

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKILLI ŞEBEKELERDE MAKİNE ÖĞRENMESİ
TEKNİKLERİYLE KISA DÖNEM RÜZGÂR HIZI TAHMİNİ:
KOCAELİ-TÜRKİYE ÖRNEĞİ

DOKTORA TEZİ

Maysa GAIDOOUM AHMED GAIDOOM

Elektrik-Elektronik Mühendisliği

Elektronik Mühendisliği

MAYIS 2024

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKILLI ŞEBEKELERDE MAKİNE ÖĞRENMESİ
TEKNİKLERİYLE KISA VADELİ RÜZGÂR HIZI TAHMİNİ:
KOCAELİ-TÜRKİYE ÖRNEĞİ

DOKTORA TEZİ

Maysa GAIDOUM AHMED GAIDOUM

Elektrik-Elektronik Mühendisliği

Elektronik Mühendisliği

Tez Danışmanı: Prof. Dr. Yılmaz UYAROĞLU

Ortak Danışman: Dr. Öğr. Üyesi Abdullah Hulusi KÖKÇAM

MAYIS 2024

Maysa Gaidoum Ahmed Gaidoum tarafından hazırlanan “Akıllı şebekelerde makine öğrenmesi teknikleriyle kısa vadeli rüzgâr hızı tahmini: Kocaeli-Türkiye örneği ” adlı tez çalışması 16.05.2024 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektronik Mühendisliği Bilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Prof. Dr. Yılmaz UYAROĞLU Sakarya Üniversitesi	
Jüri Üyesi :	Prof. Dr. İhsan PEHLİVAN Sakarya Uygulamalı Bilimler Üniversitesi	
Jüri Üyesi :	Doç. Dr. Selçuk EMİROĞLU Sakarya Üniversitesi	
Jüri Üyesi :	Doç. Dr. Üyesi Murat İSKEFİYELİ Sakarya Üniversitesi	
Jüri Üyesi :	Dr. Öğr. Üyesi Burak ARICIOĞLU Sakarya Uygulamalı Bilimler Üniversitesi	



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “**AKILLI ŞEBEKELERDE MAKİNE ÖĞRENMESİ TEKNİKLERİYLE KISA VADELİ RÜZGÂR HIZI TAHMİNİ: KOCAELİ-TÜRKİYE ÖRNEĞİ**” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(16/05/2024).

(imza)

Maysa GAIDOOUM AHMED GAIDOUM





Bu tez, değerli sevdiklerime adanmıştır; aileme, dostlarıma, danışmanıma ve ortak danışmanıma, doktora eğitimim süresince sundukları destek için minnettarlıkla teşekkür ederim.



TEŞEKKÜR

Öncelikle dekan yardımcısı Prof. Dr. Özer Uygun'a, başından beri yanımda olduğu için çok teşekkür etmek istiyorum.

Tez danışmanım Prof. Dr. Yılmaz Uyaroğlu'na paha biçilemez sabrı ve geribildirimi, aynı konuda kendisiyle devam etmem ve sağladığı bazı kaynaklar ve modeller hakkında bilgi için çok teşekkür ederim. Bilgi ve becerileri büyük bir yürekle sağlayan savunma komitem olmasaydı, bu yolculuğu gerçekleştiremezdim.

Tez konumu bulmamda bana yardımcı olan Prof. Dr. Mehmet Bayrak'a teşekkür etmek istiyorum.

Ayrıca Fen Bilimleri Enstitüsü yönetim kuruluna, sağlığım ve Sudan'ın savaş koşulları konusunda yardımları ve değerlendirmeleri için teşekkür ediyorum.

Bundan başka bu çaba, danışmanım Dr. Abdullah Kokçam'ın cömert desteği olmasaydı mümkün olamazdı. Onun teşviki ve rehberliği olmasaydı bu tezi bitiremezdim.

Ailem, özellikle annem, babamın ruhu, kardeşlerim ve sevgili dostlarım özel olarak anılmayı hak ediyor. Bana inandıkları için bu süreçte ruhum ve motivasyonum çok canlı oldu.

Maysa GAIDOOUM AHMED GAIDOUM



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
TABLO LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET	xix
SUMMARY	xxi
1. GİRİŞ	25
1.1. Tezin Kapsamı.....	26
1.2. Araştırma soruları.....	27
1.3. Tezin Amacı	27
1.4. Çalışmanın Önemi.....	27
1.5. Tezin Organizasyonu.....	28
2. TÜRKİYE'DE YENİLENEBİLİR ENERJİ VE RÜZGÂR ENERJİSİ KAYNAKLARI	31
2.1. Yenilenebilir Enerji Kaynakları:	31
2.2. Rüzgâr Enerjisi	34
2.3. Türkiye'de Rüzgâr Enerjisi.....	36
2.3.1. Kocaeli'de Rüzgâr Enerjisi	39
2.4. Rüzgâr Hızı	42
3. RÜZGÂR HIZI TAHMİN MEKANİZMALARI	43
3.1. Rüzgâr Tahmini.....	43
3.2. Rüzgâr Hızı Tahmininin Akıllı Şebekeler için Önemi.....	44
3.3. Rüzgâr Hızı Tahmini Sınıflandırılması	45
3.3.1. Zaman ölçeği sınıflandırmaları	45
3.3.1.1. Çok- kısa dönem	45
3.3.1.2. Kısa -dönem	45
3.3.1.3. Orta dönem.....	46
3.3.1.4. Uzun dönem	46
3.3.1.5. Aylık, mevsimsel ve özel kategoriler.....	46
3.3.2. Metodoloji sınıflandırmaları	47
3.3.2.1. Fiziksel yaklaşım (belirgin yaklaşım)	47
3.3.2.2. İstatistiksel yaklaşım	48
3.4. Rüzgâr Tahminini Etkileyen Faktörler.....	49
3.5. Rüzgâr Hızı Tahmininin Zorlukları ve Sınırlamaları	52
3.6. Rüzgâr Hızı / Rüzgâr Gücü (WS/WP) Tahmini Gelecek Trendleri.....	52
3.6.1. Yeni veri ön işleme yöntemlerinin geliştirilmesi	53
3.6.2. Aday özelliklerin genişlemesi	53
3.6.3. Uygun özellik çıkarma yöntemlerinin geliştirilmesi.....	53
3.6.4. Tahmin modellerindeki doğrusal olmayan uyumun geliştirilmesi	53

3.6.5. Çeşitli tahmin modelleri için optimal yapılandırmaların belirlenmesi.....	53
4. VERİ TOPLAMA VE ÖN İŞLEME	55
4.1. Arka Plan.....	55
4.2. Veri Toplama Hedefleri.....	55
4.3. Veri Kaynakları	55
4.3.1. Toplama süreci	56
4.3.2. Veri ön işleme teknikleri	56
4.3.3. Deneysel çalışma.....	59
4.4. Performans Değerlendirmesi ve Tahmin Yöntemlerinin Karşılaştırılması	62
4.5. Hiperparametre Ayarlama	62
5. METODOLOJİ	65
5.1. Model Geliştirme.....	65
5.1.1. Doğrusal Olmayan Otoregresif sinir ağı (DOOSA).....	65
5.1.2. Doğrusal olmayan dışsal girdili otoregresif sinir ağı (DODGOSA).....	66
5.1.3. Kapılı Tekrarlayan Birim (KTB).....	67
5.2. Uygulama	68
5.2.1. Kandıra'da Rüzgar Hızı Tahmini için DOOSA ve DODGOSA'nın Uygulanması.....	68
5.2.2. Kandıra'da Rüzgar Hızı Tahmini için KTB'nin Uygulanması	72
5.3. Bulgular ve Tartışma	74
6. SONUÇ VE ÖNERİLER	79
6.1. Sonuç	79
6.2. Sınırlamalar ve Gelecek Araştırma Yönelimleri	80
6.2.1. Sınırlı veri bulunabilirliği.....	80
6.2.2. Model yorumlanabilirliği	81
6.2.3. Model belirsizliği	81
6.2.4. Diğer makine öğrenimi yöntemleri ile karşılaştırma.....	81
6.2.5. Diğer yenilenebilir enerji kaynakları ile entegrasyon	81
KAYNAKLAR.....	83
ÖZGEÇMİŞ	91

KISALTMALAR

ANN	: Artificial Neural Network
ARIMA	: Autoregressive Integrated Moving Average
BR	: Bayesian Regularization
CPU	: Central Processing Unit
DNN	: Deep Neural Network
DOOSA	: Doğrusal Olmayan Oto-Regresif Sinir Ağı
DODGOSA	: Doğrusal Olmayan Dışsal Girdili Otoregresif Sinir Ağı
FIT	: Feed-in Tariff
RES	: Renewable Energy Sources
GHG	: Greenhouse Gas
GS	: Grid Search
GRU	: Gated Recurrent Unit
GWEC	: Global Wind Energy Council
IEA	: International Energy Agency
IRENA	: International Renewable Energy Agency
KTB	: kapalı Tekrarlayan Birim
LM	: Levenberg Marquardt
MSE	: Ortalama kare Hatası
NAR	: Nonlinear Autoregressive
NARX	: Nonlinear Autoregressive Exogenous
NWP	: Numerical Weather Prediction
OREHO	: Otoregresif Entegre Hareketli Ortalama
PV	: PhotoVoltaic
RES	: Renewable Energy Resources
R²	: Belirleme katsayısı
R	: Korelasyon katsayısı
RNN	: Yinelemeli Sinir Ağı
TÜREB	: Türkiye Rüzgâr Enerjisi Birliği
WSF	: Wind Speed Forecasting
YEK	: Yenilenebilir Enerji Kaynakları
YİD	: Yap-İşlet-Devret

YSA : Yapay Sinir Ağları



TABLO LİSTESİ

Sayfa

Tablo 2.1. Rüzgâr enerjisinin avantajları ve dezavantajları.	35
Tablo 2.2. Türkiye rüzgâr enerjisi çiftlikleri veri-tabanı: Kandıra rüzgâr enerjisi çiftliği.	41
Tablo 3.1. Tahmin Zaman Ölçeği Sınıflandırması.	47
Tablo 4.1. Kandıra Çiftliği'nden ilk 12 saat için hava verileri.	60
Tablo 4.2. Modellerinin veri kümesi bölümü.	61
Tablo 4.3. YSA modellerinde optimize edilmiş hiperparametreler.	61
Tablo 4.4. KTB modelinde optimize edilmiş hiperparametreler.	62
Tablo 5.1. Geri Besleme Gecikmesi = 1:47 ve Gizli Katman Nöron Sayısı = 14 için DOOSA ve DODGOSA Performans Sonuçları.	75
Tablo 5.2. KTB Performans Sonuçları.	76
Tablo 5.3. Üç makine öğrenme yönteminin Performans Sonuçları.	77



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Türkiye'nin yenilenebilir kurulu kapasitesi.	32
Şekil 2.2. Dünya'nın yenilenebilir (rüzgâr) enerji kurulu kapasitesi.	33
Şekil 2.3. Türkiye'nin yenilenebilir enerji kurulu gücü.	33
Şekil 2.4. LIAM F1 sessiz rüzgar türbini.	36
Şekil 2.5. 2002 ve 2017'de kurulu kapasite paylarının (%) karşılaştırılması.	37
Şekil 2.6. Türkiye'de rüzgâr enerjisi 2023.	37
Şekil 2.7. Türkiye'deki Rüzgâr enerjisi santralleri için birikmiş kurulum.	38
Şekil 2.8. Bu onyılıda gerçekleşen yavaş büyüme, 2030'a kadar büyük bir rüzgâr enerjisi eksikliğine yol açacaktır (Roungkvist & Enevoldsen, 2020).	39
Şekil 4.1. Rüzgâr hızı frekansı / Kandıra rüzgâr istasyonu- ham veri.	58
Şekil 4.2. Rüzgâr hızı frekansı / Kandıra rüzgâr istasyonu- temizlenmiş veri (ön işleme sonrası).	58
Şekil 4.3. En iyi parametreler için DOOSA (a) ve DODGOSA (b) ağ mimari En iyi parametreler için DOOSA (a) ve DODGOSA (b) ağ mimari.	60
Şekil 5.1. DOOSA (a) ve DODGOSA (b) için eğitim performansı (14 gizli katman nöronu).	69
Şekil 5.2. DOOSA (a) ve DODGOSA (b) için Zaman Serisi Tepkisi (Gizli Katman Nöronları: 14).	69
Şekil 5.3. DOOSA (a) ve DODGOSA (b) için Belirleme Katsayısı Grafiği (Gizli Katman Nöronları: 14).	70
Şekil 5.4. DOOSA için Eğitim Hata Histogramı (14 Gizli Katman Nöronu) (a) ve DODGOSA için (b).	71
Şekil 5.5. DOOSA ve DODGOSA ağı için farklı öğrenme algoritmalarının ortalama ve en iyi R2 skorları.	71
Şekil 5.6. KTB modeli.	72
Şekil 5.7. KTB modeli için 3 girişli veri kümesi.	72
Şekil 5.8. KTB modeli için Zaman Serisi Tepkisi.	73
Şekil 5.9. KTB eğitim ilerlemesi.	74

AKILLI ŞEBEKELERDE MAKİNE ÖĞRENMESİ TEKNİKLERİYLE KISA VADELİ RÜZGÂR HIZI TAHMİNİ: KOCAELİ-TÜRKİYE ÖRNEĞİ

ÖZET

Dünya genelinde enerji talebinin artışı, mevcut kapasitelerin yetersiz kalmasına neden olmakta ve bu talebi geleneksel yöntemlerle karşılamak mümkün olmamaktadır. Bu durum, küresel ölçekte yenilenebilir enerji kaynaklarından güç üretimine yönelimi teşvik etmektedir. Yenilenebilir enerji kaynakları, kirlilikten arındırılmış enerji üretim kapasiteleri nedeniyle giderek daha fazla ilgi görmektedir. Son yıllarda, rüzgâr enerjisi yenilenebilir, sürdürülebilir ve çevre dostu bir enerji kaynağı olarak öne çıkmış ve enerji sistemlerinde en etkili yenilenebilir enerji kaynağı olarak kabul edilmektedir. Rüzgâr enerjisinin geleceği umut verici görünmekle birlikte, başlangıç maliyetleri ve rüzgârın öngörülemez ve stokastik doğası, bu enerjinin elektrik şebekesine entegrasyonunu zorlaştırmaktadır. Bu tezde, rüzgâr hızı tahmini problemi ele alınmış ve bu problemi çözmek için doğru bir öngörü yöntemi kullanılması gerektiği vurgulanmıştır. Etkili rüzgâr hızı tahmin yöntemleri, rüzgâr enerjisinin karşılaştığı zorlukların üstesinden gelinmesine yardımcı olmaktadır. Tezin amacı, özellikle ulusal bir şebeke içinde kısa vadeli tahminler için yapay sinir ağı modellerini incelemektir. Bu çalışmada, Kocaeli-Türkiye'deki Kandıra rüzgâr çiftliğinden elde edilen veri seti kullanılarak kısa vadeli rüzgâr hızı tahminleri yapılmış ve bu amaçla Doğrusal Olmayan Otoregresif Sinir Ağı (DOOSA), Dış Girdili Doğrusal Olmayan Ototetik Sinir Ağı (DODGOSA) ve Kapılı Tekrarlayan Birim (KTB) modelleri kullanılmıştır. Bu modellerin performansları diğer veri tabanlı yöntemlerle karşılaştırılmıştır. Tezin odak noktası, mevcut DOOSA modelinin, gerçek verilerle farklı sayılardaki gizli katman nöronları, gecikmeler ve eğitim fonksiyonları kullanılarak modelin hiperparametrelerinin iyileştirilmesi üzerinedir. Performans ölçütleri olarak ortalama kare hatası (MSE) ve belirleme katsayısı (R^2) kullanılmıştır. Sonuçlar, DOOSA modelinin hiperparametre optimizasyonu ile rüzgâr hızı tahmin performansını artırdığını göstermektedir. Önerilen DOOSA modeli, dışsal girdilerle zenginleştirilmiş versiyonu olan DODGOSA (Dışsal Girdili Doğrusal Olmayan Otoregresif Sinir Ağı) ile karşılaştırılmıştır. Sonuçlar, DOOSA'nın DODGOSA'ya kıyasla benzer performans sergilediğini ve daha kısa sürede çalıştığını ortaya koymuştur. Ayrıca, öğrenme algoritmaları karşılaştırılmış ve Bayesian Regularization (BR) algoritmasının en iyi öğrenme algoritması olduğu belirlenmiştir. Ancak, Levenberg-Marquardt (LM) algoritmasının çok daha hızlı yürütüldüğü ve BR'ye yakın sonuçlar sağladığı görülmüştür. Çalışma sonuçları, modeller arasında farklı performans metriklerine dayalı bir ödünleşim olduğunu ortaya koymaktadır. GRU modeli, 0.00722 ile en düşük MSE değerine ulaşarak hata minimizasyonunda üstün bir doğruluk sergilemiştir. Bununla birlikte, DOOSA modeli, KTB modelini geride bırakarak, 0.756'lık GRU R^2 değerine kıyasla 0.886'lık bir R^2 değeri elde etmiştir. DODGOSA modeli ise 0.2253'lük bir MSE ve 0.904'lük bir R^2 değeri üretmiş; bu durum, modelin R^2 açısından iyi performans gösterdiğini ancak KTB modeline kıyasla daha yüksek bir hata oranına sahip olduğunu göstermektedir. Bu bulgular, KTB modelinin tahmin hatasını minimize etmede son derece etkili olduğunu, ancak DOOSA modelinin rüzgâr hızı verilerindeki değişkenliği daha iyi yakalayabildiğini ve bu nedenle akıllı şebekelerdeki

belirli tahmin uygulamaları için güçlü bir aday olabileceğini önermektedir. Özellikle, yeni veri seti ve kullanılan hiperparametreler, bu modelin etkinliğini ortaya koymaktadır.



SHORT-TERM WIND SPEED FORECASTING IN SMART GRIDS WITH MACHINE LEARNING TECHNIQUES: A CASE STUDY IN KOCAELI- TÜRKİYE

SUMMARY

The global surge in energy demand has underscored the shortcomings of conventional energy generation methods, which are increasingly unable to meet this growing need. As a result, there has been a pronounced shift towards renewable energy sources, which are favored for their ability to produce energy without adding to environmental pollution. Among these renewable options, wind energy has gained significant attention due to its renewable, sustainable, and environmentally friendly attributes. It stands out as one of the most promising and effective renewable energy sources within contemporary energy systems. However, despite its potential, wind energy faces several challenges that must be addressed to fully integrate it into existing electricity grids.

These challenges include the considerable initial costs associated with wind energy projects and the unpredictable and stochastic nature of wind itself, which complicates its integration into the grid. The variability and intermittent nature of wind make it difficult to ensure a consistent and reliable energy supply, posing significant hurdles for grid stability and efficiency. Addressing these issues is crucial for the widespread adoption and effective utilization of wind energy as a reliable component of global energy systems.

This thesis addresses the challenge of wind speed prediction, a critical aspect of integrating wind energy into national electricity grids. Accurate forecasting of wind speed is pivotal for managing the inherent variability of wind power generation and ensuring a stable energy supply. The primary aim of this research is to explore and evaluate the efficacy of artificial neural network (ANN) models for short-term wind speed prediction within the context of a national grid system. This study utilizes a comprehensive dataset from the Kandıra wind farm in Kocaeli, Turkey, to develop and test various ANN models. Three distinct models are investigated: the Nonlinear Autoregressive Neural Network (NARNN), the Nonlinear Autoregressive Neural Network with Exogenous Input (NARXNN), and the Gated Recurrent Unit (GRU). These models are specifically chosen for their capabilities in handling temporal data and capturing complex patterns in wind speed variations. The research involves generating short-term forecasts using these models and comparing their performance against other data-driven methods to assess their accuracy and reliability. By evaluating the effectiveness of these models, this study aims to provide insights into the optimal approaches for wind speed forecasting, thereby contributing to the broader goal of enhancing the integration of wind energy into power grids and improving energy management strategies.

A core objective of this thesis is to improve the learning phase of the existing NARNN model by employing hyperparameter optimization. This process involves adjusting various parameters of the model, including the number of hidden layer neurons, delays,

and training functions, using real-world data. The performance of the NARNN model is evaluated using two key metrics: Mean Squared Error (MSE) and the Determination Coefficient (R^2). The results of this study demonstrate that hyperparameter optimization significantly enhances the accuracy of wind speed predictions generated by the NARNN model. Moreover, the optimized NARNN model is compared to its external counterpart, the NARXNN model. It is observed that the NARNN model produces results that are comparable to those of the NARXNN model, while also operating more efficiently in terms of computational time. This indicates that the NARNN model is both effective and time-efficient, making it a suitable choice for short-term wind speed forecasting tasks.

In addition to comparing the NARNN and NARXNN models, this thesis also includes an analysis of various learning algorithms used in the training of these models. The results of this analysis reveal that the Bayesian Regularization (BR) algorithm consistently outperforms other algorithms in terms of learning efficacy. However, it is also noted that the Levenberg Marquardt (LM) algorithm, while slightly less accurate than the BR algorithm, offers a much faster execution time, producing results that are nearly as accurate as those of the BR algorithm. This finding highlights the trade-off between accuracy and computational speed, which is an important consideration when selecting a learning algorithm for wind speed forecasting tasks.

