGBoost modeline ait algoritma adımları.....	48
Çizelge 3.4. KNN modeline ait algoritma adımları	50
Çizelge 3.5. Karar Ağacı modeline ait algoritma adımları	52
Çizelge 3.6. SVR modeline ait algoritma adımları	54
Çizelge 3.7. GRU modeline ait algoritma adımları	55
Çizelge 3.8. YSA modeline ait algoritma adımları.....	57
Çizelge 3.9. CNN modeline ait algoritma adımları	59
Çizelge 3.10. Kullanılan teknolojilere göre model yapısı.....	63
Çizelge 4.1. LSTM modeline ait performans değerleri	67
Çizelge 4.2. XGBoost modeline ait performans değerleri.....	69
Çizelge 4.3. KNN modeline ait performans değerleri	71
Çizelge 4.4. Karar Ağacı modeline ait performans değerleri	73
Çizelge 4.5. SVR modeline ait performans değerleri	75
Çizelge 4.6. GRU modeline ait performans değerleri.....	77
Çizelge 4.7. YSA modeline ait performans değerleri.....	79
Çizelge 4.8. CNN modeline ait performans değerleri.....	81
Çizelge 5.1 Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerindeki veriler için LSTM, XGBoost, KNN, Karar Ağacı, SVR, GRU, YSA ve CNN algoritmalarının sonuçları	84
Çizelge 5.2. Performans değerlerine göre ML ve DL avantaj ve dezavantaj sonuçları..	86

SİMGELER VE KISALTMALAR DİZİNİ

AHS	: Analitik Hiyerarşi Süreci
ANN	: Artificial Neural Network
ARIMA	: Autoregressive İntegrated Moving Average
CART	: Classification and Regression Tree
CNN	: Convolutional Neural Network
DCN	: Deep Convolutional Network
DL	: Deep Learning
DMİ	: Devlet Meteoroloji İşleri Genel Müdürlüğü
DVM	: Döngüsel Varyans Metot
ETKB	: Enerji ve Tabii Kaynaklar Bakanlığı
GBT	: Gradient Boosting Tree
GRU	: Gated Recurrent Unit
HM	: Hibrit Modeller
ID3	: Iterative Dichotomiser 3
IEA	: International Energy Agency
KNN	: K-Nearest Neighbors
KVA	: Keşifsel Veri Analizi
LDA	: Doğrusal Diskriminant Analizi
LSTM	: Long Short Term Memory
MAE	: Mean Absolute Error
MAPE	: Mean Absolute Percentage Error
ML	: Machine Learning
MLP	: Multi-Layer Perceptro
MSE	: Mean Squared Error
PCA	: Principal Component Analysis
ReLU	: Rectified Linear Unit
RF	: Random Forest
RMSE	: Root Mean Square Error
SVM	: Support Vector Machine
SVR	: Support Vector Regression
t-SNE	: t-Distributed Stochastic Neighbor Embedding
XGBoost	: eXtreme Gradient Boosting

YEK	: Yenilenebilir Enerji Kaynakları
YSA	: Yapay Sinir Ağları
TJ	: Terajoule
Φ	: Aktivasyon Fonksiyonu
m/s	: metre/saniye



ÖZET

Yüksek Lisans Tezi

Makine Öğrenme ve Derin Öğrenme ile Rüzgâr Hızının Tahmini

Adem Demirtop

Burdur Mehmet Akif Ersoy Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Emre ÇOMAK

Haziran, 2024

Günümüzde, enerji sektörü, teknolojik ilerlemelerin hız kazanması ve çevresel etkenlerin etkisiyle önemli değişimlere maruz kalmaktadır. Bu değişim sürecinde, yenilenebilir enerji kaynakları, özellikle rüzgâr enerjisi, giderek artan bir öneme sahiptir. Rüzgâr enerjisi, sürdürülebilir enerji portföylerinde kilit bir rol oynamakta olup, rüzgâr hızı tahmini, rüzgâr enerjisi santrallerinin performansını artırmak ve enerji üretim süreçlerini optimize etmek için kritik bir unsurdur. Bu araştırma, rüzgâr enerjisi potansiyelinin en etkili şekilde değerlendirilmesi amacıyla Çanakkale ili Bozcaada, Gökçeada, Ezine ve Ayvacık ilçelerindeki rüzgâr hızı tahminine odaklanmıştır. Rüzgâr hızının doğru tahmin edilmesi, rüzgâr enerjisi santrallerinin verimliliğini artırarak enerji üretimindeki dalgalanmaları minimize etme potansiyeline sahiptir. Bu çalışma, rüzgâr hızı tahminini iyileştirmek için farklı makine öğrenmesi ve derin öğrenme algoritmalarının performansını incelemektedir. Uygulanan algoritmalar arasında Uzun Kısa Süreli Bellek (LSTM), Aşırı Dereceli Artırma (XGBoost), k-En Yakın Komşu, Yapay Sinir Ağları ve Evrişimli Sinir Ağları gibi önemli modeller bulunmaktadır. Sonuçlar, rüzgâr hızı tahmininde LSTM ve XGBoost değerlerinin genellikle yüksek bir doğruluk sağladığını ve diğer modellere göre daha başarılı olduğunu göstermektedir. XGBoost modeli, Ayvacık ilçesinde 0,9438 R-kare değeriyle en yüksek doğruluğu sağlarken, Bozcaada ve Ezine’de de benzer şekilde yüksek R-kare ve düşük hata metrikleriyle dikkat çekmiştir. Öte yandan, Gökçeada ilçesinde LSTM modeli 0,964 R-kare değeriyle diğer modellere göre yüksek doğruluk sağlamış, ancak MAPE gibi bazı hata metriklerinde dezavantaj göstermiştir. Bu bulgular, genellikle LSTM modelinin rüzgâr hızı tahmininde yüksek doğruluğa sahip olduğunu ve bazı durumlarda diğer modellerin de uygun olduğunu göstermektedir. Bu bulgular, tahmin modellerinin veri kalitesinin iyileştirilmesi ve farklı algoritmaların kullanılmasıyla doğruluğunun artırılabilirliğini vurgulamaktadır. Gelecekteki araştırmaların, rüzgâr enerjisi sektöründe tahmin modellerinin daha da geliştirilmesi ve operasyonel verimliliğin artırılması üzerine odaklanması gerektiği sonucuna varılmıştır.

Anahtar Kelimeler: rüzgâr hızı, rüzgâr enerjisi, makine öğrenme, derin öğrenme,

ABSTRACT

M.Sc. Thesis

Prediction of Wind Speed Using Machine Learning and Deep Learning

Adem Demirtop

**Burdur Mehmet Akif Ersoy University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering**

Supervisor: Prof. Dr. Emre omak

June, 2024

In today's world, the energy sector is undergoing significant changes due to the acceleration of technological advancements and the impact of environmental factors. In this process of transformation, renewable energy sources, particularly wind energy, are becoming increasingly important. Wind energy plays a crucial role in sustainable energy portfolios, and wind speed forecasting is a critical factor in improving the performance of wind energy farms and optimizing energy production processes. This research focuses on wind speed prediction in the provinces of Bozcaada, Gökçeada, Ezine, and Ayvacık in Çanakkale province, aiming to effectively assess the wind energy potential. Accurate prediction of wind speed has the potential to increase the efficiency of wind energy farms, minimizing fluctuations in energy production. This study examines the performance of various machine learning and deep learning algorithms to enhance wind speed prediction. Among the applied algorithms are Long Short-Term Memory (LSTM), Extreme Gradient Boosting (XGBoost), k-Nearest Neighbors, Advanced Artificial Neural Networks, and Convolutional Neural Networks. The results generally indicate that LSTM and XGBoost models achieve high accuracy in wind speed prediction compared to other models. Specifically, the XGBoost model demonstrates the highest accuracy with an R-squared value of 0,9438 in Ayvacık, while showing similar high R-squared and low error metrics in Bozcada and Ezine. Conversely, the LSTM model achieves high accuracy with an R-squared value of 0,964 in Gökçeada, although it exhibits disadvantages in certain error metrics like MAPE. These findings suggest that LSTM generally provides high accuracy in wind speed prediction, with other models also proving suitable in specific scenarios. The study emphasizes the potential to improve prediction model accuracy through enhanced data quality and the use of different algorithms. Future research should focus on further enhancing prediction models and improving operational efficiency in the wind energy sector.

Keywords: Wind Speed, Wind Energy, Machine Learning, Deep Learning,

1. GİRİŞ

Günümüzde hızla dönüşen ve yeniliklere açık bir endüstri olan enerji sektörü, teknolojik gelişmelerin ivme kazanması ve çevresel faktörlerin etkisiyle önemli değişimler yaşamaktadır (Grubler vd., 1999; Gielen vd., 2019). Sera gazı emisyonlarının azaltılması ve iklim değişikliğinin yavaşlatılması çabalarında, yenilenebilir enerji büyük bir öneme sahiptir. Bu değişimlerin en önemli yönlerinden biri, yenilenebilir enerji kaynaklarının (YEK) giderek artan önemi ve kullanım alanının genişlemesidir (Kiliç, 2009; Quaschnig, 2019).

Paris İklim Anlaşması çerçevesinde alınan kararlarla küresel ısınmayı 1,5 derece ile sınırlama hedefi enerji sektöründe önemli bir rol oynarken, YEK enerji dışı bağımlılığının azaltılması, istihdam yaratılması ve maliyet tasarrufu gibi çeşitli avantajlar sunmaktadır (Öztürk ve Öztürk, 2019). Bu durumu destekleyen Birleşmiş Milletler Genel Sekreteri Antonio Guterres, şu ifadelerle konuyu özetlemiştir: "Geleneksel fosil yakıtlara olan bağımlılığın azaltılması, ekonomileri karbon yoğunluğundan kurtarma fırsatı sunuyor. Yenilenebilir enerjiyi hızlandırmak, Paris Anlaşması'na olan bağlılığımızı ve 2050 net sıfır hedeflerimize ulaşma taahhüdümüzü güçlendiriyor." (Rogelj vd., 2021; Rogelj vd., 2016).

Fosil yakıtlara olan bağımlılığın azaltılması, YEK daha yaygın kullanımını teşvik eder (Bayraç ve Çildir, 2017). YEK, enerji arz güvenliğini artırır ve küresel iklim değişikliğiyle mücadelede önemli bir rol oynar. Ancak, yenilenebilir enerjinin değişkenliği ve veri eksikliği gibi zorluklar, entegrasyonunu ve benimsenmesini kısıtlar. Bu zorlukların üstesinden gelmek için doğru tahmin modelleri ve teknolojik iyileştirmeler gerekmektedir (Ellabban vd., 2014; Androniceanu ve Sabie, 2022).

Gelişen yapay zekâ teknikleri, özellikle makine öğrenimi (ML) ve derin öğrenme (DL) gibi, yenilenebilir enerji alanında önemli bir etki yaratmıştır (Benti vd., 2023; Grönquist vd., 2021). Bu teknikler, büyük miktarda veri analizi yapma yetenekleri ve karmaşık ilişkileri anlama kapasiteleri sayesinde, yenilenebilir enerji üretiminin tahmin edilmesinde kritik bir rol oynamaktadır (Öztürk ve Bilgiç, 2022).

Enerji sektöründeki dönüşüm sürecine büyük katkı sağlayan yenilenebilir enerji alanındaki gelişmeler ve teknolojik ilerlemeler (Dincer, 2020), yıllardır geleneksel tahmin modelleri olan istatistiksel ve fiziksel modellerin kullanılarak enerji üretiminin tahmin edilmesine önemli bir destek sağlamaktadır (Sweeney vd., 2020; Chen vd., 2022).

Enerji üretimi için kullanılan geleneksel tahmin modelleri, karmaşıklığı ve doğrusal olmayan ilişkileri ele almakta sınırlıdır (Zhang vd., 2014). Sayısal hava tahmini ve güneş radyasyonu modelleri gibi fiziksel modeller, sıkça kullanılırken, doğrulukları atmosferin karmaşıklığından ve hava tahminindeki belirsizliklerden etkilenmektedir (Karadavut, 2014; Gabralı ve Aslan, 2020; Grönquist vd., 2021). Bu sınırlamaları aşmak için ML ve DL algoritmaları kullanılmaktadır (Goar ve Yaday, 2024; Yılmaz, 2024; Hatipoğlu vd., 2024). ML ve DL algoritmaları, karmaşık doğrusal olmayan ilişkileri öğrenebilir ve yenilenebilir enerji verilerinin yüksek boyutlu doğasını ele almak için uygun hale gelirler. Bu algoritmalar aynı zamanda zaman serisi, meteorolojik ve coğrafi veriler gibi farklı girdi türlerini işleyebilirler.

Güneş enerjisi sistemlerinin performansını etkileyen güneş radyasyonunu tahmin etmek için ML ve DL algoritmaları üzerine yapılan çalışmalar önemlidir (Demirgül vd., 2024). Voyant vd., destek vektör regresyonu (SVR), destek vektör makineleri (SVM), otoregresif entegre hareketli ortalama (ARIMA) ve yapay sinir ağları (ANN) gibi modellerin kullanılmasının tahmin performansını artırabileceğini öne sürmüştür (Voyant, vd., 2017; Cervantes vd., 2020). Huertas vd., SVM'li hibrit modellerin (HM'ler) güneş radyasyonu tahminlerini geliştirebileceğini göstermiştir (Huertas-Tato vd., 2020). Alizamir vd., gradyan artırma ağaçları (GBT) modelinin diğerlerine göre daha yüksek doğruluk sağladığını bulmuşlardır (Alizamir vd., 2020). Kumar Srivastava vd., rastgele orman (RF) algoritmasının en iyi performansı sergilediğini belirtirken (Srivastava vd., 2020), Ağbulut vd., yapay sinir ağlarının (YSA) en doğru tahminleri sağladığını göstermiştir (Ağbulut vd., 2020).

Rüzgâr enerjisinin tahmini, doğrusal olmayan ve rastlantısal nitelikteki zorluklar nedeniyle tutarsız güç üretimine yol açar (Lipu vd., 2021). Bu nedenle, etkili bir rüzgâr enerjisi tahmini modeline olan ihtiyaç giderek artmaktadır. Araştırmacılar, artan küresel nüfus ve enerji talebi göz önüne alındığında, rüzgâr enerjisinin fosil yakıtlara alternatif bir çözüm olarak görülmesini vurgulamaktadır (Güneş, 2009). ML ve DL modelleri, rüzgâr hızı verileri ve ilgili bilgilerin kullanılmasında önemli bir rol oynamaktadır. Zendejboudi vd., rüzgâr hızı tahmini için döngüsel varyans metodunun (DVM) diğer modellere göre üstün olduğunu belirtmişlerdir (Zendejboudi vd., 2018). Benzer şekilde, Wang vd., kısa vadeli tahminler için hibrit modellerin kullanılmasını önermişlerdir (Wang, 2015). ML ve DL, yenilenebilir enerji tahmini alanında önemli gelişmeler sağlamakla birlikte, ML ve DL algoritmalarının seçimi, girdi verilerinin seçimi ve eksik verilerin ele alınması gibi bazı temel sorunlar halen çözüm beklemektedir.

Bu çalışma, Çanakkale ili Bozcada, Gökçeada, Ezine ve Ayvacık ilçelerindeki rüzgâr hızı, nem, sıcaklık, basınç gibi parametrelerin 2014-2021 yılları arasındaki ortalamalarını kullanarak farklı makine öğrenme algoritmalarıyla yapılan performans ölçümlerini ele almaktadır. Bu algoritmalar arasında Uzun Kısa Süreli Bellek (LSTM), Aşırı Dereceli Artırma (XGBoost), k-En Yakın Komşu (KNN), Gelişmiş Tek Yapay Sinir Ağları (YSA) ve Evrişimli Sinir Ağları (CNN) bulunmaktadır. Çalışmanın temel amacı, mevcut literatüre katkı sağlamanın yanı sıra, bölgesel rüzgâr hızı tahminlerine yönelik gelecek projelere ve yatırımlara katkıda bulunmaktır. Ayrıca, deniz üstü ve kara üstü projelere katkı sağlamayı, çiftlik evlerine kurulacak YEK hangisinin daha verimli olacağına dair bilgi sunmayı, gelecek nesil yenilenebilir enerji ihtiyaçlarını göz önünde bulundurmaya amaçlamaktadır. Bu çalışma, gelecekteki yenilenebilir enerji alanındaki özellikle rüzgâr enerjisine yönelik yatırım ve projelerin stratejik planlamasına ışık tutacak önemli bilgiler sağlamayı hedeflemektedir.

2. GENEL BİLGİLER

2.1. Yenilenebilir Enerjinin Makine Öğrenimi Tabanlı Tahmini

Bu bölümde, yenilenebilir enerji tahmini için kullanılan çeşitli ML ve DL teknikleri ele alınmaktadır. ML ve DL tabanlı tahmin, büyük ve karmaşık veri kümelerini işleme yeteneği nedeniyle yenilenebilir enerji çıktısını tahmin etmek için giderek daha popüler bir yaklaşım haline gelmiştir (Tarek vd., 2023; Atalay ve Çelik, 2017). İncelemede, ML algoritmalarının dört ana kategorisi olan denetimli, denetimsiz, yarı denetimli ve DL detaylı bir şekilde tartışılmakta ve bu kategorilerin çeşitli alt dalları üzerinde durulmaktadır (Alloghani vd., 2020). Ayrıca, DL teknikleri ve yenilenebilir enerji tahminindeki uygulamaları da detaylı bir şekilde incelenmektedir. Bu bölümde, her bir algoritmanın avantajları, sınırlamaları ve yenilenebilir enerji tahminindeki uygulamaları ayrıntılı bir şekilde sunulmaktadır.

2.1.1. Denetimli Öğrenme


2.1.1.1. Karar Ağaçları

Denetimli öğrenme yöntemlerinden biri olan karar ağaçları (Decision Tree), veri setlerindeki desenleri ve ilişkileri öğrenmek için kullanılan bir algoritmadır. Karar ağaçları, bir ağaç yapısında karar kurallarını ve sonuçları temsil eder (Atalay ve Çelik, 2017). Bu ağaç, bir dizi karar düğümü ve sonuç düğümü içerir. Her karar düğümü, bir özniteliği ve bu özniteliğin belirli bir eşik değerini temsil eder. Veri örnekleri bu karar düğümlerinden geçerken, her düğümde bir karar alınır ve veri örneği belirli bir yola göre yönlendirilir. Sonuç düğümlerinde ise, veri örneğinin tahmin edilen sınıfı veya çıktısı bulunur (Buntine, 2020). Karar ağaçları, karmaşık karar yapılarını basit ve yorumlanabilir bir şekilde temsil edebilme yetenekleriyle dikkat çekerler. Ayrıca, kategorik ve sayısal verilerle çalışabilirler, aşırı uyuma eğilimli değildirler ve genellikle hiperparametre ayarına hassas olmayabilirler. Bu özellikler, karar ağaçlarını veri madenciliği ve sınıflandırma problemlerinde popüler bir seçenek haline getirir (Charbuty ve Abduazeez, 2021).

Şekil 2.1'deki, en üstte yer alan kök düğüm, tüm karar ağacının başlangıç noktasıdır. Bu düğüm, veri kümesini ikiye böler ve altındaki iç düğümlere yönlendirir. Veri noktalarını sınıflandırmak veya tahmin yapmak için kullanılır. Kök düğümün altında bulunan iç düğümler, veriyi daha fazla böler. Her iç düğüm, bir özelliği temsil eder ve bu

özelliğın deęerine göre veriyi ikiye ayırır. İ düęümlerden gelen dalların sonunda bulunur. Her yaprak düęüm, sonuç sınıfını temsil eder. Örneğın, bu durumda belirli bir rüzgâr hızı kategorisini ifade edebilir. Rüzgâr hızı tahmini için, meteorolojik verileri her iç düęümde kullanarak bir karar ağacı oluşturulabilir. Her düęümde, tarihî verilerden türetilmiş eşik deęerleri veya kriterlere dayalı olarak ikili bir karar alınabilir. Bu kriterler, sıcaklık aralıkları, atmosfer basın seviyeleri, nem yüzdesi gibi faktörleri içerebilir. Bu kararlar, ağacın yapısını takip ederek belirli bir rüzgâr hızı kategorisine ulaşır.

Karar ağaçları, bir veri kümesindeki özniteliklerin önemini ve etkisini anlamak için de kullanılabilir. Ağaçtaki dalların dallanma özellikleri, belirli özniteliklerin sınıflandırmadaki önemini gösterir (Ghiasi vd., 2020).



Şekil 2.1. Karar Ağacı

Ancak, karar ağaçları bazı dezavantajlar da taşır. Özellikle çok karmaşık veri yapılarına veya yüksek boyutlu veri setlerine uyum sağlamakta zorlanabilirler. Ayrıca, bazı veri setlerinde ağaçlar aşırı karmaşık hale gelebilir, bu da aşırı uyuma yol açabilir. Bu tür sorunları çözmek için, ağaçlar genellikle düęüm kesme (pruning) gibi tekniklerle sınırlandırılır veya birleştirilerek toplu (ensemble) yöntemler kullanılır (Charbuty ve Abdouazeez, 2021).

2.1.1.2. Destek Vektör Makineleri


Destek Vektör Makineleri (Support Vector Machines-SVM), denetimli öğrenme alanında sınıflandırma ve regresyon problemlerini çözmek için kullanılan güçlü bir ML tekniğidir. Özellikle sınıflandırma problemlerinde etkilidir. SVM'nin temel amacı, veri noktalarını iki veya daha fazla sınıfa ayırmak için en uygun karar sınırını belirlemektir (Cervantes vd., 2020).

SVM'nin çalışma prensibi, veri noktalarını bir uzayda doğrusal veya doğrusal olmayan bir hiper düzlemle ayırmayı amaçlar. Bu hiper düzlem, sınıflar arasında bir

boşluk (margin) bırakacak şekilde konumlandırılır. SVM'nin öğrenme süreci, sınıflar arasındaki bu marjı (margin) maksimize eden en iyi karar sınırını bulmaya dayanır. Bu, veri noktalarının sınıflar arasında mümkün olduğunca geniş bir boşlukta ayrılmasını sağlar. Özellikle, SVM'nin doğrusal olarak ayrılabilir olmayan veri kümelerinde de etkili olabilmesi dikkat çekicidir. Doğrusal olarak ayrılabilir olmayan veri kümelerinde, SVM çekirdek (kernel) fonksiyonları kullanarak veri noktalarını yüksek boyutlu uzaylara taşır ve böylece doğrusal olarak ayrılabilir hale getirir. Bu sayede, veri noktalarını sınıflandırmak için doğrusal bir hiper düzlem kullanabilir (Cervantes vd., 2020).

Rüzgâr hızı tahmini için SVM, veri noktalarını girdi özellikleriyle ilişkilendirir ve bu özelliklerin ağırlıklarını kullanarak tahmin yapar. Örneğin, sıcaklık, basınç, nem gibi meteorolojik verileri kullanarak rüzgâr hızını tahmin edebiliriz. SVM, veri noktalarını yüksek boyutlu uzayda etkili bir şekilde ayırmak için çekirdek fonksiyonları kullanır ve bu nedenle non-lineer ilişkileri modelleyebilir.

Şekil 2.2, bir SVM mimarisini göstermektedir. SVM, sınıflandırma ve regresyon görevleri için kullanılan bir denetimli ML algoritmasıdır. Özellikle yüksek boyutlu uzaylarda etkili ve rüzgâr hızı tahmini gibi karmaşık problemlerde kullanılır. Kök Düğüm (Root Node), en üstte yer alan kök düğüm, tüm SVM yapısının başlangıç noktasıdır. Bu düğüm, girdi vektörünü işler ve altındaki destek vektörler olarak adlandırılan gizli düğümlerle ilişkilendirilmiş ağırlıklar (Lagrange Çarpanları) ile çarpılır. Bu ağırlıklı girdiler daha sonra bir sapma terimi (bias) ile toplanır ve çıktı y üretilir. Gizli düğümler (Hidden Nodes), kök düğümün altında bulunan gizli düğümler, SVM'nin temel yapı taşlarıdır. Bu destek vektörler, veri noktalarını yüksek boyutlu uzayda temsil eder ve sınıflandırma veya regresyon görevlerinde kullanılır. Her destek vektör, bir ağırlık (Lagrange Çarpanı) ile ilişkilendirilir. Bu ağırlıklar, SVM'nin eğitim sürecinde belirlenir ve modelin doğruluğunu optimize etmek için kullanılır.



  ekil 2.2. Destek Vekt  r Makineleri

SVM'nin avantajları arasında, y  ksek boyutlu   zellik uzaylarında etkili olması,   ok boyutlu ve karma  ık veri yapılarında iyi performans g  stermesi ve a  ır   uymaya (overfitting) kar  ı dayanıkl   olması sayılabilir. Ayrıca, SVM, do  rusal olmayan veri k  meleri i  in de uygulanabilir. Ancak, SVM'nin bazı dezavantajları da vardır. B  y  k veri setlerinde hesaplama a  ısından maliyetlidir ve veri   n i  leme ile parametre ayarının   nemli oldu  u bir algoritmadır. Ayrıca, sınıf etiketleri arasında kesin bir mar  ı olan problemlerde performansı d    k olabilir. Sonu   olarak, SVM, bir  ok uygulama alanında etkili olan g    l   bir ML tekni  idir. Ancak, kullanılaca  ı veri setine ve problem ba  lamına ba  lı olarak uygun parametrelerin ve kernel fonksiyonlarının se  ilmesi   nemlidir.

2.1.1.3. Yapay Sinir A  ları

Yapay Sinir A  ları (YSA/Artificial Neural Networks-ANN), biyolojik sinir a  larından esinlenerek tasarlanm     bir ML modelidir. YSA, bilgisayar programlarında karma  ık i  levleri ger  ekle  tirmek i  in kullanılır. Her bir yapay sinir, giri   verilerini alır, bu verilere belirli a  ırlıklar uygular, ardından bir aktivasyon fonksiyonuna tabi tutar ve sonu   olarak bir   ıkt     retilir. Bu i  lem, bir  ok katmandan (layer) olu  an bir a   boyunca tekrarlanır (Choi vd., 2020).

YSA,   e  itli t  rlerde olabilir.   rne  in,   ok katmanlı algılayıcılar (multilayer perceptrons - MLP), en yaygın kullanılan YSA t  rlerindendir. Bu a  lar, giri   katmanı, bir veya daha fazla gizli katman ve bir   ıkı   katmanı i  erir. Her bir katmandaki n  ronlar, bir   nceki katmandaki t  m n  ronlarla ba  lantılıdır. Bu sayede, YSA, karma  ık ili  kileri modelleme yetene  ine sahiptir.


  ekil 2.3, bir YSA d    m  n  n temel yapısını g  stermektedir. YSA, ML alanında kullanılan ve r  z  ar hızı tahmini gibi bir  ok tahminsel g  revde etkili olan modellerdir.

Girdi Değerleri (Input Values), etiketlenmiş X 'in altında indekslenmiş X 'ler ($X_1, X_2, \dots, X_m$) bulunur. Her biri, ağırlıklarla ($W_1, W_2, \dots, W_m$) belirtilen merkezi toplama noktasına bağlıdır. Ayrıca bu toplama noktasına bağlı bir sapma terimi ' b ' vardır.

Ağırlıklar (Weights): Her girdi, bir ağırlık ile çarpılır. Bu ağırlıklar, ağırlık eğitimi sırasında ayarlanır ve girdi verilerine dayalı olarak modelin karmaşık desenleri öğrenmesini sağlar.

Aktivasyon Fonksiyonu (Activation Function): Toplama işlemi, büyük sigma sembolü ile temsil edilir ve sonucu "Aktivasyon Fonksiyonu" olarak adlandırılan $\phi(\Phi)$ işlevine yönlendirir. Bu işlevin çıktısı ' y ' olarak etiketlenir ve nihai çıktıyı temsil eder.

YSA, veriye dayalı olarak ağırlıkları ve sapma terimini ayarlayarak karmaşık desenleri öğrenir ve girdi verilerine dayalı doğru tahminler yapabilir. Rüzgâr hızı tahmini için bu yapı, meteorolojik verileri kullanarak ağırlıkları ayarlayarak rüzgâr hızını tahmin edebilir. Bu ağlar, yüksek boyutlu uzaylarda etkili bir şekilde çalışabilir ve non-lineer ilişkileri modelleyebilir. YSA, modern ML algoritmalarının temelini oluşturur ve rüzgâr hızı tahmini gibi görevlerde başarılı bir şekilde kullanılır.



Şekil 2.3. Yapay Sinir Ağları

YSA'nın avantajları arasında esneklik, öğrenme yeteneği ve geniş uygulama alanları bulunur. Örneğin, resim tanıma, doğal dil işleme, ses tanıma ve zaman serisi tahmini gibi birçok alanda başarılı bir şekilde kullanılırlar (Choi vd., 2020). Ancak, YSA'nın bazı dezavantajları da vardır. Özellikle, çok büyük veri setleri ve karmaşık yapılarla çalışırken hesaplama maliyeti yüksek olabilir. Ayrıca, ağırlık eğitimi için genellikle büyük miktarda veriye ihtiyaç vardır ve uygun şekilde eğitilmediğinde aşırı uyuma eğilimli olabilirler. Bununla birlikte, yapılandırma ve hiperparametre ayarlarının

zorluğu da bazı sorunlara neden olabilir. Sonuç olarak, YSA, ML ve yapay zekâ alanında önemli bir role sahiptir ve birçok uygulama alanında başarılı bir şekilde kullanılmaktadır.

