



İSKENDERUN TEKNİK
ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**YÜKSEK
LİSANS
TEZİ**

**WRF VE YAPAY ZEKA İLE
RÜZGAR ENERJİSİ SANTRALI
OPTİMİZASYONU**

Fahrettin Fırat ÖZDEMİR

**ENERJİ SİSTEMLERİ MÜHENDİSLİĞİ
ANABİLİM DALI**

AĞUSTOS 2023





**WRF VE YAPAY ZEKA İLE RÜZGAR ENERJİSİ SANTRALİ
OPTİMİZASYONU**

Fahrettin Fırat ÖZDEMİR

**YÜKSEK LİSANS TEZİ
ENERJİ SİSTEMLERİ MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

AĞUSTOS 2023

Fahrettin Fırat ÖZDEMİR tarafından hazırlanan “WRF VE YAPAY ZEKA İLE RÜZGAR ENERJİSİ SANTRALİ OPTİMİZASYONU” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi ENERJİ SİSTEMLERİ MÜHENDİSLİĞİ Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Abdulla SAKALLI

Endüstri Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Başkan: Doç. Dr. Abdulla SAKALLI

Endüstri Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Üye: Doç. Dr. Ömer EREN

Biyosistem Mühendisliği Anabilim Dalı, Hatay Mustafa Kemal Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Üye: Dr. Öğr. Üyesi Ersin ÖZDEMİR

Elektrik-Elektronik Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Tez Savunma Tarihi: 31 / 08 / 2023

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ersin BAHÇECİ

Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

İskenderun Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülediğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
 - Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İmza

Fahrettin Fırat ÖZDEMİR

10 / 08 / 2023

WRF VE YAPAY ZEKA İLE RÜZGAR ENERJİSİ SANTRALİ OPTİMİZASYONU
(Yüksek Lisans Tezi)

Fahrettin Fırat ÖZDEMİR

İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Ağustos 2023

ÖZET

Dünya genelinde yenilebilir enerjiye olan yönelim, fosil yakıtların kullanımına bağlı olarak sera gazları yayılımı sonucu artan yüzey sıcaklığı, buzulların erimesi ile dünya ve ekosistemdeki canlılar için daha da önem kazanmaktadır. Enerji piyasasında rüzgar enerjisinin payı ise yıllar içinde artmakta ve daha yaygın bir hale gelmektedir. Rüzgar enerjisi santrali kurulumları için en az bir yıllık rüzgar verileri gereklidir. Bu verilerin ölçüm ile elde edilmesinde ekonomik ve coğrafi bazı engeller vardır. Deniz ve okyanus üzeri kurulumlarında ise doğru verilerin sağlanması ve ilk kurulumun planlanması, iletim ve üretim verimliliği için kritik öneme sahiptir. Rüzgar bileşenlerinin kısa vadeli ve hızlı bir şekilde tahmin edilebilmesi oluşabilecek sorunların önüne geçilmesi, bakım ve onarımların planlanmasına imkan sağlar. Günümüzde atmosfer koşullarının fizik denklemleriyle temsil edildiği hava tahmin modelleri ve yapay zeka ile rüzgar verileri güvenilir şekilde tahmin edilebilmektedir. Bu çalışmanın amacı, WRF sayısal tahmin modelinin uygun değişkenler ile çalıştırılması, uygun rüzgar hızı ve gücü potansiyeli tahminlerini yapay zeka yardımıyla doğru ve hızlı tahmin edilmesini sağlamaktır. Bu çalışmada 0,25 derece çözünürlüğe sahip Küresel Tahmin Sistemi (GFS) ve saatlik ölçüm verileri ile, bir yıllık zaman dilimi için hava tahmin modeli verileri ve çok değişkenli özyinelemeli sinir ağı kullanarak bir hibrit model oluşturulmuştur. Türkiye’de Hava Araştırma ve Tahmin Modeli (WRF) modeliyle atmosferik parametreler ve tarihsel veriler ile yapılan tahminlerimiz, Uzun-Kısa Vadeli Bellek (LSTM) modeli ile geliştirilmiş ve 0,04 ortalama mutlak hata (MAE) tahmin başarısı elde edilmiştir. Kısa ve uzun vadeli yapılan bu tahminler ile Türkiye enerji piyasasında ve olası gelecek yatırımlarda daha düşük maliyetli projeler geliştirilebilir ve daha verimli rüzgar enerjisi üretimleri ile Türkiye’nin rüzgar enerjisi potansiyeli kapsamlı bir şekilde ele alınarak kullanılabilir.

Anahtar Kelimeler : WRF, yapay zeka, rüzgar enerjisi, optimizasyon

Sayfa Adedi : 46

Danışman : Doçent Dr. Abdulla SAKALLI

WIND POWER PLANT OPTIMIZATION WITH WRF AND ARTIFICIAL
INTELLIGENCE
(M. Sc. Thesis)

Fahrettin Fırat ÖZDEMİR

ISKENDERUN TECHNICAL UNIVERSITY
INSTITUTE OF GRADUATE STUDIES

August 2023

ABSTRACT

The worldwide trend towards renewable energy is becoming more important for the world and the living beings in the ecosystem with the increasing surface temperature as a result of the emission of greenhouse gases due to the use of fossil fuels and the melting of glaciers. The share of wind energy in the energy market has been increasing over the years and becoming more widespread. At least one year of wind data is required for wind power plant installations. There are some economic and geographical obstacles to obtaining these data by measurement. In sea and ocean installations, providing accurate data and planning the initial installation is critical for transmission and production efficiency. Short-term and rapid prediction of wind components allows preventing possible problems and planning maintenance and repairs. Today, weather forecast models in which atmospheric conditions are represented by physics equations and wind data can be predicted reliably with artificial intelligence. The aim of this study is to run the WRF numerical prediction model with appropriate variables and to ensure that appropriate wind speed and power potential estimates are estimated accurately and quickly with the help of artificial intelligence. In this study, a hybrid model was created using the Global Forecast System (GFS) and hourly measurement data with a resolution of 0.25 degrees, weather forecast model data for a one-year period, and a multivariate recursive neural network. Our predictions, made with atmospheric parameters and historical data with the Weather Research and Forecast Model (WRF) model in Turkey, were improved with the Long-Short Term Memory (LSTM) model and a prediction success of 0.04 average absolute error (MAE) was achieved. With these short and long-term forecasts, lower-cost projects can be developed in the Turkish energy market and possible future investments, and Turkey's wind energy potential can be comprehensively handled and used with more efficient wind energy production.

Key Words : WRF, artificial intelligence, wind power, optimization
Page : 46
Supervisor : Assoc. Prof. Dr. Abdulla SAKALLI

TEŐEKKÜR

Öncelikle Lisansüstü eğitim ve öğretimim boyunca her zaman yanımda olan danışman hocam Doç. Dr. Abdulla SAKALLI'ya, destek ve tavsiyeleri için Mehmet Uğur GÜCEL'e ve çalışmalarım kapsamında üzerimde emeđi geçen tüm hocalarıma teşekkürü bir borç bilirim. Bununla birlikte maddi, manevi desteđi ve katkılarından dolayı aileme, Dr. Öğr. Üyesi Ersin ÖZDEMİR, Prof. Dr. Ergül YAŐAR, Doç.Dr. Ömer EREN ve Dr. Öğr. Üyesi Mustafa DİDİN'e en içten şükranlarımı sunuyorum.



İÇİNDEKİLER

| | Sayfa |
|---|--------------|
| ÖZET..... | iv |
| ABSTRACT | v |
| TEŞEKKÜR | vi |
| İÇİNDEKİLER | vii |
| ÇİZELGELERİN LİSTESİ | viii |
| ŞEKİLLERİN LİSTESİ | ix |
| SİMGELER VE KISALTMALAR..... | xi |
| 1. GİRİŞ | 1 |
| 2. ÖNCEKİ ÇALIŞMALAR..... | 8 |
| 3. MATERYAL VE METOT | 14 |
| 4. ARAŞTIRMA BULGULARI VE TARTIŞMA..... | 19 |
| 5. SONUÇ VE ÖNERİLER | 40 |
| KAYNAKLAR | 41 |
| DİZİN | 46 |

ÇİZELGELERİN LİSTESİ

| Çizelge | Sayfa |
|---|--------------|
| Çizelge 1.1. Yıllara göre elektrik üretimi..... | 3 |
| Çizelge 1.2. 2021 yılı Türkiye rüzgar türbini istatistikleri | 3 |
| Çizelge 1.3. Bölgelere göre RES kurulumları | 4 |
| Çizelge 1.4. En çok yatırım yapılan illere göre RES kurulumları | 4 |
| Çizelge 3.1. WRF V3.9 model yapılandırması..... | 15 |
| Çizelge 3.2. Ülkelere göre model parametreleri ve performansı | 16 |
| Çizelge 3.3. LSTM model yapılandırması..... | 18 |
| Çizelge 4.1. Rüzgar hızı hata ve performans değerlendirmesi | 19 |
| Çizelge 4.2. Çalışma bölgelerinde yağış ve sıcaklık istatistik verileri..... | 21 |
| Çizelge 4.3. Bölgelerin saatlik rüzgar hızı ölçüm (m/s) verisi istatistikleri | 22 |
| Çizelge 4.4. 2,3 MW güç eğrisi parametreleri ve hata değerleri | 27 |
| Çizelge 4.5. 3 MW güç eğrisi parametreleri ve hata değerleri | 30 |
| Çizelge 4.6. LSTM girdi parametrelerinin nicel istatistikleri..... | 30 |
| Çizelge 4.7. LSTM girdi parametrelerinin tanımlayıcı istatistikleri..... | 30 |

ŞEKİLLERİN LİSTESİ

| Şekil | Sayfa |
|--|-------|
| Şekil 1.1. RES kurulumlarının yıllara göre değişimi (TUREB, 2021) | 4 |
| Şekil 1.2. LSTM hücresi..... | 7 |
| Şekil 3.1. Çalışma bölgesi için 25 km, 9 km ve 3 km ile model ızgaraları | 14 |
| Şekil 3.2. Döngü sayısı eğitim ve test kayıpları | 18 |
| Şekil 4.1. Türkiye yıllık ortalama rüzgar hızı haritası..... | 19 |
| Şekil 4.2. Türkiye yıllık ortalama sıcaklık haritası | 20 |
| Şekil 4.3. Türkiye yıllık toplam yağış | 20 |
| Şekil 4.4. Bölgelerin rüzgar hızı ölçümünün dağılım adetleri..... | 22 |
| Şekil 4.5. Bir yıllık zaman dilimindeki farklı illerdeki bölgelerin, saatlik rüzgar hızı ölçüm verileri..... | 23 |
| Şekil 4.6. Balıkesir ilinde WRF model tahmini ve ölçüm ilişkisi | 24 |
| Şekil 4.7. Çanakkale ilinde WRF model tahmini ve ölçüm ilişkisi | 24 |
| Şekil 4.8. Hatay ilinde WRF model tahmini ve ölçüm ilişkisi | 25 |
| Şekil 4.9. İzmir-Çeşme’de WRF model tahmini ve ölçüm ilişkisi | 25 |
| Şekil 4.10. İzmir-Güzelyalı’da WRF model tahmini ve ölçüm ilişkisi..... | 26 |
| Şekil 4.11. Manisa ilinde WRF model tahmini ve ölçüm ilişkisi | 27 |
| Şekil 4.12. Türkiye mevsimsel ortalama rüzgar hızı haritası | 28 |
| Şekil 4.13. 2,3 MW ve 3 MW için eşitlenmiş güç eğrileri..... | 28 |
| Şekil 4.14. Türkiye 2,3 MW rüzgar gücü üretim potansiyeli haritası..... | 29 |
| Şekil 4.15. Türkiye 3 MW rüzgar gücü üretim potansiyeli haritası..... | 29 |
| Şekil 4.16. LSTM girdilerinin histogram ile dağılım grafikleri | 31 |
| Şekil 4.17. LSTM girdilerinin Spearman korelasyon katsayısı grafiği..... | 32 |
| Şekil 4.18. Rüzgar ölçüm hızının dağılım grafiği..... | 33 |

| Şekil | Sayfa |
|--|--------------|
| Şekil 4.19. Rüzgar hızı ölçümünün saatlik dağılımları | 33 |
| Şekil 4.20. WRF Rüzgar hızı tahmininin saatlik dağılımları | 34 |
| Şekil 4.21. Yıllık rüzgar hızı ölçümünün dönemsel trend, rezidüel mevsimsel değişimleri..... | 35 |
| Şekil 4.22. Yıllık rüzgar hızı ölçümünün dönemsel trend, rezidüel mevsimsel değişimleri..... | 35 |
| Şekil 4.23. WRF tahmini ve gözlenen rüzgar hızları..... | 36 |
| Şekil 4.24. WRF ve LSTM hibrit tahmini ve gözlenen rüzgar hızları..... | 36 |



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

| | |
|----------------|-------------------|
| % | Yüzde |
| °C | Selsius |
| A | Alan |
| C _p | Güç Katsayısı |
| h | Yükseklik |
| hPa | Hektopascal |
| km | Kilometre |
| m | Metre |
| m ² | Metrekare |
| MW | Megavat |
| P | Güç |
| s | Saniye |
| TW | Teravat |
| V | Hız |
| α | Hellman katsayısı |
| ρ | Yoğunluk |

Kısaltmalar

Açıklamalar

| | |
|---------|---|
| ACM2 | Asimetrik Konveksiyon Modeli Şeması 2 |
| AI | Yapay Zeka |
| ARIMA | Bütünleşik Otoregresif Hareketli Ortalama |
| ARMA | Otoregresif Hareketli Ortalamalar |
| ASMO | Uyarlamalı Vekil Modelleme Tabanlı Optimizasyon |
| ARW | Gelişmiş Araştırma WRF |
| BEP/BEM | Bina Parametrelendirme ve Bina Enerji Modeli |

Kısaltmalar**Açıklamalar**

| | |
|-------------------------|--|
| BGM | Gradyan Destekli Makine |
| BP | Geri Yayılım |
| CDO | İklim Veri Operatörü |
| CS-M-WRF-E | Guguk Kuşu-Ortalama-WRF-Topluluk |
| CSFC-APRIORI-WRF | Guguk Kuşu-Bulanık Sistem- Önsel-WRF |
| CS-FS-WRF-E | Guguk Kuşu-Bulanık Sistem-WRF-Topluluk |
| DBN | Derin İnanç Ağı |
| DRNN | Derin Tekrarlayan Sinir Ağları |
| DSTNN | Derin Uzay-Zamansal Sinir Ağı |
| ELM | Aşırı Öğrenme Makineleri |
| ENN | Elman Sinir Ağı |
| ETA | Arazi Dikey Koordinatı |
| FFNN | İleri Beslemeli Sinir Ağları |
| GARCH | Genelleşmiş Otomatik Regresif Değişken Varyans |
| GBM | Gradyan Destekli Makineler |
| GFS | Küresel Tahmin Sistemi |
| GRNN | Genel Regresyon Sinir Ağı |
| IOA | Anlaşma İndeksi |
| LSTM | Uzun-Kısa Vadeli Bellek |
| MAE | Ortalama Mutlak Hata |
| MAPE | Ortalama Mutlak Yüzde Hatası |
| MARS | Çok Değişkenli Uyarlanabilir Regresyon Eğrisi |
| MDN | Karışım Yoğunluğu Ağı |
| MFNN | Çok Katmanlı İleri Beslemeli Bir Sinir Ağı |
| MLP | Çok Katmanlı Algılayıcı |
| MMODA | Değiştirilmiş Çok Amaçlı Yusufçuk Algoritması |
| MOS | Model Çıktı İstatistikleri |
| MVPT | Motorsuz Görsel Algı Testi |
| M-WRF-E | Ortalama-WRF-Topluluk |
| MYJ | Mellor Yamada Janjic |
| NARX | Dışsal Girdili Doğrusal Olmayan Otoresif Ağı |