The study also explores the performance of the GRU model, which is a type of recurrent neural network designed to handle time-series data. The GRU model achieved the lowest MSE of 0.00722, indicating its superior accuracy in minimizing prediction errors. However, when considering the Determination Coefficient (R^2), the NARNN model outperformed the GRU model, with the NARNN model achieving an R^2 value of 0.886 compared to the GRU model's R^2 value of 0.756. This suggests that while the GRU model excels in minimizing errors, the NARNN model may be better suited to capturing the variability inherent in wind speed data, making it a strong candidate for specific forecasting applications within smart grids.

Furthermore, the NARXNN model was evaluated and produced an MSE of 0.2253 and an R^2 value of 0.904. While this indicates that the NARXNN model performs well in terms of the R^2 metric, it also suggests that the model exhibits higher error rates compared to the GRU model. These findings underscore the importance of selecting the appropriate model based on the specific characteristics of the dataset and the forecasting task at hand.

In conclusion, this thesis underscores the crucial importance of accurate wind speed forecasting for the successful integration of wind energy into contemporary energy systems. The ability to reliably predict wind speed is essential for managing the variability associated with wind power and ensuring a stable and efficient energy supply. This research has demonstrated the significant impact of hyperparameter optimization on enhancing the performance of artificial neural network (ANN) models, with particular emphasis on the Nonlinear Autoregressive Neural Network (NARNN) for short-term wind speed predictions. The application of advanced optimization techniques has proven to improve the model's accuracy and reliability, showcasing the potential for more precise forecasting in wind energy applications. The comparative analysis conducted in this study highlights the strengths and limitations of various models, including the NARNN, Nonlinear Autoregressive Neural Network with Exogenous Input (NARXNN), and Gated Recurrent Unit (GRU). This evaluation provides valuable insights into the trade-offs between forecasting accuracy and

computational efficiency, offering a clearer understanding of the practical considerations involved in model selection and deployment. The findings indicate that while more complex models may offer higher accuracy, they often require greater computational resources, necessitating a balanced approach to model development.

The contributions of this thesis extend beyond the immediate findings by providing a detailed framework for the application and evaluation of ANN models in wind speed forecasting. The insights gained from this research can inform future studies and guide practitioners in selecting appropriate models for specific forecasting needs. Recommendations for future work include exploring additional hyperparameter tuning strategies, incorporating more diverse datasets, and investigating hybrid models that combine the strengths of different forecasting approaches. By addressing these areas, future research can further advance the field of wind speed prediction and contribute to the efficient integration of wind energy into national and global energy systems. The findings of this study contribute to the ongoing efforts to optimize the integration of renewable energy sources into power systems, ultimately supporting the global transition towards sustainable energy.



1. GİRİŞ

Elektrik, yüksek kaliteli bir enerji türü olarak toplumun yaşam kaynağıdır; teknolojik ilerlemeyi kolaylaştırır ve yaşam kalitemizi artıran geniş bir ürün ve hizmet yelpazesine katkı sağlar. Bu nedenle, elektrik ağı, üretilen elektriğin ihtiyaç duyulan yerlere, örneğin evlere, iletilmesini sağlayan iletim hatları, transformatörler, teller ve anahtarlar gibi bileşenlerden oluşan bir sistem olarak tanımlanabilir (Shabalov et al., 2021). Son yıllarda, yüksek güvenilirlikte ancak düşük maliyetli enerji sistemlerine duyulan ihtiyaç önemli ölçüde artmıştır. Bu enerji sistemi, bir veya daha fazla kontrol merkezi tarafından işletilen, senkronize güç sağlayıcıları ve tüketicilerinin iletim ve dağıtım hatlarıyla bağlı olduğu bir ağıdır. Elektrik şebekesindeki güvenilirlik ve verimsizlik, şebeke altyapısının yaşlanması ve diğer problemlerle birleşerek hizmet sektöründe yenilik eksikliğine yol açmaktadır. Bu sorunlara ek olarak, dijital toplumlarda artan güvenilirlik ve enerji kalitesi talepleri, nihayetinde akıllı şebeke olarak adlandırılan yeni bir şebeke teknolojisi dalgasının ortaya çıkmasına neden olmuştur. Akıllı şebeke, aslında orijinal elektrik şebekesinin modernize edilmiş ve teknolojiye uyarlanmış bir versiyonu olarak karşımıza çıkmaktadır (Bogdanov et al., 2021).

Günümüzde, akıllı şebekeye yönelik yeni ve büyük teknolojilere zemin hazırlayan modernizasyon süreci, birçok yeni fikrin ortaya çıkmasına ve teknolojik gelişime katkı sağlamıştır. Bu gelişim süreçlerinden biri de klasik enerji kaynaklarına göre çeşitli avantajlar sunan yenilenebilir enerji kaynaklarının ortaya çıkmasıdır (Caglayan et al., 2019). Küresel enerji tüketimindeki dramatik artış, yenilenebilir enerji kaynaklarına olan talebi artırmıştır. Yenilenebilir enerji kaynakları, kirlilikten arınmış enerji üretim kapasiteleri nedeniyle daha fazla ilgi görmektedir (Chang, 2014). Yenilenebilir enerji, doğal olarak yenilenebilir, temiz ve çevre dostu olan ve tükenmez kaynaklardan elde edilen enerji türüdür (Dupré et al., 2020a). Bu enerji kaynakları arasında güneş enerjisi, rüzgâr, hidroelektrik, jeotermal ve biyokütle gibi kaynaklar bulunmaktadır. Bu kaynakların pazara entegrasyonu ve politika yapıcılarının maliyet etkin çözümler geliştirme odakları nedeniyle, rüzgâr ve güneş enerjilerine yönelik araştırmalar artış göstermiştir (Oyekale et al., 2020).

Yenilenebilir enerji kaynaklarının yaygınlaşmasının temel nedeni, teknolojik ilerlemenin sağladığı kurulum sonrası düşük maliyetler ve sürekli erişim imkânlarıdır (Blanco & Faaij, 2018). Bununla birlikte, çevresel sorunlar yaratsa da yenilenemeyen enerji kaynakları (örneğin fosil yakıtlar), henüz maliyet açısından kabul edilebilir yenilenebilir enerji teknolojilerine geçiş tamamlanana kadar kullanılmaya devam edilecektir (Gielen et al., 2019).

Rüzgâr enerjisinin akıllı şebekelerle entegrasyonu, rüzgâr hızının bir gün sonrası gibi kısa vadeli zaman ölçeklerinde en iyi şekilde tahmin edilmesine bağlıdır (Kosovic et al., 2020; Wan et al., 2016). Tahminleme, veri yoğunluğuna veya büyük veriye dayalı bir süreç olarak, karar verme, planlama gibi birçok alanda hizmet sunucuları tarafından kullanılmaktadır. Özellikle rüzgâr enerjisi tahmini, günümüz teknolojik yaşamında son derece önemli bir konudur; zira hedeflerin daha etkili yönetilmesine olanak tanır (Moreno et al., 2021; Sun et al., 2018).

Bu çalışmada, Türkiye'nin Kocaeli ilinde bulunan Kandıra rüzgâr çiftliğindeki rüzgâr hızını tahmin etmek amacıyla belirsizlik tahmini yöntemleri önerilmiştir. Bu tezde, çeşitli hiperparametrelerle gerçek veri seti kullanılarak Doğrusal Olmayan Otoregresif Sinir Ağı (DOOSA), Dış Girdili Doğrusal Olmayan Otoregresif Sinir Ağı (DODGOSA) ve Kapılı Tekrarlayan Birim (KTB) gibi yapay sinir ağı yöntemleri incelenmiştir. Tezin amacı, mevcut DOOSA yönteminin gerçek uygulamalarda performansını iyileştirmektir. Ayrıca, Kandıra'dan elde edilen yeni veri setiyle rüzgâr hızı tahmin doğruluğunu artırmak hedeflenmiştir. DOOSA, DODGOSA ve KTB yöntemlerinin performanslarını karşılaştırmak için de çeşitli çalışmalar gerçekleştirilmiştir.

1.1. Tezin Kapsamı

Bu çalışmanın temel amacı ve hedefi, belirli bir bölgede rüzgâr hızını tahmin etmek için operasyonel çözümler geliştirmek ve uygulamaktır. Bu doğrultuda, Kocaeli, Türkiye'den elde edilen gerçek bir veri seti kullanılarak mevcut DOOSA yönteminin etkinliğinin incelenmesi amaçlanmıştır. Araştırmanın odak noktası, kısa vadeli (bir saat öncesi) rüzgâr hızı tahminlerini doğru bir şekilde modellemek için yapay zekâ tabanlı tahmin tekniklerinin uygulanmasıdır.

Bu tezin bir diğ er amacı ise, DOOSA y nteminin performansını DODGOSA ve KTB gibi alternatif y ntemlerle karřılařtırmaktır.  alıřmanın belirli hedefleri ařağıdaki gibi sıralanabilir:

- R zg r  iftliğınden veri seti toplamak ve gerekli  n iřleme adımlarını uygulamak.
-  n iřlemden ge irilmiş veri setini sinir ağı sistemine girdi olarak sağılamak.
- DOOSA y ntemini kullanarak tahmin edilen r zg r hızı gibi istenen  ıktıları elde etmek.
- En uygun modelleri belirlemek amacıyla DOOSA, DODGOSA ve GRU y ntemlerini eğıtmek, doğırlamak ve test etmek.
- T m modellerin doğırluk ve g venilirliklerini değıerlendirmek.
- DOOSA modelinin performansını,  zellikle DODGOSA ve KTB gibi diğ er kısa vadeli r zg r hızı tahmin modelleriyle karřılařtırmak.

1.2. Arařtırma soruları

- Kocaeli-T rkiye'de kısa vadeli r zg r hızı tahmininde DOOSA, DODGOSA ve KTB modellerinin doğırluğı ve g venilirliğı nedir?
-     modelden hangisi en doğır r zg r hızı tahminlerini sağılar?
- T rkiye'nin Kocaeli b lgesinde r zg r hızı tahmini i in bu modellerin kullanılmasının zorlukları ve sınırlamaları nelerdir?

1.3. Tezin Amacı

Bu  alıřmanın temel amacı ve hedefi, belirli bir konumda r zg r hızını tahmin etmek i in operasyonel    mler geliřtirmek ve uygulamaktır. Bu doğırltuda, Kocaeli, T rkiye'den elde edilen ger ek bir veri seti kullanılarak mevcut DOOSA y nteminin etkinliğini incelemek hedeflenmiřtir. İkinci olarak, r zg r hızı tahmini i in en uygun modelleri belirlemek amacıyla DOOSA, DODGOSA ve KTB y ntemlerini eğıtmek, doğırlamak ve test etmek ama lanmaktadır. Son olarak, DOOSA modelinin performansı,  zellikle DODGOSA ve KTB gibi diğ er kısa vadeli r zg r hızı tahmin modelleri ile karřılařtırılacaktır.

1.4.  alıřmanın  nemi

Bu  alıřma birkaç nedenle  nem tařımaktadır

- Rüzgâr Enerjisinin Artan Önemi

Daha temiz enerji kaynaklarına yönelik küresel talebin artmasıyla birlikte, rüzgâr enerjisi, geleneksel fosil yakıtlara önemli bir alternatif olarak öne çıkmıştır. Rüzgâr hızının doğru tahmini, rüzgâr enerjisinin verimli bir şekilde üretilmesi, iletilmesi ve dağıtılmasında kritik bir öneme sahiptir.

- DOOSA, DODGOSA ve KTB Yaklaşımlarının Kullanımı

Bu çalışma, kısa vadeli rüzgâr hızlarını tahmin etmek amacıyla DOOSA yöntemini kullanmanın yanı sıra, DODGOSA ve GYB (Gated Recurrent Unit) yaklaşımlarını da değerlendirmektedir.

- Kocaeli-Türkiye'ye Özgü Analiz

Araştırma, Kocaeli, Türkiye bölgesine özgü rüzgâr hızı tahminlerine odaklanmaktadır. Rüzgâr desenleri, coğrafi konuma bağlı olarak önemli varyasyonlar gösterebildiğinden, belirli bir bölgeye yönelik doğru tahminler elde etmek, enerji sektöründe etkili planlama ve karar verme süreçleri açısından son derece kritik öneme sahiptir.

- Kısa-dönem Tahminlere Odaklanma

Çalışma, günlük enerji yönetiminin ve şebeke stabilitesinin kritik bir bileşeni olan kısa vadeli rüzgâr hızı tahminine odaklanmaktadır. Doğru kısa vadeli tahminler, şebeke operatörlerine enerji üretimini ve dağıtımını gerçek zamanlı olarak dinamik bir şekilde ayarlama olanağı sağlar. Bu, tutarlı ve stabil bir enerji kaynağının sağlanmasına önemli katkıda bulunur.

1.5. Tezin Organizasyonu

Bu tezin yapısı şu şekilde düzenlenmiştir: Bölüm 2, Türkiye'nin enerji manzarasını derinlemesine inceleyerek çalışmanın bağlamını sağlamaktadır. Bölüm 3, rüzgâr enerjisi ve diğer yenilenebilir enerji kaynaklarını kapsamlı bir şekilde ele alarak, bu kaynakların enerji sektöründeki önemini açıklamaktadır. Bölüm 4, rüzgâr hızı tahmin yöntemlerinin güncel durumunu detaylı bir şekilde gözden geçirerek, bu alanda kullanılan çeşitli yaklaşımları açıklığa kavuşturmaktadır. Bölüm 5, veri toplama ve ön işleme süreçlerini ayrıntılı olarak ele alarak, sonraki analizler için temel bir altyapı sunmaktadır. Bölüm 6, önerilen metodolojiyi ana hatlarıyla açıklayarak rüzgâr hızı

tahmini için yaklaşımın çerçevesini netleştirmekte ve Kocaeli, Türkiye'de gerçekleştirilen detaylı bir vaka çalışmasını sunarak metodolojinin uygulanabilirliğini vurgulamaktadır. Bölüm 7, elde edilen sonuçları ve bu sonuçların tartışmasını içermektedir. Son olarak, Bölüm 8, önerilen modelin seçim nedenlerini, avantajlarını ve dezavantajlarını özetleyerek, gelecekteki araştırmalar ve pratik uygulamalar için öneriler sunmaktadır.





2. TÜRKİYE'DE YENİLENEBİLİR ENERJİ VE RÜZGÂR ENERJİSİ KAYNAKLARI

2.1. Yenilenebilir Enerji Kaynakları:

Elektrik kaynaklarının yetersizliği ve küresel ısınmanın etkileri nedeniyle, yeni, temiz ve alternatif enerji kaynaklarına yönelik arayış artmıştır. Bu bağlamda, yenilenebilir enerji kaynakları, özellikle güneş hücreleri ve rüzgâr türbinleri, enerji krizine yönelik etkili çözümler olarak öne çıkmaktadır. Artan yenilenebilir enerji üretimi, esnek olmayan enerji sistemlerinde önemli zorluklar yaratmakta, bu durum akıllı şebeke sistemleri geliştirenler ve uygulayıcılar için bir meydan okuma oluşturmaktadır. Ayrıca, bu yeni kaynaklar, sürdürülebilir kalkınmanın "ikiz direği" olarak enerji verimliliğini de kapsamaktadır.

Kurulu güç üretim kapasitesinde hidrolik ve rüzgâr enerjileri, güneş enerjisini geride bırakmakla birlikte, güneş enerjisi diğer yenilenebilir enerji kaynaklarından daha hızlı bir büyüme göstermektedir. Güneş enerjisi, dünya genelinde her yerde mevcut olup tükenmez olarak kabul edilmekte ve küresel elektrik üretiminin yıllık miktarından daha yüksek bir potansiyele sahiptir.


Uluslararası Enerji Ajansı (IEA) tarafından sağlanan istatistikler, Covid-19 pandemi dönemlerinde yenilenebilir enerji kaynaklarının (YEK) en esnek enerji kaynağı olarak öne çıktığını göstermektedir. Pandemi sürecinde, YEK'den sağlanan elektrik, diğer yenilenebilir enerji kullanımında görülen talep düşüşünden etkilenmemiştir. Kilitlenme dönemlerinde, düşük karbonlu bir ortam sağlama ihtiyacı ve zorunluluğu nedeniyle YEK elektriği talebi artmıştır. Pandemi sonrası bazı enerji projeleri durdurulmuş olsa da, 2021 yılında yenilenebilir enerji kapasitesinin, Hindistan ve Avrupa Birliği'nde büyük çiftliklerle birlikte, önceki yıllara göre %10 oranında artması beklenmektedir. Şekil 2.1 ve Şekil 2.2, YEK için küresel yatırım ve birikmiş pazarları göstermektedir [23]. Ayrıca, Şekil 2.3, dünya genelinde son üç yılda kurulu olan çiftlikleri göstermektedir [24].

Son yıllarda, "akıllı şebeke" olarak adlandırılan yeni elektrik şebekelerinde, YEK sistemlerinin penetrasyonu, sera gazı (GHG) etkilerini azaltmak ve çevresel enerji kaynaklarını etkin bir şekilde kullanmak açısından önemli bir faktör olarak

değerlendirilmektedir. YEK'nin penetrasyonunun ana nedeni, teknolojik ilerlemelerle maliyetlerin düşmesi ve bu kaynakların bulunabilirliğidir (Blanco & Faaij, 2018).

Türkiye'de yenilenebilir enerji penetrasyonunu artırma ve güneş ile rüzgâr enerjisi gibi temiz enerji kaynaklarını önceliklendirme hedefi, sürdürülebilir kalkınma stratejilerinin bir parçasıdır (Chang, 2014; Dupré et al., 2020a). IRENA raporuna göre, Türkiye, Avrupa'da yeni kurulan yenilenebilir enerji kapasitesi bakımından 5. ve dünya genelinde 12. sıradadır (Oyekale et al., 2020).

Net sıfır hedefleri doğrultusunda, Türkiye'nin sürdürülebilir kalkınma süreci, küresel ölçekte yenilenebilir enerjiye büyük yatırımlara yol açmıştır. Sürdürülebilir kalkınma hedefleri, entegre ekonomik, sosyal ve çevresel politikaların yeşil büyümeyi nasıl destekleyebileceğini tartışmakta ve çevresel politikalar, rüzgâr ve güneş enerjisi dahil olmak üzere YEK kaynaklarının benimsenmesini içermektedir (Caglayan et al., 2019). Türkiye'nin kurulu güç hedefleri, 2035 yılı itibarıyla yenilenebilir enerjilerin payının %65 olmasını öngörmektedir (Mart 2023 itibarıyla %54).



Şekil 2.1. Türkiye'nin yenilenebilir kurulu kapasitesi.


Son 15 yılda Türkiye'de yenilenebilir enerji, özellikle de rüzgâr enerjisine olan ilgi arttırmıştır, bu durum Şekil 2.1'de görülmektedir. Türkiye'nin rüzgâr enerjisi sektörü 12.000 MW kurulu kapasiteye ulaşarak, dünya genelinde 12. ve Avrupa'da 6. sıraya yükselmiştir. Şekil 2.2'de görüldüğü gibi, 2021 yılı itibarıyla Türkiye'nin rüzgâr enerjisi üretimi, rüzgâr türbinlerinin kurulumuna başlandığı ilk yıllara kıyasla 30 TWh

artış göstermiştir. Ayrıca, güneş enerjisi de Türkiye'de elektrik üretiminde ikinci sıraya yükselmiş ve 2020'de elektrik üretimi 11 TWh'a ulaşmıştır. 2021 yılında Türkiye, enerji ithalatında 700 milyon dolardan fazla tasarruf sağlamayı başarmıştır.

Türkiye, ılıman iklimi ve geniş kıyı şeridi sayesinde yenilenebilir enerji kaynaklarının üretimi için en uygun ülkelerden biri olarak değerlendirilmektedir. Rüzgâr enerjisi kurulu gücü açısından Türkiye, Avrupa'da 6., dünya genelinde ise 12.sıradadır Şekil 2.2'de göstermektedir. 2024 yılı itibarıyla rüzgâr enerjisinden elde edilen elektrik miktarı 12 GW olup, bu, toplam elektrik üretiminin %10'una tekabül etmektedir. Şekil 2.3'de, Türkiye'nin yenilenebilir enerji kurulu gücü, 12 Haziran itibarıyla toplam kurulu gücün yüzde 57,2'sine ulaşmıştır.

ÜLKELERE GÖRE DÜNYADA RÜZGAR SANTRALİ KURULU GÜCÜ LİSTESİ			
S.	Ülke	Güncelleme	Kurulu Güç (MW)
1	Çin	Ocak 2022	328.973
2	Amerika Birleşik Devletleri	Ocak 2022	132.738
3	Almanya	Ocak 2022	63.760
4	Hindistan	Ocak 2022	40.067
5	İspanya	Ocak 2022	27.497
6	Birleşik Krallık	Ocak 2022	27.130
7	Brezilya	Ocak 2022	21.161
8	Fransa	Ocak 2022	18.676
9	Kanada	Ocak 2022	14.304
10	İsveç	Ocak 2022	12.080
11	İtalya	Ocak 2022	11.276
12	Türkiye	Haziran 2022	10.886
13	Avusturalya	Ocak 2022	8.951

Şekil 2.2. Dünya'nın yenilenebilir (rüzgâr) enerji kurulu kapasitesi.



