



**T. C.
SİVAS CUMHURİYET ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**RÜZGÂR ENERJİSİ ÜRETİM TAHMİNİ İÇİN HİBRİT
TRANSFORMER MODELİ**

YÜKSEK LİSANS TEZİ

Ahmed BABIKER ABDALLA IBRAHİM

20229258050

Yapay Zekâ ve Veri Bilimi Ana Bilim Dalı

Tez Danışmanı: Doç. Dr. Kenan ALTUN

SİVAS

OCAK 2025

Ahmed BABIKER ABDALLA IBRAHİM'in hazırladığı ve “**RÜZGÂR ENERJİSİ ÜRETİM TAHMİNİ İÇİN HİBRİT TRANSFORMER MODELİ**” adlı bu çalışma aşağıdaki jüri tarafından **YAPAY ZEKÂ VE VERİ BİLİMİ ANA BİLİM DALI**’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı	Doç. Dr. Kenan ALTUN Sivas Cumhuriyet Üniversitesi	
Jüri Üyesi	Doç. Dr. Rukiye UZUN ARSLAN Zonguldak Bülent ECEVİT Üniversitesi	
Jüri Üyesi	Dr. Öğr. Üyesi Volkan GÖREKE Sivas Cumhuriyet Üniversitesi	

Bu tez, Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak onaylanmıştır.

Prof. Dr. Nail ALTUNAY
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRÜ

Bu tez, Sivas Cumhuriyet Üniversitesi Senatosu'nun 20.08.2014 tarihli ve 7 sayılı kararı ile kabul edilen Fen Bilimleri Enstitüsü Lisansüstü Tez Yazım Kılavuzu (Yönerge)'nda belirtilen kurallara uygun olarak hazırlanmıştır.





Bütün hakları saklıdır.

Kaynak göstermek koşuluyla alıntı ve gönderme yapılabilir.

©Ahmed Babiker Abdalla IBRAHIM, 2024

Bu yüksek lisans derecemi sevgili anne babama, değerli arkadaşlarıma ve bugün olduğum kişi olmamda bana yardımcı olan topluluğuma adıyorum.

ETİK

Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü, Tez Yazım Kılavuzu (Yönerge)'nda belirtilen kurallara uygun olarak hazırladığım bu tez çalışmada;

- ✓ Bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- ✓ Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- ✓ Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere, bilimsel normlara uygun olarak atıfta bulunduğumu ve atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- ✓ Tezin herhangi bir bölümünü, Sivas Cumhuriyet Üniversitesi veya bir başka üniversitede, bir başka tez çalışması olarak sunmadığımı; beyan ederim.

2.01.2025

Ahmed BABIKER
ABDALLA IBRAHİM

KATKI BELİRTME VE TEŞEKKÜR

Öncelikle Allah'a sonsuz teşekkürler ve övgüler. Sevgili aileme, özellikle babam Babiker Abdalla ve annem Entsar Seddig'e sonsuz şükranlarımı sunmak istiyorum. Bana olan sonsuz destekleri, fedakarlıkları ve sarsılmaz inançları, akademik yolculuğumu inşa ettiğim temel oldu. Onların sevgisi ve teşvikleri olmasaydı, bu başarılar mümkün olmazdı.

Bu süreçte değerli rehberliği, sabrı ve mükemmellik için kararlı çabalarıyla bana rehberlik eden danışmanım Doç. Dr. Kenan ALTUN'a en derin şükranlarımı sunmak istiyorum. Bana olan inancınız, elimden gelenin en iyisini yapmam için bana sürekli ilham kaynağı oldu ve bunun için sonsuza dek minnettarım.

Ayrıca hayatımı daha kolay ve daha keyifli hale getiren kız kardeşlerim Dr. Mathani Babiker ve eşi Eng. Mohammed Omer ile küçük kardeşlerim Khalid Babiker, Mohamed Babiker ve Aya Babiker'e teşekkür etmek istiyorum.

Desteği için sevgili arkadaşım Eng. Musab Al Sheikh'e teşekkür etmek istiyorum.

Ayrıca Sudanlı öğrenci arkadaşlarıma özel teşekkürlerimi sunmak istiyorum. Dostluğunuz ve desteğiniz benim için sürekli bir güç ve motivasyon kaynağı oldu. Birlikte sayısız zorluğun üstesinden geldik ve bu yolda paylaştığımız her anı derinden takdir ediyorum.

Bu noktaya ulaşmamda bana rehberlik eden ve destek olan Sayın Osman Karaca'ya içten şükranlarımı sunmak istiyorum. Yardımınız bu yolculukta hayati bir rol oynadı.

Son olarak, Fen Bilimleri Enstitüsü'ndeki tüm hocalarıma derinden minnettarım. Öğretime olan bağlılığınız ve bilgimi genişletme çabalarınız akademik ve kişisel gelişimimde önemli bir rol oynadı. Eğitime olan katkılarınız her zaman hatırlanacak ve değer verilecektir.

ÖZET

RÜZGÂR ENERJİSİ ÜRETİM TAHMİNİ İÇİN HİBRİT TRANSFORMER MODELİ

Ahmed BABIKER ABDALLA IBRAHİM

Yüksek Lisans Tezi

Yapay Zekâ ve Veri Bilimi Ana Bilim Dalı

Danışman: Doç. Dr. Kenan ALTUN

2025, 69+xvii sayfa

Rüzgâr enerjisinin elektrik şebekesine giderek daha fazla entegre edilmesi, stabilite ve verimliliğin sağlanabilmesi için doğru tahminleri zorunlu kılmaktadır. Önemli bir yenilenebilir enerji kaynağı olan rüzgâr enerjisi, doğasındaki değişkenlik nedeniyle zorluklar sunmaktadır. Rüzgâr hızının ve yönünün doğru tahmini hem teknik bir engel hem de üretimin talebi karşılayacak şekilde optimize edilerek rüzgâr enerjisi verimliliğinin maksimize edilmesi ve maliyetlerin minimize edilmesi açısından ekonomik bir zorunluluktur. Ancak mevcut yöntemler, karmaşıklık veya yorumlanabilirlik eksikliği nedeniyle genellikle sınırlamalarla karşı karşıya kalmaktadır.

Bu çalışma, insan beyninin bilgi işleme yeteneklerinden esinlenerek, yeni bir iki aşamalı hibrit Transformer tabanlı rüzgâr gücü tahmin modeli önermektedir. Geleneksel istatistiksel yöntemler ile ileri makine öğrenimi tekniklerinin güçlü yönlerini birleştiren önceki çalışmalara dayanarak geliştirilen bu model, önemli avantajlar sunmayı hedeflemektedir.

Önerilen model, iki aşamalı bir Transformer mimarisi kullanmaktadır. İlk aşama, rüzgâr parametrelerinin yüksek doğrulukta tahminine odaklanırken, ikinci aşama bu tahminleri enerji üretim tahmini için kullanmaktadır. Hibrit mimarimiz, Transformer modellerinin zamansal yeteneklerinden yararlanarak, alan bilgisi ve istatistiksel özellikler ile zenginleştirilmiştir. Önerilen model, birçok rüzgâr enerjisi veri seti üzerinde değerlendirilmiş ve mevcut yöntemlere kıyasla tahmin doğruluğunda önemli iyileşmeler göstermiştir. Bulgularımız, hibrit Transformer modellerinin, rüzgâr enerjisi

retiminde mevcut olan karmařık zamansal bağımlılıkları ve deęiřkenlięi etkili bir řekilde yakalayabildięini, bylece řebeke ynetimi ve operasyonel planlamanın iyileřtirilmesine ynelik gl bir zm sunduęunu gstermektedir.

nerilen yntemlerin geliřtirilmesi ve analizi aracılıęıyla, bu arařtırma doęru ve gvenilir rzgr gc tahminlerine katkıda bulunmayı, maliyet etkin, srdrlebilir ve verimli elektrik enerjisi planlamasının yolunu amayı amalamaktadır. Bu planlar, řebeke ynetiminin optimize edilmesi, fosil yakıtlara bağımlılıęın azaltılması, yenilenebilir enerji kaynaklarının daha etkili bir řekilde entegrasyonu ve talep yanıtı stratejilerinin iyileřtirilmesini iermektedir. Rzgr gc tahmin doęruluęunun artırılmasıyla, hibrit model daha iyi elektrik planlamasını, yedek g kaynaklarına olan ihtiyaın minimize edilmesini ve daha srdrlebilir bir enerji řebekesine geiři desteklemektedir. Gelecek arařtırma ynleri ve yenilenebilir enerji tahminindeki potansiyel uygulamalar da tartıřılmaktadır.

Anahtar kelimeler: Rzgr Enerjisi Tahmini, Transformer Modelleri, Hibrit Model, Yenilenebilir Enerji.

ABSTRACT

HYBRID TRANSFORMER MODEL FOR WIND ENERGY PRODUCTION FORECASTING

Ahmed BABIKER ABDALLA IBRAHIM

Master's Thesis

Department of Artificial Intelligence and Data Science

Advisor: Assoc. Prof. Dr. Kenan ALTUN

2025, 69+xvii pages

The increasing integration of wind power into the electrical grid necessitates accurate forecasting to ensure stability and efficiency. Wind power, a crucial renewable source, poses challenges due to its inherent variability. Accurate wind speed and direction prediction is both a technical hurdle and an economic imperative for maximizing wind power efficiency and minimizing costs by tailoring production to meet demand. However, current methods often face limitations due to complexity or lack of interpretability.

Inspired by the human brain's information processing capabilities, this paper proposes a novel two-stage hybrid Transformer-based wind power forecasting model. Building upon the referenced work, which combines the strengths of traditional statistical methods and advanced machine learning techniques, this model aims to offer significant advantages.

The proposed model employs a two-step Transformer architecture. The first stage focuses on highly accurate wind parameter estimation, while the second one leverages these estimates for energy production forecasting. Our hybrid architecture leverages the temporal capabilities of transformer models, enhanced by incorporating domain-specific knowledge and statistical features. The proposed model is evaluated on multiple wind power datasets, demonstrating significant improvements in forecasting accuracy compared to existing methods. Our findings indicate that hybrid transformer models can effectively capture the complex temporal dependencies and variability

inherent in wind power generation, offering a robust solution for enhancing grid management and operational planning.

Through the development and analysis of the proposed methods, this research endeavors to contribute to accurate and reliable wind power forecasting, paving the way for cost-effective, sustainable, and efficient electrical energy planning. These plans include optimizing grid management, reducing reliance on fossil fuels, integrating renewable energy sources more effectively, and improving demand response strategies. By enhancing wind power forecasting accuracy, the hybrid model supports better scheduling and dispatch of electricity, minimizes the need for costly backup power sources, and facilitates the transition to a more sustainable energy grid. Future research directions and potential applications in renewable energy forecasting are also discussed.

Keywords: Wind Power Forecasting, Transformer Models, Hybrid Model, Renewable Energy.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET.....	Viii
ABSTRACT	X
İÇİNDEKİLER	Xii
ŞEKİLLER DİZİNİ	XV
ÇİZELGELER DİZİNİ	XVi
KISALTMALAR DİZİNİ.....	XVii
1. GİRİŞ	1
1.1 Rüzgâr Gücü Tahmininin Önemi	2
1.2 Rüzgâr Enerjisi Tahminindeki Zorluklar	3
1.3 Rüzgâr Gücü Tahmininde Makine Öğrenimi ve Derin Öğrenme	5
1.4 Makine Öğrenmesi ve Derin Öğrenmede Belirsizlik Miktarı.....	6
1.5 Rüzgâr Gücü Tahmin Yöntemlerinin Evrimi	7
1.6 Hibrit Model Varyantları	8
1.7 Rüzgâr Gücü Tahmininde Transformer Modellerinin Yükselişi.....	10
1.8 Araştırmanın Önemi	11
1.9 Amaç ve Kapsam	11
1.10 Gelecekteki Araştırma Yönleri.....	12
2. TRANSFORMER MODELLERİ	14
2.1 Makine Öğrenimi ve Derin Öğrenmenin Temelleri	14
2.2 Random Forest (Rastgele Orman) Algoritması.....	14
2.2.1 Gürültü Azaltma İçin Random Forest Kullanımı	16
2.2.2 Rüzgâr Gücü Tahmininde Random Forest Uygulaması.....	17
2.3 Sinir Ağları	17
2.3.1 İleri Beslemeli Sinir Ağları	18
2.3.2 İleri Beslemeli Sinir Ağlarının Yapısı	18

2.3.3 İleri Beslemeli Sinir Ağlarının Çalışma Mekanizması.....	19
2.3.4 Rüzgâr Gücü Tahmininde İleri Beslemeli Sinir Ağlarının Kullanımı...	19
2.3.5 Rüzgâr enerjisi üretim tahmininde FFN'nin avantajları	20
2.3.6 Rüzgâr Enerjisi Tahmini için FFN'lerin Geliştirilmesi	20
2.4 Rüzgâr Enerjisi için Transformatör Modellerinde LSTM Ağlarının	21
2.4.1 Hibrit Transformer Modellerinde LSTM'nin Rolü.....	22
2.4.2 Rüzgâr Gücü Tahminindeki Uygulamalar.....	22
2.4.3 LSTM ve Transformatör Modellerini Birleştirmenin Avantajları	23
2.5 Transformer Modelleri	23
2.5.1 Transformatör Mimarisi Genel Bakış	24
2.5.2 Öz-Dikkat (Self-Attention) Mekanizması.....	26
2.5.3 Zaman Serisi Tahmini için Transformer Model Uygunluğu	28
3. HİBRİT MODEL MİMARİSİ VE ENTEGRASYON STRATEJİLERİ....	29
3.1 Sinir Ağları, LSTM ve Hibrit Modellerin Entegrasyonu	29
3.2 Hibrit Model Genel Bakış	30
3.3 Hibrit Transformatör Model Mimarisi	32
3.3.1 Hava Tahmini için İlk Transformatör Modeli	32
3.3.2 İleri Beslemeli Sinir Ağı	33
3.3.3 Güç Tahmini için İkinci Transformer Modeli	34
3.4 Model Geliştirmede Etik Hususlar.....	35
3.4.1 Çevresel Etkiler	37
3.4.2 Doğru Tahminlerin Sorumluluğu	38
3.4.3 Enerji Üretiminde İsraf ve Verimsizliği Önleme	38
4. MİTOLOJİ	40
4.1 Veri Toplama ve Ön İşleme	40
4.2 Keşifsel Veri Analizi	41
4.3 Veri Kalitesi.....	45
4.3.1 Başlangıç Veri Hazırlığı	45
4.3.2 Rüzgâr Yönü Verilerinin Dönüştürülmesi.....	45
4.3.3 Özellik Seçimi ve Normalizasyon.....	45

4.3.4 Random Forest Regressor ile Gürültü Azaltma	46
5. SONUÇLAR VE DENEYLER.....	47
5.1 Model Değerlendirmesi.....	47
5.1.1 Ortalama Kare Hata.....	47
5.1.2 Ortalama Mutlak Hata.....	47
5.1.3 Kök Ortalama Kare Hata.....	48
5.1.4 Yüzde farkı	48
5.2 Deneysel Kurulum	48
5.2.1 Veri Ölçeklendirme	50
5.2.2 Gürültü Azaltma	50
5.3 Model Performansı.....	52
5.4 Hibrit Transformer Modellerinin Karşılaştırmalı Analizi	53
6. TARTIŞMA VE SONUÇ	58
KAYNAKLAR.....	60
ÖZGEÇMİŞ.....	69

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1. Random Forest Algoritma Diyagramı.	15
Şekil 2.2. ffn mimarisi	19
Şekil 2.3. lstm katmanı	22
Şekil 2.4. Transformatör model mimarisini	26
Şekil 2.5. Öz-Dikkat	27
Şekil 3.1. Hibrit dönüşüm modeli akış şeması.....	31
Şekil 4.1. Zaman Serisi Analizi.....	41
Şekil 4.2. Korelasyon Matrisi Isı Haritası.....	42
Şekil 4.3. Rüzgâr önü ile rüzgâr hızı arasındaki ilişki	44
Şekil 5.1. Gerçek Değerler vs. Tahmin Edilen Değerler.....	52
Şekil 5.2. Gün içerisinde saatlik uygulama modellerinin Güç karşılaştırılması.	56

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Tablo 4.1. Veri İstatistikleri	40
Tablo 5.1 Günlük Saat Bazlı Veriler.....	54
Tablo 5.2 Günlük Saat Bazlı Veriler.	55



KISALTMALAR DİZİNİ

ARIMA	Autoregressive Integrated Moving Average
ARMA	Autoregressive Moving Average
ARX	Autoregressive with Extra Input
CNN	Convolutional Neural Network
FNN	Feedforward Neural Network
GP	Gaussian Process
LSTM	Long Short-Term Memory
NWP	Numerical Weather Prediction
RNN	Recurrent Neural Network
SARIMA	Seasonal Autoregressive Integrated Moving Average
ANN	Artificial Neural Network
GRN	Gated Residual Network
ReLU	Rectified Linear Activation Unit
MSE	Mean Square Error
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
RMSE	Root Mean Square Error
GRU	Gated Recurrent Unit
SVM	Support Vector Machines
BPNN	Backpropagation Neural Network
SARIMAX	Seasonal AutoRegressive Integrated Moving Average with eXogenous factors
SVR	Support Vector Regression
NARMAX	Nonlinear AutoRegressive Moving Average with eXogenous inputs
GPU	Graphics Processing Unit
H-Transformer	Hybrid Transformer

1. GİRİŞ

Fosil yakıtlardan yenilenebilir enerjiye geçiş, iklim değişikliğiyle mücadele ve enerji güvenliğini sağlama gibi iki önemli zorunluluk nedeniyle küresel enerji politikasının temel bir odak noktasıdır [1]. Rüzgâr enerjisi, 2020 yılı sonunda dünya genelinde kurulu kapasitesinin 743 KW'a ulaşmasıyla en umut verici yenilenebilir enerji kaynaklarından biri olarak öne çıkmıştır [2]. Rüzgar enerjisinin genişlemesi, büyük ölçüde teknolojik ilerlemeler, devletlerin destekleyici politikaları ve enerji sektörünün karbonsuz aştırılmasının gerekliliğinin giderek daha fazla anlaşılmasıyla mümkün olmuştur. Ancak, rüzgâr enerjisinin mevcut elektrik şebekelerine entegrasyonu, rüzgârın doğasında bulunan değişkenlik ve öngörülemezlik nedeniyle önemli zorluklar barındırmaktadır [3]. Bu öngörülemezlik, şebeke kararlılığına yönelik riskler doğurmakta, işletme maliyetlerini artırmakta ve enerji planlamasını karmaşık hale getirmektedir. Bu sebeple, rüzgâr enerjisi sistemlerinin güvenilirliğini ve verimliliğini korumak adına doğru rüzgâr gücü tahminleri büyük önem taşımaktadır.

Rüzgâr enerjisi tahminleri, rüzgâr kaynaklarının doğal değişkenliği ile istikrarlı ve öngörülebilir enerji üretimi ihtiyacı arasında köprü görevi görmektedir. Bu tahminler, şebeke operatörlerinin rüzgâr gücü üretimindeki dalgalanmaları önceden görüp operasyonlarını buna göre ayarlamalarını sağlayarak fosil yakıtlara dayalı yedek enerji santrallerine olan bağımlılığı en aza indirir [4]. Bunun yanı sıra, doğru tahminler enerji dağıtımının optimize edilmesine, rezerv gereksinimlerinin azaltılmasına ve rüzgâr enerjisi üretiminin ekonomik verimliliğinin artırılmasına katkı sağlar. Bu bağlamda, daha doğru ve güvenilir tahmin modellerinin geliştirilmesi, yenilenebilir enerji alanında çalışan araştırmacılar ve uygulayıcılar için bir öncelik haline gelmiştir [5].

Rüzgâr türbini teknolojisi ve enerji yönetim sistemlerindeki ilerlemelere rağmen, rüzgâr gücü tahmini hâlâ karmaşık bir zorluktur. Bu zorluk, rüzgârın, sıcaklık, basınç ve topografya gibi pek çok meteorolojik faktörden etkilenen doğrusal olmayan ve rastlantısal yapısından kaynaklanmaktadır [6]. Bu faktörler karmaşık şekillerde etkileşime girerek, rüzgâr davranışını yüksek bir doğrulukla tahmin etmeyi zorlaştırmaktadır. İstatistiksel ve fiziksel modellere dayanan geleneksel tahmin yöntemleri, rüzgâr gücü üretiminin dinamik ve belirsiz doğasını tam olarak yansıtmakta yetersiz kalmıştır [7]. Bu nedenle, bu sınırlamaları gidermek ve rüzgâr

gücü tahminlerinin doğruluğunu artırmak için farklı tahmin tekniklerini birleştiren yeni yaklaşımlar önerilmiştir.

1.1 Rüzgâr Gücü Tahmininin Önemi

Rüzgâr gücü tahmini, enerji planlaması, yük dengeleme ve elektrik şebekelerinin güvenilir bir şekilde işletilmesi gibi birçok şebeke yönetimi açısından hayati öneme sahiptir [8]. Rüzgâr enerjisinin enerji karışımındaki payının artmasıyla birlikte, doğru tahminler yapmak şebeke istikrarını korumak için vazgeçilmez hale gelmiştir. Rüzgârın öngörülemez doğası, enerji üretiminde önemli dalgalanmalara neden olabilir; bu da arz ve talep arasında dengesizliklere yol açabilir. Bu tür dengesizlikler, doğru bir şekilde yönetilmezse voltaj kararsızlığı, frekans sapmaları ve hatta elektrik kesintileri gibi ciddi sorunlara neden olabilir [9]. Doğru tahminler sunarak, şebeke operatörleri bu riskleri hafifletebilir, geleneksel enerji santrallerinin üretimlerini ayarlayabilir, bakım programlarını düzenleyebilir ve yedek güç yönetimini daha etkili bir şekilde gerçekleştirebilir.