Kısaltmalar**Açıklamalar**

| | |
|-----------------------|--|
| NCAR | Ulusal Atmosferik Araştırma Merkezi |
| NCEP | Ulusal Çevresel Tahmin Merkezleri |
| NILA-WRF | Niş Bağışık Aslan Algoritması |
| NN | Sinir Ağı |
| NoahMP | Noah– Çoklu Parametreleştirme Kara Yüzeyi Modeli |
| NWP | Sayısal Hava Tahmini |
| PBL | Gezegensel Sınır Tabakası |
| PSO | Parçacık Sürü Optimizasyonu |
| PX | Pleim-Xiu |
| QNSE | Yarı Normal Ölçekli Eleme |
| R | Korelasyon Katsayısı |
| RES | Rüzgar Enerjisi Santrali |
| RF | Rastgele Orman |
| RMSE | Ortalama Karekök Sapması |
| RNN | Yinelemeli Sinir Ağı |
| SC-APRIORI-WRF | Basit Kümeleme-Önsel-WRF |
| SL | Yüzey Tabakası |
| SVM | Destek Vektör Makinesi |
| TUREB | Türkiye Rüzgar Enerjisi Birliği |
| WD | Dalgacık Ayrıştırma |
| WRF | Hava Araştırma ve Tahmin Modeli |
| VMD-PCA | Varyasyon Modu Ayrışımı-Temel Bileşenler Analizi |
| VSDA | Uçucu Durağan Gün |
| WSM6 | WRF Tek Moment Sınıf Şeması 6 |
| WSTI | Rüzgar Hızı ve Türbülans Yoğunluğu |
| XGBoost | Aşırı Gradyan Artırma |
| YSU | Yonsei Üniversite Şeması |

1. GİRİŞ

Dünya için çeşitli zararlara sebebiyet veren fosil yakıtlardan hızlı bir şekilde uzaklaşılması ve küresel ısınma sorunu için yenilenebilir enerji kaynakları günümüz için en güvenilir kaynaklar olarak görülmektedir. Rüzgar enerjisi ise artan enerji talebi için uzun vadeli makul seçeneklerden biridir ve bundan otuz yıl öncesine kadar bu konunun önemi kamuda ve dünyada etkisini göstermeye başlamıştır (Guo ve Xiao, 2014; Teixeira ve diğerleri, 2020; Xu ve diğerleri, 2021).

Yenilenebilir enerjiye geçiş sürecinde de rüzgar enerjisi büyük bir paya sahip olmakla birlikte üretilen güç ve üretim kapasitesi bakımından da önemli bir konuma sahiptir bununla birlikte önümüzdeki otuz yıl içerisinde, tüm enerji kaynaklarının üçte birinden fazlasının rüzgar enerjisinin oluşturması beklenmekte ve böylece fosil yakıtların yerini yenilenebilir enerji kaynaklarının alacağı öngörülmektedir (Salazar, Che, Zheng ve Xiao, 2021).

Rüzgar türbinin temel işleyişi bir kanat ve rotor yardımı ile kinetik enerjinin mekanik enerjiye, jeneratör ile de elektrik enerjisine dönüştürülmesi olarak özetlenebilir. Burada fark edeceğimiz gibi rüzgarın kararsız yapısı gereği, üretilen enerjideki değişimler, rüzgarın kendisinden kaynaklanmaktadır bununla birlikte bu yapının güç çıkışında meydana getirdiği frekans gibi etkiler ve gürültü, devreye girme ve çıkma aralıkları, şebekelerin ve elektrik alımının doğru planlanması da enerji üretimi için bir gerekliliktir (Guo ve Xiao, 2014; F. Li, Ren ve Lee, 2019; Salazar ve diğerleri, 2021).

Rüzgar enerjisi yatırımları için verilerin doğruluğu, erişilebilir olması ve yasal imkanların elverişli olması, yatırımcılara güven verilmesi bakımından önemlidir. Ölçümler zamansal ve ekonomik sorunlar oluşturabilir, bazı bölgelerde ise ölçüm yapmak mümkün olmayabilir. Rüzgar atmosferin yapısı gibi birçok etkenden etkilenir ve kararsız bir yapıya sahiptir, bu sebeple üretilen gücün tam manasıyla tahmin edilememesi ve değişkenliği ise şebekede güvenlik riskleri doğurur. Rüzgar, baskın yönün belirlenmesini gerektirir çünkü sık rüzgarlar aslında rüzgarın bir nevi kimliği gibidir. Rüzgar yönündeki değişimlerin tespiti için kullanılan cihazlar mevcuttur fakat bu cihazlar sahip oldukları gecikme ile o ana göre daha geriden gelirler ve yeterince fayda sağlayamazlar. Tahmin modellerinin gün öncesi veya saatlik hızlı tahminleri, güvenlik ve üretim konularında daha faydalıdır. Rüzgar türbinlerinde birçok mekanizma bulunur. Güç çıkışı kontrol mekanizmaları, güç çıkışının nominal hız ile

devreden çıkarma hızı aralığında sabit kalmasını sağlar. Rüzgar türbinleri için rüzgar enerjisi potansiyeli analizi, saha tespiti ve maliyet modelleri kullanılır (Guo ve Xiao, 2014).

Rüzgar enerjisi santralleri için en az bir yıllık rüzgar verisi gerekmektedir fakat kurulum, bakım ve maliyetler çok yüksektir ayrıca zaman açısından da uzun süreler gerekebilir. Atmosfer kararlılığı burada önem arz etmektedir. Rüzgarlar; basınç ve sıcaklık farkları, yüzey akışları ve sürtünmesi ve dünyanın dönüşü gibi etmenlerden etkilenir ve bu veriler de iyi hesaplanarak tahmin edilmeli veya analiz edilmelidir. Bir rüzgar santralindeki gücün giriş ve çıkışındaki farklılıklar, asimetrik yükler, dizi verimliliği, yüksek rüzgar hızı nedeniyle oluşan kesintiler, elektriksel kayıplar, anormal çıktılar ve türbin yerleşiminden kaynaklanan iz etkisi gibi durumlar da kurulum öncesi ve sonrasında değerlendirilmelidir. Bu konuda dikkate alınması gereken bir diğer durum olan rüzgar rampaları ise kısa süre içerisinde nominal gücün minimum değerlerinin üzerindeki güç üretimlerinden kaynaklanır ve bunun sonucunda güç çıkışında büyük ve ani değişikliklere sebep olur (Carvalho, Rocha, Gómez-Gesteira ve Santos, 2014; Y. Li ve diğerleri, 2016).

Önceden yapılan tahminler ile rüzgar ve atmosfer hakkında tarihsel ve fiziksel veriler toplanarak bazı sorunlar minimize edilebilir ve doğru üretim ve bakım planlamaları yapılabilir. Bunun için tarihsel verileri kullanan istatistiksel yaklaşımlar, atmosferi simüle eden sayısal hava tahmin modelleri, makine öğrenmesi ve derin öğrenme ile yapay zeka araçları ve bunların bir arada kullanıldığı hibrit modeller mevcuttur (Groch ve Vermeulen, 2019).

Bu konudaki istatistiksel yöntemler kısa vadede daha ucuz ve pratiklerdir fakat uzun vadede sayısal tahmin modelleri daha yüksek hesaplama maliyeti ile daha üstündür. Sayısal modeller, atmosferi matematiksel denklemler kullanarak temsil eder, uygun başlangıç koşulları belirlendiğinde isabetli çözümler üretir (Sayeed ve diğerleri, 2020; Jiang, Liu, Niu ve Zhang, 2021).

Rüzgar güç üretim denklemi Eş. 1.1'de gösterilmiştir. P (Watt): elektrik üretim gücünü, V (m/s): rüzgarın hızını, CP : güç katsayısını, A (m^2): türbin tarama alanını ve ρ (gr/cm^3): havanın yoğunluğunu belirtmektedir. Türbinin veriminde tepe bir değere sahip olan güç katsayısı, Betz limiti olarak bilinen bu değer yaklaşık %60 olarak hesaplanmaktadır (M. Ragheb ve A. M. Ragheb, 2011).

$$P = \frac{\rho \cdot V_2^3 \cdot C_p \cdot A}{2} \quad (1.1)$$

Türkiye sahip olduğu rüzgar enerjisi potansiyeli ile ve yatırımlara her geçen yıl daha çok elektrik üretimi (Çizelge 1.1) sağlamakta ve toplam üretilen enerjide rüzgarın payı da yıldan yıla artış göstermektedir. 2021 yılında bu oran %9,84'e ulaşmış (Çizelge 1.1) ve kurulu güç 11.101,82 MWh değerine ulaşmıştır (Çizelge 1.2). Bölgesel olarak ise en çok rüzgar enerjisi santrali (RES) kurulumu Marmara, Ege ve Akdeniz bölgesinde gerçekleşmiştir (Çizelge 1.3), en çok kurulum yapılan dört il ise sırasıyla İzmir, Balıkesir, Çanakkale ve Manisa illeri olmuştur (Çizelge 1.4).

Çizelge 1.1. Yıllara göre elektrik üretimi (TUREB, 2021)

| Yıl | Elektrik Üretimi (GWh) | Elektrik Üretim Oranı (%) |
|------|------------------------|---------------------------|
| 2013 | 1 844,78 | 1,50 |
| 2014 | 8 484,61 | 3,40 |
| 2015 | 11.657,92 | 4,50 |
| 2016 | 15 377,38 | 5,70 |
| 2017 | 17 716,69 | 6,10 |
| 2018 | 19 755,91 | 6,80 |
| 2019 | 21.512,28 | 7,40 |
| 2020 | 24 486,68 | 8,40 |
| 2021 | 30 900,72 | 9,84 |

Çizelge 1.2. 2021 yılı Türkiye rüzgar türbini istatistikleri (TUREB, 2021)

| | |
|-------------------------------|-----------|
| Elektrik Üretimi (GWh) | 30 900,72 |
| Kurulu Güç (MWh) | 11 101,82 |
| Trübin Sayısı | 3 983 |
| Santral Sayısı | 273 |
| Firma Sayısı | 232 |
| Yatırımcı Sayısı | 129 |
| Üretim Oranı (%) | 9,84 |


Şekil 1.1'de RES kurulumlarının yıllara bağlı değişimleri verilmiştir. Yıllık RES kurulumlarında 2021 yılı en yüksek kurulumlara sahiptir bununla birlikte 2016-2020 yılları arasında artışta bir azalma meydana gelirken bir önceki yıla göre en çok artış 2020 yılında gerçekleşmiştir (TUREB, 2021).

Çizelge 1.3. Bölgelere göre RES kurulumları (TUREB, 2021)

| Bölge | Kümülatif Kurulum (MWm) | Yıllık Kurulum (MWm) |
|-------------------|-------------------------|----------------------|
| Marmara | 4 631,77 | 4 631,77 |
| Ege | 3 717,95 | 3 717,95 |
| Akdeniz | 1 143,40 | 1 143,40 |
| İç Anadolu | 1 039,25 | 1 039,25 |
| Karadeniz | 394,20 | 394,20 |
| Güneydoğu Anadolu | 93,05 | 93,05 |
| Doğu Anadolu | 82,20 | 82,20 |

Çizelge 1.4. En çok yatırım yapılan illere göre RES kurulumları (TUREB, 2021)

| İl | Kümülatif Kurulum (MWm) | Yıllık Kurulum (MWm) |
|------------|-------------------------|----------------------|
| İzmir | 1 886,70 | 1 886,70 |
| Balıkesir | 1 375,05 | 1 375,05 |
| Çanakkale | 917,35 | 917,35 |
| Manisa | 727,55 | 727,55 |
| İstanbul | 684,39 | 684,39 |
| Kırklareli | 481,68 | 481,68 |
| Hatay | 437,85 | 437,85 |
| Afyon | 368,45 | 368,45 |



Şekil 1.1. RES kurulumlarının yıllara göre değişimi (TUREB, 2021)

Sayısal Hava Tahmini (NWP) modelleri kütle, momentum ve enerji korunumu gibi denklemleri ayrı bir şekilde yaklaşık olarak hesaplamak için kullanılan fizik denklemlerini içerir (Zhao ve diğerleri, 2016).

Hava Araştırma ve Tahmin Modeli (WRF), Gelişmiş Araştırma WRF (ARW) çekirdeğini kullanan, ABD'deki Ulusal Atmosfer Araştırmaları Merkezi (NCAR) merkezli, hidrostatik olmayan ve sınırlı bir alanı kapsayan, hava araştırma ve tahmin modelidir (Martínez-Arellano ve Nolle, 2013).

Atmosfer simüle edilirken ızgara adı verilen üç boyuta sahip birçok nokta kullanılır. Bölgenin topografyası ve coğrafi özellikleri de gözetilerek başlangıç koşulları ile birlikte çalışmanın amaç ve kapsamına göre sınır koşulları belirlenen model, her bir zaman adımında bölgedeki atmosferik durumu çözümlenerek devam eder ve tahminler üretir (Guo ve Xiao, 2014).

WRF modeli atmosferik ve coğrafi özelliklerin daha iyi çözülebilmesi için bazı parametre ve şemalar bölgenin yapısına uygun olarak doğru yapılandırılmalıdır. Gezegenel Sınır Tabakası (PBL) ve Yüzey Tabakası (SL) konfigürasyonu ve doğru temsil edilmesi, bunlardan en önemli olanlarından bazılarıdır. Bununla birlikte atmosferdeki kararsızlık ve bölge özelliklerinin doğru temsil edilememesi, zamansal ve mevsimsel farklılıklar tahmin başarımını etkileyebilir. Bazı hava olayları ise normal ızgaradan daha küçük olan alt ızgaralarda değerlendirilmelidir. Model çözünürlüğü ise performansa etki eden bir diğer faktördür fakat bu durumun daha uzun hesaplama süresi ve artan maliyetlere sebep olabileceği unutulmamalıdır (Carvalho ve diğerleri, 2014; Salfate, Marin, Cuevas ve Montecinos, 2020; Sayeed ve diğerleri, 2020; Dupuy ve diğerleri, 2021).

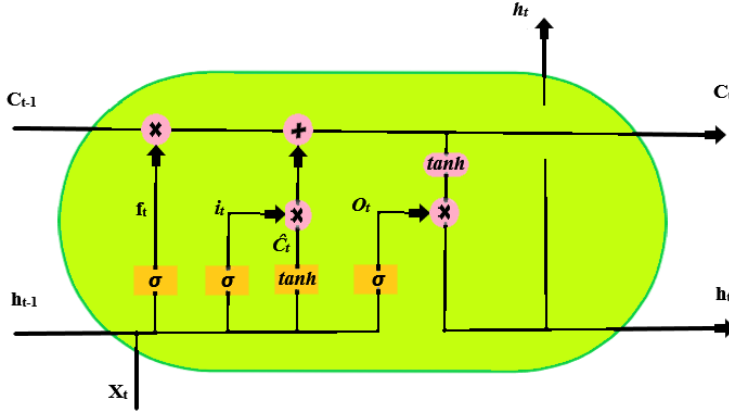
Yapay sinir ağlarının, belirli bir uygulama için üretilen veri seti üzerinde eğitildikten sonra yüksek uygulama performansına ve sabit yürütme sürelerine ulaşabildiği bilinmektedir. Bir yapay sinir ağı, sinyalleri birbirine iletebilen, farklı ağırlıklarla birbirine bağlı düğümlerden oluşan bir yapıya sahiptir. Alıcı düğümlere gelen sinyaller işlenmiş sonuçları bağlı olduğu düğümlere ileterek iletişimi devam ettirir. Her bir düğümde gerçekleşen işlem, kullanılan özgül sinir ağı parametrelerine bağlı olarak değişiklik gösterir (Bordoni ve Giagu, 2023).