Şekil 2.3. Türkiye'nin yenilenebilir enerji kurulu gücü.

Bu bölüm, Türkiye genelinde ve özellikle Kocaeli'de Rüzgâr enerjisi ile ilgili gelişmeleri, zorlukları ve fırsatları kapsamlı bir şekilde ele almayı amaçlamaktadır. Bu, Rüzgâr enerjisinin Türkiye'nin enerji portföyündeki önemli rolüne dair aydınlatıcı bir bakış sunmayı hedeflemektedir.

2.2. Rüzgâr Enerjisi

1970'lerin sonlarında modern rüzgâr türbinlerinin geliştirilmesi, rüzgâr enerjisi alanında önemli bir dönüm noktasını işaret etmiştir. Son yıllarda, rüzgâr enerjisi çağdaş güç sistemlerine sağladığı katkılarla öne çıkan ve hızla gelişen bir yenilenebilir enerji kaynağı olarak evrim geçirmiştir (Tascikaraoglu & Uzunoglu, 2014a). Rüzgâr enerjisi, hava moleküllerinin hareketinden kaynaklanan kinetik enerjiyi elektrik enerjisine dönüştürme sürecini içerir. Rüzgâr estiğinde, rüzgâr türbinleri bu kinetik enerjiyi yakalar ve türbin kanatlarının dönüşü aracılığıyla elektrik enerjisine çevirir. Rüzgâr türbinlerinin elektrik üretimi, rüzgâr hızı, kanat uzunluğu ve jeneratör kapasitesi gibi faktörlere bağlı olarak değişir (Eugene Mitnovetski, 2023).

Rüzgâr enerjisi, temizliği, maliyet etkinliği ve güvenilirliği nedeniyle hızla büyüyen ve tanınan bir enerji kaynağıdır (Eugene Mitnovetski, 2023). Ancak, rüzgâr enerjisinin sınırlı öngörülebilirlik ve kısa ile uzun vadeli değişkenlik gibi özellikleri, yeni zorluklar da yaratmaktadır. Kilovatsaat başına maliyetler önemli ölçüde düşmüş, makine verimliliği, güvenilirlik ve kullanılabilirlikte önemli iyileşmeler sağlanmıştır. Düşük rüzgâr koşullarında daha düşük hızlardan yararlanabilmek, performansı artırmakla kalmaz, aynı zamanda gürültü emisyonlarını da azaltır (Kursun, 2023) (Tascikaraoglu & Uzunoglu, 2014).

Dünya genelinde rüzgâr enerjisi üretimi en yüksek yoğunluk ve kapasiteye Çin, Amerika Birleşik Devletleri, çeşitli Avrupa ülkeleri ve Hindistan gibi ülkelerde sahiptir (Caglayan et al., 2019). Örneğin, Çin'in Gansu şehrinde bulunan Gansu Rüzgâr Çiftliği, 2012 yılında 6.000 MW'lık kapasiteye ulaşarak dünyanın en büyük rüzgâr çiftliği olarak kabul edilmiştir. 2021 ile 2030 yılları arasında hedeflenen kapasite 400 GW'dir (Rounkvist & Enevoldsen, 2020). Gansu, 2024 yılında 401 MW'lık bir kara rüzgâr enerjisi projesine ev sahipliği yapacaktır.

Rüzgâr enerjisi pazarı raporlarındaki ilerlemeler, temiz enerjiye geçiş çabalarını ve emisyonları azaltma, yeni iş alanları yaratma ve endüstriyi teşvik etme amacını vurgulamaktadır. Rüzgâr çiftliklerinin kurulumu ve bakımı, nitelikli teknisyenler

gerektirdiğinden, iş yaratma açısından önemli bir katkı sağlamaktadır (Oyekale et al., 2020; J. Zhang et al., 2019).

Tablo 2.1, rüzgâr enerjisinin avantajlarını ve dezavantajlarını detaylı bir şekilde açıklamaktadır.

Tablo 2.1. Rüzgâr enerjisinin avantajları ve dezavantajları.

Avantajlar	Dezavantajlar
Rüzgâr enerjisi, ekonomik büyümeyi teşvik eden bir ulusal kaynaktır.	İdeal rüzgâr bölgeleri genellikle uzak bölgelerde bulunur.
Rüzgâr türbinleri çeşitli bağlamlarda çalışabilir.	Türbinler gürültü üretir ve görsel görünümü etkiler.
Rüzgâr enerjisi, bu alandaki bilimsel ve teknolojik ilerlemelere bağlı olarak ekonomik olarak uygundur.	Rüzgâr türbinleri, yerel fauna üzerinde potansiyel bir etkiye sahiptir.
Rüzgâr enerjisi, temiz, sürdürülebilir bir enerji kaynağıdır.	Rüzgâr enerjisi, diğer düşük maliyetli enerji kaynaklarına karşı rekabetçi olmalıdır.

Geleneksel rüzgâr türbinlerinin dezavantajlarından biri de geniş arazilere ihtiyaç duyması, devasa kanatlarının görsel açıdan olumsuz etki yaratması, kuşlar için risk oluşturması ve bu arazilerin kullanımını engellemesidir. Bu nedenle amaç, kentsel ortamlarda zemine yakın ve binalar arasında akan daha zayıf, daha düzensiz rüzgarlardan yararlanmak için boyutlarını küçültmek ve verimliliği artırmaktır.

Böyle bir çözüm, İskoç bir şirket tarafından geliştirilen altıgen rüzgâr türbinleridir. Archimedes tarafından geliştirilen LIAM F1 sessiz rüzgâr türbini, bu alanda çitayı yükseltiyor, bu aşağıdaki şekilde açıkça görülmektedir.




Şekil 2.4. LIAM F1 sessiz rüzgar türbini.

2.3. Türkiye'de Rüzgâr Enerjisi


Türkiye, enerji ihtiyacını büyük ölçüde komşu ülkelerden ithal edilen gaz kaynaklarına dayandırmaktadır. Bu gaz kaynakları, ülkenin ulusal elektrik üretimini sağlamaktadır. Ancak, gazın yüksek ihracat maliyeti, uluslararası siyasi sorunlar, teknolojik zorluklar ve diğer çeşitli nedenler, Türkiye'nin ulusal elektrik şebekesinde enerji kıtlığı ve dalgalanmalara yol açmaktadır. Bu durum, Türkiye'yi maliyetleri azaltmak ve çevresel kirliliği en aza indirmek amacıyla fosil yakıtların yerine yenilenebilir enerji kaynaklarını değerlendirmeye yöneltmiştir (Dupré et al., 2020a).

Yenilenebilir, temiz ve çevre dostu bir enerji kaynağı olarak rüzgâr enerjisi, bu sorunlara etkili bir çözüm olarak öne çıkmaktadır. Rüzgâr enerjisi, geleneksel enerji kaynaklarına kıyasla ekonomik, ücretsiz ve saf bir enerji kaynağı olarak düşük maliyetli elektrik üretmektedir (Maldonado-Correa et al., 2021a). Araştırmalar, rüzgâr enerjisinin mevcut durumu, yenilenebilir enerji potansiyeli ve Türkiye'deki gelişimini kapsamlı bir şekilde ele almaktadır. Bu çalışmalarda, Türkiye'nin kurulu rüzgâr kapasitesi ve elektrik enerjisi üretimi detaylı olarak incelenmiş, Türk rüzgâr enerjisinin mevcut durumu değerlendirilmiştir (Hepbaslı & Ozgener, 2004; İlkiliç et al., 2011). Şekil 2.1'de görüldüğü üzere, yenilenebilir enerji ve hidroelektrik enerjinin kurulu kapasitesinin toplam oranı, son 15 yıl içinde %38'den %45'e yükselmiştir (Erdin & Ozkaya, 2019). Ayrıca, yenilenebilir enerji oranı %0'dan %13'e çıkmıştır. Yenilenebilir enerji kaynakları (RES), küresel ısınma ve iklim değişikliği endişelerini büyük ölçüde azaltmıştır.

Türkiye, rüzgâr enerjisi kapasitesini artırmak ve rüzgâr tabanlı teknolojileri geliştirmek amacıyla 2021 yılında devlet destekleriyle 1 milyar dolarlık bir yatırım gerçekleştirmiştir. Bu yatırım, rüzgâr enerjisi dağıtımındaki gecikmeleri ve ertelenmeleri önlemek amacıyla, koronavirus pandemisi sonrasında yapılmıştır ve 2022 yılını rüzgâr enerjisinden elektrik üretimi açısından "rekor yıl" haline getirmiştir. Rüzgâr enerjisi üretimi 12 megavata ulaşmış ve günlük üretim %25-27 oranında artmıştır. 2023 yılı için Türk rüzgâr endüstrisi, rüzgâr ihracatını 1,49 milyar dolar olarak hedeflemekte ve sektöre önemli yatırımlar yapmayı planlamaktadır; ayrıca kurulu kapasitenin %37,5 oranında artırılması öngörülmektedir (Kumar et al., 2022).



Şekil 2.5. 2002 ve 2017'de kurulu kapasite paylarının (%) karşılaştırılması.




Şekil 2.6. Türkiye'de rüzgâr enerjisi 2023.



Şekil 2.7. Türkiye'deki Rüzgâr enerjisi santralleri için birikmiş kurulum.

2002 ile 2017 arasındaki rüzgâr enerjisinin birikmiş kurulu kapasitesi 23.900 MW'den 539.581 MW'a kadar artmıştır, ki bu Şekil 2.5'de açıklanmıştır. 2022'de dünya genelinde birikmiş kurulu rüzgâr enerjisi kapasitesinin yaklaşık 840,9 GW çıkması beklenmektedir (Roungkvist & Enevoldsen, 2020). Revize edilen tahminlerimiz, 2024 ortasında küresel rüzgar kapasitesinin yaklaşık 1.051 GW'a ulaşacağını ve 2030 sonuna kadar dünya genelinde toplamda 1.686 GW'ın biraz üzerinde bir rüzgar kapasitesine ev sahipliği yapmasının beklendiğini göstermektedir ((EIA), 2023).



Şekil 2.8. Bu onyılda gerçekleşen yavaş büyüme, 2030'a kadar büyük bir rüzgâr enerjisi eksikliğine yol açacaktır (Roungkvist & Enevoldsen, 2020).

Güncel kurulum hızlarına dayanarak, GWEC Market Intelligence'ın tahminlerine göre, 2030 yılına kadar 1,5°C hedefi ve net sıfır emisyon hedefine ulaşmak için gerekli rüzgâr enerjisi kapasitesinin üçte ikisinden daha azına sahip olacağımız öngörülmektedir. Bu durum, iklim hedeflerimize ulaşmada önemli bir engel oluşturabilir (Roungkvist & Enevoldsen, 2020).

Türkiye ve dünya genelindeki rüzgâr enerjisinin gelişimini teşvik eden temel faktörlerden biri, yenilenebilir enerji kaynaklarından üretilen elektriğe garantili bir fiyat sunan "Feed-in Tariff" (FIT) sistemidir. FIT sistemi, özellikle Türkiye'deki rüzgâr enerjisi sektörünün erken dönemlerinde, rüzgâr enerjisi projelerine yatırım çekme konusunda önemli bir rol oynamıştır. FIT sistemine ek olarak, Türk hükümeti rüzgâr enerjisi sektörünü desteklemek amacıyla vergi teşvikleri, kredi garantileri ve kamu ihaleleri gibi çeşitli politika ve teşvikler uygulamıştır. Ayrıca, Danimarka, Almanya ve İspanya, FIT teşvikleri aracılığıyla rüzgâr enerjisi sektöründe istikrarlı pazarlar oluşturmuşlardır (Offshore Wind Farms Continue Growth, 2021).

2.3.1. Kocaeli'de Rüzgâr Enerjisi

Kocaeli, Türkiye'nin Marmara Bölgesi'nde yer alan bir ildir ve kıyı konumu ile elverişli rüzgâr koşulları nedeniyle rüzgâr enerjisi potansiyeli açısından önemli bir konumda bulunmaktadır. Ancak, yoğun endüstriyel faaliyetler sonucunda hava

kirliliği, şehrin başlıca çevresel sorunlarından biri olarak öne çıkmaktadır. Hava kirlleticilerinin taşınması ve yayılması atmosferdeki meteorolojik parametreler tarafından etkilenmektedir. Bu durum, bölgesel meteorolojik modellerin hava kirliliğinin toprak seviyesindeki dağılımına olan etkisini vurgulamaktadır (Özdemir & Taner, 2014).

Kocaeli rüzgâr enerjisi açısından önemli bir potansiyele sahiptir:

- Yenilenebilir Enerjiye Yönelik Mevcut Altyapı
- Rüzgâr Kaynağı: Rüzgâr enerjisi üretimi için ideal konum
- Akıllı Şebeke Uygulaması
- Araştırma İşbirliği.

Türkiye'de toplamda yaklaşık 300 rüzgâr çiftliği bulunmaktadır ve bu çiftliklerin tamamı karada konumlanmıştır. Toplamda yaklaşık 4.000 rüzgâr türbini içeren bu çiftlikler, Türkiye'nin rüzgâr enerjisi kapasitesinin önemli bir kısmını oluşturmaktadır. İlk rüzgâr çiftliği, 1998 yılında İzmir'de inşa edilmiş olup, Türkiye'deki ilk büyük ölçekli rüzgâr çiftliği olarak öne çıkmaktadır. Ayrıca, bu proje, Yap-İşlet-Devret (YİD) modeline göre inşa edilen ilk rüzgâr çiftliği olarak da kaydedilmiştir (Ulu & Dombayci, 2018).

Günümüzde Türkiye, enerji tüketiminin yaklaşık %7,15'ini rüzgâr enerjisi santrallerinden karşılamaktadır. Türkiye Rüzgâr Enerjisi Birliği (TÜREB) verilerine göre, 2021 itibarıyla Kocaeli'nin toplam kurulu rüzgâr enerjisi kapasitesi yaklaşık 215 MW olup, bu kapasite 94 rüzgâr türbini tarafından sağlanmaktadır. Önümüzdeki yıllarda, bu kapasitenin daha fazla rüzgâr enerjisi projesinin devreye alınmasıyla artması öngörülmektedir (Wind Energy Market in Turkey, n.d.). Kandıra Rüzgâr Çiftliği

Kocaeli'deki başlıca rüzgâr enerjisi santrallerinden biri, kurulu kapasitesi 51 MW olan ve yılda yaklaşık 157 GWh elektrik üreten Kandıra Rüzgâr Enerjisi Santrali'dir. Diğer önemli santraller arasında Erenköy Rüzgâr Enerjisi Santrali, Kocaeli Rüzgâr Enerjisi Santrali ve Sapanca Rüzgâr Enerjisi Santrali yer almaktadır.

Kandıra, Kocaeli'nin kıyısında bulunan ve 933 km²'lik bir yüzey alanına sahip bir ilçedir. Kocaeli, Türkiye'de sanayi açısından önemli bir il olup, Kandıra, hizmet, tarım ve turizm sektörlerinde de gelişim gösteren bir bölgedir. Kandıra Rüzgâr Enerjisi Santrali, Karadeniz'in ortasında yer alan kıyı ve ilçe merkezi arasında

konumlanmaktadır. Santral, mevcutta 10 rüzgâr türbini içermekte olup, gelecekte (T8, T9 ve T10) adını taşıyan üç türbin daha eklenmesi planlanmaktadır (KOCAELİ İLİ KANDIRA İLÇESİ 14.7 MW KANDIRA RÜZGÂR ENERJİ SANTRALİ, n.d.).

2023 yılı itibarıyla Türkiye hükümeti, rüzgâr enerjisi kapasitesini 10 GW'a çıkarmayı hedeflemiştir; bu hedef, Kocaeli-Kandıra dahil tüm rüzgâr enerjisi santrallerinin gelişimini etkileyebilir. Kocaeli'de yer alan 49,8 MW kapasiteli Kandıra Rüzgâr Enerjisi Santrali, çeşitli aşamalarda aktif olarak geliştirilmekte olup, bu projeler arasında en dikkat çeken olarak öne çıkmaktadır (KOCAELİ İLİ KANDIRA İLÇESİ 14.7 MW KANDIRA RÜZGÂR ENERJİ SANTRALİ, n.d.; Rtenerji-Kandirares.Pdf, n.d.).

Tablo 2.2. Türkiye rüzgâr enerjisi çiftlikleri veri-tabanı: Kandıra rüzgâr enerjisi çiftliği.

Kandıra Rüzgâr Enerjisi Çiftliği	
Genel Bilgiler	
Rüzgâr Enerjisi Çiftliği Adı	Kandıra
Ülke	Türkiye
İl / Bölge	Kocaeli

Detaylar

- Şehir: Kandıra
- Türbin(ler): Faz 8 türbinden oluşmaktadır
- Toplam nominal güç: 49.8 MW
- Çiftlik şu anda aktif durumda
- Kara üstü rüzgâr çiftliği
- 120.50m yüksekliğinde kulelere sahiptir

Konum

- Enlem: 41° 6' 49.3"
- Boylam: 30° 2' 33.1"
- Jeodezik sistem: WGS84
- Kesin konum: Evet

2.4. Rüzgâr Hızı

Rüzgâr hızı, hava moleküllerinin hareket hızını ifade eder. Rüzgârın hızı arttıkça, hasat edilebilecek kinetik enerji de artar. Rüzgâr hızı, genellikle metre/saniye (m/s) veya deniz mili cinsinden ölçülür. Ancak, yenilenebilir olmayan enerji kaynaklarının, örneğin fosil yakıtların, mevcut ve çevresel sorunlar yaratmasına rağmen hâlâ kullanılmakta olduğu ve maliyet açısından daha uygun yenilenebilir enerji teknolojileri kabul edilene kadar bu kullanımın devam edeceği görülmektedir. Küresel enerji dönüşümünde yenilenebilir enerjinin rolü, doğru ve verimli bir tahmin metodolojisinin dikkatle seçilmesini zorunlu kılmaktadır. Çeşitli tahmin teknolojileri arasında, kısa vadeli tahmin yöntemleri (örneğin, bir gün öncesine ait tahminler), enerji piyasasındaki günlük değişimleri yansıtması nedeniyle daha kritik olarak değerlendirilmektedir. Yüksek kaliteli kısa vadeli rüzgâr hızı tahmini, daha iyi ve optimal şebeke işlemleri için önemli ve zorlu bir konudur (Bhaskar et al., 2014; Freitas et al., 2018). Etkileyen faktörler ve tahmin zaman dilimleri göz önünde bulundurularak, sayısal, yapay zekâ ve bulanık modeller gibi çeşitli tahmin yöntemleri bir sonraki bölümde ele alınacaktır.

Bu çalışmada, ölçüm birimi olarak metre/saniye (m/s) kullanılacaktır. Rüzgâr hızı, topografi, atmosfer koşulları ve coğrafya gibi çeşitli faktörlerden etkilenir. Kısa mesafelerde rüzgâr hızında büyük değişiklikler yaşanabilir; bu nedenle, rüzgâr hızının ve gücünün doğru bir şekilde tahmin edilmesi kritik öneme sahiptir (Pfeifer & Schönfeldt, 2012). Rüzgâr hızı tahmini, rüzgârın son derece değişken ve öngörülemez bir kaynak olması nedeniyle karmaşık ve zorlu bir süreçtir. Rüzgâr hızı, arazi yapısı, günün saati, mevsim ve hava koşulları gibi birçok faktörden etkilenir. Bu faktörlerin doğru bir şekilde tahmin edilmesi, rüzgâr hızı tahminleri için hayati öneme sahiptir (Silva et al., 2018). Bu bağlamda, DOOSA, DODGOSA ve KTB gibi gelişmiş makine öğrenimi modelleri, rüzgâr hızı tahmini için uygulanmaktadır.

3. RÜZGÂR HIZI TAHMİN MEKANİZMALARI

Rüzgâr hızı tahmini için kullanılan farklı algoritmalar, modeller ve yöntemler detaylandırılacaktır. Bu bölümde, rüzgâr hızının gelecekteki değerlerini öngörmek için kullanılan istatistiksel ve yapay zekâ tabanlı yaklaşımlar ele alınacak ve bu yöntemlerin güçlü ve zayıf yönleri tartışılacaktır. Ayrıca, tahmin doğruluğunu artırmak için kullanılan teknikler ve bu tekniklerin uygulanabilirliği üzerine değerlendirmeler yapılacaktır.