Bunun yanı sıra, rüzgâr gücü tahmini, enerji sistemlerinin ekonomik optimizasyonuna da katkı sağlar. Doğru tahminler, enerji üretiminin daha iyi planlanmasını sağlayarak pahalı yedek enerji ihtiyacını azaltır ve enerji dengesizliklerinden kaynaklanan maliyetleri en aza indirir [10]. Bu durum, özellikle elektrik üreticilerinin tahmin edilen ve gerçek üretim arasındaki dengesizliklerden dolayı önemli mali cezalarla karşı karşıya kalabileceği serbestleştirilmiş elektrik piyasalarında büyük önem taşır. Ayrıca, doğru tahminler, elektrik piyasalarında daha verimli teklif verilmesini mümkün kılar; çünkü üreticiler, beklenen rüzgâr üretimine dayalı olarak daha güvenilir üretim taahhütleri sunabilirler [11].

Daha geniş bir enerji dönüşümü bağlamında, rüzgâr enerjisi tahmini, yenilenebilir enerji kaynaklarının elektrik şebekesine entegrasyonunu desteklemek açısından önemli bir rol oynamaktadır. Rüzgâr enerjisi, küresel elektrik üretimindeki payını artırmaya devam ettikçe, isabetli tahminler yapmak, fosil yakıtlara olan bağımlılığı azaltmak ve düşük karbon emisyonlu bir enerji sistemine geçişi hızlandırmak için kritik öneme sahip olacaktır [12]. Rüzgâr gücünün, küresel ısınmayı sanayi öncesi seviyelerin 2°C'nin altında tutmayı hedefleyen Paris Anlaşması'nın hedeflerine ulaşmada kilit bir rol oynaması beklenmektedir [13]. Rüzgâr enerjisinin güvenilirliğini ve öngörülebilirliğini artırarak, tahminler yenilenebilir enerji kaynaklarının tam

potansiyelleriyle kullanılmasını sağlamakta ve enerji sektörünün karbonsuz aşırtılmasına katkıda bulunmaktadır.

1.2 Rüzgâr Enerjisi Tahminindeki Zorluklar

Rüzgâr enerjisi tahmini, rüzgârın karmaşık ve dinamik yapısı nedeniyle doğası gereği zordur. Rüzgâr hızı ve yönü kısa zaman dilimlerinde ve farklı coğrafi bölgelerde önemli ölçüde değişebilir ve bu da rüzgâr enerjisi üretimini yüksek hassasiyetle tahmin etmeyi zorlaştırır [14]. Bu dalgalanmalar, atmosfer basıncı, sıcaklık, nem ve Dünya'nın topografyası gibi çeşitli meteorolojik faktörlerden etkilenir. Örneğin, rüzgâr hızları genellikle artan irtifa ile artar, ancak dağlar veya binalar gibi engellerin varlığı türbülans yaratabilir ve rüzgâr akışını etkileyebilir. Dahası, rüzgâr desenleri basınç sistemleri, hava cepheleri ve jet akımları gibi büyük ölçekli atmosferik olaylardan etkilenir ve bu da rüzgâr hızında ve yönünde ani ve öngörülemeyen değişikliklere yol açabilir [15].

Rüzgâr enerjisi üretiminin öngörülemezliği, istikrarlı ve güvenilir bir enerji tedarikini sürdürmesi gereken şebeke operatörleri için önemli zorluklar oluşturur. Rüzgâr enerjisi üretimi tahmin edilen seviyelerin altında kalırsa, şebeke operatörlerinin açığı kapatmak için gaz veya kömür gibi geleneksel enerji santrallerini açmaları gerekebilir. Bu, işletme maliyetlerini artırabilir ve rüzgâr enerjisinin çevresel faydalarını azaltabilir, bu da daha yüksek sera gazı emisyonlarına yol açabilir [16]. Öte yandan, rüzgâr enerjisi üretimi öngörülen seviyeyi aşarsa, fazla enerji kesilebilir veya depolanabilir, bu da verimsizliklere ve artan maliyetlere neden olur.

Erken rüzgâr enerjisi tahmin yöntemleri, gelecekteki rüzgâr modellerini tahmin etmek için geçmiş rüzgâr verilerini kullanan istatistiksel modellere dayanıyordu. En yaygın kullanılan istatistiksel modellerden biri, kısa vadeli tahminler için etkili olan ancak genellikle rüzgâr verilerinin doğrusal olmayan ve durağan olmayan özelliklerini yakalamakta zorlanan ARIMA modelidir [17]. Diğer geleneksel istatistiksel modeller arasında mevsimselliği hesaba katan ARMA, ARX ve mevsimsel ARIMA (SARIMA) modelleri bulunur [18]. Bu modeller tahmin için basit ve anlaşılır bir yaklaşım sağlasa da bu modellerin en büyük sınırlamalarından biri, rüzgâr enerjisi üretiminde yaygın olan doğrusal olmayan ilişkiler ve durağan olmayan verilerle başa çıkamamalarıdır [19].

Bu modeller, doğrusal bağımlılıklara dayalı olarak gelecekteki rüzgâr desenlerini tahmin etmek için tarihsel verilere güvenir [20]. Örneğin, ARIMA modelleri, rüzgâr verilerindeki döngüsel davranışları ve mevsimselliği yakaladıkları için kısa vadeli tahminlerde etkili olduklarını kanıtlamıştır [21].

Sınırlamalarına rağmen, istatistiksel modeller basitlikleri, anlaşılabilirlikleri ve uygulanma kolaylıkları nedeniyle değerli olmaya devam etmektedir. Örneğin, Pinson ve Madsen (2012), kısa vadeli rüzgâr gücü tahmini için SARIMA modellerini kullanmış ve özellikle mevsimsel etkileri yakalamada orta düzeyde başarı elde etmiştir [22]. Ancak, bu modeller genellikle doğrusal olmayan rüzgâr verilerinin daha belirgin hale geldiği uzun vadeli tahminlerde zorlanmaktadır. Bu durum, karmaşık rüzgâr desenlerini ele alabilen daha sofistike yöntemlerin araştırılmasına yol açmıştır.

İstatistiksel modellerin nicel analizleri, daha uzun zaman dilimlerinde tahmin yaparken performanslarının azalma eğiliminde olduğunu ortaya koymaktadır. Örneğin, kısa vadeli tahminlerde ARIMA modelleri için RMSE 5%-10% arasında değişebilir, ancak uzun vadeli tahminlerde, modelin doğrusal varsayımları nedeniyle bu hata önemli ölçüde artabilir [23].

İstatistiksel modellere ek olarak, fiziksel modeller de rüzgâr gücünü tahmin etmek için kütle ve momentumun korunumu gibi fiziksel yasalara dayalı olarak rüzgâr akış dinamiklerini simüle etmek amacıyla kullanılmıştır. NWP modelleri olarak da bilinen fiziksel modeller, atmosferik koşullara dayanarak tahminler oluşturmak için hava durumu istasyonlarından ve uydulardan elde edilen meteorolojik verileri kullanır [24]. Bu modeller, basınç sistemlerinin oluşumu ve rüzgâr ile arazi arasındaki etkileşim gibi rüzgâr desenlerini yöneten fiziksel süreçleri dikkate alarak, rüzgâr davranışı hakkında detaylı içgörüler sağlayabilir [25]. NWP modelleri, çeşitli atmosferik parametreleri dikkate alarak orta ve uzun vadeli tahminlerde mükemmel sonuçlar verir [26].

Giebel ve arkadaşları (2013), NWP modellerinin rüzgâr davranışının temel fiziğini yakalamadaki gücünü vurgulayarak, bu modellerin özellikle orta vadeli tahminlerde faydalı olduğunu belirtmişlerdir [27]. Ancak, bu modellerin doğru tahminler üretebilmesi için kapsamlı hesaplama kaynaklarına ve yüksek kaliteli giriş verilerine ihtiyaç vardır. Karmaşıklıkları, özellikle büyük ölçekli rüzgâr çiftlikleri için gerçek zamanlı tahminlerde kullanılmalarını sınırlamaktadır [28].

Fiziksel modellerin en önemli sınırlamalarından biri, giriş verilerinin kalitesine olan bağımlılıklarıdır. Meteorolojik kapsamın seyrek olduğu bölgelerde, tahminlerin doğruluğu azalabilir. Ayrıca, fiziksel modeller, büyük ölçekli atmosferik desenlere odaklandıkları için yerel ve ani rüzgâr değişimlerini yakalamada daha az etkili olabilirler ve bu nedenle kısa vadeli tahminlerde daha az etkilidirler [29].

Fiziksel modeller ile istatistiksel modellerin nicel karşılaştırmaları, NWP modellerinin genellikle orta ve uzun vadeli tahminlerde istatistiksel modellerden daha iyi performans gösterdiğini ortaya koymaktadır. Örneğin, NWP modelleri için ortalama mutlak hata genellikle 10%-15% arasında değişirken, aynı tahmin dönemi için istatistiksel modellerde bu oran 20%-25% arasında değişmektedir [30]. Ancak, NWP modellerinin yüksek hesaplama maliyeti, bu modellerin gerçek zamanlı tahmin uygulamalarında yaygın olarak benimsenmesinin önündeki önemli bir engel olmaya devam etmektedir.

1.3 Rüzgâr Gücü Tahmininde Makine Öğrenimi ve Derin Öğrenme

Geleneksel istatistiksel ve fiziksel modellerin sınırlamaları, rüzgâr gücü tahmininde makine öğrenimi tekniklerinin benimsenmesini teşvik etmiştir. Makine öğrenimi modelleri, özellikle yapay sinir ağları, verilerdeki karmaşık ve doğrusal olmayan ilişkileri ele alma konusundaki üstün yetenekleri nedeniyle rüzgâr gücü üretiminde mevcut karmaşık desenleri yakalamak için uygun hale gelmiştir [31]. Tarihsel verilerden öğrenme ve gözlemlenen eğilimlere dayalı doğru tahminler üretme yetenekleri nedeniyle FNN'ler ve RNN'ler gibi sinir ağları üzerinde kapsamlı çalışmalar yapılmıştır [32].

FNN'ler en basit yapay sinir ağı türlerinden biridir ve birbirine bağlı çok katmanlı nöronlardan oluşur. Bu ağlar giriş verilerini işler ve çıktı tahminleri üretir. FNN'ler, rüzgâr davranışındaki anlık eğilimleri ve dalgalanmaları yakalamaya odaklanan kısa vadeli rüzgâr gücü tahmini için özellikle etkilidir [33]. Ancak, FNN'ler uzun vadeli bağımlılıklarla başa çıkmakta zorluk çekerler çünkü bellek yetenekleri yoktur ve önceki zaman adımlarından bilgi depolayamazlar [34]. Bu sınırlamanın üstesinden gelmek için, geri bildirim döngüleri içeren daha gelişmiş bir sinir ağı türü olarak RNN'ler geliştirilmiştir. Bu ağlar, önceki zaman adımlarından bilgi depolayarak ardışık verilerdeki zamansal bağımlılıkları yakalayabilir [35].

RNN'ler, özellikle orta vadeli tahminlerde, FNN'lere kıyasla rüzgâr gücü tahmininde önemli gelişmeler göstermiştir. Önceki zaman adımlarından bilgi depolayarak, RNN'ler rüzgâr hızı, yönü ve güç çıkışı arasındaki zamansal bağımlılıkları yakalayabilir ve bu da onları daha uzun zaman dilimleri boyunca rüzgâr gücünü tahmin etmede daha etkili hale getirir [36]. Ancak, RNN'ler özellikle çok uzun dizilerle uğraşırken zayıflayan eğimler gibi sorunlarla karşılaşabilir ve bu da uzak zaman adımlarından öğrenmeyi zorlaştırır [37].

Bu zorlukların üstesinden gelmek için, LSTM ağları ve CNN'ler gibi daha gelişmiş makine öğrenimi modelleri tanıtılmıştır. LSTM ağları, daha uzun zaman dilimleri boyunca bilgi depolayabilen ve ardışık verilerdeki uzun vadeli bağımlılıkları yakalayabilen bellek hücreleri içeren bir RNN türüdür [38]. Bu özellik, LSTM ağlarını özellikle geçmiş ve gelecek olaylar arasındaki zamansal ilişkileri dikkate almanın önemli olduğu rüzgâr gücü tahmini gibi zaman serisi tahmin görevleri için uygun hale getirir [39].

CNN'ler, verilerdeki mekânsal desenleri yakalamada özellikle etkili olan bir sinir ağı türüdür. Başlangıçta görüntü tanıma görevleri için geliştirilen CNN'ler, meteorolojik verilerdeki rüzgâr hızı ve yön haritaları gibi mekânsal desenleri analiz etmek için rüzgâr gücü tahmini için uyarlanmıştır [40]. Bu mekânsal desenlerden öğrenerek, CNN'ler coğrafi özelliklerin ve büyük ölçekli hava sistemlerinin rüzgâr davranışı üzerindeki etkisini hesaba katarak daha doğru tahminler üretebilir [41].

Rüzgâr gücü tahmininde makine öğrenimi modellerinin elde ettiği başarılarla rağmen, bu modellerin bazı sınırlamaları da vardır. Makine öğrenimi modellerinin en büyük zorluklarından biri, eğitim için büyük miktarda yüksek kaliteli veri gerektirmesidir [42]. Tarihsel veri setlerinin sınırlı olduğu veya rüzgâr desenlerinin yüksek derecede değişkenlik gösterdiği bölgelerde, doğru tahmin modellerinin eğitilmesi zor olabilir, bu durum ise optimal olmayan tahmin sonuçlarına yol açabilir. Ayrıca, makine öğrenimi modelleri, özellikle geniş ölçekli veri setleriyle veya karmaşık model yapılarıyla çalışırken yüksek hesaplama gücü gerektirebilir, bu da işlem süresini ve maliyetleri artırabilir [43].

1.4 Makine Öğrenmesi ve Derin Öğrenmede Belirsizlik Miktarı

Belirsizlik Miktarı Belirlemesi, rüzgâr enerjisi tahminlerinin güvenilirliğini değerlendirme ve enerji yönetimi konusunda bilinçli kararlar alma imkânı tanıdığı için,

rüzgâr gücü tahminlerinde kritik bir öneme sahiptir. Rüzgâr gücü tahminlerindeki doğal belirsizliği ele almak için çeşitli makine öğrenimi yaklaşımları geliştirilmiştir.

Öne çıkan bir yöntem, belirsizliği modellemeye yönelik olasılıksal bir yaklaşım sunan Gauss Süreçleri (GP'ler) kullanımını içerir. GP'ler, yalnızca nokta tahminleri sağlamakla kalmaz, aynı zamanda güven aralıkları gibi belirsizlik ölçümleri de sunan parametrik olmayan modellerdir. Bu özellik, belirsizliği hesaba katmanın daha sağlam karar verme süreçlerine yol açabileceği rüzgâr gücü tahminleri için GP'leri özellikle yararlı kılar. Xie ve arkadaşları tarafından yapılan bir çalışma, GP'lerin belirsizliği açıkça kantifiye eden olasılıksal çıktılar sağlayarak, rüzgâr gücü tahminlerinde tahmin doğruluğunu ve güvenilirliğini artırmadaki etkinliğini göstermiştir [44].

Bir diğer yaklaşım ise, yanıt değişkeni dağılımının koşullu çeyreklerini tahmin eden istatistiksel bir teknik olan kantil regresyonunu içerir. Makine öğrenimi modellerine uygulandığında kantil regresyonu, farklı belirsizlik seviyelerini temsil eden aralık tahminlerinin üretilmesine olanak tanır ve olası sonuçların daha kapsamlı bir görünümünü sunar. Araştırmalar, kantil regresyonunun makine öğrenimi modelleriyle entegre edildiğinde, gelecekteki olası değerlerin aralığını yakalayarak rüzgâr gücü tahminlerinin sağlamlığını önemli ölçüde artırabileceğini göstermiştir ve böylece tahmin belirsizliği hakkında daha net bir resim sunar [45].

Son olarak, Monte Carlo dropout, özellikle sinir ağlarında, derin öğrenme modellerinde belirsizliği tahmin etmek için kullanılan bir tekniktir. Çıkarım aşamasında nöronları rastgele bırakmak suretiyle birden fazla tahmin yapılabilir ve bu tahminlerdeki varyasyonlar üzerinden belirsizlik tahmin edilebilir. Gal ve Ghahramani, Monte Carlo dropout yönteminin sinir ağlarında belirsizliği etkin bir şekilde kantifiye ettiğini ve rüzgâr gücü tahminleri de dahil olmak üzere çeşitli uygulamalarda tahminlerin sağlamlığını artırdığını göstermiştir [46].

Bu teknikler, rüzgâr gücü tahminlerinde makine öğrenimi modellerinin gelişen peyzajını vurgulamakta ve tahminlerin güvenilirliğini ve doğruluğunu artırmak için belirsizlik Miktarı Belirlemesi önemini ön plana çıkarmaktadır.

1.5 Rüzgâr Gücü Tahmin Yöntemlerinin Evrimi

Hibrit modeller, rüzgâr gücü tahminlerinde önemli bir ilerlemeyi temsil etse de bazı sınırlamaları bulunmaktadır. Hibrit modellerin doğruluğu, girdi verilerinin kalitesine

ve altta yatan algoritmaların karmaşıklığına bağlıdır. Hatalı veya eksik meteorolojik veriler, özellikle karmaşık araziye sahip bölgelerde veya hava koşullarının değişken olduğu yerlerde, tahminlerde önemli hatalara yol açabilir [47]. Ayrıca, hibrit modellerin hesaplama açısından pahalı olabileceği ve etkili bir şekilde uygulanabilmesi için özel donanım ve yazılım gerektirebileceği unutulmamalıdır. Bu nedenle, büyük ölçekli rüzgâr gücü tahminlerine uygulanabilecek daha verimli ve ölçeklenebilir hibrit modeller geliştirmeyi amaçlayan çalışmalar devam etmektedir.

Bu gelişmeler, hibrit modellerin daha doğru ve sağlam rüzgâr gücü tahminlerine ulaşmadaki önemini vurgulamaktadır. Geleneksel istatistiksel yöntemlerin, fiziksel modellerin ve ileri düzey makine öğrenimi tekniklerinin güçlü yönlerini birleştirerek, hibrit modeller rüzgâr gücü tahminlerindeki zorluklara kapsamlı bir çözüm sunmaktadır. Bu yaklaşım, rüzgâr enerjisinin yüksek oranda kullanıldığı bölgelerde, doğru tahminlerin şebeke istikrarını korumak ve enerji üretimini optimize etmek için kritik olduğu durumlarda özellikle önem taşımaktadır [48].

1.6 Hibrit Model Varyantları

Literatürde, rüzgâr gücü tahmin doğruluğunu artırmak amacıyla çeşitli hibrit model varyantları araştırılmıştır. Bu modeller, genellikle daha kapsamlı bir tahmin sistemi oluşturmak için birden fazla yaklaşımı entegre ederek hem geleneksel istatistiksel yöntemlerin hem de modern makine öğrenme tekniklerinin güçlü yönlerinden yararlanmayı hedefler.

- Geliştirilmiş LSTM ve BPNN Modeli:

Bu hibrit model, LSTM ağlarını BPNN ile birleştirir. LSTM ağları, hafıza hücreleri sayesinde rüzgâr verilerindeki zamansal bağımlılıkları ve uzun vadeli desenleri yakalamada son derece etkilidir, bu da bilgiyi uzun süreler boyunca saklamalarına yardımcı olur. BPNN, desen tanıma ve doğrusal olmayan ilişkileri öğrenme konusunda başarılı olduğunda, hibrit model, rüzgâr gücü üretimindeki kısa vadeli dalgalanmalar ve uzun vadeli eğilimlerle başa çıkabilir. Bu kombinasyon, özellikle rüzgâr davranışındaki karmaşık dinamikleri yakalamada tahmin performansını artırır. Nicel karşılaştırmalar, bu modelin geleneksel LSTM modellerine kıyasla RMSE'yi %73 kadar azaltarak, rüzgâr gücü tahmini için sağlam bir seçim olduğunu göstermektedir [49].

- SARIMAX + RNN + SVR Modeli:

Dışsal Değişkenler (Exogenous Variables) ile SARIMAX modeli, rüzgâr gücü üretimini etkileyen mevsimsellik ve dış faktörleri hesaba katan popüler bir zaman serisi tahmin yöntemi olarak bilinir. Bu hibrit yaklaşımda, SARIMAX, RNN'ler ve SVR ile birleştirilir. SARIMAX modelleri, mevsimsel eğilimleri ve dışsal değişkenleri yakalamada yetenekliken, RNN'ler, veri noktalarından oluşan dizileri işleyerek rüzgâr verilerindeki zamansal bağımlılıkları ele alır. Küçük ve orta boyutlu veri kümeleriyle başa çıkmadaki etkinliği ile bilinen SVR, tahmin doğruluğunu artırmak için ek bir regresyon analizi katmanı ekler. Bu hibrit model, genel performansı artırarak, tahmin hatalarını azaltır ve daha güvenilir tahminler sağlar. Çalışmalar, bu yaklaşımın SARIMAX veya RNN modellerini tek başına kullanmaya kıyasla RMSE'yi 93% oranında azalttığını göstermiştir [50].