İleri beslemeli sinir ağları, bilgiyi girdiden çıktıya kesintisiz aktarmanın temelini oluştururken, tekrarlayan sinir ağları daha karmaşık bir yapıya sahiptir ve kayıp fonksiyonunun minimize edilmesini de sağlayan geri besleme döngülerini içerir. İleri Beslemeli Sinir Ağları (FFNN), basit yapısıyla hızlı sonuçlar üretirken, Yinelemeli Sinir Ağı (RNN) karmaşık problemleri etkili bir şekilde ele alabilir. İleri beslemeli sinir ağlarında,

giriş sinyalleri gizli katman düğümlerine iletilir. Her gizli katman düğümünün çıkışı, sonraki gizli katmanın düğümlerine girdi olarak hizmet eder. Son gizli katmanın çıkışı ise çıkış katmanına iletilir. Farklı katmanlar arasındaki ağırlıklı bağlantılar W_i olarak adlandırılır ve her katmanın sapması b olarak belirtilir. Aktivasyon fonksiyonu σ , sigmoid, hiperbolik tanjant (tanh) veya doğrultulmuş lineer birim (ReLU) gibi yaygın seçenekler arasından seçilir (O'Brien, Tarasinski ve DiCarlo, 2017).

Tekrarlayan sinir ağlarında, önceki adımlardan gelen y_{t-1} ve h_{t-1} çıktıları dikkate alınır. RNN'ler, her düğümde bilginin iki yönde de hareket etmesine izin veren bir geri besleme döngüsü içerir. Bu nedenle tekrarlayan sinir ağları, gürültülü girdi akışlarında zaman içindeki desenleri belirleme yeteneğine sahiptir. Eğitim sırasında sinir ağı, verilen girdiye dayalı olarak doğru çıktıyı üretmek için ağırlıklarını ayarlar. Sinir ağı, eğitim girdilerine uygun çıktılar tahmin ettiğinde eğitim tamamlanır. Bu tahmin yakınlığını ölçmek için kayıp fonksiyonu kullanılır. Eğitimde kullanılan kayıp fonksiyonu (Eş. 1.2), istenen ve tahmin edilen çıktılar arasındaki farkları hesaplar ve sinir ağını sürekli iyileştirir. Uzun-Kısa Vadeli Bellek (LSTM) hücresi (Şekil 1.2), sinyallerin diğer düğümlere iletilip ileilmeyeceğine karar vermek için giriş, unutma ve çıkış kapıları gibi ekstra kapılar (Eş. 1.3, 1.4, 1.5, 1.6, 1.7, 1.8) içerir. W , önceki gizli katman ile mevcut gizli katman arasındaki tekrarlayan bağlantıları temsil eder. U , girdileri gizli katmana bağlayan ağırlık matrisini belirtir. C , mevcut girdiye ve önceki gizli duruma bağlı olarak hesaplanan aday gizli durumu ifade eder. C , birim içi belleği temsil eder; bu, önceki belleğin unutma kapısı ile çarpımının ve yeni hesaplanan gizli durumun çarpımının toplamını içerir. Burada n , veri noktalarının sayısını gösterirken, Y_i hedef değeri ve \hat{Y}_i tahmin edilen değeri ifade eder (Bordoni ve Giagu, 2023).

Kayıbı en aza indirmek için ağırlıkların güncellendiği sürece geri yayılım adı verilir. Bu yöntem, kayıp fonksiyonunun ağırlıklara göre gradyanını hesaplar. Sinir ağları, farklı uygulamalarda çözümler üretebilmek için her düğümün işlem adımında, doğrusal olmayan bir aktivasyon fonksiyonuna ihtiyaç duyar. Bu işlev, düğümün sonraki düğümlere olan katkısını belirler (Edmonds, 1965).



Şekil 1.2. LSTM hücresi

$$\text{Kayıp} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (1.2)$$

$$i_t = \sigma(x_t U^i + h_{t-1} W^i) \quad (1.3)$$

$$f_t = \sigma(x_t U^f + h_{t-1} W^f) \quad (1.4)$$

$$o_t = \sigma(x_t U^o + h_{t-1} W^o) \quad (1.5)$$

$$\hat{C}_t = \tanh(x_t U^g + h_{t-1} W^g) \quad (1.6)$$

$$C_t = \sigma(f_t * C_{t-1} + i_t * \hat{C}_t) \quad (1.7)$$

$$h_t = \tanh(C_t) * o_t \quad (1.8)$$

Makine öğrenimi algoritması yaklaşımı, veri analizi, model eğitimi ve bu modellerle başka verilerin analiz edilmesi şeklinde özetlenebilir ayrıca sinir ağları, derin öğrenme, gradyan artırma makinesi yöntemleri de bu alanda tercih edilen bazı yaklaşımlardır. Yapay zeka, zaman içerisinde hataları düzelterek ve kendini geliştirerek daha iyi sonuç verir ve bu nedenle zorlu problem hesaplamaları için uygun bir araçtır. Makine öğrenme yöntemi ise çok fazla veriye ihtiyaç duyar ve yüksek hesaplama maliyetlerine sebep olabilir, özellikle derin öğrenme yöntemi hesaplama süresi bakımından uzun eğitim süreleri gerektirebilir (Niu, Pu ve Dai, 2018).

Bu çalışmadaki amaç ve hedefler, WRF sayısal tahmin modelinin coğrafi özellikler gözetilerek uygun değişkenler ile çalıştırılması, bununla birlikte gün öncesi piyasası ve gelecek yatırımları için uygun rüzgar hızı ve gücü potansiyeli tahminlerini yapay zeka yardımıyla da daha doğru ve hızlı tahmin edilmesini sağlamaktır.

2. ÖNCEKİ ÇALIŞMALAR

Martínez-Arellano ve Nolle (2013) tarafından İspanya'nın Galicia bölgesinde, Genetik Programlama algoritmasıyla ortalama karekök hatasına göre model tahminin rüzgar enerjisi ile üretim doğruluğu %87 olarak bulunmuş ve dönemin standartları için iyi bir sonuç olduğu bildirilmiştir.

Guo ve Xiao, (2014) Çin'in kuzeyinde WRF-SLFN-OD ve WRF-SLFN-WD hibrit yaklaşımları ve güç eğrisi ile rüzgar hızı ile güç üretimi tahminlerinde WRF-SLFN modeline kıyasla %40,74'e varan ölçekte bağlı hatada azalma sağlamıştır.

Carvalho ve diğerleri (2014) tarafından Iber Yarımadası bölgesinde yaptıkları çalışmada WRF modeli için PBL ve SL parametrelendirmeleri ile rüzgar hızı, yönü ve enerji üretimi için duyarlılık analizi yapılmıştır. Yapılan çalışmada ortalamada PBL ve SL için sırasıyla Asimetrik Konveksiyon Modeli Şeması 2 (ACM2) ve Pleim-Xiu (PX) şemalarının üstünlüğü görülmüştür.

Y. Li ve diğerleri (2016) Kanada'nın Alberta bölgesinde WRF modeli ve Çok Katmanlı Algılayıcı Sinir Ağı (MLP-NN) ve K ortalamaları ile kümeleme yaklaşımını kullanarak, rüzgar gücü ve rampa olaylarını tahmin etmişler, farklı kümeleme şekillerinin farklı bölge koşullarında tahmin hatası bakımından farklı sonuçlar ürettiği ama büyük farklar oluşturmadığı sonucuna varılmıştır.

Zhao ve diğerleri (2016) Çin'in doğusunda Guguk Kuşu-Bulanık Sistem-WRF-Topluluk (CS-FS-WRF-E) isimli bir tahmin modeli ile Ortalama-WRF-Topluluk (M-WRF-E), FS-WRF-E ve Guguk Kuşu-Ortalama-WRF-Topluluk (CS-M-WRF-E) modellerini karşılaştırmış ve bu modellere kıyasla sırasıyla %34,30, %37,44 ve %38,18 daha düşük ortalama kare hatasına sahip olduğu bildirilmiştir.

Men, Yee, Lien, Wen ve Chen, (2016) Tayvan'da yaptıkları bir çalışmada, sinir ağı topluluk yaklaşımı Karışım Yoğunluğu Ağı (MDN) ile Otoresif Hareketli Ortalamalar (ARMA), Genelleşmiş Otomatik Regresif Değişken Varyans (GARCH) ve Dışsal Girdili Doğrusal Olmayan Otoresif Ağ (NARX) yaklaşımları ile performanslarını kıyaslamıştır ve

ortalama karekök hatası ve ortalama mutlak hata değerleri sırasıyla 1,97 ve 2,08 olarak daha başarılı sonuçlar verdiğini göstermiştir.

Zhao ve diğerleri (2017) Çin'in Shandong eyaletinde yaptıkları çalışmada, Guguk Kuşu-Bulanık Sistem- Önsel-WRF (CSFC-Apiori-WRF) hibrit tahmin yaklaşımını kullanarak ortalama karekök hatasında, sadece WRF ve Basit Kümeleme-Önsel-WRF (SC-Apiori-WRF) modelleri ile karşılaştırmışlar ve sırasıyla %29,82 ve %21,11 gelişme sağlandığını tespit etmişlerdir.

Niu ve diğerleri (2018) Moğolistan'ın merkezinde ve Çin'in güney doğu kıyılarında yaptıkları çalışmada Niş Bağışık Aslan Algoritması (NILA-WRF) ve Dalgacık Ayırıştırma (WD) hibrit modeli ile Rastgele Orman (RF), Destek Vektör Makinesi (SVM) ve Geri Yayılım (BP) yöntemlerini karşılaştırmış ve bu model ortalama mutlak yüzde hatasında sırasıyla %5,78 ve %5,45 değerleri ile üstünlüğünü göstermiştir.

Di ve diğerleri (2019) Çin'in doğusunda yaptıkları çalışmada rüzgar hızı tahminleri için WRF modelinin değişkenlerini, Uyarlamalı Vekil Modelleme Tabanlı Optimizasyon (ASMO) ve Çok Değişkenli Uyarlanabilir Regresyon Eğrisi (MARS) yaklaşımları kullanarak geliştirmiş ve ortalama karekök hatasında %7,58 iyileşme sağlamıştır.

Groch ve Vermeulen, (2019) Afrika'da yaptıkları çalışmada Motorsuz Görsel Algı Testi (MVPT) ve iki katmanlı FFNN için rüzgarın yönü ve havanın sıcaklığı değişkenlerinden de faydalanılan giderlerin tek başına bir sinir ağına göre azaltıldığı bir topluluk yaklaşımını benimsemiş ve ortalama mutlak hatada 1,60 değerine ulaşarak sinir ağlarına yaklaşan performanslara ulaşılabildiğini belirtmişlerdir.

F. Li ve diğerleri (2019) Çin'in Jilin eyaletinde Rüzgar Hızı ve Türbülans Yoğunluğu (WSTI-RNN) olarak adlandırılan bir tahmin modeli kullanmış, bunu geleneksel makine öğrenme algoritmalarıyla performanslarını değerlendirerek, üstünlük ve zayıflıklarını ortaya koymuşlardır.

Teixeira ve diğerleri (2020) tarafından Brezilya'nın Paranapanema bölgesinde yaptıkları çalışmada, bir BP kullanılarak düzenlenmiş Çok Katmanlı Algılayıcı (MLP) ile hibrit bir

yaklaşım kullanılmış ve ortalama mutlak hata değerleri sırasıyla 0,43, 0,44, 0,4256, 0,43 olmuştur.

Wei (2020) Tayvan'ın kuzeydoğusunda yaptığı çalışmada MLP, Derin Tekrarlayan Sinir Ağları (DRNN), yığılmış LSTM ve diğer sinir ağı yaklaşımlarını değerlendirmiştir. Yığılmış LSTM yaklaşımının ortalama mutlak hatası sırasıyla 0,93 ve 1,53 değerlerine ulaşmış ve daha tutarlı tahminler ürettiğini göstermiştir.

Özen, Dinç, Deniz ve Karan (2021), Kayseri Yahyalı bölgesinde gerçekleştirdikleri çalışmada Gradyan Destekli Makineler (GBM) hibrit bir yaklaşım kullanmış ve bu yaklaşımın daha yüksek hesaplama maliyetleri ve çözünürlüğü olan WRF modeli ile tahmin performanslarını karşılaştırmış ortalama mutlak hata değerinde %28,86 düşüş sağladığını ve hesaplama süresinin ise büyük bir oranda azaldığını bildirmişlerdir.

Salfate ve diğerleri (2020) Şili'nin kuzeyinde bulunan Coquimbo bölgesinde yaptıkları bir çalışmada gezegensel sınır tabakasının uygun olarak belirlenmesi için duyarlılık analizi yaparak Yarı Normal Ölçekli Eleme (QNSE) şemasını belirlemiş, bu şemanın kullanıldığı WRF modelini, BP ve Parçacık Sürü Optimizasyonu (PSO) algoritmaları ile eğitilmiş Çok Katmanlı İleri Beslemeli Bir Sinir Ağı (MFNN) kullanan bir WRF modeli ile karşılaştırmışlar ve ham WRF tahminlerinde ortalama karekök hataları 2,68 ve 2,45 değerlerinden, 1,67 BP ve 1,65 PSO değerine düşmüştür. Hesaplama sürelerinde ise %75'e varan bir kazanç elde edildiği bildirilmiştir.

Sayeed ve diğerleri (2020) Güney Kore bölgesi için yaptıkları çalışmada WRF model çıktılarında tespit edilen sapmaları azaltmak amacıyla modeldeki değişkenler için farklı bir model uygulamış ve Weather-AI adında bir model geliştirmiştir. Geliştirilen bu modelin yapılan tahminlerde %27 gelişme gösterdiği bildirilmiştir.

Donadio, Fang ve Porté-Agel (2021), İsviçre'deki Jura dağlarında yaptıkları çalışmada rüzgar ile güç üretimini sinir ağları ile tahmin ettikleri bir modeli, önce sinir ağı ile rüzgar hızının tahmin edildiği dolaylı başka bir güç üretimi tahmin modeli ile karşılaştırmıştır. Hibrit model ile Ortalama Mutlak Yüzde Hatası (MAPE) ve Ortalama Karekök Sapması (RMSE) değerlerinde sırasıyla %8,76 ve %13,03 daha tutarlı tahminler elde edildiği belirtilmiştir.

Crippa, Alifa, Bolster, Genton ve Castruccio (2021) Suudi Arabistan coğrafyasında gerçekleştirdikleri çalışmada, güç kanunu ve coğrafi olaylarla her saat değişiklik gösterebilen ve kalıcı olmayan bir dikey ekstrapolasyon metodunun, diğer formüllere göre %33'e kadar daha performansa sahip olduğu sonucuna ulaşmıştır.

Koivisto, Plakas, Ellmann, Davis ve Sørensen (2021) atmosferik yeniden analiz metodu ile birlikte, kullanılan birçok büyük ölçekli rüzgar santralindeki teknik verilerin eksikliğini gidermek için, veri setlerindeki eksik parametreleri makine öğrenmesi ile tahmin edebilen bir yaklaşımı kullanmış ve lineer regresyonla yıllık kapasite faktörü ve saatlik olasılık dağılım fonksiyonu sonuçlarını karşılaştırmışlardır.

Salazar ve diğerleri (2021) Japonya'nın Awaji adasındaki bir bölgede yaptıkları çalışmada, hız, yön, basınç, sıcaklık gibi değişkenleri içeren çok değişkenli bir yöntemle, tek değişkenli yöntemleri ayrıca sinir ağlarında giriş kısmında bulunan kısmi ve tamamen bağlı olma durumlarını ele almış bununla birlikte, gizli katmanlı sinir ağı ile WRF ham çıktılarını karşılaştırmış ve ortalama mutlak hata değerlerinde yaklaşık %30 bir iyileşme sağladığını bildirmişlerdir.