3.1. Rüzgâr Tahmini

Önceki bölümde belirtildiği üzere, enerji talebinin ve arzının dengelenmesi kritik bir öneme sahiptir. Bu dengenin sağlanması için tahmin edilen enerji miktarının kullanılması gerekmektedir. Ancak, bu tahminlerin yapılmasının da maliyetleri bulunmaktadır. Rüzgâr tahmini, rüzgâr türbinlerinin bir sonraki zaman diliminde üreteceği güç miktarını öngörmeye yönelik bir süreçtir. Bu çalışmada, rüzgâr hızının tahmin edilmesi, araştırmamızın temel adımlarından biridir. Rüzgâr hızı tahmininin önemi, rüzgâr tesislerinin enerji şebekesi üzerindeki etkilerini azaltma ve şebekenin güvenli işleyişini sağlama kapasitesinde ortaya çıkmaktadır. Rüzgâr tahmini, öncelikle sistem operatörlerine değişken yenilenebilir enerji kaynaklarından gelen enerji üretimini dengelemek için gereken yan hizmetleri daha etkili planlama imkânı sağlar. Ayrıca, rüzgâr üreticilerine enerji piyasası fiyatları ile uyumlu işletme kararları alma konusunda rehberlik eder (Ullah et al., 2009).

Rüzgâr hızı ve gücünü tahmin etmek için kullanılan araç ve yöntemler genellikle birkaç ana kategoriye ayrılabilir: süreklilik yöntemleri, fiziksel yöntemler, istatistiksel yöntemler, uzamsal korelasyon yöntemleri, yapay zekâ yöntemleri ve hibrit yaklaşımlar. Her bir yöntemin kendine özgü avantajları ve dezavantajları bulunmaktadır. Bazı durumlarda yöntemler, veri setinin türüne bağlı olarak değişiklik gösterirken, diğer durumlarda hata miktarını minimize etme ihtiyacı belirleyici olabilir.

Fiziksel yöntemler, sıcaklık, basınç, nem gibi meteorolojik bilgileri dikkate alarak rüzgâr hızını tahmin eder ve genellikle sayısal formüller kullanılarak hesaplamalar

yapılır. İstatistiksel yöntemler ise rüzgâr hızını tahmin etmek için meteorolojik veriler arasındaki ilişkileri değerlendirir ve geçmiş verilere dayanır. Bu yöntemin dezavantajı, tahmin süresinin uzamasıyla birlikte hatanın artmasıdır.

Rüzgâr tahminlerinde zaman ve mekân önemli rol oynar. Tahminler, coğrafi bölgeler arasında değişiklik gösterir çünkü tüm bölgeler için tek bir universal teknik geliştirilmemiştir. Bu makale, rüzgâr hızı ve gücü tahmini yapmak için mevcut detaylı teknikleri incelemekte ve gelecekteki olası gelişmeleri belirlemeye çalışmaktadır. Temel amaç, tüm modeller arasında (ve tüm teknikler arasında) en iyi performansı sergileyen modeli keşfetmek ve rüzgâr hızı tahminine dair sonuçlar çıkarmaktır. Bu nedenle, belirli koşullarda daha yeni ve doğru tahmin yöntemlerine duyulan ihtiyaç devam etmektedir (Guo et al., 2011).

Genel olarak, rüzgârın kesintili doğası onu programlanabilir olmayan bir enerji kaynağı yapmaktadır. Rüzgâr, çevreye zarar vermeyen ve yenilenebilir bir enerji kaynağı olarak, türbinler fosil yakıt kullanmadan enerji üretir. Ancak, kısa süreli değişkenliği rüzgâr enerjisinin doğru bir şekilde tahmin edilmesini zorlaştırmaktadır. Bu değişkenlik, mevcut ve geçmiş verilerden bilgi üreten tahmin tekniklerinin kullanılmasıyla yönetilebilir.

Önceki çalışmalar, kullanılan modelin konum ve veri setine bağlı olarak değişiklik gösterdiğini ortaya koymaktadır. Ayrıca, her bölgenin iklim özellikleri de farklılık arz etmektedir. Çalışmalarda en yaygın olarak kullanılan yazılım, verileri analiz etme yeteneği açısından MATLAB'dır; diğer çalışmalar ise R, Python ve KERAS gibi çeşitli çerçeveleri kullanmaktadır (Maldonado-Correa et al., 2021b).

3.2. Rüzgâr Hızı Tahmininin Akıllı Şebekeler için Önemi

Günümüzde artan enerji talebiyle birlikte rüzgâr enerjisinin penetrasyonu da önemli ölçüde artmıştır. Ancak, bu yenilenebilir enerji kaynağının üretimi çeşitli zorlukları beraberinde getirmekte ve sistem güvenilirliği ile güç kalitesini riske atmaktadır. Bu durum, denge yönetimi ve rezerv kapasiteleri gibi temel şebeke entegrasyon sorunlarını gündeme getirebilmektedir. Yenilenebilir enerji tahminleri, akıllı şebekeler içinde maliyetlerin kontrol edilmesinde kritik bir rol oynamaktadır (Stromsather et al., n.d.). Bu nedenle, enerji ve çevre alanında faaliyet gösteren birçok üniversite ve araştırma merkezi, çeşitli rüzgâr hızı ve güç tahmini yöntemlerini geliştirmeye yönelik çalışmalar yürütmektedir.

3.3. Rüzgâr Hızı Tahmini Sınıflandırılması

Literatürde, birçok yenilenebilir enerji tahmin tekniği önerilmiştir. Rüzgâr hızı tahmin teknikleri, belirli zaman ufuklarına sahip yöntemler ve teknolojiler kullanılarak yüksek performans sergileyebilir. Rüzgâr hızı tahmini, tahmin yöntemleri, tahmin nesnesi, tahmin verileri veya giriş parametreleri ve zaman ufukları gibi çeşitli faktörlere göre sınıflandırılabilir (Lange & Focken, 2008). Farklı zaman ufuklarına sahip tahminler, şebekede uygulanan çeşitli yöntemlerle desteklenir. Bu çalışmada, sistemin işletme açısından kritik öneme sahip olan ve programlama, ünite tahsisi ve yük izleme gibi işlemler için önemli olan gün öncesi (kısa vadeli) tahminler incelenmektedir (Foley et al., 2012; El-Fouly et al., 2008). Rüzgâr hızı tahmin modelleri genellikle iki ana gruba ayrılmaktadır:

3.3.1. Zaman ölçeği sınıflandırmaları

Zaman ölçeği sınıflandırmaları, rüzgâr hızı tahminlerinde kullanılan verilerin belirli zaman dilimlerine göre kategorize edilmesini ifade eder. Bu sınıflandırmalar, tahmin süresinin uzunluğuna bağlı olarak farklılık gösterir ve her biri için farklı yöntemlerin uygulanmasını gerektirir. Genel olarak, zaman ölçeği sınıflandırmaları üç ana kategoriye ayrılmaktadır.:

3.3.1.1. Çok- kısa dönem

Çok kısa dönem (saniyelerden birkaç dakikaya) tahmin modelleri, rüzgâr akışının büyük ölçekli atmosferik hareketler ile mikro iklim etkilerinin bir kombinasyonu olarak değerlendirilir. Bu zaman dilimi için yapılan tahminler genellikle, gözlemlenen veriler arasındaki ilişkileri temel alan istatistiksel modellere dayanır. Bu tahminler, ekonomik dağıtım ve ünite tahsisi gibi alanlarda potansiyel kullanım alanlarıyla dikkat çekerken, aynı zamanda güç sistemleri yönetimi ve enerji ticareti için de önem arz etmektedir (A.Adeoti et al., 2020) (Potter et al., 2010).

3.3.1.2. Kısa -dönem

Kısa vadeli rüzgâr hızı tahmin modelleri, (genellikle 1 saat ile birkaç saatlik) zaman dilimlerinde uygulanır. Bu modeller, Sayısal Hava Tahmini (NWP) yöntemlerinin uzun işlem süreleri ve yüksek hesaplama kaynakları gerektirmesi nedeniyle çoğunlukla istatistiksel yaklaşımlara dayalı olarak geliştirilir. Bu tür tahmin yöntemleri, rüzgâr türbinlerinin yapılandırılması ve ek pazar bilgilerine ilişkin belirsizliklerin giderilmesi açısından kritik öneme sahiptir (Miranda & Dunn, 2006).

Diğer zaman ölçeğine dayalı tahmin modelleri ise şu şekildedir:

3.3.1.3. Orta dönem

(7 güne kadar) tahmin, birkaç gün ila iki hafta arasındaki bir zaman dilimini kapsar. Orta vadeli rüzgâr hızı tahmini, enerji tedariki ve üretim programları hakkında bilinçli kararlar alınmasına yardımcı olur. Ayrıca çiftçilere ve diğer paydaşlara hava koşullarını daha iyi anlama fırsatı verir; böylece tarım ve hayvancılık yönetimi uygulamalarını optimize etmek için kullanabilirler (Soman et al., 2010).

3.3.1.4. Uzun dönem

(Haftalar boyunca) tahmin, birkaç haftadan başlayıp birkaç aya kadar olan bir zaman dilimini kapsar. Uzun vadeli rüzgâr hızı tahmini başlıca yatırım planlaması ve stratejik karar alma için kullanılır. Yatırımcılara ve proje geliştiricilere rüzgâr çiftliğinin potansiyelini değerlendirme, gelecekteki kapasite genişlemesi için plan yapma ve farklı bölgelerde yenilenebilir enerji yatırımlarının risklerini ve fırsatlarını değerlendirme konusunda yardımcı olur (Soman et al., 2010).

3.3.1.5. Aylık, mevsimsel ve özel kategoriler

Rüzgâr çiftlikleri tarafından üretilen rüzgâr hızını tahmin etmeye yönelik araştırmalar, etkili ve güvenilir araçların geliştirilmesine odaklanmıştır. Bu araçlar, tahmin sürecinde arazi bilgileri gibi konum verilerinin girdi olarak kullanılıp kullanılmamasına göre sınıflandırılabilir. Bu sınıflandırmanın detayları Tablo 3.1'de sunulmaktadır:

Bu sınıflandırmalar, rüzgâr hızı tahmininde kullanılacak modellerin seçimini ve bu modellerin veri işleme süreçlerini doğrudan etkiler. Her bir zaman ölçeği, belirli bir analiz yöntemi gerektirir ve bu nedenle, tahminlerin doğruluğu ve güvenilirliği açısından zaman ölçeği sınıflandırmaları büyük önem arz eder.

Tablo 3.1. Tahmin Zaman Ölçeği Sınıflandırması.

Zaman Ölçeği	Tahmin Horizontu	Uygulamalar
Çok Kısa Vadeli	Bir Saat Öncesi	Yük Takibi. Gerçek Zamanlı Şebeke İşlemleri, Düzenleme Hareketleri
Kısa Vadeli	Bir Gün Öncesi	Elektrik Piyasasındaki İşletme Güvenliği, Ekonomik Yük Dağıtım Planlaması.
Daha Uzun Zaman Ölçeği	Birden Fazla Gün Öncesi	Optimal İşletme Maliyeti. Bakım Planlaması. İşletme Yönetimi.

Rüzgâr hızı tahminlerinde kullanılan iki temel yaklaşım, fiziksel ve istatistiksel yöntemlerdir. Bazı modeller, bu iki yaklaşımın avantajlarını birleştiren karma yöntemleri kullanarak daha kapsamlı tahminler sağlar.

3.3.2. Metodoloji sınıflandırmaları

Metodoloji sınıflandırmaları, rüzgâr hızı tahmininde uygulanan çeşitli teknik ve yaklaşımların türlerine göre kategorize edilmesini ifade eder. Bu sınıflandırmalar, kullanılan yöntemlerin doğasını, veri işleme süreçlerini ve modelleme tekniklerini kapsamlı bir şekilde ele alır. Genel olarak, metodoloji sınıflandırmaları üç ana kategoriye ayrılmaktadır::

3.3.2.1. Fiziksel yaklaşım (belirgin yaklaşım)

Fiziksel yöntemler, rüzgâr hızı tahmininde hava tahmin verilerini, örneğin sıcaklık, basınç, yüzey pürüzlülüğü ve engeller gibi faktörleri kullanarak alt atmosfer koşullarını veya sayısal hava tahmini (NWP) modelini temel alır. Bu yöntemlerde, yerel meteoroloji servislerinden elde edilen rüzgâr hızı verileri, rüzgâr çiftliklerinde rüzgâr türbinlerine dönüştürülerek rüzgâr enerjisine çevrilir. İstatistiksel yaklaşımların aksine, fiziksel yöntemler tarihsel verilerden eğitim gerektirmeden çalışabilir. Genellikle topografik özellikler ve hava faktörleri gibi giriş değişkenlerini kullanarak gelecekteki rüzgâr enerjisi eğilimlerini tahmin ederler. Bu yöntemlerin avantajı, uzun vadeli tahminlerde büyük miktarda tarihsel veri gerektirmemeleridir (Dzebre et al., 2021).

3.3.2.2. İstatistiksel yaklaşım

İstatistiksel yöntemler, geniş bir geçmiş veri setine dayanarak tahminler yapar ve meteorolojik koşulları doğrudan dikkate almaz. Bu yöntemler genellikle önceki tarihsel verileri kullanarak bir istatistiksel model oluşturur. Bu model, belirli bir zaman t noktasındaki çevrimiçi ölçümler ve zaman $t+k$ için yapılan sayısal hava tahminleri (NWP) kullanılarak birkaç saat sonrasını tahmin eder ve kısa vadeli rüzgâr gücünü etkili bir şekilde öngörebilir. Modelleme süreci genellikle kolay ve maliyet açısından uygundur; ancak, fiziksel yaklaşımlardan farklı olarak, istatistiksel yöntemler geçmiş verilerle eğitildiği için tahmin hatası zamanla artar ve bu durum uzun vadeli tahminlerde güvenilirlik sorunlarına yol açar [46]. İstatistiksel yöntemler genellikle yapay zekâ teknikleri (sinir ağları, nöro-fuzzy ağlar) ve zaman serisi analizi yaklaşımlarını içerir (Rodríguez et al., 2020).

Sonuç olarak, rüzgâr hızı tahminlerinde doğru yöntemin seçilmesi, veri türü ve diğer gereksinimlerin titizlikle değerlendirilmesini zorunlu kılar. Uygun metodolojinin belirlenmesi, tahminlerin doğruluğunu ve güvenilirliğini artırarak enerji sistemlerinin etkin yönetimini destekler.

Rüzgâr hızı tahmininde kullanılan birkaç tür veri odaklı (istatistiksel) model vardır, bunlar arasında Otoregresif Entegre Hareketli Ortalama (OREHO), Yapay Sinir Ağları (YSA), Doğrusal Olmayan Otoregresif Dışsal Sinir Ağları (DODGOSA) ve Kapalı Tekrarlayan Birim (KTB) gibi yöntemler bulunmaktadır.

- Oto-Regresif entegre hareketli ortalama (OREHO-ARIMA)

OREHO modelleri, tahminler üretmek amacıyla geçmiş rüzgâr hızı verilerini kullanan zaman serisi modelleridir. Bu modeller, bir zaman serisinin gelecekteki değerlerinin, geçmiş değerler ve hata terimleri ile ilişkili olduğu varsayımına dayanır. OREHO modellerinin genellikle kısa vadeli tahminlerde etkili olduğu kanıtlanmıştır. (Shi et al., 2011).

- Doğrusal olmayan otoregresif sinir ağı (DOOSA- NAR)

Doğrusal olmayan otoregresif (DOOSA) sinir ağı, zaman serisi desenlerini ve doğrusal olmayan özellikleri tanımlama konusunda avantajlı özelliklere sahip olan güçlü bir model sınıfını temsil eder.

Doğrusal Olmayan Otoregresif (DOOSA) modeli, gecikmeli verileri kullanarak zaman serisi tahminleri yapmak için uygun bir modeldir. Bu modelin yapısı, bir otoregresif

model ile entegre edilmiş çok katmanlı algılayıcılardan oluşur (Arabeyyat et al., 2018; Sansa et al., 2021)

- Doğrusal olmayan dışsal girdili otoregresif sinir ağı – (DODGOSA- NARX)

DODGOSA modelleri, rüzgâr hızı tahmini için kullanılan bir sinir ağı modelidir. Bu modeller, hava durumu verileri veya türbin verileri gibi dışsal girdileri tahmin sürecine entegre edebilir. DODGOSA modellerinin, rüzgâr hızı tahmininde etkili olduğu kanıtlanmış olup hem kısa vadeli hem de uzun vadeli tahminler için kullanılabilir (Di Piazza et al., 2016; Sansa et al., 2021).

- Kapılı Tekrarlayan birimi (KTB-GRU)

KTB modeli, geleneksel Tekrarlayıcı Sinir Ağları'na (RNN) kıyasla daha verimli olacak şekilde tasarlanmış bir tür yinelemeli sinir ağı modelidir. KTB modelinin, geleneksel RNN'lerden ayrılan temel özelliği, bilgi akışını kontrol etmek için kapı mekanizmaları kullanmasıdır. Bu özellik, geleneksel RNN'lerde yaygın olarak görülen gradyan kaybı sorununu önlemeye yardımcı olur ve modelin etkili bir şekilde eğitilmesini sağlar (Xie et al., 2021).

Son on yılda hem güneş ışınımı hem de rüzgâr hızı tahminlerinde önemli ilerlemeler kaydedilmiş olmasına rağmen, temel zorluk tahminlerin doğruluk düzeyidir. Bu doğruluk, tahminin amacı (tahmin ufku ve tahmin sıklığı) ve değişkenlik koşullarıyla yakından ilişkilidir. Çoğu metodoloji genellikle tahminin amacına göre belirlenir ve genellikle meteorolojik veriler kullanılarak gerçekleştirilir. Ancak, birçok bölgede meteorolojik veri eksikliği, bu bölgelerde tahmin algoritmalarının uygulanmasında önemli bir engel teşkil etmektedir. Ayrıca, kullanılan veri kalitesinin bazen yetersiz olması, sonuçların doğruluğunu olumsuz etkileyebilir. Gerçek zamanlı veri elde etmenin yüksek maliyeti de tahmin doğruluğunu artırma çabalarını zorlaştıran bir faktördür. (Ssekulima et al., 2016).

3.4. Rüzgâr Tahminini Etkileyen Faktörler

Rüzgâr tahmini, pek çok değişkene bağlı karmaşık bir süreçtir ve bu değişkenler, tahminlerin doğruluk ve güvenilirlik düzeyini büyük ölçüde etkiler. Bu faktörlerin derinlemesine anlaşılması, etkili tahmin modellerinin geliştirilmesi açısından kritik öneme sahiptir. İlerleyen bölümlerde, rüzgâr tahminine etki eden temel unsurlar detaylı bir şekilde ele alınacaktır (“Green Energy and Technology,” 2006).

- Arazi ve Topografi:

Yerel coğrafya ve arazi yapısı, rüzgâr desenlerini belirgin bir şekilde etkileyebilir. Dağlar, tepeler, vadiler ve kıyı bölgeleri gibi topografik unsurlar, rüzgâr hızı ve yönünde kayda değer değişikliklere yol açabilir. Bu tür coğrafi özellikler, rüzgârın akışını engelleyebilir, yönünü değiştirebilir veya hızını artırabilir, bu da rüzgâr tahminlerinde dikkate alınması gereken önemli faktörlerdendir.

- Yüzey Pürüzlülüğü

Rüzgârın geçtiği yüzey türü, rüzgâr hızını etkileyen önemli bir faktördür. Su yüzeyleri, ormanlar, kentsel alanlar veya açık düzlükler gibi farklı yüzey türleri, rüzgâr üzerinde farklı sürtünme kuvvetleri oluşturur. Bu sürtünme, rüzgârın hızını yavaşlatabilir veya artırabilir, dolayısıyla rüzgâr hızı tahminlerinde dikkate alınması gereken kritik bir unsurdur.

- Sıcaklık Gradyanları:

Bölgeler arasındaki sıcaklık farkları, basınç gradyanlarının oluşmasına neden olarak rüzgâr akışını doğrudan etkileyebilir. Bu termal varyasyonlar, yerel rüzgâr sistemlerinin gelişimini destekler ve rüzgâr hızında ve yönünde değişikliklere yol açabilir. Dolayısıyla, bu faktörler, rüzgâr tahmin modellerinin doğruluğunu artırmak amacıyla dikkatle analiz edilmelidir.

- Basınç Sistemleri

Yüksek ve alçak basınç sistemleri, rüzgâr desenlerinin oluşumunda kritik bir rol oynar. Rüzgâr, genellikle yüksek basınçlı alanlardan alçak basınçlı alanlara doğru hareket eder. Bu sistemlerin gücü, konumu ve hareketleri, rüzgâr hızını ve yönünü belirleyen temel faktörler arasında yer alır. Dolayısıyla, bu basınç sistemlerinin analizi, rüzgâr tahminlerinin doğruluğunu artırmak için hayati öneme sahiptir.

Coriolis Etkisi
Dünya'nın dönmesi, Coriolis etkisine neden olarak hareket eden hava kütlelerini sapmaya iter. Bu etki, küresel ölçekte rüzgâr yönünü etkiler.

- Hava Cepheleri

Farklı hava kütlelerinin hava cephelerinde birbiriyle etkileşimi, rüzgâr desenlerinde önemli değişikliklere yol açabilir. Sıcak ve soğuk hava kütlelerinin hareketi, özellikle cephe bölgelerinde, dinamik ve değişken hava koşullarının ortaya çıkmasına neden

olabilir. Bu etkileşimler, rüzgâr hızını ve yönünü etkileyerek tahminlerdeki belirsizliği artırabilir. Seasonal Changes.