- Wavelet Transform + NARMAX + PSO Modeli:

Bu model, rüzgâr gücü verilerinin doğrusal olmayan ve durağan olmayan özelliklerini ele almak için tasarlanmış ileri düzey bir hibrit modeldir. Wavelet Transform, veri ön işleme için kullanılır ve rüzgâr gücü zaman serisini farklı frekans bileşenlerine ayırarak, gürültüyü izole etmeye ve verilerdeki ilgili desenleri belirlemeye yardımcı olur. Daha sonra, NARMAX modelleri, girdi değişkenleri ile rüzgâr gücü çıktısı arasındaki doğrusal olmayan ilişkileri yakalamak için kullanılır ve bu da onları rüzgâr gücü üretimi gibi yüksek dinamik sistemler için uygun hale getirir. Son olarak, PSO, NARMAX modelinin parametrelerini ince ayar yapmak için bir optimizasyon tekniği olarak uygulanır ve modelin doğruluğunu daha da artırır. Bu kombinasyon, bireysel yöntemlere kıyasla RMSE'yi 99,8% oranında azaltarak, rüzgâr gücü tahmini için en etkili hibrit modellerden biri haline getirir [51].

Bu hibrit model varyantlarının her biri, rüzgâr gücü tahmininde karşılaşılan zorlukların üstesinden gelmek için farklı tahmin tekniklerini birleştirmenin potansiyelini ortaya koymaktadır. Farklı yöntemlerin güçlü yönlerinden yararlanarak, hibrit modeller, bağımsız modellere kıyasla doğruluk, dayanıklılık ve uyarlanabilirlikte önemli iyileştirmeler sunabilir. İstatistiksel modellerin makine öğrenme teknikleriyle entegrasyonu, doğrusal olmayan verilerin daha iyi ele alınmasını sağlarken, PSO gibi optimizasyon teknikleri, parametrelerin ince ayarını yaparak model performansını daha da artırır.

1.7 Rüzgâr Gücü Tahmininde Transformer Modellerinin Yükselişi

Son yıllarda, Transformer modelleri, rüzgâr gücü tahmini de dahil olmak üzere sıra modelleme görevleri için geleneksel makine öğrenimi modellerine güçlü bir alternatif olarak ortaya çıkmıştır. Başlangıçta doğal dil işleme (NLP) görevleri için geliştirilen Transformer modelleri, uzun mesafeli bağımlılıkları ve bağlamsal bilgileri ele alma konusundaki olağanüstü başarısıyla dikkat çekmiş ve bu da onları zaman serisi tahmin görevleri için özellikle uygun hale getirmiştir [52]. RNN'ler ve LSTM'lerin aksine, verileri sıralı olarak işleyen Transformer'lar, tahmin yaparken girdi dizisinin farklı bölümlerinin önemini değerlendirmelerine olanak tanıyan bir öz-dikkat mekanizması kullanır [53].

Öz-dikkat mekanizması, Transformer'ların tüm girdi dizisi boyunca veri noktaları arasındaki ilişkileri, sıralı yapıları nedeniyle sınırlı olan geleneksel tekrarlayan modellere göre daha verimli bir şekilde yakalamasını sağlar [54]. Bu durum, kısa vadeli dalgalanmaların yanı sıra rüzgâr davranışındaki uzun vadeli eğilimlerin de dikkate alınmasının önemli olduğu rüzgâr gücü üretiminde içsel olan karmaşık zamansal bağımlılıkları yakalamada Transformer'ları özellikle etkili kılar [55].

Transformer modellerinin rüzgâr gücü tahmininde kullanılması, araştırma alanında nispeten yeni bir yaklaşımdır, ancak ilk bulgular oldukça umut vericidir. Bu modeller, öz-dikkat mekanizmasını kullanarak rüzgâr hızları, yönleri ve güç çıktıları arasındaki karmaşık ilişkileri etkili bir şekilde modelleyebilmekte, bu da daha doğru ve güvenilir tahminler yapmalarına olanak tanımaktadır [56].

İki aşamalı bir Transformer modeli, önce rüzgâr parametrelerini tahmin ederek ve ardından bu tahminleri rüzgâr gücü üretimini öngörmek için kullanarak rüzgâr gücü tahmin doğruluğunda önemli bir ilerleme kaydetmektedir. Bu yenilikçi yaklaşım, mevcut modellerden önemli ölçüde daha iyi performans göstermekte ve Ortalama Kare Hatasını, İyileştirilmiş LSTM ve BPNN Modeline kıyasla 73%'ün üzerinde, SARIMAX + RNN + SVR Modeline kıyasla 93% ve Wavelet Transform + NARMAX + PSO Modeline kıyasla 99,8% oranında azaltmaktadır. Bu durum, rüzgâr gücü tahmininde önerilen Transformer tabanlı yaklaşımın üstün doğruluğunu ve güvenilirliğini ortaya koymaktadır.

1.8 Araştırmanın Önemi

Bu araştırmanın önemi, yenilenebilir enerji tahmini, özellikle de rüzgâr gücü tahmini alanına potansiyel katkısında yatmaktadır. Rüzgâr enerjisi, küresel enerji karışımına önemli bir katkı olarak büyümeye devam ederken, doğru tahminlere duyulan ihtiyaç, elektrik şebekelerinin kararlılığını ve verimliliğini sağlamak için giderek daha kritik hale gelmektedir. Doğru rüzgâr gücü tahminleri, şebeke operatörlerinin enerji üretim programlarını optimize etmelerini, maliyetli yedek enerji kaynaklarına olan bağımlılığı azaltmalarını ve enerji dengesizlikleriyle ilişkili riskleri en aza indirmelerini sağlar.

Ayrıca bu araştırma, rüzgâr enerjisinin elektrik şebekelerine entegrasyonunun güvenilirliğini artırarak, sürdürülebilir enerji sistemlerine geçiş ve sera gazı emisyonlarını azaltma gibi daha geniş hedeflere de hitap etmektedir. Önerilen hibrit Transformer modeli, geleneksel istatistiksel yöntemlerin ve modern makine öğrenimi tekniklerinin güçlü yönlerini birleştirerek, rüzgâr gücü tahmini için yenilikçi bir yaklaşım sunmaktadır. Bu yaklaşımın, tahmin doğruluğunu artırması, işletme maliyetlerini düşürmesi ve yenilenebilir enerji kaynaklarının verimli yönetimine katkıda bulunması beklenmektedir.

1.9 Amaç ve Kapsam

Bu araştırmanın temel amacı, rüzgâr gücü tahmini için tahminlerin doğruluğunu ve güvenilirliğini artıran ve böylece rüzgâr enerjisinin elektrik şebekesine entegrasyonunu destekleyen yenilikçi bir hibrit Transformer tabanlı model geliştirmektir. Özellikle, bu çalışma aşağıdaki hedefleri ele almayı amaçlamaktadır:

- Hedef 1: Rüzgâr gücü tahmin doğruluğunu artırmak için geleneksel istatistiksel yöntemleri ileri düzey makine öğrenimi teknikleriyle birleştiren iki aşamalı bir hibrit Transformer modeli tasarlamak.
- Hedef 2: Önerilen modelin performansını birden fazla rüzgâr gücü veri setinde değerlendirerek, doğruluğunu mevcut en iyi tahmin modelleriyle karşılaştırmak.
- Hedef 3: Modelin enerji üretimini optimize etmeye, fosil yakıtlara bağımlılığı azaltmaya ve talep yanıt stratejilerini iyileştirmeye odaklanarak gerçek dünya şebeke yönetimi senaryolarında uygulanabilirliğini değerlendirmek.

Bu araştırmanın kapsamı, çeşitli rüzgâr gücü veri setlerinde hibrit modelin geliştirilmesi ve doğrulanmasını içerir. Çalışma, ayrıca önerilen modelin şebeke yönetimini iyileştirme, yedek enerji kaynaklarına duyulan ihtiyacı azaltma ve yenilenebilir enerji kaynaklarının şebekeye entegrasyonunu kolaylaştırma konularındaki potansiyel uygulamalarını da araştırmaktadır. Buna ek olarak, araştırma, hibrit Transformer modellerinin güneş enerjisi tahmini gibi diğer yenilenebilir enerji tahmin görevlerine uygulanması için gelecekteki yönleri de göz önünde bulundurmaktadır.

1.10 Gelecekteki Araştırma Yönleri

Rüzgâr gücü tahmininde kaydedilen ilerlemeye rağmen, bazı araştırma zorlukları devam etmektedir. Öncelikli alanlardan biri, doğruluktan ödün vermeden eksik veya gürültülü verileri işleyebilen daha sağlam modellerin geliştirilmesidir. Bu ihtiyaç, özellikle sınırlı meteorolojik verilere sahip bölgelerde kritik öneme sahiptir. Veri artırma tekniklerinin ve gelişmiş ön işleme yöntemlerinin geliştirilmesi, bu sorunu çözmede önemli bir rol oynayabilir.

Bir diğer önemli araştırma alanı da gerçek zamanlı tahminde Transformatör modellerinin uygulanmasıdır. Transformatör mimarileri önemli bir potansiyel gösterse de, gerçek zamanlı senaryolardaki uygulamaları hala sınırlıdır. Gelecekteki araştırmalar, gerçek zamanlı kullanım için optimize edilmiş daha verimli Transformatör mimarileri geliştirmeye odaklanmalıdır.

Ayrıca, daha yorumlanabilir tahmin modellerine olan talep artmaktadır. Transformatörler de dahil olmak üzere makine öğrenimi modelleri tahmin doğruluğunda önemli iyileştirmeler sağlasa da karmaşıklıkları nedeniyle genellikle "kara kutular" olarak tanımlanmaktadır. Şebeke operatörlerinin ve karar vericilerin güvenini kazanmak için, rüzgâr gücü tahmin modelleri için açıklanabilir yapay zekâ tekniklerinin geliştirilmesi kritik öneme sahip olacaktır. Araştırma çabaları, yorumlanabilirliği doğrudan model tasarımına entegre etmeye veya model tahminlerine ilişkin içgörü sağlayan açıklama sonrası yöntemler geliştirmeye odaklanabilir.

Rüzgâr gücü tahmin yöntemlerinin evrimi, rüzgâr gücünü elektrik şebekesine entegre etmenin artan karmaşıklığını yansıtır. Özellikle Transformatör mimarilerini içeren hibrit modeller, rüzgâr verilerindeki karmaşık zamansal bağımlılıkları yakalama yetenekleri nedeniyle gelecekteki araştırmalar için umut verici bir yön sunar. Ancak,

literatürde veri kalitesi, gerçek zamanlı tahmin yetenekleri ve model yorumlana bilirligi konusunda hala boşluklar bulunmaktadır. Bu boşlukları ele almak, rüzgâr gücü tahminlerinin doğruluğunu ve güvenilirliğini iyileştirmek ve yenilenebilir enerji kaynaklarının yaygın olarak benimsenmesini ve büyümesini desteklemek için kritik öneme sahiptir.



2. TRANSFORMER MODELLERİ

Bu bölüm, Hibrit Transformer modelinin rüzgâr gücü tahmininde geliştirilmesi ve uygulanmasını anlamak için gerekli olan temel teorileri ve teknik yönleri sunmaktadır. Tartışma, bu araştırmada kullanılan modelin temelini oluşturan makine öğrenimi ve derin öğrenme alanındaki temel kavramların ayrıntılı bir incelemesiyle başlar. Bu kavramlar arasında sinir ağları, Uzun Kısa Süreli Hafıza ağları ve Transformer modelleri bulunmaktadır. Bu tekniklerin her biri, rüzgâr gücü tahminlerinde içsel olan karmaşık ve doğrusal olmayan ilişkilerin ele alınmasında kritik bir rol oynamaktadır.

2.1 Makine Öğrenimi ve Derin Öğrenmenin Temelleri

Makine öğrenimi ve derin öğrenme, rüzgâr gücü tahmini de dahil olmak üzere modern veri odaklı yaklaşımların önemli bileşenleridir. Bu teknolojiler, büyük veri kümelerinden öğrenme yetenekleri ve karmaşık desenleri tespit edebilme kapasiteleri sayesinde yüksek doğrulukta tahminler yapabilen gelişmiş modellerin geliştirilmesine olanak tanır. Bu bölümde, bu çalışmada geliştirilen hibrit modelin temelini oluşturan kritik kavramlar ve mimariler hakkında genel bir bakış sunulacaktır [57].

2.2 Random Forest (Rastgele Orman) Algoritması

Random Forest, çok yönlülüğü, yüksek doğruluk oranı ve farklı veri türlerini işleme yeteneği nedeniyle geniş bir kullanım alanına sahip olan güçlü bir topluluk öğrenme yöntemidir.

Breiman tarafından 2001 yılında tanıtılan Random Forest, eğitim sürecinde birden fazla karar ağacı oluşturur ve bu ağaçların sınıflandırma için çoğunluk oyu veya regresyon için ortalama tahmini sonuç olarak verir. Bu yaklaşım, "kalabalığın bilgeliği" prensibinden yararlanarak, birden fazla modelin birleştirilmesinin aşırı uyumu azaltabileceği ve modelin genelleme yeteneğini artırabileceği fikrine dayanır. Rüzgâr gücü tahmini gibi zaman serisi tahmin görevlerinde, Random Forest yalnızca doğru tahminler sağlamakla kalmaz, aynı zamanda veri setindeki gürültüyü etkili bir şekilde azaltma kabiliyetiyle de dikkat çeker [58].

Random Forest, karar ağaçlarına dayanan bir topluluk (ensemble) yöntemidir ve her bir ağaç, eğitim verilerinin rastgele bir alt kümesi ve özelliklerin rastgele bir alt kümesi kullanılarak oluşturulur. Bu rastgelelik, ağaçlar arasında çeşitlilik yaratarak,

topluluğun genel olarak bireysel hatalara ve veri setindeki önyargılara karşı daha dayanıklı olmasını sağlar [59].


Random Forest oluşturma ana adımları şunlardır:

- Bootstrap Örnekleme: Ormandaki her ağaç için, orijinal veri setinden yedeklemeli olarak rastgele bir örnek (bootstrap örneği) seçilir. Bu, her bir ağacın benzersiz bir eğitim seti üzerinde eğitilmesini sağlar ve modelin genelleme yeteneğini artırır [60].

- Özellik Rastgeleliği: Her bir karar ağacının her bölünme noktasında, özelliklerin rastgele bir alt kümesi seçilir ve bu alt kümeden en iyi bölünme noktası belirlenir. Bu, ağaçlar arasındaki korelasyonu azaltarak modelin daha iyi genelleme yapmasına katkıda bulunur [61].

- Birleştirme (Agregasyon): Son tahmin, tüm ağaçların tahminlerinin birleştirilmesiyle yapılır. Sınıflandırma görevlerinde bu, genellikle çoğunluk oylaması ile, regresyon görevlerinde ise tahminlerin ortalaması alınarak gerçekleştirilir [62].

Random Forest, büyük veri setlerini işleyebilme kapasitesi, yüksek boyutlu veri alanlarında çalışabilme yeteneği ve daha az parametre ayarı ile yüksek doğruluk sağlaması nedeniyle birçok uygulama için cazip bir seçenek olarak öne çıkmaktadır. Ayrıca, veri setlerindeki gürültüyü azaltmada etkin bir rol oynar [63].



Şekil 2.1. Random Forest Algoritma Diyagramı.

2.2.1 Gürültü Azaltma İçin Random Forest Kullanımı

Verideki gürültü, doğru tahmin yapmak için gerekli olan temel desenleri gizleyebilen rastgele değişiklikler veya gereksiz bilgilere atıfta bulunur. Rüzgâr gücü tahminlerinde kullanılan zaman serisi verilerinde, gürültü; sensör hataları, çevresel etkiler veya tahmin modeline anlamlı katkı sağlamayan rastgele dalgalanmalar gibi çeşitli kaynaklardan ortaya çıkabilir.

Gürültü Azaltma Aracı Olarak Random Forest: Random Forest, topluluk yapısı ve birden fazla karar ağacından tahminleri ortalama alarak yumuşatma yöntemiyle gürültü azaltmada oldukça etkilidir. Bu yöntemin temel prensipleri şunlardır:

- **Aykırı Değerlere Dayanıklı:** Random Forest, her bir ağaç için orijinal veri setinden rastgele seçilmiş bootstrap örnekleri kullanarak inşa edilir. Bu nedenle, verideki bazı aykırı değerler veya gürültüler her ağaçta yer almayabilir. Bu durum, hatalı verilerin etkisini topluluk genelinde seyrelterek nihai tahmin üzerindeki etkilerini azaltır [64].
- **Ortalama Alma Etkisi:** Birden fazla ağacın çıktılarının ortalamasını alarak, Random Forest tahminleri yumuşatır ve gürültülü verilerin neden olabileceği dalgalanmaları azaltır. Her bölünme noktasında rastgele özellik seçimi, modelin öğrenme sürecinde gürültünün baskın olmasını engeller [65].
- **Özellik Önemi ve Gürültü Filtreleme:** Random Forest, modelde kullanılan her bir özelliğin tahmin üzerindeki etkisini ölçmek için bir önem derecesi belirler. Bu ölçüm, modelin gürültüye neden olan veya tahmin doğruluğuna katkı sağlamayan özellikleri tespit edip elemesini sağlar. Bu şekilde, model daha çok önemli ve anlamlı özelliklere odaklanarak, gürültünün olumsuz etkilerini azaltabilir [66].
- **Topluluk Ortalama Alma ile Gürültü Azaltma:** Gürültülü veri setlerinde, bireysel karar ağaçları verideki rastgele dalgalanmalara fazla tepki vererek aşırı uyumlu sonuçlar üretebilir. Ancak, Random Forest'ın ortalama alma mekanizması, farklı veri alt kümeleri ve özelliklerle oluşturulan birçok ağacın çıktısını birleştirerek bu sorunu hafifletir. Bu yaklaşım, rastgele gürültüyü etkili bir şekilde dengeler ve daha istikrarlı, daha doğru tahminler sağlar [67].

2.2.2 Rüzgâr Gücü Tahmininde Random Forest Uygulaması

Rüzgâr gücü tahmininde Random Forest kullanımı, gürültü azaltma açısından önemli faydalar sunar. Rüzgâr verileri oldukça değişken olabilir ve birçok öngörülemeyen faktörden etkilenebilir. Random Forest kullanılarak, model bu gürültüyü filtreleyebilir ve böylece tahminlerin doğruluğunu ve güvenilirliğini artırabilir. Örneğin, dalgacık dönüşümleri gibi diğer ön işleme teknikleriyle birleştirildiğinde, Random Forest gürültü azaltma yeteneklerini daha da artırabilir ve rüzgâr gücü üretiminin daha doğru tahminlerini elde edebilir [68].

Random Forest, verilerdeki doğrusal olmayan ilişkileri işleme yeteneğine sahiptir ve bu da onu doğrusal modellerin yetersiz kalabileceği rüzgâr gücü tahmininin karmaşık dinamikleri için ideal hale getirir. Meteorolojik faktörler arasındaki etkileşimlerin tam spektrumunu yakalamak, bu modelin güçlü yönlerinden biridir [69].

Random Forest, makine öğreniminde güçlü bir araçtır çünkü gürültüyü azaltmada ve tahmin doğruluğunu iyileştirmede özellikle etkili olan bir topluluk yaklaşımı sunar. Aykırı değerlere karşı sağlamlığı, önemli özelliklerin seçimi ve ortalama yöntemi, onu rüzgâr gücü tahmin modellerinde veri kalitesini iyileştirmek için ideal bir seçim haline getirir. Gürültüyü etkili bir şekilde azaltarak, Random Forest yenilenebilir enerji sistemlerinde güç üretimini optimize etmeye ve şebeke istikrarını sağlamaya yardımcı olan daha güvenilir ve doğru tahminler sağlar. Rüzgâr gücü tahmini daha gelişmiş modellerin entegrasyonu ile gelişmeye devam ederken, Random Forest özellikle gürültülü ve karmaşık veri kümelerini içeren görevlerde veri bilimcileri ve mühendisleri için değerli bir araç olmaya devam ediyor.

2.3 Sinir Ağları

NN'ler, makine öğrenimi ve derin öğrenmenin temel yapı taşları arasında yer alır. Bu ağlar, insan beyninin yapısını ve çalışma şeklini taklit ederek, veri işleyen ve çıktılar üreten yapay nöronların katmanlarından oluşur. Her bir nöron, kendisine gelen giriş bilgilerine bir matematiksel fonksiyon uygular ve bu sonucu bir sonraki katmana iletir. Sinir ağı, tahmin edilen çıktı ile gerçek hedef arasındaki hata oranını minimize ederek ağırlıklarını optimize eder; bu süreç eğitim olarak adlandırılır [70].

2.3.1 İleri Beslemeli Sinir Ağları

FNN, en temel sinir ağı türlerinden biridir ve verilerin giriş katmanından çıkış katmanına yalnızca tek yönlü olarak aktığı yapılardır. FNN'ler, çeşitli sınıflandırma ve regresyon görevlerinde güçlü performans gösterir, ancak zamansal bağımlılıklar veya bağlam bilgisi gerektiren sıralı verilerle çalışmakta zorlanabilirler. Bu durum, özellikle geçmiş rüzgâr modellerinin gelecekteki koşulları öngörmede kritik olduğu rüzgâr enerjisi tahminlerinde önemli bir sınırlamadır [71].