Bodini, Hu, Optis, Cervone ve Alessandrini (2021) Kaliforniya Dış Kıta Sahaneliğinde açık deniz karakteristiğini belirlemek için yapılan bir çalışmada GBM yaklaşımı ile analog topluluk yaklaşımını değerlendirmişler, GBM yaklaşımının daha düşük korelasyon, yanlılık ve ortalama karekök hatasına sahip olduğunu bildirmişlerdir.

Tan ve diğerleri (2021), Türkiye'nin batı bölgesi için yaptıkları çalışmada, WRF modeli kullanılarak yapılan rüzgar hızı ve rüzgar enerjisi ile güç üretim tahmini için bir yapay sinir ağı ve Model Çıktı İstatistikleri (MOS) yaklaşımı kullanılmıştır. Kullanılan hibrit yöntemin özellikle yaz aylarında ortalama karekök hatası değeri için %29 daha iyi tahminler ürettiği belirtilmiştir.

Liu, Zhang, Zhang, Zhao ve Zou (2021) Çin'in Shandong eyaletindeki Jining şehrinde yaptıkları çalışmada, Catboost, LSTM, LightBGM ve Aşırı Gradyan Artırma (XGBoost) algoritmaları karşılaştırılmış, güç üretimi tahminleri için Catboost ve LSTM algoritmaları

sırayla 7,50, 7,30 ortalama bağıl hata değerlerine ulaşırken, Catboost yaklaşımının önemli ölçüde kısa bir zaman eğitildiği belirtilmiştir.

Xu ve diğerleri (2021) Çin'in Sichuan eyaletinde yaptıkları çalışmada, çok adımlı WRF-Varyasyon Modu Ayrışımı (VMD)-Temel Bileşenler Analizi (PCA)-LSTM yaklaşımını geliştirmiştir. Kullanılan model birçok farklı hibrit modelle karşılaştırılmış ve WRF-LTS modelinde ortalama mutlak yüzde hata %68,93 iken geliştirilen modelde %13,28 olduğu bildirilmiştir.

Dupuy ve diğerleri (2021) Fransa'nın güneydoğusunda bulunan Alp eteklerinde gerçekleştirdikleri bir çalışmada, filtre seçimi ve sıralı ileri seçim yaklaşımları kullanılarak değişkenleri filtreleyen ve seçen bir yapay sinir ağı yaklaşımı ile ham WRF modelini çıktı performansını geliştirerek rüzgar hızı tahminlerinde 0,62 ortalama bağıl hata değerine ulaştığını bildirmişlerdir.

Christoforou, Emiris, Florakis, Rizou ve Zaharia (2021) Yunanistan'da gerçekleştirdikleri çalışmada, evrimsel sinir ağı (CNN) ve LSTM'nin bir arada kullanıldığı bir yaklaşım ile mekansal ve zamansal olarak rüzgarı inceleyen bir Derin Uzay-Zamansal Sinir Ağı (DSTNN) modeli geliştirmiş ve ortalama mutlak hata değeri 1,75 olarak, ortalama karekök hata değerinin ise 2,30 olarak hesaplandığı belirtilmiştir.

Jiang ve diğerleri (2021) Çin'in Shandong yarımadasında yaptıkları çalışmada rüzgar hızı tahmini için istatistiksel yöntemler ile hem sinir ağlarından hem de derin öğrenme tekniklerinden temel olarak faydalanan bir hibrit yöntem geliştirmiştir. Ayrıca Değiştirilmiş Çok Amaçlı Yusufçuk Algoritması (MMODA) ve çeşitli alt modeller ile Bütünleşik Otoregresif Hareketli Ortalama (ARIMA), (BP), NN, Derin İnanç Ağı (DBN), Aşırı Öğrenme Makineleri (ELM), Elman Sinir Ağı (ENN), Genel Regresyon Sinir Ağı (GRNN) ve LSTM vb. birçok algoritmayı değerlendirmiştir. Geliştirilen hibrit sistemin ortalama mutlak yüzde hatasında sırasıyla bölge 1 için, %2,92, %3,17 ve %4,84, bölge 2 için %2,27, %2,59 ve %3,48 değerlerine ulaştığını bildirmiştir.

Han ve diğerleri (2022) çok değişkenli doğrusal regresyon teorisi temel alınarak rüzgar hızı tahmin aralığı oluşturmak için WRF'den gelen çok sayıda değişkeni kullanmıştır ve veri toplama, çözümlenme ve aralık tahmininden oluşan üç modülü içeren yeni bir rüzgar hızı

yöntemi önerilmiştir. Deneysel sonuçlar, bu modelin, birkaç temel yönteme göre daha iyi tahmin aralığı doğruluğu elde ettiğini göstermiştir. Rüzgar hızı tahmin aralığı durumunda, VMD-BP ve VMD-LSTM üzerinde sırasıyla %49,53 ve %15,21 oranında iyileşme olduğu bildirilmiştir.

Xiong, Zou, Sheng, Zeng ve Ye (2023) tarafından rüzgar hızı tahminini WRF modelinden daha doğru hale getirmek amacıyla rüzgar hızı dalgalanma özelliklerine dayalı ultra kısa vadeli bir rüzgar hızı düzeltme yöntemi olan Uçucu Durağan Gün modeli (VSDA)-BO-LSTM modeli önerilmiştir. VSDA modelinin çıktısıyla birleştirilen LSTM, WRF modelinin rüzgar hızı tahmin değerinin düzeltilmesi için kullanılmıştır. Önerilen yöntem mevcut en son teknoloji model ile karşılaştırıldığında oldukça başarılı olduğu bildirilmiştir.

3. MATERYAL VE METOT

Bu arařtırmada, 2021-2022 zaman diliminde Trkiye genelinde ve zellikle gney ve batı blgeleri iin (WRF-ARW) 3.9 versiyonu ile bir sayısal tahmin modeli ve bir yinelemeli sinir ađı (RNN) olan Uzun Kısa Sreli Bellek (LSTM) yaklařımı ile rzgar hızı, yađıř, sıcaklık, nem gibi veriler llen deđerlerle karřılařtırılmıř ve aynı zamanda yapay zeka modelindeki deđiřkenler olarak tahmin performansının geliřtirilmesi iin kullanılmıřtır.

Kullanılan model (izelge 3.1), Ulusal evresel Tahmin Merkezleri (NCEP) ve Kresel Tahmin Sistemi (GFS) temellidir ve 0,25 x 0,25 znrlđne sahip bařlangı, sınır kořulları ile saatlik tahminler retilmiřtir. Biri byk olmak zere iki adet kk etki alanı erevesindeki alıřma blgesi (řekil 3.1) birbirinden farklı beř řehir ve altı konumda olmak zere bir saatlik zaman adımları ile bařlatılmıřtır. lm verileri ve kaynakları yasal sebeplerden tr paylařılmamıřtır. Veriler İklım Veri Operatr (CDO), Excel ve Pandas ile dzenlenmiř, Panoply ve Python ile grselleřtirilmiřtir. Rzgar enerjisi ile 3 MW ve 2,30 MW g retim potansiyeli haritaları tm Trkiye ve kıyılarını kapsayan bir projeksiyon iin gnuplot yazılımında eđri eřitleme yaklařımı kullanılarak  deđiřkenli bir sigmoid fonksiyonu kullanılmıř, bilinmeyen deđiřkenler ise bu řekilde hesaplanmıř ve incelenmiřtir.



řekil 3.1. alıřma blgesi iin 25 km, 9 km ve 3 km ile model ızgaraları

Hesaplanan fonksiyondaki eşitlik sayesinde, 10 m yükseklikteki tahminler gerçekleştirilebilirken, gerçekte 90 m ve daha yüksek olan bölgelerin farklı hava koşulları ve dolayısı ile farklı rüzgar hızlarının doğru hesaplanabilmesi için, Thompson (2002: 224) bildirdiği üzere (Eş. 3.1) ve 0,30 değerindeki Hellman katsayısı, insan yaşam bölgesi sayılan dengesizlik ve nötr hava için iki değer arasında uygun olarak belirlenmiştir.

Çizelge 3.1. WRF V3.9 model yapılandırması

| | |
|-------------------------------------|------------------------|
| Başlangıç Tarihi | 1 Ocak 2021 |
| Model Versiyonu | V3,90 |
| Çalışma Aralığı | 365 Gün |
| PBL | YSU Şeması |
| Mikrofizik | Ferrier Şeması |
| Yüzey Tabakası | Monin-Obukhov Şeması |
| Kara Yüzeyi Modeli | Termal Difüzyon Şeması |
| Uzun / Kısa Dalga Radyasyonu | RRTM/Dudhia Şeması |
| Kümüls | Kain-Fritsch Şeması |
| Dikey Seviye | 42 |
| Aerosol | Yok |
| Hata Değerlendirmesi | MAE, MSE, RMSE, IOA |
| Giriş Verisi | GFS (0,25 x 0,25) |
| Izgara Çözünürlükleri | 25 km, 9 km, 3 km |

$$v_w(h) = v_{10} * \left(\frac{h}{h_{10}}\right)^a \quad (3.1)$$

Geçmiş araştırmalardaki kullanılan fizik ve gezegensel sınır tabakası parametrelerinden bazıları da Çizelge 3.2’de gösterilmiş ve parametre seçimlerinde referans olarak değerlendirilmiştir.

Hata ve performans ölçümlerinde ortalama kare hatası, ortalama bağıl hata, kareler ortalamasının karekökü değerlendirmeleri ile birlikte Holley ve Guilford (1964) bildirdiği üzere (Eş. 3.2), Anlaşma İndeksi (IOA) kullanılmıştır.

$$d = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad 0 \leq d \leq 1 \quad (3.2)$$

Çizelge 3.2. Ülkelere göre model parametreleri ve performansı

| Parametre (boş=verilmemiş) | MAE (boş=verilmemiş) | RMSE (boş=verilmemiş) | Bölge | ATIF |
|-------------------------------|-------------------------|--------------------------|----------------------------|-------------------------------------|
| YSU (WSM6) | | 3,09 | Portekiz | (Carvalho ve diğerleri, 2012) |
| ACM2-APP | | 1,91 | Portekiz | (Carvalho ve diğerleri, 2014) |
| MYNN2.5 (New Thompson, WSM3) | 0,88-1,03 | 1,56 | Kuzey denizi (su üzerinde) | (Giannakopoulou ve Nhili, 2014) |
| MYJ (Eta) | 0,86-4,72 | | Çin | (Zhao ve diğerleri, 2016) |
| YSU (Monin-Obukhov) | 1,92 | | Çin-Tayvan | (Men ve diğerleri, 2016) |
| Mellor-Yamada-Janjic | | 1,76-4,61 | Norveç | (Bilal ve diğerleri, 2016) |
| MYJ (Eta) | | 3,22-3,37 | Çin | (Zhao ve diğerleri, 2017) |
| BouLac (NoahMP-BEP/BEM) | 1,80 | | Amerika | (Salamanca ve diğerleri, 2018) |
| YSU (Goddard) | | 3,30 | Çin | (Di ve diğerleri, 2019) |
| MYJ, ACM2 | 1,68-1,73 | | Güney Afrika | (Groch ve Vermeulen, 2019) |
| MYJ, ACM2 | 1,31 | | Çin | (F. Li ve diğerleri, 2019) |
| MYNN2.5 (Eta) | | | Brezilya | (Teixeira ve diğerleri, 2020) |
| YSU (WSM5) | 1,09-1,36 | | Tayvan | (Wei, 2020) |
| MYNN 2.5 (WSM6) | 6,32-14,21 | | Türkiye | (Özen ve diğerleri, 2021) |
| MYNN3 (ice) | | 2,45-2,68 | Şili | (Salfate ve diğerleri, 2020) |
| YSU(WSM3) | 1,65-2,60 | | Türkiye | (Tan ve diğerleri, 2021) |
| | 0,29-0,48 | | Çin | (Jiang ve diğerleri, 2021) |
| YSU (WSM6) | 1,51-2,49 | | Çin | (Xu ve diğerleri, 2021) |
| MYNN+YSU (Ferrier) | | 0,55-0,73 | Amerika (su üzerinde) | (Bodini ve diğerleri, 2021) |
| MYNN2.5 (WSM5) | 1,80-3,21 | | İspanya | (Prieto-Herráez ve diğerleri, 2021) |
| YSU (Lin) | | 2,33-3,00 | Avusturya | (Oetl ve Veratti, 2021) |
| ACM2 (WSM6) | 1,92-2,40 | | Japonya | (Salazar ve diğerleri, 2021) |
| QNSE (WSM6) | 1,32 | | Fransa | (Dupuy ve diğerleri, 2021) |
| | 1,99-2,54 | | Yunanistan | (Christoforou ve diğerleri, 2021) |

Bir rüzgar türbinin güç eğrisi, üreticiler tarafından rüzgar hızı ve gücünün saha ölçümlerinden ve kısmen çevresel faktörlerden (sıcaklık, basınç ve bağıl nem) elde edilir.

Güç eğrilerinde üç ana nokta vardır bunlar: Türbinin güç üretemeyeceği değerin altında kesme hızı, türbinin nominal gücünün üretildiği nominal hız, türbinin güç iletmesine izin verilmeyen hız (kesim).

Tek bir türbin güç eğrisi ise göbek yüksekliğinde türbin çıkışı ve rüzgar giriş akım hızı ölçülerek belirlenir. Anormal güç çıkışı, güç eğrisini ideal eğriden saptırır ve rüzgar hızındaki artışlarda eğrilerde birbirinden uzaklaşır. Hatalı veriler oluşmaması ve daha doğru sonuçlar almak için veriler aykırı değerlerden ayıklanmalıdır (Carvalho ve diğerleri, 2014).

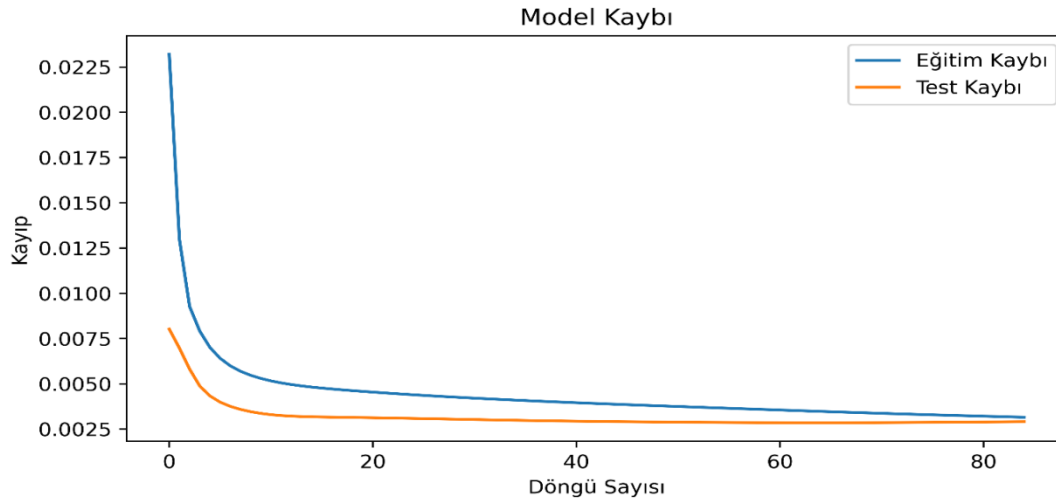
Yinelemeli bir sinir ağı olan LSTM için Çanakkale ili daha tutarlı WRF sonuçları sergilediği için test bölgesi olarak uygun görülmüştür. Veriler LSTM modeli için uygun hale getirilmelidir, bunun için veriler düzenlenmeli ve denetimli öğrenme gerçekleştirilmedi. Python yazılımı ve kütüphaneleri modelin çalıştırılması, veri analizi ve düzenlenmesi için kullanılmıştır. Ayrıca LSTM modeli Intel 11800h işlemci ve 16 gb ram donanımlarına sahip bir bilgisayar ile Windows ortamında test edilmiştir.