2.1.1.4. Lojistik Regresyon

Lojistik regresyon, ML alanında sınıflandırma problemlerini çözmek için kullanılan bir algoritmadır. Bu algoritma, giriş verileriyle belirli bir sınıfa ait olma olasılığını tahmin etmek için kullanılır. Temel olarak, lojistik regresyon bir bağımlı değişkenin (sınıf etiketinin) olasılığını hesaplayan bir model oluşturur. Ancak, bu model doğrudan çıktı değerini tahmin etmez, bunun yerine belirli bir sınıfa ait olma olasılığını hesaplar (Nusinovici vd., 2020). Lojistik regresyon, veri noktalarının giriş özellikleri ve ilgili ağırlıklar arasındaki doğrusal bir ilişkiyi temsil eden matematiksel bir formülasyona dayanır. Bu doğrusal ilişki, sigmoid (logistic) fonksiyonu olarak bilinen bir aktivasyon fonksiyonu aracılığıyla işlenir. Sigmoid fonksiyonu, her bir sınıfa ait olma olasılığını 0 ile 1 arasında bir değere dönüştürür. Lojistik regresyonun avantajlarından biri, modelin basitliğidir. Lojistik regresyon modeli, giriş verileri ile çıktı arasındaki ilişkiyi açıkça gösterir ve sonuçları kolayca yorumlanabilir hale getirir. Ayrıca, hesaplama maliyeti diğer bazı sınıflandırma algoritmalarına göre daha düşüktür, bu da büyük veri setleri üzerinde daha verimli çalışmasını sağlar (Nusinovici vd., 2020). Ancak, lojistik regresyonun bazı dezavantajları da vardır. Örneğin, model sınıflar arasındaki ilişkiyi doğrusal olarak modeller, bu da doğrusal olarak ayrılabilen veri kümeleri için uygun olabilir, ancak doğrusal olarak ayrılabilen olmayan veri kümeleri için yetersiz kalabilir. Ayrıca, eğer veri seti karmaşık veya aşırı uyuma eğilimli ise, lojistik regresyon modeli bu durumu ele almakta zorlanabilir ve overfitting problemi ortaya çıkabilir. Lojistik regresyon, tıbbi teşhislerden pazarlama analizine, risk tahmininden sınıflandırmaya kadar birçok farklı alan ve uygulamada yaygın bir şekilde kullanılmaktadır. Özellikle, iki sınıflı sınıflandırma problemlerinde başarıyla kullanılmaktadır.

2.1.2. Denetimsiz Öğrenme

2.1.2.1. Kümeleme

Kümeleme (K-Means Clustering), denetimsiz öğrenme yöntemlerinden biridir ve veri setindeki benzer özelliklere sahip veri noktalarını gruplara ayırmak için kullanılır. Bu gruplar, veri setindeki desenleri ve yapıları anlamak için önemli ipuçları sağlayabilir.

K-Means, en yaygın kullanılan kümeleme algoritmalarından biridir (Sinaga ve Yang, 2020).

K-Means algoritması, veri setindeki veri noktalarını belirli bir sayıda küme veya grubun ortalamasına (merkezine) en yakın olan kümeye atar. Algoritma, başlangıçta rastgele seçilen merkezler etrafında iteratif bir şekilde çalışır ve her iterasyonda veri noktalarını en yakın merkezlere atar, ardından merkezlerin konumunu günceller. Bu işlem, merkezlerin konumları değişmeyene veya bir iterasyon limitine ulaşına kadar devam eder (Sinaga ve Yang, 2020).

K-Means algoritması, kümeleme işlemi sırasında her veri noktasının yalnızca bir küme ile ilişkilendirilmesine dayanır. Her veri noktasının, kümelere atanacak olan merkezlere olan mesafesine dayanarak karar verilir. Bu mesafe genellikle Öklid mesafesi veya Manhattan mesafesi gibi uzaklık ölçütleri kullanılarak hesaplanır (Sinaga ve Yang, 2020).

K-Means algoritmasının avantajları arasında basitlik, etkinlik ve ölçeklenebilirlik bulunur. Ancak, algoritmanın başlangıç merkezlerinin rastgele seçilmesi nedeniyle, farklı başlangıç noktaları bazen farklı sonuçlara yol açabilir. Ayrıca, veri setindeki kümelerin sayısını önceden belirlemek gereklidir, bu da bazı durumlarda zor olabilir.

K-Means algoritması, genellikle pazarlama analizi, müşteri segmentasyonu, görüntü işleme, biyomedikal görüntüleme ve doğal dil işleme gibi birçok alanda kullanılan yaygın bir kümeleme yöntemidir. Veri setindeki benzerlikleri ve yapıları belirlemek, veri keşfi sürecinde önemli bir adımdır ve K-Means bu süreçte etkili bir araç olarak kullanılabilir.


2.1.3. Yarı Denetimli Öğrenme

2.1.3.1. Çoklu Öğrenme

Yarı denetimli öğrenme altındaki çoklu öğrenme (multi-view learning), veriyi farklı bakış açılarından ele alan ve bu farklı bakış açılarını bir araya getirerek daha iyi bir öğrenme performansı elde etmeyi amaçlayan bir ML yaklaşımıdır. Çoklu öğrenme, genellikle etiketlenmiş ve etiketlenmemiş veri örnekleri arasındaki ilişkiyi kullanarak öğrenme sürecini geliştirir (Ouali vd., 2020).

Şekil 2.4, rüzgâr hızı tahmini için veri işleme sürecini göstermektedir. İlk adım, sınıflandırma algoritmasının optimize edilmesidir. Bu adım, modelin performansını artırmak ve daha doğru tahminler yapabilmek için gerçekleştirilir. İlk sınıflandırıcı,

veriye dayalı olarak öğrenilir ve bu aşamada modelin başlangıç hali olarak kullanılır. Daha sonra, kullanılan veri türlerini göstermek için gri daireler kullanılarak "çoklu etiketli" ve "çoklu etiketsiz" veri grupları tanımlanır. Etiketli veri, rüzgâr hızı ölçümlerinin olduğu veri noktalarını içerirken, etiketsiz veri, bu ölçümlerin olmadığı veri noktalarını temsil eder. Sonrasında, etiketsiz verilerin etiketlenmiş örnekler için sınıflandırılması adımı gelir. Bu adımda, etiketsiz veriler, etiketli örnekleri sınıflandırmak veya sınıflandırmaya katkıda bulunmak için kullanılır. Bu süreçte, etiketsiz veri, modelin daha iyi genelleme yapabilmesi için etiketli veriyle birleştirilir. Son olarak, model yeniden eğitilir. Yeniden eğitme, modelin performansını güncel veriye göre iyileştirmek amacıyla gerçekleştirilir. Gri dairelerin olduğu bölgeye dönük ok, bu iteratif süreci gösterir.



Şekil 2.4. Çoklu Öğrenme

Geleneksel denetimli öğrenme yöntemlerinde, öğrenme süreci etiketlenmiş veri noktalarına dayanır. Ancak, etiketlenmiş veri genellikle sınırlıdır ve modelin öğrenme kapasitesini kısıtlar. Çoklu öğrenme, etiketlenmiş veriye ek olarak etiketlenmemiş veri örneklerini de kullanarak modelin performansını artırmayı hedefler. Bu yaklaşım, veri setindeki farklı görüşler veya özellikler arasındaki ilişkileri keşfetmeye çalışır. Çoklu öğrenme, farklı veri temsillerini bir araya getirerek öğrenme performansını artırır. Örneğin, bir görüntü sınıflandırma problemi üzerinde çalışırken, görüntülerin piksel değerlerini kullanmanın yanı sıra görüntülerin renk histogramları veya kenar özellikleri gibi farklı öznitelikleri de modele entegre edilebilir. Bu şekilde, model farklı öznitelikleri öğrenerek daha kapsamlı bir öğrenme süreci geçirebilir (Ouali vd., 2020).

Çoklu öğrenme yöntemleri genellikle çeşitli ML algoritmalarıyla birleştirilir. Örneğin, SVM, karar ağaçları veya DL modelleri gibi algoritmalarla birlikte kullanılabilirler. Bu sayede, modelin çeşitli öznitelikleri veya bakış açılarını bir araya getirerek daha iyi bir genelleme yapması sağlanır (Zhou ve Zhou, 2021).

Sonu olarak, oklu ğrenme, farklı veri temsillerini birleřtirerek daha kapsamlı bir ğrenme süreci saėlayan ve modelin ğrenme performansını artıran bir yarı denetimli ğrenme yaklařımıdır. Bu yöntem, zellikle sınırlı etiketlenmiř veriye sahip problemlerde etkili olabilir.

2.1.3.2. Yarı-Denetimli ğrenme

Yarı-denetimli ğrenme hem etiketlenmiř hem de etiketlenmemiř verilerin kullanıldıėı bir ML yöntemidir. Etiketlenmiř veriler, giriř verilerine karřılık gelen doėru ıktı etiketlerine sahipken, etiketlenmemiř verilerin ıktı etiketleri bulunmamaktadır. Yarı denetimli ğrenme, genellikle etiketlenmiř verilerin az olduėu durumlarda veya etiketleme maliyetinin yüksek olduėu durumlarda kullanılır. Bu yöntem, etiketlenmiř verilerle birlikte, etiketlenmemiř verilerden de bilgi ıkararak modelin performansını artırmayı amalar (Van Engelen ve Hoos, 2020).

Yarı-denetimli ğrenme bařlıėı altında bulunan yarı-denetimli ğrenme ise, sınıflandırma veya regresyon gibi grevlerde kullanılan modellerin eėitiminde hem etiketlenmiř hem de etiketlenmemiř verilerin kullanılmasıyla ilgilidir. Buradaki temel fikir, etiketlenmiř verilere sahip olduėumuz durumlarla benzer yapıya sahip olan ancak etiketlenmemiř verilere sahip olduėumuz durumların bilgisinden yararlanmaktır. Yarı-denetimli ğrenme, genellikle etiketlenmiř veri miktarının sınırlı olduėu veya etiketleme iřleminin maliyetli olduėu durumlarda kullanılır (Van Engelen ve Hoos, 2020).

Yarı-denetimli ğrenme yöntemlerinden biri olan oklu ğrenme (Multi-View Learning), farklı veri temsillerini veya bakıř aılarını kullanarak bir model oluřturmayı amalar. Bu yöntemde, aynı veri rnekleri farklı zellik uzaylarında temsil edilir ve bu farklı grnmlerden elde edilen bilgi modelin performansını artırmak iin bir araya getirilir. rneėin, bir grnty hem piksel deėerleri hem de kenar detayları ile temsil ederek iki farklı grnm elde edilebilir. Bu iki grnmn birleřtirilmesi, modelin daha iyi bir temsil oluřturmasına ve dolayısıyla daha iyi bir performans gstermesine yardımcı olabilir. Bu řekilde, etiketlenmiř ve etiketlenmemiř verilerden elde edilen farklı grnmler bir araya getirilerek modelin performansı artırılabilir.

2.1.4. Derin Öğrenme

2.1.4.1. Evrişimli Sinir Ağları


DL alt başlığı olan Evrişimli Sinir Ağları (Convolutional Neural Networks-CNN), özellikle görüntü işleme alanında başarıyla kullanılan bir YSA türüdür. CNN, özellikle resim tanıma, nesne tespiti, yüz tanıma, karakter tanıma gibi görsel veri analizi alanlarında etkili sonuçlar verir (Kattenborn vd., 2021).

CNN'lerin temel fikri, verinin yapısını ve hiyerarşik özelliklerini daha iyi yakalayabilen evrişim (convolution) ve havuzlama (pooling) katmanları gibi özel mimari yapılarını kullanmaktır. Bu mimari, özellikle büyük boyutlu ve karmaşık görüntü verileri üzerinde etkili bir şekilde çalışır.

Evrişim katmanları, girdi verisi üzerinde küçük filtrelerin (kernel) kaydırılması yoluyla görüntü üzerinde evrişim işlemi gerçekleştirir. Bu filtreler, verideki belirli özellikleri (örneğin kenarlar, köşeler, doku desenleri) vurgulamak için kullanılır. Bu sayede, ağın daha düşük katmanları basit özellikleri ve yapıları öğrenirken, daha üst katmanlar daha karmaşık özellikleri ve desenleri öğrenir.

Şekil 2.5, bir CNN modelinin mimarisini betimlemektedir. Modelin ilk katmanı, giriş katmanıdır ve burada işlenecek olan veriye giriş yapılır. Ardından, konvolüsyon katmanları gelir; bu katmanlar, veri üzerinde belirli boyutlarda filtreler uygulayarak özellikleri çıkarır. Bu filtreler, özellikle görüntü tanıma gibi görsel veri analizi görevlerinde, kenarlar, köşeler veya diğer önemli desenler gibi görsel özellikleri vurgular. Konvolüsyon katmanlarının çıktıları genellikle aktivasyon fonksiyonlarıyla (örneğin Doğrusal Düzgün Birim- Rectified Linear Unit (ReLU)) geçirilerek, modelin daha derin ve karmaşık desenleri öğrenmesine yardımcı olunur. Bu işlemin ardından max-pooling katmanları gelir; bu katmanlar, verinin boyutunu küçültmek ve hesaplama yükünü azaltmak için alt örnekleme işlemi yapar. Bu, modelin daha genel ve özgül olmayan özellikleri öğrenmesini sağlar. Tam bağlantılı sinir ağı katmanları, ardından gelir; bu katmanlar, özellikleri sınıflara tahmin etmek için kullanılır ve bu aşamada, modelin öğrendiği özelliklerin temsil gücü artırılır. Son olarak, çıkış katmanı bulunur; bu katman, farklı sınıfların olasılıklarını içeren bir çıktı vektörü üretir. Örneğin, rakam tanıma gibi bir görevde, çıkış katmanı, 0'dan 9'a kadar olan rakamların olasılıklarını içeren bir vektör üretebilir. Bu model, görsel veri analizi gerektiren çeşitli uygulamalarda kullanılabilir, örneğin rüzgâr hızı tahmini. Ancak, belirli bir uygulama için doğrudan kullanılacak

hale gelmesi için, modelin bu alana özgü verilerle eğitilmesi ve ayarlanması gerekmektedir.



Şekil 2.5. Evrişimli Sinir Ağları

Havuzlama katmanları, evrişim sonrası elde edilen özellik haritalarını küçültmek veya özetlemek için kullanılır. Bu katmanlar, özellik haritalarının boyutunu azaltarak ve öne çıkan özellikleri belirginleştirerek ağın hesaplama maliyetini azaltır. Ayrıca, havuzlama katmanları sayesinde ağ, girdiye göre daha az hassas hale gelir, yani belirli özelliklerin konumunu ve büyüklüğünü daha genel bir şekilde öğrenir (Sahu ve Dash, 2021). CNN'ler, bu evrişim ve havuzlama katmanlarının bir araya gelmesiyle oluşan birçok katmandan (genellikle onlarca veya yüzlerce) oluşur. Bu katmanlar, görüntü verisindeki hiyerarşik yapıları öğrenmek için birlikte çalışır. Öğrenme süreci, geriye yayılım (backpropagation) algoritması kullanılarak gerçekleştirilir. Sonuç olarak, CNN, özellikle görüntü işleme ve tanıma alanlarında önemli bir rol oynayan ve genellikle karmaşık ve büyük boyutlu görüntü verileri üzerinde etkili sonuçlar veren bir YSA türüdür.


2.1.4.2. Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNN), DL altındaki önemli bir YSA modelidir. RNN'ler, zaman serileri, doğal dil işleme ve diğer sıralı veri türleri gibi zaman veya sıra bağımlılığı içeren problemlerde etkili bir şekilde kullanılabilirler. Temel fikir, önceki adımlarda elde edilen bilgileri bellekte saklayabilen ve ardından bu bilgileri mevcut adımda kullanabilen bir yapıya sahip olmalarıdır (Sherstinsky, 2020).

RNN'lerin temel yapıları, birbirine bağlı tekrarlayan birimlerden oluşur. Her bir birim hem geçerli girişi hem de bir önceki adımdan gelen gizli durumu (hidden state) alır. Bu gizli durum, geçmiş adımlardaki bilgileri temsil eder ve ağı belleği gibi davranır. Bu

yapı, ağın önceki adımlarda elde edilen bilgileri gelecekteki adımlarda kullanmasına olanak tanır (Öztürk ve Bilgiç, 2022).

Şekil 2.6, RNN mimarisini görselleştirir. RNN, özellikle zaman serisi ve ardışık verilerin analizi için kullanılan bir YSA türüdür. Modelin bileşenleri arasında giriş katmanı, gizli katmanlar ve çıkış katmanı bulunur. Giriş katmanı, ağa veri beslerken, gizli katmanlar veriyi işleyerek içsel temsiller oluşturur; RNN'nin özelliği, gizli katmanlarda döngülerin bulunmasıdır, bu da önceki adımlardan gelen bilgiyi korur ve ardışık verilerin analizinde geçmiş bilgiyi kullanmamıza olanak tanır. Çıkış katmanı ise sonuçları üretir, örneğin, metin verisi üzerinde çalışılıyorsa, metin sınıflandırma sonuçlarını üretebilir. Bu tür bir sinir ağı, zaman içindeki verilerin analizi ve ardışık veri yapılarının işlenmesi için kullanılabilir. Örneğin, rüzgâr hızı tahmini gibi ardışık verilerin analiz edildiği görevlerde bu tür modeller kullanılabilir; ancak modelin belirli bir uygulama için kullanılabilir hale gelmesi için daha fazla eğitim ve ayarlama gerekebilir.




Şekil 2.6. Tekrarlayan Sinir Ağları

RNN'lerin avantajlarından biri, sıralı veri türlerini işleme yetenekleridir. Bu, doğal dil işleme gibi dil tabanlı görevlerde veya zaman serileri tahmininde oldukça etkilidir. Ayrıca, RNN'lerin esnek bir mimarisi vardır ve farklı uzunluktaki giriş dizilerini işleyebilirler. Ancak, RNN'lerin bazı dezavantajları da vardır. Özellikle, uzun vadeli bağımlılıkları başarılı bir şekilde ele alamazlar ve bu da "uzun vadeli bağımlılık sorunu" olarak adlandırılır. Bu sorun, ağın geçmiş adımlardaki bilgileri hatırlama yeteneğinin sınırlı olması nedeniyle ortaya çıkar. Ayrıca, RNN'lerin eğitimi zaman alabilir ve hesaplama maliyeti yüksek olabilir (Shi vd., 2022). RNN'lerin birçok varyasyonu bulunmaktadır, bunlar arasında LSTM ve GRU gibi yapılar bulunmaktadır. Bu varyasyonlar, özellikle uzun vadeli bağımlılık sorununu ele almak için tasarlanmıştır ve daha gelişmiş bellek mekanizmaları içerirler (Karadağ, 2022). Sonuç olarak, RNN, DL

altındaki önemli bir yapıdır ve sıralı veri türlerinin işlenmesinde etkili bir şekilde kullanılır. Doğal dil işleme, zaman serisi analizi, çeviri gibi birçok alanda başarılı sonuçlar vermiştir (Khurna vd., 2023). Şekil 2.7, makine öğrenme türlerinin denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve DL en sık kullanılanlar tablo halinde gösterilmiştir.





Şekil 2.7. Makine Öğrenim Türleri

Çizelge 2.1. Makine öğrenme türlerinin avantajları ve dezavantajları

Makine Öğrenimi Türü	Alt Başlıklar	Avantajlar	Dezavantajlar
Denetimli Öğrenme	- Karar Ağaçları (Decision Trees)	- Kolay yorumlanabilir modeller oluşturur	- Yüksek boyutlu veri setlerinde aşırı uyuma eğilimli olabilir
	- Destek Vektör Makineleri (SVM)	- Etkili sınıflandırma performansı sağlar	- Hiperparametre ayarının önemi ve hesaplama yoğunluğu
	- Yapay Sinir Ağları (ANN)	- Esneklik ve karmaşıklıkta geniş bir yelpazede çalışabilir	- Büyük veri setleri için yetersiz olabilir
	- Lojistik Regresyon	- İyi dengelenmiş veri setlerinde iyi performans gösterir	- Çok sayıda öz nitelikte başa çıkma zorluğu
Denetimsiz Öğrenme	- Kümeleme (K-Means)	- Veri setinde gizli yapıları keşfeder	- Küme sayısının önceden belirlenmesi gerekliliği
	- Otomatik Kodlayıcılar (Autoencoders)	- Öz nitelik çıkarma ve gürültü azaltma için kullanılabilir	- Eğitim sürecinin uzunluğu ve modelin karmaşıklığı
Yarı Denetimli Öğrenme	- Çoklu Öğrenme	- Etiketlenmiş ve etiketlenmemiş verilerden yararlanarak model performansını artırır	- Etiketlenmiş veri miktarının sınırlı olması
	- Yarı-denetimli Öğrenme	- Veri setinde etiketlenmiş verinin az olduğu durumlarda kullanışlıdır	- Modelin etiketlenmemiş verilere duyarlı olma riski
Derin Öğrenme	- Evrişimli Sinir Ağları (CNN)	- Büyük ve karmaşık veri setlerinde mükemmel performans gösterir	- Eğitim sürecinin uzunluğu ve hesaplama yoğunluğu
	- Rekurrent Sinir Ağları (RNN)	- Zaman serileri gibi zaman bağımlı verilerde kullanışlıdır	- Uzun zaman aralıklarındaki bağımlılıkları öğrenmede zorluklar
	- Evrişimli Rekurrent Sinir Ağları (CRNN)	- Hem evrişimli hem de rekurrent özelliklerin birleştirilmesi	- Karmaşık hiperparametre ayarları gerektirebilir
	- Derin Evrişimli Ağlar (Deep Convolutional Networks)	- Derinlemesine öğrenme ve temsil yetenekleri	- Veri seti boyutuna ve modelin karmaşıklığına duyarlılık

ML türlerinin çeşitli avantajlarını ve dezavantajlarını içeren Çizelge 2.1'e göre, denetimli, denetimsiz, yarı denetimli ve DL yöntemlerine odaklanan bir inceleme sunulmaktadır. Denetimli öğrenme yöntemlerinde, karar ağaçları modellerinin kolay yorumlanabilirlik sağladığı ve lojistik regresyonun dengeli veri setlerinde iyi performans gösterdiği belirtilirken, SVM ve YSA'nın aşırı uyuma ve veri boyutu gibi zorluklarla karşılaşabileceği vurgulanmaktadır (Sri Preethaa vd., 2023; Mohd ve Singh, 2024). Denetimsiz öğrenme tekniklerinde, k-ortalama kümeleme yönteminin gizli yapıları keşfetme yeteneğine sahip olduğu ve otomatik kodlayıcıların öznel çıkarma ve gürültü azaltma için kullanılabileceği belirtilirken, boyut azaltma yönteminin anlamsız boyutların oluşturulma riski taşıdığı ifade edilmektedir (Karaman, 2023). Yarı denetimli ve DL tekniklerinde, model performansını artırmak ve belirli veri yapılarını ele almak için çoklu öğrenme ve CNN gibi yöntemlerin kullanışlı olduğu, ancak uzun eğitim süreleri ve karmaşık hiperparametre ayarları gibi zorluklarla karşılaşılabilmesi belirtilmektedir. Bu çeşitli yöntemlerin kullanımı, rüzgâr hızı tahmininin doğruluğunu artırabilir ve YEK daha etkin kullanımını sağlayabilir.

Rüzgâr hızı tahmini alanında, denetimli öğrenme yöntemlerinden SVM, zaman serilerindeki desenleri tanımlamak ve gelecekteki rüzgâr hızını tahmin etmek için etkili bir şekilde kullanılabilir (Zheng vd., 2023). Ayrıca, rüzgâr hızının zamana bağlı olarak değiştiği senaryolarda RNN ve CNN, zaman serisi verilerini işlemek ve zaman içindeki ilişkileri modellemek için idealdir. DL yöntemlerinden biri olan CNN, rüzgâr hızı tahmini için kullanılan görüntü verilerini etkili bir şekilde işleyebilir ve önemli özellikleri otomatik olarak çıkarabilir (Wood, 2023). Bu yöntemlerin kullanımı, rüzgâr enerjisi santrallerinin verimliliğini artırmak ve enerji üretimini optimize etmek için değerli bir araç olabilir.

Yenilenebilir enerjinin ML tabanlı tahminine ilişkin çalışmalarda, rüzgâr hızı, nem, sıcaklık ve basınç gibi meteorolojik değişkenlerin kullanılması, rüzgâr enerjisi üretimini optimize etmek için önemli bir yaklaşımdır. Bu bağlamda, çeşitli ML modelleri incelenmektedir. LSTM, XGBoost, KNN, Karar Ağacı, SVR, GRU, YSA ve CNN gibi algoritmalar, rüzgâr hızı tahmini için değerlendirilmektedir. Bu modeller, farklı özellikler ve öğrenme yaklaşımlarıyla rüzgâr hızını tahmin etmek üzere tasarlanmıştır (Khan vd., 2020). Örneğin, LSTM ve GRU gibi RNN modelleri, ardışık verilerin işlenmesinde etkilidir ve zaman serilerindeki uzun vadeli bağımlılıkları modellemek için kullanılabilir (Akkurt ve Sarıçiçek, 2024). XGBoost ve Karar Ağacı gibi ağaç tabanlı yöntemler, özellikler arasındaki karmaşık etkileşimleri yakalamak için uygunken, CNN gibi DL

modelleri de görüntü verilerini etkili bir şekilde işleyebilir (Meddage vd., 2024; Sevinç ve Kaya, 20221). Bu modellerin kullanımı, rüzgâr enerjisi üretimini optimize etmek ve YEK daha etkin kullanımını sağlamak için önemli bir adımdır.


Ayrıca, bu modellerin performansını artırmak ve tahmin doğruluğunu optimize etmek için çeşitli ön işleme ve özellik mühendisliği teknikleri de kullanılacaktır. Örneğin, veri normalizasyonu, eksik değerlerin doldurulması ve özellik seçimi gibi adımlar, modelin daha güçlü ve genelleştirilebilir hale gelmesine yardımcı olabilir. Ayrıca, farklı model hiperparametrelerinin ve özellik kombinasyonlarının sistemli bir şekilde değerlendirilmesi, en iyi tahmin performansını elde etmek için kritik öneme sahiptir. Bu bağlamda, yenilenebilir enerji alanında ML tabanlı tahmin çalışmaları hem bilimsel hem de endüstriyel açıdan büyük önem taşımaktadır ve gelecekte enerji sektöründe sürdürülebilir ve verimli bir dönüşümü destekleyebilir.

2.2. Türkiye’deki Rüzgâr Enerjisi Potansiyeli

Rüzgâr enerjisi, temiz ve yenilenebilir bir enerji kaynağı olması sebebiyle giderek daha fazla ilgi görmektedir. Türkiye gibi rüzgâr potansiyeli yüksek olan ülkelerde, rüzgâr enerjisi, enerji üretiminde önemli bir rol oynamaktadır. Ancak, rüzgâr enerjisi santrallerinin verimli çalışabilmesi için rüzgâr hızının doğru bir şekilde tahmin edilmesi gerekmektedir. Bu noktada, ML ve DL gibi veri odaklı tekniklerin kullanılması, rüzgâr hızının tahmin edilmesinde önemli bir rol oynamaktadır (Wu vd., 2019). Küresel enerji sistemlerindeki dönüşümler, son yıllarda giderek daha belirgin hale gelmektedir. Bu dönüşümler, küresel ekonomik büyüme ile fosil yakıt talebi arasındaki geleneksel ilişkideki değişimlerle başlamaktadır (Timilsina vd., 2013). Gelişen temiz enerji teknolojileri ve artan çevresel farkındalık, fosil yakıt kullanımının azalmasına ve temiz enerji kaynaklarının öneminin artmasına yol açmaktadır.

Küresel enerji sisteminde önemli değişimler yaşanmaktadır. Ekonomik büyüme ile fosil yakıt talebi arasındaki sıkı ilişki, temiz enerji ekonomisinin yükselişiyle gevşemektedir. Mevcut politika yönergelerine göre, her bir fosil yakıttan üçü 2030’a kadar zirveye ulaşacak. 1975’te yenilenebilir enerji elektrik üretiminin %70’ini sağlıyordu, ancak 2030-2024 arasında Güneş PV, en büyük elektrik kaynağı haline geldi. 2050’de satılan ısıtma ünitelerinin yarısı fosil yakıt kullanmayacak. 1990’da fosil yakıt talebi artarken, 1977’de fosil yakıtlar elektrik üretiminin %70’ini sağlıyordu. 2002’de dünya genelinde 650 milyon araç yollardaydı, ancak 2030’da bu sayı 650 milyon elektrikli araca ulaşacak. 1990’dan bu yana yıllık ortalama verimlilik artışı < %1 iken,

2022'den beri bu artış $> \%2$ 'ye yükseldi. Son olarak, 2030'da yükselen piyasalar ve gelişmekte olan ekonomiler küresel fosil yakıtın üçte ikisini tüketiyor olacak (Şekil 2.8) (IEA, 2024).



Şekil 2.8. Küresel enerji sisteminde dönüşümler (IEA, 2024)

Özellikle, YEK arasında rüzgâr enerjisi de önemli bir yer tutmaktadır. Rüzgâr türbinleri, düşük karbonlu elektrik üretiminde önemli bir rol oynamaktadır ve giderek daha fazla tercih edilmektedir. Özellikle deniz üzerindeki rüzgâr çiftlikleri, yüksek verimlilikleri ve düşük çevresel etkileri nedeniyle dikkat çekmektedir. Bu şekilde, rüzgâr enerjisi küresel elektrik arzında giderek daha büyük bir paya sahip olmaktadır.

Güneş enerjisi gibi, rüzgâr enerjisinin de maliyetlerinin düşmesi ve teknolojisinin gelişmesi, bu enerji kaynağının daha yaygın bir şekilde benimsenmesine olanak tanımaktadır. Bu nedenle, rüzgâr enerjisi gelecekte küresel enerji dönüşümünde önemli bir role sahip olabilir.

Geleceğe yönelik projeksiyonlar, fosil yakıt talebinde zirve noktalarının yaklaşmakta olduğunu göstermektedir. Öngörüler, petrol, kömür ve doğalgaz gibi ana fosil yakıtların talebinin 2030'dan önce zirveye ulaşacağını öne sürmektedir. Bu dönemde, artan elektrikli araç kullanımı ve ısıtma sistemlerindeki dönüşümler, fosil yakıt talebindeki düşüşü destekleyecektir. Örneğin, ısıtma sistemlerinde fosil yakıt kullanımının azalmasıyla birlikte, ısı pompaları ve elektrikli ısıtıcılar gibi daha temiz ve verimli teknolojilerin kullanımı artacaktır (Demirtürk, 2021).


Bu dönüşümler, küresel enerji sisteminin sürdürülebilirliğini ve çevresel etkilerini iyileştirmeyi amaçlamaktadır. Ancak, bu geçiş sürecinde birçok zorluk ve engelle de karşılaşabilir. YEK altyapıya entegrasyonu, depolama teknolojilerinin geliştirilmesi ve enerji verimliliğinin artırılması gibi konularda daha fazla çalışma ve yatırım gerekmektedir. Ayrıca, fosil yakıt endüstrisindeki dönüşüm süreci, ekonomik ve sosyal açıdan etkileyici olabilir ve bu nedenle dengeli ve adil politika yaklaşımları gerektirebilir (Gürül, 2019).