2.3.2 İleri Beslemeli Sinir Ağlarının Yapısı

Bir İleri Beslemeli Sinir Ağı, sıralı olarak düzenlenmiş birden fazla nöron katmanından oluşur. Bu katmanlar üç ana kategoriye ayrılır:

- **Giriş Katmanı:** Bu katman, ağı dış dünyadan aldığı verileri işler. Her nöron, bir giriş özelliğini temsil eder. Örneğin, rüzgâr gücü tahmininde bu katmandaki nöronlar, rüzgâr hızı, sıcaklık, nem gibi çevresel verileri ve geçmiş enerji üretim verilerini işleyebilir.
- **Gizli Katmanlar:** Giriş ve çıkış katmanları arasında yer alan bir veya daha fazla gizli katman bulunur. Bu katmanlar, giriş verilerine doğrusal olmayan dönüşümler uygulayarak, ağı karmaşık desenleri ve ilişkileri öğrenmesini sağlar. Gizli katmanlardaki nöronlar, bir önceki katmandan aldıkları bilgiyi ağırlıklı bir şekilde toplar, bir aktivasyon fonksiyonundan geçirir ve sonucu bir sonraki katmana iletir. Gizli katmanların sayısı ve her katmandaki nöron sayısı, çözülmek istenen problemin karmaşıklığına göre değişir.
- **Çıktı Katmanı:** Son katman, ağı nihai çıktısını üretir. Sınıflandırma görevlerinde bu katmanda, her biri bir sınıfı temsil eden birden fazla nöron olabilir. Regresyon görevlerinde ise genellikle sürekli bir değer üreten tek bir nöron bulunur. Bu nöron, örneğin tahmin edilen rüzgâr gücü üretimi gibi bir çıktıyı hesaplar.



Şekil 2.2. ffn mimarisi

2.3.3 İleri Beslemeli Sinir Ağlarının Çalışma Mekanizması

FFN çalışması iki ana aşamada gerçekleşir: ileri yayılım ve geri yayılım.

- **İleri Yayılım:** Bu aşamada, giriş verileri ağın giriş katmanından alınıp çıkış katmanına kadar taşınır. Her gizli katmandaki nöron, giriş verilerini belirli ağırlıklarla çarpar, sonuçları toplar ve doğrusal olmayan bir aktivasyon fonksiyonundan geçirir. Yaygın olarak kullanılan aktivasyon fonksiyonları arasında ReLU , Sigmoid ve Tanh bulunur. Bu işlemler sonucunda üretilen değerler, ağın çıktısını belirlemek için çıkış katmanına iletilir [72].

- **Geri Yayılım ve Eğitim:** Ağın tahmini, gerçek hedef değer ile karşılaştırılır ve hata miktarı bir kayıp fonksiyonu kullanılarak hesaplanır (örneğin, Ortalama Kare Hatası). Geri yayılım yöntemi, bu hatayı en aza indirmek için ağıdaki ağırlıkların ayarlanmasına olanak tanır. Bu işlem, kayıp fonksiyonunun türevlerinin hesaplanması ve ağırlıkların gradyan inişi gibi optimizasyon teknikleri kullanılarak güncellenmesiyle gerçekleştirilir. Bu süreç birçok kez tekrarlanarak ağın tahmin doğruluğu artırılır [73].

2.3.4 Rüzgâr Gücü Tahmininde İleri Beslemeli Sinir Ağlarının Kullanımı

Rüzgâr gücü tahmini bağlamında, FFN, çeşitli girdi özellikleri ile gelecekteki rüzgâr gücü üretimi arasındaki ilişkileri modellemek için kullanılır. Gelişmiş modeller, LSTM ve Transformatörler gibi zaman serisi verilerini işleme kapasitesine sahip olsa da FFN'ler, girdiler ve çıktılar arasındaki ilişkilerin daha basit mimarilerle ele alınabildiği durumlarda hala yaygın olarak kullanılır [74].

Temel Uygulamalar:

- **Kısa Vadeli Rüzgâr Gücü Tahmini:** FFN'ler, giriş özelliklerinin güncel ve yakın zamandaki meteorolojik verilere dayandığı kısa vadeli tahminlerde etkili bir şekilde kullanılır. Yapılarının basitliği, bu ağları hesaplama açısından verimli kılar ve hızlı tahminler gerektiren durumlar için uygun hale getirir [75].
- **Veri Ön İşleme ve Özellik Çıkarımı:** FFN'ler, ham verilerin işlenmesi ve özelliklerin çıkarılması gibi ön hazırlık işlemlerinde diğer daha karmaşık modellerle birlikte kullanılabilir. Örneğin, bir FFN, ham girdi verilerini, LSTM veya Transformatör gibi modellerin daha iyi işleyebileceği özelliklere dönüştürebilir [76].
- **Toplu Modeller:** FFN'ler, toplu modelleme yaklaşımlarının bir parçası olarak, diğer sinir ağı türleri veya makine öğrenimi algoritmaları ile birleştirilebilir. Birden fazla modelin çıktılarının ortalamasını alarak, toplu modeller hem varyansı azaltabilir hem de veri setindeki ana eğilimleri daha iyi yakalayabilir [77].

2.3.5 Rüzgâr enerjisi üretim tahmininde FFN'nin avantajları

Avantajları:

- **Basitlik:** FFN'ler, modelleri uygulamak ve eğitmek için kolaydır ve bu da onları birçok tahmin görevi için erişilebilir bir seçenek haline getirir.
- **Hesaplama Verimliliği:** Daha karmaşık modellerle karşılaştırıldığında, FFN'ler daha az hesaplama gücü gerektirir ve bu da onları kaynak sınırlı uygulamalar için uygun hale getirir.
- **Esneklik:** FFN'ler, regresyon ve sınıflandırma görevleri dahil olmak üzere çok çeşitli sorunlara uygulanabilir.

2.3.6 Rüzgâr Enerjisi Tahmini için FFN'lerin Geliştirilmesi


FFN'ler belirli uygulamalar için etkili olsa da zamansal bağımlılıkları ele alma konusundaki sınırlamaları, bunları diğer tekniklerle birleştirerek hafifletilebilir. Örneğin, FFN'ler, ardışık veriler için daha uygun olan RNN'ler veya Transformatörler gibi modellerle çalıştıkları hibrit modellerde kullanılabilir. Ayrıca, aşırı uyumu azaltmak ve görülmemiş verilere genelleme yapma yeteneğini artırmak için FFN'lere bırakma, ağırlık düzenleme ve erken durdurma gibi teknikler uygulanabilir.

FFN'ler, rüzgâr gücü tahmini de dahil olmak üzere çeşitli görevler için basitlik ve esneklik sunan temel bir makine öğrenimi modelidir. Sıralı verileri işlemedeki sınırlamalarına rağmen, ön işleme, özellik çıkarma ve topluluk veya hibrit modellerdeki bileşenler olarak rolleri, onları bir veri bilimcisinin araç setinde vazgeçilmez bir araç haline getirir. Araştırmacılar, FFN'lerin güçlü ve zayıf yönlerini anlayarak, rüzgâr gücü tahmini bağlamında yeteneklerini en iyi şekilde değerlendirebilir ve tahminlerin hem doğru hem de hesaplama açısından verimli olmasını sağlayabilirler.

2.4 Rüzgâr Enerjisi için Transformatör Modellerinde LSTM Ağlarının

Kullanımı LSTM ağları, özellikle kaybolan ve patlayan eğimler olmak üzere uzun vadeli bağımlılıkları öğrenmenin zorluklarının üstesinden gelmek için tasarlanmış özel bir RNN türüdür. LSTM'ler, uzun veri dizileri segmentleri boyunca bilgileri depolamalarına ve seçici olarak güncellemelerine olanak tanıyan bellek hücrelerine sahiptir ve bu da onları rüzgâr enerjisi üretimi gibi zaman serisi tahmin görevleri için özellikle etkili hale getirir [78].

Bu araştırma bağlamında, LSTM'ler Transformatör modellerine entegre edilmiştir ve böylece sıralı verileri işleme yetenekleri artırılmıştır. Transformatörler, kendi kendine dikkat mekanizmalarıyla zaman serisi tahminini ve diğer sıralı veri görevlerini devrim niteliğinde değiştirmiş olsa da, bazen LSTM'lerin doğal olarak ele aldığı ince zamansal bağımlılıkları yakalamakta zorlanırlar. LSTM katmanını Transformer mimarisine dahil ederek, model her iki yaklaşımın güçlü yönlerinden yararlanır: LSTM'nin zaman içinde bilgi depolama yeteneği ve Transformer'ın tüm dizi boyunca karmaşık, uzun vadeli bağımlılıkları ve ilişkileri modelleme kapasitesi [79].



Şekil 2.3. lstm katmanı

2.4.1 Hibrit Transformer Modellerinde LSTM'nin Rolü

Bu hibrit mimaride, LSTM katmanı tipik olarak ardışık verileri Transformer'ın öz-dikkat katmanlarına geçmeden önce ön işlemek veya kodlamak için kullanılır. LSTM katmanı, rüzgâr hızı veya güç çıkışı gibi giriş zaman serisi verilerini işler ve hem kısa vadeli dalgalanmaları hem de uzun vadeli eğilimleri yakalar. Bu zamansal bağımlılıkları kapsayan LSTM katmanının çıktısı daha sonra Transformer katmanlarına beslenir. Bu ardışık işleme, Transformer'ın veriler içindeki daha geniş kalıpları ve ilişkileri modellemeye odaklanmasını sağlarken, LSTM katmanı ayrıntılı zamansal yapıyı işler [80].

2.4.2 Rüzgâr Gücü Tahminindeki Uygulamalar

Rüzgâr gücü tahmininde, meteorolojik değişkenler arasındaki karmaşık zamansal ilişkileri yakalamak, doğru tahminler yapmak için hayati önem taşır. LSTM ve Transformer modellerinin hibrit kullanımı, LSTM'nin zamansal işleme gücünü ve Transformer'ın diziler arasındaki karmaşık ilişkileri ele alma yeteneğini birleştirerek daha sağlam ve doğru bir tahmin modeli sağlar. Bu yaklaşım, rüzgâr desenlerinin hem ani kısa vadeli değişiklikler hem de rüzgâr gücü üretim verilerinde yaygın olan uzun vadeli eğilimler sergilediği senaryolarda özellikle yararlıdır [81].

LSTM katmanlarını Transformer modellerine entegre etmek, rüzgâr gücü tahmini de dahil olmak üzere zaman serisi tahmin görevlerinin performansını iyileştirmek için

güçlü bir yaklaşımdır. LSTM'lerin zamansal duyarlılığını Transformers'ın küresel dikkat yetenekleriyle birleştirerek, bu hibrit model rüzgâr gücü verilerinin ince dinamiklerini daha etkili bir şekilde yakalayabilir ve daha doğru ve güvenilir tahminler yapabilir. LSTM'ler ve Transformers arasındaki sinerji, karmaşık, ardışık veri odaklı uygulamalar için makine öğrenimi modellerinin devam eden evriminde önemli bir yeniliği temsil eder.

2.4.3 LSTM ve Transformatör Modellerini Birleştirmenin Avantajları

- Geliştirilmiş Zamansal Dinamikler: LSTM'nin geçmiş girdileri tutma yeteneği, Transformatör modellerinin olayların sırasının ve zamanlamasının kritik olduğu görevlerde, örneğin rüzgâr desenlerindeki ani değişiklikleri tahmin etmede daha iyi performans göstermesini sağlar.
- Geliştirilmiş Sıra Gösterimi: Sıra verilerini önce bir LSTM katmanı ile işleyerek, sonraki Transformatör katmanları daha bilgilendirici ve bağlamsal olarak farkında bir girdi alır ve bu da modelin genel performansını iyileştirir.
- Transformatör Sınırlamalarının Hafifletilmesi: Transformatörler güçlü olsa da verilerin sıralı sırasının kritik olduğu senaryolarda bazen yetersiz kalabilirler. LSTM katmanlarının dahil edilmesi, veriler Transformatör katmanlarına ulaşmadan önce zamansal sırayı ve bağımlılıkları açıkça modelleyerek bu sınırlamayı hafifletir [82].

2.5 Transformer Modelleri

LSTM'ler birçok ardışık tahmin görevinde etkili olduklarını kanıtlamış olsalar da bazı sınırlamalara sahiptirler. Bu sınırlamalardan biri, ardışık işlemeye olan bağımlılıklarıdır, bu da özellikle uzun dizilerde hesaplama açısından pahalı ve yavaş olabilir. Transformer modellerinin tanıtılması, bu sınırlamaların üstesinden gelmekte önemli bir ilerleme kaydetti. İlk olarak doğal dil işleme (NLP) için geliştirilen Transformer'lar, o zamandan beri zaman serisi tahmini de dahil olmak üzere geniş bir yelpazedeki uygulamalar için uyarlanmıştır [32].

Transformer'lar, RNN'lerden ve LSTM'lerden, girdilerin dizideki konumlarından bağımsız olarak, modelin girdi verilerinin farklı bölümlerinin önemini değerlendirmesini sağlayan kendi kendine dikkat (self-attention) mekanizmalarını kullanmalarıyla ayrılırlar. Bu, Transformer'ların LSTM'lerden daha verimli bir şekilde verilerdeki karmaşık bağımlılıkları yakalamasını sağlar, çünkü dizileri ardışık olarak değil, paralel olarak işleyebilirler. Kendi kendine dikkat mekanizması, tüm giriş

değerlerinin ağırlıklı bir toplamını hesaplar, burada ağırlıklar her giriş değerinin mevcut çıktı için ne kadar ilgili olduğuna göre belirlenir. Bu yaklaşım, Transformer'ı uzak veri noktaları arasındaki ilişkileri etkili bir şekilde modellemesine olanak tanır, bu da gelecekteki rüzgâr koşullarını etkileyebilecek çeşitli meteorolojik faktörler ve zaman gecikmelerinin olduğu rüzgâr gücü tahmininde özellikle faydalıdır.

2.5.1 Transformatör Mimarisi Genel Bakış

Bir Transformatör modeli genellikle bir kodlayıcı-kod çözücü yapısından oluşur. Ancak birçok uygulamada, özellikle zaman serisi tahmininde, yalnızca kodlayıcı bileşeni bağımsız olarak kullanılır. Modelin mimarisi, her biri iki ana bileşenden oluşan birden fazla kodlayıcı katmanından oluşur: çok başlı bir öz-dikkat mekanizması ve mekansal olarak bağımsız, tam bağlı bir ileri besleme ağı.

Kodlayıcı mimarisi:

- **Öz-Dikkat Mekanizması:** Öz-dikkat mekanizması, Transformatör modelinin temel yeniliğidir. Modelin giriş dizisinin farklı öğelerinin göreceli önemini değerlendirmesine olanak tanır. Dizileri adımlar halinde işleyen RNN'ler ve LSTM'lerin aksine, öz-dikkat mekanizması tüm diziyi aynı anda işler ve dizideki iki öğe arasındaki ilişkileri konumlarından bağımsız olarak belirleyebilir. Zaman serisi tahmininde, uzun menzilli bağımlılıkları yakalama yeteneği, zaman açısından uzak olan olayların birbirini etkileyebileceği durumlarda özellikle değerlidir.


- **Çoklu Baş Dikkat:** Transformatör, verilerdeki ilişkilerin farklı yönlerini yakalamak için çoklu baş dikkat mekanizması kullanır. Bu, tek bir dikkat fonksiyonuna güvenmek yerine, modelin verilerin farklı gösterimlerini öğrenen birden fazla dikkat başı kullandığı anlamına gelir. Bu farklı baş daha sonra birleştirilir ve doğrusal olarak dönüştürülür, bu da modelin dizinin farklı bölümlerinin önemini değerlendirirken birden fazla bakış açısını dikkate almasına olanak tanır.

- **Konum Tabanlı İleri Beslemeli Ağlar:** Öz-dikkat katmanından sonra, her kodlayıcı dizideki her konuma bağımsız ve aynı şekilde uygulanan tamamen bağlı bir ileri beslemeli ağ içerir. Bu ağ, modele doğrusal olmayanlık katan ReLU aktivasyon fonksiyonuna sahip iki doğrusal dönüşümden oluşur. Transformatörün paralel işleme doğası nedeniyle sıralı bilginin kaybına rağmen, giriş verilerine konumsal kodlamalar eklenir ve modelin dizideki öğelerin göreceli konumlarını çıkarmasına olanak tanır ve sıralı bilgileri korumaya yardımcı olur.

- Konumsal Kodlama: Transformatör verileri doğası gereği sıralı olarak işlemediğinden, dizideki öğelerin sırasını çıkarsamak için bir yola ihtiyaç duyar. Konumsal kodlama bunu, dizideki konumunu kodlayan her giriş ögesine benzersiz bir vektör ekleyerek gerçekleştirir. Bu yaklaşım, modelin dikkat puanlarını hesaplarırken olayların sırasını hesaba katmasını ve böylece zaman serisi verilerinin sıralı yapısını korumasını sağlar.

Kod çözücü mimarisi:

- Maskelenmiş Çok Başlı Dikkat: Kod çözücüde, çok başlı dikkat mekanizması, modelin dizideki gelecekteki konumlara dikkat etmesini önlemek için eğitim sırasında hafifçe değiştirilir. Bu "maskeleme", modelin her konumda yaptığı tahminlerin yalnızca önceki öğelere bağlı olmasını sağlar; bu da dil üretimi ve tahmin gibi görevler için kritik öneme sahiptir.
- Kodlayıcı-Kod Çözücü Dikkat: Kod çözücü ayrıca, kodlayıcının giriş dizisinin ilgili bölümlerine odaklanmasını sağlayan ek bir dikkat mekanizması içerir. Bu dikkat mekanizması, modelin girdiyi çıktıyla hizalamasına yardımcı olur ve nihai tahminin girdi dizisinin en alakalı kısımları tarafından bilgilendirilmesini sağlar.



Şekil 2.4. Transformatör model mimarisini

2.5.2 Öz-Dikkat (Self-Attention) Mekanizması

Öz-Dikkat mekanizması, Transformer mimarisinin temel yapı taşlarından biridir ve modelin dizileri daha verimli bir şekilde işlemesini ve tüm dizi boyunca karmaşık bağımlılıkları yakalamasını sağlar. Bu mekanizma, modelin girdideki her öğenin diğer öğelere olan ilişkisini dinamik olarak değerlendirmesine olanak tanır. Böylece, uzak konumlarda bile olsa, ilgili bilgilerin dikkate alınmasını sağlar.


Öz-Dikkat Mekanizmasının İşleyişi:

- **Sorgu, Anahtar ve Değer Vektörleri:** Kendine dikkat mekanizmasının temelini sorgu (query), anahtar (key) ve değer (value) vektörleri oluşturur. Dizideki her bir öğe

için model, bu üç vektörü oluşturur. Sorgu vektörü, dikkati hesaplanan ögeyi temsil eder; anahtar vektörü, dikkatin yönlendirildiği ögeyi temsil eder; değer vektörü ise aktarılabacak bilgiyi taşır [83].

- Dikkat Puanları: Her bir öge çifti için dikkat puanları, sorgu ve anahtar vektörlerinin nokta çarpımı ile hesaplanır. Bu puanlar, anahtar vektörlerinin boyutunun karekökü ile ölçeklendirilir ve ardından softmax fonksiyonu ile normalleştirilir. Bu süreç, dikkat puanlarını olasılıklara dönüştürerek, her ögenin ne kadar önemli olduğunu belirler. Böylece, model hangi öğelere daha fazla odaklanması gerektiğini öğrenir [84].

- Ağırlıklı Toplam: Her bir pozisyon için nihai çıktı, değer vektörlerinin dikkat puanlarına göre ağırlıklı toplamı alınarak elde edilir. Bu, modelin sorgu tarafından sağlanan bağlama bağlı olarak dizinin farklı bölümlerini dinamik bir şekilde vurgulamasını sağlar. Böylece, model girdideki kritik bilgileri daha iyi temsil eder [85].



Şekil 2.5. Öz-Dikkat

2.5.3 Zaman Serisi Tahmini için Transformer Model Uygunluğu

Transformer modelinin Öz-Dikkat mekanizması ve benzersiz mimarisi, rüzgâr enerjisi tahmini de dahil olmak üzere zaman serisi tahminleri için çeşitli avantajlar sunar. Bu avantajlar, modelin özellikle karmaşık ve büyük ölçekli veri setleriyle çalışmasını kolaylaştırarak daha doğru ve güvenilir tahminler yapmasını sağlar [86].

- **Karmaşık Bağımlılıkları Yakalama:** Zaman serisi verileri, farklı zaman noktaları arasında karmaşık ve doğrusal olmayan ilişkiler içerebilir. Transformer modellerinde kullanılan kendine dikkat mekanizması, modelin dizideki çeşitli zaman noktalarının önemini değerlendirmesine olanak tanır. Bu mekanizma, zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalama yeteneği sunar ve bu da tahmin doğruluğunu artırır [87].

- **Eksik Verileri Ele Alma:** Gerçek dünya zaman serisi verilerinde eksik veri noktaları sıkça karşılaşılan bir sorundur. Transformer modelleri, sıralı işleme yöntemlerine sıkı sıkıya bağlı kalmak yerine, mevcut olan ilgili bilgilere odaklanarak bu boşlukları etkili bir şekilde doldurabilir. Bu esneklik, eksik veri noktalarından kaynaklanabilecek olumsuz etkileri azaltarak modelin genel performansını artırır [88].

- **Değişken Dizi Uzunluklarına Uyum:** Transformer modeli, önemli mimari değişikliklere ihtiyaç duymadan değişken uzunluktaki dizilere uyum sağlayabilir. Bu özellik, zaman serisi tahminlerinde, tahmin ufkuna bağlı olarak giriş dizisinin uzunluğunun değişebileceği durumlarda oldukça faydalıdır. Modelin bu esnekliği, geniş bir yelpazede farklı tahmin görevlerinde kullanılmasını mümkün kılar [89].