10 dakikalık zaman adımlı veriler veri karakteristiğinin kaybolmaması için saatlik verilere çevrilmiştir. Eksik ve tanımsız veriler ise model sonuçlarını etkileyebilir. Bunun için veri filtreleme amacıyla eksik verileri temizleme ve veri türetme yaklaşımları kullanılmıştır. Eksik veriler çıkarılarak devam edilmiştir.

Veriler normallik açısından değerlendirilmiş, verilerdeki korelasyon, durağanlık, çarpıklık ve simetrik olma durumları incelenmiştir. Veriler sonrasında günlük verilere de çevrilerek aylık ve sezonluk rezidüel ve trend durumu incelenmiştir.

Tüm veriler 0-1 değerleri aralığına sıkıştırılmış ve 0,78 eğitim 0,22 test verisi olacak şekilde ayrılmıştır, geriye bakılan zaman adımı ise sekiz saat olarak belirlenmiştir, bunun için veri kaydırma yöntemi kullanılmış ve nihayetinde beş farklı değişken, modele özellik olarak verilmiştir. Değişkenlerin seçiminde literatürden faydalanılmış ve yaptığımız testlerde en iyi sonuçları veren özellikler sıcaklık, rüzgar yönü, basınç, yağış ve WRF modelinin rüzgar hızı tahminleri olarak seçilmiştir. Hücre sayısı tek bir katmandan oluşan model için 128 adettir.

Fazla katman ve hücre kullanımı model karmaşıklığını artırabilir bu nedenle veri büyüklüğü ve çalışılan konu amacına uygun olarak seçilmiştir. Kullanılan parametreler ve hiper parametreler için de en iyi sonucu veren parametreler uygun bir öğrenme durumu (Şekil 3.2) ve veri büyüklüğü gözetilerek seçilmiştir (Çizelge 3.3).




Şekil 3.2. Döngü sayısı eğitim ve test kayıpları

Çizelge 3.3. LSTM model yapılandırması

| | |
|-----------------------|---------------------------|
| ANN | RNN |
| Model | LSTM |
| Çalışma Aralığı | 6 ay |
| Katman Sayısı | 1 |
| Hücre Sayısı | 128 |
| Veri Ayırma Oranı | 0,78 |
| Veri seyreltme | Yok |
| Toplu Normalleştirme | Yok |
| Geriye Bakma | 8 |
| Döngü Sayısı | 78 |
| Aktivasyon Fonksiyonu | Sigmoid |
| En iyileştirici | Adam |
| Kayıp Yöntemi | MSE |
| Güncelleme Örneği | 8 |
| Erken Çağırma | 20 |
| Hata Değerlendirmesi | MAE, RMSE, R ² |
| Zaman Adımı | 1 saat |

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Dünya genelindeki hava durumu ve rüzgar hızı tahminleri, rüzgar enerjisi santrali kurulumları için bölgenin coğrafi konumu ve topografyası da dikkate alınarak analiz edilmiştir. Model simülasyonlarının etkili bir şekilde temsil edilebilmesi için seçilen gezegensel sınır tabakası ve mikro fizik parametreleri (Çizelge 3.2) ile birlikte, Türkiye'nin rüzgar hızı potansiyelini gösteren haritada (Şekil 4.1), Çanakkale, Balıkesir, İzmir ve Manisa bölgelerinin ortalama olarak yüksek rüzgar hızlarına sahip olduğu belirlenmiştir. Bu faktörlerin göz önünde bulundurulmasıyla (Çizelge 4.1), model parametreleri uygun şekilde ayarlanmış ve bu durum, performans değerlendirmelerine olumlu şekilde yansımıştır.




Şekil 4.1. Türkiye yıllık ortalama rüzgar hızı haritası

Çizelge 4.1. Rüzgar hızı hata ve performans değerlendirmesi


| Bölgeler | MAE | MSE | RMSE | IOA |
|-----------------|------|-------|------|------|
| Balıkesir | 1,47 | 3,85 | 1,96 | 0,83 |
| Çanakkale | 1,35 | 3,24 | 1,80 | 0,87 |
| Hatay | 2,28 | 9,70 | 3,11 | 0,64 |
| İzmir-Çeşme | 4,06 | 22,30 | 4,72 | 0,52 |
| İzmir-Güzelyalı | 1,45 | 3,75 | 1,94 | 0,67 |
| Manisa | 3,10 | 13,14 | 3,62 | 0,38 |

Şekil (4.1, 4.2, 4.3) incelendiğinde, Türkiye'nin bir yıllık ortalama rüzgar hızı, sıcaklık ve toplam yağış tahmin haritalarına göre genel olarak 3-5 m/s arasında rüzgar hızları tahmin edilmiştir. Yıllık ortalama olarak, Akdeniz, İç Anadolu ve Ege bölgeleri 4 m/s ve üzeri

rüzgar hızlarına sahipken, bu koşullar güç üretimi için elverişli bir potansiyel sunar. Türkiye'nin güney ve batı bölgeleri genel olarak ortalama sıcaklıkların üstünde yer alırken, kuzey ve iç bölgeler daha dengeli bir sıcaklık dağılımına sahiptir. Bununla birlikte, doğu bölgelerinde model genellikle daha soğuk tahminler üretmiştir.



Şekil 4.2. Türkiye yıllık ortalama sıcaklık haritası



Şekil 4.3. Türkiye yıllık toplam yağış

Sıcaklığın arttığı bölgelerde yağışlar da görülebilmektedir. Türkiye genelinde yıllık toplam yağış miktarları (Şekil 4.3), metrekare başına en fazla Marmara, Ege ve Akdeniz bölgelerinin bazı bölgelerinde yoğunlaşmıştır. Ancak ağırlıklı ortalama bakıldığında, Karadeniz ve Akdeniz'in belirli bölgelerinde yoğun yağış görülmektedir. Bu duruma ek olarak, tahmin edilen bölgelerin ortalama sıcaklıkları birbirine yakın sonuçlar vermektedir (Çizelge 4.2).

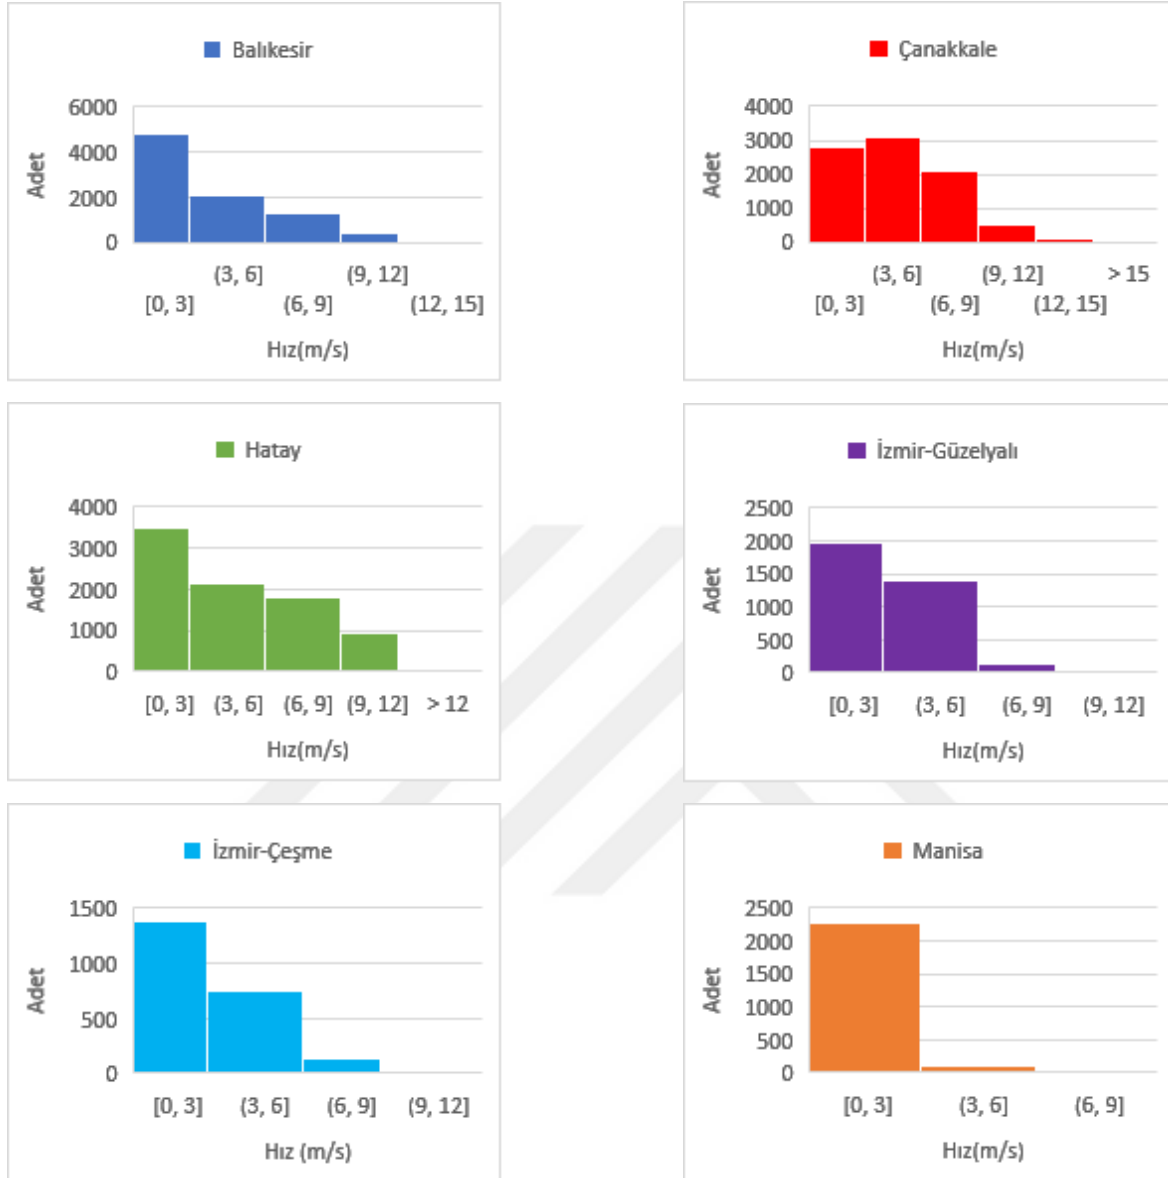
Çizelge 4.2. Çalışma bölgelerinde yağış ve sıcaklık istatistik verileri

| Bölgeler | Yağış Ortalama | Sıcaklık Ortalama | Yağış Varyasyon |
|-----------------|-----------------------|--------------------------|------------------------|
| Balıkesir | 0,29 | 12,61 | 288,44 |
| Çanakkale | 0,52 | 13,06 | 343,43 |
| Hatay | 0,23 | 16,83 | 519,08 |
| İzmir-Çeşme | 0,57 | 15,09 | 493,20 |
| İzmir-Güzelyalı | 0,36 | 15,05 | 299,55 |
| Manisa | 0,54 | 12,52 | 281,55 |

| Bölgeler | Yağış Standart Sapma | Sıcaklık Standart Sapma | Sıcaklık Varyasyon |
|-----------------|-----------------------------|--------------------------------|---------------------------|
| Balıkesir | 0,85 | 9,41 | 74,59 |
| Çanakkale | 1,77 | 8,95 | 68,52 |
| Hatay | 1,18 | 8,89 | 52,81 |
| İzmir-Çeşme | 2,79 | 8,15 | 53,98 |
| İzmir-Güzelyalı | 1,08 | 9,53 | 63,27 |
| Manisa | 1,53 | 9,11 | 72,75 |

Bir yıl boyunca saatlik ölçümlerle elde edilen verilere göre, bölgelerin rüzgar hızı dağılımları incelendiğinde (Şekil 4.4), Manisa bölgesi dışındaki tüm bölgelerin çoğunlukla 0-3 m/s ve 3-6 m/s aralıklarında rüzgar hızlarına ev sahipliği yaptığı gözlenmiştir. Ayrıca, ölçümlerde tespit edilen maksimum hız aralığı olan 12-21 m/s aralığında sık rastlanmadığı görülmüştür. Şekillerin analizi sonucunda, Manisa dışındaki bölgelerin enerji üretimi için yeterli rüzgar hızlarına sahip olduğu sonucuna varılmıştır.

Bir yıllık zaman dilimindeki Türkiye'nin çeşitli illerinin ve bölgelerinin saatlik rüzgar hızı ölçümlerine dayalı dağılım grafiği incelendiğinde (Şekil 4.5), Hatay'ın genel olarak diğer bölgelere göre daha homojen bir profil sergilediği ve ortalama olarak daha yüksek hızlarla ilişkilendirildiği gözlemlenmektedir. Bununla birlikte, model tahminleri Hatay için farklı bir tablo çizmektedir. Ölçümlerde ise, Çanakkale ve Hatay arasında benzer bir dağılım görülmektedir. Manisa bölgesinin ortalama rüzgar hızları (Çizelge 4.3) yıl boyunca en düşük hızlara sahipken, hız yoğunluğu bakımından değerlendirildiğinde sıralamanın sırasıyla Çanakkale, Hatay, Balıkesir, İzmir-Güzelyalı, İzmir-Çeşme ve Manisa şeklinde olduğu görülmektedir.




Şekil 4.4. Bölgelerin rüzgar hızı ölçümünün dağılım adetleri

Çizelge 4.3. Bölgelerin saatlik rüzgar hızı ölçüm (m/s) verisi istatistikleri

| Bölgeler | Aritmetik Ortalama | Standart Sapma | Varyasyon |
|-----------------|--------------------|----------------|-----------|
| Balıkesir | 3,11 | 3,00 | 96,30 |
| Çanakkale | 4,65 | 2,77 | 59,69 |
| Hatay | 4,52 | 3,27 | 72,24 |
| İzmir-Çeşme | 2,77 | 1,66 | 59,97 |
| İzmir-Güzelyalı | 2,77 | 1,64 | 59,31 |
| Manisa | 0,84 | 0,95 | 113,39 |

2021-2022 yıllarına ait yıllık saatlik ortalama rüzgar hızları gözden geçirildiğinde (Çizelge 4.3), Çanakkale ve Hatay illerinin en yüksek hızlara sahip olduğu görülmektedir. Manisa ve

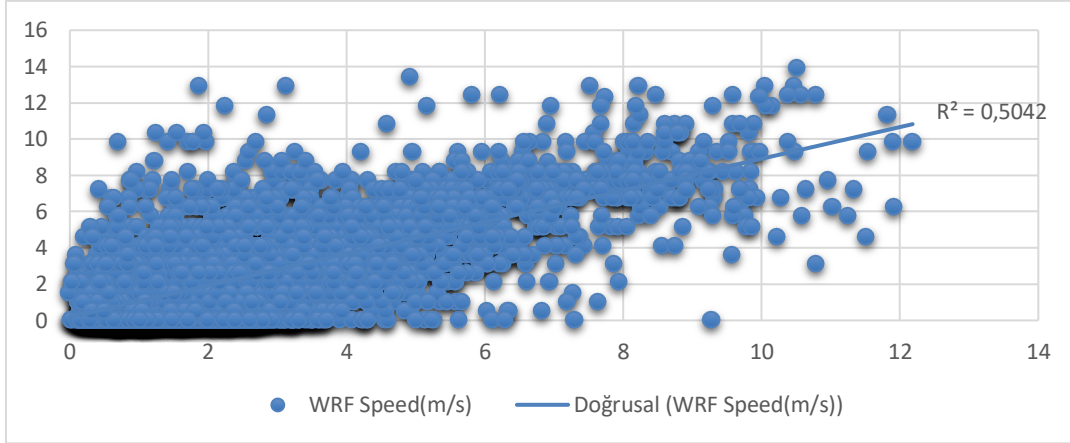
İzmir ise en düşük standart sapma değerlerine sahipken, tüm iller aritmetik ortalamaya yakın veya yüksek değerlere sahiptir, bu nedenle rüzgar hızı ölçüm verileri homojen bir görüntü sergilemektedir.