ML algoritmaları, büyük miktarda veriyi analiz ederek rüzgâr hızının gelecekteki değerlerini tahmin etmek için kullanılabilir. Aynı zamanda, DL yöntemleri de geçmiş rüzgâr verilerini kullanarak gelecekteki rüzgâr hızlarını tahmin etmede etkili olabilir. Bu tez, Türkiye’deki rüzgâr enerjisi potansiyelini değerlendirmek ve rüzgâr hızının tahmin edilmesinde ML ve DL yöntemlerini kullanarak daha doğru tahminler yapmayı amaçlamaktadır. Bu sayede, rüzgâr enerjisi sektöründe verimliliği artırmak ve enerji üretiminde sürdürülebilirliği sağlamak mümkün olacaktır.

2.2.1. Türkiye’deki Genel Durum ve Bölgesel Analizler

Türkiye’nin rüzgâr enerjisi potansiyeli, coğrafi konumu ve topografik özellikleriyle yakından ilişkilidir. Ülkenin genelinde, özellikle sahil şeritleri ve yüksek rakımlı bölgelerde, rüzgâr enerjisi kaynakları oldukça zengindir. Karadeniz’in kuzey sahil şeridi ve Ege Bölgesi’nin bazı kısımları, özellikle yüksek rüzgâr hızlarına sahiptir. Ancak, iç kesimlerdeki düzlüklerde ve Güneydoğu Anadolu Bölgesi’nde rüzgâr hızları daha düşük olabilir. Bu nedenle, Türkiye’nin farklı coğrafi bölgeleri arasında rüzgâr enerjisi potansiyeli açısından önemli farklılıklar bulunmaktadır (Çakır, 2010).


Türkiye’deki rüzgâr enerjisinin yıllara göre toplam kurulu güç içerisindeki oranı (Şekil 2.9), Haziran 2022 itibarıyla %10,81’e ulaşmıştır. Bu durum, Türkiye’nin enerji portföyünde rüzgâr enerjisinin giderek daha büyük bir yer edindiğini ve ülkenin enerji sektöründe sürdürülebilirlik ve çeşitlilik açısından önemli adımlar attığını göstermektedir. Rüzgâr enerjisi, temiz ve yenilenebilir bir kaynak olması nedeniyle, Türkiye’nin enerji bağımsızlığını artırma ve karbon salınımını azaltma hedeflerine ulaşmasına katkı sağlayabilir. Bu artış aynı zamanda rüzgâr enerjisi endüstrisinin Türkiye’deki büyüme potansiyelini ve ekonomiye olan katkısını da yansıtmaktadır. Gelecekte, rüzgâr enerjisi yatırımlarının artmasıyla birlikte, Türkiye’nin enerji ihtiyacını karşılama ve çevresel sürdürülebilirlik açısından daha sağlam bir temel oluşturması beklenmektedir (ETKB, 2024).



Şekil 2.9. Türkiye’deki rüzgâr enerjisinin yıllara göre toplam kurulu güç içerisindeki oran (ETKB, 2024)

Bölgesel analizler, Türkiye’nin farklı bölgelerindeki rüzgâr enerjisi potansiyelini daha ayrıntılı bir şekilde değerlendirmeyi sağlar. Örneğin, Karadeniz Bölgesi’nde yoğunlaşan rüzgâr enerjisi potansiyeli, Marmara Bölgesi’nden farklılık gösterebilir. Bu analizde, her bölgenin rüzgâr rejimi, ortalama rüzgâr hızı ve enerji üretim potansiyeli incelenebilir. Bu sayede, rüzgâr enerjisi yatırımlarının belirli bölgelere odaklanması veya farklı bölgelerde farklı teknolojilerin kullanılması gibi stratejik kararlar alınabilir.


Türkiye’de 2010 yılından itibaren 2022’ye kadar olan süreçte rüzgâr enerjisi kurulu gücünün sürekli arttığını Şekil 2.10 ‘da göstermektedir. 2010 yılında yaklaşık 1.279 MW olan kurulu güç, 2022 yılına gelindiğinde yaklaşık 10.976 MW’a ulaşmıştır. Belirli yıllarda, örneğin 2011’de 2.261 MW ve 2014’te 3.630 MW gibi, kurulu güçte belirgin artışlar görülmektedir. En yüksek değerler ise 2021 ve 2022 yıllarında kaydedilmiştir, her ikisi de yaklaşık 10.000 MW’un üzerindedir. Bu grafik, rüzgâr enerjisi kapasitesinin belirli bir bölgede veya ülkede on yılı aşkın bir süre boyunca nasıl büyüdüğünü görsel olarak temsil etmektedir. Bu durum, YEK benimsenmesinde önemli bir ilerlemeyi vurgulamaktadır (ETKB, 2024).



Şekil 2.10. Türkiye’deki rüzgâr enerjisine dayalı yıllara göre kurulu güç (ETKB, 2024)

Türkiye’deki rüzgâr enerjisi potansiyelinin yanı sıra, ülkenin genel ekonomik ve politik durumu da sektörün gelişimi üzerinde önemli bir etkiye sahiptir. Özellikle son yıllarda, Türkiye’de enerji sektöründe yapılan düzenlemeler ve teşvikler rüzgâr enerjisi yatırımlarını artırmıştır.

Türkiye’de 2000’den itibaren yenilenebilir elektrik üretiminin kaynağa göre gelişimine odaklanan Şekil 2.11’de yer alan grafik, 2022 yılına kadar olan süreçte hidroelektrik enerjinin belirgin bir liderlik sergilediğini, rüzgâr enerjisinin ikinci sırada yer aldığını, güneş enerjisinin üçüncü sırada ve jeotermal enerjinin ise dördüncü sırada bulunduğunu göstermektedir. Bu dönem boyunca, Türkiye’nin YEK olan yatırımları ve bu kaynakların elektrik üretimindeki payı artarak devam etmiştir. Bu eğilim, Türkiye’nin enerji üretimini çeşitlendirmek ve daha sürdürülebilir bir enerji portföyü oluşturmak için attığı adımların bir yansımasıdır (IEA, 2024).



Şekil 2.11. Türkiye’de 2000’den itibaren yenilenebilir elektrik üretiminin kaynağa göre gelişimi (IEA, 2024)


Türkiye’de 2000 yılından 2021 yılına kadar olan süreçte toplam nihai tüketimin gelişimini Şekil 2.12’de göstermektedir. Bu dönemde, petrol ürünleri en fazla tüketilen enerji kaynağı olmuş ve ilk sırada yer almıştır. Doğal gaz ikinci sırada gelirken, üçüncü sırada elektrik tüketimi yer almıştır. Kömür ise dördüncü sıradadır. Beşinci sırayı ise rüzgâr ve güneş enerjisi gibi yenilenebilir kaynaklar almıştır. Bu veriler, Türkiye’nin enerji tüketim profiline ve enerji kaynaklarına olan talep eğilimlerine ışık tutmaktadır. Özellikle, fosil yakıtların (petrol, doğal gaz, kömür) hala büyük bir paya sahip olduğu ancak YEK (rüzgâr, güneş) öneminin giderek arttığı gözlemlenmektedir. Bu durum, Türkiye’nin enerji dönüşümü ve sürdürülebilirlik hedeflerine ulaşmak için atması gereken adımları belirlemede önemli bir referans noktası sağlamaktadır (IEA, 2024).



Şekil 2.12. Türkiye’de 2000’den itibaren toplam nihai tüketimin gelişimi (IEA, 2024)


Türkiye’de toplam elektrik tüketiminin dağılımını Şekil 2.13’te göstermektedir. Verilere göre, elektrik tüketiminin büyük bir kısmı petrol ürünlerinden (%36) ve doğal gazdan (%25,9) sağlanmaktadır. Elektrik tüketiminin önemli bir kısmı da elektrik

enerjisinden (%21,1) gelmektedir. Kömür ise elektrik tüketiminin %11,2'sini karşılamaktadır. Bu veriler, Türkiye'nin enerji portföyünün çeşitliliğini ve enerji kaynaklarının elektrik üretimindeki rolünü göstermektedir. Özellikle, petrol ve doğal gaz gibi fosil yakıtların hala elektrik üretiminde büyük bir paya sahip olduğu görülmektedir. Ancak, elektrik tüketiminin önemli bir kısmının elektrik enerjisi kaynaklarından da karşılandığı dikkate değerdir. Bu veriler, Türkiye'nin enerji arz güvenliğini sağlamak ve sürdürülebilirlik hedeflerine ulaşmak için YEK daha fazla benimsenmesi gerekliliğini vurgulamaktadır (IEA, 2024).




Şekil 2.13. Türkiye toplam elektrik tüketim dağılımı (IEA, 2024)

Türkiye'deki toplam enerji arzının gelişimini Şekil 2.14'te göstermektedir. Verilere göre, Türkiye'nin toplam enerji arzının büyük bir kısmı petrol (%28,8) ve doğal gaz (%27,4) gibi fosil yakıtlardan sağlanmaktadır. Kömür, enerji arzının %25,1'ini karşılar, yenilenebilir kaynaklar (rüzgâr, güneş vb.) ise %11,6'lık bir paya sahiptir. Bu veriler, Türkiye'nin enerji talebini karşılamak için halen fosil yakıtlara yoğun bir şekilde bağımlı olduğunu göstermektedir. Ancak, YEK payının artması, Türkiye'nin enerji arzında çeşitliliği artırma ve sürdürülebilir bir enerji geleceğine doğru ilerleme çabalarının bir yansımasıdır. Bu bağlamda, Türkiye'nin enerji politikalarının ve yatırımlarının, fosil yakıtlara olan bağımlılığı azaltma ve YEK teşvik etme yönünde daha da güçlendirilmesi önemlidir (IEA, 2024).



Şekil 2.14. Türkiye'deki toplam enerji arzının gelişimi (IEA, 2024)


Türkiye'de 2000'den 2022'ye kadar olan süreçte toplam enerji arzının değişimini Şekil 2.15'te göstermektedir. Verilere göre, bu dönemde enerji arzının en büyük bileşeni petrol olmuştur. Hemen altında doğal gaz gelmektedir, ardından kömür gelmektedir. Yenilenebilir kaynaklar olan rüzgâr ve güneş enerjisi gibi unsurlar da belirli bir paya sahiptir. Grafikte en alt sırada ise hidroelektrik enerji yer almaktadır. Bu veriler, Türkiye'nin enerji arzının çeşitliliğini ve kaynaklarının kullanımındaki değişimi göstermektedir. Özellikle, petrol ve doğal gaz gibi geleneksel kaynaklardan YEK doğru bir kayma olduğu görülmektedir. Bu eğilim, Türkiye'nin enerji tedarik güvenliğini artırmak ve çevresel sürdürülebilirliği desteklemek amacıyla yapılan politika ve yatırımların bir yansımasıdır (IEA, 2024).



Şekil 2.15. Türkiye'de 2000'den bu yana toplam enerji arzının değişimi (IEA, 2024)


Türkiye'de yurtiçi enerji üretiminin 2000 ile 2022 yılları arasındaki gelişimi Şekil 2.16'da gösterilmektedir. Verilere göre, yaklaşık 800.000 Terajul (TJ) civarında enerji üretimi sağlayan yenilenebilir kaynaklar olan rüzgâr ve güneş enerjisi gibi unsurlar grafikte en üst sırada yer almaktadır. İkinci sırada kömürden elde edilen enerji

gelmektedir. Grafikte en alt sıralarda ise yaklaşık 200.000 TJ civarında hidroelektrik enerji üretimi yer almakta olup, altında biyokütle ve atık (bio and waste) enerji kaynakları bulunmaktadır. Ayrıca, bu verilere göre 2014 ile 2022 yılları arasında, rüzgâr, güneş enerjisi ve diğer yenilenebilir kaynaklardan elde edilen enerji üretimi, yaklaşık 200.000 TJ'den 800.000 TJ'a yaklaşık dört kat artmıştır. Bu durum, Türkiye'nin enerji sektöründe yenilenebilir enerjiye yönelik artan yatırımlarının ve bu kaynakların kullanımının artmasıyla birlikte enerji üretimindeki değişimi ve dönüşümü yansıtmaktadır (IEA, 2024).



Şekil 2.16. Türkiye’de yurtiçi enerji üretiminin gelişimi (IEA, 2024)

Şekil 2.17, Türkiye’deki yurtiçi enerji üretimini 2022 yılına odaklanarak göstermektedir. Verilere göre, bu dönemde enerji üretiminin büyük bir kısmı yenilenebilir kaynaklardan gelmektedir; rüzgâr, güneş ve diğer yenilenebilir kaynaklar yaklaşık olarak %36,1’lik bir paya sahiptir. Kömür ise enerji üretiminin önemli bir kısmını oluşturmaktadır ve %33,3’lük bir paya sahiptir. Biyoyakıtlar ve atıklar da enerji üretiminde %10,7’lik bir paya sahipken, ham petrol ise %7,5’lik bir paya sahiptir. Bu veriler, Türkiye’nin enerji portföyünün çeşitlenmekte olduğunu ve yenilenebilir kaynaklara olan geçişin arttığını göstermektedir. Özellikle, kömürün hala önemli bir rol oynadığı ancak yenilenebilir kaynakların da giderek daha fazla önem kazandığı gözlemlenmektedir. Bu eğilim, Türkiye’nin enerji üretiminde çevresel etkileri azaltma ve enerji arz güvenliğini artırma çabalarının bir yansımasıdır (IEA, 2024).



Şekil 2.17. Türkiye’deki yurtiçi enerji üretimi 2022 yılı (IEA, 2024)

Ancak, mevcut altyapı eksiklikleri ve belirsizlikler sektörün büyümesini sınırlayabilir. Bu nedenle, Türkiye’deki rüzgâr enerjisi potansiyelini değerlendirirken ekonomik ve politik faktörlerin de dikkate alınması gerekmektedir. Rüzgâr enerjisi, temiz ve yenilenebilir bir enerji kaynağı olması sebebiyle giderek daha fazla ilgi görmektedir. Türkiye gibi rüzgâr potansiyeli yüksek olan ülkelerde, rüzgâr enerjisi, enerji üretiminde önemli bir rol oynamaktadır. Ancak, rüzgâr enerjisi santrallerinin verimli çalışabilmesi için rüzgâr hızının doğru bir şekilde tahmin edilmesi gerekmektedir. Bu noktada, ML ve DL gibi veri odaklı tekniklerin kullanılması, rüzgâr hızının tahmin edilmesinde önemli bir rol oynamaktadır.


2.2.2. Çanakkale İli ve Rüzgâr Enerjisi

Çanakkale, Türkiye’nin rüzgâr enerjisi potansiyeli açısından önemli bir role sahip olan illerinden biridir. Özellikle Gelibolu Yarımadası ve Biga Yarımadası gibi sahil bölgeleri, yüksek ve sürekli rüzgâr hızlarına sahiptir. Bu bölgelerdeki rüzgâr enerjisi potansiyeli, uluslararası standartlara uygun rüzgâr enerjisi santrallerinin kurulması için oldukça uygun koşullar sunmaktadır. Çanakkale’nin rüzgâr enerjisi potansiyeli, yerel ekonomiye de olumlu katkılarda bulunmaktadır. Rüzgâr enerjisi santrallerinin inşası ve işletilmesi, bölgede istihdamı artırarak ekonomik kalkınmaya katkı sağlamaktadır (Yılmaz, 2021; Balcıoğulları, 2020).

Şekil 2.18’de yer alan görselde mavi bölgelerde yıllık ortalama rüzgâr hızı yaklaşık 2 m/s iken, kırmızı bölgelerde bu hız 8,5 m/s’ye kadar yükselmektedir. Bu dağılım, Çanakkale bölgesindeki rüzgâr potansiyelinin farklılığını ve yerel iklim koşullarının çeşitliliğini göstermektedir. Mavi bölgelerde düşük rüzgâr hızları, enerji üretimi için uygun olmayabilirken, kırmızı bölgelerdeki yüksek rüzgâr hızları, rüzgâr enerjisi

potansiyelini artırabilir ve bu bölgelerde rüzgâr enerjisi santrallerinin kurulmasını teşvik edebilir. Bu veriler, rüzgâr enerjisi yatırımları ve planlaması için önemli bir rehber sağlamaktadır, çünkü farklı rüzgâr hızlarına sahip bölgelerde farklı enerji üretim stratejileri gerekebilir (ETKB, 2024).

YILLIK ORTALAMA RÜZGAR HIZI DAĞILIMI – 100 METRE



Şekil 2.18. Çanakkale yıllık ortalama rüzgâr hız dağılımı (ETKB, 2024)

Çanakkale'nin rüzgâr enerjisi potansiyelini değerlendirirken, çevresel etkiler de dikkate alınmalıdır. Rüzgâr enerjisi santrallerinin kurulması ve işletilmesi, doğal yaşamı ve yerel ekosistemleri etkileyebilir. Bu nedenle, Çanakkale'deki rüzgâr enerjisi projeleri sürdürülebilirlik ilkeleri doğrultusunda planlanmalı ve uygulanmalıdır. Buna ek olarak, yerel halkın ve çevre örgütlerinin görüşleri de projelerin tasarımı sürecinde önemlidir. Bu şekilde, Çanakkale'nin rüzgâr enerjisi potansiyelinden en iyi şekilde yararlanırken çevresel ve sosyal etkiler de minimize edilebilir.

2.2.3. Bozcaada, Ezine, Ayvacık ve Gökçeada'da Rüzgâr Enerjisi

Bozcaada, Ege Denizi'nde yer alan ve Türkiye'nin en büyük adası olan Bozcaada, rüzgâr enerjisi potansiyeli bakımından dikkat çekmektedir. Adanın konumu ve coğrafi özellikleri, sürekli ve güçlü rüzgârlarla karakterizedir. Bu nedenle, Bozcaada'da rüzgâr enerjisi santrallerinin kurulması ve işletilmesi için uygun bir ortam bulunmaktadır. Ancak, adanın doğal ve tarihi güzelliklerinin korunması da göz önünde bulundurulmalı ve rüzgâr enerjisi projeleri hassas bir şekilde planlanmalıdır.

Ezine, Çanakkale'nin önemli ilçelerinden biridir ve rüzgâr enerjisi potansiyeli açısından önemli bir role sahiptir. Özellikle ilçenin yüksek rakımlı bölgeleri, sürekli ve güçlü rüzgârlarla karakterizedir. Bu bölgelerde rüzgâr enerjisi santrallerinin kurulması

hem yerel ekonomiye katkı sağlayabilir hem de bölgenin enerji ihtiyacını karşılamaya yardımcı olabilir. Ancak, rüzgâr enerjisi projelerinin çevresel etkileri göz önünde bulundurularak planlanması önemlidir.

Ayvacık, Çanakkale'nin sahil ilçelerinden biridir ve rüzgâr enerjisi potansiyeli bakımından önemli bir role sahiptir. Özellikle ilçenin sahil bölgeleri, sürekli ve güçlü rüzgârlara maruz kalmaktadır. Bu nedenle, Ayvacık'ta rüzgâr enerjisi santrallerinin kurulması ve işletilmesi için uygun bir potansiyel bulunmaktadır. Ancak, rüzgâr enerjisi projelerinin doğal yaşamı ve yerel ekosistemleri olumsuz etkilememesi için dikkatli bir planlama yapılmalıdır. Gökçeada, Türkiye'nin en büyük ikinci adası olup, Ege Denizi'nde yer almaktadır. Gökçeada'nın coğrafi konumu, sürekli ve güçlü rüzgârlarla karakterizedir. Bu nedenle, adada rüzgâr enerjisi potansiyeli oldukça yüksektir. Gökçeada'da rüzgâr enerjisi santrallerinin kurulması ve işletilmesi, adanın enerji ihtiyacını karşılamaya ve yerel ekonomiye katkı sağlamaya yönelik önemli bir adım olabilir. Ancak, rüzgâr enerjisi projelerinin adanın doğal ve kültürel mirasını koruyacak şekilde planlanması önemlidir.


Bozcaada, Ezine, Ayvacık ve Gökçeada gibi Çanakkale'nin önemli ilçelerinde rüzgâr enerjisi potansiyeli oldukça yüksektir. Bu ilçelerin coğrafi konumları, sürekli ve güçlü rüzgârlarla karakterizedir ve bu da rüzgâr enerjisi santrallerinin kurulması için uygun bir ortam sunmaktadır. Özellikle sahil bölgeleri ve yüksek rakımlı alanlar, rüzgâr enerjisi projelerinin yoğunlaşabileceği potansiyel alanlardır. Ancak, bu projelerin planlanması ve uygulanması sürecinde çevresel etkilerin dikkate alınması önemlidir. Doğal yaşamı, yerel ekosistemleri ve kültürel mirası korumak için hassas bir denge sağlanmalıdır. Bu ilçelerdeki rüzgâr enerjisi projeleri, hem yerel ekonomiye katkı sağlayarak istihdamı artırabilir hem de bölgenin enerji ihtiyacını karşılamaya yardımcı olabilir. Ancak, sürdürülebilirlik ilkeleri doğrultusunda planlanmalı ve yerel halkın katılımı ve görüşleri dikkate alınmalıdır. Bu şekilde, rüzgâr enerjisi potansiyelinin en iyi şekilde değerlendirilmesi ve çevresel, ekonomik ve sosyal faydaların maksimize edilmesi mümkün olabilir.

2.2.4. Yıllık Ortalama Rüzgâr Hızı Dağılımı

Yıllık ortalama rüzgâr hızı dağılımı, belirli bir bölgede yıllık olarak ortalama rüzgâr hızlarının farklı zaman dilimlerindeki dağılımını gösterir. Bu dağılım, genellikle belirli bir yükseklik seviyesine (genellikle 100 metre) göre hesaplanır ve rüzgâr enerjisi

potansiyelini değerlendirmek için kullanılır. Yıllık ortalama rüzgâr hızı dağılımı, rüzgâr enerjisi projelerinin planlanması ve tasarımı için önemli bir parametre olarak kabul edilir. Yıllık ortalama rüzgâr hızı dağılımı, genellikle rüzgâr hızının belirli bir zaman dilimindeki istatistiksel dağılımını ifade eden bir grafik veya tablo şeklinde sunulur. Bu dağılım, belirli bir bölgedeki farklı rüzgâr hızlarının olasılıklarını gösterir ve genellikle belirli bir yıl veya uzun süreli veri setlerine dayanarak hesaplanır.

Türkiye'nin yıllık ortalama rüzgâr hız dağılımına ait olan Şekil 2.19'da, kıyı kesimlerinde rüzgâr hızı yoğunlukla 8,5 m/s civarında görülürken, iç kesimlere doğru gidildikçe bu hız ortalama 4 m/s'ye düşmektedir. Bu dağılım, Türkiye'nin farklı coğrafi bölgelerindeki rüzgâr potansiyelinin farklılığını göstermektedir. Kıyı bölgelerinde yüksek rüzgâr hızları, rüzgâr enerjisi potansiyelini artırırken, iç kesimlerde daha düşük rüzgâr hızları, enerji üretimi için daha zorlu koşullar sunabilir. Bu veriler, Türkiye'nin rüzgâr enerjisi potansiyelini değerlendirirken ve enerji politikalarını planlarken coğrafi faktörlerin önemini vurgulamaktadır. Özellikle, rüzgâr enerjisi yatırımlarının optimal konumlandırılması ve etkin bir şekilde kullanılması için coğrafi faktörlerin dikkate alınması gerekmektedir (ETKB, 2024).




Şekil 2.19. Türkiye yıllık ortalama rüzgâr hız dağılımı (ETKB, 2024)

Marmara bölgesinin yıllık ortalama rüzgâr hız dağılımına ait olan Şekil 2.20'de, Çanakkale bölgesinin yoğunluğunun kırmızı renge, yani 8,5 m/s'lik bir rüzgâr hızına işaret ettiği ve iç kesimlerde ise yer yer kırmızı bölgelerin görüldüğü gözlemlenmektedir. Bu durum, Marmara Bölgesi'nin genelinde rüzgâr hızının değişken olduğunu ve coğrafi olarak farklı bölgelerde farklı rüzgâr potansiyellerinin bulunduğunu göstermektedir. Çanakkale bölgesindeki yüksek rüzgâr hızları, rüzgâr enerjisi potansiyelini artırırken, iç

kesimlerdeki kırmızı bölgelerdeki yüksek hızlar da benzer bir potansiyelin varlığına işaret etmektedir. Bu veriler, Marmara Bölgesi'nin rüzgâr enerjisi üretimi için uygun bir potansiyele sahip olduğunu ve bu potansiyelin farklı coğrafi bölgelerde farklılık gösterdiğini göstermektedir. Bu bilgiler, rüzgâr enerjisi yatırımlarının planlanması ve uygulanmasında bölgesel farklılıkların dikkate alınmasına yardımcı olabilir (ETKB, 2024).


YILLIK ORTALAMA RÜZGAR HIZI DAĞILIMI – 100 METRE



Şekil 2.20. Marmara bölgesine ait yıllık ortalama rüzgâr hız dağılımı (ETKB, 2024)

Çanakkale iline ait Şekil 2.21’de yoğunluk genellikle sarı bölgelerde olsa da yer yer kırmızı bölgelerin de olduğu gözlemlenmektedir. Bu durum, Çanakkale ilindeki rüzgâr hızının genel olarak orta seviyelerde seyrettiğini ancak belirli bölgelerde yüksek rüzgâr hızlarının da mevcut olduğunu göstermektedir. Sarı bölgelerdeki rüzgâr hızları daha düşük olsa da bu bölgelerde de enerji üretim potansiyeli bulunmaktadır. Öte yandan, kırmızı bölgelerdeki yüksek rüzgâr hızları, Çanakkale ilinin rüzgâr enerjisi üretimi için önemli bir potansiyele sahip olduğunu işaret etmektedir. Bu veriler, Çanakkale ilinin rüzgâr enerjisi projeleri için uygun bir konum sağladığını ve bölgenin enerji üretimine katkıda bulunabileceğini göstermektedir. Bu bilgiler, bölgedeki rüzgâr enerjisi yatırımlarının planlanması ve geliştirilmesinde dikkate alınabilir (ETKB, 2024).

YILLIK ORTALAMA RÜZGAR HIZI DAĞILIMI – 100 METRE



Şekil 2.21. Çanakkale iline ait yıllık ortalama rüzgâr hız dağılımı (ETKB, 2024)

Yıllık ortalama rüzgâr hızı dağılımının incelenmesi, rüzgâr enerjisi potansiyelini daha doğru bir şekilde değerlendirmeye yardımcı olabilir. Bu dağılım, rüzgâr enerjisi projelerinin verimliliğini ve karlılığını belirlemek için kullanılan temel girdilerden biridir. Yüksek ortalama rüzgâr hızlarına sahip bölgeler genellikle daha fazla enerji üretim potansiyeline sahiptir, bu da rüzgâr enerjisi yatırımlarının bu bölgelere odaklanmasını teşvik eder.

2.3. Kaynak Özetleri

Demirgöl vd., (2024) tarafından gerçekleştirilen çalışmada Türkiye'nin farklı coğrafi bölgelerindeki solar radyasyonun tahmini incelenmiştir. 2004-2021 yılları arasındaki veriler kullanılarak MARS ve LSSVR gibi ML teknikleri uygulanmıştır. LSSVR yöntemi diğerlerine kıyasla daha yüksek başarı göstermiş ve geleneksel yöntemlerin yerine makine öğrenme algoritmalarının kullanılabilirliğini vurgulamıştır. Ayrıca, Yılmaz (2024) tarafından gerçekleştirilen çalışmada, 4,8 MW gücündeki bir rüzgâr türbininde yapay zekâ tabanlı arıza teşhisi üzerine araştırma yapılmıştır. Değişken çalışma koşullarına sahip olan rüzgâr türbin sistemleri için YSA yapısı arıza teşhisi için kullanılmıştır. Son olarak, Akkurt ve Sarıççek (2024) tarafından yapılan çalışmada, sırasıyla LSTM ve LightGBM gibi DL teknikleri kullanılarak üretim performansının ölçülmesi ve tahmin edilmesi amaçlanmıştır. LightGBM'nin LSTM'den daha iyi performans gösterdiği ortaya konmuştur.

Oğuz ve Pekin (2024) hava kirliliği tahmini üzerine yaptıkları çalışmada, çok katmanlı algılayıcı sinir ağı algoritmasının en iyi sonuçları verdiğini tespit etmişlerdir.

Korkmaz vd., (2024) ise rüzgâr enerjisi santrali için uygun sahaları belirlemek için Analitik Hiyerarşi Süreci (AHS) yöntemini kullanmışlardır. Sağ ve Hasırcı Tuğcu (2023) ise akıllı şebekelerde DL tekniklerinin kullanımını inceleyerek, bu tekniklerin şebekenin güvenilirliği, güvenliği ve dayanıklılığını artırabileceğini öne sürmüşlerdir.

Akgün ve Barlık (2023) çalışmasında Ardahan, Kars, Erzurum ve Iğdır illeri şehir merkezlerindeki hava kalitesi indeksi ile meteorolojik parametreler arasındaki ilişkiyi incelemiş ve HKİ'nin tahmini için çoklu doğrusal regresyon analizi ile ML yöntemlerini kullanmıştır. ML algoritmaları %68,91 ile %74,89 arasında doğruluk oranları sağlamıştır. Beyoğlu (2023) ise Balıkesir'deki bir güneş enerji santralinin verilerini kullanarak analitik ve DL yöntemleriyle iki model geliştirmiştir. Bu modeller, güneş enerji santralinin performansını optimize etmeyi amaçlamaktadır ve güneş enerjisi santrallerinin verimliliğini artırmak için literatüre katkıda bulunmayı hedeflemektedir.

Yıldırım vd., (2023) çalışması, NASA'nın ORNL DAAC web sitesinden alınan veri seti ile orman yangınlarını önceden tahmin etmeyi amaçlamaktadır. Altı farklı sınıflandırma algoritması kullanılarak oluşturulan modelde, Rasgele Orman ve Naive Bayes algoritmaları %97 ve %96 doğruluk oranlarıyla öne çıkmaktadır. Bu çalışma, orman yangınlarının tahmininde ML tekniklerinin etkinliğini göstererek literatüre önemli bir katkı sunmaktadır. Demirtop ve Işık (2023) çalışması, Çanakkale Bozcaada'dan alınan 2014 yılı rüzgâr verileri Weka ve MATLAB'da YSA modelleri ile karşılaştırılarak MATLAB'ın WEKA'dan daha iyi sonuçlar verdiği görülmüştür. Bu çalışmanın bulguları, YSA ve MATLAB'ın rüzgâr enerjisi alanında literatüre katkı sağlayabileceği ve diğer YEK da uygulanabileceği öngörülmektedir.