Mevsimsel değişiklikler de rüzgâr desenlerini etkiler. Örneğin, kıyı bölgelerinde kara ve deniz arasındaki sıcaklık farkları, yaz ve kış aylarında farklı rüzgâr desenlerinin oluşmasına neden olabilir.

- Yerel Rüzgâr Sistemleri

Deniz meltemleri, dağ/vadi esintileri ve katabatik rüzgarlar gibi çeşitli yerel rüzgâr sistemleri, belirli bölgelerde rüzgâr tahminlerinin doğruluğunu önemli ölçüde etkileyebilir.

- Güneş Radyasyonu

Güneş ışınımı, konvektif akımların oluşumuna katkıda bulunarak yerel rüzgâr desenlerini etkiler. Gündüz saatlerinde yaşanan ısınma ve gece soğuma süreçleri, tahmin edilebilir günlük rüzgâr varyasyonlarına neden olabilir.

- Engeller ve Binalar

Kentsel yapılar ve büyük binalar, rüzgârın bu engellerle etkileşiminde yönlendirme ve hız değişikliklerine yol açabilir. Bu nedenle, kentsel alanlarda rüzgâr tahmini yaparken bu etkilerin dikkate alınması önemlidir.

- Rüzgâr Türbini Uyanma Etkileri

Rüzgâr çiftliklerinin bulunduğu bölgelerde, bir türbin tarafından oluşturulan uyandırma etkisi diğer türbinlerin performansını etkileyebilir. Bu nedenle, rüzgâr çiftliklerinin konumlarında doğru tahminler yaparken bu etkilerin dikkate alınması gereklidir.

Bu faktörlerin anlaşılması ve modellenmesi, meteorologlar ve rüzgâr enerjisi operatörlerinin güvenilir rüzgâr tahminleri yapabilmeleri açısından büyük önem taşır. Bu durum, özellikle rüzgâr çiftliklerinden elde edilen yenilenebilir enerji üretimi bağlamında kritik bir rol oynar. Gelişmiş meteorolojik modeller ve teknolojiler, bu çeşitli etkenleri dikkate alarak rüzgâr tahminlerinin doğruluğunu artırmayı sürdürmektedir (Nazir et al., 2020; Spiliotis et al., 2020) (Konstantinou & Hatzigryriou, 2023).

3.5. Rüzgâr Hızı Tahmininin Zorlukları ve Sınırlamaları

Rüzgâr hızı tahmininde kaydedilen ilerlemelere rağmen, hâlâ çeşitli zorluklar ve sınırlamalar bulunmaktadır (Belu et al., 2012) .

- Hava desenlerinin öngörülemezliği

Ana zorluklardan biri, hava desenlerinin öngörülemezliğidir. Hava desenleri, hızla ve öngörülemez bir şekilde değişebilir, bu da doğru rüzgâr hızı tahminleri oluşturmayı zorlaştırır. Özellikle uzun vadeli tahminler açısından bu öngörülemezlik, tahmin doğruluğunu önemli ölçüde azaltabilir, çünkü tahmin süresi uzadıkça doğruluk seviyesi genellikle düşer (Belu et al., 2012).

- Doğru ve güvenilir veri ihtiyacı

Başka bir zorluk, doğru ve güvenilir veriye olan ihtiyaçtır. Rüzgâr hızı tahmin modelleri, veriler üzerine inşa edilmiştir ve hatalı veya güvenilmez veriler, yanlış tahminlere yol açabilir. Bu nedenle, tahmin modellerinde kullanılan verilerin sürekli olarak doğru, güvenilir ve tutarlı olması önemlidir. Bu durum, sınırlı veri kaynaklarına sahip veya veri kalitesi düşük bölgelerde özellikle sorun teşkil edebilir. Tahmin modellerinin karmaşıklığı

Tahmin modellerinin karmaşıklığı da önemli bir sınırlama teşkil edebilir. Özellikle sinir ağları gibi veri odaklı modelleme teknikleri, geliştirme ve bakım aşamalarında önemli miktarda hesaplama gücü ve uzmanlık gerektirmektedir. Bu karmaşıklık, sınırlı kaynaklara sahip küçük ölçekli kuruluşlar veya bu alana yeni giriş yapanlar için bir engel oluşturabilir.

Son olarak, rüzgâr hızı tahmini, rüzgâr enerjisi tahmininin yalnızca bir bileşenidir. Rüzgâr enerjisi tahmini, rüzgâr türbinlerinin güç çıkışını da öngörmeyi içerir. Bu öngörü, sadece rüzgâr hızına değil, aynı zamanda türbin özellikleri, çevresel koşullar ve şebeke kısıtlamaları gibi diğer faktörlere de bağlıdır. Dolayısıyla, tahmin modelleri geliştirilirken tüm rüzgâr enerjisi tahmin sürecinin dikkate alınması büyük önem arz etmektedir (Wang et al., 2021).

3.6. Rüzgâr Hızı / Rüzgâr Gücü (WS/WP) Tahmini Gelecek Trendleri

WSF'nin doğruluğunu artırmak amacıyla, bazı yaklaşımlar yukarıda belirtilen zorlukları ele alarak geliştirilmiştir (Wang et al., 2021)::

3.6.1. Yeni veri ön işleme yöntemlerinin geliştirilmesi

Rüzgâr verilerindeki belirsizlikleri dikkate alan yeni veri ön işleme tekniklerinin geliştirilmesi büyük önem taşımaktadır. Rüzgâr verilerinin karmaşık yapısı nedeniyle, mevcut veri ön işleme yöntemleri, diğer belirsiz veri kümeleri üzerinde yeterli analiz sağlamayabilir. Bu belirsizlikleri gidermeye yönelik ön işleme yöntemleri, tahmin doğruluğunu önemli ölçüde iyileştirebilir.

3.6.2. Aday özelliklerin genişlemesi

WS/WP dalgalanmaları, aday özelliklerin artışından kaynaklanmaktadır. WS ve WP varyasyonlarını daha doğru bir şekilde açıklayabilmek için topografik ve meteorolojik unsurlar gibi ek faktörlerin dikkate alınması faydalı olabilir. Bu tür verilerin toplanabilmesi için uygun sensörlerin kurulumunun yapılması da önerilebilir.

3.6.3. Uygun özellik çıkarma yöntemlerinin geliştirilmesi

Sınırlı özelliklerden daha fazla fayda sağlayacak yeni özellik çıkarma yöntemlerinin geliştirilmesi önemlidir. Geleneksel özellik çıkarma teknikleri ile yapay sinir ağı (ANN) modellerinin birlikte kullanılması, daha verimli ve etkili özelliklerin elde edilmesi potansiyelini taşımaktadır.

3.6.4. Tahmin modellerindeki doğrusal olmayan uyumun geliştirilmesi

İklim değişkenliği ve karmaşık arazi, WS/WP dalgalanmalarını tanımlamayı zorlaştırır. Doğrusal olmayan uyum kabiliyetini artırmak için farklı tahmin modellerinin birleştirilmesi faydalı olabilir. WS/WP'nin dalgalanma özelliklerini bağımsız olarak karakterize etmek için farklı DNN tabanlı ve geleneksel tahmin modelleri kullanmak mümkündür. Ardından, farklı tahmin modellerinin farklı doğrusal olmayan uyum yeteneklerinden faydalanmak için optimal birleştirme stratejisi geliştirilebilir.

3.6.5. Çeşitli tahmin modelleri için optimal yapılandırmaların belirlenmesi

Teorik olarak, bir DNN'ın karmaşık olmayan ilişkileri modelleyebilmesi mümkündür. Ancak, DNN tabanlı tahmin modellerinin performansı, büyük ölçüde model yapısı ve öğrenme algoritması gibi yapılandırmalardan etkilenir. Ayrıca, WS/WP özellikleri farklı konumlarda değişiklik gösterir. Günümüzde, birçok akıllı optimizasyon yöntemi, sığ tahmin modellerinin optimal yapılandırmalarını belirlemek ve daha iyi tahmin sonuçları elde etmek için kullanılmaktadır. Ancak, derin modellerin birçok ayarlanması gereken parametreye sahip olması, uygun yapılandırmalarını bulmayı

zaman alıcı ve zor hale getirebilir. Bu nedenle, gelecekteki çalışmalar, belirli bir rüzgâr veri setinin özelliklerine dayalı olarak karmaşık tahmin modelleri için optimal yapılandırmaları sağlayacak genel kurallar üzerinde odaklanmalıdır. Ayrıca, derin tahmin modellerini ayarlamak için daha verimli yapay optimizasyon yöntemlerinin tasarımı ve uygulanması gerekmektedir. (Wang et al., 2021).



4. VERİ TOPLAMA VE ÖN İŞLEME

4.1. Arka Plan

Makine öğrenimi tekniklerinin akıllı şebekeler içinde kısa vadeli rüzgâr hızı tahmini amacıyla başarılı bir şekilde uygulanabilmesi, büyük ölçüde temel verilerin kalitesine ve ilgili olmasına bağlıdır. Bu bölüm, veri toplama sürecinin ayrıntılarını ele alarak, veri kümesinin bütünlüğünü korumak ve sonraki analizler için uygun hale getirmek amacıyla gerçekleştirilen ön işleme adımlarını açıklamaktadır.

4.2. Veri Toplama Hedefleri

Veri toplamanın temel hedefleri iki ana katmandan oluşmaktadır: birincisi, Kocaeli'deki rüzgâr hızı özelliklerini yansıtan temsilci bir veri kümesi elde etmek, ikincisi ise toplanan verileri, tahmin için kullanılan makine öğrenimi modellerinin gereksinimleriyle uyumlu hale getirmektir. Bu bölüm, veri toplamanın nedenlerini açıklayarak belirli hedefleri özetlemektedir.

4.3. Veri Kaynakları

Bu çalışma için Kocaeli, Türkiye'deki belirli bir konumda 2018 yılına ait bir veri kümesi kullanılmıştır. Kandıra Rüzgâr Çiftliği, on rüzgâr türbinini içeren bir enerji projesinin parçasıdır. Kandıra'nın enerji projesi, Türkiye'deki elektrik enerjisi krizine çözüm olarak "RES" alternatiflerinden biri olan rüzgâr enerjisini kullanmayı hedeflemektedir. Bu proje, ülkenin rüzgâr kapasitesini 49.8 MW artırma potansiyeline sahip olarak değerlendirilmiştir [1]. Kandıra rüzgâr çiftliği, çevresel ve sosyal açıdan duyarlı bir şekilde işletilmekte olup yılda yaklaşık 75.000 ton CO2 emisyonunun azaltılmasına katkıda bulunmaktadır. Kocaeli, Türkiye'deki Kandıra rüzgâr çiftliği için DOOSA modelinin uygulanması, bir yıl boyunca rüzgâr hızını tahmin ederek bir gün önceden güç tahminleri yapılmasına olanak tanır. Bu, ülkenin genelindeki Kandıra projesine destek sağlayabilir. Sonrasında, diğer makine öğrenimi yöntemleri olan DODGOSA ve KTB ile birlikte, üç yöntem arasındaki performans karşılaştırılacaktır.

4.3.1. Toplama süreci

Veri toplama süreci, rüzgâr hızı tahmini için gerekli bilgilerin elde edilmesinde kritik bir aşamadır. Bu bölümde, rüzgâr hızı ve çeşitli çevresel faktörlere ilişkin tarihsel verilerin toplanmasında izlenen sistematik yöntem ayrıntılı olarak ele alınmaktadır.

- **Zamansal Kapsam:** Veri toplamanın zaman aralığı, Ocak 2018 ile Aralık 2018 arasındaki bir yıllık dönemi kapsar. Bu geniş zaman dilimi, rüzgâr hızı desenlerinin belirlenen süre zarfında ayrıntılı bir şekilde incelenmesine olanak tanır.
- **Örnekleme Frekansı:** Veri kümesinin örnekleme frekansı, dikkatle seçilmiş düzenli 60 dakikalık aralıklarla belirlenmiştir. Bu yaklaşım, rüzgâr hızındaki ince değişimlerin tespit edilmesine olanak sağlayan yüksek çözünürlüklü bir zaman dizisi sunar.
- **Çevresel Faktörler:** Veri toplama süreci, yalnızca rüzgâr hızını değil, aynı zamanda sıcaklık, rüzgâr yönü, nem ve basınç gibi çeşitli çevresel faktörleri de içerecek şekilde genişletilmiştir. Bu faktörler, analiz süreçlerini zenginleştirerek tahmin modellerinin doğruluğunu artırır.

Toplanan veriler daha sonra iki ana bölüme ayrılır: eğitim verisi ve test verisi. Eğitim verisi, DOOSA, DODGOSA ve KTB modellerinin eğitimi için kullanılırken, test verisi bu üç modelin performansını değerlendirmek amacıyla kullanılır. Eğitim verisi ayrıca giriş verisi ve hedef veri olarak iki alt gruba ayrılır. Giriş verisi, tarihsel rüzgâr hızı verileri ile birlikte sıcaklık, nem ve basınç gibi dışsal değişkenleri içerir. Hedef veri ise bir sonraki zaman adımı için rüzgâr hızı değerlerini içermektedir.

Toplanan bu veriler, kısa vadeli rüzgâr hızı tahminleri için sürü tabanlı veri modellerinin geliştirilmesi amacıyla kullanılır. DOOSA modelinin performansı, ortalama karesel hata (MSE) ve korelasyon katsayısı (R2) gibi çeşitli metrikler kullanılarak değerlendirilir. DOOSA modelinin performansı, DODGOSA ve KTB gibi diğer kısa vadeli rüzgâr hızı tahminleme modelleriyle karşılaştırılarak, önerilen modelin etkinliği belirlenir.

4.3.2. Veri ön işleme teknikleri

Veri ön işleme, toplanan veri kümesini kapsamlı bir analize uygun hale getirmek ve veri kalitesini garanti altına almak adına kritik bir aşamadır (W. Zhang ve ark., 2017). MATLAB kodlaması bağlamında, 24 saat sonrası rüzgâr hızını tahmin etmek amacıyla

çeşitli adımlar izlenecektir. Ham veri kümesi, girişlere alınmadan ve MATLAB'a aktarılmadan önce dönüştürülmelidir. Toplanan veri ham durumda olup, hatalı, eksik ve gereksiz veriler içermektedir. Bu nedenle, daha isabetli sonuçlar elde etmek için veri ön işlemeye ihtiyaç duyulmaktadır. Ham veriler düzensiz olduğundan, Ocak 2018'den Aralık 2018'e kadar olan döneme ilişkin düzenlemeler ve filtrelemeler yapılmıştır.


Ön işleme süreci, aykırı değerlerin, eksik verilerin veya hataların giderilmesini kapsar. Bu aşamalar şunları içerir:

- Eksik Değerlerin İşlenmesi: Ortalama, mod, medyan amputasyonu, interpolasyon veya eksik veriye sahip satır/sütunların çıkarılması gibi yöntemler kullanılır.
- Veri Normalizasyonu: Rüzgâr hızı verileri, makine öğrenimi modellerinin eğitimi için $[0, 1]$ aralığında normalize edilmiştir. Bu işlem için Min-Max normalizasyon tekniği uygulanmıştır.
- Özellik Seçimi: DOOSA ve KTB modelleri için rüzgâr hızı tek girdi olarak kullanılmıştır. DODGOSA modeli için ise ek meteorolojik değişkenler eksojen girdiler olarak dahil edilmiştir. En önemli özellikleri belirlemek amacıyla özellik önem analizi gerçekleştirilmiştir.
- Veri Setinin Bölünmesi: Modelin performansını değerlendirmek amacıyla veri seti eğitim ve test gruplarına ayrılmıştır. Veri seti eğitim (%70), doğrulama (%15) ve test (%15) setlerine bölünmüştür.


Birçok ön işleme adımı aynı Excel tablosunda gerçekleştirilmiştir: İlk olarak boş veriler çıkarılmış, ardından gereksiz satırlar silinmiş ve eksik değerler, veri setinin eksik verilere yakın olduğu yılın tam günleri için ortalama kullanılarak düzeltilmiştir. Son olarak, filtrelenmiş veriler, MATLAB'da modelleme için uygun bir tabloya dönüştürülmüştür. Bu çalışma, Intel(R) Core(TM) i7-10510U CPU @ 1.80GHz, 2304 MHz, 4 çekirdek, 8 mantıksal işlemciye sahip bir dizüstü bilgisayar üzerinde MATLAB kullanılarak gerçekleştirilmiştir.

Araştırma, Otoregresif Entegre Hareketli Ortalama (OEHO), Yapay Sinir Ağları (YSA), Doğrusal Olmayan Otoregresif Dışsal Sinir Ağları (DODGOSA) ve Kapılı Tekrarlayan Ünite (KTB) gibi çeşitli veri odaklı modellerin kullanımını içermektedir.

Şekil 4.1 ve Şekil 4.1. Rüzgâr hızı frekansı / Kandıra rüzgâr istasyonu- ham veri. Şekil 4.2, veri ön işleme öncesi ve sonrasında veri seti frekansının, DOOSA modelinin girişi (rüzgâr hızı) için karşılaştırıldığını göstermektedir. Ayrıca, aynı prosedürün DODGOSA ve KTB'ya uygulandığı dört girişle (rüzgâr hızı ve üç dış değişken) gösterilmektedir.



Şekil 4.1. Rüzgâr hızı frekansı / Kandıra rüzgâr istasyonu- ham veri.



Şekil 4.2. Rüzgâr hızı frekansı / Kandıra rüzgâr istasyonu- temizlenmiş veri (ön işleme sonrası).

4.3.3. Deneysel çalışma


- Eğitim, Doğrulama ve Test Etme

Verilerin toplanması ve ön işlenmesinin ardından, bir sonraki adım, işlenecek verilerin sisteme aktarılmasını kapsamaktadır. Bu aşamada, normalize edilmiş veriler zaman endeksine göre bölünmüştür. Verilerin ilk %70'lik kısmı eğitim amacıyla kullanılmıştır (öğrenme algoritmaları aracılığıyla YSA modellerini eğitmek için), sonraki %15'lik kısmı doğrulama için ayrılmıştır (ağın genelleştirme kapasitesini değerlendirmek ve genelleştirme artık iyileşmediğinde eğitimi durdurmak için) ve son %15'lik kısım ise test aşaması için ayrılmıştır (eğitim sonrası ağ performansını bağımsız olarak değerlendirmek amacıyla). Bu süreçte, DOOSA modeline dayalı bir beslemeli sinir ağı uygulanmıştır.

Aynı veri bölme yöntemi, DODGOSA ve KTB modelleri için de geçerli kılınmıştır. Her iki YSA modelinin ağ mimarisi iteratif bir süreçle belirlenmiş ve Şekil 4.3'te gösterilmiştir. Tüm DOOSA, DODGOSA ve KTB modelleri için aşağıdaki uygulama adımları izlenmiştir.

Rüzgâr çiftliği konumu olan Kandıra istasyonundan alınan 4*8576'lık veri seti ilk adım olarak kullanılmıştır. Bu veri seti 4*8576, yani dört hava parametresini ve 2018 yılındaki 8576 saatlik veriyi içerir. Bu veri setinin örnekleri Tablo 4.2'de sunulmuştur.

MATLAB kullanılarak, 2018 yılı boyunca Kandıra rüzgâr çiftliği için rüzgâr hızı verilerinin ve veri kümesinin frekansının belirlenmesi amacıyla bir dizi adım gerçekleştirilecektir. Analiz için, 12 ay boyunca tam veri setine sahip olduğumuz dört konumdan biri seçilmiştir.



Şekil 4.3. En iyi parametreler için DOOSA (a) ve DODGOSA (b) ağ mimari En iyi parametreler için DOOSA (a) ve DODGOSA (b) ağ mimari.

Tablo 4.1. Kandıra Çiftliği'nden ilk 12 saat için hava verileri.

Zaman	Rüzgâr Hızı	Rüzgâr Yönü	Sıcaklık	Nem
1/1/2018 0:00	0.4	168°	8.5	94.0
1/1/2018 1:00	0.4	1°	7.4	95.0
1/1/2018 2:00	0.3	343°	7.6	94.0
1/1/2018 3:00	0.4	270°	7.8	94.0
1/1/2018 4:00	0.4	1°	7.0	94.0
1/1/2018 5:00	0.3	335°	7.1	93.0
1/1/2018 6:00	0.5	325°	7.1	83.0
1/1/2018 7:00	1.1	193°	7.2	75.0
1/1/2018 8:00	2	216°	7.4	64.0
1/1/2018 9:00	2.1	217°	6.5	66.0
1/1/2018 10:00	2	234°	5.7	74.0
1/1/2018 11:00	1.7	232°	4.7	68.0

Tablo 4.2. Modellerinin veri kümesi bölümü.