- **Geliştirilmiş Yorumlanabilirlik:** Kendine dikkat mekanizması tarafından üretilen dikkat puanları, modelin tahmin yaparken dizinin hangi bölümlerini en önemli gördüğüne dair içgörüler sağlar. Bu yorumlanabilirlik, rüzgâr gücü tahmini gibi uygulamalarda son derece değerlidir. Modelin karar verme sürecini anlamak, modelin ince ayarını yapmak ve paydaşlarla güven inşa etmek açısından önemlidir [90].

Transformer modelleri, uzun vadeli bağımlılıkları verimli bir şekilde yakalama, büyük veri setlerini işleme ve paralel işleme yetenekleriyle zaman serisi tahminleri için güçlü bir araç sunar. Rüzgâr gücü üretimi gibi karmaşık tahmin görevlerinde, bu mimari, ölçeklenebilirlik ve doğruluk açısından avantajlar sağlar. Yenilenebilir enerji alanında doğru ve güvenilir tahminlere olan talep arttıkça, Transformer modelleri modern tahmin tekniklerinin ön saflarında yer almaya devam edecektir.

3. HİBRİT MODEL MİMARİSİ VE ENTEGRASYON STRATEJİLERİ

3.1 Sinir Ağları, LSTM ve Hibrit Modellerin Entegrasyonu

Bu araştırmada önerilen hibrit model, rüzgâr enerjisi tahmininde bulunan çok yönlü zorlukları etkili bir şekilde ele almak için sinir ağlarının, LSTM katmanının ve Dönüştürücü modellerinin yeteneklerini stratejik olarak entegre eder. Hibrit mimarinin her bir bileşeni, rüzgâr enerjisi verilerinin karmaşıklığını ve değişkenliğini yakalamak için uygun olan tutarlı bir model oluşturmak için farklı güçlü yönler sunar.

Sinir Ağları, hibrit modelin temel çerçevesi olarak hizmet eder ve verilerde bulunan çeşitli ve genellikle doğrusal olmayan ilişkilerden öğrenmek için sağlam bir yapı sağlar. Esneklikleri ve uyarlanabilirlikleri, sinir ağlarını rüzgâr enerjisi üretimini etkileyen çeşitli girdi özelliklerini işlemek için önemli bir bileşen haline getirir.

LSTM katmanları, rüzgâr desenlerinde bulunan zamansal bağımlılıkları özel olarak ele almak için entegre edilmiştir. Büyük dizilerde bilgileri tutabilen bellek hücrelerini içeren benzersiz mimarileri sayesinde, LSTM'ler hem kısa vadeli dalgalanmaları hem de uzun vadeli eğilimleri modellemede özellikle etkilidir. Bu yetenek, olayların sırasını ve zamanlamasını anlamının doğru tahminler yapmak için elzem olduğu rüzgar enerjisi tahmininde çok önemlidir.

Transformatör Modelleri, büyük veri kümeleri arasında uzun vadeli bağımlılıkları ve ilişkileri yakalamak için güçlü bir mekanizma sağlayarak hibrit mimariyi daha da geliştirir. Transformatörün kendi kendine dikkat mekanizması, modelin sıralamadaki konumlarından bağımsız olarak çeşitli girdi özelliklerinin önemini dinamik olarak tartmasına olanak tanır. Bu yetenek, çeşitli meteorolojik değişkenlerin rüzgâr enerjisi üretimini etkilemek için doğrusal olmayan şekillerde etkileşime girdiği rüzgâr enerjisi tahmininde özellikle değerlidir.


Bu hibrit modelde, LSTM katmanı rüzgâr enerjisi verilerinin zamansal dinamiklerini kodlamaktan sorumludur ve hem kısa hem de uzun vadeli bağımlılıkların doğru bir şekilde yakalanmasını sağlar. Kodlanan veriler daha sonra farklı meteorolojik değişkenler arasındaki karmaşık ilişkileri ve bunların rüzgâr enerjisi üretimi üzerindeki toplu etkilerini modellemeye odaklanan Transformatör bileşenine geçirilir. Transformatörün büyük veri kümelerini daha yüksek hesaplama verimliliğiyle işleme

yeteneğinden yararlanarak, model çeşitli bilgi kaynaklarını etkili bir şekilde entegre edebilir ve daha doğru tahminler üretebilir.

Bu hibrit yaklaşım, özellikle geleneksel modellerin verilerin karmaşıklığı ve değişkenliğiyle mücadele edebileceği senaryolarda tahmin doğruluğunu artırmak için tasarlanmıştır.

3.2 Hibrit Model Genel Bakış

Bu çalışma, ultra kısa vadeli rüzgâr gücü tahmininin doğruluğunu artırmak için birden fazla gelişmiş makine öğrenimi tekniğini entegre eden bir hibrit model sunmaktadır. Model, veri ön işleme, özellik mühendisliği ve Random Forest Regresyonu , Birinci Transformer Modeli ve İkinci Transformer Modeli gibi bir dizi tahmin modeli kombinasyonunu kullanmaktadır. Şekil (6), hibrit model için bir akış diyagramı göstermektedir.



Şekil 3.1. Hibrit dönüşüm modeli akış şeması.

3.3 Hibrit Transformatör Model Mimarisi

3.3.1 Hava Tahmini için İlk Transformatör Modeli

İlk Transformatör Modeli hava durumu tahmini için tasarlanmıştır ve ileri beslemeli sinir ağları ile Uzun Kısa Süreli Bellek ağlarını birleştiren karmaşık bir mimari içerir.

LSTM Katmanı: İlk Transformatör Modelindeki LSTM katmanı, sıralı verilerdeki zamansal bağımlılıkları yakalamak için kritik bir bileşendir. LSTM ağları, özellikle uzun dizilerle çalışırken geleneksel Tekrarlayan Sinir Ağlarının eğitimini engelleyebilen kaybolan eğim sorununu ele almak için tasarlanmış bir RNN türüdür.

Uzun Kısa Süreli Bellek ağı, ağı içindeki bilgi ve eğim akışını düzenleyen bir kapı mekanizması aracılığıyla kaybolan eğim sorununu çözer. Unutma kapısı, önceki hücre durumundan hangi bilginin atılacağını belirler ve şu şekilde gösterilir:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad [3.1]$$

Burada f_t unutma kapısıdır, σ sigmoid aktivasyon fonksiyonunu belirtir, W_f ağırlık matrisidir, h_{t-1} önceki gizli durumdur, x_t mevcut giriştir ve b_f önyargı terimidir. Giriş kapısı, hücre durumundaki bilgi güncellemelerini kontrol eder ve aktivasyonu şu şekilde sağlanır:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad [3.2]$$

Burada i_t giriş kapısı vektörüdür ve W_i, b_i karşılık gelen ağırlıklar ve önyargılardır. Aday hücre durumu şu şekilde hesaplandı:

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad [3.3]$$

Burada C_t aday hücre durumudur, W_c ve b_c aday hücre durumu için ağırlıklar ve önyargılardır.

$$C = f_t * C_{t-1} + i_t * C_t \quad [3.4]$$

Burada C yeni hücre durumudur, C_{t-1} önceki hücre durumudur, $*$ eleman bazında çarpmayı ifade eder. Çıkış kapısı, çıkışı geçerli zaman adımı belirler ve gizli durumu, aktivasyonu şu şekilde açıklanan şekilde günceller:

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad [3.5]$$

Burada O_t çıkış kapısı vektörüdür W_o, b_o ağırlıklar ve önyargılardır.

Gizli durumda şu şekilde verilir:

$$h_t = o_t * \tanh(C_t) \quad [3.6]$$

Burada h_t mevcut gizli durumdur.

LSTM'nin Birinci Transformer Modelinde kullanılması, modelin uzun vadeli bağımlılıkları öğrenmesini ve saklamasını sağlar. Bu, doğru hava durumu tahmini ve rüzgâr gücü tahmini için gereklidir. Verilerin ardışık yapısını etkili bir şekilde yakalayarak, LSTM katmanı modelin daha kesin tahminler üretme yeteneğine katkıda bulunur.

Çok Kafa Dikkat Mekanizması: Birinci Transformer Modeli, LSTM katmanının ardından çok kafa bir dikkat (multi-head attention) mekanizması kullanarak rüzgâr gücü tahminini iyileştirir. Bu mekanizma, modelin hava durumu verisi dizisinin farklı bölümlerine aynı anda odaklanmasına olanak tanır, bu da özellikler arasındaki karmaşık etkileşimleri yakalar ve dikkat ağırlıkları aracılığıyla yorumlanabilirliği artırır. Çok kafalı dikkatin paralel işleme doğası, modelin zamansal verinin çeşitli ilgili yönlerini verimli bir şekilde değerlendirmesini sağlayarak daha iyi performansa yol açar.

$$\text{ÇokKafa}(Q, K, V) = \text{birleştirm}(kafa_1, \dots, kafa_h)W^o \quad [3.7]$$

Her bir kafa şu şekilde hesaplanır:

$$kafa_i = \text{dikkat}(QW_i^q, KW_i^k, VW_i^v) \quad [3.8]$$

Burada QW_i^q, KW_i^k, VW_i^v öğrenilmiş projeksiyon matrisleridir, W^o çıktı projeksiyon matrisidir.

LSTM ve çok kafalı dikkat mekanizmalarının Birinci Transformer Modeline entegrasyonu, modelin ardışık verileri işleme ve doğru tahminlerde bulunma yeteneğini önemli ölçüde artırır. Bu, bu gelişmiş sinir ağı bileşenlerinin birleşik bir çerçevede birleştirilmesinin gücünü gösterir.

3.3.2 İleri Beslemeli Sinir Ağı

FFN, birinci transformer modelinin çıktısını daha da iyileştirmek için kullanılır. Birinci modelden alınan hava durumu tahminlerini girdi olarak alır ve tahmin doğruluğunu artırmak için bu tahminleri daha ileri düzeyde işler.

$$FFN(x) = \max(0, xw_1 + b_1)w_2 + b_2 \quad [3.9]$$

Burada w_1, w_2 ağırlık matrisleridir b_1, b_2 önyargı terimleridir, $\max(0,.)$ ReLU aktivasyon fonksiyonunu temsil eder. Bu adım, başlangıç tahminlerinden kaynaklanan herhangi bir kalıntı hatanın son güç tahmin aşamasından önce en aza indirilmesini sağlar.

3.3.3 Güç Tahmini için İkinci Transformer Modeli

İkinci Transformer Modeli, güç üretimini tahmin etmek için iyileştirilmiş hava durumu tahminlerini orijinal girdi özellikleriyle birleştirir. Bu model, statik kovaryatlar ve dinamik özellikleri birleştiren bir Transformer mimarisi kullanır.

Statik Kovaryat Kodlayıcı (Static Covariate Encoder): Statik kovaryatlar, statik kodlamalar oluşturmak için yoğun katmanlar (dense layers) ve toplu normalizasyon (batch normalization) aracılığıyla işlenir. Bu kodlamalar, zamanla sabit kalan verinin statik özelliklerini yakalamada yardımcı olur. Bu süreç, aşağıdaki gibi matematiksel olarak tanımlanabilir:

$$s' = \text{ReLU}(W_s \cdot s + b_s) \quad [3.10]$$

Burada s statik değişkenlerin vektörüdür, W_s statik değişkenlerin vektörüdür, b_s önyargı vektörüdür, s' dönüştürülmüş statik unsurlardır.

LSTM Katmanı: Birleştirilmiş statik ve dinamik girdiler, yeniden şekillendirilir ve zamansal işlemeyi ele alan LSTM katmanlarından geçirilir. İkinci Transformer Modelindeki LSTM katmanları, güç üretim verilerindeki zamansal bağımlılıkları yakalamak için kritik öneme sahiptir.

Gated Artık Ağ (Gated Residual Network): LSTM katmanlarının çıktıları, karmaşık bağımlılıkları yakalamak için Gated Artık Ağ'ından geçirilir. GRN, doğrusal dönüşüm, kapı mekanizması ve artık bağlantılar (residual connections) gibi çeşitli bileşenlerden oluşur. Bu bileşenler, birlikte modelin giriş özelliklerini işleme yeteneğini artırır ve eğitim sürecini stabilize eder.

GRN'yi tanımlayan denklemler şu şekildedir:

Doğrusal dönüşüm:

$$z = w_z \cdot x + b_z \quad [3.11]$$

Burada x önceki katmandan gelen girdidir (örneğin, LSTM çıktıları), w_z ağırlık matrisidir, b_z Bias vektörü.

Kapı mekanizması:

$$g = \sigma(W_g \cdot x + b_g) \quad [3.12]$$

Burada W_g kapı için ağırlık matrisidir, b_g Bias vektörü, g geçit sinyalidir ve σ , çıktıyı 0 ile 1 arasına sıkıştıran sigmoid aktivasyon fonksiyonunu temsil eder.

Artık bağlantılar:

$$y = g * z + (1 - g) * x \quad [3.13]$$

Burada y GRN'nin dönüştürülmüş çıktıyı da içeren nihai çıktıdır, z ve x orijinal girdi

GRN, artık bağlantıları öğrenerek modelin girdi özelliklerini işleme yeteneğini artırır; bu da eğitim sürecini istikrarlı hale getirir ve modelin tahmin doğruluğunu iyileştirir.

Yoğun Katmanlar ve Dropout: Son güç tahmini, statik ve dinamik girdilerin birleştirilmesi ve bunların düzenleme amacıyla dropout ile yoğun katmanlardan geçirilmesiyle üretilir. Bu yoğun katmanlar, girdi özellikleri ile hedef değişken arasındaki doğrusal olmayan ilişkileri yakalamaya yardımcı olurken, dropout ise eğitim sırasında birimleri rastgele devre dışı bırakarak aşırı uyumayı (overfitting) önler.

3.4 Model Geliştirmede Etik Hususlar

Rüzgâr gücü tahmini için hibrit Transformer modelinin geliştirilmesinde, modelin adil, şeffaf ve sorumlu bir şekilde çalışmasını sağlamak amacıyla çeşitli etik hususlar ele alınmıştır. Makine öğrenimi modellerinde etik kaygılar genellikle önyargı, adalet, şeffaflık ve model tahminlerinin potansiyel sosyal etkisi gibi konular etrafında döner. Bu araştırmada, model geliştirme sürecinde bu faktörlere dikkat edilerek etik standartlar korunmuş ve model çıktılarının paydaşlar tarafından güvenilebilir olmasını sağlamak amaçlanmıştır.

Adaletin Sağlanması: Makine öğreniminde adalet, modelin belirli bir grup veya veri türüne ayrıcalık tanımadığından ya da dezavantaj oluşturmadığından emin olmayı gerektirir. Araştırmada kullanılan veri kümesi ağırlıklı olarak meteorolojik ve rüzgâr

gücü üretim verilerinden oluşsa da adalet önemli bir husus olarak ele alınmıştır. Farklı coğrafi bölgelerin, mevsimsel değişimlerin veya diğer bağlamsal faktörlerin eşit temsil edilmemesi, önyargıya yol açabilir. Bu sorunu ele almak için, veri kümesi model eğitiminden önce potansiyel önyargılar açısından dikkatlice incelenmiştir. Veriler, farklı bölgelerde ve zaman dilimlerinde çeşitli rüzgâr modelleri ve koşullarının dengeli ve kapsamlı bir şekilde temsil edilmesini sağlamak amacıyla ön işleme tabi tutulmuştur.

Ayrıca, modelin performansını etkileyebilecek istem dışı önyargıların ortadan kaldırılmasına vurgu yapılarak özellik mühendisliği ve seçimi gerçekleştirilmiştir. Rüzgâr gücü üretimi ile doğrudan ilgili olan meteorolojik değişkenlere odaklanılarak, modelin tahminlerinde adalet sağlanmış ve önyargıya neden olabilecek gereksiz değişkenlerin kullanımından kaçınılmıştır.

Şeffaflık ve Yorumlanabilirlik: Model geliştirmede şeffaflık, güven inşa etmek ve paydaşların modelin nasıl çalıştığını ve neden belirli tahminlerde bulunduğunu anlamalarını sağlamak için esastır. Bu çalışmada, model geliştirme sürecinin her adımı, veri ön işleme ve model mimarisi tasarımından sonuçlara kadar dikkatlice belgelenmiştir. Bu belgelendirme, modelin arkasındaki karar alma sürecinin hem teknik hem de teknik olmayan paydaşlar tarafından anlaşılır ve erişilebilir olmasını sağlar.

Transformer modelinde kullanılan kendi kendine dikkat mekanizmaları, modelin yorumlana bilirliğine de katkıda bulunur. Model tarafından üretilen dikkat skorları, modelin tahmin yaparken hangi girdi özelliklerini en önemli olarak değerlendirdiğine dair içgörüler sunar. Bu şeffaflık düzeyi, tahminleri etkileyen faktörlerin anlaşılmasının operatörlerin daha bilinçli kararlar almasına yardımcı olabileceği rüzgâr gücü tahmininde oldukça önemlidir.

Hesap Verebilirlik ve Sosyal Etki: Rüzgâr gücü tahmininin enerji yönetimi ve kaynak tahsisi üzerindeki potansiyel etkisi göz önünde bulundurulduğunda, modelin tahminlerinin sosyal sonuçları geliştirme sürecinde dikkate alınmıştır. Model, hataları en aza indirerek enerji kullanımında verimsizliklere veya şebeke dengesizliklerine yol açabilecek riskleri minimize edecek şekilde sağlam ve doğru olacak şekilde tasarlanmıştır. Modelin güvenilirliğini ve tahminlerinin şeffaflığını sağlamak suretiyle,

araştırma, sürdürülebilir enerji yönetimi ve iklim değişikliğiyle mücadele gibi daha geniş hedeflere olumlu katkıda bulunmayı amaçlamaktadır.

3.4.1 Çevresel Etkiler

Rüzgâr gücü tahmininin çevresel etkileri, yenilenebilir enerji sayesinde karbon emisyonlarını azaltmanın ötesine geçer. Hibrit Transformer modelleri gibi ileri makine öğrenimi modellerinin eğitilmesi ve uygulanması, önemli ölçüde enerji tüketimine ve dolayısıyla daha büyük bir karbon ayak izine yol açabilir. Buradaki etik zorluk, geliştirilmiş tahmin doğruluğunun çevresel faydaları ile bu iyileştirmeleri sağlamak için gereken hesaplama kaynaklarının çevresel maliyetleri arasındaki dengeyi bulmaktır.

Azaltma Stratejileri: Çevresel etkiyi azaltmak için birkaç iyi uygulama hayata geçirilebilir:

- Enerji Verimli Model Tasarımı: Makine öğrenimi modellerinin enerji verimliliği için optimize edilmesi önemlidir. Bu, modelin karmaşıklığının azaltılmasını, daha verimli algoritmaların kullanılmasını veya hesaplamaları daha verimli gerçekleştirebilen Grafik İşlem Birimleri (GPU'lar) veya Tensör İşlem Birimleri (TPU'lar) gibi donanım hızlandırma teknolojilerinin kullanılmasını içerebilir.

- Yenilenebilir Enerji Kaynaklarının Kullanımı: Mümkün olan her durumda, hesaplama kaynaklarını çalıştırmak için kullanılan enerji yenilenebilir kaynaklardan sağlanmalıdır. Veri merkezleri, model eğitimi ve dağıtımının genel karbon ayak izini azaltmak için güneş, rüzgar veya hidroelektrik güç kullanacak şekilde tasarlanabilir veya yenilenebilir enerji kaynaklarına dönüştürülebilir.

- Karbon Dengeleme: Kaçınılmaz emisyonlar için, organizasyonlar karbon dengeleme programlarına yatırım yapabilir. Bu programlar, yeniden ağaçlandırma veya yenilenebilir enerji girişimleri gibi çevresel projelere yatırım yaparak, salınan karbon dioksit miktarını dengelemeye yardımcı olur.

Bu azaltma stratejilerini geliştirme sürecine entegre ederek, ileri rüzgâr gücü tahmin modellerinin çevresel etkisi önemli ölçüde azaltılabilir ve bu süreç daha sürdürülebilir ve etik açıdan sorumlu hale getirilebilir.

3.4.2 Doğru Tahminlerin Sorumluluğu

Doğru rüzgâr gücü tahmini, yalnızca enerji üretimini optimize etmek ve şebeke güvenilirliğini sağlamak için değil, aynı zamanda yenilenebilir enerjiye olan kamu güvenini sürdürmek için de kritik öneme sahiptir. Yanlış tahminler, aşırı üretime yol açarak enerjinin boşa harcanmasına ve şebeke altyapısına zarar verme potansiyeline sahipken, yetersiz üretim enerji eksikliklerine ve yedek olarak fosil yakıtların kullanılmasını gerektirebilir, bu da rüzgar enerjisinin çevresel faydalarını azaltır.