Altan ve Karasu (2020) çalışması, Marmara Bölgesi'nde rüzgâr hızı tahminini geliştirmek için ayrıştırma ve DL birlikte kullanılmasını inceliyor. Ayrıştırma yöntemleri ve LSTM ile derin öğrenmenin kombine edildiği modeller, tek başına LSTM'den daha iyi performans gösteriyor. En yüksek başarı ise topluluk ampirik kip ayrışımı ile elde ediliyor.

Sevinç ve Kaya (2021) çalışması, Diyarbakır'daki hava sıcaklığı tahmininde LSTM modelinin en yüksek doğrulukta tahmin sağladığını göstermektedir. Karabulut ve Topçu (2022) çalışması da Kars'ta hava sıcaklığı tahmini için DL yönteminin etkinliğini araştırıyor ve LSTM tabanlı modelin istatistiksel yöntemlerden daha doğru tahminler sağladığı görülüyor. Özkay, B. (2021) çalışmasında ise Bilecik'te rüzgâr hızı tahmini için eğitilen LSTM sinir ağlarının daha doğru tahminlerle karar vermeyi destekleyebileceği ortaya konmaktadır. Barış vd., (2021) Marmara Bölgesi'nde rüzgâr hızı tahminini

geliştirmek için DL ile ampirik kip ayrıştırma yöntemlerini birleştirmişlerdir. Sinüs dalgaları ve Fourier serisi gibi yöntemlerle rüzgâr hızındaki farklı frekans bileşenleri ayrıştırılarak DL modelinin başarımı arttırılmıştır. Bu çalışma, DL tabanlı rüzgâr hızı tahmin modellerinin doğruluğunu artırmak için ampirik kip ayrıştırmanın faydalı olabileceğini ortaya koyuyor.

Görgel ve Kavlak (2020), rüzgâr enerjisi üretimi tahmininde ML modeliyle şebeke dengesizliklerini azaltmayı ve kârı maksimize etmeyi amaçlamıştır. İzmir Urla'dan alınan rüzgâr hızı verisiyle geliştirilen hibrit ESA-UKSH yöntemi, en iyi tahmin doğruluğunu sağlayarak, rüzgâr enerjisinin daha verimli kullanılmasına katkı sunmuştur. Sevinç ve Kaya (2021) çalışması, DL ve istatistiksel modelleme yöntemlerinin sıcaklık tahminindeki performansını karşılaştırmıştır. Bingöl, Solhan'dan alınan verilerle yapılan çalışmada, Uzun Kısa Süreli Hafıza (UKH) modelinin, ARIMA'dan daha iyi performans göstererek sıcaklık tahminlerinde DL potansiyelini vurgulamıştır. Singh vd., (2024) çalışması ise rüzgâr enerjisi üretim tahmininde MLnin potansiyelini ortaya koymak için CNN ve LSTM modellerinin hibrit yapısını kullanarak yüksek tahmin doğruluğu elde etmiştir.

Meddage vd., (2024), yüksek binalarda rüzgâr yükü tahminlerini hassaslaştırmak için ML kullanmıştır. Üç boyutlu geçici rüzgâr basıncını modellemek için ML daha ayrıntılı sonuçlar elde etmişlerdir. XGBoost modeli, rüzgâr tüneli testleri verilerini kullanarak akış zamanı boyunca rüzgâr basıncını başarıyla tahmin etmiştir. Huang ve Huang (2024) çalışması, rüzgâr enerjisi tahmini ve risk değerlendirmesine "yeşil öğrenme" adı verilen çevre dostu bir yaklaşım sunmuştur. Bu metod, enerji verimliliği ve sürdürülebilirlik ilkelerine dayanarak ML modellerini kullanmaktadır.

Hanifi vd., (2024) çalışmasında, rüzgâr enerjisi tahmin modellerinin doğruluğunu ve hızını arttırmak için literatürde ilk kez rastgele başlatma özellikleri incelenerek üç gelişmiş hiperparametre optimizasyon tekniği karşılaştırılmıştır. Mollick, vd., (2024) çalışması, kıyı bölgelerinde rüzgâr enerjisi santrallerinin performansını optimize etmek için ML algoritmalarının etkinliğini araştırmıştır. Farklı ML algoritmalarının rüzgâr hızını tahmin etmedeki doğruluğunu karşılaştıran çalışma, rastgele ormanların en yüksek performansı gösterdiğini ve rüzgâr santrallerinin güvenilirliği ve saha seçimi için en uygun olduğunu bulmuştur. Mohd ve Singh (2024), ML ile rüzgâr santrallerinin üretimini optimize ederek gelecekteki rüzgâr gücünü tahmin ediyorlar. SVR modeli sayesinde rüzgâr hızı ve hava durumu verilerinden yola çıkarak daha fazla temiz enerji üretimi ve sürdürülebilir bir gelecek için yenilenebilir enerji entegrasyonuna katkı sağlıyorlar.

Moreno vd., (2024), rüzgâr hızı tahminlerinin doğruluğunu artırmak için ML tekniklerini sinyal ayrıştırma yöntemleriyle birleştirerek hibrit bir yaklaşım geliştiriyorlar. Brezilya'daki bir rüzgâr çiftliğinden elde edilen veriler üzerinde test edilen bu hibrit model, geleneksel ML yöntemlerine göre %30'a kadar hata azalması sağlayabiliyor.

Sun vd., (2024), kısa vadeli rüzgâr hızı tahminlerini geliştirmek için istatistiksel yöntemler kullanıyorlar. Random Forest ve SVM gibi teknikler doğrudan tahmin stratejisiyle birlikte kullanıldığında yüksek doğruluk sağlıyor ve olasılıksal son işleme ile tahminlerin güvenilirliğini artırarak rüzgâr enerjisi ve diğer alanlarda daha iyi karar vermeyi mümkün kılıyorlar. Subrahmayam vd., (2024), hava sistemlerini anlamak için zonal rüzgârları tahmin etmek için ML algoritmalarını araştırıyorlar. Farklı ML algoritmalarının performansını karşılaştıran çalışma, zonal rüzgârlarını tahmin etmede geleneksel yöntemlere kıyasla daha iyi sonuçlar verdiğini gösteriyor. Tarek vd., (2023), rüzgâr santrallerinin verimliliğini optimize etmek için ML ve DL modellerini araştırıyorlar. Bu modeller, rüzgâr hızı, hava durumu ve üretim verileri kullanılarak eğitilmiş ve geleneksel yöntemlere kıyasla daha iyi performans göstermiştir.

Rodríguez vd., (2023), çok kısa vadeli rüzgâr hızı tahminleri için zaman-frekans analizi ve ML algoritmalarını birleştiren bir ensemble modeli geliştiriyorlar. Bu model, rüzgâr enerjisi tesislerinin verimliliğini artıracak etkili tahminler sunuyor. Karaman (2023), çoklu hedefli öngörü modelleri kullanarak rüzgâr enerjisi tahminlemesini gerçekleştiriyor. YSA, RNN, CNN ve LSTM ağları gibi çeşitli ML yöntemleri kullanarak başarılı tahminler elde ediyorlar. Hao vd., (2023), kentsel enerji sistemlerinde rüzgâr hızı tahminlemesi için DL ile birleştirilmiş bir strateji temelinde yeni bir model geliştirmiştir. Yöntem bölümünde, kullanılan DL stratejileri ve diğer tahmin teknikleri ayrıntılı olarak ele alınmıştır ve modelin oluşturulması ve eğitilmesi süreci detaylı olarak incelenmiştir.

Sri Preethaa vd., (2023), rüzgâr akış deseni tahminlemesi için kullanılan ML tekniklerini kapsayan kapsamlı bir derleme sunarak farklı ML yöntemlerinin rüzgâr akış deseni tahminlemesindeki uygulanabilirliğini ve etkinliğini incelemiştir. Benti vd., (2023), ML ve DL tekniklerinin kullanılarak yenilenebilir enerji üretiminin tahminlenmesindeki mevcut ilerlemeleri ve gelecek perspektiflerini incelemiştir, mevcut araştırmaların kapsamını ve gelecek araştırma yönelimlerini belirlemeyi amaçlamıştır. Wazirali vd., (2023), yapay sinir ağları, ML ve DL teknikleri kullanılarak mikro şebekelerde enerji ve yük tahminlemesi üzerine mevcut durumu inceleyerek literatürdeki mevcut yöntemlerin kapsamını ve uygulanabilirliğini değerlendirmiştir.

Tyass vd., (2023), istatistiksel ve DL modellerine dayalı olarak rüzgâr hızı tahminlemesini karşılaştırmış ve her iki yaklaşımın tahmin performansını değerlendirmiştir. BenMoshe vd., (2023) ise kentsel alanlardaki rüzgâr akışını tahmin etmek için ML kullanmış ve farklı ML algoritmalarının kentsel rüzgâr akışı tahminindeki etkinliğini değerlendirmiştir. Zhou vd., (2023), ızgara verilerini kullanarak siteye özgü rüzgâr hızlarını tahmin etmeyi amaçlayan ve çeşitli ML modellerini karşılaştıran bir çalışma yapmıştır. Zheng vd., (2023), rüzgâr enerjisi dönüşüm sistemleri için rüzgâr hızı tahmininin önemini vurgulayarak bir dağlık alandaki rüzgârlı bir şehirden elde edilen verilerle gerçekleştirilen bir çalışmada çekirdek ridge regresyon modelini önermiş ve bu modelin etkinliğini diğer referans modellerle karşılaştırmıştır.

Singh ve Rizwan (2023) ise kısa vadeli rüzgâr enerjisi üretiminin tahmin doğruluğunu artırmak için ML tekniklerini kullanarak bir çalışma gerçekleştirmiştir. Wood (2023), son saatlerdeki meteorolojik koşullardaki değişiklikleri yakalayarak, bireysel rüzgâr çiftliklerinden gelen rüzgâr enerjisi üretim tahminlerine yardımcı olmak için yeni bir özellik ortalaması tekniği geliştirmiştir.

Alkabbani vd., (2023), Ontario, Kanada'daki bölgesel rüzgâr enerjisi için zaman serisi tahmininde çeşitli ML algoritmalarını kullanmış ve SVR/SVM'nin en umut verici tahmin modeli olduğunu göstermiştir. Liu vd., (2023) ise rüzgâr türbini göbek yüksekliğindeki rüzgâr hızının tahmin edilmesinde rastgele orman (RF) ML algoritmasının geleneksel güç yasası yönteminden daha doğru olduğunu bulmuştur. Fang vd., (2023), Hangzhou, Zhejiang Eyaleti, Çin'deki otomatik meteoroloji istasyonlarında kısa vadeli rüzgâr hızı tahmininde yanlışlığın düzeltilmesi için WSFBC-XGB adlı bir XGBoost ML modeli kullanmıştır. Modelin geleneksel MOS yöntemine göre daha iyi performans gösterdiği ve rüzgâr hızı tahminlerindeki hataları azalttığı bulunmuştur. Wang vd., (2023), belirsizlikleri ele alan bir olasılık tahmin sistemi önermiş ve DL modeliyle birlikte yeni bir çoklu amaçlı kombinasyon stratejisi geliştirmiştir. Rababaah (2023), rüzgâr türbinlerinin sağlık durumunu izlemeye yönelik DL çözümlerinin nadir olduğunu ve CNN modelinin diğer geleneksel ML modellerinden daha etkili olduğunu belirtmiştir.

3. MATERYAL VE YÖNTEM

3.1. Veri Seti Tanımı


Rüzgâr enerjisi, bölgedeki coğrafi yapı ve rüzgâr hareketiyle yakından ilişkilidir (Li vd., 2020). Çanakkale'nin rüzgâr enerjisi potansiyeli, özellikle sahil şeridinde ve adalarda bulunan rüzgâr çiftlikleriyle dikkate değerdir. Bölgenin düzenli ve güçlü rüzgârları, rüzgâr enerjisi üretimini destekleyen bir ortam oluşturur. Bu durum, bölgenin YEK özellikle rüzgâr enerjisinden yararlanma potansiyelini artırır. Bu nedenle, meteorolojik verilerin analizi, bölgedeki rüzgâr enerjisi potansiyelini belirlemede ve rüzgâr enerjisi projelerinin planlanmasında önemli bir rol oynar. Bölgenin coğrafi yapısı, rüzgârın hareketini önemli ölçüde etkileyen bir faktördür. Çanakkale, genellikle kıyı bölgeleri ve adalardan oluşan bir yapıya sahip olduğu için, deniz ve karasal hava kütlelerinin etkileşimi rüzgâr oluşumunu belirleyen önemli bir unsurdur. Bu coğrafi konum, rüzgârın yönünü, hızını ve karakterini etkileyen karmaşık bir yapı oluşturur. Bölgedeki topografik farklılıklar ve jeolojik yapılar da rüzgâr hareketini şekillendiren diğer önemli faktörler arasında yer almaktadır. Bu nedenle, bölgedeki meteorolojik verilerin analizi, coğrafi yapıların ve jeolojik özelliklerin rüzgâr oluşumu ve hareketi üzerindeki etkilerini daha iyi anlamamıza yardımcı olabilir (Bakırov ve Aslan, 2023).

Çanakkale iline bağlı Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerine ait meteoroloji genel müdürlüğünden elde edilen veriler, 2014 ile 2021 yılları arasındaki dönemi kapsamaktadır (DMİ, 2022). Bu veriler, günlük ortalama rüzgâr hızı, nem, basınç ve sıcaklık gibi meteorolojik parametreleri içermektedir (Çizelge 3.1). Analizde kullanılan veriler, her bir ilçe için ayrı ayrı incelenmiş ve hem grafiklerle hem de tablolarla sunulmuştur.


Çizelge 3.1. Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerine ait günlük ortalama değerler

Ayvacık					Bozcaada				
Sıra	Nem(%)	Basınç(hPa)	Sıcaklık(°C)	Hız(m/sn)	Sıra	Nem(%)	Basınç(hPa)	Sıcaklık(°C)	Hız(m/sn)
0	81,8	1007,0	11,6	3,0	0	81,3	1009,8	13,8	4,4
1	87,9	1006,2	13,5	4,8	1	84,5	1007,9	13,9	6,9
2	83,9	1003,9	13,4	5,0	2	83,9	1006,7	14,2	4,5
3	88,5	1008,4	13,4	3,9	3	85,2	1007,0	13,7	4,3
4	84,5	1011,5	13,3	3,4	4	87,5	1012,0	12,5	6,1
...	...	...	...	...	...	...	...	...	...
2511	72,5	1019,3	10,2	3,6	2849	73,3	1023,4	17,2	6,9
2512	71,0	1025,4	6,6	3,7	2850	71,4	1019,7	17,8	6,7
2513	84,0	1030,0	5,4	6,6	2851	79,8	1018,3	19,2	11,1
2514	91,7	1029,4	10,0	4,2	2852	90,6	1019,5	18,3	9,3
2515	82,6	1024,9	13,8	4,8	2853	82,6	1017,7	16,0	5,4


Ezine					Gökçeada				
Sıra	Nem(%)	Basınç(hPa)	Sıcaklık(°C)	Hız(m/sn)	Sıra	Nem(%)	Basınç(hPa)	Sıcaklık(°C)	Hız(m/sn)
0	84,8	1012,7	7,6	8,5	0	98,5	1014,7	6,2	4,8
1	89,4	1007,5	6,0	5,4	1	99,0	1012,7	7,4	4,0
2	87,1	1008,9	5,8	4,2	2	99,0	1013,5	8,5	3,1
3	89,8	1016,0	4,6	9,8	3	98,9	1016,0	8,9	2,5
4	95,2	1018,3	4,6	7,3	4	97,1	1014,9	8,8	1,8
...	...	...	...	...	...	...	...	...	...
2845	78,0	1014,1	19,9	6,2	2816	74,7	1012,2	17,2	2,5
2846	80,4	1016,1	18,0	8,7	2817	68,8	1013,7	17,4	4,2
2847	86,7	1018,3	20,6	4,3	2818	82,1	1012,2	12,5	2,3
2848	92,4	1018,4	19,5	3,2	2819	76,7	1013,5	12,0	1,8
2849	82,7	1018,2	19,9	2,7	2820	93,0	1013,4	12,9	4,4




Şekil 3.1. Ayvacık ilçesine ait normalize edilmiş meteorolojik verilerin zamana göre değişim grafiği



Şekil 3.2. Bozcaada ilçesine ait normalize edilmiş meteorolojik verilerin zamana göre değişim



Şekil 3.3. Ezine ilçesine ait normalize edilmiş meteorolojik verilerin zamana göre değişim



Şekil 3.4. Gökçeada ilçesine ait normalize edilmiş meteorolojik verilerin zamana göre değişim

İlgili veriler, her bir parametre için belirli bir süre boyunca toplanmış ve günlük ortalama değerler halinde kaydedilmiştir. Bu süreçte, Ayvacık, Bozcaada, Ezine ve

Gökçeada ilçelerine ait meteorolojik ölçümler yapılmış ve elde edilen verilerin doğruluğu titizlikle kontrol edilmiştir. Sonuçlar, belirli bir dönemde söz konusu ilçelerdeki hava koşullarının genel özelliklerini yansıtmaktadır (Şekil 3.1, Şekil 3.2, Şekil 3.3, Şekil 3.4). Analiz sonuçları, her bir parametrenin zaman içindeki değişimini görsel olarak sunan grafiklerle desteklenmiştir. Ayrıca, bu verilerin daha ayrıntılı bir şekilde incelenmesini sağlamak amacıyla tablolar oluşturulmuştur. Bu tablolar, her bir ilçe için günlük ortalama rüzgâr hızı, nem, basınç ve sıcaklık değerlerini detaylı bir şekilde göstermektedir. Bu veriler, ilgili meteorolojik parametrelerin incelenmesi ve gelecekteki analizler için önemli bir kaynak oluşturmaktadır.

3.2. Python Programlama Dili

Araştırma metodolojisi, bütün analizlerin yürütülmesinde temel araç olarak Python'a kök salmıştır (Subasi, 2020). Python'un esnekliği ve geniş kütüphaneleri, veri manipülasyonunun karmaşık yönleri, keşifsel veri analizi (KVA) ve modelleme gibi işlemleri ele almak için ideal bir seçim yapar (Arslan, 2019).


Başlangıçta, Python, veri işlemenin kritik aşamasını kolaylaştırır. Çeşitli Python kütüphaneleri aracılığıyla, veri kümesi titiz temizleme süreçlerinden geçer. Eksik değerler ele alınır, aykırı değerler işlenir ve gereksiz veya ilgisiz veri noktaları kaldırılır. Bu hazırlık adımı, veri kümesinin bütünlüğünü ve kalitesini sağlayarak, sonraki analizler için sahneyi hazırlar. Ardından gelen aşama, Python'un yeteneklerinden yararlanarak veri keşfi analizine derinlemesine iner. Pandas, Matplotlib ve Seaborn gibi Python kütüphaneleri, dağılımları görselleştirmek, ilişkileri belirlemek ve anormallikleri tespit etmek için önemli rol oynar. Bu görsel temsiller, veri kümesinin temel özelliklerini, ilişkilerini ve potansiyel desenlerini anlamada yardımcı olur (Demirtaş vd., 2019).

KVA'nın ardından, metodoloji, bir sinir ağı kullanarak tahmin modellemeye ilerler. Python'un Tensor Flow veya Keras gibi kütüphaneleri genellikle sinir ağı modelini oluşturmak ve eğitmek için kullanılır. Ağın mimarisi, eğitim parametreleri ve optimizasyon teknikleri dikkatlice Python içinde yapılandırılır, bu da modelin veri kümesinde yer alan karmaşık desenleri öğrenmesini ve çıkarmasını sağlar. Metodolojinin zirvesi, etkileşimli bir Python dosyasında özetlenmiştir (.ipynb). Bu dosya, sadece yürütülebilir kodu değil, aynı zamanda sinir ağı modelinin performansına ve analizden elde edilen içgörülere dair detaylı belgeleri ve yorumları da içerir. Bu etkileşimli dosya, okuyucuların araştırma sürecini keşfetmelerini, modelin davranışını anlamalarını ve elde edilen sonuçları tam olarak anlamalarını sağlayan şeffaf ve erişilebilir bir platform olarak

hizmet eder (Sahoo vd., 2019). Bu metodolojik yolculuk boyunca, Python, araçlar ve işlevselliklerin zengin ekosistemi sunarak köşe taşı görevini üstlenir. Veri işleme, keşif analizi, modelleme ve belgeleme boyunca sorunsuz entegrasyonu, simülasyonların, analizlerin yürütülmesi ve bulguların sunulması için sağlam ve şeffaf bir çerçeve sağlar (Sevli, 2021). Python programıyla kullanılan modeller LSTM, XGBoost, KNN, Karar Ağacı, SVR, GRU, YSA ve CNN olarak uygulanmıştır.

3.3. Modelin Tanımı

Veri bilimi ve ML uygulamalarında kullanılan çeşitli algoritmaların bir iş akışı tablosu, model geliştirme sürecinin yönlendirilmesinde büyük önem taşır. Şekil 3.5, veri yükleme ve hazırlama adımlarından başlayarak, veri keşfi, model seçimi, model eğitimi, doğrulama ve sonuçların değerlendirilmesi gibi adımları kapsar. LSTM, XGBoost, KNN, Karar Ağacı, SVR, GRU, YSA ve CNN gibi çeşitli algoritmaların bu iş akışı içindeki rol ve sıralaması, her bir algoritmanın özelliklerine, veri setinin yapısına ve problem bağlamına bağlı olarak belirlenir. Örneğin, zaman serisi veri setlerinde LSTM ve GRU gibi RNN modelleri tercih edilirken, yapısal verilerle çalışırken Karar Ağacı veya XGBoost gibi ağaç tabanlı modeller daha etkili olabilir (Hanifi vd., 2024; Liv vd., 2022). Her bir algoritmanın avantajları, dezavantajları ve uygun kullanım senaryoları göz önünde bulundurularak, iş akışı tablosu, veri bilimi projelerinde model seçimi ve uygulama aşamalarının yönetiminde önemli bir araç olarak kullanılır. Şekil 3.5, veri bilimi uygulayıcılarına, doğru algoritma seçimi ve model geliştirme sürecinin adımlarını belirleme konusunda rehberlik eder.



Şekil 3.5. LSTM, XGBoost, KNN, Karar Ağacı, SVR, GRU, YSA ve CNN ait iş akış şeması

3.3.1. Uzun Kısa Süreli Bellek

Uzun Kısa Süreli Bellek (Long Short-Term Memory- LSTM), DL alanında RNN'lerin bir türü olarak öne çıkmıştır. Geleneksel RNN'lerin karşılaştığı "uzun vadeli bağımlılık sorunu"nun üstesinden gelmek amacıyla geliştirilmiştir. Bu model, uzun süreli bağımlılıkları işlemek için özel bir bellek hücresi yapısına sahiptir ve bu sayede zaman serileri gibi zamanla değişen verilerin daha etkili bir şekilde analiz edilmesine olanak tanır (Singh ve Gupta, 2024; Hanifi vd., 2024).

LSTM'in tezde kullanılacağı potansiyel alanlardan biri, rüzgâr hızı tahminidir. Bu tahminler genellikle sıcaklık, basınç ve nem gibi hava durumu parametreleriyle ilişkilendirilir. LSTM, bu parametrelerin bir araya getirilmesi ve geçmiş verilerin analizi yoluyla gelecekteki rüzgâr hızını tahmin etmek için kullanılabilir. Çizelge 3.2'de LSTM modeline ait algoritma adımları verilmiştir.

Çizelge 3.2. LSTM modeline ait algoritma adımları

Adım	İşlem
1	Kütüphanelerin içe aktarılması: numpy, pandas, matplotlib, keras, sklearn
2	Veri setinin CSV dosyasından okunması ve gereksiz sütunların kaldırılması
3	Hız, nem, sıcaklık ve basınç sütunlarının seçilmesi
4	Verilerin normalizasyonu (MinMaxScaler kullanılarak)
5	Veri hazırlama fonksiyonunun tanımlanması (bağımsız ve bağımlı değişkenlerin ayarlanması)
6	Adım sayısının belirlenmesi ve eğitim/test verilerinin hazırlanması
7	LSTM modelinin oluşturulması (girdi katmanı, gizli katmanlar, çıkış katmanı)
8	Modelin derlenmesi (loss fonksiyonu ve optimizör belirlenmesi)
9	Modelin eğitilmesi (eğitim verileriyle fit işlemi)
10	Tahminlerin yapılması (test verileri üzerinde predict işlemi)
11	Tahminlerin tersine çevrilmesi (normalizasyonun tersi işlemi)
12	Sonuçların görselleştirilmesi (gerçek ve tahmin edilen değerlerin karşılaştırılması)
13	Performans metriklerinin hesaplanması (RMSE, MAE, MAPE, R-kare)

Şekil 3.6’da LSTM rüzgâr hız tahmin modeli akış şeması verilmiştir. Tezin birinci adımı, rüzgâr hızı tahmini için gerekli verilerin toplanmasıdır. Bu veriler genellikle meteorolojik istasyonlardan elde edilen zaman serilerini içerir. Bu zaman serileri, rüzgâr hızı ölçümleri ile birlikte sıcaklık, basınç ve nem gibi hava durumu verilerini içerir.

İkinci adım, toplanan verilerin ön işlenmesidir. Bu aşamada, veriler normalize edilir, eksik değerler doldurulur ve gereksiz özellikler çıkarılır. Ön işleme adımı, veri setinin model eğitimi için uygun hale getirilmesini sağlar.

Üçüncü adım, LSTM modelinin oluşturulmasıdır. Bu model, önceden işlenmiş hava durumu verilerini alacak ve geçmiş veri noktalarından gelecekteki rüzgâr hızını tahmin etmek için eğitilecektir.

Dördüncü adımda, model eğitilir ve değerlendirilir. Eğitim verileri, modelin belirli bir zaman dilimindeki performansını ölçmek için kullanılır. Bu aşamada, eğitim verilerinin bir kısmı modelin eğitimi için kullanılırken, diğer bir kısmı modelin performansının değerlendirilmesi için ayrılır.

Son adımda, eğitilen model kullanılarak gelecekteki rüzgâr hızı tahminleri yapılır. Bu adım, modelin gerçek dünya koşullarında ne kadar etkili olduğunu değerlendirmek için önemlidir.

Çeşitli akademik çalışmalarda yer alan LSTM ile ilgili yazılar incelendiğinde, Singh, Jha ve Gupta (2024) çalışması rüzgâr enerjisi alanındaki verimlilik sorunlarına odaklanarak önemli bir katkı sağlamıştır. Bu çalışmada, rüzgâr hızının değişkenliği nedeniyle zorlu olan üretim tahminini çözmek için ML kullanılmıştır. CNN ve LSTM modellerinin birleşiminden oluşan hibrit bir yapı ile yüksek tahmin doğruluğu elde edilmiş ve rüzgâr enerjisi tahmininde ML potansiyeli gösterilmiştir. Hanifi vd., (2024) tarafından yapılan çalışma ise rüzgâr enerjisi tahmin modellerinin doğruluğunu ve hızını artırmak için rastgele başlatma özelliklerinin üç farklı gelişmiş hiperparametre optimizasyon tekniği ile karşılaştırıldığı ilk çalışmadır. Bu çalışmanın sonuçları, Optuna'nın en etkili yöntem olduğunu ve Hyperopt ile optimize edilen LSTM modelinin en doğru tahminleri sağladığını göstermektedir. Bu durum, gelişmiş hiperparametre optimizasyonunun rüzgâr enerjisi tahmin modellerinin performansını önemli ölçüde artırabileceğini göstermektedir. Karaman (2023) tarafından gerçekleştirilen çalışmada, çeşitli ML yöntemlerinin kullanıldığı ve rüzgâr enerjisi tahminlemesinin gerçekleştirildiği bir çalışma yer alıyor. İki farklı veri seti birleştirilerek tahminleme yapılmış ve sonuçlar, LSTM, RNN, CNN ve ANN gibi algoritmaların etkili tahminler gerçekleştirdiğini ortaya koymuştur. Alkabbani vd., (2023) tarafından yapılan çalışmada ise Ontario, Kanada'daki bölgesel rüzgâr enerjisi için zaman serisi tahmininde çeşitli ML algoritmaları kullanılmıştır. Bu çalışma, SVR/SVM'nin en umut verici tahmin modeli olduğunu göstermiştir. Bu çalışmalar, rüzgâr enerjisi tahmini alanında LSTM'in önemli bir rol oynadığını ve ML yöntemlerinin kullanımının tahmin modellerinin doğruluğunu artırabileceğini göstermektedir.

3.3.2. Aşırı Gradyan Artırma

Aşırı Gradyan Artırma (Extreme Gradient Boosting -XGBoost), gradient boosting tekniğinin sofistike ve etkili bir uygulamasıdır. Ayrıca "extreme Gradient Boosting" olarak da bilinen bu model, denetimli ML uygulamalarında kullanılır. Olağanüstü performansı, verimliliği ve yapılandırılmış verilerin yönetimi konusundaki esnekliği ile tanınır ve bu özellikler geniş çapta kabul görmüştür (Meddage vd., 2024).

Temel olarak, XGBoost, daha az başarılı öğrencilerden (çoğunlukla karar ağaçları) elde edilen sonuçları entegre ederek güçlü ve güvenilir bir tahmin modeli geliştirmek için bir artırma stratejisidir. Bu, her biri önceki modellerin ürettiği hataları düzeltmeye odaklanan yeni modellerin yinelenmeli bir şekilde eğitilmesiyle gerçekleştirilir, böylece toplam tahmin kapasitesi giderek artar (Wan vd., 2024).

XGBoost'un daha gelişmiş bir düzenleme stratejisi ve dağıtılmış bir hesaplama mimarisi kullanması nedeniyle, özellikle büyük ölçekli veri kümelerini işlemek için kullanışlıdır. Bu, daha geleneksel gradient boosting yöntemlerinden farklıdır, çünkü bu özellikleri kullanmazlar.