Veri	Oran (%)	Miktarı
Training	70	6003
Test	15	1286
Validation	15	1286
Total	100	8576

Yukarıda belirtildiği gibi MATLAB simülasyonu şu adımlarla gerçekleştirilir: Bu normalize edilmiş ve temizlenmiş veriler, zaman endekslerine dayalı olarak bölünmüştür. İlk 70%'lik veri, eğitim için kullanılır, bu da 6003'e eşittir. Sonraki 15%'lik veri (1286), doğrulama için kullanıldı. Geriye kalan veri (15%), Tablo 4.2 'de sunulduğu gibi test için kullanıldı. Gizli katmandaki nöron sayısını ve geri bildirim gecikmelerini temsil eden hiperparametreler sırasıyla 1 ile 15 ve 1 ile 48 arasında bulunmaktadır (1:47, bir sonraki adıma kadar olan gecikme noktalarını ifade eder). Bir sonraki adım, verilerimize ve asıl amaç(lar)ımıza en uygun olan sinir ağı modelini seçmektir, çünkü bu Kocaeli'de kısa vadeli bir tahmin türüdür. Tüm bu koşullara göre DOOSA seçilmiş, DODGOSA ve KTB metodolojileri ile karşılaştırılmıştır. DOOSA modeli için önerilen diyagram, tüm simülasyon adımlarını içere Şekil 4.3'te gösterilmiştir. Aynı zamanda, YSA ağı eğitim süreci, eğitimin sonunu belirleyen birkaç iterasyonun epok noktasında durdurulur ve bununla birlikte doğrulama süreci devam eder. Sonunda, test süreci, DOOSA modelinin performansını değerlendirmek için kullanılır. Tüm modellere ilişkin hiper parametreler ve değerleri aşağıdaki Tablo 4.3 ve Tablo 4.4'te gösterilmektedir.

Tablo 4.3. YSA modellerinde optimize edilmiş hiperparametreler.

Ağ Türleri	NAR / NARX Sinir Ağı
Eğitim Fonksiyonları	BR, LM
Performans Fonksiyonları	MSE/ R^2
Giriş ve Geri Bildirim Gecikmeleri	$i \in [1,48]$
Gizli Katmandaki Nöron Sayısı	$i \in [1,15]$
Kullanılan Aktivasyon Fonksiyonu	Tangent-Sigmoid
İterasyon Sayısı	1000

Tablo 4.4. KTB modelinde optimize edilmiş hiperparametreler.

Giriş Boyutu	‘Auto’
Gizli Katman Nöron Sayısı	14
Performans Fonksiyonları	MSE/ R ²
Durum Aktivasyon Fonksiyonu	‘Tanh’
Çıkış Modu	‘dizi’
Kapı Aktivasyon Fonksiyonu	Sigmoid
İterasyon Sayısı	1000
Sıfırlama Kapı Modu	‘çarpım-sonrası’

4.4. Performans Değerlendirmesi ve Tahmin Yöntemlerinin Karşılaştırılması

Farklı rüzgâr hızı tahmin modellerinin değerlendirilmesi, grafiksel çizimlerden daha etkili bir karşılaştırmayı mümkün kılan çeşitli istatistiksel ölçümleri içerir (Nie et al., 2021). Bu çalışma, MSE ve R² metrikleri kullanarak öngörü performansını nicelendirir (Arzu et al., 2020b), bunlar denklem ile tanımlanır:

$$R^2 = 1 - \frac{\sum(\hat{y}_t - y_t)^2}{\sum y_t^2} \quad (4.1)$$

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (4.2)$$

Burada, değerlendirme kriterlerinde y_t , $(y_t)^\wedge$ ve n sırasıyla hedef değeri (gerçek gözlem), model çıktısı ve gözlem sayısını temsil eder. Düşük MSE, tahmin edilen ve gerçek rüzgâr hızı arasındaki farkın az olduğunu ve doğru performansı gösterdiğini belirtir. MSE değeri yeterince küçükse, tahmin modelleri en iyi rüzgâr hızı tahminleri için uygun kabul edilir. Ayrıca, 1'e daha yakın bir korelasyon katsayısı değeri arzu edilen bir durumdur.

4.5. Hiperparametre Ayarlama

Tahmin modelinin performansı, büyük ölçüde eğitim sürecini optimize etmek için kullanılan hiperparametrelerin seçimine bağlıdır. Bu çalışmada, tahmin modellerinin ince ayarını yapmak amacıyla gizli katmanlardaki nöron sayısı, kullanılan aktivasyon fonksiyonu ve giriş ile geri bildirim gecikmeleri gibi hiperparametreler optimize

edilmiştir (Kisvari ve diğerleri, 2021). Hiperparametrelerin aralıkları Tablo 5.1'de sunulmaktadır. Hiperparametre optimizasyonu için GS (Grid Search) yöntemi tercih edilmiştir (Xie ve diğerleri, 2021). Bu yöntemde, olası hiperparametre değerlerinin bir ızgarası oluşturulmakta ve her olası kombinasyon için model ayarlanmaktadır. Her kombinasyonun model performansı kaydedilmekte ve en iyi performansı sağlayan kombinasyon seçilmektedir (Quan ve Shang, 2020).





5. METODOLOJİ

Bu bölüm, akıllı şebekelerde kısa vadeli rüzgâr hızı tahmini için kullanılan yöntemleri, özellikle Doğrusal Olmayan Otoregresif (DOOSA), Dış Girdili Doğrusal Olmayan Otoregresif (DODGOSA) ve Kapılı Tekrarlayan Birim (KTB) modellerini detaylandırmaktadır. Çalışma, Kocaeli, Türkiye'de gerçekleştirilen bir vaka çalışmasına odaklanmakta olup, rüzgâr hızı verileri toplanmış ve analiz edilmiştir. Metodoloji, model geliştirme, uygulama ve sonuçlar ile tartışma bölümlerini içermektedir.

5.1. Model Geliştirme

Bu bölüm, kısa vadeli rüzgâr hızı tahmini için kullanılan makine öğrenimi modellerinin geliştirilmesini detaylandırmaktadır. Kullanılan modeller, Doğrusal Olmayan Otoregresif (NAR), Dış Girdili Doğrusal Olmayan Otoregresif (NARX) ve Kapılı Tekrarlayan Birim (GRU) modelleridir.

5.1.1. Doğrusal Olmayan Otoregresif sinir ağı (DOOSA)

Bu makalede önerilen tahmin yaklaşımı DOOSA'dır. Gelecekteki değerleri (burada tahmin edilen rüzgâr hızını) tahmin etmek için geçmiş zaman serisi değerlerini kullanır. DOOSA, giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanını içeren ileri beslemeli yöntemlerden biridir. DOOSA, ANN modeli için simülasyon, izleme ve kontrol yapabilen dinamik ve tekrarlayan bir modellemedir. DOOSA modeli, tek değişkenli zaman serisi tahminleri için kullanılabilir (Baca Ruiz et al., 2019).

DOOSA denklem modeli aşağıdaki denklem'de verilmiştir:

$$y_t = h(y_{t-1}, y_{t-2}, y_{t-3}, \dots, y_{t-d}) + \varepsilon_t \quad (5.1)$$

İleri beslemeli sinir ağı (DOOSA) modeli için $h(\cdot)$ fonksiyonu önceden bilinmez ve sinir ağı ağırlıklarını ve nöron önyargısını optimize ederek bu fonksiyonu yaklaşılaştırmayı amaçlar. DOOSA modeli için detaylı denklem şu şekildedir (Arzu et al., 2020a):

$$y_t = \alpha_0 + \sum_{j=1}^k \alpha_j \phi(\sum_{i=1}^a Y_{t-i} \beta_{ij} + \beta_{0j}) + \varepsilon_t \quad (5.2)$$

Burada a , giriş birimlerinin sayısını; k , aktivasyon fonksiyonu ϕ ile gizli katman sayısını; β_{ij} , i 'nin giriş birimi ile j 'nin gizli birimi arasındaki bağlantı ağırlığına karşılık gelen parametreyi; α_j , gizli birim j ile çıkış birimi arasındaki bağlantı ağırlığıdır. β_{0j} ve α_0 ise sırasıyla uzak birim j 'ye ve çıkış birimine karşılık gelen sabitlerdir (Taherdangkoo et al., 2020).

DOOSA'nın önerilen mimarisi, hedef çıktıyı elde etmek için rüzgâr hızını tahmin etme adımlarını açıklayan Şekil 3'te gösterilmiştir. Makalenin DOOSA modellerinin genel yapısı Şekil 4.3. En iyi parametreler için DOOSA (a) ve DODGOSA (b) ağ mimari. En iyi parametreler için DOOSA (a) ve DODGOSA (b) ağ mimari., Şekil 5.1'ten Şekil 5.2'ye gösterilmiştir. Yapay sinir ağı modelinin diğer modellere göre belirli avantajları vardır; bu büyük alanda gerçek zamanlı rüzgâr hızı tahmini için çok kolaydır ve bir kez eğitilmesi gereken kadar hızlı işleme sahiptir. Çıkış, tahmin edilen rüzgâr hızıdır ve üçüncüsü çok uygun bir şekilde çalışır (Tseng et al., 2007a) (Hochreiter & Schmidhuber, 1997).

Bu çalışmada, DOOSA'nın gizli katmandaki nöron sayısı, gecikmeler ve eğitim algoritmaları gibi hiperparametrelerin değiştirilmesi, rüzgâr hızı tahmini performansını iyileştirmeye odaklanan bu makamenin elde etmeyi amaçladığı sonuca yol açacaktır.

5.1.2. Doğrusal olmayan dışsal girdili otoregresif sinir ağı (DODGOSA)

Doğrusal Olmayan Dışsal Girdili Otoregresif Sinir Ağı (DODGOSA), genellikle zaman serisi tahminleri için kullanılan bir yapay sinir ağı türüdür. NARX modeli, otoregresif modelin bir uzantısıdır ve modelde dışsal değişkenleri içerir. NARX modeli, giriş ve çıkış değişkenleri arasındaki karmaşık olmayan ilişkileri yakalamak için tasarlanmıştır, bu da onu akıllı şebeke uygulamalarında kısa vadeli rüzgar hızı tahmininde etkili bir araç yapar (Cadenas et al., 2016)(A.Adeoti et al., 2020).

DODGOSA sinir ağı modelinin dinamik davranışı, aşağıdaki denklem tarafından tanımlanır:

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-ny), u(t-1), u(t-2), \dots, u(t-nu)) + e(t) \quad (5.3)$$

Burada, $y(t)$ hedef çıkışı temsil eder ve

$y(t - 1), y(t - 2), \dots, y(t - ny), u(t - 1), u(t - 2), \dots, u(t - nu)$ Zaman t 'sindeki hedef çıkış ve harici girişin geçmiş değerleridir. t , and $e(t)$ ise genellikle Gaussian ve beyaz gürültü olarak varsayılan bir gürültü terimidir. Nonlinear mapping fonksiyonu $f(.)$ genellikle bilinmeyen bir fonksiyondur ve yaklaşık olarak belirlenebilir.

Bu çalışma kapsamında, bahsedildiği gibi üç harici değişken model içine dahil edilecektir (Cadenas et al., 2016).

5.1.3. Kapılı Tekrarlayan Birim (KTB)

KTB modeli, geleneksel RNN'lerden daha verimli olacak şekilde tasarlanmış bir tekrarlayan sinir ağı (TSA) türüdür. KTB modeli ile geleneksel TSA'lar arasındaki temel fark, KTB modelinin ağ üzerinde bilgi akışını kontrol etmek için kapı mekanizmaları kullanmasıdır. Bu, geleneksel TSA'larda görülebilen kaybolan gradyan sorununu önlemeye yardımcı olur; burada gradyan çok küçük hale gelebilir ve ağı etkili bir şekilde eğitmeyi zorlaştırabilir (Emeksiz & Fındık, 2022).

Rüzgâr hızı tahmininde KTB modelini kullanabilmek için, rüzgâr hızına ait tarihsel veriler ağa beslenir ve ağ, bu verilere dayanarak gelecekteki rüzgâr hızını tahmin etmek üzere eğitilir. Giriş verileri, rüzgâr yönü, sıcaklık ve nem gibi çeşitli değişkenleri içerebilir, ayrıca tarihsel rüzgâr hızı verilerini içerir.

Ağ eğitildikten sonra, belirli bir dönem için rüzgâr hızı tahminleri oluşturmak için kullanılabilir. KTB modeli tarafından üretilen tahminlerin doğruluğu, girdi verisinin kalitesi, modelin karmaşıklığı ve tahmin ufkunun uzunluğu gibi çeşitli faktörlere bağlıdır. Zt güncelleme kapısı aşağıdaki denklem hesaplanır:

$$Z_t = \delta(W^{(z)} x_t + U^{(z)} h_{t-1}) \quad (5.4)$$

Burada x_t örnek birimine eklenirse, kendi ağırlığı $W^{(z)}$ ile çarpılır. Güncelleme kapısı, modelin önceki zaman adımlarından ne kadar geçmiş bilgiyi ileteceğini belirlemesine yardımcı olur (Tseng et al., 2007a) [66].

KTB'nın ilgili bilgileri yakalama ve saklama yeteneği, onu zaman serisi tahmininde, özellikle akıllı şebeke uygulamalarındaki rüzgâr hızı tahmininde değerli bir araç haline getirir. Performansı, giriş verisi kalitesi, model karmaşıklığı ve tahmin yatay uzunluğu gibi faktörlere bağlıdır (Kaja et al., 2021).

5.2. Uygulama


Bu bölümde, Kandıra Rüzgâr Çiftliği, Kocaeli'de rüzgâr hızı tahmini için üç farklı modelin uygulanması detaylandırılmaktadır: Doğrusal Olmayan Otoregresif (DOOSA), Dışsal Girdili Doğrusal Olmayan Otoregresif (DODGOSA) ve Kapılı Tekrarlayan Birim (KTB). Sonuçlar karşılaştırılarak en iyi performans gösteren model belirlenmiştir.

5.2.1. Kandıra'da Rüzgar Hızı Tahmini için DOOSA ve DODGOSA'nın Uygulanması

DOOSA modelinin uygulanması ve mimarisi Şekil 4.3-a'da gösterilmiştir. Modelin uygulanmasından sonra, tahmin modelinin oluşturulması amacıyla eğitim süreci tamamlanmış, ardından doğrulama ve test aşamaları gerçekleştirilmiş ve DOOSA modelinin performansı değerlendirilmiştir. Modelin performansı R^2 ve MSE ölçütleriyle değerlendirilmiş olup, çıktılar ile hedefler arasındaki ilişkiyi ve tüm modeller arasındaki doğruluğunu ortaya koymaktadır. MSE değeri ne kadar düşük ve R^2 değeri ne kadar yüksekse, modelin performansı o kadar iyi olarak kabul edilir.


Şekil 4.3. En iyi parametreler için DOOSA (a) ve DODGOSA (b) ağ mimari En iyi parametreler için DOOSA (a) ve DODGOSA (b) ağ mimari. Şekil 5.1'ten Şekil 5.5'ye modellerin uygulanmasının sonuçlarını gösterir. Bu figürler, gizli katmanın farklı nöronları (1 ila 15), farklı gecikmeler (1 ila 48) ve 13 eğitim fonksiyonu ile simülasyonun örnekleri olarak kullanılan sonuçları gösterir. Makalede verilen figürler, en iyi sonuçlara sahip olan 14 nöron ve 1:47 gecikmeli figürlerdir. Örneğin, Şekil 5.1-a, 14 gizli katman nöronu, Bayesian Regularization (BR) eğitim algoritması ve 1:47 gecikme ile DOOSA mimarisini sunmaktadır.

Şekil 5.4, DOOSA a ve DODGOSA b için en iyi eğitim performansını (MSE değeri) açıklar. DOOSA için en iyi değer, 1000. yineleme noktasında 0.16511'dir ve DODGOSA için en iyi değer, 627. yineleme noktasında 0.1473'tür.




Şekil 5.1. DOOSA (a) ve DODGOSA (b) için eğitim performansı (14 gizli katman nöronu).

Şekil 5.2, (a ve b), DOOSA ve DODGOSA modellerinin çıkışlarının zaman serisi tepkisini gösterir. Bu, BR eğitim fonksiyonu, 1:47 gecikme ve gizli katman nöronlarının 14 olduğu durumda tüm eğitim, doğrulama ve test hedefleri ile çıkışların tepkisini açıklar. Şekiller, hedefin çoğu zaman noktasında çıkış rüzgâr hızını örttüğünü açıklar. DOOSA modeli için zaman 7000'deki yanıt, DODGOSA'a kıyasla daha hızlı ve daha doğru bir performans sağladığı için daha iyi olarak değerlendirilebilir. Ayrıca, yukarıda belirtildiği gibi, bu, belirli özelliklere ve hiperparametrelere sahip DOOSA sinir ağı kullanıldığında rüzgâr hızı tahmini için yüksek performansı yansıtmaktadır.



Şekil 5.2. DOOSA (a) ve DODGOSA (b) için Zaman Serisi Tepkisi (Gizli Katman Nöronları: 14).




Şekil 5.3. DOOSA (a) ve DODGOSA (b) için Belirleme Katsayısı Grafiği (Gizli Katman Nöronları: 14).

Şekil 5.3'dan, 0.94005 R değeri, bağımlı değişkenin varyansının %94.005'inin (rüzgâr hızı çıkışı) bağımsız değişkenin (rüzgâr hızı hedef değeri) varyansı tarafından açıklandığını gösterir. Bu, modelin verilere iyi uyduğunu ve bağımsız değişkenin bağımlı değişkenle güçlü bir ilişkisi olduğunu gösterir. Dolayısıyla, R^2 katsayısı değerleri DOOSA için 0.8837 ve DODGOSA için 0.8914 olarak bulunmuştur.


BR eğitim fonksiyonu kullanıldığında hem DOOSA hem de DODGOSA modellerinde gizli katmandaki nöron sayısı 14 olduğunda 1'e yakın bir R^2 değeri (0.94) elde edilmiştir. Bu durum, en iyi performansı temsil etmekte olup, DOOSA modelinin DODGOSA ile benzer sonuçlar verdiğini ancak CPU çalışma süresi açısından DOOSA'nın daha hızlı olduğunu göstermektedir.

Aynı optimal hiperparametreleri kullanarak, Şekil 5.4-a DOOSA modelinin eğitim hatası histogramını açıklarken, Şekil 5.4-b DODGOSA modelinin hata histogramını temsil etmektedir.



Şekil 5.4. DOOSA için Eğitim Hata Histogramı (14 Gizli Katman Nöronu) (a) ve DODGOSA için (b).

Tablo 5.1’de, geri besleme gecikmeleri=1:47 ve gizli katman nöronları=14 için DOOSA ve DODGOSA performans ölçütlerini açıklar. Gizli katman nöron sayısını, yani 14’ü, farklı eğitim algoritmaları LM ve BR ile birlikte sunar. Ayrıca, tablo her bir satır için farklı hiperparametreleri (sütunlarda) gösterir. Sütunlar, eğitim işlevini ve diğer performans faktörlerini içerir: genel performans (MSE) ve belirleme katsayısı (R^2). Şekil 5.5’te, farklı eğitim algoritmaları için DOOSA ve DODGOSA modelleri için ortalama ve en iyi R^2 skorlarını örnekler.




Şekil 5.5. DOOSA ve DODGOSA ağırları için farklı öğrenme algoritmalarının ortalama ve en iyi R^2 skorları.

Sonuç olarak hem DOOSA hem de DODGOSA sinir ağı modellerinde, 1:47 geri bildirim gecikmesi ve 14 gizli katman nöronuna sahip yapılar kullanıldığında, BR eğitim fonksiyonunun en iyi performansı ve model uyumunu sağladığı

gözlemlenmiştir. Bununla birlikte, LM algoritması da hızlı bir şekilde yürütülmüştür. Bu çalışmada, hedefe ulaşmak amacıyla 13 algoritma arasından yalnızca BR ve LM eğitim algoritmaları tercih edilmiştir.


5.2.2. Kandıra'da Rüzgâr Hızı Tahmini için KTB'nın Uygulanması

Bu bölümde, Kocaeli, Türkiye'de kısa vadeli rüzgâr hızı tahmini için Kapılı Tekrarlayan Birimi (KTB) modelinin uygulanması detaylandırılmaktadır. Sonuçlar, Doğrusal Olmayan Otoregresif (DOOSA) ve Dışsal Girdili Doğrusal Olmayan Otoregresif (DODGOSA) modellerinden elde edilen sonuçlarla karşılaştırılmaktadır.



Şekil 5.6. KTB modeli.


KTB modeline yapılan girişler için, rüzgâr hızı, rüzgâr yönü ve nem en etkili değişkenlerdi. Bu faktörler, rüzgâr hızı tahmininin performansını önemli ölçüde etkiledi. Şekil 5.7, bu üç girişin veri kümesini göstermektedir.



Şekil 5.7. KTB modeli için 3 girişli veri kümesi.

KTB modelinin zaman serisi yanıtı, modelin tahminlerinin gerçek gözlemlerle zaman içindeki karşılaştırmasını detaylı bir şekilde sunar; bu durum Şekil 5.8'de görülmektedir. Bu yanıtı inceleyerek, modelin gelecekteki değerleri ne kadar doğru


tahmin ettiğini değerlendirebilir ve tahmin edilen ile gerçek değerler arasındaki farkları belirlenebilir. Bu karşılaştırma, KTB modelinin verilerdeki temel eğilimleri ve desenleri ne derecede etkili bir şekilde yakaladığı belirlenir. Ayrıca, modelin tahmin performansı ve güvenilirliği kapsamlı bir şekilde değerlendirilir.