Şekil 4.5. Bir yıllık zaman dilimindeki farklı illerdeki bölgelerin, saatlik rüzgar hızı ölçüm verileri


Çizelge 4.3 verilerine göre, Manisa ve Balıkesir illeri en yüksek varyasyon değerlerine sahiptir. Tüm veriler, aritmetik ortalama, standart sapma ve varyasyon kriterlerine göre değerlendirildikten sonra, en iyi performansı Çanakkale ilinin sergilediği görülmektedir. Çünkü bu il, daha yüksek ortalama hız, daha düşük standart sapma ve varyasyon değerleri ile öne çıkmaktadır. Bölge illerinin rüzgar hızı ölçüm verileri ile model tahminlerinin hata değerlendirmesi ve performans sonuçları Çizelge 4.1'de sunulmuştur. Rüzgar hızı ölçüm verileri ve model tahmin performansları bazı bölgelerde tatmin edici seviyededir, ancak bazı bölgelerde yüksek hata değerleri gözlemlenmektedir.

Balıkesir ilindeki bölge, en yakın yerleşim alanına 2 km uzaklıktadır ve deniz seviyesinden 98 m yüksektedir. Bu alan geniş bir açık araziye sahiptir, bu da bölgedeki doğal veya yapay etkilerin daha az olduğu anlamına gelir. Ancak, model ızgarasında bulunan bölgenin koordinatları içinde, özellikle yakındaki insan yerleşimlerindeki 50 m'ye kadar olan yükseklik farkları gibi durumlar bulunmaktadır. Bu nedenle, dikey rüzgar gradyanına etki etmesi kaçınılmazdır ve bu da tahminleri etkileyebilir (Şekil 4.6). Bununla birlikte, WRF modeli 1,46 Ortalama Mutlak Hata (MAE) ile bu alanda başarılı bir tahminde bulunmuştur (Bu bölge çoğunlukla ölçüm yüksekliğine yakındır).



Şekil 4.6. Balıkesir ilinde WRF model tahmini ve ölçüm ilişkisi


Çanakkale ilindeki bölge ise insan yerleşimlerine daha yakındır ve deniz seviyesinden 8 m yüksektedir. Ayrıca, ızgaranın içinde sahil, açık su yüzeyleri, dağlar ve ağaçlar gibi öğeler bulunmaktadır. Bu durum, benzer şekilde ~50 m'ye kadar olan yükseklik farklarına neden olabilir ve ayrıca sıcaklık ve basınç farkları da rüzgar hızındaki değişikliklere neden olabilir (Şekil 4.7).



Şekil 4.7. Çanakkale ilinde WRF model tahmini ve ölçüm ilişkisi


Hatay bölgesindeki konum ise deniz seviyesinden 8 m yüksektedir. Ölçüm noktası açık bir arazi üzerindedir ve bu tür alanlarda yüzey sürtünmesi daha düşüktür, bu da daha yüksek rüzgar hızlarının beklenebileceği anlamına gelir. Ancak, bu bölgedeki nispeten düşük performansın nedeni, ızgara içindeki alandaki çok sayıda ve yüksek dağlar tarafından oluşturulan yükseklik farkları ve ağaçlık bölgelerdir. Bu tespitler sonucunda, model

tahminlerini etkilediği sonucuna varılmıştır. Burada WRF modeli, rüzgar hızı ölçümlerine göre ağırlıklı olarak daha düşük tahminler üretmiştir (Şekil 4.8).




Şekil 4.8. Hatay ilinde WRF model tahmini ve ölçüm ilişkisi

İzmir-Çeşme ilçesindeki bölge, deniz seviyesinden 52 m yüksekte yer almaktadır ve geniş bir açık araziye sahiptir. Bu bölgede, model tarafından bölgesel türbülanslar, yüzey sürtünmesi ve konveksiyonların iyi temsil edilemediği belirlenmiştir. Ayrıca, ızgara içinde sahil, açık su yüzeyi, dağlık ve ağaçlık bölgeler ile 110 m'ye varan yükseklik farkları bulunmaktadır, bu da model tahminlerini etkilemektedir. Bu nedenlerle WRF modelinin bu bölgede genel olarak aşırı tahminler yapmış olabileceği düşünülebilir (Şekil 4.9).



Şekil 4.9. İzmir-Çeşme'de WRF model tahmini ve ölçüm ilişkisi

İzmir-Güzelyalı ilçesindeki ızgara konumunda, insan yaşam alanları, sahil bölgeleri ve açık su yüzeyleri bulunmaktadır. Ancak, bölge içindeki yapılar ve ağaçlık bölgeler, yaklaşık 80 m'ye kadar olan yükseklik farkları ile model tahminlerini etkilemektedir. Bu bölge deniz seviyesine oldukça yakın bir konumda bulunmaktadır. Yerden yükseklik azaldıkça, yüzey sürtünmesi ve rüzgar hızında değişimler ile türbülanslar ortaya çıkabilir ve bu durum genellikle tahminleri olumsuz etkiler. WRF modeli, bu bölgede 1,45 MAE değeri ile iyi bir performans sergilemiştir (Şekil 4.10).




Şekil 4.10. İzmir-Güzelyalı’da WRF model tahmini ve ölçüm ilişkisi

Manisa bölgesi, deniz seviyesinden 62 m yüksekte yer almakta olup, ızgara içindeki dağlık alanlar ise 390 m'ye kadar olan yükseklik farklarına sahiptir. Aynı zamanda bölgede bulunan insan yaşam alanları ve ağaç yoğunluğu, rüzgar hızını önemli ölçüde etkilemektedir. Model simülasyonunun coğrafyayı iyi temsil edememesi ve ölçümlere kıyasla normalden daha yüksek tahminler yapmasına neden olmuş olabilir. Manisa bölgesi, Çeşme'yi takiben en düşük performansa sahip olan bir bölge olarak öne çıkmaktadır (Şekil 4.11).

Model tahminleri ve rüzgar hızları mevsimsel olarak da analiz edilmiştir. Karasal bölgelerde, kış mevsimi boyunca doğu bölgeleri ve Marmara Bölgesi için rüzgar yoğunluğu daha homojen bir dağılıma sahiptir (Şekil 4.12). Yaz ve sonbahar aylarında ise Karadeniz'in uzak bölgelerinde ortalama 4 m/s ve üzerinde rüzgar hızları gözlenirken, İç Anadolu'da ilkbahar mevsimi ile birlikte rüzgar hızlarında artış görülmektedir. Açık denizlerde ise batı bölgeleri her mevsimde yüksek rüzgar hızlarına sahipken, Akdeniz en iyi performansı kış ve ilkbahar

mevsimlerinde sergilemektedir. Bu bağlamda, Karadeniz için en uygun rüzgar koşullarının sonbahar ve kış mevsimlerinde olduğu görülmektedir.




Şekil 4.11. Manisa ilinde WRF model tahmini ve ölçüm ilişkisi

Üç parametrelili sigmoid fonksiyonunu kullanarak oluşturulan 2,3 MW ve 3 MW güç eğrileri (Şekil 4.13), verilen fonksiyonla uyumlu bir şekilde eşleşmiştir (Çizelge 4.4 ve 4.5). Bu eğriler temel alınarak Türkiye'nin rüzgar enerjisi üretim potansiyeli haritaları da oluşturulmuştur (Şekil 4.14 ve 4.15). Bu haritalar, sırasıyla 2,3 MW ve 3 MW ortalama güç üretim potansiyelini göstermektedir. Batı ve güney bölgeleri ile kıyı kesimleri, ortalama rüzgar gücü üretimi için daha elverişli bölgeler olarak belirlenmiştir.


Çizelge 4.4. 2,3 MW güç eğrisi parametreleri ve hata değerleri

| 2,3 MW Güç Eğrisi | a | b | c |
|-----------------------------|------------------|------------------|-----------------|
| Ayarlanmış Parametre Değeri | 2 395,7 | 8,83 | 1,47 |
| Asimptotik Standart Hata | +/-20,37 (%0,85) | +/- 0,05 (0,55%) | +/-0,04 (%2,58) |
| Korelasyon Matrisi a | 1,00 | | |
| Korelasyon Matrisi b | 0,76 | 1,00 | |
| Korelasyon Matrisi c | 0,67 | 0,51 | 1,00 |


Güç eğrisi parametrelerinin incelenmesi sonucunda, asimptotik standart hataların (Çizelge 4.4 ve 4.5) %1'in altında olduğu görülmüştür. En yüksek korelasyon matris ilişkileri sırasıyla a-b ve a-c arasında bulunmaktadır. En düşük ilişki ise b ve c parametreleri arasında tespit edilmiştir.




Şekil 4.12. Türkiye mevsimsel ortalama rüzgar hızı haritası



Şekil 4.13. 2,3 MW ve 3 MW için eşitlenmiş güç eğrileri

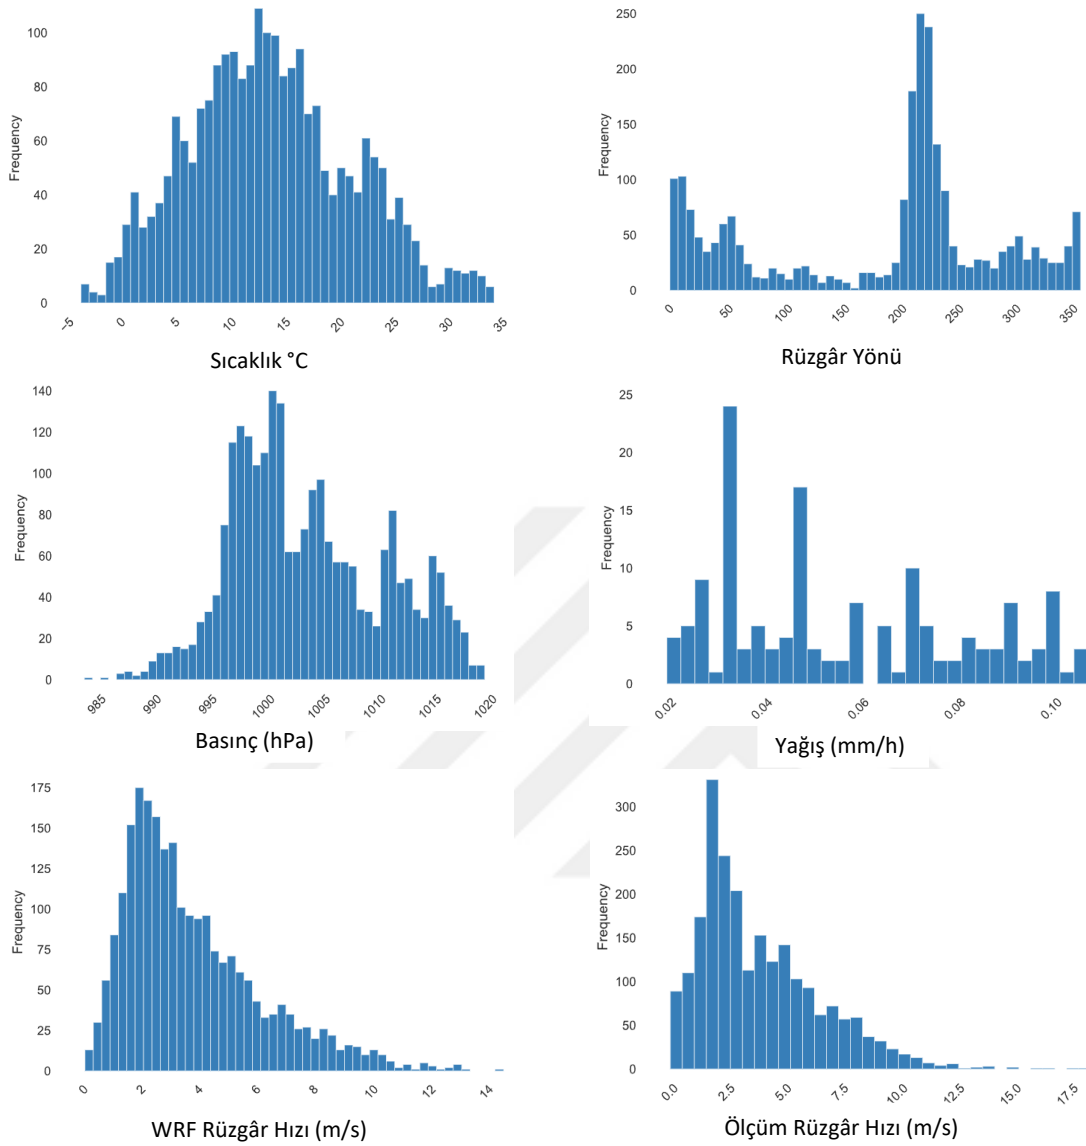


Şekil 4.14. Türkiye 2,3 MW rüzgar gücü üretim potansiyeli haritası



Şekil 4.15. Türkiye 3 MW rüzgar gücü üretim potansiyeli haritası

LSTM girdi parametrelerinin nicel (Çizelge 4.6) incelendiğinde sıcaklık verilerinin ortalama değeri medyan değerine oldukça yakın görünse de minimum ile maksimum değerler arasındaki büyük fark, veri setindeki geniş bir dağılıma işaret etmektedir. Bu geniş dağılımın, sıcaklık verilerindeki çeşitliliği ve muhtemelen dönemsel değişkenlikleri yansıttığı öngörülmüştür.



Şekil 4.16. LSTM girdilerinin histogram ile dağılım grafikleri

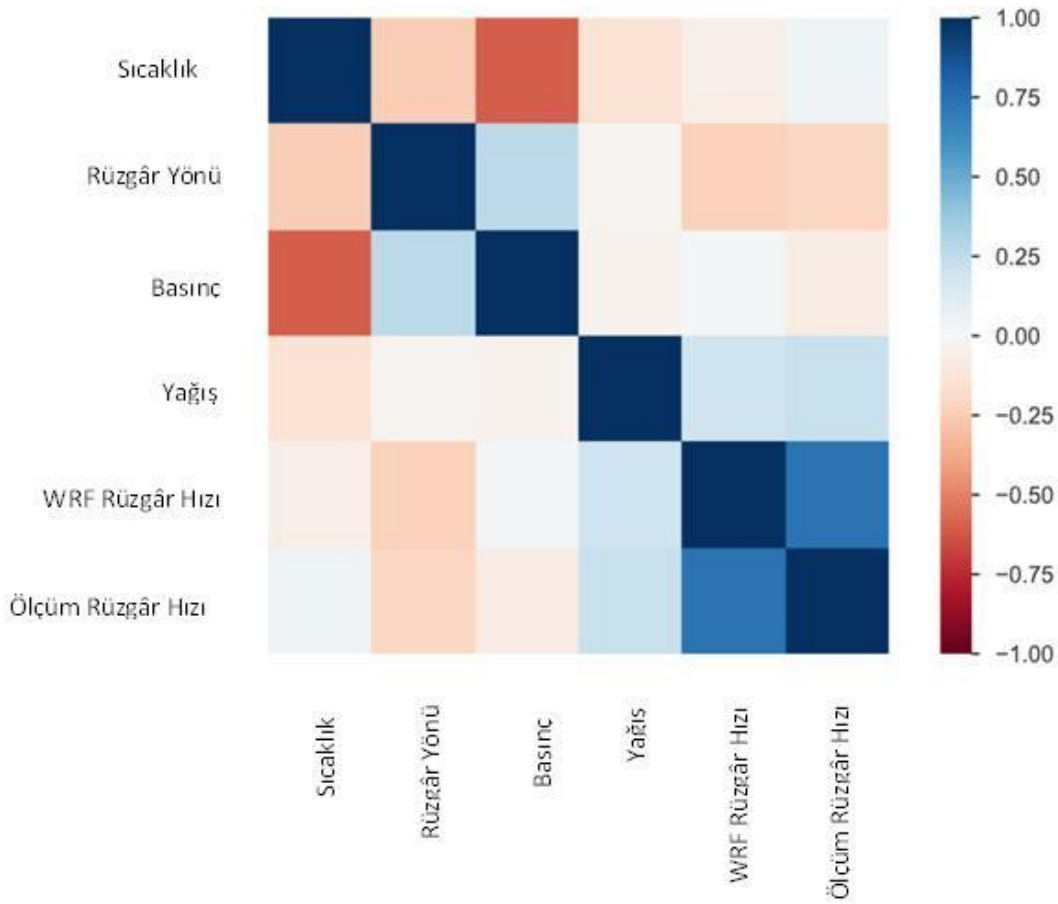
Basınç istatistikleri ise sıcaklık verilerine göre farklı olarak biraz daha yassı basık ve az bir miktar daha pozitif yönlü bir çarpıklığa sahip olmakla birlikte normal bir dağılıma sahiptir.