Bu yöntem, veri içindeki karmaşık etkileşimleri yönetme esnekliği ve çeşitli veri türleriyle başa çıkma yeteneği nedeniyle sınıflandırma, regresyon ve sıralama gibi çeşitli görevler için tercih edilen bir seçenektir.

XGBoost'un hızının artması ve performansı optimize etme yeteneği, veri bilimcileri ve ML uygulayıcılarının araç çantasındaki önemli bir araç olarak ortaya çıkmasını sağlamıştır. Bu da tahminsel modelleme ve veri analizinin ilerlemesine önemli katkıda bulunmuştur. Çizelge 3.3'te XGBoost modeline ait algoritma adımları gösterilmiştir.

Çizelge 3.3. XGBoost modeline ait algoritma adımları

Adım	İşlem
1	Kütüphanelerin içe aktarılması: numpy, pandas, matplotlib, keras, sklearn
2	Veri setinin CSV dosyasından okunması ve gereksiz sütunların kaldırılması
3	Hız, nem, sıcaklık ve basınç sütunlarının seçilmesi
4	Verilerin normalizasyonu (MinMaxScaler kullanılarak)
5	Veri hazırlama fonksiyonunun tanımlanması (bağımsız ve bağımlı değişkenlerin ayarlanması)
6	Adım sayısının belirlenmesi ve eğitim/test verilerinin hazırlanması
7	XGBoost regresyon modelinin tanımlanması
8	Modelin eğitilmesi (eğitim verileriyle fit işlemi)
9	Tahminlerin yapılması (test verileri üzerinde predict işlemi)
10	Tahminlerin tersine çevrilmesi (normalizasyonun tersi işlemi)
11	Sonuçların görselleştirilmesi (gerçek ve tahmin edilen değerlerin karşılaştırılması)

Kullanılan modelde, günlük ortalama rüzgâr hızı verilerini kullanarak XGBoost regresyon modeli oluşturur. İlk olarak, veri seti okunur ve hız, nem, sıcaklık ve basınç sütunları seçilir. Ardından, veriler normalize edilir ve bağımsız ve bağımlı değişkenler hazırlanır. Eğitim ve test verileri, belirli bir adım sayısı ile hazırlanır. Daha sonra, XGBoost regresyon modeli tanımlanır ve eğitilir. Model eğitildikten sonra, test veri seti üzerinde tahminler yapılır ve gerçek değerlerle karşılaştırılır. Tahminlerin gerçek değerlerle karşılaştırılmasıyla kök ortalama kare hata (Root Mean Square Error-RMSE), ortalama mutlak hata (Mean Absolute Error-MAE), ortalama mutlak yüzde hata (Mean

Absolute Percentage Error -MAPE) ve R-kare (Coefficient of determination) hesaplanır. Şekil 3.7’de XGBoost rüzgâr hız tahmin modeli akış şeması verilmiştir.

XGBoost, her yeni ağacın, toplu tahminin negatif gradyanına uygun şekilde eğitildiği gradyan artırma tekniğini kullanır. Bu süreç, her yeni ağacın, önceki ağaçların kombinasyonel tahminlerinin yaptığı hataları azaltmak amacıyla yinelemeli olarak gerçekleştirilir. Detaylı denklemler ve optimizasyon adımları karmaşıktır, ancak temel fikir, ağaçları sırayla ekleyerek ve katkılarını toplam kayıp ve düzenleme içinde değerlendirerek amaç fonksiyonunu optimize etmektir. XGBoost’un hızlı, doğruluğu ve esnekliği, çeşitli ML uygulamalarında popüler bir tercih olmasını sağlar (Asselman vd., 2023).

Çeşitli akademik çalışmalarda yapılan araştırmalar, rüzgâr enerjisi tahmininde ML tekniklerinin kullanımını ve bu tekniklerin rüzgâr enerjisi alanında sağladığı potansiyeli vurgulamaktadır. Meddage vd., (2024), yüksek binalarda rüzgâr yükü tahminlerini daha hassas hale getirmek amacıyla ML kullanmıştır. Geleneksel yöntemler, genellikle tek boyutlu tahminlerle sınırlı kalırken, bu çalışma üç boyutlu geçici rüzgâr basıncını modellemek için ML devreye sokarak daha detaylı sonuçlar elde etmiştir. Rüzgâr tüneli testleri verileri üzerinde eğitilen bir XGBoost modeli, akış zamanı boyunca rüzgâr basıncını başarıyla tahmin etmiştir. Bu yenilikçi yaklaşım, rüzgâr mühendisliğinde daha güvenli ve ayrıntılı rüzgâr yükü tahminlerine olanak sağlamaktadır. Fang vd., (2023) tarafından gerçekleştirilen çalışmada ise Hangzhou, Zhejiang Eyaleti, Çin’deki otomatik meteoroloji istasyonlarında kısa vadeli rüzgâr hızı tahminindeki yanlılığın düzeltilmesi için WSFBC-XGB adlı bir XGBoost ML modeli kullanılmıştır. WSFBC-XGB modelinin, geleneksel MOS yöntemine göre daha iyi performans sergilediği ve rüzgâr hızı tahminindeki hataların azaltıldığı gözlemlenmiştir. Bu modelin, kısa vadeli rüzgâr hızı tahminlerinin doğruluğunu artırarak büyük ölçekli açık hava etkinliklerine destek sağlayabileceği belirtilmiştir.

3.3.3. K-en Yakın Komşuluk

K-en Yakın Komşuluk (k-Nearest Neighbor- KNN), veri noktalarının özelliklerine dayalı olarak bir uzaklık metriği kullanarak benzerliklerini ölçer. Bir tahmin yapmak için, bilinmeyen bir nokta ile diğer tüm noktalar arasındaki uzaklıklar hesaplanır ve en yakın k komşular seçilir. Sınıflandırma problemlerinde, bu k komşuların etiketleri üzerinde bir oylama yapılır ve en yaygın sınıf veya etiket tahmin olarak seçilir. Regresyon

problemlerinde ise, k komşuların etiketlerinin ortalaması alınarak tahmin edilen değer elde edilir (Ren ve Suganthan, 2024).

KNN algoritması, ilk olarak Cover ve Hart (1967) tarafından "Nearest neighbor pattern classification" ve daha sonra Cover (1968) tarafından "Rates of Convergence for Nearest Neighbor Procedures" başlıklı çalışmalarında önerilmiştir. Bu algoritma, test örneği ile tüm örnekler arasındaki mesafeleri hesaplar ve karar olarak en yakın komşunun sınıfını kullanır.

KNN, parametrik olmayan bir sınıflandırma algoritmasıdır, yani temel veri kümesi üzerinde herhangi bir varsayımda bulunmaz. Sınıflandırmada, farklı özellikler, etiketlenmemiş verilerin ait olduğu sınıfı belirler. KNN çoğunlukla sınıflandırıcı olarak kullanılır ve bir regresyon problemiyle de kullanılabilir. Çizelge 3.4'te KNN modeline ait algoritma adımları verilmiştir.

Çizelge 3.4. KNN modeline ait algoritma adımları

Adım	İşlem
1	Kütüphanelerin içe aktarılması: pandas, numpy, sklearn, matplotlib
2	Veri setinin CSV dosyasından yüklenmesi
3	Bağımsız değişkenlerin (Nem, Basınç, Sıcaklık) ve hedef değişkenin (Hız) seçilmesi
4	KNN modelinin oluşturulması
5	Modelin eğitilmesi
6	Tahminlerin yapılması
7	Performans metriklerinin hesaplanması (RMSE, MAE, MSE, R-kare, MAPE)
8	Gerçek ve tahmin edilen değerlerin grafiğinin çizilmesi

Sürekli veriler için en yakın komşularını hesaplamak için Öklid mesafesi kullanılır. Yeni bir girdi için K en yakın komşu hesaplanır ve komşu verilerin çoğunluğu yeni girdi için sınıflandırmaya karar verir. Hesaplama maliyeti biraz yüksektir, çünkü tüm hesaplamalar veri setinde karşılaşıldığında değil, eğitim verileri sınıflandırılırken yapılır. Bu nedenle, veri kümesi eğitilirken, eğitim verilerini depolamak ve bunun yerine veri kümesini ezberlemek dışında pek bir şey yapılmadığı için KNN tembel bir öğrenme algoritmasıdır. Buda, eğitim veri seti üzerinde genelleme yapmamasına yol açar ve test aşamasında eğitilen tüm temel veri kümesinin gerekliliğini ortaya çıkarır (Yesilbudak vd., 2017). Şekil 3.8. KNN rüzgâr hız tahmin modeli akış şeması gösterilmiştir.

KNN algoritması, özellikle veri setinin boyutu küçük olduğunda ve veri setindeki sınıfların dengeli olduğu durumlarda iyi performans gösterir. Ancak, büyük veri setleri

ve yüksek boyutlu özellik uzayları ile çalışırken hesaplama maliyeti artabilir ve performans düşebilir.

Kullanılan kod, günlük ortalama rüzgâr hızı verilerini kullanarak bir KNN (k-en yakın komşu) regresyon modeli oluşturur ve performansını değerlendirir. İlk olarak, veri seti okunur ve bağımsız değişkenler (Nem, Basınç, Sıcaklık) ile bağımlı değişken (Hız) ayrıştırılır. Veri seti, eğitim ve test veri setlerine bölünür. Ardından, KNN regresyon modeli oluşturulur ve eğitilir. Eğitilmiş model, test veri setinde kullanılarak tahminler yapılır. Tahminlerle gerçek değerler arasındaki RMSE, MAE ve R-kare hesaplanır. Bu değerler, modelin performansını değerlendirmek için kullanılır ve ekrana yazdırılır. Bu şekilde, KNN regresyon modelinin günlük ortalama rüzgâr hızını tahmin etmedeki başarısını değerlendirebilirsiniz. Bu algoritmanın temel avantajları arasında kolay yorumlanabilirlik, sınıflandırma ve regresyon problemlerinde kullanım için çok yönlülük ve parametrik olmayan doğası bulunmaktadır. Literatürde farklı akademik çalışmalar da sunulmuştur. Bunlar, Ren ve Suganthan (2014) rüzgâr hızı tahmininde kullanılan EMD ve KNN yöntemlerini birleştiren iki EMD-kNN konfigürasyonunu incelemiştir. EMD-kNN-P, IMF'ler ve artık için ayrı modelleme yapar ve sonuçları toplar. EMD-kNN-M ise tüm IMF'lerden ve artıktan oluşan bir vektör kümesi kullanır ve tek bir KNN modeli oluşturur. Yeşilbudak vd., (2017) rüzgâr enerjisi tahmininde çok boyutlu meteorolojik verileri kullanan etkili bir model önermiştir. Çalışmaları, tahmin hatalarının farklı meteorolojik parametrelere göre değişimini göstermektedir.

3.3.4. Karar Ağacı

Rüzgâr hızı tahmini için kullanılan model, karar ağacı (Decision Tree) algoritması temelinde geliştirilmiştir. Bu modelin temeli, veri setini bir dizi karar kuralı ve koşullarla bölerek, rüzgâr hızını tahmin etmek için kullanılmasıdır. Çizelge 3.5'te karar ağacı modeline ait algoritma adımları verilmiştir.

Çizelge 3.5. Karar Ağacı modeline ait algoritma adımları

Adım	İşlem
1	Kütüphanelerin içe aktarılması: numpy, pandas, sklearn
2	Veri setinin CSV dosyasından okunması ve gereksiz sütunların kaldırılması
3	Hedef ve özellik sütunlarının seçilmesi
4	Verinin normalize edilmesi
5	Veri hazırlama fonksiyonunun tanımlanması (bağımsız ve bağımlı değişkenlerin ayarlanması)
6	Adım sayısının belirlenmesi ve eğitim/test verilerinin hazırlanması
7	Karar Ağacı Modeli oluşturulması
8	Modelin eğitilmesi
9	Tahminlerin yapılması
10	Tahminlerin geri dönüşümü (denormalize edilmesi)
11	Performans metriklerinin hesaplanması (RMSE, MAE, MAPE, R-kare)

Veri toplama süreci, meteorolojik istasyonlardan toplanan verilerle gerçekleştirilmiştir. Bu veriler, rüzgâr hızı ölçümleriyle birlikte sıcaklık, basınç ve nem gibi hava durumu parametrelerini içermektedir. Veri toplama süreci, güvenilirlik ve doğruluk açısından dikkatle yürütülmüştür. Şekil 3.9’da karar ağacı rüzgâr hız tahmin modeli akış şeması verilmiştir.

Toplanan veriler, modelin eğitimine uygun hale getirilmiştir. Bu aşamada, veriler normalize edilmiş, eksik değerler doldurulmuş ve gereksiz özellikler çıkarılmıştır. Ön işleme adımı, modelin daha tutarlı ve güvenilir tahminler yapmasını sağlamıştır. Modelin eğitim ve değerlendirme süreci, eğitim veri seti üzerinde gerçekleştirilmiştir. Modelin performansı, RMSE, MAE ve R kare gibi performans metrikleri kullanılarak değerlendirilmiştir.

Eğitilen karar ağacı modeli, yeni hava durumu verileri alarak gelecekteki zaman noktaları için rüzgâr hızı tahminlerinde bulunmuştur. Bu adım, modelin pratik uygulamalarda ne kadar etkili olduğunu belirlemek için önemlidir. Bu şekilde, karar ağacı modelinin tez içinde akademik bir şekilde açıklanması sağlanabilir. Bu açıklamalar, modelin seçilme nedenlerini, nasıl kullanıldığını ve performansının nasıl değerlendirildiğini anlamak için okuyuculara kapsamlı bir bakış sunar. Literatürde farklı çalışmalar yer almaktadır. Bunlar, İrfan vd., (2021) tarafından yapılan araştırmada, rüzgâr enerjisi tahmininde kullanılan dört farklı makine öğrenme algoritması incelenmiştir. Karar ağacı yöntemi, basitliği ve kısa eğitim süresi nedeniyle öne çıkmış ve üç farklı karar

ağacı modeli tasarlanmıştır. Akıncı ve Noğay (2019) tarafından yapılan çalışmada ise rüzgâr hızı tahmini, bölgenin rüzgâr enerjisi potansiyelini belirlemek için önemli bir faktördür. Karar ağacı yöntemi, diğer makine öğrenme yöntemlerine göre daha basit ve hızlı olmasıyla dikkat çekmiş, "Basit Karar Ağacı" yöntemi en doğru tahminleri vermiştir.

3.3.5. Destek Vektör Regresyon

Destek Vektör Regresyonu (Support Vector Regression - SVR), ML alanında yaygın olarak kullanılan bir regresyon tekniğidir. SVR, regresyon problemlerini çözmek için özellikle etkilidir ve veri noktalarını bir hiper düzlemde böler, bu hiper düzlemde bir doğru veya düzlem bulmaya çalışır. Temel amacı, belirli bir marj ile hiper düzlemi bölen en uygun doğruyu/düzlemi bulmaktır (Singh ve Rizvan, 2023).

SVR'nin kullanım alanları oldukça geniştir ve çeşitli endüstrilerde yaygın olarak kullanılmaktadır. Özellikle finansal tahminlerden hava durumu tahminlerine, tıbbi tahminlerden enerji tahminlerine kadar birçok alanda kullanılmaktadır (Alkabbani vd., 2023).

Tez çalışmasında, rüzgâr hızı tahmininde SVR kullanılabilir. Bu durumda, sıcaklık, basınç ve nem gibi hava durumu parametreleri kullanılarak rüzgâr hızı tahmini gerçekleştirilebilir. Bu parametreler, meteorolojik istasyonlardan elde edilen verilerle birlikte incelenir ve SVR modeli bu veriler kullanılarak eğitilir.

Kullanılan kod, günlük ortalama rüzgâr hızı verilerini kullanarak bir SVR modeli oluşturur ve performansını değerlendirir. İlk olarak, veri seti okunur ve 'Tarih' sütunu oluşturulur. Daha sonra, bağımsız ve bağımlı değişkenler ayrıştırılır. Veri seti, eğitim ve test veri setlerine bölünür. Veriler, Standart Ölçekleme işlemi uygulanarak ölçeklenir. SVR modeli oluşturulur ve eğitilir. Eğitilmiş model kullanılarak eğitim ve test veri setlerinde tahminler yapılır. Gerçek ve tahmin edilen değerler arasındaki ilişkiyi gösteren bir çizgi grafiği oluşturulur. Bu grafiğin üzerinde, gerçek hız değerleri mavi çizgiyle, eğitim veri setindeki tahminler mavi dairelerle ve test veri setindeki tahminler kırmızı dairelerle gösterilir. Bu görselleştirme, SVR modelinin günlük ortalama rüzgâr hızını tahmin etmedeki performansını görsel olarak değerlendirmeye olanak sağlar. Çizelge 3.6'da SVR modeline ait algoritma adımları yer almaktadır.

Çizelge 3.6. SVR modeline ait algoritma adımları

Adım	İşlem
1	Kütüphanelerin içe aktarılması: numpy, pandas, sklearn
2	Veri setinin CSV dosyasından okunması ve gereksiz sütunların kaldırılması
3	Hedef ve özellik sütunlarının seçilmesi
4	Verinin normalize edilmesi
5	Veri hazırlama fonksiyonunun tanımlanması (bağımsız ve bağımlı değişkenlerin ayarlanması)
6	Adım sayısının belirlenmesi ve eğitim/test verilerinin hazırlanması
7	SVR Modeli oluşturulması
8	Modelin eğitilmesi
9	Tahminlerin yapılması
10	Tahminlerin geri dönüşümü (denormalize edilmesi)
11	Performans metriklerinin hesaplanması (RMSE, MAE, MAPE, R-kare)

Eğitilen SVR modeli, yeni hava durumu verileri alarak gelecekteki zaman noktaları için rüzgâr hızı tahminlerinde bulunabilir. Bu tahminler, rüzgâr enerjisi tesislerinin verimliliğini artırmak veya hava koşullarına dayalı faaliyetleri planlamak gibi çeşitli uygulamalarda kullanılabilir. Literatürde yer alan farklı çalışmalar da vardır. Bunlar, Singh ve Rizwan (2023) tarafından yürütülen çalışmada, kısa vadeli rüzgâr enerjisi üretim tahminlerinin doğruluğunu artırmak için ML teknikleri olan SVR ve GBRT kullanılmıştır. Alkabbani vd., (2023) ise Ontario'daki bölgesel rüzgâr enerjisi tahmininde SVR/SVM'nin en umut verici model olduğunu bulmuştur. Demirgöl vd., (2024) ise Türkiye'deki solar radyasyon tahmininde LSSVR yönteminin diğerlerine göre daha başarılı olduğunu ortaya koymuştur. Şekil 3.10. SVR rüzgâr hız tahmin modeli akış şeması verilmiştir.

3.3.6. Geçitli Tekrarlayan Birim

Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU), RNN bir alt türü olarak, uzun süreli bağımlılıkları daha etkili bir şekilde modellemek için tasarlanmıştır. Geleneksel RNN'lerin karşılaştığı çözülmesi zor olan "uzun vadeli bağımlılık" sorununu ele alır. Bu model, özellikle zaman serileri gibi sıralı verilerdeki desenleri keşfetmek ve gelecekteki durumları tahmin etmek için kullanılır (Sevinç ve Kaya, 2021). GRU'nun kullanım alanları oldukça çeşitlidir. Özellikle, dil işleme ve zaman serisi analizi gibi alanlarda etkilidir. Metin sınıflandırma, dil modelleme, hava durumu tahmini ve finansal

piyasa analizi gibi uygulamalarda başarıyla kullanılmaktadır. Çizelge 3.7’de GRU modeline ait algoritma adımları verilmiştir.

Çizelge 3.7. GRU modeline ait algoritma adımları

Adım	İşlem
1	Kütüphanelerin içe aktarılması: numpy, pandas, matplotlib, keras, sklearn
2	Veri setinin CSV dosyasından okunması ve gereksiz sütunların kaldırılması
3	Hız, nem, sıcaklık ve basınç sütunlarının seçilmesi
4	Verilerin normalizasyonu (MinMaxScaler kullanılarak)
5	Veri hazırlama fonksiyonunun tanımlanması (bağımsız ve bağımlı değişkenlerin ayarlanması)
6	Adım sayısının belirlenmesi ve eğitim/test verilerinin hazırlanması
7	GRU modelinin oluşturulması (girdi katmanı, gizli katmanlar, çıkış katmanı)
8	Modelin derlenmesi (loss fonksiyonu ve optimizör belirlenmesi)
9	Modelin eğitilmesi (eğitim verileriyle fit işlemi)
10	Tahminlerin yapılması (test verileri üzerinde predict işlemi)
11	Tahminlerin tersine çevrilmesi (normalizasyonun tersi işlemi)
12	Sonuçların görselleştirilmesi (gerçek ve tahmin edilen değerlerin karşılaştırılması)
13	Performans metriklerinin hesaplanması (RMSE, MAE, MAPE, R-kare)

Tezde yer alan, hava durumu tahmini için sıcaklık, basınç ve nem gibi meteorolojik parametrelerle rüzgâr hızı arasındaki ilişkiyi inceleyebilirsiniz. Bu parametrelerin zaman serisi verilerini ve geçmiş rüzgâr hızı verilerini içeren bir eğitim veri seti oluşturarak, GRU gibi sıralı veri analizi için uygun DL algoritmaları kullanarak bir tahmin modeli geliştirilmiştir. (Ji vd., 2022). Kullanılan kod, günlük ortalama rüzgâr hızı verilerini kullanarak bir GRU modeli oluşturur ve performansını değerlendirir. İlk olarak, veri seti yüklenir ve tarih sütunu oluşturulur. Daha sonra, veri normalize edilir ve bağımsız ve bağımlı değişkenler ayarlanır. Ardından, GRU modeli oluşturulur ve derlenir. Model, eğitim seti üzerinde belirli bir epoch sayısı için eğitilir. Eğitim tamamlandıktan sonra, test seti üzerinde tahminler yapılır ve gerçek değerlerle karşılaştırılır. Tahminlerin gerçek değerlerle karşılaştırılmasıyla modelin performansı değerlendirilir. Bu değerlendirme, MSE, R-kare, MAE, MAPE gibi istatistiksel ölçütler kullanılarak gerçekleştirilir. Sonuçlar, çeşitli performans metrikleri kullanılarak yazdırılır. Bu işlem, modelin ne kadar etkili olduğunu belirlemeye ve günlük ortalama rüzgâr hızını tahmin etmek için hangi modelin daha uygun olduğunu değerlendirmeye

yönelik bir analiz sağlar. Şekil 3.11’de GRU rüzgâr hız tahmin modeli akış şeması gösterilmektedir.

Sonrasında, modelimiz, belirli hava koşullarında gelecekteki rüzgâr hızını tahmin etmek için kullanılabilir. Bu, hem akademik araştırmalarda hem de pratik uygulamalarda önemli bir analitik araç olarak hizmet edebilir. Literatürde yapılan bazı çalışmalar, Sevinç ve Kaya’nın (2021) çalışması, Diyarbakır’da hava sıcaklığı tahmininde DL yöntemlerinin etkinliğini incelemiştir. LSTM, GRU ve CNN gibi farklı modeller karşılaştırılmış ve sonuçlar, LSTM modelinin en yüksek doğrulukta tahmin sağladığını ortaya koymuştur (ortalama hata: 0,78°C). Bu bulgular, DLnin Diyarbakır’daki hava durumu tahminlerinde klasik yöntemlere göre daha etkili bir araç olabileceğini ve bölgedeki enerji yönetimi ve tarım gibi alanlarda daha iyi planlamaya olanak tanıyabileceğini göstermektedir. Ji vd., (2022) çalışması ise hidroelektrik santral inşaatlarında kanyon rüzgârının etkisini ele almıştır. Özellikle, kanyon rüzgârının inşaat personelinin güvenliğini etkileyebileceği durumlarda, kanyon rüzgâr hızının kısa vadeli tahmininin önemi vurgulanmıştır. Bu çalışma, aktarım öğrenmesine dayalı bir zaman serisi tahmin yöntemi önermektedir. Bu yöntem, az miktarda rüzgâr hızı verisi ile kısa vadeli tahmini başarabilir ve karmaşık arazi altında kanyonlardaki rüzgâr hızı tahmini uygulamalarına yeni bir bakış açısı getirebilir.

3.3.7. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA/Artificial Neural Network- ANN), biyolojik sinir sistemlerinden esinlenerek tasarlanmış matematiksel model sistemleridir. YSA’lar, birçok katman içeren ve bu katmanlardaki düğümler arasındaki bağlantıların güçlerini ayarlayarak girdi verilerinden çıktı üreten algoritmalar olarak tanımlanabilir (Yılmaz, 2024).

YSA’ların kullanım alanları oldukça geniştir. Özellikle, desen tanıma, sınıflandırma, regresyon, tahminleme ve veri analizi gibi alanlarda yaygın olarak kullanılırlar. Gelişmiş yapay zeka uygulamalarında, özellikle büyük veri setlerinde karmaşık desenleri tanımlamak ve tahmin etmek için tercih edilirler (Demirtop ve Işık, 2023). Çizelge 3.8. YSA modeline ait algoritma adımları yer almaktadır.

Çizelge 3.8. YSA modeline ait algoritma adımları

Adım	İşlem
1	Kütüphanelerin içe aktarılması: pandas, sklearn, tensorflow.keras, matplotlib, numpy
2	Veri setinin CSV dosyasından yüklenmesi
3	Bağımsız değişkenlerin (Nem, Basınç, Sıcaklık) ve hedef değişkenin (Hız) seçilmesi
4	Verilerin normalize edilmesi (MinMaxScaler kullanılarak)
5	Eğitim ve test setlerine ayırma (train_test_split kullanılarak)
6	Yapay Sinir Ağı (YSA) modelinin tanımlanması (Sequential model, Dense katmanları)
7	Modelin derlenmesi (optimizer olarak Adam, loss olarak 'mse' kullanılarak)
8	Modelin eğitilmesi (fit metoduyla)
9	Tahminlerin yapılması (predict metoduyla)
10	Tahminlerin normalize edilmiş halden geri çevrilmesi
11	Performans metriklerinin hesaplanması (MSE, R ² , RMSE, MAE, MAPE)

Kullanılan kod, günlük ortalama rüzgâr hızı verilerini kullanarak bir YSA modeli oluşturur ve performansını değerlendirir. İlk adımda, veri seti yüklenir ve özellikler ile hedef değişken (rüzgâr hızı) ayrılır. Daha sonra, veri normalize edilir ve eğitim ve test setlerine ayrılır. Ardından, YSA modeli tanımlanır ve derlenir. Model, tam bağlantılı katmanlar içerir ve ReLU (Rectified Linear Unit- Doğrusal Doğrultma Birimi) aktivasyon fonksiyonu kullanır. Model, eğitim seti üzerinde 50 epoch boyunca eğitilir. Eğitim tamamlandıktan sonra, test seti üzerinde tahminler yapılır ve gerçek değerlerle karşılaştırılır. Tahminlerin gerçek değerlerle karşılaştırılmasıyla modelin performansı değerlendirilir. Bu değerlendirme, MSE, R-kare, RMSE ve MAE gibi istatistiksel ölçütler kullanılarak gerçekleştirilir. Sonuçlar, çeşitli performans metrikleri kullanılarak yazdırılır. Bu işlem, modelin ne kadar etkili olduğunu belirlemeye ve günlük ortalama rüzgâr hızını tahmin etmek için hangi modelin daha uygun olduğunu değerlendirmeye yönelik bir analiz sağlar. Şekil 3.12'de YSA rüzgâr hız tahmin modeli akış şeması gösterilmektedir.

Daha sonra, modelinizi eğitim veri setiyle eğitip test veri setiyle doğrulayabilirsiniz. Modelinizin performansını değerlendirmek için doğruluk, ortalama kare hatası veya diğer uygun metrikleri kullanabilirsiniz. Sonuçlarınızı analiz ederek, kullanılan parametrelerin rüzgâr hızı tahminindeki etkisini ve modelin tahmin yeteneğini değerlendirebilirsiniz. Bu çalışma hem akademik araştırmalarda hem de pratik meteorolojik uygulamalarda değerli bir katkı sağlayabilir. Literatürde çeşitli akademik

alışmalar vardır. Bunlar, Yılmaz'ın (2024) alışması, 4.8 MW gücündeki bir rüzgâr türbininde yapay zekâ tabanlı arıza teşhisi üzerine yoğunlaşmıştır. Rüzgâr türbin sistemlerinin deęişken alışma koşulları göz önüne alındığında, doğrusal sınıflandırma yöntemlerinin yeterli olmadığı belirlenmiş ve çeşitli veriler Neural Network Toolbox kullanılarak eğitilmiş ve YSA yapısı arıza teşhisi için kullanılmıştır. Demirtop ve Işık'ın (2023) alışması, anakkale Bozcaada'dan alınan 2014 yılı rüzgâr verileri üzerinde YSA modelleriyle MATLAB programı kullanarak rüzgâr enerjisi verimliliğini artırmayı amaçlamıştır. Bulgular, MATLAB'ın WEKA'dan daha iyi sonuçlar verdiğini göstermiştir. Wazirali vd., (2023) alışması, YSA, ML ve DL tekniklerini kullanarak mikro şebekelerde enerji ve yük tahminlemesi üzerine mevcut durumu incelemiştir. Makale, alandaki literatürü kapsamlı bir şekilde ele alarak, mevcut yöntemlerin kapsamını ve uygulanabilirliğini deęerlendirmeyi amaçlamaktadır.

3.3.8. Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (Convolutional Neural Network- CNN), DL alanında önemli bir YSA modelidir. Görüntü işleme alanında özellikle etkilidir, ancak metin, ses ve zaman serileri gibi dięer veri türlerinde de başarıyla kullanılabilir (Rababaah, 2023). CNN'ler, özellikle görüntü tanıma ve sınıflandırma gibi görsel veri işleme görevlerinde yaygın olarak kullanılır. Bu ağlar, bir veri setinden özellikleri (örneğin kenarlar, köşeler, desenler) otomatik olarak ıkarmak için kullanılan özelleştirilebilir evrişim filtreleri kullanır. Bu filtreler, resmin farklı bölgelerine uygulanarak resimdeki özellikleri belirlemeye yardımcı olur. Sonra, bu özellikler bir veya daha fazla tam baęlı katmana (dense layer) aktarılır ve sınıflandırma veya regresyon gibi görevler için sonuç üretmek için kullanılır (Sevin ve Kaya, 2021). izelge 3.9'da CNN modeline ait algortima adımlarını göstermektedir.