Şekil 5.8. KTB modeli için Zaman Serisi Tepkisi.

KTB modelinin eğitim süreci, kayıp fonksiyonunu en aza indirmek için model parametrelerinin birden fazla yineleme yoluyla ayarlanmasını içerir. Yinelemeler ile RMSE/kayıp arasındaki ilişki, tipik olarak, modelin hedef değerleri tahmin etmede

artan performansını yansıtan bir azalma eğilimi ile karakterize edilir. Şekil 5.9 KTB eğitiminin ilerlemesini açıklamaktadır.



Şekil 5.9. KTB eğitim ilerlemesi.

❖ KTB Model Performansı:

- CPU çalıştırma süresi: 0s 4ms/step
- MSE: 0.00722
- RMSE: 0.08502
- R^2 : 0.756440

5.3. Bulgular ve Tartışma

DOOSA, DODGOSA ve KTB öngörü modellerinin optimize edilmiş hiperparametreleri Tablo 4.3 ve Tablo 4.4'te açıklanmıştır. En yüksek ve optimum R^2 ile en düşük MSE değerlerini elde etmek için farklı sayıda gizli katman nöronu ve geri bildirim gecikmeleri ile birçok model oluşturulmaktadır. LM ve BR algoritmaları, modeli eğitmek için bu modeller uygulanırken seçilen en doğru tasarımlar, gelecekteki rüzgâr hızı değerlerini tahmin etme konusundaki doğruluklarına bağlı olarak seçilmiştir. Yüksek performanslı ve daha doğru bir DOOSA modeli, sonuçları DODGOSA ve KTB ile karşılaştırdıktan sonra bu hedefe ulaşmayı amaçlamaktadır. Performans değerlendirme ölçütleri, her model için farklı parametrelerle

değerlendirilir. Şekil 4.3. En iyi parametreler için DOOSA (a) ve DODGOSA (b) ağ mimari En iyi parametreler için DOOSA (a) ve DODGOSA (b) ağ mimari, Şekil 5.1'ten Şekil 5.5'ye kadar olan grafikler, çeşitli DOOSA ve DODGOSA rüzgâr hızı tahmin modellerini temsil etmektedir. ,Tablo 4.3'te DOOSA ve DODGOSA modellerinin performansını etkileyen optimum sayıdaki parametreleri gösterir. Tablo 5.1, gizli katman nöron sayısının 14 ve gecikmelerin 1:47 olduğu durumda iki farklı eğitim fonksiyonu kullanıldığında elde edilen sonuçları gösterir.

LM ve BR eğitim fonksiyonları, bahsedilen 13 eğitim algoritması arasında karşılaştırılmak üzere kullanılmıştır. Bu hiperparametreler DOOSA modeli için uygulandığında, altı model elde edilmiş ve altı modelle DODGOSA ile karşılaştırılmıştır. Tablo 5.1 ve Şekil 5.1'ten Şekil 5.5'ye kadar elde edilen sonuçlara göre performans ve korelasyon katsayısı değerleri değerlendirilmiştir. Tablo 5.1'den açıkça görüleceği üzere, en iyi model performansı, gizli katman nöron sayısı 14 ve geri bildirim gecikmeleri sayısı 1:47 olarak tasarlanmış min MSE ve max R^2 değerleri ile elde edilmiştir.

Tablo 5.1. Geri Besleme Gecikmesi = 1:47 ve Gizli Katman Nöron Sayısı = 14 için DOOSA ve DODGOSA Performans Sonuçları.

	DOOSA		DODGOSA	
Eğitim Fonksiyonu	LM	BR	LM	BR
Geri Besleme Gecikmeleri	1:47	1:47	1:47	1:47
MSE	0.2204	0.2192	0.2228	0.2253
R2	0.869	0.886	0.874	0.904
CPU time/sec	Avg: 29	Max:311	Avg:253	Max:3129

Tablo 5.1'de gizli katman nöron sayısının 14 ve gecikmenin 1:47 olarak belirlendiği durumlarda, performans sonuçları eğitim algoritmasına göre değerlendirilmiştir. BR algoritması kullanıldığında, MSE ve R^2 değerleri şu şekilde elde edilmiştir: DOOSA için sırasıyla 0.2192 ve 0.886, DODGOSA için ise 0.2253 ve 0.904. LM algoritması kullanıldığında ise sonuçlar şu şekildedir: DOOSA için sırasıyla 0.2204 ve 0.869, DODGOSA için ise 0.2280 ve 0.874. Elde edilen bulgulara göre, BR algoritması LM'yi geride bırakmış olup, MSE değeri açısından DOOSA için en düşük değer elde edilmiştir. BR ve LM algoritmalarının sonuçları, DOOSA modelinde hiperparametre

olarak 14 gizli katman nöronu ve 1:47 gecikme ile uygulanan sürecin ardından, DODGOSA modelinde de benzer şekilde BR ve LM eğitim algoritmaları ile aynı sürecin uygulandığı göz önüne alındığında, her iki modelin performansı karşılaştırılmıştır. CPU süreleri incelendiğinde, DOOSA modelinin DODGOSA'ya kıyasla daha hızlı olduğu gözlemlenmiştir. Eğitim algoritmalarının çoğu ortalama 2 ila 9 saniye sürerken, BR algoritması yaklaşık 140 saniye sürmüştür ve DODGOSA modelleri BR algoritması için DOOSA'dan neredeyse dokuz kat daha fazla süre almıştır.

KTB modelinin sonuçlarını tartışmak için; Şekil 5.6'dan Şekil 5.9'ye kadar olan figürler, KTB kullanılarak yapılan çeşitli rüzgâr hızı tahmin modellerini göstermektedir. Bu figürler, KTB modelinin rüzgâr hızını etkili bir şekilde tahmin etmek için kullanılan farklı yaklaşımları ve konfigürasyonları sergilemektedir. Tablo 4.4'de, KTB modelinin performansını etkileyen optimum parametre sayısını sunmaktadır. Bu tabloda, farklı parametre ayarlarının modelin doğruluğunu ve verimliliğini nasıl etkilediğini vurgulamaktadır. Tablo 5.2, KTB modelinin performans sonuçlarını detaylandırmaktadır; bu sonuçlar arasında CPU yürütme süresi, Ortalama Kare Hatası (MSE) ve Belirlilik Katsayısı (R^2) yer almaktadır. Bu metrikler, modelin hesaplama verimliliği ve tahmin doğruluğu hakkında bilgiler sağlamaktadır.

Tablo 5.2. KTB Performans Sonuçları.

	KTB modeli
MSE	0.00722
R^2	0.756440
CPU time/ Sec	0s 4ms

0s 4ms/adım olan CPU yürütme süresi, GRU modelinin eğitim ve tahmin aşamalarında verimli bir şekilde çalıştığını göstermektedir. Bu hızlı işlem süresi, gerçek zamanlı tahmin uygulamaları için faydalıdır ve en güncel rüzgâr hızı verilerine dayanarak zamanında güncellemeler ve kararlar alınmasını sağlar. MSE değeri 0.00722, tahmin edilen ve gerçek rüzgâr hızları arasındaki ortalama kare farkı temsil etmektedir. Bu nispeten düşük MSE, GRU modelinin düşük hata ile doğru tahminler sağladığını önermektedir. Daha düşük bir MSE, modelin rüzgâr hızı verilerindeki temel desenleri etkin bir şekilde yakaladığını ve güvenilir tahminler yaptığını gösterir. R^2 değeri 0.756440, rüzgâr hızındaki değişkenliğin yaklaşık %75,6'sının GRU modeli tarafından

açıklanabildiğini göstermektedir. Bu değer, tahmin edilen ve gerçek değerler arasındaki güçlü bir uyumu gösterir ve modelin verinin değişkenliğinin önemli bir kısmını yakaladığını öne sürer. 0.75'in üzerindeki bir R^2 değeri genellikle iyi bir sonuç olarak kabul edilir ve modelin Kandıra Rüzgâr Çiftliği'ndeki rüzgâr hızı desenlerini sağlam bir şekilde temsil ettiğini göstermektedir.

Bu çalışmada, rüzgâr hızı tahmini için çeşitli makine öğrenme modellerinin performansını değerlendirdik. Bu modeller arasında Doğrusal Olmayan Otoregresif (DOOSA) modeli, Doğrusal Olmayan Otoregresif Eksojen Girdilerle (DODGOSA) modeli ve Kapılı Tekrarlayıcı Birim (KTB) modeli bulunmaktadır. Aşağıda, her modelin temel performans faktörlerine dayanan performans sonuçlarının bir özeti verilmiştir:

Tablo 5.3. Üç makine öğrenme yönteminin Performans Sonuçları.

Performance	DOOSA	DODGOSA	KTB
MSE	0.2192	0.2253	0.00722
R^2	0.886	0.904	0.756

KTB modeli, en düşük MSE'yi elde ederek tahminlerinde en yüksek doğruluğu sağladı. Bu, tahmin edilen ve gerçek rüzgâr hızları arasındaki ortalama kare hatayı minimize etme yeteneğini yansıtır. Buna karşılık, DOOSA ve DODGOSA modelleri daha yüksek MSE değerleri gösterdi ve bu da daha büyük tahmin hatalarına işaret eder.

DOOSA ve DODGOSA modelleri daha yüksek R^2 değerleri gösterdi, bu da rüzgâr hızı verilerindeki değişkenliğin daha büyük bir kısmını açıkladıkları anlamına gelir. Bu, bu modellerin verilerdeki genel desenleri ve trendleri daha iyi yakaladığını gösterir. Ancak, KTB modeli daha düşük bir R^2 değerine sahip olmasına rağmen, belirgin şekilde daha düşük MSE ile üstün bir doğruluk sergilemiştir.

Bu çalışma kapsamında, rüzgâr hızı tahmininde kullanılan yapay zekâ sinir ağı modellerinden biri olan DOOSA modelinin, LM algoritması ve 14 nöron ile iki performans ölçüsü olan MSE ve R^2 açısından başarılı bir performans sergilediği gözlemlenmiştir. DOOSA modelinin çeşitli değerlendirme ölçütleri ile test edilmesi, doğru tahmin sonuçlarının elde edilmesini sağlamıştır. Ancak, diğer araştırmacıların uyguladığı yöntemlerin aksine, DOOSA modeli ile karşılaştırma amacıyla farklı modeller kullanılmamış ve hangi modelin diğerlerini geride bıraktığı belirlenmemiştir.

Eđitim parametrelerinin (öđrenme algoritmasının eđitim fonksiyonları, gizli katman nöron sayısı vb.) deđiřtirilmesi ve çeřitli metriklerin kullanılması, farklı modellerin elde edilmesine ve karřılařtırılmasına olanak tanıyabilir, bu da sinir ađı modellerinin karmařıklıđının önlenmesine yardımcı olabilir. Tseng ve arkadaşlarının (2007b) Tayvan'da tayfun dalga tahmininde BPN modelinin dođruluđunu deđerlendirmek amacıyla kullandıkları performans endeksi, bu alıřmanın temelini oluřturmuřtur. Benzer řekilde, bir modeli (DOOSA) seilerek farklı performans endeksleri ile alt modellere ayrılmıřtır. Arařtırmanın sonularına göre, herhangi bir tahmin modelinin performansını etkileyen çeřitli kořul ve faktörler belirlenmiřtir. Türkiye'deki belirli bir konum ve hiperparametreler dikkate alındıđında, DOOSA modelinin uygulanmasının en uygun model olabileceđi sonucuna varılmıřtır.

6. SONUÇ VE ÖNERİLER

6.1. Sonuç

DOOSA sinir ağı, belirli bir konumda rüzgâr hızını tahmin etmek için geliştirilmiştir. Bu nedenle, Kandıra, Türkiye'nin Kocaeli ilindeki rüzgâr çiftliklerinden biridir ve veri seti rüzgâr hızını tahmin etmek için alınan yerdir. Türkiye'deki bu bölge, belirli bir zamandaki rüzgâr hızını tahmin ederek rüzgâr enerjisinin bir türü olarak enerjiyi artırmak amacıyla bir projeye sahiptir. Ayrıca, bu DOOSA modelinin geliştirilmesi, Kandıra'nın rüzgâr çiftliğinden dört meteorolojik kısıtlama kullanılarak gizli katman nöronları, eğitim fonksiyonları ve gecikmelerin bazılarını belirleyerek gerçekleştirilmiştir. MATLAB için DOOSA ağı eğitimi için iki eğitim fonksiyonu seçilmiştir: Bayesian Regularization (BR) ve LM fonksiyonları. Bu DOOSA modelinin geliştirilmesini iyileştirmek için performansı, farklı eğitim fonksiyonlarını, gizli katman nöronlarını ve geri besleme gecikmelerini karşılaştırarak incelenmiştir. Performans için iki değerlendirme faktörü incelenmiştir, ortalama karesel hata (MSE) değerini en aza indirme (0,2192) ve belirleme katsayısı değerini (R^2) maksimize etme (0,886) değeri, DOOSA sinir ağı modeli için hızlı CPU çalışma süresi açısından. Farklı DOOSA modelleri tasarlamak için MATLAB2022b'nin araç kutusundan doğru eğitim fonksiyonunu seçmek, bu çalışmada kullanılan 13 YSA eğitim fonksiyonunun tümü arasında en iyi performansı veren BR'yi doğru eğitim fonksiyonu olarak seçmek en kritik konudur. Bu çalışmada, doğru ağı eğitim fonksiyonunu seçmek, en iyi performansı verir ve LM'yi geride bırakır. Ancak, LM çok daha hızlıdır ve bu iki fonksiyon zaten bu uygulamada kullanılan tüm 13 YSA eğitim fonksiyonu arasında en iyi performansa sahiptir. Buna ek olarak, nöron sayısı sonuçları etkiledi. Örneğin, bu tasarım için optimal sayı olan 14, aynı eğitim fonksiyonunu kullanırken umut verici sonuçlar gösterir ve gecikme sayıları karşılaştırılmalıdır. Gecikmeler ne kadar yüksekse, sonuç o kadar iyi olur. Örneğin, 1:47'de geri besleme gecikmeleri daha iyi sonuç verdi. Sonuçlar, belirli koşullar altında belirli bir DOOSA modelinin, aynı hiperparametreleri kullanarak diğer modellere (bizim durumumuzda DODGOSA ve KTB) üstün olabileceğini gösterdi. DOOSA modeli, bazı diğer sonuçlar için DODGOSA modelleri kadar veya CPU çalışma süresi açısından daha doğru olduğunu

kanıtlamıştır, çünkü belirli dış değişkenler, özellikle nispeten nem gibi, sonuçları önemli ölçüde etkilememiştir, ancak üç değişken eklenmiştir. KTB sonuçları, DOOSA ve DODGOSA modelleri ile karşılaştırıldığında, KTB modelinin 0.00722 ile en düşük Ortalama Kare Hata (MSE) değerine sahip olduğu tespit edilmiştir. Bu bulgu, KTB modelinin tahmin hatasını minimize etmede üstün bir doğruluk sergilediğini göstermektedir. Ancak, 0.904'lük R^2 değeri ile DODGOSA modeli ve 0.886'lık R^2 değeri ile DOOSA modeli, rüzgâr hızı verilerindeki değişkenliği daha iyi yakalama yeteneği göstermektedir. Bu bağlamda, KTB modelinin hata minimizasyonunda son derece etkili olduğu; ancak, DOOSA ve DODGOSA modellerinin veri setindeki varyansı açıklamada daha yetkin olduğu belirlenmiştir. Bu durum, DOOSA ve DODGOSA modellerinin akıllı şebekelerdeki çeşitli tahmin uygulamaları için güçlü adaylar olduğunu ortaya koymaktadır. Araştırmanın Türkiye'de belirli bir yerde seçilen modeli (DOOSA) ve hiperparametreleri, bunun uygulanması için en iyi model olabilir. Gelecek çalışmalarda, mevcut veri kümesi ve aynı koşullar altında farklı modellerin (veya modellerin) veya zaman serisi modellerinin kullanılması ve bu sonuçların DOOSA sinir ağları ile karşılaştırılması önerilmektedir. Ayrıca, veri kümesine rüzgâr enerjisi verilerinin dahil edilmesi durumunda, Kandıra konumu için rüzgâr enerjisinin tahmin edilebilirliği değerlendirilebilir.

6.2. Sınırlamalar ve Gelecek Araştırma Yönelimleri

"Kocaeli-Türkiye'de Akıllı Şebeke İçin Temel Terim Rüzgâr Hızı Tahmini": Doğrusal Olmayan Otoresif Eksojen Girdilerle üzerine yapılan çalışma umut verici sonuçlar göstermiş olsa da, hala bazı sınırlamalar ve gelecek araştırma fırsatları bulunmaktadır. Bunlar şunları içermektedir:

6.2.1. Sınırlı veri bulunabilirliği:

Çalışma, yalnızca tek bir bölgeden elde edilen rüzgâr hızı ve meteorolojik verilerini kullanmış olup, bu durum bulguların diğer bölgeler veya farklı iklim koşullarına genelleme yapılabilirliğini sınırlayabilmektedir. Gelecek araştırmalarda, diğer bölgelerden veri toplanması veya daha fazla veri kaynağının dahil edilmesi önerilmektedir; bu yaklaşımlar, modellerin doğruluğunu ve sağlamlığını artırma potansiyeline sahip olacaktır.

6.2.2. Model yorumlanabilirliđi

DODGOSA modeli, karmařık bir sinir ađı yapısına sahip olduđundan, yorumlanabilirliđi sınırlı kalabilir ve rüzgâr hızı deđiřkenliđini yönlendiren temel faktörlere dair anlayıř sađlama yeteneđi kısıtlanabilir. Gelecek arařtırmalarda, daha açıklanabilir modeller geliřtirilerek rüzgâr hızı deđiřkenliđini yönlendiren fiziksel süreçler hakkında daha kapsamlı bir anlayıř elde edilmesi hedeflenebilir.

6.2.3. Model belirsizliđi

Çalıřmada, model belirsizliđi ve tahmin sonuçlarındaki hata veya yanlıřlık potansiyeli açıkça ele alınmamıřtır. Gelecek arařtırmalarda, model belirsizliđini nicelendirmek ve ele almak için yöntemlerin geliřtirilmesine odaklanılabilir; bu durum, rüzgâr hızı tahmini sonuçlarının güvenilirliđini artırma potansiyeline sahip olabilir.

6.2.4. Diđer makine öğrenimi yöntemleri ile karřılařtırma

Çalıřmada, DODGOSA modeli diđer kısa vadeli rüzgâr hızı tahmin yöntemleri ile karřılařtırılmıř olmakla birlikte, model derin öğrenme veya pekiřtirmeli öğrenme gibi diđer makine öğrenimi yöntemleri ile karřılařtırılmamıřtır. Gelecek arařtırmalarda, bu yöntemlerin rüzgâr hızı tahmini üzerindeki etkinlikleri incelenebilir.

6.2.5. Diđer yenilenebilir enerji kaynakları ile entegrasyon

Çalıřmada yalnızca rüzgâr hızı tahmini üzerine odaklanılmıřtır. Gelecek arařtırmalarda, rüzgâr hızı tahmininin güneř enerjisi veya hidroelektrik gibi diđer yenilenebilir enerji kaynakları ile entegrasyonu incelenebilir. Bu yaklařım, yenilenebilir enerji üretiminin genel verimliliđini ve güvenilirliđini artırma potansiyeli tařımaktadır.