Yağış verileri ele alındığında en düşük standart sapmaya sahip olmakla beraber basıklık değeri en yüksek veridir ve sivri basıktır aynı zamanda en çarpık veridir ve bu çarpıklığın pozitif yönde olduğu tespit edilmiştir.

Rüzgar verileri ise WRF ve ölçüm hemen her istatistikte benzer verilere sahiptir. Her iki veri de kabul edilebilir sınırlar altına pozitif yönde çarpıklığa ve sivri basıklığa sahiptir bununla


birlikte ölçüm verilerininin WRF verilerine göre daha sivri bir basıklığa sahip olduğu görülmüştür.

LSTM girdilerinin Spearman korelasyon katsayısı analizine göre birbirleriyle olan ilişkileri (Şekil 4.17) görüldüğü gibi en yüksek korelasyonlar mavinin koyu tonlarındaki karelerde yüksektir. Grafiğin negatif ilişkili görünen barın alt kısmında kalan kısımlar ise daha sıcak renkler ile parametreler arasında olan daha düşük bir ilişkiyi temsil etmektedir. Yağış ile ölçülen rüzgar ve basınç ile rüzgar yönü aralarında pozitif ve anlamlı bir ilişki saptanırken, basınç ve sıcaklık arasında negatif bir ilişki saptanmıştır.




Şekil 4.17. LSTM girdilerinin Spearman korelasyon katsayısı grafiği

LSTM için uygun görülen ilin rüzgar ölçüm hızları (Şekil 4.18), normal dağılım basıklığı ve çarpıklığı sırasıyla 1,409 ve 1,073 olarak hesaplanmıştır. Hesaplamalar ve grafikte de görüldüğü üzere pozitif yönde ufak bir çarpıklık mevcuttur ve bu nedenle normal bir dağılıma sahiptir bununla birlikte grafik sivri basık olarak adlandırılan şekilde bir basıklığa sahiptir.



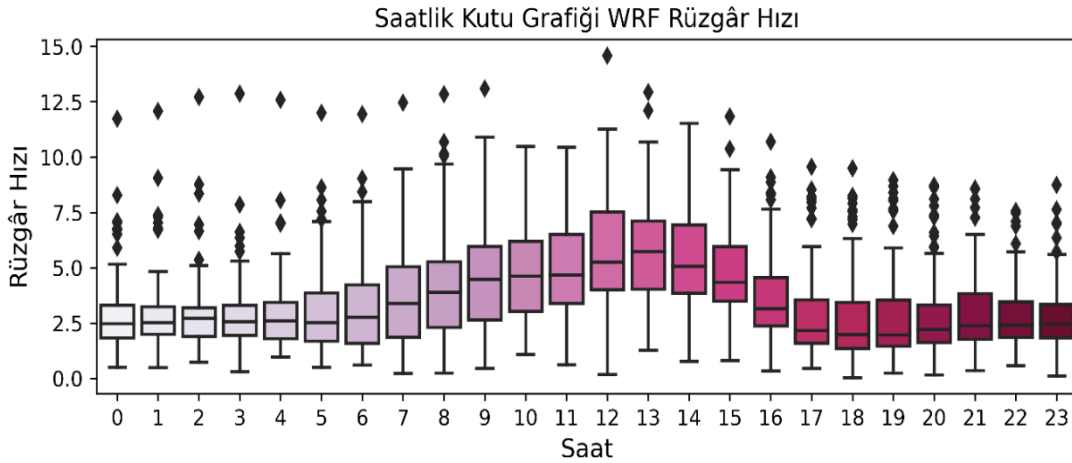
Şekil 4.18. Rüzgar ölçüm hızının dağılım grafiği

Rüzgar hızının saatlik dağılımları incelendiğinde (Şekil 4.19 ve 4.20), ölçüm ve WRF modeli tahminleri benzerlik göstermektedir. Gün saatlerinde öğlen saatlerine doğru bir artış gözlemlenirken gece saatlerine doğru bu durumun azalarak genellikle sabah saatlerindeki hızlara yaklaştığı tespit edilmiştir.



Şekil 4.19. Rüzgar hızı ölçümünün saatlik dağılımları

Grafikte günün ilk çeyreğine kadar medyanlar aynı hizada iken öğle ve akşam yediye kadar olan zaman diliminde ve özellikle öğle vakti medyanlar farklılaşmış, yediden itibaren tekrar birbirine yaklaşarak normalleştiği görülmüştür.




Şekil 4.20. WRF Rüzgar hızı tahmininin saatlik dağılımları


Gece vakitleri veriler daha birbirlerine yakın ve daha az dağılmış bir durumda iken günün geri kalan vakitlerinde veriler daha geniş bir alana yayılarak daha dağınık bir yapıda gözlemlenmiştir.

Ekstrem durumlar yani aykırı değerler, rüzgar hızı ölçümlerinde birbirine benzer şekilde en fazla gece ve akşam vakitlerinde gözlemlenirken WRF tahminlerinde akşam vakitlerinde daha fazla aykırı değer tespit edilmiştir bununla birlikte ölçüm verileri çoğunlukla alt limite yaklaşarak pozitif bir eğiklik meydana getirirken WRF tahminlerinde ise önemli ölçüde simetrik ve normal durumlar daha fazla gözlenmiştir.

Yılın ilk yarısında (Şekil 4.21 ve 4.22) en yüksek seviyeye ulaşan rüzgar hızı, sonraki yarım dönemde rezonans etkileriyle azalma eğilimi göstermektedir. Bu eğilim, mevsimsel etkiler ve sıcaklık farkları tarafından yönlendirilen bir trend oluşumu ile uyumlu bir şekilde meydana gelir. Mevsimsel etkiler, belli haftalarda değişkenlik gösterse de genellikle belirli bir ortalama değere yakınsar ve genellikle rüzgar hızının ana etkeni değildir. Rezidüel analizi, rüzgar hareketlerinin kalıcılığını ve zamansal uzantılarını anlamamıza yardımcı olur. Göstergeler, mevsimsel koşullardan mikro düzeyde etkilense de trend kanalı güçlendikten sonra istikrarlı bir görünüm kazanır bununla birlikte hem ölçüm hem de WRF tahminlerinde kış aylarından yaza doğru rüzgar hızları trendinde azalarak sabitleşen bir yönelim söz konusudur. Aylık ve mevsimsel olarak anormal bir durum gözlenmemiştir.




Şekil 4.21. Yıllık rüzgar hızı ölçümünün dönemsel trend, rezidüel mevsimsel değişimleri




Şekil 4.22. Yıllık rüzgar hızı ölçümünün dönemsel trend, rezidüel mevsimsel değişimleri

WRF tahmin modeli burada (Şekil 4.23) gerçekten başarılı bir performans ortaya koymuştur.

Tutarlı tahminler için hibrit modeller bu vakada da benzer şekilde sonuçları iyileştiren bir yönde etki göstermiştir. WRF tahminleri de LSTM modeline eklendiğinde (Şekil 4.24) model gözlem verilerine çok daha yakın sonuçlara ulaşmaktadır. Ortalama mutlak hata ve ortalama karekök hatası hata değerlendirmeleri sırasıyla 0,039 ve 0,054 değerlerine gerileyerek gelişmiştir, bununla birlikte R^2 değerinde bir iyileşme gözlemlenmiş ve 0,67 değerine ulaşılmıştır.



Şekil 4.23. WRF tahmini ve gözlenen rüzgar hızları



Şekil 4.24. WRF ve LSTM hibrit tahmini ve gözlenen rüzgar hızları

Şahin, Bilgili ve Akıllı (2005), Doğu Akdeniz'deki rüzgar verilerini WASP modeli ile incelemiştir. Hatay bölgesinde rüzgar hızı ve güç üretim potansiyelini değerlendirmişler ve Samandağ bölgesinde rüzgar hızının günün %72'sinde 3 m/s ve üzerinde olduğunu tespit etmişlerdir. Araştırmacıların bu bulguları Hatay ilinde yapılan saatlik rüzgar hızı ölçüm verilerine benzerlik göstermektedir.

Mentes ve diğerleri (2012), Manisa bölgesinde üç günlük bir zaman diliminde yaptıkları çalışmada, WRF ve WindSim modellerini kullanmışlardır. Bu çalışmada elde edilen

sonular, 1,28 ile 2,46 arasında deęişen mutlak hata deęerlerine sahiptir. MISO yapay sinir aęı ise 0,92 ile 0,98 arasında korelasyon katsayısına sahip olup iki gnlk bir eęitim sresi kullanılmıřtır. Bu alıřmada farklı veri setleri, model parametreleri, konum ve alıřma sresi gibi faktrler sonuların farklı olmasına neden olabilir.

Hu ve Chen (2018) in'de gerekleřtirdięi alıřmada, WRF olmadan da birok farklı LSTM kombinasyonu denenerek benzer sonulara ulařılmıřtır. Burada kullanılan veri setinin byklę ve btnlę korunarak daha iyi eęitilmiř modeller retilabilir. Daha az hataya sahip byk veri setleri rzgarın yapay zeka tarafından daha iyi analiz edilerek ęrenilmesine imkan saęlayabilir.

Groch ve Vermeulen (2019) yaptıkları alıřmada, ileri beslemeli bir Sinir Aęı (NN) kullanıldıęı iin model rzgar karakteristięini yeterince ęrenememiř olabilir. Zaman serilerinde geri beslemeli modeller daha iyi sonu vermektedir. Bu alıřmada rzgar yn ve sıcaklık da yksek korelasyonlarından dolayı parametre olarak eklenmiřtir. Bizim alıřmamızda parametre olarak tercih edilen fakat doęrudan yksek korelasyona sahip olmasa da sonuca olumlu etki eden parametreler ve WRF tahminlerinden de elde edilen girdilerden yararlandık bu da daha iyi tahminler yapmamızda etkili olmuř olabilir.

Wei (2020) yaptıęı alıřmada, Stacked-LSTM ve 50 nron ile daha farklı sonulara ulařmıřtır. LSTM girdilerinin karakteristięini kaybetmeden seilecek uygun zaman adımı ve aynı řekilde rzgarın gn iindeki hareketlerinin doęru analiz edilerek seilecek geri bakma adımı parametresi ve konum olarak WRF modelinin bařarılı tahmin yaptıęı bir blgenin yapay zeka iin seilmesi gibi kullandıęımız etkenler sonuların bir miktar farklı olmasında etkili olmuř olabilir.

Feroz, Javed, Syed, Kazmi ve Uddin (2020), Pakistan'da yaptıkları alıřmada 0,5 derecelik GFS bařlangı znrlęyle yaz ve kıř aylarının ilk ayının bir haftalık sre aralıęındaki etkilerini incelemiřler ve 1,20 ile 1,87 arasında MAE deęerlerine ulařmıřlardır. Bařlangı kořulları, model parametreleri ve topoęrafyadaki farklılıklar sonuları etkileyebilir.

Tan ve dięerleri (2021), Manisa blgesinde ECMWF verilerini kullanarak benzer bir alıřma yapmıřlardır. Bu alıřmanın sonuları, rzgar hızı tahminlerinde 0,89 ile 0,92 arasında bir

İndeks Uygunluk performansına sahiptir. Ölçüm verileri ile model tahminleri arasındaki farklılıklar sonuçları etkileyebilir.

Devrim ve Sakallı (2021), Hatay bölgesinde WRF modeli kullanarak bir aylık bir çalışma gerçekleştirmişler ve değerlendirmede 0,92 korelasyon katsayısına ulaşmışlardır. Bu çalışmadaki, zamansal çözünürlük, çalışma süresi ve model parametrelerindeki farklılıkların, sonuçlardaki farklılıklara neden olduğu düşünülmektedir.

Jacondino ve diğerleri (2021), Brezilya'da rüzgar hızı için yaptıkları çalışmada saatlik ölçümler ve aylık değerlendirmeler sonucunda 1,1 MAE değerine ulaşmışlardır. Bu değer, sizin yıllık 1,35 MAE değerimize yakındır. Coğrafi farklılıklar, model şemaları ve parametrelerdeki farklılıklar her bölge için farklı tahminler üretebilir ve sonuçları etkileyebilir.

Christoforou ve diğerleri (2021)'nin yaptığı çalışmada sadece LSTM ile farklı bir tahmin başarımına ulaşmıştır. Hibrit bir model kullanmaması bu duruma sebep olmuş olabilir. Bazı durumlarda nöron ve katman sayılarındaki fazlalık ve parametrelerin fazla olması modelde karışıklıklara performans kaybına sebebiyet verebilir bununla birlikte modele ekstradan eklediğimiz sigmoid fonksiyonunun ise yapılan testlerde sonuçlara az da olsa olumlu bir etki ederek daha iyi bir tahmin yapmamıza olanak sağlamıştır.

Dupuy ve diğerleri (2021) tarafından bir sinir ağı kullanarak yapılan çalışmada iyi sonuçlara ulaşmıştır. Bizden farklı olarak eğitim verisi %60 olarak tercih edilmiştir, bizim çalışmamızda ise eğitim grubuna çok daha yüksek bir oranda ayırma işlemi gerçekleştirilmiştir. Aşırı öğrenmeden de kaçınarak yüksek öğrenme oranlarıyla eğitilmiş modeller daha yüksek doğrulukta tahminler yapabilmektedir.

Shao, Song, Bian ve Zhao (2021) tarafından gerçekleştirilen çalışmada birçok farklı LSTM seçeneği test edilerek uygulanmış hibrit modelde anlamlı sonuçlara ulaşılmıştır. Farklı geriye bakma penceresi değerleri modelin eğitilmesi ve model sonuçlarına doğrudan etki etmektedir.

Özdemir ve Sakallı (2023) tarafından gerçekleştirilen bir çalışma, Türkiye'nin altı farklı bölgesini içeren sıcaklık, yağış ve rüzgar hızı tahminlerini ele almış ve eğri eşitleme yöntemi

kullanarak Türkiye'nin 2,3 MW ve 3 MW'lık rüzgar gücü üretim potansiyeli tahminlerini incelemiştir. Bu çalışma, orta ve uzun vadeli enerji yatırımları için uygun bir alternatif kaynağın Türkiye için sağlanabileceğini belirtmiştir. Çalışma sonuçlarına göre en başarılı tahminler Çanakkale bölgesinde elde edilmiş, WRF modeline dayalı yıllık rüzgar hızı tahminlerinde sırasıyla 1,35 MAE ve 0,87 IOA değerleri tespit edilmiştir.