Çizelge 3.9. CNN modeline ait algoritma adımları

Adım	İşlem
1	Kütüphanelerin içe aktarılması: pandas, numpy, sklearn, tensorflow.keras, matplotlib
2	Veri setinin CSV dosyasından yüklenmesi
3	Bağımsız değişkenlerin (Nem, Basınç, Sıcaklık) ve hedef değişkenin (Hız) seçilmesi
4	Verilerin normalize edilmesi (MinMaxScaler kullanılarak)
5	Eğitim ve test setlerine ayırma (train_test_split kullanılarak)
6	CNN modelinin tanımlanması (Conv1D, Flatten, Dense katmanları)
7	Modelin derlenmesi (optimizer olarak Adam, loss olarak ‘mse’ kullanılarak)
8	Verinin CNN için yeniden şekillendirilmesi
9	Modelin eğitilmesi (fit metoduyla)
10	Tahminlerin yapılması (predict metoduyla)
11	Performans metriklerinin hesaplanması (MSE, R-kare)

Rüzgâr hızı tahmini gibi zaman serisi tahmin problemlerinde, CNN’ler doğrudan kullanılmak yerine, zaman serileri verilerini işlemek için daha uygun olan diğer sinir ağı modelleri, örneğin LSTM veya GRU gibi modeller tercih edilir. Bu modeller, zaman serilerindeki zaman bağımlılıklarını daha iyi modelleyebilirler (Singh vd., 2024). Şekil 3.13’te CNN rüzgâr hız tahmini modeli akış şeması yer almaktadır.

Kullanılan kod, günlük ortalama rüzgâr hızı verilerini kullanarak bir CNN modeli oluşturur ve performansını değerlendirir. İlk adımda, veri seti yüklenir ve özellikler ile hedef değişken (rüzgâr hızı) ayrılır. Daha sonra, veri normalleştirilir ve eğitim ve test setlerine ayrılır. Ardından, CNN modeli tanımlanır ve derlenir. Model, evrişimli katmanlar ve tam bağlantılı katmanlar içerir. Eğitim, modelin belirlenen hiperparametrelerle 50 epoch boyunca gerçekleştirilir. Tahminler yapılır ve gerçek değerlerle karşılaştırılarak modelin performansı değerlendirilir. Bu değerlendirme, MSE, R-kare, RMSE ve MAE gibi istatistiksel ölçütler kullanılarak gerçekleştirilir. Sonuçlar, gerçek ve tahmin edilen değerlerin karşılaştırılmasıyla görselleştirilir ve çeşitli performans metrikleri kullanılarak yazdırılır. Bu işlem, modelin ne kadar etkili olduğunu belirlemeye ve Ayvacı ilçesindeki günlük ortalama rüzgâr hızını tahmin etmek için hangi modelin daha uygun olduğunu değerlendirmeye yönelik bir analiz sağlar.

Ancak, rüzgâr hızı tahmini gibi bir görevde, CNN’ler bazı durumlarda veri ön işleme veya özellik çıkarma aşamalarında kullanılabilir. Örneğin, giriş verilerini daha küçük boyutlara indirgemek veya belirli desenleri tespit etmek için kullanılabilirler (Çalışan ve Talu, 2020). Bununla birlikte, genellikle zaman serileri için daha uygun olan LSTM veya

GRU gibi modeller, bu tür tahmin problemleri için daha yaygın olarak tercih edilir. Literatürde yer alan çeşitli araştırmalar mevcuttur. Bunlar, Sevinç ve Kaya (2021) çalışması, Diyarbakır'da hava sıcaklığı tahmininde CNN modelinin etkinliğini ortaya koyarak, diğer DL modelleriyle karşılaştırmıştır. Singh vd., (2024) araştırması, rüzgâr enerjisi tahmini için yüksek doğruluk sağlayan CNN modelinin kullanımını vurgulamıştır. Wood'un (2023) çalışması ise, rüzgâr enerjisi üretim tahminlerinde CNN modelinin başarıyla kullanıldığını ve özellikle meteorolojik koşullardaki değişikliklerin tahmininde etkili olduğunu belirtmiştir. Bu çalışmalar, CNN modelinin çeşitli hava ve enerji tahmini uygulamalarında potansiyelini göstermektedir.

3.4. Kullanılan Teknolojilere Göre Sistem Mimarileri

Bu çalışmada kullanılan ML ve DL tekniklerinden ilki k-Nearest Neighbors (KNN) algoritmasıdır. Bu algoritma, Gökçeada'nın günlük hava verilerini işlemek üzere seçilmiştir. Veriler, CSV formatında yüklenmiş ve nem, basınç, sıcaklık gibi belirli özellikler seçilerek normalize edilmiştir. Normalizasyon işlemi, verilerin Min-Max yöntemi kullanılarak ölçeklendirilmesiyle gerçekleştirilmiştir. Model eğitimi sırasında KNN algoritması, belirlenen komşuluk sayısı ($k=5$) ile uygulanmış ve performans değerlendirmesi için RMSE, MAE, MSE ve R-kare skorları hesaplanmıştır. Son olarak, gerçek ve tahmin edilen değerlerin grafiksel olarak görselleştirilmesi için matplotlib kütüphanesi kullanılmıştır.

Karar Ağacı yöntemi de bu çalışmanın odak noktalarından biridir. Bu modelde, Gökçeada'nın günlük hava verileri aynı şekilde yüklenmiş ve belirli özellikler (nem, basınç, sıcaklık) seçilerek normalize edilmiştir. Veri normalizasyonu, Min-Max yöntemiyle yapılmıştır. Karar ağacı model mimarisi, derinliği 5 olan ağaç yapısıyla belirlenmiş ve minimum örnekleme sayıları göz önünde bulundurularak eğitilmiştir. Modelin performansı için RMSE, MAE, MSE ve R-kare skorları hesaplanmış ve elde edilen sonuçlar görsel olarak matplotlib kullanılarak sunulmuştur.

SVR yöntemi, veri setinin Gökçeada günlük hava verileriyle yüklenmesiyle başlamıştır. Nem, basınç, sıcaklık gibi özellikler seçilmiş ve Min-Max normalizasyonu uygulanarak veriler ölçeklendirilmiştir. SVR modeli, $\text{kernel}='rbf'$, $C=1,0$, $\text{gamma}='scale'$, ve $\text{epsilon}=0,1$ gibi belirli hiperparametrelerle yapılandırılmıştır. Model eğitimi sırasında, veriler doğrudan eğitim seti olarak kullanılmış ve RMSE, MAE, MSE ve R-kare skorları performans değerlendirmesi için hesaplanmıştır. Son olarak, gerçek ve

tahmin edilen deęerlerin grafiksel olarak grselleřtirilmesi iin matplotlib ktphanesi kullanılmıřtır.

XGBoost yntemi, Gkeada'nın gnlk hava verilerini ieren CSV formatındaki veri setiyle bařlamıřtır. Nem, basın, sıcaklık gibi zellikler seilmiř ve Min-Max normalizasyonu kullanılarak veriler leklendirilmiřtir. XGBoost modeli, 1000 aęa, max_depth=7, learning_rate=0,2, reg_alpha=0,2, reg_lambda=0,3 gibi belirli parametrelerle yapılandırılmıřtır. Model eęitimi sırasında, veriler doęrudan eęitim seti olarak kullanılmıř ve RMSE, MAE, MSE ve R-kare skorları performans deęerlendirmesi iin hesaplanmıřtır. En son adımda, modelin tahmin ettięi ve gerek deęerlerin grselleřtirilmesi matplotlib ktphanesi ile saęlanmıřtır.

LSTM modeli, İlelerin gnlk ortalama hava verilerini ieren CSV formatındaki veri setiyle bařlamıřtır. Veriler yklenmiř, gerekli stunlar seilmiř ve Min-Max normalizasyonu kullanılarak leklendirilmiřtir. Model mimarisi, giriř katmanı-> LSTM katmanı-> ıkıř katmanı řeklinde belirlenmiřtir. Kayıp fonksiyonu olarak Mean Squared Error ve optimizasyon iin Adam optimizer kullanılmıřtır. Model, toplamda 25 epoch sresince eęitilmiř ve batch boyutu 1 olarak belirlenmiřtir. Performans deęerlendirmesi iin RMSE, MAE, MAPE ve R-kare skorları hesaplanmıř, sonular matplotlib ktphanesiyle grselleřtirilmiřtir.

GRU modeli de aynı řekilde İlelerin gnlk ortalama hava verileriyle alıřmıřtır. Veriler yklenmiř, gerekli stunlar seilmiř ve Min-Max normalizasyonu kullanılarak leklendirilmiřtir. Model mimarisi, giriř katmanı-> GRU katmanı-> ıkıř katmanı olarak belirlenmiřtir. Kayıp fonksiyonu olarak Mean Squared Error ve optimizasyon iin Adam optimizer kullanılmıřtır. Model, 25 epoch sresince eęitilmiř ve batch boyutu 1 olarak ayarlanmıřtır. Performans deęerlendirmesi iin RMSE, MAE, MAPE ve R-kare skorları hesaplanmıř, sonular matplotlib ktphanesiyle grselleřtirilmiřtir.

CNN modeli, İlelerin gnlk ortalama hava verileriyle alıřmıřtır. Veriler yklenmiř, gerekli stunlar seilmiř ve Min-Max normalizasyonu kullanılarak leklendirilmiřtir. Model mimarisi, Conv1D katmanı-> Flatten katmanı-> Dense katmanı řeklinde belirlenmiřtir. Kayıp fonksiyonu olarak Mean Squared Error ve optimizasyon iin Adam optimizer kullanılmıřtır. Model, 50 epoch sresince eęitilmiř ve batch boyutu 32 olarak belirlenmiřtir. Performans deęerlendirmesi iin RMSE, MAE, MAPE ve R-kare skorları hesaplanmıř, sonular matplotlib ktphanesiyle grselleřtirilmiřtir.

YSA modeli de aynı veri setiyle çalışmıştır. Veriler yüklenmiş, gerekli sütunlar seçilmiş ve Min-Max normalizasyonu kullanılarak ölçeklendirilmiştir. Model mimarisi, giriş katmanı-> gizli katmanlar-> çıkış katmanı olarak belirlenmiştir. Kayıp fonksiyonu olarak Mean Squared Error ve optimizasyon için Adam optimizer kullanılmıştır. Model, 50 epoch süresince eğitilmiş ve batch boyutu 32 olarak ayarlanmıştır. Performans değerlendirmesi için RMSE, MAE, MAPE ve R-kare skorları hesaplanmış, sonuçlar matplotlib kütüphanesiyle görselleştirilmiştir. ML ve DL ait modellerin Çizelge 3.10'da gösterilmiştir.



Çizelge 3.10. Kullanılan teknolojilere göre model yapısı

Kullanılan Teknoloji	Model Mimarı	Model Derleme	Model Eğitimi
k-En Yakın Komşu	Komşuluk sayısı (k) 5 olarak belirtilmiştir.	Model eğitiminde KNN algoritması kullanılmıştır.	Veriler eğitim seti olarak kullanılmıştır.
Karar Ağacı	Karar ağaç derinliği 5, min örnek ayrımı 10 ve yaprak düğümlerinde minimum örnekleme sayısı 5 olarak belirlenmiştir.	Model eğitiminde Karar Ağacı algoritması kullanılmıştır.	Veriler eğitim seti olarak kullanılmıştır.
SVR	63ernel='rbf', C=1,0, gamma='scale', ve epsilon=0,1 gibi belirli hiperparametreler belirtilmiştir.	Model eğitiminde SVR algoritması kullanılmıştır.	Veriler eğitim seti olarak kullanılmıştır.
XGBoost	1000 ağaç, max_depth=7, learning_rate=0,2, reg_alpha=0,2, reg_lambda=0,3 ile yapılandırılmış regresyon modeli.	Model eğitiminde XGBoost algoritması kullanılmıştır.	Veriler eğitim seti olarak kullanılmıştır.
LSTM	Giriş katmanı (input layer) -> LSTM katmanı -> Çıkış katmanı (output layer)	Kayıp fonksiyonu: Mean Squared Error, Optimizasyon: Adam optimizier kullanılmıştır.	Toplamda 25 epoch boyunca eğitilmiştir. Batch boyutu: 1
GRU	Giriş katmanı (input layer) -> GRU katmanı -> Çıkış katmanı (output layer)	Kayıp fonksiyonu: Mean Squared Error, Optimizasyon: Adam optimizier kullanılmıştır.	Toplamda 25 epoch boyunca eğitilmiştir. Batch boyutu: 1
CNN	Conv1D katmanı-> Flatten katmanı-> Dense katmanı	Kayıp fonksiyonu: Mean Squared Error, Optimizasyon: Adam optimizier kullanılmıştır.	Toplamda 50 epoch boyunca eğitilmiştir. Batch boyutu: 32
YSA	Yapay Sinir Ağı (YSA): Giriş katmanı-> Gizli katmanlar-> Çıkış katmanı	Kayıp fonksiyonu: Mean Squared Error, Optimizasyon: Adam optimizier kullanılmıştır.	Toplamda 50 epoch boyunca eğitilmiştir. Batch boyutu: 32

3.5 Performans Değerlendirmesi

Çalışmanın yöntemlerinin değerlendirilmesi, temel olarak çeşitli istatistiksel ölçütler aracılığıyla gerçekleştirilmiştir. Bu ölçütler, kullanılan modellerin performansını objektif bir şekilde değerlendirmek için önemli bir araç sağlamaktadır. R-kare, MAE, RMSE, MAPE ve MSE gibi metrikler, her bir modelin tahmin yeteneğini analiz etmek için kullanılmıştır (Sada ve Ikpeseni, 2021). Bu metrikler, gerçek ve tahmin edilen değerler arasındaki farkları ve tahminlerin doğruluğunu ölçerek modellerin performansını karşılaştırmak için kullanılmaktadır. Bu ölçütler ilgili denklemler yardımıyla hesaplanmaktadır.

Korelasyon Katsayısı (R^2):

$$R = 1 - \frac{\sum_{i=1}^n y_{iG} - y_{iT}^2}{\sum_{i=1}^n y_{iG}^2} \quad (3.1)$$

Ortalama mutlak hata (MAE):

$$MAE = \frac{1}{n} |y_{iG} - y_{iT}| \quad (3.2)$$

Ortalama kare hata (MSE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{iG} - y_{iT})^2 \quad (3.3)$$

Kök Ortalama Kare Hata (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{iG} - y_{iT})^2} \quad (3.4)$$

Ortalama Mutlak Yüzde Hata (MAPE):

$$MAPE = \frac{1}{n} \left| 100 \times \frac{y_{iG} - y_{iT}}{y_{iG}} \right| \quad (3.5)$$

Denklem 3.1,3.2,3.3,3.4 ve 3.5'te yer alan değerlerin anlamı; y_{iG} , gözlemlenen bağımlı değişken değerlerini temsil ederken, y_{iT} , regresyon modelinden beklenen bağımlı değişken değerlerini, y_{iT} ise gözlemlenen bağımlı değişkenin ortalama değerini temsil eder ve n , gözlem sayısını temsil etmektedir.


Meteoroloji Genel Müdürlüğü'nden temin edilen Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerine ait 2014-2021 yılları arasındaki günlük ortalama rüzgâr hızı verileri üzerinde, modellerin etkinliğini belirlemek için performans metrikleri kullanılmıştır (DMİ, 2022). LSTM, XGBoost, KNN, Karar Ağacı, SVR, GRU, YSA ve CNN gibi çeşitli ML modellerinin performansı incelenmiştir. Bu modellerin performansı, belirtilen istatistiksel ölçütler kullanılarak değerlendirilmiştir. Her bir model için R-kare, MAE, RMSE, MAPE ve MSE gibi ölçütler hesaplanmış ve karşılaştırılmıştır. Değerlendirme süreci, farklı modellerin performansını karşılaştırarak en uygun modelin belirlenmesinde kritik bir rol oynamaktadır. Özellikle, R-kare bir modelin verileri ne kadar iyi açıkladığını gösterirken, MAE ve RMSE gibi ölçütler ise tahminlerin doğruluğunu göstermektedir. Sonuç olarak, çalışmanın performans değerlendirmesi, kullanılan modellerin Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerindeki günlük ortalama rüzgâr hızı verileri üzerindeki tahmin yeteneklerini analiz etmiştir. Elde edilen sonuçlar, belirli bir modelin ne kadar etkili olduğunu değerlendirmek için önemli bir yol sağlamaktadır. Bu performans metrikleri, araştırmanın bulgularını anlamak ve sonuçları yorumlamak için temel bir araç olarak kullanılmıştır.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

4.1. Uzun Kısa Süreli Bellek Analizi

LSTM modeli, zaman serileri gibi ardışık verilerin analizi için etkili bir DL yöntemidir (Hanifi vd., 2024). Rüzgâr hızı tahmini gibi zaman serileri problemlerinde, LSTM modeli özellikle güçlü bir performans sergileyebilir. Bu model, geçmiş zaman adımlarındaki verileri ve ilişkileri öğrenerek gelecekteki değerleri tahmin eder. LSTM'in avantajı, uzun dönem bağımlılıkları etkili bir şekilde modelleyebilmesi ve aynı zamanda girdi verilerindeki gürültüyü de tolere edebilmesidir (Akkurt ve Sarıçiçek, 2024). Bu özellikleri sayesinde, rüzgâr hızı gibi karmaşık zaman serilerinin tahmininde başarılı sonuçlar elde edilebilir. Ancak, modelin başarısı, kullanılan veri setinin kalitesi, modelin yapılandırılması ve hiperparametrelerin uygun şekilde ayarlanmasına bağlıdır. Ayrıca, LSTM'in genellikle büyük miktarda veri gerektirdiği ve eğitim sürecinin hesaplama yönünden yoğun olabileceği de göz önünde bulundurulmalıdır. Bu nedenle, rüzgâr hızı tahmini gibi uygulamalarda LSTM'in etkili bir şekilde kullanılabilmesi için dikkatli bir veri hazırlığı ve model optimizasyonu gerekmektedir (Altan ve Karasu, 2020).

LSTM modeline ait Şekil 4.1'de Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerinin günlük ortalama tahmin rüzgâr hızı grafikleri yer almaktadır. LSTM modeline dayalı olarak oluşturulan grafikler, Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerinin günlük ortalama tahmin hızlarını ayrıntılı bir şekilde göstermektedir. Bu grafikler, modelin her bir ilçe için gerçek değerlerle ne kadar uyumlu olduğunu ve tahminlerin belirli dönemlerde nasıl performans gösterdiğini anlamamıza yardımcı olur. Bu bilgiler, meteorolojik tahminlerin doğruluğunu değerlendirmek ve gelecekteki tahminlerin iyileştirilmesine katkıda bulunmak için önemlidir.



Şekil 4.1. LSTM modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri

Çizelge 4.1. LSTM modeline ait performans değerleri

İlçe	R-kare	MSE	RMSE	MAE	MAPE
Ayvacık	0,929	9,285	3,047	2,549	59,654
Bozcaada	0,950	5,976	2,445	1,986	92,366
Ezine	0,909	6,764	2,601	2,269	79,247
Gökçeada	0,964	4,433	2,105	1,727	64,285

Çizelge 4.1’de sunulan LSTM modeline dayalı performans değerlendirmesi, Ayvacık, Bozcaada, Ezine ve Gökçeada gibi farklı coğrafi bölgelerdeki rüzgâr hızı tahminlerini içermektedir. Ayvacık bölgesi için elde edilen sonuçlar, modelin oldukça yüksek bir uyum seviyesi sergilediğini göstermektedir (R-kare: 0,9142). Ayrıca, MSE ve RMSE gibi hata ölçütleri düşük değerlerde bulunmuş, bu da modelin tahminlerinin gerçek değerlere yakın olduğunu göstermiştir. Ancak, MAPE değeri bazı sapmaları ifade etmektedir. Ayvacık için tahminlerin gerçek değerlerle karşılaştırıldığı Grafik 5(a) görseli, bu sonuçları desteklemektedir.


Bozcaada ve Gökçeada için elde edilen sonuçlar da benzer şekilde başarılıdır. Yüksek R-kare değerleri (%95,04 ve %92,06) ile modelin bağımsız değişkenlerin varyansının büyük bir kısmını açıkladığını gösterir. Ancak, Bozcaada için MAPE değeri %92,37, Gökçeada için ise %64,28 olarak belirlenmiştir, bu da bazı tahminlerde sapmalar olduğunu işaret eder. Bozcaada ve Gökçeada için tahminlerin gerçek değerlerle karşılaştırıldığı Şekil 4.1(b) ve 4.1(d) görselleri, bu sonuçları desteklemektedir.

Genel olarak, elde edilen sonuçlar, LSTM modelinin farklı coğrafi bölgelerdeki rüzgâr hızını tahmin etmede etkin olduğunu göstermektedir. Ancak, bazı bölgelerde (örneğin Ezine), modelin performansının daha fazla iyileştirme veya düzeltilme gerektirebileceğini belirtmek önemlidir. Bu bulgular, rüzgâr enerjisi kaynak tahmininde LSTM modellerinin kullanımının, yerel coğrafi ve iklimsel faktörlerin dikkate alınması gerektiğini vurgular. Çalışmalarda LSTM modeline odaklanan bulgular, Sevinç ve Kaya'nın (2021) araştırmasında, Diyarbakır'daki hava sıcaklığı tahmininde LSTM modelinin en yüksek doğrulukta tahmin sağladığı belirlenmiştir (ortalama hata: 0,78°C). Benzer şekilde, Karabulut ve Topçu'nun (2022) çalışması da Kars'ta hava sıcaklığı tahmininde LSTM tabanlı modelin istatistiksel yöntemlere göre daha doğru tahminler sunduğunu göstermiştir (ortalama hata: 0,65°C). Karaman'ın (2023) çalışmasında ise, rüzgâr enerjisi tahminlemesi için yapılan analizde LSTM modelinin etkili tahminler gerçekleştirdiği gözlemlenmiştir; LSTM modeli özellikle başarılı olduğu belirlenmiş ve R-kare değeri 0,9574, MAE değeri 0,0209, MSE değeri 0,0038 ve RMSE değeri 0,0614 olarak hesaplanmıştır. Alkabbani vd., (2023) araştırmasında, Ontario, Kanada'daki bölgesel rüzgâr enerjisi için yapılan zaman serisi tahmininde LSTM modelinin MIMO yaklaşımıyla daha güvenilir tahminler sağladığı ve daha yüksek doğruluk oranları elde ettiği belirtilmiştir. Bu çalışmalar, LSTM modelinin rüzgâr hızı, hava sıcaklığı tahmini ve rüzgâr enerjisi tahminleme gibi alanlarda etkili bir şekilde kullanılabileceğini ortaya koymaktadır.

4.2. Aşırı Gradyan Artırma Analizi

XGBoost algoritması, rüzgâr hızı tahmini gibi regresyon problemlerinde etkili bir şekilde kullanılan bir ML modelidir (Meddage vd., 2024). Bu model, karmaşık ilişkileri modelleyebilme yeteneği ve yüksek tahmin doğruluğuyla öne çıkar. Özellikle, XGBoost'un rüzgâr enerjisi planlaması gibi alanlarda güvenilir ve hassas tahminler sağladığı gözlemlenmiştir. Elde edilen sonuçlar, XGBoost'un düşük hata değerleri ve yüksek R-kare değerleri ile rüzgâr hızı tahmininde başarılı bir performans sergilediğini

ortaya koymaktadır. Bu nedenle, XGBoost modeli, rüzgâr enerjisi uygulamalarında güvenilir bir tahmin aracı olarak değerlendirilebilir (Fang vd., 2023).



Şekil 4.2. XGBoost modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri

Çizelge 4.2. XGBoost modeline ait performans değerleri

İlçe	R-kare	MSE	RMSE	MAE	MAPE
Ayvacık	0,9438	0,8577	0,7357	0,6777	38,3416
Bozcaada	0,8851	0,9242	0,8541	0,7048	14,3904
Ezine	0,9034	0,7902	0,6245	0,6013	10,2798
Gökçeada	0,9167	0,6657	0,4432	0,5285	21,2617

Şekil 4.2’de yer alan XGBoost modeliyle değerlendirilen Ayvacık, Bozcaada, Ezine ve Gökçeada’daki rüzgâr hızı tahminlerine odaklanılmıştır. Çizelge 4.2’deki XGBoost modelleriyle yapılan değerlendirmeler, Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerindeki rüzgâr hızı tahminleri için önemli veriler sunmaktadır. Her bir ilçe için elde edilen sonuçlar şu şekildedir: Ayvacık ilçesinde XGBoost modeli, %94,38 R-kare değeriyle oldukça yüksek bir doğruluk sağlamıştır. Modelin MSE değeri 0,8577 ve


RMSE değeri 0,7357 olarak hesaplanmıştır. Ayrıca, modelin MAE değeri 0,6777 ve MAPE değeri %38,34 olarak belirlenmiştir. Bu sonuçlar, Ayvacık'taki XGBoost modelinin rüzgâr hızı tahminlerinde güvenilir ve etkili olduğunu göstermektedir. Bozcaada ilçesinde ise XGBoost modelinin R-kare değeri %88,51 olarak ölçülmüştür. MSE değeri 0,9242 ve RMSE değeri 0,8541 olarak belirlenmiştir. Modelin MAE değeri 0,7048 ve MAPE değeri %14,39 olarak hesaplanmıştır. Bu sonuçlar, Bozcaada'daki XGBoost modelinin de güçlü bir performans sergilediğini ve tahminlerinin gerçek verilere yakın olduğunu göstermektedir. Ezine ilçesinde XGBoost modelinin R-kare değeri %90,34 olarak ölçülmüştür. MSE değeri 0,7902 ve RMSE değeri 0,6245 olarak hesaplanmıştır. Modelin MAE değeri 0,6013 ve MAPE değeri %10,28 olarak belirlenmiştir. Bu sonuçlar, Ezine'deki XGBoost modelinin de rüzgâr hızı tahminlerinde başarılı olduğunu ve düşük hata değerleri ile güvenilir tahminler sunduğunu göstermektedir. Son olarak, Gökçeada ilçesinde XGBoost modelinin R-kare değeri %91,67 olarak hesaplanmıştır. MSE değeri 0,6657 ve RMSE değeri 0,4432 olarak belirlenmiştir. Modelin MAE değeri 0,5285 ve MAPE değeri %21,26 olarak ölçülmüştür. Gökçeada'daki bu sonuçlar, XGBoost modelinin burada da etkili bir şekilde çalıştığını ve güvenilir tahminler sağladığını göstermektedir.

Bu bulgular, XGBoost modelinin Ayvacık, Bozcaada, Ezine ve Gökçeada gibi farklı ilçelerde rüzgâr hızı tahminleri için güçlü bir araç olduğunu ve yenilenebilir enerji planlaması için önemli bir kaynak olarak kullanılabileceğini ortaya koymaktadır. Literatürde yer alan çeşitli araştırmalarda alınan sonuçlardan bazıları şöyledir, Li vd., (2022) çalışmalarında, NWP rüzgâr hızı düzeltme ve tahmin modeli için VMD-BGRU yöntemini XGBoost algoritmasıyla önermektedirler. XGBoost tahmin modeli, diğer geleneksel ML yöntemlerine (MLP ve SVR) kıyasla daha üstün bir performans sergilemektedir ve %7,53'lik RMSEp değeriyle daha düşük bir hata payına sahip olduğunu göstermişlerdir (Li, vd., 2022).

4.3. K-en Yakın Komşuluk Analizi

k-En Yakın Komşu (KNN) algoritması, rüzgâr hızı tahmini gibi regresyon problemlerinde sıklıkla kullanılan bir yaklaşımdır (Karaman, 2023). Bu yöntemde, bir veri noktasının tahmini yapılırken, bu noktaya en yakın k komşusu kullanılarak bir tahmin yapılır. KNN algoritması basit ve anlaşılması kolay olmasının yanı sıra, esnek bir yapıya sahiptir ve karmaşık veri yapılarına uyum sağlayabilir (Ren ve Suganthan, 2014). Ancak, bu esneklik bazen aşırı uyum sorununa neden olabilir, yani model eğitim verilerine çok

fazla uyum sağlar ve genelleme yeteneği düşer. Bu durumda, model yeni verilere doğru şekilde uygulanamaz. Özellikle düşük boyutlu veri setlerinde ve belirli hiper parametreler seçildiğinde, KNN modeli iyi performans gösterebilir. Ancak, büyük veri setleri veya yüksek boyutlu veri setleri gibi durumlarda, hesaplama maliyeti yüksek olabilir ve modelin performansı düşebilir. Sonuç olarak, KNN yöntemi, uygun hiper parametrelerle ve veri setinin özelliklerine uygun olarak kullanıldığında etkili bir tahmin yöntemi olabilir, ancak aşırı uyum ve hesaplama maliyeti gibi potansiyel zorluklara dikkat edilmesi gerekmektedir.



Şekil 4.3. KNN modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri

Çizelge 4.3. KNN modeline ait performans değerleri

İlçe	R-kare	MSE	RMSE	MAE	MAPE
Ayvacic	0,2571	8,1009	2,8462	2,2655	47,4903
Bozcaada	0,2021	4,7138	2,1711	1,6873	34,5691
Ezine	0,2710	5,1016	2,2587	1,7546	38,3161
Gökçeada	0,2732	3,4446	1,8560	1,4625	34,7512

Şekil 4.3'te, KNN modeli kullanılarak Ayvacık, Bozcaada, Ezine ve Gökçeada'daki rüzgâr hızının tahmin performansı değerlendirilmiştir. Bu grafikler, KNN algoritmasının her bir ilçe için gerçek rüzgâr hızlarını tahmin etme yeteneğini gösterir.

Değerlendirme sonuçları, modelin belirli dönemlerdeki tahmin doğruluğunu ve performansını analiz etmek için önemlidir. Bu bilgiler, rüzgâr tahmin modellerinin geliştirilmesi ve iyileştirilmesi için yol gösterici olabilir. Çizelge 4.3'te her bir lokasyon için eğitim ve test veri setleri üzerinde KNN modelinin R-kare, MSE, RMSE ve MAE ölçütleri incelenmiştir. İlk olarak, Ayvacık ilçesinde, modelin R-kare değeri 0,2571'dir. Bu değer, modelin gözlemlenen verileri açıklama yeteneğinin sınırlı olduğunu gösterir. MSE değeri 8,1009, RMSE değeri 2,8462, MAE değeri 2,2655 ve MAPE değeri 47,4903'tür. Bu istatistikler, modelin tahminlerinin gerçek verilere ne kadar yakın olduğunu ve tahminlerin ne kadar güvenilir olduğunu değerlendirir.