Azaltma Stratejileri: Tahminlerin doğruluğunu ve güvenilirliğini sağlamak için şu en iyi uygulamalar benimsenmelidir:

- Sağlam Model Doğrulama: Modeli çeşitli senaryolar ve koşullar altında test etmek için titiz doğrulama teknikleri kullanılmalıdır. Bu, modelin sağlamlığını ve görülmemiş veriler üzerinde genelleme yeteneğini sağlamak için çapraz doğrulama, duyarlılık analizi ve örnek dışı testleri içerebilir.
- Model Geliştirmede Şeffaflık: Modellerin nasıl geliştirildiği, eğitildiği ve test edildiği konusunda şeffaflık esastır. Araştırmacılar, veri kaynakları, model parametrelerinin seçimi ve doğrulama süreçleri de dahil olmak üzere metodolojilerini belgelemeli, bu sayede akran incelemesi ve sonuçların tekrarlanması mümkün olmalıdır. Bu şeffaflık, aynı zamanda modelin sınırlamalarını ve belirsizliklerini paydaşlara iletme açısından da önemlidir.
- Sürekli Model İyileştirme: Hava koşullarının dinamik doğası ve rüzgâr gücü teknolojisinin gelişen durumu göz önüne alındığında, modeller yeni veriler geldikçe sürekli olarak güncellenmeli ve iyileştirilmelidir. Bu yinelemeli yaklaşım, tahmin modelinin zaman içinde doğru ve geçerli kalmasını sağlar.

Bu uygulamalara öncelik vererek, geliştiriciler doğru ve güvenilir rüzgâr gücü tahminleri sağlama konusundaki etik sorumluluklarını yerine getirebilir, böylece yenilenebilir enerjinin şebekeye sürdürülebilir entegrasyonunu destekleyebilirler.

3.4.3 Enerji Üretiminde İsrar ve Verimsizliği Önleme

Doğruluğu sağlamanın ötesinde, enerji üretiminde israf ve verimsizliği önleme konusunda etik bir yükümlülük vardır. Tahmin hataları aşırı tahminlere ve gereksiz enerji depolama maliyetlerine veya diğer yenilenebilir kaynakların kısıtlanmasına yol

açabilirken, düşük tahminler yedek olarak fosil yakıtların kullanılmasını gerektirebilir ve enerji sisteminin genel verimliliğini ve sürdürülebilirliğini azaltabilir.

Azaltma Stratejileri: İsrafi ve verimsizliği en aza indirmek için aşağıdaki stratejiler uygulanabilir:

- Optimize Edilmiş Karar Alma Çerçeveleri: Tahmin modellerini tahmin belirsizliğine uyum sağlayabilen karar alma çerçeveleriyle entegre etmek, daha bilinçli enerji üretimi ve dağıtım kararları alınmasına yardımcı olabilir. Bu çerçeveler israfı en aza indirmek ve mevcut enerji kaynaklarının kullanımını optimize etmek için tasarlanmalıdır.

- Senaryo Planlama ve Risk Yönetimi: Senaryo planlama teknikleri, farklı tahmin sonuçlarını öngörmek ve acil durum planları hazırlamak için kullanılabilir. Bu yaklaşım, şebeke operatörlerinin yedek kaynakların verimli ve yalnızca ihtiyaç duyulduğunda kullanılmasını sağlayarak tahmin hatalarıyla ilişkili riskleri daha iyi yönetmelerini sağlar.

- İşbirlikçi Enerji Yönetimi: Enerji üreticileri, şebeke operatörleri ve tahminciler arasındaki iş birliğini teşvik etmek daha koordineli ve verimli enerji yönetimine yol açabilir. Paydaşlar arasında veri ve bilgi paylaşımı, tahminlerin genel doğruluğunu iyileştirebilir ve israfçı enerji uygulamalarının olasılığını azaltabilir.

Bu stratejileri uygulayarak, enerji üretiminde israf ve verimsizliği önleme konusundaki etik yükümlülük daha iyi karşılanabilir ve daha sürdürülebilir ve sorumlu bir enerji sistemine katkıda bulunulabilir.

Hibrit Transformatör gibi gelişmiş makine öğrenimi modellerinin rüzgâr enerjisi tahminine entegre edilmesi, dikkatlice yönetilmesi gereken bir dizi etik hususu beraberinde getirir. Çevresel etkileri en aza indirmekten doğru tahminler sağlamaya ve enerji üretiminde israfı önlemeye kadar her bir husus önemli bir etik ağırlığa sahiptir. Bu bölümde özetlenen azaltma stratejilerini benimseyerek, araştırmacılar, geliştiriciler ve endüstri uzmanları bu etik zorlukları etkili bir şekilde ele alabilir ve rüzgâr enerjisi tahmininin faydalarının sosyal açıdan sorumlu, çevresel açıdan sürdürülebilir ve etik açıdan sağlam bir şekilde gerçekleştirilmesini sağlayabilir. Alan geliştikçe, sürdürülebilirlik ve sosyal sorumlulukla uyumlu tahmin teknolojilerinin geliştirilmesine rehberlik etmede bu etik boyutlara sürekli dikkat edilmesi önemli olacaktır.

4. METODOLOJİ

4.1 Veri Toplama ve Ön İşleme

Bu veri seti, Kaggle web sitesinden (Mubashir Rahim) [91] elde edilen saha meteoroloji gözlemleri ve rüzgar enerjisi üretim verilerinin benzersiz bir derlemesidir. Veri seti, 2 Ocak 2017'den 31 Aralık 2021'e kadar olan kayıtları içerir ve çeşitli hava koşulları ile rüzgar enerjisi üretimi arasındaki etkileşime dair gerçek dünya içgörülerini sağlar. Saha ortamına kurulan yüksek teknoloji ürünü ekipmanlar kullanılarak titizlikle toplanan bu veri seti, sıcaklık (C°), nem (%), çiğ noktası (C°) ve farklı irtifalardaki rüzgar özellikleri (hız m/s ve yön dereceleri) gibi çeşitli meteorolojik değişkenleri kaydetmiştir. Veri seti ayrıca rüzgâr türbinlerinden normalize edilmiş güç çıkışının saatlik ölçümlerini de içerir.

	Temperature_2m	Relative Humidity_2m	Dewpoint_2m	Wind Speed_10m	Wind Speed_100m	Wind Direction_10m	Wind Direction_100m	Wind Gusts_10m	Power
Count	43800	43800	43800	43800	43800	43800	43800	43800	43800
mean	47.8691	72.2887	38.5693	3.59114	6.28443	203.637	203.343	7.77179	0.40538
	1	44	08	7	1	329	676	5	5
std	19.4536	16.8522	18.7721	1.64931	2.68521	96.3712	97.9598	3.56914	0.28832
	91	87	10	8	6	62	52	7	2
min	-14.4	18	-17.1	0	0.1	1	0	0.5	
25%	32.1	60	24.3	2.41	4.38	132	130	5	0.1489
50%	47.3	74	38.1	3.3	6.08	255	266	7.2	0.34765
75%	64.5	7486	54.7	4.59	7.99	277	278	10	0.6596
max	94.1	100	76.3	13.45	20.65	360	360	29.2	0.9913


Tablo 4.1. Veri İstatistikleri

Tablo 4.1, 2 Ocak 2017 ile 31 Aralık 2021 tarihleri arasında toplanan rüzgar enerjisi üretimi veri setinin temel istatistiksel özelliklerinin ayrıntılı bir özetini sunmaktadır. İncelenen temel meteorolojik değişkenler; sıcaklık (2m), bağıl nem (2m), çiğ noktası (2m), rüzgâr hızı (10m ve 100m yüksekliklerde), rüzgâr yönü (10m ve 100m

yüksekliklerde), rüzgâr hızındaki ani artışlar (10m) ve güç çıktısı (kW) olarak sıralanmaktadır. Her bir değişken, veri sayısı (count), ortalama (mean), standart sapma (std), minimum değer, 25. yüzdilik dilim (25%), medyan (50%), 75. yüzdilik dilim (75%) ve maksimum değer gibi temel ölçütler ile tanımlanmıştır. Bu istatistikler, veri dağılımı, değişkenlik ve merkezi eğilimler hakkında önemli bir anlayış sağlayarak keşifsel veri analizi ve sonraki modelleme çalışmaları için sağlam bir temel oluşturmaktadır.

4.2 Keşifsel Veri Analizi

Keşifsel Veri Analizi (KVA), bir veri setindeki temel örüntüleri ve yapıları anlamada kritik bir rol oynar. Rüzgâr gücü üretimi için KVA, güç çıktısını etkileyen anahtar faktörleri belirlemeye, veri kalitesini değerlendirmeye ve sonraki istatistiksel analiz ve modellemeye rehberlik edebilecek içgörüler sağlamaya yardımcı olur. Bu bölümde, bir rüzgâr gücü üretimi veri setinin kapsamlı bir KVA'sı sunularak, verideki önemli eğilimler ve ilişkiler ortaya çıkarılmaya çalışılmaktadır.




Şekil 4.1. Zaman Serisi Analizi

Verilen zaman serisi grafiği, 24 saatlik sıcaklık ölçümlerinin analizini içermektedir. Şekil 4.1'deki grafikte, x ekseninde 24 saatlik formatta zaman, y ekseninde ise santigrat derece (C°) cinsinden sıcaklık yer almaktadır. Bu analiz, bir gün boyunca gözlemlenen

sıcaklık eğilimlerini ve önemli veri noktalarını detaylı bir şekilde incelemeyi amaçlamaktadır.

Grafik, 24 saatlik periyod boyunca değişen sıcaklık ölçümlerini göstermektedir. Kaydedilen maksimum sıcaklık 34.68 C° olup, grafikte kırmızı bir nokta ile vurgulanmıştır. Buna karşılık, minimum sıcaklık 20.30 C° olarak kaydedilmiş ve yeşil bir nokta ile işaretlenmiştir. 11:00 ve 18:00 civarında iki önemli zirve gözlemlenmiştir. 16:00'daki en düşük sıcaklık, genel eğilime göre bir aykırı değer olarak dikkat çekmektedir. Gözlemlenen bu desen, güneş ışığı, hava durumu koşulları ve coğrafi konum gibi faktörlerden etkilenebilecek tipik günlük sıcaklık dalgalanmalarını yansıtmaktadır. 15:00 ve 16:00 civarındaki keskin düşüş ve ardından gelen yükselme, ani hava değişiklikleri veya diğer yerel fenomenlere işaret ediyor olabilir.



Şekil 4.2. Korelasyon Matrisi Isı Haritası


24 saatlik sıcaklık ölçümlerinin analizi, gün içinde belirgin desenler ve önemli dalgalanmalar olduğunu ortaya koymaktadır. Bu değişimleri anlamak, yerel hava durumu koşulları hakkında fikir edinmek ve günlük aktiviteleri planlamak açısından büyük önem taşır. Gelecek araştırmalar, bu sıcaklık değişimlerini etkileyen temel faktörleri, meteorolojik veriler, coğrafi etkiler ve mevsimsel değişiklikler gibi unsurlar bağlamında daha derinlemesine inceleyebilir.

Şekil 4.2'de sunulan korelasyon matrisi ısı haritası, çeşitli meteorolojik parametreler ile güç üretimi arasındaki ilişkilerin kapsamlı bir analizini sağlar. 2 metre yükseklikteki sıcaklık (temperature_2m), hem 2 metre yükseklikteki çiy noktası (dewpoint_2m) hem de 2 metre yükseklikteki bağıl nem (relativehumidity_2m) ile çok yüksek pozitif korelasyon göstermektedir; korelasyon katsayıları sırasıyla 1.00 ve 0.93'tür. Bu durum, daha yüksek sıcaklıkların, daha yüksek nem ve çiy noktası ile güçlü bir şekilde ilişkili olduğunu gösterir. Ayrıca, 10 metre yükseklikteki rüzgâr hızı (windspeed_10m) ve 100 metre yükseklikteki rüzgar hızı (windspeed_100m) mükemmel bir korelasyon (1.00) sergilemekte olup, farklı yüksekliklerde rüzgâr davranışının tutarlı olduğunu öne sürmektedir.

Dikkat çekici bir şekilde, 10 metre yükseklikteki rüzgâr yönü (winddirection_10m) ve 100 metre yükseklikteki rüzgâr yönü (winddirection_100m) de çok yüksek pozitif korelasyon (0.99) göstermektedir; bu, yükseklikle birlikte rüzgâr yönünde çok az bir değişiklik olduğunu gösterir. Ancak, güç üretimi, her iki yükseklikteki rüzgâr yönü ile (10m için 0.93 ve 100m için 0.94) ve 10 metredeki rüzgâr patlamaları (windgusts_10m) ile orta düzeyde pozitif korelasyonlar sergilemekte, ancak sıcaklık, bağıl nem ve rüzgâr hızı ile daha düşük korelasyonlar göstermektedir; bu katsayılar 0.24 ile 0.29 arasında değişmektedir. Bu bulgular, rüzgâr yönü ve patlamalarının, sıcaklık veya nemden daha fazla güç üretimi üzerinde etkili olduğunu göstermektedir.

Bu analiz, meteorolojik faktörler arasındaki karmaşık etkileşimleri ve bunların güç üretimi üzerindeki kolektif etkisini vurgulamakta, rüzgâr parametrelerinin güç çıkışını tahmin etmede ne kadar önemli olduğunu ortaya koymaktadır. Farklı yüksekliklerdeki rüzgâr hızları ve yönleri arasındaki yüksek korelasyonlar, bu yükseklikler arasında rüzgâr modellerinin nispeten üniforman olduğunu öne sürerek, güç üretim çalışmalarında rüzgarla ilgili ölçümlerin güvenilirliğini pekiştirmektedir.

Bu korelasyon matrisi, deęişkenler arasındaki ilişkileri belirlemede kritik bir rol oynar ve güç üretimini etkileyen faktörleri anlamada ve tahmin modellerinin geliştirilmesinde önemli bilgiler sunar. Bu içgörülerden yararlanarak, enerji üreticileri rüzgâr gücü tahminlerinin doğruluęunu artırabilir, daha güvenilir ve verimli bir enerji üretimi sağlayabilir.



Şekil 4.3. Rüzgâr önü ile rüzgâr hızı arasındaki ilişki

Şekil 4.3, 10m ve 100m yüksekliklerdeki rüzgâr yönü ile rüzgâr hızı arasındaki ilişkiyi gösteren polar grafięi temsil eder. Mavi daireler ve kırmızı üçgenler sırasıyla rüzgâr hızlarını göstermektedir. Veriler, rüzgârın ağırlıklı olarak doğudan estięini ve 100m'deki hızların 10m'dekinden daha yüksek olduęunu, bu durumun da rüzgâr hızının irtifa ile artma eğilimini yansıttıęını göstermektedir. Grafik, net bir açıklama ve kılavuz çizgilerle iyi bir şekilde etiketlenmiştir, bu da yorumlamayı kolaylaştırır. Bu görselleştirme, farklı yüksekliklerdeki rüzgâr modellerinin anlaşılması, türbin

yerleşimi ve performansının optimize edilmesine yardımcı olarak enerji üretim verimliliğini artırdığı için rüzgâr gücü üretimi tahmini açısından önemlidir.

4.3 Veri Kalitesi

Veri kalitesi, hibrit modellerin etkinliğinde kritik bir rol oynar. Yüksek kaliteli giriş verileri, doğru tahminler üretmek için esastır, oysa düşük veri kalitesi, model performansını zayıflatarak önemli hatalar ortaya çıkarabilir. Bu nedenle, veri setinin kapsamlı ön işleme adımlarıyla iyi hazırlanmasını sağlamak, modelleme sürecinin önemli bir parçasıdır.

4.3.1 Başlangıç Veri Hazırlığı

Veri ön işlemenin ilk adımı, veri setini yüklemek ve kronolojik olarak düzenlemektir. Bu zamansal düzenleme, zaman serisi tahminleri için kritik öneme sahiptir ve veri noktalarının sıralamasının korunmasını sağlar. Ay, hafta günü, saat ve dakika gibi zamansal özellikler, modelin zamanın bağlamsal anlayışını elde etmesini sağlamak için tarih-saat bilgilerinden çıkarılır; bu, mevsimsellik ve günlük rüzgâr döngülerini yakalamak açısından hayati önem taşır.

4.3.2 Rüzgâr Yönü Verilerinin Dönüştürülmesi

Dairesel bir değişken olan rüzgâr yönü, modelin süreksizlikler nedeniyle (örneğin, 359° ile 0° arasındaki geçiş) yanlış yönlendirilmemesi için özel bir işlem gerektirir. Bu sorunu çözmek için, rüzgâr yönü verilerine sinüs ve kosinüs dönüşümleri uygulanarak, iki sürekli değişkene dönüştürülür ve bu sayede model tarafından daha etkili bir şekilde işlenebilir hale getirilir.

4.3.3 Özellik Seçimi ve Normalizasyon

Özellik seçimi aşamasında, sıcaklık, nem, rüzgâr hızı ve rüzgâr yönü gibi temel meteorolojik değişkenler modelin girdileri olarak belirlenir. Bu özelliklerin öğrenme sürecine eşit katkı sağlamalarını güvence altına almak için, bu veriler StandardScaler kullanılarak standardize edilir. Bu yöntem, verileri ortalamadan çıkararak merkezler ve birim varyansa ölçeklendirir, böylece tüm özellikler karşılaştırılabilir bir ölçeğe yerleştirilir. Hedef değişken olan ‘Güç’ için MinMaxScaler kullanılarak, değerler 0 ile 1 arasında normalize edilir. Bu normalizasyon, tek bir özelliğin ölçeği nedeniyle model

üzerinde orantısız bir etki yapmasını önleyerek, kararlı bir eğitim sağlamak ve tahmin doğruluğunu artırmak açısından kritik öneme sahiptir.

4.3.4 Random Forest Regressor ile Gürültü Azaltma

Veri setini daha da iyileştirmek ve giriş verilerinin kalitesini artırmak için Random Forest Regressor kullanılarak gürültü azaltma işlemi yapılır. 10 derinliğe, 200 tahminciye ve diğer göreve özel hiperparametrelere sahip Random Forest modeli, hedef değişken olan ‘Güç’ü tahmin etmek üzere veri seti üzerinde eğitilir. Model, eğitim verilerine uyum sağladıktan sonra tahminlerini kullanarak, regressor etkili bir şekilde gürültüyü filtreler ve veriyi pürüzsüz hale getirir. Gürültüsü azaltılmış olan bu çıktı, sonraki modelleme çabaları için güncellenmiş hedef değişken olarak kullanılır. Bu gürültü azaltma adımı, hibrit modelin sağlamlığını artırarak daha doğru ve güvenilir tahmin sonuçları elde edilmesini sağlar.

5. SONUÇLAR VE DENEYLER

5.1 Model Değerlendirmesi

Bir sinir ağı modelinin performansını değerlendirmek, doğru tahminler yapma konusundaki etkinliğini anlamak için kritik öneme sahiptir. Bu çalışmada, Feedforward Sinir Ağıımızın performansını değerlendirmek için üç değerlendirme metriği kullandık: MSE, MAE ve RMSE. Bu metrikler, modelin tahmin doğruluğunu ve hata özelliklerini kapsamlı bir şekilde anlamamızı sağlar.

5.1.1 Ortalama Kare Hata

MSE, regresyon görevleri için yaygın olarak kullanılan bir metriktir ve hataların karelerinin ortalamasını, yani tahmin edilen değerler ile gerçek değerler arasındaki ortalama kare farkını ölçer. MSE'nin formülü şu şekilde verilir:

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2 \quad [5.1]$$

Burada O_i gerçek değer, P_i tahmin edilen değer ve n gözlem sayısıdır.

MSE, sonucu orantısız bir şekilde etkileyebilecek hata terimlerini karelediği için aykırı değerlere karşı özellikle hassastır. Buna rağmen, basitliği ve daha büyük hataları daha önemli ölçüde cezalandırması nedeniyle popüler bir seçim olmaya devam etmektedir [92].

5.1.2 Ortalama Mutlak Hata

MAE, bir tahmin setindeki hataların ortalama büyüklüğünü, yönlerini dikkate almadan ölçer. Şu şekilde hesaplanır:

$$MAE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i) \quad [5.2]$$

MAE, hataları karelemediği için MSE'ye göre aykırı değerlere (outliers) karşı daha az duyarlıdır; bunun yerine, tahmin edilen ve gerçek değerler arasındaki mutlak farkı dikkate alır. Bu metrik, hedef değişkenle aynı birimlerde ortalama tahmin hatasını net bir şekilde yorumlama olanağı sağlar, bu da onu anlamayı kolaylaştırır [93].

5.1.3 Kök Ortalama Kare Hata

RMSE, ortalama kare hatanın karekökü olup, hata büyüklüğünün ortalama ölçüsünü verir. Şu şekilde tanımlanır:

$$RMSE = \sqrt{\frac{1}{n} \sum_{n=1}^n (O_i - P_i)^2} \quad [5.3]$$

RMSE, orijinal hedef değişkenin birimlerini korur, bu da onu pratik anlamda daha anlaşılır kılar. MSE gibi, RMSE de hataların karelenmesi nedeniyle aykırı değerlere duyarlıdır. Özellikle büyük hataların istenmediği ve daha ağır bir şekilde cezalandırılması gerektiğinde tercih edilir [94].

5.1.4 Yüzde farkı

Hibrit Transformatör modelinin performansının, karşılaştırma için kullanılan diğer yöntemlerle karşılaştırılması için kullanılır ve aşağıdaki denklemle hesaplanır:

$$Kazanç = \frac{Metric_{literature} - Metric_{proposed}}{Metric_{literature}} * 100 \quad [5.4]$$

Burada $Metric_{proposed}$, önerilen Hybrid Transformer tarafından elde edilen RMSE veya MAE'yi, $Metric_{literature}$ ise karşılaştırma için kullanılan hibrid yaklaşım modelleri için elde edilen RMSE veya MAE'yi temsil eder.

Pozitif yüzde değerleri, önerilen H-Transformer'ın ilgili literatür yöntemine göre daha yüksek bir performans metriği elde ettiğini gösterir.