KAYNAKLAR

- Arabeyyat, O., Shatnawi, N., & Matouq, M. (2018). Nonlinear multivariate rainfall prediction in Jordan using NARX-ANN model with GIS techniques. *Jordan Journal of Civil Engineering*, 12(3), 359–368.
- Arzu, A., Ahmed, M. R., & Khan, M. G. M. (2020a). Wind Speed Forecasting using Regression, Time Series and Neural Network Models: A Case Study of Suva. *22nd Australasian Fluid Mechanics Conference, AFMC 2020, December*, 7–10. <https://doi.org/10.14264/ccee311>
- Arzu, A., Ahmed, M. R., & Khan, M. G. M. (2020b, November 17). Wind Speed Forecasting using Regression, Time Series and Neural Network Models: A Case Study of Suva. *Proceedings of the 22nd Australasian Fluid Mechanics Conference AFMC2020*. <https://doi.org/10.14264/ccee311>
- Baca Ruiz, L. G., Cuéllar, M. P., Calvo-Flores, M. D., & Pegalajar Jiménez, M. D. C. (2019). An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings. *Energies*, 9(9). <https://doi.org/10.3390/en9090684>
- Belu, R., Canadillas, B., Horvath, K., Koraćin, D., Vellore, R., Smith, C., Jiang, J., & Mccord, T. (2012). A Review of Challenges in Assessment and Forecasting of Wind Energy Resources A REVIEW OF CHALLENGES IN ASSESSMENT AND FORECASTING OF WIND ENERGY RESOURCES Pregled izazova u procjeni i prognoziranju energetskeg potencijala vjetra. In *Hrvatski meteorološki časopis A Croatian Meteorological Journal* (Vol. 47). <https://www.researchgate.net/publication/283319536>
- Bhaskar, M., Jain, A., & Srinath, N. V. (2014). *Wind Speed Forecasting : Present Status. November 2010*. <https://doi.org/10.1109/POWERCON.2010.5666623>
- Blanco, H., & Faaij, A. (2018). A review at the role of storage in energy systems with a focus on Power to Gas and long-term storage. In *Renewable and Sustainable Energy Reviews* (Vol. 81, pp. 1049–1086). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2017.07.062>
- Bogdanov, D., Ram, M., Aghahosseini, A., Gulagi, A., Oyewo, A. S., Child, M., Caldera, U., Sadovskaia, K., Farfan, J., De Souza Noel Simas Barbosa, L., Fasihi, M., Khalili, S., Traber, T., & Breyer, C. (2021). Low-cost renewable electricity as the key driver of the global energy transition towards sustainability. *Energy*, 227. <https://doi.org/10.1016/j.energy.2021.120467>
- Cadenas, E., Rivera, W., Campos-Amezcu, R., & Cadenas, R. (2016). Wind speed forecasting using the NARX model, case: La Mata, Oaxaca, México. *Neural Computing and Applications*, 27(8), 2417–2428. <https://doi.org/10.1007/s00521-015-2012-y>

- Caglayan, D. G., Ryberg, D. S., Heinrichs, H., Linßen, J., Stolten, D., & Robinius, M. (2019). The techno-economic potential of offshore wind energy with optimized future turbine designs in Europe. *Applied Energy*, 255. <https://doi.org/10.1016/j.apenergy.2019.113794>
- Chang, W.-Y. (2014). A Literature Review of Wind Forecasting Methods. *Journal of Power and Energy Engineering*, 02(04), 161–168. <https://doi.org/10.4236/jpee.2014.24023>
- Di Piazza, A., Di Piazza, M. C., & Vitale, G. (2016). Solar and wind forecasting by NARX neural networks. *Renewable Energy and Environmental Sustainability*, 1, 39. <https://doi.org/10.1051/rees/2016047>
- Dupré, A., Drobinski, P., Alonzo, B., Badosa, J., Briard, C., & Plougonven, R. (2020a). Sub-hourly forecasting of wind speed and wind energy. *Renewable Energy*, 145, 2373–2379. <https://doi.org/10.1016/j.renene.2019.07.161>
- Dupré, A., Drobinski, P., Alonzo, B., Badosa, J., Briard, C., & Plougonven, R. (2020b). Sub-hourly forecasting of wind speed and wind energy. *Renewable Energy*, 145, 2373–2379. <https://doi.org/10.1016/j.renene.2019.07.161>
- Dzebre, D. E. K., Ampofo, J., & Adaramola, M. S. (2021). An assessment of high-resolution wind speeds downscaled with the Weather Research and Forecasting Model for coastal areas in Ghana. *Heliyon*, 7(8). <https://doi.org/10.1016/j.heliyon.2021.e07768>
- El-Fouly, T. H. M., El-Saadany, E. F., & Salama, M. M. A. (2008). One day ahead prediction of wind speed and direction. *IEEE Transactions on Energy Conversion*, 23(1), 191–201. <https://doi.org/10.1109/TEC.2007.905069>
- Emeksiz, C., & Findık, M. M. (2022). Hybrid Estimation Model (CNN-GRU) Based on Deep Learning for Wind Speed Estimation. *International Journal of Multidisciplinary Studies and Innovative Technologies*, 6(1), 104. <https://doi.org/10.36287/ijmsit.6.1.104>
- Erdin, C., & Ozkaya, G. (2019). Turkey's 2023 energy strategies and investment opportunities for renewable energy sources: Site selection based on ELECTRE. *Sustainability (Switzerland)*, 11(7). <https://doi.org/10.3390/su11072136>
- Eugene Mitnovetski. (2023). Wind vs. Solar Power: Which Renewable Energy is Better? In <https://www.solarflow.com.au>.
- Foley, A. M., Leahy, P. G., Marvuglia, A., & McKeogh, E. J. (2012). Current methods and advances in forecasting of wind power generation. *Renewable Energy*, 37(1), 1–8. <https://doi.org/10.1016/j.renene.2011.05.033>
- Freitas, N. C. A. De, Silva, M. P. S., & Sakamoto, M. S. (2018). *Wind Speed Forecasting: A Review*. March. <https://doi.org/10.9790/9622-0801010409>
- Gielen, D., Boshell, F., Saygin, D., Bazilian, M. D., Wagner, N., & Gorini, R. (2019). The role of renewable energy in the global energy transformation. *Energy Strategy Reviews*, 24, 38–50. <https://doi.org/10.1016/j.esr.2019.01.006>
- Green Energy and Technology. (2006). In *Green Energy and Technology*. <https://doi.org/10.2174/97816080528511060101>

- Guo, Z. H., Wu, J., Lu, H. Y., & Wang, J. Z. (2011). A case study on a hybrid wind speed forecasting method using BP neural network. *Knowledge-Based Systems*, 24(7), 1048–1056. <https://doi.org/10.1016/j.knosys.2011.04.019>
- Hepbasli, A., & Ozgener, O. (2004). A review on the development of wind energy in Turkey. In *Renewable and Sustainable Energy Reviews* (Vol. 8, Issue 3, pp. 257–276). <https://doi.org/10.1016/j.rser.2003.10.006>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Ilkiliç, C., Aydin, H., & Behçet, R. (2011). The current status of wind energy in Turkey and in the world. *Energy Policy*, 39(2), 961–967. <https://doi.org/10.1016/j.enpol.2010.11.021>
- Kaja, S., Shakshuki, E. M., & Yasar, A. (2021). Long short-term memory approach for routing optimization in cloud acknowledgement scheme for node network. *Procedia Computer Science*, 184(2020), 461–468. <https://doi.org/10.1016/j.procs.2021.03.058>
- Kisvari, A., Lin, Z., & Liu, X. (2021). Wind power forecasting – A data-driven method along with gated recurrent neural network. *Renewable Energy*, 163, 1895–1909. <https://doi.org/10.1016/j.renene.2020.10.119>
- KOCAELİ İLİ KANDIRA İLÇESİ 14.7 MW KANDIRA RÜZGÂR ENERJİ SANTRALİ. (n.d.).
- Konstantinou, T., & Hatziaargyriou, N. (2023). Complex terrains and wind power: enhancing forecasting accuracy through CNNs and DeepSHAP analysis. *Frontiers in Energy Research*, 11(January), 1–12. <https://doi.org/10.3389/fenrg.2023.1328899>
- Kosovic, B., Haupt, S. E., Adriaansen, D., Alessandrini, S., Wiener, G., Monache, L. D., Liu, Y., Linden, S., Jensen, T., Cheng, W., Politovich, M., & Prestopnik, P. (2020). A comprehensive wind power forecasting system integrating artificial intelligence and numerical weather prediction. *Energies*, 16(3). <https://doi.org/10.3390/en13061372>
- Kumar, A., Pal, D., Kar, S. K., Mishra, S. K., & Bansal, R. (2022). An overview of wind energy development and policy initiatives in India. In *Clean Technologies and Environmental Policy* (Vol. 24, Issue 5, pp. 1337–1358). Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1007/s10098-021-02248-z>
- Kursun, B. (2023). Exploitable wind power potential in Turkey with technological advancement and resulting environmental-economic aspects. *Energy Exploration and Exploitation*, 41(1), 187–209. <https://doi.org/10.1177/01445987221115814>
- Lange, M., & Focken, U. (2008). New developments in wind energy forecasting. *IEEE Power and Energy Society 2008 General Meeting: Conversion and Delivery of Electrical Energy in the 21st Century*, PES, 1–8. <https://doi.org/10.1109/PES.2008.4596135>

- Maldonado-Correa, J., Solano, J. C., & Rojas-Moncayo, M. (2021a). Wind power forecasting: A systematic literature review. In *Wind Engineering* (Vol. 45, Issue 2, pp. 413–426). SAGE Publications Inc. <https://doi.org/10.1177/0309524X19891672>
- Maldonado-Correa, J., Solano, J. C., & Rojas-Moncayo, M. (2021b). Wind power forecasting: A systematic literature review. *Wind Engineering*, 45(2), 413–426. <https://doi.org/10.1177/0309524X19891672>
- Miranda, M. S., & Dunn, R. W. (2006). One-hour-ahead wind speed prediction using a Bayesian methodology. *2006 IEEE Power Engineering Society General Meeting, PES*. <https://doi.org/10.1109/pes.2006.1709479>
- Moreno, S. R., Mariani, V. C., & Coelho, L. dos S. (2021). Hybrid multi-stage decomposition with parametric model applied to wind speed forecasting in Brazilian Northeast. *Renewable Energy*, 164, 1508–1526. <https://doi.org/10.1016/j.renene.2020.10.126>
- Nazir, M. S., Alturise, F., Alshmrany, S., Nazir, H. M. J., Bilal, M., Abdalla, A. N., Sanjeevikumar, P., & Ali, Z. M. (2020). *Wind Generation Forecasting Methods and Proliferation of Artificial Neural Network: A Review of Five Years Research Trend*.
- Nie, Y., Liang, N., & Wang, J. (2021). Ultra-short-term wind-speed bi-forecasting system via artificial intelligence and a double-forecasting scheme. *Applied Energy*, 301. <https://doi.org/10.1016/j.apenergy.2021.117452>
- Offshore Wind Farms Continue Growth (2021).
- Oyekale, J., Petrollese, M., Tola, V., & Cau, G. (2020). Impacts of renewable energy resources on effectiveness of grid-integrated systems: Succinct review of current challenges and potential solution strategies. In *Energies* (Vol. 13, Issue 18). MDPI AG. <https://doi.org/10.3390/en13184856>
- Özdemir, U., & Taner, S. (2014). Impacts of Meteorological Factors on PM10: Artificial Neural Networks (ANN) and Multiple Linear Regression (MLR) Approaches. *Environmental Forensics*, 15(4), 329–336. <https://doi.org/10.1080/15275922.2014.950774>
- Pfeifer, S., & Schönfeldt, H. J. (2012). The response of saltation to wind speed fluctuations. *Earth Surface Processes and Landforms*, 37(10), 1056–1064. <https://doi.org/10.1002/esp.3227>
- Potter, C. W., & Negnevitsky, M. (2006). Very short-term wind forecasting for Tasmanian power generation. *IEEE Transactions on Power Systems*, 21(2), 965–972. <https://doi.org/10.1109/TPWRS.2006.873421>
- Quan, J., & Shang, L. (2020). Short-term wind speed forecasting based on ensemble online sequential extreme learning machine and Bayesian optimization. *Mathematical Problems in Engineering*, 2020. <https://doi.org/10.1155/2020/7212368>
- Rodríguez, F., Florez-Tapia, A. M., Fontán, L., & Galarza, A. (2020). Very short-term wind power density forecasting through artificial neural networks for microgrid control. *Renewable Energy*, 145, 1517–1527. <https://doi.org/10.1016/j.renene.2019.07.067>

- Roungkvist, J. S., & Enevoldsen, P. (2020). Timescale classification in wind forecasting: A review of the state-of-the-art. *Journal of Forecasting*, 39(5), 757–768. <https://doi.org/10.1002/for.2657> *rtenerji-kandirares.pdf*. (n.d.).
- Sansa, I., Boussaada, Z., & Bellaaj, N. M. (2021). *of ARMA and NARX*.
- Shabalov, M. Y., Zhukovskiy, Y. L., Buldysko, A. D., Gil, B., & Starshaia, V. V. (2021). The influence of technological changes in energy efficiency on the infrastructure deterioration in the energy sector. *Energy Reports*, 7, 2664–2680. <https://doi.org/10.1016/j.egyr.2021.05.001>
- Shi, J., Qu, X., & Zeng, S. (2011). Short-term wind power generation forecasting: Direct versus indirect ARIMA-based approaches. *International Journal of Green Energy*, 8(1), 100–112. <https://doi.org/10.1080/15435075.2011.546755>
- Silva, M., A de Freitas, N. C., dos S Silva, M. P., & Sakamoto, M. S. (2018). GeoDMA-Geographic Data Mining Analyst View project Wind Speed Forecasting: A Review. *Int. Journal of Engineering Research and Application Wwww.Ijera.Com*, 8(1), 4–09. <https://doi.org/10.9790/9622-0801010409>
- Soman, S. S., Zareipour, H., Malik, O., & Mandal, P. (2010). A review of wind power and wind speed forecasting methods with different time horizons. *North American Power Symposium 2010, NAPS 2010*. <https://doi.org/10.1109/NAPS.2010.5619586>
- Spiliotis, E., Petropoulos, F., & Nikolopoulos, K. (2020). The impact of imperfect weather forecasts on wind power forecasting performance: Evidence from two wind farms in Greece. *Energies*, 13(8). <https://doi.org/10.3390/en13081880>
- Ssekulima, E. B., Anwar, M. B., Al Hinai, A., & El Moursi, M. S. (2016). Wind speed and solar irradiance forecasting techniques for enhanced renewable energy integration with the grid: A review. *IET Renewable Power Generation*, 10(7), 885–898. <https://doi.org/10.1049/iet-rpg.2015.0477>
- Stromsather, Jon., Flego, Gianluca., Vitiello, Silvia., Marretta, Laura., Fulli, Gianluca., & European Commission. Joint Research Centre. (n.d.). *Cost-benefit analysis of Smart Grid projects Isernia: costs and benefits of Smart Grid pilot installations and scalability options*.
- Sun, Z., Sun, H., & Zhang, J. (2018). Multistep Wind Speed and Wind Power Prediction Based on a Predictive Deep Belief Network and an Optimized Random Forest. *Mathematical Problems in Engineering*, 2018. <https://doi.org/10.1155/2018/6231745>
- Taherdangkoo, R., Tatomir, A., Taherdangkoo, M., Qiu, P., & Sauter, M. (2020). Nonlinear autoregressive neural networks to predict hydraulic fracturing fluid leakage into shallow groundwater. *Water (Switzerland)*, 12(3). <https://doi.org/10.3390/w12030841>
- Tascikaraoglu, A., & Uzunoglu, M. (2014a). A review of combined approaches for prediction of short-term wind speed and power. *Renewable and Sustainable Energy Reviews*, 34, 243–254. <https://doi.org/10.1016/j.rser.2014.03.033>
- Tascikaraoglu, A., & Uzunoglu, M. (2014b). A review of combined approaches for prediction of short-term wind speed and power. In *Renewable and Sustainable Energy Reviews* (Vol. 34, pp. 243–254). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2014.03.033>

- Tseng, C. M., Jan, C. D., Wang, J. S., & Wang, C. M. (2007a). Application of artificial neural networks in typhoon surge forecasting. *Ocean Engineering*, 34(11–12), 1757–1768. <https://doi.org/10.1016/j.oceaneng.2006.09.005>
- Tseng, C. M., Jan, C. D., Wang, J. S., & Wang, C. M. (2007b). Application of artificial neural networks in typhoon surge forecasting. *Ocean Engineering*, 34(11–12), 1757–1768. <https://doi.org/10.1016/j.oceaneng.2006.09.005>
- Ullah, N. R., Bhattacharya, K., & Thiringer, T. (2009). Wind farms as reactive power ancillary service providers-technical and economic issues. *IEEE Transactions on Energy Conversion*, 24(3), 661–672. <https://doi.org/10.1109/TEC.2008.2008957>
- Ulu, E. Y., & Dombayci, O. A. (2018). Wind Energy in Turkey: Potential and Development. *Technology, Engineering & Mathematics (EPSTEM)*, 4. www.isres.org
- Wan, C., Zhao, J., Song, Y., Xu, Z., Lin, J., & Hu, Z. (2016). Photovoltaic and solar power forecasting for smart grid energy management. *CSEE Journal of Power and Energy Systems*, 1(4), 38–46. <https://doi.org/10.17775/cseejpes.2015.00046>
- Wang, Y., Zou, R., Liu, F., Zhang, L., & Liu, Q. (2021). A review of wind speed and wind power forecasting with deep neural networks. *Applied Energy*, 304. <https://doi.org/10.1016/j.apenergy.2021.117766>
- Xie, Y., Li, C., Tang, G., & Liu, F. (2021). A novel deep interval prediction model with adaptive interval construction strategy and automatic hyperparameter tuning for wind speed forecasting. *Energy*, 216. <https://doi.org/10.1016/j.energy.2020.119179>
- Zhang, J., Yan, J., Infield, D., Liu, Y., & Lien, F. sang. (2019). Short-term forecasting and uncertainty analysis of wind turbine power based on long short-term memory network and Gaussian mixture model. *Applied Energy*, 241, 229–244. <https://doi.org/10.1016/j.apenergy.2019.03.044>
- Zhang, W., Qu, Z., Zhang, K., Mao, W., Ma, Y., & Fan, X. (2017). A combined model based on CEEMDAN and modified flower pollination algorithm for wind speed forecasting. *Energy Conversion and Management*, 136, 439–451. <https://doi.org/10.1016/j.enconman.2017.01.022>
- U.S. Energy Information Administration. (2024). (publication). *Short-Term Energy Outlook 2024*. Retrieved August 25, 2024, from chrome-exte
- (EIA), U. E. I. A. (2023). Short-Term Energy Outlook Short-Term Energy Outlook. *Short-Term Energy Outlook*, 2023(June), 4–6.
- A.Adeoti, O., A. Osanaiye, P., Aasim, Singh, S. N., Mohapatra, A., Abbasipour, M., Igder, M. A., Liang, X., Abhinav, R., Alkhayat, G., Mehmood, R., Almasoud, A. H., Gandayh, H. M., Aly, H. H. H., Alzahrani, A. A. I., Shamsi, P., Dagli, C., Ferdowsi, M., Arabeyyat, O., ... Long, C. (2020). No Title. *Renewable Energy*, 8(3), 119361. <https://doi.org/10.1016/j.energy.2020.119361>
- Cadenas, E., Rivera, W., Campos-Amezcu, R., & Heard, C. (2016). Wind speed prediction using a univariate ARIMA model and a multivariate NARX model. *Energies*, 9(2). <https://doi.org/10.3390/en9020109>

- Kursun, B. (2023). Exploitable wind power potential in Turkey with technological advancement and resulting environmental-economic aspects. *Energy Exploration and Exploitation*, 41(1), 187–209. <https://doi.org/10.1177/01445987221115814>
- Potter, C. W., Member, S., & Negnevitsky, M. (2010). *Very Short-Term Wind Forecasting for Tasmanian Power Generation*. 21(2), 965–972.
- Tascikaraoglu, A., & Uzunoglu, M. (2014). A review of combined approaches for prediction of short-term wind speed and power. *Renewable and Sustainable Energy Reviews*, 34, 243–254. <https://doi.org/10.1016/j.rser.2014.03.033>
- Xie, Y., Li, C., Tang, G., & Liu, F. (2021). A novel deep interval prediction model with adaptive interval construction strategy and automatic hyperparameter tuning for wind speed forecasting. *Energy*, 216. <https://doi.org/10.1016/j.energy.2020.119179>





ÖZGEÇMİŞ

Ad-Soyad : Maysa GAIDOUM AHMED GAIDOUM

ÖĞRENİM DURUMU:

- **Lisans** : Sudan Bilim ve Teknoloji Üniversitesi (SUST), Mühendislik Fakültesi, Elektronik Mühendisliği
- **Yükseklisans** : 2014, ElNeelain Üniversitesi, Bilgisayar Mühendisliği, Embedded Systmes

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2014-2015 yılları arasında Sudan Bilim ve Teknoloji Üniversitesi'nde öğretim üyesi olarak çalıştı.
- Ulusal Araştırma Merkezi'nde (NCR) araştırmacı olarak çalıştı.
- 2014 yılında Bilkent Üniversitesinde "Nano Technology" bursu kazandı.
- 2015 yılında Sakarya Üniversitesinde YTB'den burs kazandı.
- 2017 İspanya'daki Erasmus programına 6 aylığına stajyer olarak seçildim.

TEZDEN TÜRETİLEN ESERLER:

- Gidom, M. Babiker, S. 2014. CubSat Project, an Eduactional for Development Processes: Relaiability Issuea, *International Conference on ddistance Learning*, Khartoum, Sudan.
- Gidom, M. 2015. Fault Handling in Knsat-1 prototype-2 Cubesat System, *book project published in LAP LAMBERT Academic Publishing*, Germany,
- Gidom, M. Abdulla, F. and Uygun, Ö. 2018. Efficiency Analysis of Lighting Bulbs Using Fuzzy Data Envelopment Analysis, *International Conference on Computer, Control, Electrical, and Electronics Engineering (ICCCEEE)*, Khartoum, pp. 1-4, doi: 10.1109/ICCCEEE.2018.8515841.
- Gidom, M. Kökçam, A.H. & Uyaroğlu, Y. 2023. Short-Term Wind Speed Forecasting Using Nonlinear Autoregressive Neural Network: A Case Study in KocaeliTürkiye, *Electric Power Components and Systems*, DOI: 10.1080/15325008.2023.2220688.