Bozcaada ilçesinde, R-kare değeri 0,2021'dir, bu da modelin gözlemlenen verileri açıklama yeteneğinin Ayvacık'tan daha düşük olduğunu gösterir. Ancak, MSE değeri 4,7138, RMSE değeri 2,1711, MAE değeri 1,6873 ve MAPE değeri 34,5691'dir. Bu istatistikler, Bozcaada'daki tahminlerin Ayvacık'a göre biraz daha iyi olduğunu ve modelin daha iyi performans gösterebileceğini gösterir.


Ezine ilçesinde, R-kare değeri 0,2710'dur ve Bozcaada ile benzer düzeydedir. MSE değeri 5,1016, RMSE değeri 2,2587, MAE değeri 1,7546 ve MAPE değeri 38,3161'dir. Bu istatistikler, Ezine'deki tahminlerin Bozcaada'dan biraz daha kötü olduğunu ancak yine de makul bir performans gösterdiğini gösterir.

Son olarak, Gökçeada ilçesinde, R-kare değeri 0,2732'dir ve Ezine ile benzer düzeydedir. MSE değeri 3,4446, RMSE değeri 1,8560, MAE değeri 1,4625 ve MAPE değeri 34,7512'dir. Bu istatistikler, Gökçeada'daki tahminlerin diğer ilçelere göre daha iyi olduğunu ve modelin bu ilçede daha iyi çalıştığını gösterir. Bu değerler, her bir ilçede KNN modelinin rüzgâr hızı tahmin performansını ayrıntılı bir şekilde değerlendirmemize olanak sağlar.

4.4. Karar Ağacı Analizi

Karar Ağacı modeli, rüzgâr hızı tahmininde yaygın olarak kullanılan bir yöntemdir. Karar ağaçları, veri kümesini sınıflandırmak veya regresyon yapmak için kullanılan ağaç benzeri bir yapıya sahiptir (Irfan vd., 2021). Bu model, veri setindeki özellikler arasındaki ilişkileri hiyerarşik olarak ifade eder ve bu ilişkileri kullanarak tahminler yapar. Rüzgâr hızı tahmini için Karar Ağacı modeli kullanıldığında, model eğitim veri setinde iyi bir uyum sağlayabilir ancak test veri setinde beklenmedik sonuçlar üretebilir. Bu durum, modelin aşırı uyum sorunu yaşadığını ve yeni verilere genelleme yapma yeteneğinin sınırlı olduğunu gösterebilir. Bu nedenle, Karar Ağacı modelinin

performansı değerlendirilirken hem eğitim hem de test veri setleri üzerinde dikkatle incelenmelidir (Sri Preethaa vd., 2023).



Şekil 4.4. Karar Ağacı modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri

Çizelge 4.4. Karar Ağacı modeline ait performans değerleri

İlçe	R-kare	MSE	RMSE	MAE	MAPE
Ayvacık	0,377	7,625	2,761	1,288	28,11
Bozcaada	0,303	4,570	2,138	0,973	38,92
Ezine	0,179	6,274	2,505	1,164	74,56
Gökçeada	0,290	3,427	1,851	0,815	31,12

Şekil 4.4'teki grafikler, Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerindeki günlük ortalama tahmin hızlarını Karar Ağacı modeliyle göstermektedir. Bu grafikler, her bir ilçe için oluşturulan Karar Ağacı modelinin günlük tahminlerini ve gerçek ölçümleri karşılaştırır. Grafikler, modelin her ilçe için nasıl performans gösterdiğini ve tahminlerin ne kadar doğru olduğunu görsel olarak gösterir. Bu görsel analiz, Karar Ağacı modelinin her bir ilçede rüzgâr hızı tahminlerini nasıl yaptığını daha iyi anlamamıza yardımcı olabilir. Bu bilgiler, modelin güvenilirliğini değerlendirmek ve gelecekteki tahminlerin iyileştirilmesi için yol gösterici olabilir


Çizelge 4.4' te verilere göre, her bir bölge için bir karar ağacı modeli oluşturulmuş ve bu modellerin eğitim ve test performansları ölçülmüştür. R-kare değeri, modelin verileri ne kadar iyi açıkladığını gösterir, 1'e ne kadar yakınsa o kadar iyidir. MSE, RMSE ve MAE ise modelin tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini ölçer. MAPE, sapmanın yüzdesel olarak ifadesidir.

Ayvacak ve Gökçeada için test R-kare değerleri negatif olduğundan, model bu bölgelerde beklenenden daha kötü tahminler yapmış gibi görünüyor. Bununla birlikte, Bozcaada ve Ezine için test R^2 değerleri pozitif ancak oldukça düşük, bu da modelin bu bölgelerde verileri açıklama yeteneğinin zayıf olduğunu gösterebilir.

Son olarak, her bölge için MAPE değerlerinin oldukça yüksek olduğu görülüyor, bu da modelin tahminlerinin gerçek değerlere göre yüksek oranda sapma gösterdiğini gösteriyor. Bu, modelin iyileştirilmesi gerektiğini veya daha fazla veri toplanması gerektiğini düşündürülebilir.

4.5. Destek Vektör Regresyon Analizi

SVR, karmaşık ilişkileri modellemek için kullanılan bir ML algoritmasıdır ve rüzgâr hızı tahmini gibi zaman serisi verilerinin analizinde yaygın olarak kullanılmaktadır (Singh ve Rizwan, 2023). SVR modeli, özellik vektörlerini yüksek boyutlu uzayda haritalayarak, bu uzayda bir hiperdüzlem oluşturarak ve bu hiperdüzlemi optimize ederek regresyon işlemini gerçekleştirir. Rüzgâr hızı tahmini bağlamında, SVR modeli, rüzgâr hızını etkileyen karmaşık faktörleri dikkate alarak doğru tahminler yapmaya çalışır. Ancak, elde edilen sonuçlara göre, SVR modeli genellikle düşük R-kare değerleri ve yüksek hata metrikleri ile karakterizedir. Bu durum, SVR'nin rüzgâr hızı tahmini konusunda diğer modellere kıyasla daha az etkili olduğunu işaret etmektedir. SVR modelinin başarısızlığı, rüzgâr hızının zaman içindeki değişkenliğiyle ilgili karmaşıklığı ve bu değişkenliği yeterince yakalayamamasından kaynaklanabilir. Bu nedenle, rüzgâr hızı tahmininde SVR gibi modellerin kullanımı, daha fazla geliştirme ve iyileştirme gerektirebilir (Alkabbani vd., 2023).



Şekil 4.5. SVR modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri

Çizelge 4.5. SVR modeline ait performans değerleri

İlçe	R-kare	MSE	RMSE	MAE	MAPE
Ayvacık	0,8654	10,5534	3,2457	2,5593	150,202
Bozcaada	0,8697	7,2792	2,6983	2,0775	42,449
Ezine	0,768	6,7865	2,6053	1,9278	31,116
Gökçeada	0,9112	4,3874	2,0955	1,6668	64,112

Şekil 4.5’te, Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerinin günlük ortalama tahmin hızlarını gösteren grafikler yer alıyor. Bu grafikler, SVR modelinin her bir ilçe için oluşturduğu tahminlerin, gerçek hızlarla karşılaştırılmasını sağlar. Bu verilerin analizi, her bir ilçenin hava tahmini modellerinin ne kadar doğru ve güvenilir olduğunu anlamak için önemli bir kaynak sağlar.


Çizelge 4.5’teki verilere göre, her bir bölge için oluşturulan SVR modellerinin performansı incelenmiştir. SVR modelleri, karar ağacı modellerine göre daha iyi bir performans sergiliyor gibi görünüyor, çünkü genel olarak daha yüksek R-kare değerleri ve daha düşük hata metrikleri elde edilmiş. Ayvacık, Bozcaada, Ezine ve Gökçeada ilçeleri için oluşturulan SVR modellerinin performansını değerlendirmek amacıyla kullanılmıştır. R-kare değerleri, her bir modelin bağımsız değişkenlerin bağımlı

değişkendeki varyansı ne kadar açıkladığını göstermektedir. Yüksek R-kare değerleri, modelin verilere ne kadar iyi uyduğunu gösterirken, düşük değerler ise modelin uyumsuzluğunu yansıtabilir. Bu bağlamda, Gökçeada ilçesi için en yüksek R-kare değerine sahipken, Ezine ilçesi için daha düşük bir değer gözlemlenmektedir. MSE ve RMSE değerleri, modelin gerçek değerlerden ne kadar uzak olduğunu ve bu uzaklığın büyüklüğünü ölçer. Düşük MSE ve RMSE değerleri, daha iyi bir model performansını işaret eder. Öte yandan, MAE ve MAPE değerleri, modelin tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini belirler. Bu istatistikler, her bir ilçe için oluşturulan SVR modellerinin performansının detaylı bir şekilde analiz edilmesine olanak sağlar. Ancak, bu istatistiklerin yanı sıra, modellerin başarısını tam olarak anlamak için görsel analiz de gereklidir. Grafiklerin incelenmesi, modelin tahminlerinin gerçek verilere göre nasıl dağıldığını ve her bir ilçenin hava koşullarına göre modelin performansının nasıl değiştiğini gözlemlemek açısından önemlidir. Bu nedenle, istatistiksel değerlendirmelerle birlikte, grafiklerin incelenmesi modelin doğruluğunun daha kapsamlı bir şekilde anlaşılmasına yardımcı olabilir. Her bir bölge için MAPE değerlerinin yine yüksek olduğu görülüyor, bu da SVR modellerinin de iyileştirilmesi gerektiğini gösteriyor. Yüksek MAPE değerleri, modellerin tahminlerinin gerçek değerlere göre hala yüksek oranda sapma gösterdiğini gösterir. Genel olarak, SVR modelleri karar ağacı modellerine göre daha iyi performans gösterse de hala iyileştirme potansiyeli bulunuyor gibi görünüyor. Daha fazla veri toplanması veya modelin ayarlanması gibi adımların düşünülmesi gerekebilir.

4.6. Geçitli Tekrarlayan Birim Analizi

Güncel araştırmalar, GRU gibi RNN türlerinin, zaman serisi verilerinin analizi ve tahmini gibi karmaşık problemlerde etkili bir şekilde kullanılabileceğini göstermektedir. GRU, özellikle zaman içindeki girdi verilerindeki uzun vadeli bağımlılıkları modellemek için tasarlanmıştır ve sınırlı bellek birimleri sayesinde önceki girdilerin önemini korur (Sevinç ve Kaya, 2021). Rüzgâr hızı tahmini gibi zaman serisi verilerinin analizinde GRU, geçmiş verilerle güncel durum arasındaki ilişkileri yakalamak ve gelecekteki değerleri tahmin etmek için kullanılır. GRU modeli, geleneksel istatistiksel yöntemlere göre daha esnek bir yapı sunar ve karmaşık hava dinamiklerini ve rüzgâr hızını etkileyen çeşitli faktörleri dikkate alarak tahminlerde bulunabilir. Bu nedenle, GRU gibi DL modelleri, rüzgâr hızı tahmininde etkili ve güvenilir bir araç olarak kabul edilir ve

gelecekteki arařtırmalarda daha geniř kapsamlı veri setleri ve daha geliřmiř modelleme teknikleriyle birlikte daha da iyileřtirilebilir (Ji vd., 2022).



řekil 4.6. GRU modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri

Çizelge 4.6. GRU modeline ait performans deęerleri

İlçe	R-kare	MSE	RMSE	MAE	MAPE
Ayvacık	0,698	7,133	2,671	2,127	75,412
Bozcaada	0,807	4,475	2,115	1,654	55,128
Ezine	0,847	5,497	2,345	1,922	92,189
Gökçeada	0,568	3,676	1,917	1,498	53,727

řekil 4.6’da, Ayvacık, Bozcaada, Ezine ve Gökçeada gibi řehirlere ait günlük ortalama rüzgâr hızı tahminlerini gösteren grafikler yer almaktadır. Bu grafikler, GRU modelinin her bir řehrin günlük rüzgâr hızlarını tahmin etme yeteneğini deęerlendirmek için kullanılmıřtır. GRU, zaman serileri analizi ve doęal dil iřleme gibi alanlarda yaygın olarak kullanılan bir tür tekrarlayan sinir aęı mimarisidir. Grafikler, modelin gerçek verilere ne kadar iyi uyum saęladığını ve tahminlerinin doęruluęunu görsel olarak gösterir. Bu tabloda, her bir bölge için bir GRU modeli oluřturulmuř ve bu modellerin performansı ölçölmüřtür. GRU modellerinin genel olarak iyi performans gösterdiği görölmektedir, çünkü yüksek R-kare deęerleri ve düşük hata metrikleri elde edilmiřtir. Bu, GRU modellerinin verileri daha iyi açıklama yeteneğine sahip olduęunu gösterebilir.


Çizelge 4.6'daki istatistikler, Ayvacık, Bozcaada, Ezine ve Gökçeada gibi ilçelerdeki rüzgâr hızı tahminlerinin performansını değerlendirmek için kullanılmıştır. R-kare, her bir modelin bağımsız değişkenlerin bağımlı değişkendeki varyansını açıklama yüzdesini ölçer. Yüksek R-kare değerleri, modelin verilere ne kadar iyi uydurulduğunu gösterirken, düşük değerler modelin uyumsuzluğunu işaret edebilir. MSE ve RMSE, modelin gerçek değerlerden ne kadar uzak olduğunu ve bu farkların büyüklüğünü ölçer. Düşük MSE ve RMSE değerleri, daha iyi bir model performansını işaret eder. Ancak, ilçelerin rüzgâr hızı tahminlerinde MAE ve MAPE değerlerine baktığımızda, Ezine ilçesinin MAPE değerinin yüksek olduğunu görmekteyiz. Bu durum, Ezine ilçesi için tahminlerin gerçek değerlerden daha fazla sapma gösterdiğini işaret edebilir. Bu istatistikler, her bir ilçe için oluşturulan tahmin modellerinin performansının detaylı bir şekilde analiz edilmesine olanak sağlar ve modelin geliştirilmesi için önemli ipuçları sunabilir.

Ancak, Ezine için MAPE değeri oldukça yüksek olduğundan, bu modelin bazı durumlarda hala yüksek oranda sapma gösterebileceğini gösterir. Bu durumda, modelin iyileştirilmesi veya ayarlanması gerekebilir.

Genel olarak, GRU modelleri diğer modellere kıyasla daha iyi performans göstermektedir. Ancak, her bir bölge için spesifik koşullar ve veri özellikleri dikkate alınarak modellerin iyileştirilmesi önemlidir.

4.7. Yapay Sinir Ağları Analizi

YSA, rüzgâr hızı tahmini gibi karmaşık zaman serisi verilerinin analizinde yaygın olarak kullanılan DL yöntemlerinden biridir (Demirtop ve Işık, 2023). Bu model, geniş veri setlerinden öğrenerek rüzgâr hızının zamana bağlı değişimini öngörmek için geliştirilmiştir. YSA, girdi verilerinden gizli ilişkileri öğrenerek esnek bir model oluşturur ve bu sayede rüzgâr hızı tahmininde doğruluk sağlamak için optimize edilir. Bu yöntem, karmaşık hava dinamiklerini ve rüzgâr hızını etkileyen çeşitli faktörleri göz önünde bulundurarak tahminlerde bulunabilir, ancak doğruluğu artırmak için sürekli olarak iyileştirilmelidir (Subrahmayam vd., 2024).



Şekil 4.7. YSA modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikler

Çizelge 4.7. YSA modeline ait performans değerleri

İlçe	R-kare	MSE	RMSE	MAE	MAPE
Ayvacık	0,0719	0,0323	3,1811	2,5334	215,9353
Bozcaada	-0,0018	0,0200	0,1414	0,1122	50,7574
Ezine	-0,0125	0,0193	0,1390	0,1039	34,8061
Gökçeada	0,0939	0,0201	0,1416	0,1125	73,1245

Şekil 4.7’de sunulan grafikler, Ayvacık, Bozcaada, Ezine ve Gökçeada gibi belirli bölgelerde YSA modelinin günlük ortalama tahmin hızlarını göstermektedir. YSA, DL alanında yaygın olarak kullanılan ve karmaşık veri yapılarını modellemek için kullanılan bir yapay zekâ modelidir. Grafiklerin incelenmesi, YSA modelinin her bir bölgede günlük hız tahminlerini ne kadar etkili bir şekilde gerçekleştirdiğini değerlendirmemize olanak sağlar. Bu tabloda, her bir bölge için bir YSA modeli oluşturulmuş ve bu modellerin performansı ölçülmüştür. Ancak, R-kare değerlerinin negatif olması ve MAPE değerlerinin iyi olmaması, modellerin kötü bir uyum sağladığını ve tahminlerin gerçek değerlerle uyumlu olmadığını gösterir. Bu durumda, YSA modellerinin iyileştirilmesi veya farklı bir modelleme yaklaşımının denenmesi gerekebilir.


Çizelge 4.7’deki istatistikler, Ayvacık, Bozcaada, Ezine ve Gökçeada gibi ilçeler için YSA modelinin performansını değerlendirmektedir. R-kare, her bir modelin

bağımsız değişkenlerin bağımlı değişkendeki varyansını açıklama yüzdesini ölçer. Ancak, bu ilçeler için R-kare değerlerinin oldukça düşük olduğunu görüyoruz, bu da modelin verilere uymadığını veya veri yapısını açıklamakta zorlandığını işaret edebilir. MSE ve RMSE, modelin gerçek değerlerden ne kadar uzak olduğunu ve bu farkların büyüklüğünü ölçer. Düşük MSE ve RMSE değerleri, daha iyi bir model performansını işaret eder. MAE ve MAPE, modelin tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini belirler. Ancak, bu ilçeler için MAPE değerlerinin oldukça yüksek olduğunu görmekteyiz, bu da modelin tahminlerindeki büyük sapmaları işaret eder. Bu istatistikler, YSA modelinin bu ilçeler için tahmin performansının zayıf olduğunu göstermektedir. Bu durum, modelin iyileştirilmesi veya farklı bir modelin kullanılması gerektiğini düşündürülebilir.

Bu bulgular, YSA modelinin Gökçeada'daki rüzgâr hızını tahmin etmede yetersiz kaldığını ve gerçek veriyle uyum sağlamada zorlandığını göstermektedir. Modelin performansındaki bu sınırlamalar, Gökçeada'daki rüzgâr hızının karmaşıklığını ve belki de modelin göz ardı ettiği veya yeterince yakalayamadığı önemli değişkenleri yansıtabilir. Bu sonuçlar, gelecekteki araştırmalarda daha gelişmiş modelleme tekniklerinin ve daha kapsamlı veri setlerinin kullanılmasının önemini vurgular.

4.8. Evrişimli Sinir Ağları Analizi

Rüzgâr hızı tahmini, birçok endüstride ve alanda önemli bir faktör olarak kabul edilir. Özellikle enerji üretimi, denizcilik, tarım ve havacılık gibi sektörlerde, doğru rüzgâr hızı tahmini büyük önem taşır (Uselis vd., 2020). CNN modeli, bu tahminleri daha hassas ve verimli hale getirmek için önemli bir adım olarak görülmektedir. Çünkü DL modelleri, büyük veri setlerinden karmaşık ilişkileri öğrenerek daha kesin tahminler yapabilirler. Bu nedenle, CNN gibi DL modellerinin rüzgâr hızı tahmini gibi önemli uygulamalarda kullanılması, gelecekte daha güvenilir ve verimli bir enerji üretimi, deniz taşımacılığı ve tarımsal faaliyetler gibi alanlarda önemli etkiler yaratabilir (Singh vd. 2024).



Şekil 4.8. CNN modeline ait Ayvacık (a), Bozcaada (b), Ezine (c) ve Gökçeada (d) ilçelerinin günlük ortalama rüzgâr hızı tahmin grafikleri

Çizelge 4.8. CNN modeline ait performans değerleri

İlçe	R-kare	MSE	RMSE	MAE	MAPE
Ayvacık	0,1722	0,0313	0,1770	0,1426	226,3784
Bozcaada	0,0322	0,0206	0,1435	0,1126	48,6647
Ezine	0,0279	0,0186	0,1362	0,1027	36,5688
Gökçeada	0,0757	0,0205	0,1430	0,1135	77,9277

Şekil 4.8, belirli bir ilçeye ait günlük ortalama tahmin hızlarını gösteren grafikleri içerir ve bu grafikler, CNN modelinin ilgili ilçenin günlük hız tahminlerini ne kadar başarılı bir şekilde gerçekleştirdiğini gösterir. CNN, DL alanında yaygın olarak kullanılan bir sinir ağı mimarisidir ve genellikle görüntü tanıma gibi görevlerde başarıyla uygulanmaktadır. Bu grafiklerin analizi, modelin hız tahminlerinin gerçek verilere ne kadar iyi uyum sağladığını değerlendirmeye olanak sağlar. Bu tabloda, her bir bölge için bir CNN modeli oluşturulmuş ve bu modellerin performansı ölçülmüştür. Ancak, CNN R-kare değerlerinin çok düşük veya negatif olması ve CNN MAPE değerlerinin sonsuz olması, CNN modellerinin kötü bir uyum sağladığını ve tahminlerin gerçek değerlerle uyumlu olmadığını gösterir. Bu durumda, CNN modellerinin iyileştirilmesi veya farklı bir modelleme yaklaşımının denenmesi gerekebilir.

Çizelge 4.8'deki istatistikler, Ayvacık, Bozcaada, Ezine ve Gökçeada gibi ilçeler için CNN modelinin performansını değerlendirmektedir. R-kare, her bir modelin

bağımsız değişkenlerin bağımlı değişkendeki varyansını açıklama yüzdesini ölçer. Ancak, bu ilçeler için R-kare değerlerinin oldukça düşük olduğunu görüyoruz, bu da modelin verilere uymadığını veya veri yapısını açıklamakta zorlandığını işaret edebilir. MSE ve RMSE, modelin gerçek değerlerden ne kadar uzak olduğunu ve bu farkların büyüklüğünü ölçer. Düşük MSE ve RMSE değerleri, daha iyi bir model performansını işaret eder. Ancak, ilçelerin tahminlerinde MAPE değerlerinin oldukça yüksek olduğunu görüyoruz, bu da modelin tahminlerinde büyük sapmaları işaret eder. Bu istatistikler, CNN modelinin bu ilçeler için tahmin performansının zayıf olduğunu göstermektedir. Bu durum, modelin iyileştirilmesi veya farklı bir modelin kullanılması gerektiğini düşündürülebilir.



5. SONUÇ VE ÖNERİLER

Rüzgâr enerjisi, YEK arasında önemli bir yere sahiptir ve enerji üretimi için potansiyel bir kaynak olarak ön plana çıkmaktadır. Rüzgâr hızının doğru bir şekilde tahmin edilmesi, rüzgâr enerjisi santrallerinin verimliliğinin artırılması ve enerji üretim süreçlerinin optimize edilmesi için hayati öneme sahiptir (Emeksiz vd., 2021). Bu bağlamda, ML ve DL teknikleri, rüzgâr hızı tahmininde giderek artan bir şekilde kullanılmaktadır.

Bu çalışma, Çanakkale ili Bozcada, Gökçeada, Ezine ve Ayvacık ilçelerindeki rüzgâr hızı, nem, sıcaklık, basınç gibi parametrelerin 2014-2021 yılları arasındaki ortalamalarını kullanarak farklı ML ve DL algoritmalarının algoritmalarıyla yapılan performans ölçümlerini ele almaktadır. Bu algoritmalar arasında LSTM, XGBoost, KNN, YSA ve CNN bulunmaktadır.

Çalışmanın temel amacı, mevcut literatüre katkı sağlamanın yanı sıra, rüzgâr türbinlerinin günlük, haftalık, aylık ve yıllık bakımlarına odaklanarak, bölgesel rüzgâr hızı tahminlerine yönelik gelecek projelere ve yatırımlara katkıda bulunmaktır. Ayrıca, deniz üstü ve kara üstü projelere katkı sağlamayı, çiftlik evlerine kurulacak güneş enerjisi veya rüzgâr enerjisi sistemlerinin hangisinin daha verimli olacağına dair bilgi sunmayı, gelecek nesil yenilenebilir enerji ihtiyaçlarını göz önünde bulundurmayı amaçlamaktadır. Bu çalışma, gelecekteki yenilenebilir enerji alanındaki yatırım ve projelerin stratejik planlamasına ışık tutacak önemli bilgiler sağlamayı hedeflemektedir.

Çizelge 5.1 Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerindeki veriler için LSTM, XGBoost, KNN, Karar Ağacı, SVR, GRU, YSA ve CNN algoritmalarının sonuçları

İlçe	Algoritma	R-kare	MSE	RMSE	MAE	MAPE
Ayvacık	XGBOOST	0,9438	0,8577	0,736	0,678	38,3416
	KNN	0,2571	8,1009	2,846	2,266	47,4903
	Karar Ağacı	0,377	7,625	2,761	1,288	28,11
	SVR	0,8654	10,553	3,246	2,559	150,202
	GRU	0,698	7,133	2,671	2,127	75,412
	YSA	0,0719	0,0323	3,181	2,533	215,935
	CNN	0,1722	0,0313	0,177	0,143	226,378
	LSTM	0,929	9,285	3,047	2,549	59,654
Bozcaada	XGBOOST	0,8851	0,9242	0,854	0,704	14,3904
	KNN	0,2021	4,7138	2,171	1,687	34,5691
	Karar Ağacı	0,303	4,57	2,138	0,973	38,92
	SVR	0,8697	7,2792	2,698	2,078	42,449
	GRU	0,807	4,475	2,115	1,654	55,128
	YSA	-0,002	0,02	0,141	0,112	50,7574
	CNN	0,0322	0,0206	0,144	0,113	48,6647
	LSTM	0,95	5,976	2,445	1,986	92,366
Ezine	XGBOOST	0,9034	0,7902	0,625	0,601	10,2798
	KNN	0,271	5,1016	2,259	1,755	38,3161
	Karar Ağacı	0,179	6,274	2,505	1,164	74,56
	SVR	0,768	6,7865	2,605	1,928	31,116
	GRU	0,847	5,497	2,345	1,922	92,189
	YSA	-0,013	0,0193	0,139	0,104	34,8061
	CNN	0,0279	0,0186	0,136	0,103	36,5688
	LSTM	0,909	6,764	2,601	2,269	79,247
Gökçeada	XGBOOST	0,9167	0,6657	0,443	0,529	21,2617
	KNN	0,2732	3,4446	1,856	1,463	34,7512
	Karar Ağacı	0,29	3,427	1,851	0,815	31,12
	SVR	0,9112	4,3874	2,096	1,667	64,112
	GRU	0,568	3,676	1,917	1,498	53,727
	YSA	0,0939	0,0201	0,142	0,113	73,1245
	CNN	0,0757	0,0205	0,143	0,114	77,9277
	LSTM	0,964	4,433	2,105	1,727	64,285

Python programıyla gerçekleştirilen analizler, LSTM, XGBoost, KNN, Karar Ağacı, SVR, GRU, YSA ve CNN gibi farklı makine öğrenme ve YSA modellerinin performansını değerlendirmiştir. Performans değerleri R-kare, MAE, RMSE, MAPE ve MSE gibi metrikler kullanılarak değerlendirilmiştir. Çizelge 5.1’de ki sonuçları detaylı bir şekilde yorumlarsak, Ayvacık, Bozcaada, Ezine ve Gökçeada ilçelerinde XGBoost modelinin genellikle en iyi performansı gösterdiği görülmektedir. XGBoost, yüksek R-

kare deęerleri ve dūřuk RMSE, MAE gibi hata metrikleri ile tahminlerin doęruluęu ve hassasiyeti aısından dięer modellere gre nemli avantajlar sunmaktadır. rneęin, Ayvacık ilesinde XGBoost modeli 0,9438 R-kare deęeri ile en yksek doęruluk saęlarken, Bozcaada ve Ezine’de de benzer řekilde yksek R-kare ve dūřuk hata metrikleriyle ne ıkmaktadır. Dięer taraftan, DL modelleri olan GRU, LSTM ve CNN, zaman serileri gibi zaman baęımlı veri setlerinde iyi performans sergileme potansiyeline sahip olsalar da, bazı durumlarda zellikle MAPE deęerlerinde dięer modellere gre daha yksek hata oranlarına sahip oldukları gzlenmektedir. rneęin, LSTM modeli Gkeada ilesinde 0,964 R-kare ile yksek doęruluęa sahipken, MAPE deęeri dięer modellere kıyasla daha yksektir, bu da tahminlerin yzde olarak doęruluęunun dięer modellere gre daha dūřuk olduęunu iřaret etmektedir. Basit ęrenme modelleri olarak adlandırılan ML ait KNN, Karar Aęacı ve SVR ise genellikle XGBoost’a gre daha dūřuk performans sergilemiřlerdir. zellikle KNN ve Karar Aęacı modelleri dūřuk R-kare deęerleri ve yksek hata metrikleri ile modelin tahmin gcnn sınırlı olduęunu gstermektedir. SVR modeli ise genellikle orta seviyede bir R-kare saęlasa da dięer hata metriklerinde XGBoost’a gre daha yksek deęerler gstermektedir. Son olarak, YSA modelinin genellikle ok dūřuk R-kare deęerleri ve yksek MAPE deęerleri ile tahmin performansının zayıf olduęu gzlemlenmektedir. Bu model genellikle karmařık iliřkileri ve zaman baęımlılıklarını yakalamakta dięer modellere gre daha zayıf kalmaktadır. Genel olarak, her bir modelin performansı ilelere gre farklılık gstermekle birlikte, XGBoost’un stabil ve yksek doęruluęuyla ne ıktıęı ve DL modellerinin ise belirli durumlarda ek avantajlar saęlayabileceęi sylenebilir. Ancak, modellerin seimi veri setinin zellikleri, modelin amacı ve hedeflenen doęruluk dzeyine baęlı olarak dikkatlice yapılmalıdır.