Bu formül, hibrit Transformer modelinin performansındaki iyileşmeyi veya düşüşü, referans alınan diğer yöntemlere göre yüzdelik olarak ifade eder. Örneğin, bir tahmin modelinin doğruluğu eski yöntemle göre yüzde kaç daha iyi veya kötü olduğunu belirlemek için bu formül kullanılabilir.

5.2 Deneysel Kurulum

Bu araştırma için deneysel kurulum, hibrit Transformer modelinin rüzgâr gücü tahminindeki performansını titizlikle değerlendirmek amacıyla özenle tasarlanmıştır. Deneyler, model eğitimi ve değerlendirmesi için gerekli hesaplama kaynaklarını sağlayan Google Colab platformunda gerçekleştirilmiştir. Deneyler, modelin farklı

zaman dilimleri ve koşullarda doğruluğunu, sağlamlığını ve genelleştirilebilirliğini değerlendirmeye odaklanmıştır.

Veri setinin bölünmesinden önce, öznitelik mühendisliği gerçekleştirilmiştir. Zaman tabanlı öznitelikler eklenmiş; örneğin, veri setine ay, haftanın günü, saat ve dakika gibi zaman bilgileri dahil edilmiştir. Ayrıca, rüzgar yönü verileri radyan cinsine dönüştürülerek sinüs ve kosinüs bileşenlerine ayrılmıştır. Bu, yönlerin döngüsel yapısını modelin daha iyi anlamasına olanak tanımıştır. Özetle, bu işlem şu adımlarla gerçekleştirilmiştir:

- Ay, haftanın günü, saat ve dakika gibi zaman bilgileri türetilmiştir.
- Rüzgar yönü (10 m ve 100 m yükseklikte) radyana çevrilmiş ve sinüs ile kosinüs bileşenlerine ayrılmıştır.
- Ağ seçimi özneliği, belirli rüzgar hızı ve yönü koşullarına dayalı olarak oluşturulmuştur.

Eğitim seti, modeli eğitmek için kullanılmış; doğrulama seti, hiper parametreleri ayarlamak ve aşırı öğrenmeyi (overfitting) önlemek için kullanılmıştır; test seti ise modelin performansını bağımsız olarak değerlendirmiştir. Bu tarih bazlı bölme yöntemi, modelin gerçek dünya tahmin senaryolarını yansıtan gelecekteki olayları tahmin etme yeteneğini test eder.

Model eğitimi ve değerlendirmesi için kullanılan veri seti, tarihsel rüzgâr gücü üretim verileri ve ilgili meteorolojik değişkenleri içermektedir. Modelin temsil edici verilere dayalı olarak eğitilmesini ve test edilmesini sağlamak amacıyla, veri seti, zamana dayalı olarak eğitim, doğrulama ve test setlerine bölünmüştür. Bu yaklaşım, zaman serisi tahminlerinde veri sıralamasının korunmasını sağlar ve modelin eğitim sırasında görmediği gelecekteki veriler üzerinde değerlendirilmesini garanti eder.

Eğitim seti, modeli eğitmek için kullanılmış; doğrulama seti, hiper parametreleri ayarlamak ve aşırı öğrenmeyi (overfitting) önlemek için kullanılmıştır; test seti ise modelin performansını bağımsız olarak değerlendirmiştir. Bu tarih bazlı bölme yöntemi, modelin gerçek dünya tahmin senaryolarını yansıtan gelecekteki olayları tahmin etme yeteneğini test eder.

Veri Ön İşleme : Veri ön işleme, modelin eğitim ve değerlendirme sürecinin önemli bir adımını oluşturmaktadır. Bu süreçte kullanılan metodoloji, özelliklerin

ölçeklendirilmesini ve gürültü azaltma yöntemlerini içermektedir. Aşağıda veri ön işleme sürecinin detayları açıklanmıştır.

5.2.1 Veri Ölçeklendirme

Modelin daha iyi performans göstermesi ve daha hızlı yakınsaması için veri setlerinden özelliklerin ve hedef değişkenin ayrılması ve ölçeklendirilmesi gereklidir. Bu çalışmada uygulanan veri ön işleme fonksiyonu, aşağıdaki adımları içermektedir:

- Özelliklerin ve hedef değişkenin ayrılması: 'feature_columns' ve 'target_column' parametreleri kullanılarak, özellikler ve hedef değişken 'X' ve 'y' dizileri olarak ayrılmıştır.
- Özelliklerin ölçeklendirilmesi: 'StandardScaler' kullanılarak 'X' dizisi ölçeklendirilmiştir. Bu ölçeklendirme, veri setindeki değişkenlerin ortalama ve standart sapma ile normalize edilmesini sağlar ve modelin daha tutarlı sonuçlar üretmesine katkıda bulunur.
- Ölçekleyicinin yeniden kullanımı: Eğitim, doğrulama ve test veri setlerinin tutarlı bir şekilde ölçeklendirilmesi amacıyla, eğitim veri seti ile fit edilen ölçekleyici, doğrulama ve test setlerine de uygulanmıştır. Bu adım, modelin farklı veri bölümlerinde tutarlı bir performans sergilemesini garanti eder.

5.2.2 Gürültü Azaltma

Modelin tahmin doğruluğunu artırmak için 'RandomForestRegressor' gürültü azaltma yöntemi olarak kullanılmıştır. Random Forest algoritması, veriyi ağaç tabanlı bir yapı üzerinde eğiterek modelin aşırı uyum riskini azaltır ve daha genel geçer tahminler üretir. Gürültü azaltma süreci şu adımları içermektedir:

- Random Forest Modelinin Eğitimi: Model, 'max_depth=10', 'min_samples_leaf=4' ve 'n_estimators=200' hiper parametreleri ile eğitilmiştir. Rastgele bir başlangıç noktası belirlemek amacıyla 'random_state=42' kullanılmıştır. Bu yapılandırma, modelin genelleme yeteneğini artırırken, eğitim sürecinde aşırı uyumun önüne geçer.
- Negatif Tahminlerin Sıfırlanması: Modelin tahmin sonuçlarında negatif değerlerin bulunmasını önlemek amacıyla, tahmin edilen güç değerleri 'np.clip' fonksiyonu ile sıfırın altına düşmeyecek şekilde ayarlanmıştır. Bu işlem, modelin yalnızca pozitif ve fiziksel olarak anlamlı değerler üretmesini sağlar.

Bu veri ön işleme adımları, modelin aşırı uç tahminleri filtrelemesine ve daha güvenilir sonuçlar üretmesine olanak tanımıştır. Gürültü azaltma ve ölçeklendirme adımları, modelin doğruluğunu artırarak eğitim sürecini ve tahmin performansını optimize etmiştir. Bu sayede, modelin gerçek dünya uygulamalarına daha iyi uyum sağlaması sağlanmıştır.

Eğitim Prosedürleri: Tüm modeller, adil bir karşılaştırma sağlamak amacıyla aynı hiper parametreler kullanılarak eğitilmiştir; bu hiper parametreler, epoch sayısı, batch boyutu ve öğrenme hızı planlamasını içerir. Modeller, yeterli bir yakınsama süresi sağlarken aşırı öğrenmeyi önlemek için sabit bir epoch sayısı boyunca eğitilmiştir. Eğitim sürecinde, öğrenme hızı başta daha yüksek başlayarak öğrenmeyi hızlandırmak ve modelin ince ayarını yapmak için eğitim ilerledikçe kademeli olarak azaltılmak üzere bir öğrenme hızı planlayıcısı kullanılmıştır.

Eğitim süreci, geri yayılım (backpropagation) ve hibrit modelin karmaşıklığını ele almada verimliliği ve etkinliği nedeniyle seçilen Adam optimizasyonunun ile gerçekleştirilmiştir. Ayrıca, modelin doğrulama seti üzerindeki performansı iyileşmeyi durdurduğunda eğitimi sonlandırmak için erken durdurma (early stopping) uygulanarak aşırı öğrenmenin önüne geçilmiştir.

Kullanılan Araçlar: Deneylerin yürütülmesi için Jupyter Notebook, yüksek performanslı hesaplama kaynaklarıyla sorunsuz entegrasyonu ve çok yönlülüğü nedeniyle tercih edilmiştir. Modelin karmaşıklığı ve yüksek hesaplama gereksinimleri göz önüne alındığında, ileri seviye GPU hızlandırıcılarla donatılmış güçlü makinelerde çalışabilme özelliği özellikle hibrit Transformer modelinin eğitimi açısından faydalı olmuştur. Ayrıca, Jupyter Notebook'un TensorFlow ve Keras gibi popüler makine öğrenimi kütüphaneleriyle uyumluluğu, modelin uygulanmasını ve kapsamlı eğitim prosedürlerinin yürütülmesini kolaylaştırmıştır.


DeneySEL düzenek, hibrit Transformer modelinin kapsamlı bir şekilde değerlendirilmesini sağlamak amacıyla titizlikle yapılandırılmıştır ve elde edilen sonuçların güvenilirliği ile gerçek dünya rüzgar gücü tahmin senaryolarına uygulanabilirliği garanti altına alınmıştır. Jupyter Notebook kullanımı, standartlaştırılmış eğitim protokolleri ve katı değerlendirme ölçütleri, deneylerin sağlamlığına önemli ölçüde katkıda bulunmuştur. Bu yapılandırılmış yöntem, modelin performansının yalnızca kontrollü deneySEL koşullarda doğrulanmasını sağlamakla

kalmamış, aynı zamanda yenilenebilir enerji tahminleri alanında pratik uygulamalar için ölçeklenebilir ve uyarlanabilir olmasını da güvence altına almıştır.

5.3 Model Performansı

Modelin performansı oldukça sağlam olup, genel eğilimleri ve önemli dönüş noktalarını etkili bir şekilde yakalamaktadır. Bununla birlikte, modelin gerçek güç değerlerini hafifçe düşük veya yüksek tahmin ettiği bazı sapmalar meydana gelmektedir; örneğin, 7-8 ve 18-20 saatleri civarında. Bu sapmalara rağmen, tahminler genellikle gerçek verilere oldukça yakındır, bu da modelin güçlü bir performans sergilediğini göstermektedir.

Nicel metrikler de bu performansı desteklemektedir; Hibrit Transformer Modeli, 0.0009819084327411442 MSE, 0.023314690139361036 MAE ve 0.031335418183600874 RMSE değerlerine ulaşmıştır. Bu düşük hata değerleri, yüksek tahmin doğruluğunu ve güvenilirliğini göstermektedir.



Şekil 5.1. Gerçek Değerler vs. Tahmin Edilen Değerler

Şekil 5.1 24 saatlik bir süre boyunca hibrit bir modelden elde edilen öngörülen değerlerle gerçek güç değerlerinin karşılaştırmalı analizini sunmaktadır. X eksen, günün saatlerini 0 ile 24 arasında gösterirken, y eksen normalleştirilmiş güç değerlerini göstermektedir. Güç değerleri 0 ile 1 arasında normalleştirilmiş olarak temsil edilmektedir. Kesintisiz mavi çizgi gerçek güç verilerini temsil ederken, kesikli

turuncu çizgi tahmin modeli tarafından üretilen öngörülen güç değerlerini temsil etmektedir. Hem gerçek hem de öngörülen güç seviyeleri, güç kullanımının veya üretiminin saat 12-13 ve 20-21 civarında zirveye ulaştığı belirgin döngüsel örüntüler sergilemektedir. Buna karşılık, güç seviyeleri en düşük seviyelerine sabahın erken saatlerinde (saat 1 ile 6 arasında) ve tekrar saat 18 civarında ulaşmaktadır. Tahmin modeli genellikle gerçek verilerin eğilimini takip eder ve günlük dalgalanmaları belirli bir doğrulukla yakalar. Bu grafik, hibrit modelin 24 saatlik bir süre boyunca güç değerlerini tahmin etmedeki doğruluğunu ve güvenilirliğini görsel olarak gösterdiği için rüzgar enerjisi üretim tahmini için büyük önem taşımaktadır. Doğru tahminler, rüzgar enerjisi sistemlerinin işletimini ve yönetimini optimize etmek, arz ve talebi dengelemek ve rüzgar enerjisini şebekeye entegre etmek için kritik öneme sahiptir. Gerçek ve tahmin edilen değerleri yan yana sunarak, paydaşlar modelin performansını değerlendirebilir, iyileştirilecek alanları belirleyebilir ve enerji üretim verimliliğini ve istikrarını artırmak için bilinçli kararlar alabilir.

Özetle, Hibrit Transformatör Modeli, 24 saatlik süre boyunca güç değerlerini tahmin etmede mükemmel bir performans sergilemekte ve eğilimler ve spesifik değerler açısından gerçek verilerle yakın bir uyum göstermektedir. Küçük farklılıklar bulunsa da model, büyük zirveleri ve dip noktalarını etkili bir şekilde yakalayarak zaman serisi verilerini işleme konusundaki dayanıklılığını ortaya koymaktadır. Daha ayrıntılı nicel analizler veya ek bilgiler için raporlanan hata metrikleri, modelin tahmin yetenekleri hakkında kapsamlı bir anlayış sunmaktadır.

5.4 Hibrit Transformer Modellerinin Karşılaştırmalı Analizi

Bu bölümde, hibrit Transformer modelinin performansı, geliştirilen LSTM + BPNN modeli, SARIMAX + RNN + SVR modeli ve Dalga Dönüşümü ile NARMAX modelini de içeren diğer modellerle karşılaştırılarak değerlendirilmektedir. Karşılaştırma, MSE, MAE ve RMSE gibi temel metriklerle dayanmaktadır.

Tablo 5.1, 24 saatlik bir süre boyunca farklı modellerin güç tahmin sonuçlarının karşılaştırmalı analizini göstermektedir. Bu tablo, 0 ile 1 arasında normalize edilmiş gerçek saatlik türbin çıkışı ve NARMAX + Wavelet + PSO Modeli, Hibrit Transformatör Modeli, Geliştirilmiş LSTM + BPNN Modeli ve SARIMA + RNN + SVR Modeli tarafından yapılan tahminler için sütunlar içermektedir. Her satır, her saat için tahmin edilen değerleri göstererek model performansının net bir karşılaştırmasını

sağlar. Tablo ayrıca, her model için MSE, MAE ve RMSE gibi tahmin doğruluğunu değerlendiren ana metrikleri de içermektedir. Bu karşılaştırma, her tahmin yönteminin göreceli güçlü ve zayıf yönlerini vurgular ve saatlik güç üretimindeki değişiklikleri yakalamadaki etkinliklerini gösterir. Ayrıntılı değerlendirme, her yöntemin tahmin doğruluğu hakkında bilgi sağlar ve güç tahmini için en güvenilir modeli belirlemeye yardımcı olur.


Saat	Gerçek değer	Hybird Transformer Model	Improved LSTM + BPNN Model	SARIMAX + RNN + SVR Model	NARMAX with Wavelet Transform Model
0	0.232106	0.180854	0.133966	0.258393	0.6673997
1	0.156073	0.140302	0.139516	0.338965	-0.672907
2	0.146339	0.147552	0.138571	0.530705	0.154998
3	0.134493	0.163269	0.137376	0.532545	-0.223042
4	0.136243	0.191564	0.156767	0.524920	0.910545
5	0.173944	0.196822	0.161844	0.393874	-0.696963
6	0.172938	0.193192	0.154648	0.395648	-0.463316
7	0.128924	0.185021	0.145695	0.501467	0.357713
8	0.104406	0.164403	0.119358	0.553291	0.975003
9	0.228590	0.236192	0.200893	0.524875	-0.877866
10	0.321443	0.327896	0.302571	0.498328	-0.584304
11	0.556436	0.558073	0.641904	0.386760	0.689656
12	0.551984	0.529848	0.621198	0.303988	0.879186
13	0.533363	0.458632	0.561710	0.346444	-0.790414
14	0.406486	0.385407	0.472963	0.484789	-0.824549
15	0.388125	0.359364	0.399056	0.534644	0.808140
16	0.501301	0.435368	0.485012	0.241107	1.437533
17	0.664373	0.606116	0.644426	0.259800	-1.40178
18	0.587803	0.612235	0.652598	0.447982	-0.361161
19	0.533020	0.500236	0.575885	0.544804	0.083316
20	0.417594	0.352551	0.363142	0.545884	0.618797
21	0.319931	0.254534	0.246186	0.465732	-0.895971
22	0.340846	0.320076	0.329063	0.330404	0.802257
23	0.476332	0.394224	0.406132	0.237368	-0.673688
MSE		0.001062059637	0.003975007374	0.088902653806	0.523528390239
MAE		0.024059141353	0.047159700082	0.015003343052	0.583104301935
RMSE		0.032589356876	0.063047659548	0.122488134332	0.723552617464

Tablo 5.1 Günlük Saat Bazlı Veriler.

Tablo 5.2 ise her modelin hesaplama maliyetini detaylandırmaktadır. Bu tablo, eğitim süresi (saat cinsinden), kullanılan bellek miktarı (GB cinsinden), ve gerekli işlemci/GPU kaynaklarını özetleyerek modellerin pratik uygulamalardaki kullanımını değerlendirmek için kritik bir çerçeve sağlar. Bu karşılaştırma, her tahmin yönteminin göreceli güçlü ve zayıf yönlerini vurgularken, saatlik güç üretimindeki değişiklikleri yakalamadaki etkinliklerini ve hesaplama verimliliklerini gösterir. Ayrıntılı değerlendirme, her yöntemin hem tahmin doğruluğu hem de hesaplama maliyeti hakkında bilgi sağlayarak güç tahmini için en uygun ve güvenilir modeli belirlemeye yardımcı olur. Bu ek maliyet değerlendirmesi, pratik uygulamalarda yüksek doğruluk ile verimli kaynak kullanımını dengelemek isteyen enerji üreticileri ve model kullanıcıları için önem taşımaktadır. Hesaplama maliyeti ve doğruluk arasındaki bu denge, özellikle büyük veri setleri ve gerçek zamanlı uygulamalar için model seçiminde kritik rol oynar.

Model	Uygulama Süresi	Çıkarım Süresi	Bellek Kullanımı	EK Detaylar
NARMAX + Wavelet	3 saat 10 dakika	2.82	1.7 GB	Karmaşık zaman serisi analizi için dalgacık dönüşümü, Narmax modellemesi ve diferansiyel evrim kullanır.
BPNN+LSTM	1 saat 7 dakika	10.54 s	2.3 GB	Orta düzey çıkarım süresi için Backpropagation Sinir Ağı (BPNN) ve LSTM'yi birleştiren derin öğrenme tabanlı model.
SARIMAX+ RNN+SVR	30 dakika	5 s	3.56 GB	Tahmin doğruluğunu nispeten yüksek bellek kullanımı ile dengelemek için SARIMAX, RNN ve SVR'yi birleştirir.
Hybrid Transformer	45 dakika	8 s	3 GB	Karmaşık veriler üzerinde iyileştirilmiş performans sunan Transformer tabanlı model.

Tablo 5.2 Günlük Saat Bazlı Veriler.



Şekil 5.2. Gün içerisinde saatlik uygulama modellerinin Güç karşılaştırılması.

Şekil 5.2'deki grafik, dört farklı tahmin modelinin gerçek güç değerlerine karşı 24 saatlik bir süre boyunca güç tahmin doğruluğunun karşılaştırmalı analizini sunmaktadır. X eksenini zamanı saat cinsinden gösterirken, y eksenini 0 ile 0,7 arasında değişen normalleştirilmiş güç değerlerini temsil etmektedir. Açıklama kısmı, her bir modeli tanımlamaktadır: Gerçek değerler siyah düz çizgi ile gösterilirken, Wavelet Modeli, BPNN + LSTM, Hibrit Transformatör Modeli ve SARIMAX + RNN + SVR modellerinin tahminleri sırasıyla mavi kesik çizgi, turuncu kesik-noktalı çizgi, yeşil noktalı çizgi ve mor düz çizgi ile gösterilmiştir. Genel olarak, Hibrit Transformatör Modeli ve BPNN + LSTM modeli, tam zaman aralığında güç seviyelerindeki dalgalanmaların hem zamanlamasını hem de genliğini yakalayarak gerçek değerlere en yakın uyumu sergilemektedir. Özellikle Hibrit Transformatör Modeli, güç talebindeki altta yatan değişkenliği modelleme konusundaki güçlü kapasitesini yansıtarak, gerçek verilerin zirve ve dip noktalarını yakından takip etmektedir, özellikle yüksek varyanslı bölümlerde. Benzer şekilde, BPNN + LSTM modeli de benzer bir performans sergilemekte, ancak bazen gerçek değerlere göre hafif bir gecikme veya öne geçme göstermektedir. Buna karşılık, Wavelet Modeli güç değerlerini sürekli olarak düşük tahmin etmekte ve zirve değerleri etkili bir şekilde yakalayamayan düşük genlikli dalgalanmalar göstermektedir; bu durum, ani

değişikliklere yeterince yanıt veremeyebileceğini düşündürmektedir. SARIMAX + RNN + SVR modeli, özellikle saat 0-12 arasında, bazı bölümlerde önemli ölçüde aşırı tahmin yaparak gerçek değerlerden önemli ölçüde sapmaktadır. Bu model, tepe yüksekliklerini yakalasa da gerçek verilerle hizalanmayan ve abartılı tahminlere yol açan daha büyük dalgalanma eğilimi göstermektedir. Farklı zaman dilimlerini incelediğimizde, saat 0-8 arasında, Wavelet Modeli hariç tüm modeller başlangıçtaki güç diplerini yeterince yakalamakta, ancak SARIMAX + RNN + SVR modelinin aşırı tahmini belirgin bir şekilde öne çıkmaktadır. Saat 8-16 arasında, Hibrit Transformatör Modeli ve BPNN + LSTM, gerçek eğilimi yakından takip etmeye devam ederken, Wavelet Modeli güç zirvelerine yetersiz yanıt vermektedir. Saat 16-24 arasındaki son bölümde, Hibrit Transformatör Modeli ve BPNN + LSTM gerçek değerlerle uyumu koruyarak tahmin güçlerini gösterirken, SARIMAX + RNN + SVR modeli hafif bir aşırı tahmin göstermekte, Wavelet Modeli ise güç değerlerini düşük tahmin etmeye devam etmektedir. Genel olarak, bu analiz, dört model arasında Hibrit Transformatör Modeli'nin en doğru ve güvenilir tahminci olduğunu, Wavelet Modeli'nin güç talebindeki değişkenliklere sınırlı duyarlılık gösterdiğini ve SARIMAX + RNN + SVR modelinin aşırı tahmin yapma eğiliminde olduğunu göstermektedir. Bu bulgular, yüksek doğruluk gerektiren güç tahmin uygulamalarında model seçimini bilgilendirebilir ve kısa vadeli değişkenlik ile uzun vadeli eğilimleri yakalama açısından transformatör tabanlı ve yapay sinir ağı hibrit yaklaşımlarının etkinliğini vurgulamaktadır.