5. SONUÇ VE ÖNERİLER

Rüzgar enerjisi yatırımları, yüksek maliyetlerle karşılaşmaktadır ve bu alandaki en büyük zorluklardan biri, doğru ve sürekli rüzgar hızı ölçüm verilerine erişmek ve bu verileri analiz etmektir. Ölçümler, maliyet ve zaman açısından rüzgar enerjisi projelerini zorlaştırmaktadır ve her bölgede ölçüm yapmak mümkün olamamaktadır. Bu nedenle, rüzgar bileşenlerinin doğru ve hızlı bir şekilde tahmin edilmesi, enerji santrali yatırımları ve enerji piyasaları için büyük önem taşımaktadır.

Bu çalışmada seçilen başlangıç koşulları ve uygun parametrelerle yapılan WRF model tahminleri ile ölçüm verilerinin analizi sonucunda, Türkiye'de 2,3 MW ve 3 MW rüzgar güç üretim potansiyelinin tahmin edildiği görülmektedir. 2,3 MW'lık üretim bölgeleri mevcutken güç üretim haritalarının incelenmesi, uzun vadede 3 MW'lık yatırımların daha verimli sonuçlar verebileceğini göstermektedir bunula birlikte yapay zeka destekli hibrit tahmin modellerinin daha başarılı sonuçlar ortaya koyarak tahmin performansı ve RES optimizasyonlarında fayda sağlayabileceği de göz önünde bulundurulmalıdır. Ayrıca, kara üzerindeki kurulumlar dışında su üzerindeki hibrit kurulumlar için de Türkiye'nin iyi bir potansiyele sahip olduğu görülmektedir. Gelecekteki araştırmalarda, bu potansiyel daha detaylı bir şekilde incelenerek dalga ve akıntı enerjileri ile rüzgar ve güneş enerjilerini bir araya getiren hibrit kurulumlar için uygun bölgeler belirlenebilir.

KAYNAKLAR

- Bilal, M., Solbakken, K. ve Birkelund, Y. (2016). Wind speed and direction predictions by WRF and WindSim coupling over Nygårdstjønn. *Journal of Physics: Conference Series* 753(8), 082018.
- Bodini, N., Hu, W., Optis, M., Cervone, G. ve Alessandrini, S. (2021). Assessing boundary condition and parametric uncertainty in numerical weather prediction modeled, long term offshore wind speed through machine learning and analog ensemble. *Wind Energy Science*, 6(6), 1363-1377.
- Bordoni, S. ve Giagu, S. (2023). Convolutional neural network based decoders for surface codes. *Quantum Information Processing*, 22(3), 151.
- Carvalho, D., Rocha, A., Gómez Gesteira, M. ve Santos, C. (2012). A sensitivity study of the WRF model in wind simulation for an area of high wind energy. *Environmental Modelling & Software*, 33, 23-34.
- Carvalho, D., Rocha, A. M. A. C., Gómez-Gesteira, M. ve Santos, C. S. (2014). Sensitivity of the WRF model wind simulation and wind energy production estimates to planetary boundary layer parameterizations for onshore and offshore areas in the Iberian Peninsula. *Applied Energy*, 135, 234-246.
- Christoforou, E., Emiris, I. Z., Florakis, A., Rizou, D. ve Zaharia, S. (2021). Spatio temporal deep learning for day ahead wind speed forecasting relying on WRF predictions. *Energy Systems*, 1, 21.
- Crippa, P., Alifa, M., Bolster, D., Genton, M. G. ve Castruccio, S. (2021). A temporal model for vertical extrapolation of wind speed and wind energy assessment. *Applied Energy*, 301, 117378.
- Devrim, M. A. ve Sakalli, A. (2021). Estimation of wind speed and energy potential by atmospheric model for day ahead market and wind power plants in Turkey. *In IOP Conference Series: Materials Science and Engineering*, 1032(1), 012042.
- Di, Z., Ao, J., Duan, Q., Wang, J., Gong, W., Shen, C. ve Liu, Z. (2019). Improving WRF model turbine height wind speed forecasting using a surrogate based automatic optimization method. *Atmospheric Research*, 226, 1-16.
- Donadio, L., Fang, J. ve Porté-Agel, F. (2021). Numerical weather prediction and artificial neural network coupling for wind energy forecast. *Energies*, 14(2), 338. doi.org/10.3390/en14020338
- Dupuy, F., Duine, G. J., Durand, P., Hedde, T., Pardyjak, E. ve Roubin, P. (2021). Valley winds at the local scale: Correcting routine weather forecast using artificial neural networks. *Atmosphere*, 12(2), 128.
- Edmonds, J. (1965). Paths, trees, and flowers. *Canadian Journal of mathematics*, 17, 449-467.

- Feroz, R. M. A., Javed, A., Syed, A. H., Kazmi, S. A. A. ve Uddin, E. (2020). Wind speed and power forecasting of a utility scale wind farm with inter farm wake interference and seasonal variation. *Sustainable Energy Technologies and Assessments*, 42, 100882.
- Giannakopoulou, E.M. ve Nhili, R. (2014). WRF model methodology for offshore wind energy applications. *Advances in Meteorology*.
- Groch, M. ve Vermeulen, H. J. (2019, December). Wind speed event forecasting using a hybrid WRF and ANN model. In *2019 9th International Conference on Power and Energy Systems (ICPES) IEEE*, 1-6.
- Guo, Z. ve Xiao, X. (2014, January). Wind power assessment based on a WRF wind simulation with developed power curve modeling methods. In *Abstract and Applied Analysis*, Hindawi.
- Han, Y., Mi, L., Shen, L., Cai, C. S., Liu, Y. ve Li, K. (2022). A short-term wind speed interval prediction method based on WRF simulation and multivariate line regression for deep learning algorithms. *Energy Conversion and Management*, 258, 115540.
- Holley, J. W. ve Guilford, J. P. (1964). A note on the G index of agreement. *Educational and psychological measurement*, 24(4), 749
- Hu, Y. L. ve Chen, L. (2018). A nonlinear hybrid wind speed forecasting model using LSTM network, hysteretic ELM and Differential Evolution algorithm. *Energy conversion and management*, 173, 123-142.
- Jacondino, W. D., da Silva Nascimento, A. L., Calvetti, L., Fisch, G., Beneti, C. A. A. ve da Paz, S. R. (2021). Hourly day ahead wind power forecasting at two wind farms in northeast Brazil using WRF model. *Energy*, 230, 120841.
- Jiang, P., Liu, Z., Niu, X. ve Zhang, L. (2021). A combined forecasting system based on statistical method, artificial neural networks, and deep learning methods for short-term wind speed forecasting. *Energy*, 217, 119361.
- Koivisto, M., Plakas, K., Ellmann, E. R. H., Davis, N. ve Sørensen, P. (2021). Application of microscale wind and detailed wind power plant data in large-scale wind generation simulations. *Electric Power Systems Research*, 190, 106638.
- Li, F., Ren, G. ve Lee, J. (2019). Multi-step wind speed prediction based on turbulence intensity and hybrid deep neural networks. *Energy conversion and management*, 186, 306-322.
- Li, Y., Dai, C., Wang, T., Zhou, Z., Zhou, S., Cai, L. ve Lozowski, E. (2016, March). Separate wind power and ramp predictions based on meteorological variables and clustering method. In *2016 IEEE 6th International Conference on Power Systems (ICPS) IEEE*, 1-6.

- Liu, X., Zhang, L., Zhang, Z., Zhao, T. ve Zou, L. (2021). Ultra Short term wind power prediction model based on WRF wind speed prediction and Catboost. *In IOP Conference Series: Earth and Environmental Science*, 838(1), 012001.
- Martínez-Arellano, G. ve Nolle, L. (2013, December). Genetic programming for wind power forecasting and ramp detection. *In International Conference on Innovative Techniques and Applications of Artificial Intelligence*, Springer, Cham., 403-417.
- Men, Z., Yee, E., Lien, F. S., Wen, D. ve Chen, Y. (2016). Short term wind speed and power forecasting using an ensemble of mixture density neural networks. *Renewable Energy*, 87, 203-211
- Mentes, S., Tan, E., Ozdemir, T., Unal, E., Unal, Y., Efe, B. ve Borhan, Y. (2021.) Short term wind power forecast in Manisa, Turkey by using the WRF model coupled to a cfd model. *Conference: EWRES & ECRES The European Workshop & Conference on Renewable Energy Systems*, 17-28.
- Niu, D., Pu, D. ve Dai, S. (2018). Ultra-short-term wind-power forecasting based on the weighted random forest optimized by the niche immune lion algorithm. *Energies*, 11(5), 1098.
- O'Brien, T. E., Tarasinski, B. ve DiCarlo, L. (2017). Density-matrix simulation of small surface codes under current and projected experimental noise. *npj Quantum Information*, 3(1), 39.
- Oetl, D. ve Veratti, G. (2021). A comparative study of mesoscale flow field modelling in an Eastern Alpine region using WRF and GRAMM SCI. *Atmospheric Research*, 249, 105288.
- Özdemir, F. F. ve Sakallı, A. (2023). Türkiye'nin rüzgar enerji potansiyelinin sayısal hava tahmin sistemi ile simülasyonu ve analizi. *Avrupa Bilim ve Teknoloji Dergisi*, (46), 179-192.
- Özen, C., Dinç, U., Deniz, A. ve Karan, H. (2021). Wind power generation forecast by coupling numerical weather prediction model and gradient boosting machines in Yahyalı wind power plant. *Wind Engineering*, 45(5), 1256-1272.
- Prieto-Herráez, D., Frías Paredes, L., Cascón, J. M., Lagüela López, S., Gastón Romeo, M., Asensio Sevilla, M. I. ve González Aguilera, D. (2021). Local wind speed forecasting based on WRF HDWind coupling. *Atmospheric Research*, 248, 105219.
- Ragheb, M. ve Ragheb, A. M. (2011). Wind turbines theory-the betz equation and optimal rotor tip speed ratio. *Fundamental and advanced topics in wind power*, 1(1), 19-38.
- Salamanca, F., Zhang, Y., Barlage, M., Chen, F., Mahalov, A. ve Miao, S. (2018). Evaluation of the WRF-urban modeling system coupled to Noah and Noah-MP land surface models over a semiarid urban environment. *Journal of Geophysical Research: Atmospheres*, 123(5), 2387-2408.

- Salazar, A. A., Che, Y., Zheng, J. ve Xiao, F. (2021). Multivariable neural network to postprocess short-term, hub-height wind forecasts. *Energy Science & Engineering*.
- Salfate, I., Marin, J. C., Cuevas, O. ve Montecinos, S. (2020). Improving wind speed forecasts from the Weather Research and Forecasting model at a wind farm in the semiarid Coquimbo region in central Chile. *Wind Energy*, 23(10), 1939-1954.
- Shao, B., Song, D., Bian, G. ve Zhao, Y. (2021). Wind speed forecast based on the LSTM neural network optimized by the firework algorithm. *Advances in Materials Science and Engineering*, 2021, 1-13.
- Sayeed, A., Choi, Y., Jung, J., Lops, Y., Eslami, E. ve Salman, A. K. (2020). A deep convolutional neural network model for improving WRF forecasts. *IEEE Transactions on Neural Networks and Learning Systems*, 6489.
- Şahin, B., Bilgili, M. ve Akıllı, H. (2005). The wind power potential of the eastern Mediterranean region of Turkey. *Journal of Wind Engineering and Industrial Aerodynamics*, 93(2), 171-183.
- Tan, E., Menten, S. S., Unal, E., Unal, Y., Efe, B., Barutcu, B. ve Incecik, S. (2021). Short term wind energy resource prediction using WRF model for a location in western part of Turkey. *Journal of Renewable and Sustainable Energy*, 13(1), <https://doi.org/10.1063/5.0026391>
- Teixeira, R. S., Santos Conterato, F., Maria, P., Dias, A., Kaore, Y. ve Kitagawa, L. (2020). Hybrid model of wind speed prediction in short time range using WRF and artificial neural networks. *VI International Symposium on Innovation and Technology (SIINTEC)*.
- Thompson, R. D. (2002). Atmospheric Processes and systems. *Routledge*, London. <https://doi.org/10.4324/9780203015872>, pp: 224.
- Türkiye Rüzgar Enerjisi Birliği, (2021). Türkiye Rüzgar Enerjisi İstatistik Raporu: Temmuz 2021. URL: <https://tureb.com.tr/lib/uploads/55081baf3b9a1091.pdf> Son Erişim Tarihi: 17.11.2022
- Xiong, X., Zou, R., Sheng, T., Zeng, W. ve Ye, X. (2023). An ultra-short-term wind speed correction method based on the fluctuation characteristics of wind speed. *Energy*, 129012.
- Xu, W., Liu, P., Cheng, L., Zhou, Y., Xia, Q., Gong, Y. ve Liu, Y. (2021). Multi-step wind speed prediction by combining a WRF simulation and an error correction strategy. *Renewable Energy*, 163, 772-782.
- Wei, C. C. (2020). Development of stacked long short term memory neural networks with numerical solutions for wind velocity predictions. *Hindawi Advances in Meteorology*, Article ID 5462040, 2020, 18. doi.org/10.1155/2020/5462040

Zhao, J., Guo, Z. H., Su, Z. Y., Zhao, Z. Y., Xiao, X. ve Liu, F. (2016). An improved multi-step forecasting model based on WRF ensembles and creative fuzzy systems for wind speed. *Applied Energy*, 162, 808-826.

Zhao, J., Guo, Y., Xiao, X., Wang, J., Chi, D. ve Guo, Z. (2017). Multi step wind speed and power forecasts based on a WRF simulation and an optimized association method. *Applied Energy*, 197, 183-202.



DİZİN

A

Anahtar kelimeler iv
 Abstract v
 Araştırma Bulguları ve Tartışma
 18

B

Bilal 15, 40
 Bodini 11, 15, 40
 Bordoni 5, 6, 40

C

Crippa 10, 40
 Carvalho 2, 5, 8, 15, 16, 40

Ç

Çizelge viii, 3, 4, 13, 14, 15, 17,
 18, 20, 21, 26, 29

D

Donadio 10, 40
 Dupuy 5, 12, 15, 37, 40
 Devrim 37, 40

E

Eşitlik (Eş.) 2, 6, 14
 Edmonds 7, 40

F

Feroz 36, 41

G

Giriş 1
 Guo 1, 2, 5, 8, 41
 Groch 2, 9, 15, 36, 41
 Giannakopoulou 15, 41

H

Hu 36, 41

İ

İçindekiler vii

J

Jiang 2, 12, 15, 41
 Jacondino 37, 41

K

Key Words v
 Kaynaklar 40
 Koivisto 11, 41

L

Liu 11, 41

M

Martinez-Arellano 5, 8, 41
 Men 8, 15, 42
 Mentés 35, 42
 Materyal ve Metod 13

N

Niu 7, 9, 42

O

O'Brien 6, 42
 Oettl 15, 42

Ö

Önceki çalışmalar 8
 Özen 10, 15, 42
 Özet iv
 Özdemir 12, 38, 42

P

Prieto-Herráez 15, 42

R

Ragheb 2, 42

S

Simgeler ve kısaltmalar xi
 Salamanca 15, 43
 Salazar 1, 11, 15, 43
 Salfate 5, 10, 15, 43
 Sayeed 2, 5, 10, 43
 Sonuç ve Öneriler 39
 Sakallı vi, 12, 37, 38, 42

Ş

Şahin 35, 43

T

Tan 12, 15, 43
 Teixeira 1, 9, 15, 43
 TUREB xiii, 3, 4, 43
 Teşekkür vi

U

Ucuz 2
 Uzantı 33

X

Xu 1, 11, 15, 43

W

Wei 9, 15, 36, 43

Y

Y.Li 8, 41

Z

Zhao 4, 8, 9, 15, 43



TEKNOVERSITE



teknoversite **AYRICALIĞINDASINIZ**

İSTE