Sonuçlar, her bir modelin farklı blgelerdeki rzgr hızını tahmin etme yeteneęini ortaya koymuřtur. zellikle, LSTM ve XGBoost modelleri Ayvacık, Bozcaada, Ezine ve Gkeada’da yksek R-kare deęerleri ve dūřuk hata metrikleri ile en iyi performansı sergilemiřtir. Ancak, dięer modeller de belirli blgelerde bařarılı sonuçlar elde etmiřtir. Elde edilen sonuçlara gre ML ve DL ile ilgili her bir modele ait en iyi performansını veren modellerin avantaj ve dezavantajları izelge 5. 2’de verilmiřtir.

Çizelge 5.2. Performans değerlerine göre ML ve DL avantaj ve dezavantaj sonuçları

Algoritma	R-kare	MSE	RMSE	MAE	MAPE	Avantaj	Dezavantaj
ML (XGBoost)	0,9438	0,6657	0,443	0,529	14,3904	Hızlı eğitim süresi, geniş veri setlerinde etkili	Yüksek hiperparametre ayarı gerekebilir
ML (KNN)	0,2732	3,4446	1,856	1,463	34,7512	Basit uygulama, veriye duyarlı	Veri boyutu büyüdükçe performans düşebilir
ML (Karar Ağacı)	0,303	4,57	2,138	0,973	38,92	Anlaşılabilirlik, aşırı değerlere dayanıklılık	Overfitting eğilimi olabilir
ML (SVR)	0,9112	4,3874	2,096	1,667	64,112	Esnek kernel seçimi, yüksek boyutlarda etkili	Veri ölçeklendirmeye önemli, yavaş eğitim süresi
DL (GRU)	0,807	4,475	2,115	1,654	55,128	Zamansal ilişkileri yakalama yeteneği	Daha fazla veri ve hesaplama gücü gerektirebilir
DL (YSA)	0,0939	0,0201	0,142	0,113	73,1245	Basit mimari, küçük veri setlerinde kullanışlı	Derin öğrenme yöntemlerine kıyasla sınırlı performans
DL (CNN)	0,0757	0,0205	0,143	0,114	77,9277	Uzaysal yapıları yakalama, görüntü işlemede etkili	Seri verilerde uygulama zorlukları
DL (LSTM)	0,964	4,433	2,105	1,727	59,654	Zamansal bağımlılıkları uzun süreli hatırlama	Aşırı uyum (overfitting) eğilimi olabilir

Çizelge 5.2’de verilen performans metriklerine göre yapılan karşılaştırmalı analizde, XGBoost gibi geleneksel makine öğrenimi yöntemleri geniş veri setlerinde hızlı eğitim süresi ve etkili performans sunarken, yüksek hiperparametre ayarı gerekliliği dezavantaj olarak öne çıkmaktadır. KNN gibi basit modeller veriye duyarlı olmalarıyla bilinirken, veri boyutu arttıkça performanslarının düşebileceği gözlemlenmiştir. Karar ağacı algoritmaları anlaşılabilirlik ve outlier’lara karşı direnç avantajlarına sahip olsa da,

overfitting eğilimi bu yöntemin genelleme yeteneğini sınırlayabilir. SVR gibi destek vektör regresyonu esnek kernel seçimi ve yüksek boyutlarda etkin performans sunarken, veri ölçeklendirme ve uzun eğitim süreleri gibi dezavantajlar barındırabilir. DL teknikleri olan GRU ve LSTM zaman serisi verilerindeki zaman bağımlılıklarını modelleme yetenekleriyle öne çıkar ancak daha fazla veri ve hesaplama gücü gerektirebilirken, YSA ve CNN gibi daha basit mimarilere sahip modeller ise küçük veri setlerinde kullanışlı olabilirken genel olarak DL yöntemlerine kıyasla performanslarında sınırlılıklar yaşanabilir.

Bu sonuçlar, rüzgâr enerjisi endüstrisinde tahmin modellerinin geliştirilmesi ve rüzgâr enerjisi santrallerinin verimliliğinin artırılması konusunda önemli bir yol haritası sunmaktadır. Özellikle, rüzgâr hızı tahmininde ML ve DL tekniklerinin kullanımının, rüzgâr enerjisi üretiminde daha doğru ve güvenilir tahminler yapılmasına yardımcı olabileceği görülmektedir. Bu çalışma, gelecekteki araştırmalara ve uygulamalara yol göstermek amacıyla, rüzgâr enerjisi endüstrisindeki önemli bir boşluğu doldurmaktadır. Ayrıca, bu bulgular, YEK daha etkin bir şekilde kullanılmasını ve enerji üretiminin sürdürülebilirliğini artırmayı hedefleyen politika yapıcılar için de değerli bir kaynak olabilir. Rüzgâr hızı tahmininin doğruluğunu artırmak için öncelikle veri kalitesinin iyileştirilmesi gerekmektedir. Bu, meteorolojik veri toplama sistemlerinin güncellenmesi, sensörlerin düzenli bakımının yapılması ve veri kayıtlarının doğruluğunun sürekli olarak kontrol edilmesini içerir. Ayrıca, eksik veya hatalı verilerin düzeltilmesi için veri kalite kontrol süreçleri oluşturulmalıdır. Tahmin modellerinin güncel ve doğru tahminler yapabilmesi için düzenli olarak güncellenmesi ve eğitilmesi önemlidir. Bu, yeni veri akışlarına adapte olmayı ve değişen hava koşullarına uyumu sağlayabilir. Model güncellemeleri ve eğitim süreci, tahmin doğruluğunun artırılmasında kritik bir rol oynar.

Farklı ML ve DL algoritmalarının kullanılması, rüzgâr hızı tahmini modellerinin geliştirilmesi açısından önemlidir. Bu, model çeşitliliğinin artırılmasını ve en uygun modelin belirlenmesini sağlayabilir. Farklı modellerin performansının karşılaştırılması, doğru tahminlerin yapılmasına katkı sağlayabilir. Tahmin modellerinin bölgesel özelliklere uyum sağlaması için ilçeler arasındaki farklılıkların dikkate alınması önemlidir. Coğrafi faktörlerin ve yerel iklim koşullarının tahminler üzerindeki etkileri daha detaylı olarak incelenmeli ve analiz edilmelidir. Bölgesel analizlerin derinleştirilmesi, tahmin modellerinin doğruluğunu artırabilir.

KAYNAKLAR

- Ağbulut, Ü., Ayyıldız, M., ve Sarıdemir, S. (2020). Prediction of performance, combustion and emission characteristics for a CI engine at varying injection pressures. *Energy*, 197, 117257.
- Akgün, M., ve Barlik, N. (2023). Makine Öğrenmesi Algoritmaları Kullanılarak Hava Kalitesi İndeksinin Tahmini. *Avrupa Bilim Ve Teknoloji Dergisi*(51), 97-107. <https://doi.org/10.31590/ejosat.1241170>
- Akıncı, T. Ç., ve Noğay, H. S. (2019). Application of decision tree methods for wind speed estimation. *European Journal of Technique (EJT)*, 9(1), 74-83.
- Akkurt, T., ve Sarıçieçek, İ. Derin öğrenme teknikleri kullanılarak üretim sistemlerinde KPI tabanlı performans tahminleme. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 39(3), 1499-1508.
- Alizamir, M., Kim, S., Kisi, O., ve Zounemat-Kermani, M. (2020). A comparative study of several machine learning based non-linear regression methods in estimating solar radiation: Case studies of the USA and Turkey regions. *Energy*, 197, 117239.
- Alkabbani, H., Hourfar, F., Ahmadian, A., Zhu, Q., Almansoori, A., ve Elkamel, A. (2023). Machine Learning-based Time Series Modelling for Large-Scale Regional Wind Power Forecasting: a Case Study in Ontario, Canada. *Cleaner Energy Systems*, 5, 100068.
- Alloghani, M., Al-Jumeily, D., Mustafina, J., Hussain, A., ve Aljaaf, A. J. (2020). A systematic review on supervised and unsupervised machine learning algorithms for data science. *Supervised and unsupervised learning for data science*, 3-21.
- Altan, A., ve Karasu, S. (2020). Ayırıştırma Yöntemlerinin Derin Öğrenme Algoritması ile Tanımlanan Rüzgâr Hızı Tahmin Modeli Başarımına Etkisinin İncelenmesi. *Avrupa Bilim Ve Teknoloji Dergisi*(20), 844-853. <https://doi.org/10.31590/ejosat.785699>
- Androniceanu, A., ve Sabie, O. M. (2022). Overview of green energy as a real strategic option for sustainable development. *Energies*, 15(22), 8573.
- Arslan, İ. (2019). Python ile veri bilimi. Pusula.
- Asselman, A., Khaldi, M., ve Aammou, S. (2023). Enhancing the prediction of student performance based on the machine learning XGBoost algorithm. *Interactive Learning Environments*, 31(6), 3360-3379.
- Atalay, M., ve Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları-artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.

- Bakırov, R., ve Aslan, Z. (2023). Rüzgâr şiddetinin yapay sinir ağları yöntemleri ile modellenmesi. *Anadolu Bil Meslek Yüksekokulu Dergisi*, 17(66), 117-137.
- Barış, C., Bilgin, A. C., ve Altan, A. (2021). Ampirik Kip Ayırıştırma Yöntemi ile Elde Edilen İçsel Kip Fonksiyonlarının Derin Öğrenme Tabanlı Rüzgâr Hızı Tahmin Modeli Başarımına Etkisinin Belirlenmesi. *Avrupa Bilim Ve Teknoloji Dergisi*(31), 661-669. <https://doi.org/10.31590/ejosat.1026742>
- Bayraç, H. N., ve Çildir, M. (2017). AB Yenilenebilir Enerji Politikalarının Ekonomik Büyüme Üzerindeki Etkisi. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 13(13), 201-212.
- BenMoshe, N., Fattal, E., Leitl, B., ve Arav, Y. (2023). Using machine learning to predict wind flow in urban areas. *Atmosphere*, 14(6), 990.
- Benti, N. E., Chaka, M. D., ve Semie, A. G. (2023). Forecasting renewable energy generation with machine learning and deep learning: Current advances and future prospects. *Sustainability*, 15(9), 7087.
- Beyoğlu, M. F. (2023). Analitik ve derin öğrenme yöntemleriyle Balıkesir koşullarında şebekeye bağlı bir güneş enerji santralinin modellenmesi ve verimlilik analizi.
- Buntine, W. (2020). Learning classification trees. In *Artificial Intelligence frontiers in statistics* (pp. 182-201). Chapman and Hall/CRC.
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., ve Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189-215.
- Charbuty, B., ve Abdulazeez, A. (2021). Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 2(01), 20-28.
- Chen, Y., Guo, M., Chen, Z., Chen, Z., ve Ji, Y. (2022). Physical energy and data-driven models in building energy prediction: A review. *Energy Reports*, 8, 2656-2671.
- Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., ve Campbell, J. P. (2020). Introduction to machine learning, neural networks, and deep learning. *Translational vision science ve technology*, 9(2), 14-14.
- Çalışan, M., ve Talu, M. F. (2020). Boyut İndirgeme Yöntemlerinin Karşılaştırmalı Analizi. *Türk Doğa ve Fen Dergisi*, 9(1), 107-113.
- Demirgöl, T., Demir, V., ve Sevimli, M. F. (2024) Farklı makine öğrenmesi yaklaşımları ile Türkiye'nin solar radyasyon tahmini. *Geomatik*, 9(1), 106-122.
- Demirtaş, A. (2019). Döner kanatlı insansız hava araçları ile görsel verilere dayalı erken yangın algılama sistemi (Master's thesis, Fen Bilimleri Enstitüsü).

- Demirtop, A., ve Işık, A. H. (2023). Yapay Sinir Ağları ile Rüzgâr Enerji Verimliliğine Yönelik Yeni Bir Tahmin Yaklaşımı: Çanakkale ili Bozcaada Örneği. *Uluslararası Mühendislik Tasarım ve Teknoloji Dergisi*, 5(1-2), 25-32.
- DMİ, (2022). Devlet Meteoroloji İşleri Genel Müdürlüğü. Erişim adresi <https://www.mgm.gov.tr/> (Son Erişim Tarihi: 06/06/2024).
- Dincer, I. (2000). Renewable energy and sustainable development: a crucial review. *Renewable and sustainable energy reviews*, 4(2), 157-175.
- Ellabban, O., Abu-Rub, H., ve Blaabjerg, F. (2014). Renewable energy resources: Current status, future prospects and their enabling technology. *Renewable and sustainable energy reviews*, 39, 748-764.
- Emeksiz, C., ve Fındık, M. M. (2021). Sürdürülebilir kalkınma için yenilenebilir enerji kaynaklarının Türkiye ölçeğinde değerlendirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 155-164.
- Fang, Y., Wu, Y., Wu, F., Yan, Y., Liu, Q., Liu, N., ve Xia, J. (2023). Short-term wind speed forecasting bias correction in the Hangzhou area of China based on a machine learning model. *Atmospheric and Oceanic Science Letters*, 16(4), 100339.
- Gabralı, D., ve Aslan, Z. (2020). Güneş enerjisi potansiyelinin çoklu lineer regresyon ve yapay sinir ağları ile modellenmesi. *AURUM Journal of Engineering Systems and Architecture*, 4(1), 23-36.
- Ghiasi, B., Jodeiri, A., ve Andik, B. (2021). Using a deep convolutional network to predict the longitudinal dispersion coefficient. *Journal of Contaminant Hydrology*, 240, 103798.
- Ghiasi, M. M., Zendehboudi, S., ve Mohsenipour, A. A. (2020). Decision tree-based diagnosis of coronary artery disease: CART model. *Computer methods and programs in biomedicine*, 192, 105400.
- Gielen, D., Boshell, F., Saygin, D., Bazilian, M. D., Wagner, N., ve Gorini, R. (2019). The role of renewable energy in the global energy transformation. *Energy strategy reviews*, 24, 38-50.
- Goar, V., ve Yadav, N. S. (2024). Foundations of machine learning. In *Intelligent Optimization Techniques for Business Analytics* (pp. 25-48). IGI Global.
- Goldberg, Y. (2022). *Neural network methods for natural language processing*. Springer Nature.
- Görgel and E. Kavlak, “Uzun Kısa Süreli Hafıza ve Evrimsel Sinir Ağları ile Rüzgâr Enerjisi Üretim Tahmini”, *DUJE*, vol. 11, no. 1, pp. 69–80, 2020, doi: 10.24012/dumf.596533.

- Grönquist, P., Yao, C., Ben-Nun, T., Dryden, N., Dueben, P., Li, S., ve Hoefler, T. (2021). Deep learning for post-processing ensemble weather forecasts. *Philosophical Transactions of the Royal Society A*, 379(2194), 20200092.
- Grübler, A., Nakićenović, N., ve Victor, D. G. (1999). Dynamics of energy technologies and global change. *Energy policy*, 27(5), 247-280.
- Güneş, M. A. (2009). Türkiye'nin enerji sorunu için alternatif çözüm önerileri ve rüzgâr enerjisinin önemi (Master's thesis, Adnan Menderes Üniversitesi, Sosyal Bilimler Enstitüsü).
- Hanifi, S., Cammarono, A., ve Zare-Behtash, H. (2024). Advanced hyperparameter optimization of deep learning models for wind power prediction. *Renewable Energy*, 221, 119700.
- Hao, Y., Yang, W., ve Yin, K. (2023). Novel wind speed forecasting model based on a deep learning combined strategy in urban energy systems. *Expert Systems with Applications*, 219, 119636.
- Hatipoğlu, A., Güneri, Y., ve YILMAZ, E. (2024). Makine ve derin öğrenme temelli karşılaştırmalı bir öngörücü bakım uygulaması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 39(2), 1037-1048.
- Huang, H. H., ve Huang, Y. H. (2024). Applying green learning to regional wind power prediction and fluctuation risk assessment. *Energy*, 295, 131057.
- Huertas-Tato, J., Aler, R., Galván, I. M., Rodríguez-Benítez, F. J., Arbizu-Barrena, C., ve Pozo-Vázquez, D. (2020). A short-term solar radiation forecasting system for the Iberian Peninsula. Part 2: Model blending approaches based on machine learning. *Solar Energy*, 195, 685-696.
- Irfan, A. S. M., Bhuiyan, N. H., Hasan, M., ve Khan, M. M. (2021, July). Performance analysis of machine learning techniques for wind speed prediction. In *2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1-6). IEEE.
- Ji, L., Fu, C., Ju, Z., Shi, Y., Wu, S., ve Tao, L. (2022). Short-term canyon wind speed prediction based on CNN—GRU transfer learning. *Atmosphere*, 13(5), 813.
- Karabulut, M. A., ve Topçu, E. (2022). Derin Öğrenme Tekniği Kullanılarak Kars İlının Hava Sıcaklık Tahmini. *Mühendislik Bilimleri ve Tasarım Dergisi*, 10(4), 1174-1181. <https://doi.org/10.21923/jesd.1067700>
- Karadağ, K. (2022). Hibrit derin öğrenme modelleri ile hisse senedi fiyat tahmini (Master's thesis, Trakya Üniversitesi Sosyal Bilimler Enstitüsü).
- Karadavut, C. (2014). WRF ve ALARO sayısal hava tahmin modelleri için verifikasyon sonuçlarının karşılaştırılması (Master's thesis, Fen Bilimleri Enstitüsü).

- Karaman, Ö. A. (2023). Prediction of wind power with machine learning models. *Applied Sciences*, 13(20), 11455.
- Kattenborn, T., Leitloff, J., Schiefer, F., ve Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 173, 24-49.
- Khan, A., Sohail, A., Zahoor, U., ve Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial intelligence review*, 53, 5455-5516.
- Kiliç, C. (2009). Küresel İklim Değişikliği Çerçevesinde Sürdürülebilir Kalkınma Çabaları ve Türkiye. *Cumhuriyet Üniversitesi Journal Of Economics ve Administrative Sciences (JEAS)*, 10(2).
- Korkmaz, M. S., Öztürk, N., ve Harnuboğlu, S. (2024). Kırşehir il sınırları içerisinde Rüzgâr Enerjisi Santrali (RES) kurulumu için uygun sahaların mekânsal olarak belirlenmesi. *Düzce Üniversitesi Bilim Ve Teknoloji Dergisi*, 12(1), 463-495. <https://doi.org/10.29130/dubited.1181883>
- Kumar Srivastava, A., Singh, D., ve Pandey, A. S. (2020). Short term load forecasting using regression trees: Random forest, bagging and m5p.
- Li, A., Yuan, M., Zheng, C., ve Li, X. (2020). Speech enhancement using progressive learning-based convolutional recurrent neural network. *Applied Acoustics*, 166, 107347.
- Lipu, M. H., Miah, M. S., Hannan, M. A., Hussain, A., Sarker, M. R., Ayob, A., ... ve Mahmud, M. S. (2021). Artificial intelligence based hybrid forecasting approaches for wind power generation: Progress, challenges and prospects. *IEEE Access*, 9, 102460-102489.
- Liu, B., Ma, X., Guo, J., Li, H., Jin, S., Ma, Y., ve Gong, W. (2023). Estimating hub-height wind speed based on a machine learning algorithm: implications for wind energy assessment. *Atmospheric Chemistry and Physics*, 23(5), 3181-3193.
- Meddage, D. P. P., Mohotti, D., ve Wijesooriya, K. (2024). Predicting transient wind loads on tall buildings in three-dimensional spatial coordinates using machine learning. *Journal of Building Engineering*, 108725.
- Mohd, Y., ve Singh, H. (2024, March). Wind energy forecasting and analysis using machine learning. In *AIP Conference Proceedings* (Vol. 3072, No. 1). AIP Publishing.
- Mollick, T., Hashmi, G., ve Sabuj, S. R. (2024). Wind speed prediction for site selection and reliable operation of wind power plants in coastal regions using machine learning algorithm variants. *Sustainable Energy Research*, 11(1), 5.
- Moreno, S. R., Seman, L. O., Stefenon, S. F., dos Santos Coelho, L., ve Mariani, V. C. (2024). Enhancing wind speed forecasting through synergy of machine learning,

- singular spectral analysis, and variational mode decomposition. *Energy*, 292, 130493.
- Nusinovici, S., Tham, Y. C., Yan, M. Y. C., Ting, D. S. W., Li, J., Sabanayagam, C., ... ve Cheng, C. Y. (2020). Logistic regression was as good as machine learning for predicting major chronic diseases. *Journal of clinical epidemiology*, 122, 56-69.
- Oğuz, K., ve Pekin, M. A. (2024). Prediction of Air Pollution with Machine Learning Algorithms. *Turkish Journal of Science and Technology*, 19(1), 1-12. <https://doi.org/10.55525/tjst.1224661>
- Ouali, Y., Hudelot, C., ve Tami, M. (2020). An overview of deep semi-supervised learning. *arXiv preprint arXiv:2006.05278*.
- Özkay, B. (2021). Derin öğrenme kullanılarak Bilecik ili rüzgâr hızı tahmini (Master's thesis, Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü).
- Öztürk, B., ve Bilgiç, G. (2022). Yenilenebilir Enerji Tahmini İçin Derin Öğrenme Yaklaşımları. *Teknobilim-2022: Enerji Krizi ve Yenilenebilir Enerji*, 111.
- Öztürk, M., ve Öztürk, A. (2019). BMİDÇS'den Paris Anlaşması'na: Birleşmiş Milletler'in iklim değişikliğiyle mücadele çabaları. *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 12(4), 527-541.
- Quaschnig, V. V. (2019). *Renewable energy and climate change*. John Wiley ve Sons.
- Rababaah, A. R. (2023). Comparative Study of Deep Learning Models Versus Machine Learning Models for Wind Turbine Intelligent Health Diagnosis Systems. *Arabian Journal for Science and Engineering*, 48(8), 10875-10899.
- Ren, Y., ve Suganthan, P. N. (2014). Empirical mode decomposition-k nearest neighbor models for wind speed forecasting. *Journal of Power and Energy Engineering*, 2(4), 176-185.
- Rodríguez, F., Alonso-Pérez, S., Sánchez-Guardamino, I., ve Galarza, A. (2023). Ensemble forecaster based on the combination of time-frequency analysis and machine learning strategies for very short-term wind speed prediction. *Electric Power Systems Research*, 214, 108863.
- Rogelj, J., Den Elzen, M., Höhne, N., Fransen, T., Fekete, H., Winkler, H., ... ve Meinshausen, M. (2016). Paris Agreement climate proposals need a boost to keep warming well below 2 C. *Nature*, 534(7609), 631-639.
- Rogelj, J., Geden, O., Cowie, A., ve Reisinger, A. (2021). Three ways to improve net-zero emissions targets. *Nature*, 591(7850), 365-368.
- Sada, S. O., ve Ikpeseni, S. C. (2021). Evaluation of ANN and ANFIS modeling ability in the prediction of AISI 1050 steel machining performance. *Heliyon*, 7(2).

- Sağ, R., ve Hasırcı Tuğcu, Z. (2023). Akıllı Şebeke Uygulamalarında Derin Öğrenme Tekniklerinin Kullanımına İlişkin Kısa Bir İnceleme. EMO Bilimsel Dergi, 13(1), 41-61.
- Sahoo, K., Samal, A. K., Pramanik, J., ve Pani, S. K. (2019). Exploratory data analysis using Python. International Journal of Innovative Technology and Exploring Engineering, 8(12), 4727-4735.
- Sahu, M., ve Dash, R. (2021). A survey on deep learning: convolution neural network (CNN). In Intelligent and Cloud Computing: Proceedings of ICICC 2019, Volume 2 (pp. 317-325). Springer Singapore.
- Sevinç, A., ve Kaya, B. (2021). Derin Öğrenme ve İstatistiksel Modelleme Yöntemiyle Sıcaklık Tahmini ve Karşılaştırılması. Avrupa Bilim Ve Teknoloji Dergisi(28), 1222-1228. <https://doi.org/10.31590/ejosat.1014106>
- Sherstinsky, A. (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. Physica D: Nonlinear Phenomena, 404, 132306.
- Shi, Z., Hu, Y., Mo, G., ve Wu, J. (2022). Attention-based CNN-LSTM and XGBoost hybrid model for stock prediction. arXiv preprint arXiv:2204.02623.
- Sinaga, K. P., ve Yang, M. S. (2020). Unsupervised K-means clustering algorithm. IEEE access, 8, 80716-80727.
- Singh, S. K., Jha, S. K., ve Gupta, R. (2024). Enhancing the accuracy of wind speed estimation model using an efficient hybrid deep learning algorithm. Sustainable Energy Technologies and Assessments, 61, 103603.
- Singh, U., ve Rizwan, M. (2023). Analysis of wind turbine dataset and machine learning based forecasting in SCADA-system. Journal of Ambient Intelligence and Humanized Computing, 14(6), 8035-8044.
- Sri Preethaa, K. R., Muthuramalingam, A., Natarajan, Y., Wadhwa, G., ve Ali, A. A. Y. (2023). A Comprehensive Review on Machine Learning Techniques for Forecasting Wind Flow Pattern. Sustainability, 15(17), 12914.
- Subasi, A. (2020). Practical machine learning for data analysis using python. Academic Press.
- Subrahmayam, K. V., Udupa, S. R., Kumar, K. K., Ramana, M. V., Srinivasulu, J., ve Bothale, R. V. (2024). Prediction of Zonal Wind Using Machine Learning Algorithms: Implications to Future Projections of Indian Monsoon Jets. Journal of the Indian Society of Remote Sensing, 1-11.
- Sun, L., Lan, Y., Sun, X., Liang, X., Wang, J., Su, Y., ... ve Xia, D. (2024). Deterministic forecasting and probabilistic post-processing of short-term wind speed using statistical methods. Journal of Geophysical Research: Atmospheres, 129(7), e2023JD040134

- Sweeney, C., Bessa, R. J., Browell, J., ve Pinson, P. (2020). The future of forecasting for renewable energy. *Wiley Interdisciplinary Reviews: Energy and Environment*, 9(2), e365.
- ETKB. (2024). T.C Enerji ve Tabii Kaynaklar Bakanlığı. Erişim adresi <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-ruzgar> (Son Erişim Tarihi: 06/06/2024).
- Tarek, Z., Shams, M. Y., Elshewey, A. M., El-kenawy, E. S. M., Ibrahim, A., Abdelhamid, A. A., ve El-dosuky, M. A. (2023). Wind Power Prediction Based on Machine Learning and Deep Learning Models. *Computers, Materials ve Continua*, 75(1).
- Timilsina, G. R., van Kooten, G. C., ve Narbel, P. A. (2013). Global wind power development: Economics and policies. *Energy Policy*, 61, 642-652.
- Tyass, I., Khalili, T., Mohamed, R., Abdelouahed, B., Raihani, A., ve Mansouri, K. (2023). Wind speed prediction based on statistical and deep learning models. *International Journal of Renewable Energy Development*, 12(2), 288.
- IEA. (2024). Uluslararası Enerji Ajansı, International Energy Agency: <https://www.iea.org/reports/world-energy-outlook-2023/pathways-for-the-energy-mix> (Son Erişim Tarihi: 06/06/2024). Bilgi
- Uselis, A., Lukoševičius, M., ve Stasytis, L. (2020). Localized convolutional neural networks for geospatial wind forecasting. *Energies*, 13(13), 3440.
- Van Engelen, J. E., ve Hoos, H. H. (2020). A survey on semi-supervised learning. *Machine learning*, 109(2), 373-440.
- Voyant, C., Notton, G., Kalogirou, S., Nivet, M. L., Paoli, C., Motte, F., ve Foulloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable energy*, 105, 569-582.
- Wan, A., Du, C., Gong, W., Wei, C., AL-Bukhaiti, K., Ji, Y., ... ve Ao, L. (2024). Using Transfer Learning and XGBoost for Early Detection of Fires in Offshore Wind Turbine Units. *Energies*, 17(10), 2330.
- Wang, J., ve Hu, J. (2015). A robust combination approach for short-term wind speed forecasting and analysis—Combination of the ARIMA (Autoregressive Integrated Moving Average), ELM (Extreme Learning Machine), SVM (Support Vector Machine) and LSSVM (Least Square SVM) forecasts using a GPR (Gaussian Process Regression) model. *Energy*, 93, 41-56.
- Wang, J., Guo, H., Li, Z., Song, A., ve Niu, X. (2023). Quantile deep learning model and multi-objective opposition elite marine predator optimization algorithm for wind speed prediction. *Applied Mathematical Modelling*, 115, 56-79.
- Wazirali, R., Yaghoubi, E., Abujazar, M. S. S., Ahmad, R., ve Vakili, A. H. (2023). State-of-the-art review on energy and load forecasting in microgrids using artificial neural

- networks, machine learning, and deep learning techniques. *Electric power systems research*, 225, 109792.
- Wood, D. A. (2023). Feature averaging of historical meteorological data with machine and deep learning assist wind farm power performance analysis and forecasts. *Energy Systems*, 14(4), 1023-1049.
- Yesilbudak, M., Sagioglu, S., ve Colak, I. (2017). A novel implementation of kNN classifier based on multi-tupled meteorological input data for wind power prediction. *Energy conversion and management*, 135, 434-444.
- Yıldırım, O., Gunay, F. B., ve Yağanoğlu, M. (2023). Makine Öğrenmesi Yöntemleriyle Orman Yangını Tahmini. *Journal of the Institute of Science and Technology*, 13(3), 1468-1481. <https://doi.org/10.21597/jist.1249908>
- Yılmaz, O. (2024). Rüzgâr türbinlerinde yapay zeka tabanlı arıza teşhisi mekanizması (Master's thesis, Bilecik Şeyh Edebali Üniversitesi, Lisansüstü Eğitim Enstitüsü).
- Zendehboudi, A., Baseer, M. A., ve Saidur, R. (2018). Application of support vector machine models for forecasting solar and wind energy resources: A review. *Journal of cleaner production*, 199, 272-285.
- Zhang, Y., Wang, J., ve Wang, X. (2014). Review on probabilistic forecasting of wind power generation. *Renewable and Sustainable Energy Reviews*, 32, 255-270.
- Zheng, Y., Ge, Y., Muhsen, S., Wang, S., Elkamchouchi, D. H., Ali, E., ve Ali, H. E. (2023). New ridge regression, artificial neural networks and support vector machine for wind speed prediction. *Advances in Engineering Software*, 179, 103426.
- Zhou, J., Feng, J., Zhou, X., Li, Y., ve Zhu, F. (2023). Estimating Site-Specific Wind Speeds Using Gridded Data: A Comparison of Multiple Machine Learning Models. *Atmosphere*, 14(1), 142.
- Zhou, Z. H., ve Zhou, Z. H. (2021). Semi-supervised learning. *Machine Learning*, 315-341.