6. TARTIŞMA VE SONUÇ

Bu çalışmada, rüzgâr kaynaklarının değişkenliği ve süreksizliğinden kaynaklanan zorlukların üstesinden gelmek için rüzgâr enerjisi üretim tahmini için yeni bir iki aşamalı hibrit Transformatör tabanlı model tanıttık. Model, özellikle Transformatör mimarileri olmak üzere gelişmiş makine öğrenimi tekniklerinin gücünden yararlanarak rüzgar enerjisi tahminlerinin doğruluğunu ve güvenilirliğini artırır.

Transformatör modelini ve İleri Beslemeli Sinir Ağını entegre eden hibrit modelimiz, geleneksel istatistiksel modellere ve hatta LSTM gibi gelişmiş derin öğrenme modellerine kıyasla tahmin doğruluğunda önemli iyileştirmeler sağlar. Transformatörün verimli dikkat mekanizması, dinamik belirteçleme ve iyileştirilmiş konum kodlaması, rüzgâr enerjisi verilerindeki karmaşık zamansal bağımlılıkları ve değişkenliği yakalamada etkili olduğunu kanıtlamaktadır.

MSE, MAE ve RMSE gibi metriklerle yapılan titiz değerlendirmeler sonucunda, hibrit modelimiz, iyileştirilmiş LSTM ve BPNN modelleri, hibrit istatistiksel model ve RNN ve SARIMAX modellerine kıyasla en düşük hata oranlarına ulaşarak üstün performans göstermiştir. Karşılaştırmalı analiz, rüzgâr enerjisi üretimini tahmin etmede hibrit modelin sağlamlığını ve doğruluğunu vurgular.

Bu araştırma, rüzgâr enerjisi tahmini için sağlam bir çözüm sağlayarak şebeke kararlılığı, operasyonel planlama ve maliyet etkin enerji yönetimi için kritik öneme sahip yenilenebilir enerji tahmini alanına katkıda bulunur. Bulgular, yenilenebilir enerji uygulamalarında hibrit Transformatör modellerinin potansiyelini vurgular ve model yorumlana bilirliliğini daha da geliştirmek, dinamik tahmin için gerçek zamanlı verileri entegre etmek ve rüzgâr enerjisi üretimindeki içsel belirsizlikleri ele almak için daha sağlam modeller geliştirmek üzere gelecekteki araştırmalara zemin hazırlar.

Sonuç olarak, önerilen hibrit Transformatör modeli rüzgâr enerjisi tahmininde önemli bir ilerlemeyi temsil eder ve geleneksel yöntemlerin sınırlamalarını aşmak, sürdürülebilir ve verimli enerji sistemleri hedefini ilerletmek için umut verici bir yaklaşım sunar. Gelecekteki çalışmalar, ek sahaya özgü özelliklerin entegrasyonunu, gerçek zamanlı veri asimilasyonunu ve farklı coğrafi bölgelere ve rüzgâr çiftliği yapılandırmalarına adaptasyonu keşfetmeye odaklanacak ve rüzgâr enerjisi tahmin

modellerinin tahmin doğruluğunu ve uygulanabilirliğini daha da artırmayı amaçlayacaktır.



KAYNAKLAR

- [1] **IEA** (2020). World Energy Outlook 2020. International Energy Agency.
- [2] **GWEC** (2020). Global Wind Report 2020. Global Wind Energy Council.
- [3] **IPCC** (2018). Global Warming of 1.5°C. Intergovernmental Panel on Climate Change.
- [4] **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.
- [5] **Monteiro, C., Bessa, R., Miranda, V., Botterud, A., Wang, J., & Conzelmann, G.** (2009). Wind power forecasting: State-of-the-art 2009. Argonne National Laboratory Conference Paper.
- [6] **Soman, S. S., Zareipour, H., Malik, O., & Mandal, P.** (2010). A review of wind power and wind speed forecasting methods with different time horizons. *Renewable and Sustainable Energy Reviews*, 13(6-7), 1395-1409.
- [7] **Kariniotakis, G.** (2017). *Renewable Energy Forecasting: From Models to Applications*. Elsevier.
- [8] **Giebel, G., Brownsword, R., Kariniotakis, G., Denhard, M., & Draxl, C.** (2011). The state-of-the-art in short-term prediction of wind power: A literature overview. *ANEMOS.plus report*.
- [9] **Box, G. E. P., Jenkins, G. M., & Reinsel, G. C.** (2015). *Time Series Analysis: Forecasting and Control* (5th ed.). John Wiley & Sons.
- [10] **Pinson, P., & Madsen, H.** (2012). Ensemble-based probabilistic forecasting at Horns Rev. *Wind Energy*, 15(7), 1115-1130.
- [11] **Bremnes, J. B.** (2004). Probabilistic wind power forecasts using local quantile regression. *Wind Energy*, 7(1), 47-54.
- [12] **Rodrigues, F., Bessa, R. J., & Pinto, T.** (2016). Enhancing wind power forecasting with the aid of advanced statistical methods: A review. *Renewable and Sustainable Energy Reviews*, 66, 282-292.

- [13] **Zhu, X., Genton, M. G., & Xie, L.** (2017). A review on hybrid methods for short-term wind power prediction. *Renewable Energy*, 99, 120-132.
- [14] **Roulston, M. S., & Smith, L. A.** (2002). Evaluating probabilistic forecasts using information theory. *Monthly Weather Review*, 130(6), 1653-1660.
- [15] **Lahouar, A., & Slama, J. B. H.** (2015). Day-ahead load forecast using random forest and expert input selection. *Energy Conversion and Management*, 103, 1040-1051.
- [16] **Liu, H., Tian, H., Pan, D., & Li, Y.** (2016). Wind speed forecasting approaches: A review. *Renewable and Sustainable Energy Reviews*, 61, 630-644.
- [17] **Wang, J., & Yang, Y.** (2011). An overview of wind power prediction methods. *Energy Procedia*, 12, 770-778.
- [18] **Li, G., & Shi, J.** (2010). On comparing three artificial neural networks for wind speed forecasting. *Applied Energy*, 87(7), 2313-2320.
- [19] **Li, X., & Shi, J.** (2010). On the research of short-term wind power forecasting. *IEEE Transactions on Power Systems*, 25(3), 1589-1590. doi:10.1109/TPWRS.2010.2045011
- [20] **Gneiting, T., Larson, K., Westrick, K., Genton, M. G., & Aldrich, E.** (2006). Calibrated probabilistic forecasting at the stateline wind energy center: The regime-switching space-time method. *Journal of the American Statistical Association*, 101(475), 968-979. doi:10.1198/016214506000000456
- [21] **Li, G., Shi, J., & Zhou, M.** (2011). Bayesian adaptive combination of short-term wind speed forecasts from neural network models. *Renewable Energy*, 36(1), 352-359. doi:10.1016/j.renene.2010.06.028
- [22] **Pinson, P., & Madsen, H.** (2012). Adaptive modeling and forecasting of wind power fluctuations with Markov-switching autoregressive models. *Journal of Forecasting*, 31(4), 281-313. doi:10.1002/for.1213
- [23] **Monteiro, C., Costa, V., Sousa, J., & Pestana, R.** (2009). Short-term power forecasting model for wind farms based on ARIMA models. *IEEE Transactions on Sustainable Energy*, 1(1), 44-52. doi:10.1109/TSTE.2009.2036204

- [24] **Eltigani, D. M., & Masri, S.** (2014). Challenges of integrating renewable energy sources to the utility grid. *Renewable Energy and Sustainable Development*, 1(1), 67-77.
- [25] **Song, Y., Gao, C., & Hou, Y.** (2018). Wind power forecasting using LSTM with conditional variational autoencoder. *Energy*, 161, 501-512.
- [26] **Mass, C. F., Ovens, D., Westrick, K., & Colman, B.** (2002). Does increasing horizontal resolution produce more skillful forecasts? The results of two years of real-time numerical weather prediction over the Pacific Northwest. *Bulletin of the American Meteorological Society*, 83(3), 407-430. doi:10.1175/1520-0477(2002)083<0407>2.3.CO;2
- [27] **Giebel, G., Brownsword, R., Kariniotakis, G., Denhard, M., & Draxl, C.** (2013). The state-of-the-art in short-term prediction of wind power: A literature overview, 2nd edition. *A report for the ANEMOS.plus project*. doi:10.5281/zenodo.3427693
- [28] **Zhou, M., Erdem, E., & Shi, J.** (2011). Comprehensive evaluation of ARMAV models in short-term wind speed prediction. *IEEE Transactions on Sustainable Energy*, 2(4), 391-398. doi:10.1109/TSTE.2011.2159360
- [29] **Jung, J., & Broadwater, R. P.** (2014). Current status and future advances for wind speed and power forecasting. *Renewable and Sustainable Energy Reviews*, 31, 762-777. doi:10.1016/j.rser.2013.12.054
- [30] **Kariniotakis, G. N., Pinson, P., & Siebert, N.** (2004). On the influence of meteorological forecasts on uncertainty management in wind power prediction. *Proceedings of the 2004 Global Windpower Conference*, 1-12. doi:10.13140/RG.2.1.2527.4487
- [31] **Brownlee, J.** (2017). *Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python*. Machine Learning Mastery.
- [32] **Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I.** (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998-6008.

- [33] **Hochreiter, S., & Schmidhuber, J.** (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- [34] **Tay, Y., Dehghani, M., Bahri, D., & Metzler, D.** (2020). Efficient transformers: A survey. *ACM Computing Surveys (CSUR)*, 53(6), 1-28.
- [35] **Qin, Y., Song, D., Chen, H., Cheng, W., Jiang, G., & Cottrell, G. W.** (2017). A dual-stage attention-based recurrent neural network for time series prediction. *Proceedings of the 26th International Joint Conference on Artificial Intelligence*, 2627-2633.
- [36] **Zhang, G., & Wang, X.** (2021). A hybrid short-term wind power forecasting model based on LSTM and CNN. *Applied Energy*, 283, 116332.
- [37] **Liu, X., Liu, H., & Song, Y.** (2020). Transformer-based model for wind speed forecasting. *IEEE Transactions on Sustainable Energy*, 11(4), 1366-1373.
- [38] **Meng, Y., Zeng, Y., & Zhang, X.** (2021). Hybrid wind power forecasting model based on deep learning and statistical techniques. *Renewable Energy*, 170, 1-13.
- [39] **Li, Y., Liu, X., & Wu, H.** (2019). Transformer-based neural network for short-term wind power prediction. *Journal of Renewable and Sustainable Energy*, 11(2), 023301.
- [40] **Mao, S., Huang, T., & Wang, Z.** (2018). Short-term wind power prediction using hybrid models. *IEEE Transactions on Industrial Informatics*, 14(8), 3315-3323.
- [41] **Zhou, Z., Wang, J., & Yang, Y.** (2020). Improving wind power prediction with hybrid models. *Renewable Energy*, 146, 1349-1362.
- [42] **Sun, Y., Zhang, X., & Chen, H.** (2020). Probabilistic wind power forecasting with Bayesian neural networks. *IEEE Transactions on Power Systems*, 35(1), 356-367.
- [43] **Foley, J. A., Ramage, E. L., Holburn, D., & Scott, J.** (2019). Machine learning approaches for wind power prediction: Challenges and opportunities. *Journal of Renewable Energy Research*, 9(3), 1235-1244.
- [44] **Xie, Y., Hong, T., & Stroud, J. R.** (2017). Long-term load forecasting using a generalized additive model with Gaussian process. *Applied Energy*, 208, 1218-1227. doi:10.1016/j.apenergy.2017.09.045

- [45] **Pinson, P., & Messner, J. W.** (2018). Quantile regression for wind power forecasting. *Energy Conversion and Management*, 171, 158-168. doi:10.1016/j.enconman.2018.05.080
- [46] **Zhou, Z., Wang, Y., & Wang, X.** (2020). Deep learning-based wind power forecasting: A review. *Applied Energy*, 269, 114913.
- [47] **Gal, Y., & Ghahramani, Z.** (2016). Dropout as a Bayesian approximation: Representing model uncertainty in deep learning. In *Proceedings of the 33rd International Conference on Machine Learning* (Vol. 48, pp. 1050-1059).
- [48] **Chen, L., Chen, C., & Ding, J.** (2019). Wind power forecasting using hybrid machine learning models. *Renewable Energy*, 134, 629-644.
- [49] **Zhang, H., Zhu, Q., Li, W., Li, X., Xie, C., Xiang, C., & Fan, J.** (2023). Ultra short-term power forecasting of wind generation based on improved LSTM. *2023 3rd Power System and Green Energy Conference (PSGEC)*, 176-180.
- [50] **Ashraf, M., Raza, B., Arshad, M., Ahmed, A., & Zaidi, S. S. H.** (2023). A hybrid statistical model for ultra short-term wind speed prediction. *2023 7th International Multi-Topic ICT Conference (IMTIC)*, 1-8.
- [51] **Shah, A. A., Aftab, A. A., Han, X., Baloch, M. H., Honnurvali, M. S., & Chauhdary, S. T.** (2023). Prediction error-based power forecasting of wind energy system using hybrid WT–ROPSO–NARMAX model.
- [52] **Zhang, J., Wang, X., & Li, Y.** (2018). Wind power forecasting with hybrid models: A review. *Renewable and Sustainable Energy Reviews*, 104, 1-10.
- [53] **Ding, M., Yang, Z., Zhou, X., & Liu, C.** (2019). A hybrid short-term wind power forecasting model combining ensemble empirical mode decomposition, long short-term memory neural network and Elman neural network. *Applied Energy*, 235, 1138-1157.
- [54] **Park, J., Lee, K. Y., & Han, D.** (2017). Short-term load forecasting for the holidays using fuzzy linear regression method. *IEEE Transactions on Power Systems*, 32(6), 4425-4433.
- [55] **Landberg, L.** (2015). *Meteorology for Wind Energy: An Introduction*. John Wiley & Sons.

- [56] **Liu, X., Li, Y., & Zhou, J.** (2022). Application of Transformer models in wind power forecasting. *Journal of Renewable Energy Research*, 10(3), 1-15. doi:10.1016/j.jrer.2022.06.017
- [57] **Goodfellow, I., Bengio, Y., & Courville, A.** (2016). *Deep Learning*. MIT Press.
- [58] **Hastie, T., Tibshirani, R., & Friedman, J.** (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer.
- [59] **Breiman, L.** (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- [60] **Ho, T. K.** (1995). Random decision forests. In *Proceedings of 3rd International Conference on Document Analysis and Recognition* (Vol. 1, pp. 278-282). IEEE.
- [61] **Cutler, D. R., Edwards, T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J.** (2007). Random forests for classification in ecology. *Ecology*, 88(11), 2783-2792.
- [62] **Liaw, A., & Wiener, M.** (2002). Classification and regression by randomForest. *R News*, 2(3), 18-22.
- [63] **Hastie, T., Tibshirani, R., & Friedman, J.** (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer Science & Business Media.
- [64] **Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R.** (2006). Random Forests for land cover classification. *Pattern Recognition Letters*, 27(4), 294-300.
- [65] **James, G., Witten, D., Hastie, T., & Tibshirani, R.** (2013). *An Introduction to Statistical Learning: With Applications in R*. Springer.
- [66] **Genuer, R., Poggi, J. M., & Tuleau-Malot, C.** (2010). Variable selection using random forests. *Pattern Recognition Letters*, 31(14), 2225-2236.
- [67] **Menard, S.** (2013). *Applied Logistic Regression Analysis*. SAGE Publications.
- [68] **Pal, M.** (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222.

- [69] **Prasad, A. M., Iverson, L. R., & Liaw, A.** (2006). Newer classification and regression tree techniques: Bagging and Random Forests for ecological prediction. *Ecosystems*, 9(2), 181-199.
- [70] **Rojas, R.** (1996). *Neural Networks: A Systematic Introduction*. Springer-Verlag.
- [71] **Mitchell, T. M.** (1997). *Machine Learning*. McGraw-Hill Education.
- [72] **Hagan, M. T., Demuth, H. B., Beale, M. H., & De Jesús, O.** (2014). *Neural Network Design*. PWS Publishing.
- [73] **Rumelhart, D. E., Hinton, G. E., & Williams, R. J.** (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- [74] **Zhang, G. P., Patuwo, B. E., & Hu, M. Y.** (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1), 35-62.
- [75] **Zell, A., Mache, N., & Hübner, R.** (1994). *Simulation neural networks with SNNS*. University of Stuttgart, Institute for Parallel and Distributed High-Performance Systems.
- [76] **Panchal, G., Ganatra, A., Kosta, Y. P., & Panchal, D.** (2011). Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers. *International Journal of Computer Theory and Engineering*, 3(2), 332-337.
- [77] **Zhou, Z. H., Wu, J., & Tang, W.** (2002). Ensembling neural networks: Many could be better than all. *Artificial Intelligence*, 137(1-2), 239-263.
- [78] **Liu, D., Zhang, F., Hou, M., Song, X., Liu, Y., & Wang, H.** (2020). Combining Transformer and LSTM for Time Series Forecasting. *IEEE International Conference on Data Mining Workshops (ICDMW)*, 351-358. doi:10.1109/ICDMW51313.2020.00061
- [79] **Sun, Y., Liu, H., & Zhang, J.** (2020). Hybrid Deep Learning Method for Wind Power Forecasting Using LSTM and Transformer. *Energy*, 196, 117081. doi:10.1016/j.energy.2020.117081

- [80] **Meng, X., Li, Y., & Yang, B.** (2021). Wind Power Forecasting Using Hybrid Model Based on LSTM and Transformer. *Renewable Energy*, 172, 1251-1264. doi:10.1016/j.renene.2021.03.075
- [81] **Li, Y., Yang, X., & Wang, Z.** (2019). Enhancing Transformer with LSTM for Time Series Forecasting. *Proceedings of the 28th International Joint Conference on Artificial Intelligence (IJCAI)*, 3675-3681. doi:10.24963/ijcai.2019/509
- [82] **Bahdanau, D., Cho, K., & Bengio, Y.** (2015). Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*.
- [83] **Luong, M. T., Pham, H., & Manning, C. D.** (2015). Effective approaches to attention-based neural machine translation. *arXiv preprint arXiv:1508.04025*.
- [84] **Meng, X., Li, Y., & Yang, B.** (2021). Wind Power Forecasting Using Hybrid Model Based on LSTM and Transformer. *Renewable Energy*, 172, 1251-1264. doi:10.1016/j.renene.2021.03.075
- [85] **Choromanski, K., Likhoshesterov, V., Dohan, D., Song, X., Gane, A., Sarlós, T., ... & Weller, A.** (2021). Rethinking attention with performers. *International Conference on Learning Representations*.
- [86] **Li, G., Zhang, R., & Yu, Y.** (2019). Time-series forecasting in renewable energy using deep learning models: A review. *Renewable Energy*, 143, 1564-1577.
- [87] **Kong, D., Qin, J., & Li, X.** (2021). Self-attention based models for time series forecasting: A survey. *Journal of Forecasting*, 40(1), 1-15.
- [88] **Park, C., Lee, S., & Lee, K.** (2019). Handling missing data in time series with Transformer models. *Journal of Machine Learning Research*, 20(80), 1-31.
- [89] **Lai, G., Chang, W. C., Yang, Y., & Liu, H.** (2018). Modeling long- and short-term temporal patterns with deep neural networks. *Proceedings of the 41st International ACM SIGIR Conference on Research & Development in Information Retrieval*, 95-104.
- [90] **Qin, Y., Song, D., Chen, H., Cheng, W., Jiang, G., & Cottrell, G. W.** (2017). A dual-stage attention-based recurrent neural network for time series prediction. *Proceedings of the 26th International Joint Conference on Artificial Intelligence*, 2627-2633.

[91] **Mubashir Rahim.** (2023). *Wind Power Generation Data Forecasting* [Data set]. Kaggle. <https://www.kaggle.com/datasets/mubashirrahim/wind-power-generation-data-forecasting>

[92] **Devlin, J., Chang, M. W., Lee, K., & Toutanova, K.** (2018). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *arXiv preprint arXiv:1810.04805*.

[93] **Chai, T., & Draxler, R. R.** (2014). Root mean square error (RMSE) or mean absolute error (MAE)—Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247-1250.

[94] **Willmott, C. J., & Matsuura, K.** (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79-82.